

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**MOTOR HAYAL EEG İŞARETLERİNİN KAYNAK YERELLEŞTİRME KULLANARAK  
SINIFLANDIRILMASI**

**DOKTORA TEZİ**

**Bilgisayar Yük. Müh. Mustafa YAZICI**

**MAYIS 2021  
TRABZON**



**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**MOTOR HAYAL EEG İŞARETLERİNİN KAYNAK YERELLEŞTİRME KULLANARAK  
SINIFLANDIRILMASI**

**Bilgisayar Yük. Müh. Mustafa YAZICI**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde**  
**DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)**  
**Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 02 / 10 / 2020**

**Tezin Savunma Tarihi : 24 / 05 / 2021**

**Tez Danışmanı : Prof. Dr. Mustafa ULUTAŞ**

**Trabzon 2021**

## ÖNSÖZ

Bu tez çalışmasında, Motor Hayali esnasında saçlı kafa derisine 10-20 sisteminde yerleştirilen elektrotlar yardımıyla kaydedilen EEG sinyalleri ile işlemler yapılmıştır. EEG işaretlerini oluşturan kortikal kaynak uzayındaki potansiyellerin geri problem çözümüyle elde edilmesinden sonra, nöroanatomik ve nörofizyolojik bilgiler yardımıyla farklı motor hayalindeki sinyallerin ayırt edilmesi üzerine çalışılmıştır.

Akademik hayata başladığım dönemden itibaren hem yüksek lisans ve hem de doktora çalışmalarında bilimsel desteği, anlayışı ve yönlendirici fikirleriyle bana yardımcı olan ve yol gösteren danışmanım Prof. Dr. Mustafa ULUTAŞ'a, yine tez çalışmam süresince değerli katkılarda bulunan Prof. Dr. Cemal KÖSE ve Prof. Dr. İsmail KAYA'ya ve tez jürisindeki Prof. Dr. Rıfat YAZICI ve Prof. Dr. Tülay YILDIRIM'a çok teşekkür ederim. Tezin daha kapsamlı olması için tıbbi konularda danışmanlığımızı karşılıksız ve en özverili şekilde yapan Doç. Dr. Mukadder OKUYAN hocama da çok teşekkür ederim.

Tez düzeninde fikirleriyle yanımda olan Dr. Öğr. Üyesi Sultan ZAVRAK'a ve Öğr. Gör. Dr. Emre GÜRBÜZ'e çok teşekkür ederim.

Tüm eğitim-öğretim hayatımda benden hiçbir desteği esirgemeyen kıymetli aileme ve arkadaşlarıma da teşekkürü bir borç bilirim.

Bu tezin bundan sonraki çalışmalara faydalı olmasını dilerim.

Mustafa YAZICI

Trabzon 2021

## **TEZ ETİK BEYANNAMESİ**

Doktora Tezi olarak sunduđum “MOTOR HAYAL EEG İŐARETLERİNİN KAYNAK YERELLEŐTİRME KULLANARAK SINIFLANDIRILMASI” baŐlıklı bu alıŐmayı baŐtan sona kadar danıŐmanım Prof. Dr. Mustafa ULUTAŐ’ın sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, baŐka kaynaklardan aldıđım bilgileri metinde ve kaynakada eksiksiz olarak gösterdiđimi, alıŐma sürecinde bilimsel araŐtırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya ıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 24/05/2021

Mustafa YAZICI

# İÇİNDEKİLER

## Sayfa No

TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	XI
SUMMARY.....	XII
ŞEKİLLER DİZİNİ.....	XIII
TABLolar DİZİNİ.....	XVI
SEMBOLLER DİZİNİ.....	XVII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Beyin Bilgisayar Arayüzü Motivasyonu.....	2
1.3. Elektroensefalografi (EEG).....	2
1.4. Nöron Fizyolojisi.....	3
1.4.1. Nöron Çeşitleri.....	3
1.4.1.1. Duyu Nöronları.....	3
1.4.1.2. Ara Nöronlar.....	4
1.4.1.3. Motor Nöronlar.....	4
1.5. Beyin ve Anatomisi.....	4
1.6. Beyin Nörogörüntüleme Teknikleri.....	7
1.6.1. EEG.....	8
1.6.1.1. Saçlı Deri EEG Kaydı.....	10
1.6.1.2. İntrakraniyal EEG (iEEG) Kaydı.....	10
1.6.1.3. EEG Dalgaları.....	10
1.6.1.3.1. Delta Dalgaları.....	10
1.6.1.3.2. Teta Dalgaları.....	11
1.6.1.3.3. Alfa Dalgaları.....	11
1.6.1.3.4. Beta Dalgaları.....	11
1.6.1.3.5. Gama Dalgaları.....	12
1.6.1.4. EEG Sinyallerine Eklenen Bozucu Etkiler ve Giderilmesine Dair Teknikler.....	12
1.6.1.4.1. EEG Önışlemleri.....	13

1.6.1.4.2.	Çentik Filtre .....	14
1.6.1.4.3.	Epok Alımı .....	14
1.6.1.4.4.	Yüksek Geçiren Filtre .....	14
1.6.1.4.5.	Alçak Geçiren Filtre .....	14
1.6.1.4.6.	Bant Geçiren Filtreler .....	14
1.6.1.5.	Geri Problem Çözümünü Etkileyen Parametreler .....	15
1.6.1.6.	Elektrot Yerleştirme Standartları .....	15
1.6.1.6.1.	Uluslararası 10-20 Sistemi .....	15
1.6.1.6.2.	Uluslararası 10-10 Sistemi .....	16
1.6.1.6.3.	Uluslararası 10-5 Sistemi .....	16
1.6.2.	Fonksiyonel Manyetik Rezonans Görüntüleme (fMRG) .....	17
1.6.3.	Manyetoensefalografi (Magnetoencephalography, MEG) .....	18
1.6.4.	Pozitron Emisyon Tomografisi (Positron Emission Tomography, PET) .....	18
1.6.5.	Tek Foton Emisyon Bilgisayarlı Tomografi (Single-Photon Emission Computed Tomography, SPECT) .....	18
1.6.6.	Bilgisayarlı Tomografi (BT) .....	19
1.6.7.	Manyetik Rezonans Görüntüleme (MRG) .....	19
1.6.8.	Beyin Görüntüleme Yöntemlerinin Çözünürlüklerinin Karşılaştırılması .....	19
1.7.	EEG Analiz Yazılımları .....	20
1.8.	Beyin Bilgisayar Arayüzleri .....	21
1.8.1.	BBA Nasıl Çalışır? .....	21
1.8.2.	BBA Performansını Etkileyen Parametreler .....	22
1.8.3.	Girişimsel (İnvazif) BCI .....	23
1.8.4.	Girişimsel Olmayan (Noninvazif) BBA .....	23
1.8.5.	Yarı Girişimsel BBA .....	23
1.8.6.	Beyin Bilgisayar Arayüzlerinde Hesaplamalı EEG Analizi .....	24
1.8.7.	Beyin Bilgisayar Arayüzlerinde Neden EEG Tercih Edilmelidir? .....	24
1.8.7.1.	Beyin Aktivitelerinin Ölçülmesi .....	25
1.8.8.	Motor Hayali (MH) .....	26
1.8.8.1.	Motor Hayalinde Neden EEG Tercih Edilmeli? .....	26
1.9.	Motor Hayali ile İlgili Beyin Bölgeleri .....	28
1.9.1.	Primer Motor Korteks .....	28
1.9.2.	Premotor Alan .....	28
1.9.3.	Suplementer Motor Alan .....	29

1.10.	Literatür .....	30
1.11.	Tezin Amacı .....	34
2.	YAPILAN ÇALIŞMALAR .....	36
2.1.	İleri ve Geri Problem Çözümü .....	36
2.1.1.	İleri Problem Çözümü .....	38
2.1.1.1.	Kafa Modelleri .....	39
2.1.1.1.1.	Analitik (Küresel) Kafa Modelleri .....	39
2.1.1.1.2.	Gerçekçi Kafa Modelleri .....	40
2.1.2.	Geri Problem Çözümü .....	42
2.1.2.1.	EEG Sinyalleri Kullanılarak Beyin Kaynak Yerelleştirilmesi .....	42
2.1.2.2.	Sınır Elemanlar Yöntemi (Boundary Element Method, BEM) .....	43
2.1.2.3.	Minimum Norm Yerelleştirme Teknikleri .....	43
2.1.2.4.	Standardized Low Resolution Brain Electromagnetic Tomography (sLORETA) .....	45
2.1.2.5.	Dynamic Statistical Parametric Mapping (dSPM) .....	47
2.1.2.6.	Dipolar Yöntem .....	47
2.2.	Brainstorm Yazılımı ile Kaynak Lokalizasyonu Adımları .....	49
2.3.	İletkenlik Değerlerinin Tahmin Edilmesi .....	50
2.3.1.	Beyin İletkenlik Değeri .....	50
2.3.2.	Beyin Omurilik Sıvısı (BOS) CSF .....	50
2.3.3.	Kafatası (Skull) .....	50
2.3.4.	Kafa Derisi (Scalp) .....	51
2.4.	EEG Sinyallerinin Ön İşlenmesi .....	51
2.4.1.	Özellik Seçimi .....	51
2.5.	Kullanılan Veri Tabanları .....	51
2.5.1.	Veri Kümesi 2a Motor Hayali (Data sets 2a: 4-class motor imagery) .....	52
2.5.1.1.	Veri Kaydı .....	53
2.5.2.	Veri Kümesi IVa (Data set IVa <motor imagery, small training sets>) .....	53
2.5.2.1.	Teknik Bilgiler .....	54
2.6.	Yapılan Çalışmaların Akış Diyagramı .....	54
2.7.	EMKG Çözümünün Başarılı ve Güvenilir Olması İçin Gerekli Parametreler .....	55
2.7.1.	Kafa Yüzeyine Yerleştirilen Elektrot Sayısı ve Pozisyonu .....	55
2.7.2.	Referans Elektrotun Seçimi .....	56
2.7.3.	Elektrot Tipi .....	56
2.7.4.	Epok Belirleme .....	57

2.7.5.	Varsayımların Geçerliliği .....	58
2.7.6.	Kafa Modelinin Uygun Seçimi .....	58
2.7.7.	Doğru MRG Kesitinin Seçilmesi .....	59
2.7.8.	Öziletkenlik Değerleri .....	59
2.7.9.	Elektrot Konumları ve Kafa Modelinin Çakıştırılması .....	59
2.7.10.	Geri Problem Algoritmasının Seçilmesi .....	60
2.7.11.	Denek Etkisi .....	60
2.8.	Özellik Çıkarma .....	60
2.8.1.	Ortak Uzamsal Örüntüler Yöntemi (OUÖ, Common Spatial Patterns, CSP) .....	60
2.9.	İlgili Bölge Seçimi .....	63
2.10.	Geri Problem Çözümü.....	64
2.11.	Sınıflandırma Yöntemleri.....	64
2.11.1.	Destek Vektör Makineleri .....	64
2.11.2.	Yapay Sinir Ağları (YSA).....	67
2.11.2.1.	YSA'ların Çalışma Mantığı .....	68
2.11.2.2.	Ağ Eğitimi.....	69
2.11.2.2.1.	Geri Yayılım Algoritması.....	70
2.11.2.3.	Normalizasyon .....	71
2.11.2.4.	Ağın Öğrenmesi .....	71
2.12.	Performans Ölçütü.....	78
3.	BULGULAR VE İRDELEME.....	80
3.1.	Veri Kümesi 2a ile Elde Edilen Doğruluk Oranları .....	81
3.2.	Veri Kümesi 4a ile Elde Edilen Doğruluk Oranları .....	84
3.3.	Veri Kümesi 2a Üzerinde Mü Bandı ile DVM Sınıflandırıcı Sonuçları .....	89
3.3.1.	Dipolar Yöntem.....	89
3.3.2.	dSPM Yöntemi.....	90
3.3.3.	Minimum Norm Yöntemi.....	91
3.3.4.	sLORETA Yöntemi.....	92
3.4.	YSA Sınıflandırıcı ile Veri Kümesi 2a Sonuçları .....	92
3.4.1.	Dipolar Yöntem.....	93
3.4.2.	dSPM Yöntemi.....	94
3.4.3.	Minimum Norm Yöntemi.....	94
3.4.4.	sLORETA Yöntemi.....	95
3.5.	DVM Sınıflandırıcı ile Veri Kümesi (Dataset) 4a Sonuçları .....	96



3.5.1.	Dipolar Yöntem.....	96
3.5.2.	dSPM Yöntemi.....	97
3.5.3.	Minimum Norm Yöntemi.....	98
3.5.4.	sLORETA Yöntemi.....	98
3.5.5.	Veri Kümesi 2a Üzerinde YSA Eğitimi Esnasında Oluşan Eğitim-Doğrulama için Hata-Epok Eğrileri .....	99
3.6.	YSA Sınıflandırıcı ile Veri Kümesi 4a Sonuçları .....	101
3.6.1.	Dipolar Yöntem.....	101
3.6.2.	dSPM Yöntemi.....	102
3.6.3.	Minimum Norm Yöntemi.....	102
3.6.4.	sLORETA Yöntemi.....	103
3.6.5.	Veri Kümesi 4a Üzerinde YSA Eğitimi Esnasında Oluşan Eğitim-Doğrulama için Hata-Epok Eğrileri .....	104
3.7.	DVM Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sağ Lop bölge Kombinasyonları ile Elde Edilen Başarı .....	106
3.7.1.	DVM Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular .....	106
3.7.2.	DVM Sınıflandırıcı ve dSPM Yöntem ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular .....	107
3.7.3.	DVM Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular .....	108
3.7.4.	DVM Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular.....	109
3.8.	DVM Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sol Lop bölge Kombinasyonları ile Elde Edilen Başarı .....	110
3.8.1.	DVM Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için ile Elde Edilen Bulgular .....	110
3.8.2.	DVM Sınıflandırıcı ve dSPM Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular .....	111
3.8.3.	DVM Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular.....	112
3.8.4.	DVM Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular.....	112
3.9.	YSA Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sağ Lop Bölge Kombinasyonları ile Elde Edilen Başarılar .....	113
3.9.1.	YSA Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular .....	113

3.9.2.	YSA Sınıflandırıcı ve dSPM Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular .....	114
3.9.3.	YSA Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular.....	115
3.9.4.	YSA Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular.....	116
3.10.	YSA Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sol Lop Bölge Kombinasyonları ile Elde Edilen Başarılar .....	117
3.10.1.	YSA Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular .....	117
3.10.2.	YSA Sınıflandırıcı ve dSPM Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular .....	118
3.10.3.	YSA Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular .....	118
3.10.4.	YSA Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular.....	119
4.	SONUÇLAR .....	120
5.	ÖNERİLER VE TARTIŞMA .....	125
6.	KAYNAKLAR.....	128
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

MOTOR HAYAL EEG İŞARETLERİNİN KAYNAK YERELLEŞTİRME  
KULLANARAK SINIFLANDIRILMASI

Mustafa YAZICI

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı  
Danışman: Prof. Dr. Mustafa ULUTAŞ  
2021, 139 Sayfa

Beyin Bilgisayar Arayüzü (BBA), beyni ve harici bir cihazı birbirine bağlayan bir iletişim yöntemidir. BBA'ların tasarımı ve uygulanması disiplinler arası bir çalışma alanıdır. Amaç, nöromusküler hastalıkları veya engelleri olan kişilerin yaşam kalitesini iyileştirmektir. Ticari olarak temin edilebilen çok sayıda BBA vardır, ancak daha yüksek doğruluğa sahip kullanıcı dostu BBA'lar için hala büyük bir talep vardır. EEG sinyalleri yüksek zamansal çözünürlüğe sahip olmalarına rağmen, düşük uzaysal çözünürlüğe sahiptirler. Bu çalışmada, kafa derisinden alınan EEG sinyalleri EEG Kaynak Görüntüleme kullanılarak kortikal aktivasyonlara dönüştürülerek düşük uzaysal çözünürlük telafi edilmektedir. Kortikal kaynak sinyalleri, nöroanatomi ve nörofizyoloji bilgileri eklenerek başarılı bir şekilde sınıflandırılabilir. Bu tez, bilgisayar mühendisliği ve tıp biliminin fizyoloji bölümü ile çok disiplinli bir çalışmadır. Burada, motor hayaline karşılık gelen beyin bölgelerinden gelen kortikal sinyaller, nörogörüntüleme ile EEG sinyallerinin ayırt edilmesini geliştirebilmek için kullanıldı. Sonuç olarak, EEG kortikal sinyallerinin elektrot seviyesindeki sinyallere kıyasla başarılı bir şekilde sınıflandırılması gerçekleştirildi. Motor hayal bölgelerinde kişiler arası küçük farklılıklar da gözlemlendi.

**Anahtar Kelimeler:** EEG, Motor Hayali, EEG Kaynak Görüntüleme, EEG Nörogörüntüleme, Sinyal İşleme.

PhD. Thesis

SUMMARY

CLASSIFICATION OF MOTOR IMAGERY EEG SIGNALS USING SOURCE  
LOCALIZATION

Mustafa YAZICI

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Computer Engineering Graduate Program  
Supervisor: Prof. Dr. Mustafa ULUTAŞ  
2021, 139 Pages

Brain Computer Interface (BCI) is a communication method which links brain and an external device. Design and implementation of BCIs is an interdisciplinary field of study. The aim is to improve the quality of life of those with neuromuscular diseases or disabilities. There are many commercially available BCIs but, there is still a big demand for user friendly BCIs with higher accuracy. Although EEG signals have high temporal resolution, they have low spatial resolution. In this study, for low spatial resolution is compensated by converting the EEG signals received from the scalp into cortical activations using EEG Source Imaging. Cortical source signals can be classified successfully by adding neuro anatomy and neurophysiology information. This is a multi-disciplinary study with the computer engineering and physiology department of medical science. Here, cortical signals from brain regions corresponding to motor imagery is used to improve the discrimination on the EEG signals by neuroimaging. As a result, successful classification of the EEG cortical signals compared to the signals at the electrode level is accomplished. Minor interpersonal differences in motor imagery regions are also observed.

**Key Words:** EEG, Motor Imagery, EEG Source Imaging, EEG Neuroimaging, Signal Processing.

## ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Nöron Yapısı [8] .....	4
Şekil 2. Serebral korteksin görünümü [10] .....	5
Şekil 3. Serebrumun Lopları [12].....	6
Şekil 4. 10-20 uluslararası sisteme göre 19 elektrot konumları .....	9
Şekil 5. 10-10 EEG Uluslararası sistemi .....	16
Şekil 6. 10-5 EEG Uluslararası sistemi [23] .....	17
Şekil 7. Nörogörüntüleme yöntemlerinin uzamsal ve zamansal çözünürlükleri [33]. .....	20
Şekil 8. BBA teknolojisinde meydana gelen gelişmelerin tarihsel gösterimi [36] .....	22
Şekil 9. Kas Gruplarının gösterimi.....	30
Şekil 10. Nörogörüntüleme yöntemlerinin zamansal ve uzamsal çözünürlüklerinin gösterimi [11] .....	37
Şekil 11. İleri ve Geri Problem çözümü gösterimi [85] .....	38
Şekil 12. Üç tabakalı ve dört tabakalı kafa modelleri.....	40
Şekil 13. Kaynak Yeniden Yapılandırma Adımları [95].....	49
Şekil 14. Kayıtlar alınırken kullanılan paradigmanın zamanlama diyagramı .....	52
Şekil 15. Akış diyagramları Veri Kümesi 4a ve Veri Kümesi 2a.....	54
Şekil 16. Motor hayali ile ilgili kullanılan ilgili bölgeler Anastasiou vd. [133].....	63
Şekil 17. Destek Vektör Makinelerinde destek vektörlerin örnek bir gösterimi [138] .....	65
Şekil 18. Çalışmada kullanılan YSA modeli a) Keras çıktısı b) Graf gösterimi [150] .....	78
Şekil 19. Veri Kümesi 2a dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar .	90
Şekil 20. Veri Kümesi 2a dSPM yöntem ile mü bandı ve DVM ile elde edilen sonuçlar...	91
Şekil 21. Veri Kümesi 2a Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	91
Şekil 22. Veri Kümesi 2a sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	92
Şekil 23. Veri Kümesi 2a Dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar..	93
Şekil 24. Veri Kümesi 2a dSPM yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar...	94
Şekil 25. Veri Kümesi 2a Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar .....	95
Şekil 26. Veri Kümesi 2a sLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar .....	95

Şekil 27. Veri Kümesi 4a Dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar	97
Şekil 28. Veri Kümesi 4a dSPM yöntem ile mü bandı ve DVM ile elde edilen sonuçlar...	97
Şekil 29. Veri Kümesi 4a Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	98
Şekil 30. Veri Kümesi 4a sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	99
Şekil 31. a-i) Denek 1-9 için eğitim ve doğrulama (val) veri setlerine bağlı epok-hata grafikleri .....	100
Şekil 32. Veri Kümesi 4a Dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar	101
Şekil 33. Veri Kümesi 4a dSPM yöntem ile mü bandı ve YSA ile elde edilen sonuçlar..	102
Şekil 34. Veri Kümesi 4a Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar .....	103
Şekil 35. Veri Kümesi 4a sLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar .....	104
Şekil 36. Denek aa, al, av, aw ve ay için eğitim ve doğrulama (val) veri setlerine bağlı epok-hata grafikleri .....	105
Şekil 37. Veri Kümesi 4a sağ lop kombinasyonları, dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar .....	107
Şekil 38. Veri Kümesi 4a sağ lop kombinasyonları, dSPM yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	108
Şekil 39. Veri Kümesi 4a Sağ Lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	109
Şekil 40. Veri Kümesi 4a sağ lop kombinasyonları, sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	110
Şekil 41. Veri Kümesi 4a sol lop kombinasyonları, dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar .....	111
Şekil 42. Veri Kümesi 4a sol lop kombinasyonları, dSPM yöntem ile mü bandı ve DVM ile elde edilen sonuçlar .....	111
Şekil 43. Veri Kümesi 4a sol lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	112
Şekil 44. Veri Kümesi 4a sol lop kombinasyonları, sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar .....	113
Şekil 45. Veri Kümesi 4a sağ lop kombinasyonları, dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar .....	114
Şekil 46. Veri Kümesi 4a sağ lop kombinasyonları, dSPM yöntem ile mü bandı ve YSA ile elde edilen sonuçlar .....	115
Şekil 47. Veri Kümesi 4a sağ lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar .....	115
Şekil 48. Veri Kümesi 4a sağ lop kombinasyonları, SLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar .....	116

Şekil 49. Veri Kümesi 4a sol lop kombinasyonları, dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar.....	117
Şekil 50. Veri Kümesi 4a sol lop kombinasyonları, dSPM yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar.....	118
Şekil 51. Veri Kümesi 4a sol lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar .....	119
Şekil 52. Veri Kümesi 4a Sol lop kombinasyonları, sLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar.....	119



## TABLolar DİZİNİ

	<b><u>Sayfa No</u></b>
Tablo 1. Veri kümesi 4a'da yer alan eğitim ve test örnek sayıları .....	53
Tablo 2. Veri Kümesi 2a DVM sonuçları 12 bölgenin 4'lü kombinasyonu ve M1H_L ve M1H_R'nin eklenmesiyle elde edilen en başarılı sonuçları (mü bandı) .....	81
Tablo 3. Veri Kümesi 2a DVM sonuçları 12 bölgenin 4'lü kombinasyonu ve M1H_L ve M1H_R'nin eklenmesiyle elde edilen en başarılı sonuçları (0.5-30 Hz bandı bandı) .....	82
Tablo 4. Veri Kümesi 2a YSA sonuçları 12 bölgenin 4'lü kombinasyonu ve M1H_L ve M1H_R'nin eklenmesiyle elde edilen en başarılı sonuçları (mü bandı) .....	83
Tablo 5. DVM sınıflandırıcı ile mü bandı sonuçları .....	84
Tablo 6. DVM sınıflandırıcı ile 0.1-30 Hz bandı sonuçları .....	85
Tablo 7. YSA sınıflandırıcı için mü bandı sonuçları .....	85
Tablo 8. DVM sınıflandırıcı ile sağ lop bölge kombinasyonlarının 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri .....	86
Tablo 9. YSA sınıflandırıcı ile sağ lop dörtlü bölge kombinasyonlarının 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri .....	86
Tablo 10. DVM sınıflandırıcı ile sol lop bölge dörtlü kombinasyonlarına, 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri .....	87
Tablo 11. YSA sınıflandırıcı ile sol lop bölge dörtlü kombinasyonlarına, 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri .....	87



## SEMBOLLER DİZİNİ

A/D	: Analog Dijital
Adam	: Adaptive Moment Estimation
BBA	: Beyin Bilgisayar Arayüzü
BCI	: Brain-Computer Interface
BEM	: Boundary Element Method
BOLD	: Blood Oxygen Level Dependent
BOS	: Beyin Omurilik Sıvısı
BT	: Bilgisayarlı Tomografi
CMA	: Cingulate Motor Area
CSP	: Common Spatial Pattern
DN	: Doğru Negatif
DP	: Doğru Pozitif
dSPM	: Dynamic Statistical Parametric Map
DVM	: Destek Vektör Makineleri
EA	: Epileptojenik Alan
ECD	: Equivalent Current Dipole
ECoG	: Electrocorticography
EEG	: Elektroensefalografi
ERD	: Event-Related Desynchronization
ERS	: Event-Related Synchronization
ESI	: Electrical Source Imaging
FDM	: Finite Difference Method
FEM	: Finite Element Method
fMRG	: Fonksiyonel Manyetik Rezonans Görüntüleme
fMRI	: Functional Magnetic Resonance Imaging
fNIRS	: Functional Near-Infrared Spectroscopy
Hz	: Hertz
iEEG	: intrakraniyal Elektroensefalografi
IoT	: Internet of Things
LMS	: Least Mean Square

M1F	: Primary Foot Motor Area
M1H	: Primary Hand Motor Area
M1L	: Primary Lip Motor Area
MEG	: Magnetoencephalography
MH	: Motor Hayali
MN	: Minimum Norm
MRG	: Manyetik Rezonans Görüntüleme
MSE	: Mean Squared Error
NIRS	: Near-infrared spectroscopy
OİP	: Olaya İlişkin Potansiyeller
OKB	: Obsesif Kompulsif Bozukluk
OKH	: Ortalama Kareysel Hata
OUÖ	: Ortak Uzamsal Örüntüler
PET	: Positron Emission Tomography
PMd	: Dorsal Premotor Cortex
PMv	: Ventral Premotor Cortex
pSMA	: preSupplementary Motor Area
RBF	: Radial Basis Function
S1F	: Primary Foot Somatosensory Area
S1H	: Primary Hand Somatosensory Area
S2	: Secondary Somatosensory Area
SAC	: Somatosensory Association Cortex
sLORETA	: Standardized Low Resolution Brain Electromagnetic Tomography
SMA	: Supplementary Motor Area
SPECT	: Single Photon Emission Computerized Tomography
SSE	: Sum of Squared Errors
SVM	: Support-Vector Machine
tanh	: hiperbolik tanjant
val	: validasyon
vd.	: ve diğerleri
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları

# 1. GENEL BİLGİLER

## 1.1. Giriş

Bilgisayar, insan beyninin şimdiye kadar ortaya koyduğu en mükemmel cihazlardan biridir. Bilgisayarlar sayesinde insan beyninin neler üretebileceği ve bazı kısıtlamaların nasıl aşılabileceği görülmüştür. Örneğin, çok zor olan bazı hesaplamalar bilgisayarlar yardımıyla kolayca çözülebilmektedir.

İletişim, ilk çağ uygarlıklarından beri insanlar için önemli bir kavramdır. Yazı yazma, konuşma, mimikler kullanma bunlara örnektir. Beyin Bilgisayar Arayüzü (BBA), insanın çevresinde bulunan aygıtlar ile iletişimde yeni bir yol olma potansiyeli taşımaktadır. Motor fonksiyonları yerine getirememesi ile sonuçlanan çeşitli hastalıklar, kişinin kas sistemini kontrol edememesi durumuna neden olmaktadır. BBA sayesinde, kas sinir sistemi kullanılmadan beyin ile bilgisayar arasında iletişime izin verilmektedir. BBA'lar, haberleşme veya denetim amacıyla kullanılmaktadır [1].

Motor işlev kısıtlaması sağlık sorunu yaşayan ve bilgisayar ile geliştirilen cihazlardan yararlanan BBA'dan yararlanan en ünlü kişilerin başında teorik fizikçi ve evren bilimci olan Stephen Hawking gelmektedir. Kendisi Einstein'dan sonraki fizik dehası kabul edilmektedir. Hayatı boyunca kitaplar yayımlamıştır ve pek çok onur ödülünün sahibi olmuştur. 21 yaşında iken kendisinde motor nöron hastalığı ortaya çıkmıştır. Erken yaşında felçle karşılaşan Stephen Hawking, beyninden gelen sinyaller ve yanak kasları aracılığıyla konuşma üreten bir cihaza sahiptir. Bilgisayarıyla etkileşim için de BBA kullandığı bildirilmektedir [2].

BBA'lar ayrıca engelli bireylerin bağımsız hayat yaşamalarına da olanak sağlayabilmektedir. Ev, ofis veya sokakta istediklerini gerçekleştirebilmeleri için çeşitli uygulamalar vardır ve halen geliştirilmektedir. Tekerlekli sandalyenin beyin gücüyle sürülmesi, yazı yazılması veya bir enstrümanın çalınması gibi önemli inanılması güç uygulamalar vardır.

## 1.2. Beyin Bilgisayar Arayüzü Motivasyonu

Beyin, yapılan birçok arařtırmalara rađmen halen alıřma prensibi ve zellikleri tam olarak aıklanamayan, insanın en gizemli organıdır. Düşünmemizi, kendimizi ve evremizi algılamamızı sađlamaktadır. Duyusal verilerimizi iřlemesinin yanında, duygularımızın kontrolünden ve kasların motor hareketlerinden de sorumludur. Vücut salgılarından sorumludur ve hormonların düzenlenmelerine de yardımcı olmaktadır. Beyin evrendeki en karmařık yapılardan biri olduđu için “bilimin son sınırı” olarak isimlendirilmektedir [2].

Beyin son derece karmařıktır ve ok büyük sayıda sinir hücresi ieren sinir ađlarından oluşmaktadır. Son yıllarda nöro bilimciler beyni anlamak için birçok alıřma gerekleřtirmişlerdir. Merkezi sinir sistemi hastalıkları, davranıř bozuklukları ve uyku sorunları gibi hastalıkların beynin hangi kısımları ve nelerle iliřkili olabileceđine dair alıřmalar yapılmıřtır ve belli bir dereceye kadar sonuçlar elde edilebilmiřtir.

BBA’lar sađlık alanında yaygın biimde kullanılmaktadır. Özellikle ileri yařtaki bireylerin Alzaymır, Parkinson, depresyon, fel gibi nörolojik hastalıklarla karřılařma riski fazla olmakta, bu rahatsızlıklar ileri yař gruplarında daha büyük oranda görülmektedir. BBA alanı sinyal iřleme, makine ğrenmesi ve robotik sistemlerin keřiřiminde yer almaktadır [3].

Son yıllarda, daha ucuz ve hızlı bilgisayarların ortaya ıkması, beynin duyusal bilgileri nasıl iřleyerek, motor ıktıyı nasıl ürettiđi hakkındaki bilgi birikiminin artmıř olması, beyin sinyallerini kaydedebilecek olan cihazlara eriřimin kolay olması ve son yıllarda geliřtirilen güçlü sinyal iřleme ve makine ğrenmesi algoritmalarının ortaya ıkması BBA’ya olan ilginin artmasında etkili olduđu söylenebilir [4].

## 1.3. Elektroensefalografi (EEG)

Kafa derisi üzerine yerleřtirilen elektrotlar yardımıyla, beyin elektriksel potansiyellerinin deri üzerinden ölçülmesi iřlemine Elektroensefalografi (EEG) adı verilir. Bu sözcük Yunanca kaynaklı olup, “enkephalo (beyin)” ve “graphein (yazmak)” sözcüklerinden köken almakta olup, “beyin elektriđinin resmi”, ve “beyin elektriđinin yazılması” anlamlarına gelmektedir [5]. İlk olarak Alman bilim insanı Hans Berger tarafından 1929 yılında tek kanallı olarak ölçülmüřtür. Ardından ok kanallı modeller geliřtirilmiřtir. Elektrotlardan ölçülen deđerler, beyni oluřturan nöronların alıřma potansiyellerinin toplamının oluřturduđu bir iřaret olduđundan ok önemli bilgiler

içermektedir. Elektroensefalografi ile beynin elektriksel işlevleri elektrotlar yardımıyla kaydedilebilmektedir.

Son yıllarda hem mikro hem makro düzeyde geliştirilen ve iyileştirilen yöntemler ile beyin fonksiyonları hakkında daha fazla bilgi edinmek mümkün olmuştur. Mikro seviyede sinaptik aktiviteler gözlemlenirken, makro düzeyde ise beyin nörogörüntülemesi üzerine birçok çalışma yapılmıştır. Veri alma sistemlerinin ve elektrot üretimlerinin gelişmesiyle daha başarılı kayıtlar elde edilmiştir. Ayrıca yüksek başarımlı ve süper bilgisayar mimarileri yardımıyla birlikte de yüksek işlem gücü gerektiren karmaşık kompleks simülasyonların ve veri analiz yöntemlerinin gelişmesi de söz konusu mümkün olmuştur. Bu gelişmeler, son yılların popüler bilim alanlarından hesaplamalı nörobilime katkı sağlamıştır [6].

## **1.4. Nöron Fizyolojisi**

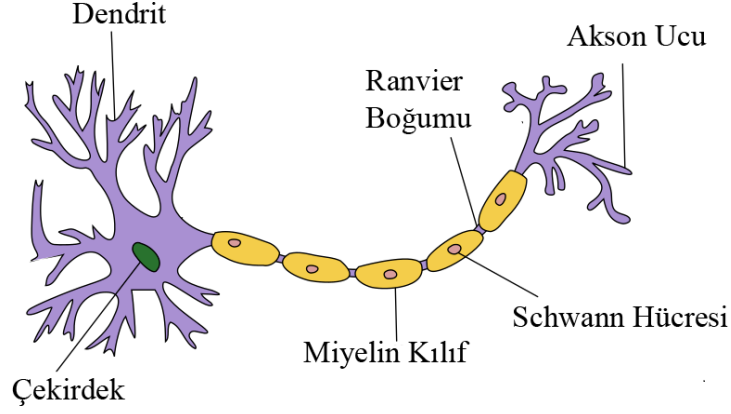
Sinir hücresi (nöron), hücre gövdesinden (soma) ve bu gövdeden çıkan uzun ve kısa uzantılardan oluşmaktadır. Uzun çıkıntılara akson, kısa çıkıntılara ise dendrit adı verilir. Hücre gövdesi, içerisinde çekirdeği ve sitoplazmanın büyük bir bölümünü bulundurduğu için hücrenin merkezidir. Hücre beslenmesi ve yönetimi bu kısımdan sağlanmaktadır. Aksonlar nöron bilgilerini sonraki nörona veya sinir ağlarına iletmektedirler [7]. Çoğu aksonda Schwann hücreleri ve bunların salgıladıkları miyelin kılıf yer almaktadır. Bu sayede elektriksel işaretin hücreler arası sıçrayarak iletimi miyelin kılıfsız nöronlara kıyasla 10 kata kadar daha hızlı gerçekleşmektedir. Dendritler ise hücreye gelen bilgileri almaktadır. Dendritler çok sayıda oldukları için gelen birçok bilgiyi eş zamanlı olarak almaktadırlar. Hücre gövdesi, dendritten aldığı bilgiyi, aksonlara iletmektedir. Şekil 1’de nöron yapısı verilmiştir.

### **1.4.1. Nöron Çeşitleri**

Nöronlar, görevlerine göre 3 gruba ayrılmaktadırlar.

#### **1.4.1.1. Duyu Nöronları**

Dendritten gelen uyarıları merkezi sinir sistemine ileten nöronlardır. Yani duyu organlarından gelen uyarıları omuriliğe ve beyine iletmektedirler.



Şekil 1. Nöron Yapısı [8]

#### 1.4.1.2. Ara Nöronlar

Bu nöronlar duyu nöronlardan gelen bilgileri alırlar merkezi sinir sisteminde değerlendirirler ve ardından motor nöronlara iletmektedirler.

#### 1.4.1.3. Motor Nöronlar

Ara nöronlardan aldıkları cevaba göre salgı bezlerine ve kaslara gerekli bilgileri gönderirler. Yani beynin ve omuriliğin verdikleri tepkileri, ilgili organlara veya bezlere aktarırlar.

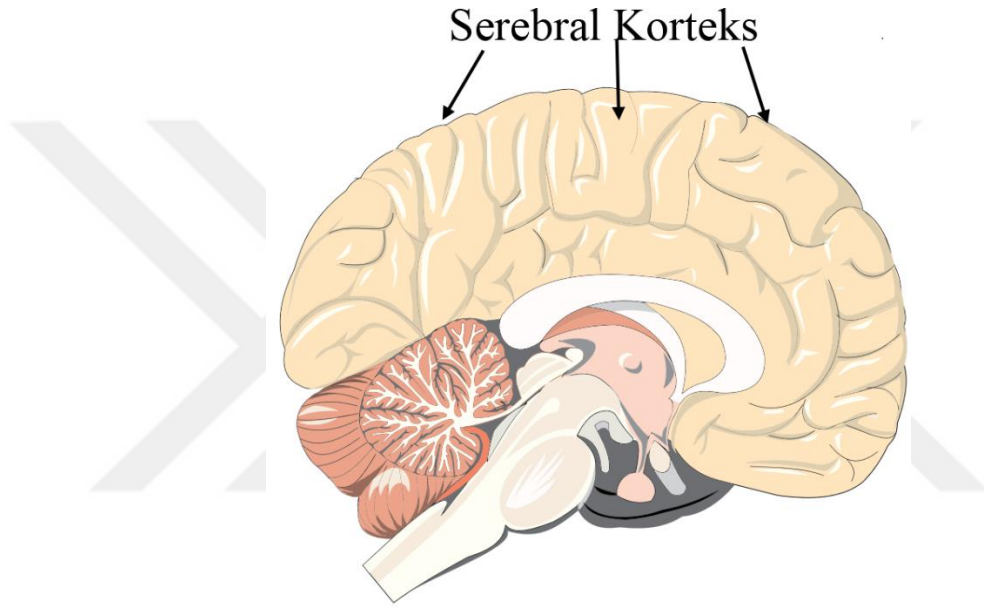
### 1.5. Beyin ve Anatomisi

Beyin, merkezi sinir sistemini yöneten; görme, duyma, tatma, denge, koklama ile ilgili duyu organlarımıza yakın noktada bulunan, insan vücudunun en kompleks organıdır. Beyinde 15-33 milyar arasında nöron olduğu tahmin edilmektedir. Beyin, bireyin anne karnında 17-18 haftalık olmasından yaşamının sonuna kadar elektriksel işaretler üretmektedir [9].

İnsanın hayati fonksiyonlarının yönetimini bu organ kontrol etmektedir. İnsanın kendisini ve çevresini algılamasını sağlamaktadır. Konuşma, hareket etme, uyku

faaliyetlerinin yanında üzüntü, korku, öfke ve aşk gibi duyguların kaynağını da beyin oluşturmaktadır. Ayrıca gönderdiği emirler ile vücut homeostasisini düzenler.

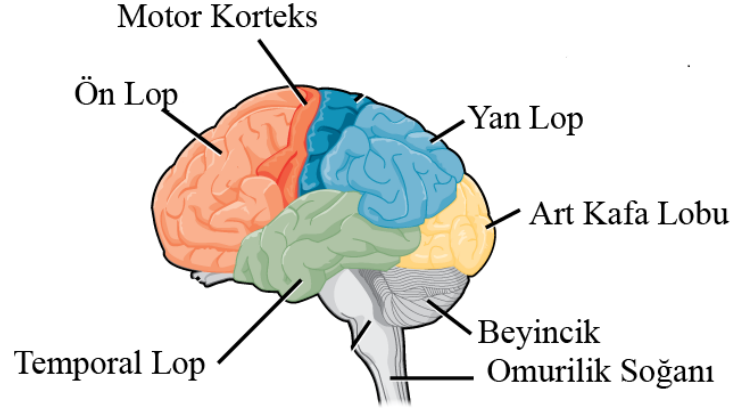
İnsanların diğer canlılardan üstün olmasını sağlayan en temel özellik, yüksek kavrama yeteneğine sahip olmalarıdır; bu işlevleri parmaklarını kullanarak dünyayı şekillendirerek yeniden dizayn ederek gösterir. İnsanlarda serebral korteksin gelişmişliği, motor yetenekleri yanı sıra bilişsel işlevleri ile de üstün kılmaktadır. Şekil 2’de serebral korteksin yapısı verilmiştir.



Şekil 2. Serebral korteksin görünümü [10]

Korteks, merkezi sinir sistemi yerleşkesinde kemik çatının altında bulunmaktadır ve insanlarda diğer canlılara oranla oldukça gelişmiştir. Beyin iki yarım küreden oluşmakta olup, cevize benzemektedir.

Beynin serebrumu, aynı adı taşıyan kemikler ile uyumlu 5 lopa ayrılmaktadır. Bu loplara frontal, parietal, temporal, oksipital ve insula olarak adlandırılmıştır. Şekil 3’te bu bölümler beyin üzerinde gösterilmiş ve görevleri açıklanmıştır [11].



Şekil 3. Serebrumun Lopları [12]

#### Ön Lop (Frontal Lop)

- Yazma ve okuma
- Hareket
- Entelektüel düşünme, incelik ve öz farkındalık
- Yargılama
- Motor beceriler
- Problem çözme
- Davranış, konuşmanın bir kısmı, üretici düşünme

#### Paryetal (Yan) Lop

- Dil yorumlama ve sözcükler
- Dokunma hissi
- Görsel ve işitsel sinyallerin yorumlanması
- Mekânsal ve görsel algı

#### Temporal Lop

- Dil yorumlama
- Hafıza
- Dinleme



- Organize etme

#### Oksipital (Artkafa) Lop

- Görsel yorumlama
- Beyin loplarının en küçüğüdür.
- Bu lobun hasara uğraması durumunda görme bozuklukları, halüsinasyonlar ortaya çıkmaktadır.

#### İnsula

- Duygulara ve hislere bu bölüm katkı sunmaktadır.

Beyinde yer alan Beyin Omurilik Sıvısı (BOS), beyin içinde ventrikül adı verilen boşluklarda ve omuriliğin dışında bulunan sıvıdır. Bu sıvı zaman zaman beyin yüzeyinde dolaşıp geri dönmektedir. Günde yaklaşık yarım litre sıvı dolaşım yapmaktadır. Beyin omurilik sıvısı, beyin basıncının ayarlanmasında çok önemli bir role sahiptir. Ayrıca, kimyasal maddeler de taşımaktadır. Önemli beyin ve omurilik iltihaplarında veya enfeksiyon hastalıklarında bu sıvının ponksiyon işlemi ile dışarı alınarak biyokimyasal incelemeye tabi tutulmaktadır.

### 1.6. Beyin Nörogörüntüleme Teknikleri

Beyin, kompleks yapısıyla en çok merak edilen organlardan biridir. Beyin nörogörüntüleme teknikleri alanında yıllardır çeşitli araştırmalar yapılmaktadır. Özellikle son 40 yılda girişimsel (invazif) olmayan nörogörüntüleme yöntemlerinin gelişmesiyle birlikte bu alanda çok önemli çalışmaların daha kolay yapılabilmesi sağlanmıştır. Beyin için yapılan nörogörüntüleme 2 kategoriye ayrılmaktadır. Birincisi yapısal görüntülemedir, bu yöntemle beyin görselleştirilerek büyük yaralanmalar ve kafa içi hastalıkları teşhis edilebilmektedir. İkincisi fizyolojik/fonksiyonel görüntülemedir, bu yöntemden mikro anatominin ve metabolik hastalıkların yüksek doğrulukla teşhisinde faydalanılmaktadır [13].

Sinapsların, aksonların ve dendritlerin mikro düzeydeki iletişimlerinin ve bağlantılarının anlaşılması için yeni çalışmalar yapılması gerekmektedir. Beyinden alınan

sinyallerin işlenebilmesi için ileri düzeyde matematiksel işlemler gerekmektedir. Beynin zarar görmeden görüntülenebilmesi için de mühendisler tarafından geliştirilen nörogörüntüleme cihazlarına ihtiyaç vardır.

Nörogörüntüleme yöntemlerinin birbirlerine göre tercih edilmelerine dair parametreler şunlardır [14]:

- Zamansal çözünürlük
- Uzamsal çözünürlük
- Kullanım kolaylığı
- Erişim kolaylığı
- Hesaplama karmaşıklığı
- Güvenlik ve riskler

### 1.6.1. EEG

EEG, beyin elektrik aktivitesinin saçlı deri üzerinden, farklı elektrot konumları kullanılarak ölçülmesi işlemidir. Beyin elektrik aktivite değişimlerini milisaniye düzeyinde göstermesi bakımından oldukça yüksek zamansal çözünürlüğe sahiptir. Ölçüm saçlı deri üzerinden yapıldığı yani cerrahi müdahale barındırmadığı için kolaylık sağlamaktadır. EEG cihazları ekonomik olmaları, her ilde bulunmaları ve donanımlarının diğer nörogörüntüleme yöntemlerinininkilere kıyasla daha az yer kaplaması sonucunda beyin görüntüleme sıklıkla tercih edilmektedir [6]. Bu yüzden EEG cihazları hem kliniklerde hem de beyin araştırma laboratuvarlarında sıklıkla bulunmaktadır.

EEG yöntemi zamansal çözünürlüğü ile çok önemli bir avantaj sunmuş olsa da, uzamsal çözünürlükte diğer nörogörüntüleme yöntemlerinin gerisinde kalmaktadır. Çünkü yapılan ölçümler çok sayıda nöron grubunun toplamsal aktivite potansiyellerini yansıtmaktadır. Bu nöron grupları da ölçüm elektrotlarının konumlarından farklı uzaklıklarda yer almaktadır. Bu yüzden fMRG gibi yöntemler tek başına veya EEG ile eş zamanlı olarak tercih edilebilmektedir.

Uzamsal çözünürlüğün artması için daha fazla sayıda elektrot kullanılarak geliştirilen cihazlar vardır. Son yıllarda, mühendislik alanında, bu sinyallerin örnekleme frekansının 256 Hz'den 1024 Hz'e çıkarılmasıyla elde edilen daha fazla miktardaki verinin incelenmesi ve

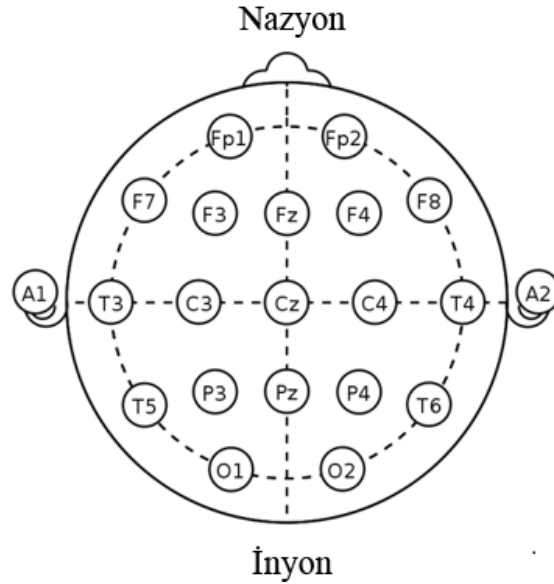
analizlerinin yapılması amacıyla mühendislikte birçok yöntem geliştirilmiştir. EEG sinyalleri doğaları gereği sinyal-gürültü oranları düşük, kompleks, lineer olmayan ve durağan olmayan sinyallerdir. Tecrübeli hekimler ve araştırmacılar EEG sinyallerini çıplak gözle inceleyerek önemli çıkarımlar yapabilmektedir. Ancak bu alanda geliştirilen hesaplamalı yöntemlerle, gözle görülenden çok daha fazla bilgiler elde etmek mümkün olabilmektedir. Şekil 4'te 10-20 uluslararası sisteme göre elektrot konumları gösterilmiştir.

EEG yönteminin en önemli üç avantajı aşağıda belirtilmiştir:

- Girişimsel olmayan bir yöntemdir. (Cerrahi müdahale gerektirmez.)
- Yüksek zamansal çözünürlüğe sahiptir.
- Mali olarak nispeten ucuzdur.

EEG yönteminin en önemli üç dezavantajı aşağıda belirtilmiştir:

- Uzamsal çözünürlük düşüktür.
- Ölçümler beynin dışında elde edilmektedir.
- Kayıtlar, ölçüm bileşenlerinin karışmasının ardından yapılmaktadır.



Şekil 4. 10-20 uluslararası sisteme göre 19 elektrot konumları

### **1.6.1.1. Saçlı Deri EEG Kaydı**

Saçlı deri üzerine yerleştirilen elektrotlar yardımıyla elde edilen, girişimsel olmayan (noninvazif) kayıtlamadır. Saçlı deri üzerine iletken krem veya jel sürülerek daha doğru ölçümlerin yapılması hedeflenir. Ölçülen beyin elektrik aktivite değerleri bilgisayara kaydedilmekte ve ekranda gösterilmektedir. EEG verileri uzman hekim tarafından klinikte gözle analiz edilerek hasta bilgilendirilmektedir.

### **1.6.1.2. İntrakraniyal EEG (iEEG) Kaydı**

Bazı durumlarda EEG ölçümlerinin direkt olarak beyin yüzeyinde yapılması gerekmektedir. Bu işleme intrakraniyal EEG yöntemi adı verilmektedir. Girişimsel olduğundan dolayı saçlı deri EEG kaydına göre oldukça zahmetli bir işlemdir. Beyin yüzeyine yerleştirilen grid (ızgara) veya strip (şerit) kullanılmasıyla ya da kafatası üzerinde delik açılarak yerleştirilen derinlik elektrotlar aracılığıyla kayıt yapılmaktadır. Bu yöntemin önemli avantajlarından biri kayıtların sinyal/gürültü oranının yüksek olmasıdır. Yani EEG kaydını olumsuz etkileyen bozucu etkiler ölçüme katılmamaktadır. Ayrıca, kafatasından geçtikten sonra kaydedilemeyen yüksek frekanslı ancak çok düşük genlikli sinyallerin de ölçülmesini sağlamaktadır. Özellikle de beynin derinindeki kaynak sinyaller hakkında bilgi sağlamaktadır [15, 16]. Bu yöntemin en önemli dezavantajları, cerrahi müdahale söz konusu olduğu için zaman ve para kaybına sebep olması ve beynin enfeksiyon kapması riskini barındırmasıdır.

### **1.6.1.3. EEG Dalgaları**

Beyin dalgaları, frekanslarına göre farklı kategorilere ayrılmaktadır. Aşağıda bu kategoriler ve özellikleri verilmiştir [17].

#### **1.6.1.3.1. Delta Dalgaları**

Delta dalgalarının özellikleri aşağıda maddeler hâlinde yer almaktadır:

- 0.5-4 Hz arasında frekans dağılımına sahiptirler.
- Genlikleri 100 mikro voltun altındadır.
- Gevşeme ve onarıcı uyku ile ilişkilidirler.
- Beyin hastalıklarında ve derin uykuda gözlemlenirler.
- Genellikle merkezi serebrum ve paryetal lopta gözlemlenirler.
- Kas hareketinin bozucu etkisinden çok etkilenirler.

#### **1.6.1.3.2. Teta Dalgaları**

Teta dalgalarının özellikleri aşağıda maddeler hâlinde yer almaktadır:

- 4-7 Hz arasında değer alırlar.
- Genlikleri 100 mikro voltun altındadır.
- Stres ve uyku anında daha çok ortaya çıkarlar.
- Hipnotik durum, hayal kurma ve duygularla ilişkilidirler.
- Paryetal ve temporal bölgede bulunurlar.
- Stres çalışmalarında özellikle bu sinyallerden yararlanılır.

#### **1.6.1.3.3. Alfa Dalgaları**

Alfa dalgalarının özellikleri aşağıda maddeler hâlinde yer almaktadır:

- 8-13 Hz frekans aralığında değerler alırlar.
- Genlikleri 50 mikro voltun altındadır.
- Uyanıkken ve normal aktivite yaparken gözlemlenirler.
- Genellikle oksipital bölgede gözlemlenirler.
- Olaya ilişkin potansiyel çalışmalarında, gözler kapalı dinlenme pozisyonunda gözlemlenirler.
- Obsesif Kompulsif Bozukluk (OKB), kaygı ve stresle ilişkilidir.

#### **1.6.1.3.4. Beta Dalgaları**

Beta dalgalarının özellikleri aşağıda maddeler hâlinde yer almaktadır:

- 14-26 Hz aralığında deęer alırlar.
- 30 mikro voltun altında genlik deęerine sahiptirler.
- Saęlıklı bireylerde konsantre olunca, aktif düşünürken, okurken, düşünürken ve heyecanlı durumlarda ortaya çıkarlar.
- Genellikle ön ve merkezi bölgelerde genellikle gözlemlenirler.
- Panik anında yüksek seviyede beta dalgaları ortaya çıkar.

#### 1.6.1.3.5. Gama Dalgaları

Gama dalgalarının özellikleri aşağıda maddeler hâlinde yer almaktadır:

- 30 Hz'in üzerinde frekansa sahiptirler.
- Genlikleri çok düşüktür.
- Olaya ilişkin potansiyeller çalışmalarında, özel durumlarda ve hastalıklarda ortaya çıkarlar.
- Beynin ön bölgesinde gözlemlenirler.
- Yüksek seviyelerde, stres ve kaygı anında ortaya çıkarlar.
- Düşük seviyelerde, dikkat eksikliği hiperaktivite bozukluğu veya depresyon anında gözlemlenirler.

#### 1.6.1.4. EEG Sinyallerine Eklenen Bozucu Etkiler ve Giderilmesine Dair Teknikler

EEG sinyalleri düşük genlikleri nedeniyle, ölçüme katılan bozucu etkilerden oldukça fazla etkilenmektedirler. Bu istenmeyen sinyaller göz kırpması, göz hareketleri, baş sallama, kalp atışı, kas aktivitesi gibi nedenlerle dolayı ortaya çıkmaktadır [18]. Göz kırpması ve göz hareketleri özellikle kafanın ön bölgesinden kayıt yapan F1 ve F2 elektrotlarına girişim yapmaktadır. Baş hareketleri de özellikle düşük genlikli sinyaller ile korelasyona uğramaktadır. Bunu elimine etmek için genellikle 1 Hz köşe frekanslı yüksek bant geçiren filtre kullanılmaktadır.

Ayrıca; cihaz kaynaklı olarak, elektrot kaynaklı olarak veya kaydedilen ortamdan dolayı da gürültüler EEG sinyallerine girişim yapabilmektedir. Kayıt ortamında, özellikle çevresel bozucu etkilerin, ölçüme eklenmesinin kısıtlanması oldukça önemlidir. Bu amaçla

akustik ve elektriksel olarak korumalı kabinlerin kullanılması faydalı olacaktır. Bazı laboratuvarlarda Faraday kafeslerinin kullanılması tercih edilmektedir.

EEG işaretlerinde meydana gelen gürültünün olası nedenleri aşağıda verilmiştir [2]:

- Kalp atışı
- Yatay göz hareketleri
- Dikey göz hareketleri
- Omuz hareketleri
- Boyun hareketleri
- Ayak hareketleri
- Öksürme
- Çiğneme
- Oturulan sandalyenin sallanması
- Kayıt cihazından kaynaklanan bozucu etkiler
- Elektrot kaynaklı bozucu etkiler
- Dil hareketi

#### 1.6.1.4.1. EEG Önışlemleri

Bu aşama normalleştirme, ölçü alınan çizginin çıkarılması, gürültüden arındırma veya bozucu etkilerin giderilmesi gibi işlemlerin yapılmasını kapsamaktadır. Bilindiği gibi; EOG, EKG gibi göz hareketlerinden veya kalp atış ritminden kaynaklanan sinyaller EEG ölçümlerine eklenebilmektedir.

Fizyolojik veya fizyolojik olmayan dış etkenler nedeniyle de EEG ölçümlerine harici sinyaller eklenebilmektedir [19]. Analizlerin en doğru şekilde yapılabilmesi için sadece EEG sinyalleri ile çalışmak son derece önemlidir.

EEG önışlemleri farklı amaçlarla yapılabilir. Önışlem, toplanan verinin işlenmek istenen veriye dönüştürülmesi veya yeniden düzenlenmesi için uygulanmaktadır. Bu adım bazen veride hiçbir deęişikliğe neden olmayacak şekilde de yapılabilir. Örneğin veride epok almak, veride deęişikliğe neden olmamaktadır; sadece işlem yapılmak istenen özel pencere veya pencereler seçilmektedir. Bozucu etkilerden, etkilenen bölümler veya kanallar analiz edilecek veriden tamamen çıkarılabilmektedir.

#### **1.6.1.4.2. Çentik Filtre**

EEG sinyalleri üzerinde 50 Hz'lik veya 60 Hz'lik sinüzoidal salınımlar yer alabilmektedir. Bu değer ülkeden ülkeye farklılık gösterebilmektedir. Çentik (notch) filtre uygulanarak bu bileşenler ortadan kaldırılmaktadır.

#### **1.6.1.4.3. Epok Alımı**

EEG verileri sürekli olarak kaydedilir ve örneklenerek [elektrot dizisi  $\times$  zaman matrisi] şeklinde örneklenerek kaydedilmektedir. EEG verilerinin kaydedilme amacına göre belli görevlerle ilgili kısımlarının analiz edilmesi gerekmektedir. Bu amaçla EEG sinyali üzerinde ilgili bölge veya bölgeler seçilerek, bu kısımların analizlerinin yapılması en anlamlı sonuçları üretecektir.

Bazı deney tasarımlarında uyarım anı, öncesi veya sonrası önemli olabilmektedir. Bu nedenle epok anlarının belirlenmesi oldukça önemlidir.

#### **1.6.1.4.4. Yüksek Geçiren Filtre**

Bu filtredeki kesim (cut-off) frekansı çok doğru seçilmelidir. Hatalı seçilmesi, ilgilenilen bölgenin ortadan kaldırılmasına sebep olabilmektedir. Belirlenen frekansın altındaki işaretler zayıflatılmaktadır.

#### **1.6.1.4.5. Alçak Geçiren Filtre**

Bu filtrelerde kesim frekansı düşük seçilirse bu sefer ilgilenilen önemli yüksek frekans bileşenleri ortadan kaybolabilir. Belirlenen frekansın üstündeki sinyaller zayıflatılır.

#### **1.6.1.4.6. Bant Geçiren Filtreler**

Bu filtreleme ile belirli aralıktaki frekanslar geçirilirken, bu aralığın dışındaki frekanslar zayıflatılarak, yok edilmeye çalışılmaktadır.



### 1.6.1.5. Geri Problem Çözümünü Etkileyen Parametreler

Geri problem çözümünü etkileyen parametreler aşağıda maddeler hâlinde verilmiştir [32]:

- EEG kayıtları üzerinde en uygun anın veya aralığın seçilmesi
- Önsel varsayımların seçimi
- Kullanılan elektrot sayıları
- Elektrotların kafa üzerine yerleştirilme şekilleri
- Seçilen geri problem yöntemi
- Kafa modelinin seçiminde ideal veya gerçek kişiden alınan MR görüntüsünün kullanılması
- Hacim öz iletkenlik değerlerinin seçimi
- Elektrotların kafa modeline uygun ve doğru bir şekilde hizalanması
- Referans elektrotun belirlenmesi
- Veriler üzerinde yapılan ön işlem adımları

### 1.6.1.6. Elektrot Yerleştirme Standartları

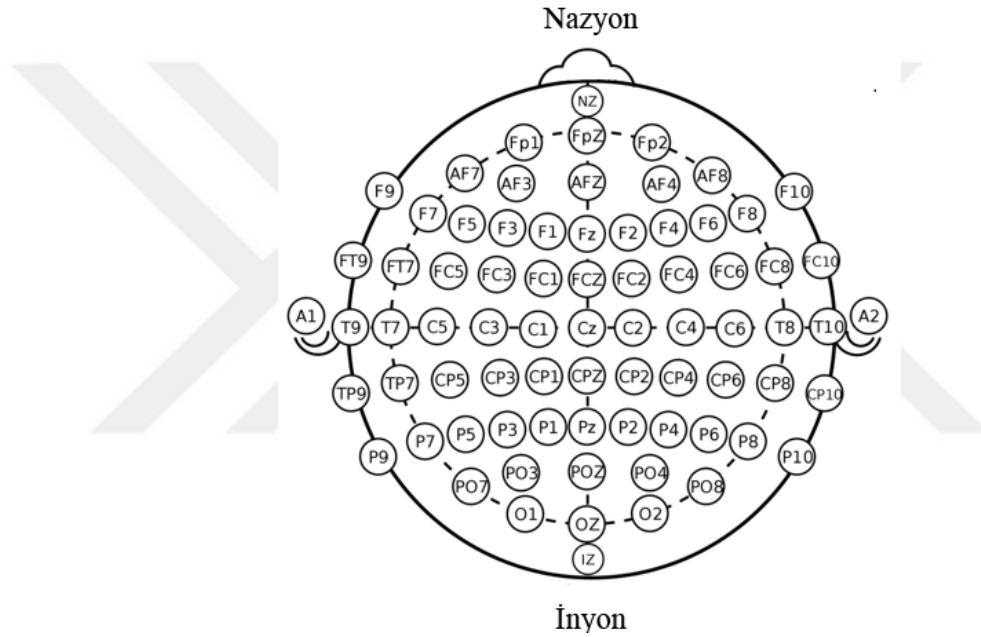
Geliştirilen daha iyi donanımlar sayesinde EEG ölçümlerinin daha fazla sayıda elektrot kullanılarak yapılmasına olanak tanınmıştır.

#### 1.6.1.6.1. Uluslararası 10-20 Sistemi

1947 yılında Londra'da gerçekleştirilen ilk uluslararası EEG kongresinde, elektrot yerleştirme işlemi için bir uluslararası standart belirlenmesi gerektiği fikri kabul edilmiştir [20]. Jasper, elektrot yerleştirmenin standartları üzerine çalışmış olup, 1958 yılında 10-20 sistemini geliştirmiştir [21]. Tanımlandığı o tarihten günümüze, 10-20 sistemi hem klinik EEG uygulamalarında hem de beyin araştırmalarında kullanılan bir standart haline gelmiştir. Bu kayıt sisteminde tipik olarak 21 elektrot ile kayıt yapılmaktadır

### 1.6.1.6.2. Uluslararası 10-10 Sistemi


EEG donanımlarındaki gelişmelerle birlikte, özellikle Olaya İlişkin Potansiyeller (OİP) çalışmalarıyla, daha fazla kanaldan alınan veriler ile beynin farklı noktalarından alınan ölçümlerden de yararlanılmak istenmiştir. OİP incelemeleri daha yoğun elektrot gerektirmektedir. Bu durumda 21 elektrottan daha fazlası gerekmektedir. Bu gelişme ile 10-10 sistemi, diğer ismiyle %10 sistemi kullanılmaya başlanmıştır. Şekil 5'te uluslararası 10-10 sistemi gösterilmiştir.



Şekil 5. 10-10 EEG Uluslararası sistemi

### 1.6.1.6.3. Uluslararası 10-5 Sistemi

10-10 sistemin etiketleme şekline uygun olarak, elektrotlara eşit mesafede olacak şekilde, yeni elektrot konumları eklendi [22]. Bilişsel sinirbilim uygulamalarında 300 civarı elektrot kullanılabilir. Önerilen bu sistemle birlikte, kafa konturları arasında %5'lik mesafeler kullanılarak, saçlı deri üzerine 300'ün üzerinde elektrot yerleştirilebilir. Şekil 6'da uluslararası 10-5 sistemi gösterilmiştir.



Şekil 6. 10-5 EEG Uluslararası sistemi [23]

### 1.6.2. Fonksiyonel Manyetik Rezonans Görüntüleme (fMRG)

Bu yöntem, kan akışının artışının nöronal aktivitenin artması ile ilişkili olduğunu varsaymaktadır. Bu varsayıma göre, beyinde belli bir nöral alan kullanımında ise o bölgeye olan kan akışının artması beklenmektedir. fMRG'nin ilk formu kandaki tüketilen oksijen miktarı ile aktivite ölçmeyi sağlamaktaydı. BOLD (blood oxygen level dependent) ilişkisi, enerji tüketimi olan bölgelerde oksijen miktarının azalacağı gerçeğini kullanmaktadır.

fMRG yöntemi; cerrahi müdahale gerektirmemesi, özel madde yutulmaması ve iyonize radyasyona maruz kalınmaması bakımından avantajlı bir yöntemdir. Uzamsal çözünürlüğü oldukça yüksektir. Bu yöntemin en önemli dezavantajlarından biri, zamansal çözünürlüğünün EEG'ninkine kıyasla çok düşük kalmasıdır. Ayrıca nöronal aktivite nöronlar üzerinden değil kan akışı ile ölçüldüğü için, nöronal aktivite hakkında direkt değil dolaylı bir gözlem sunmaktadır [24]. Ek olarak, fMRG cihazları pahalıdır, büyükçe bir

donanıma sahiptirler ve doğru bir şekilde kullanılmaları için teknik donanımlı personele ihtiyaç vardır.

### **1.6.3. Manyetoensefalografi (Magnetoencephalography, MEG)**

Manyetoensefalografi (MEG), beyinde elektrik akımlarının meydana getirdiği manyetik alanların kaydedilerek beyin haritalamasının yapıldığı fonksiyonel bir nörogörüntüleme yöntemidir. EEG'den çok daha yüksek uzamsal çözünürlüğe sahiptir ve çok daha geniş frekans aralığında analize imkân tanımaktadır [25]. MEG, klinikte ve beyin araştırmalarında yaygın olarak kullanılmaktadır. Algısal ve bilişsel beyin süreçleri ile, cerrahi öncesi şüpheli bölge tespitinde ve beynin çeşitli bölgelerinin fonksiyonlarının araştırılmasında kullanılmaktadır. Algısal ve bilişsel beyin süreçlerinin değerlendirilmesinde, cerrahi öncesi şüpheli bölge tespitinde ve beynin çeşitli bölgelerinin fonksiyonlarının araştırılmasında kullanılmaktadır.

### **1.6.4. Pozitron Emisyon Tomografisi (Positron Emission Tomography, PET)**

Vücuda pozitron yayan bir biyolojik madde verildikten sonra, bu maddenin yaymış olduğu gama ışınları analiz edilerek beyin haritalarının oluşturulduğu yöntemdir [26]. PET kamera kullanılarak kayıtlar yapılmakta ve görüntüler elde edilmektedir. Gama ışınları saptanarak transaksiyel, koronal ve sagittal kesitsel görüntüler elde edilmektedir. Bu yöntem ile oksijen ve glikoz değişim ölçümleri yapılabilmektedir.

### **1.6.5. Tek Foton Emisyon Bilgisayarlı Tomografi (Single-Photon Emission Computed Tomography, SPECT)**

Single-Photon Emission Computed Tomography (SPECT), 3 boyutlu olarak beyin hakkında bilgiler vermektedir. Vücuda verilen radyoaktif madde ve özel kamera kullanılarak beynin daha fazla ve daha az çalışan bölgelerinin tespit edilmesine olanak tanımaktadır. Vücuda radyoaktif bir işaretçi verilmesi ve radyoaktif bir yöntem olması bu yöntemin en önemli dezavantajlarından olmaktadır. 3 boyutlu görüntüler sunması yöntemi diğer metotların önüne geçirmektedir. Oluşan beyin haritalarında açık renkli bölgeler daha az aktif bölgeleri, koyu renkli bölgeler ise daha fazla aktif bölgeleri göstermektedir [27].

### **1.6.6. Bilgisayarlı Tomografi (BT)**

Bilgisayarlı tomografi, doku yoğunluğunun ve dokudaki atom türlerinin doku üzerinden geçen X ışınlarına etkilerini ölçen, röntgen görüntüleme tekniğidir [28]. Bu yöntemde beyin yapısının görülmesi için röntgenler çekilmektedir. Bu yöntem yardımıyla, beyin dokusuyla ilgili olarak kanama, yara dokusu veya tümör olup-olmadığı hakkında bilgiler elde edilmektedir. Bazı durumlarda beyin dokusunun daha iyi gözlemlenmesi için damar içine özel madde enjekte edildikten sonra röntgen çekimleri yapılmaktadır. MRG ile yapılan çekimler daha ayrıntılı olmaktadır. Bazen hekimler her iki çekimden de yararlanmaktadır.


### **1.6.7. Manyetik Rezonans Görüntüleme (MRG)**

Manyetik rezonans görüntüleme, 1970'li yıllarda kullanılmaya başlanmıştır. Görüntü işleme alanında mühendislerin yaptığı iyileştirmeler ve geliştirmeler, işletme masraflarını azaltarak, MRG'nin daha yaygın olarak kullanımını artırmaya devam etmektedir [29]. Canlıların fizyolojisinin ve iç anatomisinin girişimsel olmayan bir yöntemle görüntülenmesini sağlayan bir araçtır [30]. Beynin veya diğer dokuların 2 ve birleştirilerek 3 boyutlu olarak hassas görüntülerinin elde edilmesi için, röntgen yerine yüksek manyetik alan altında radyo dalga darbeleri ile kutuplanan hidrojen atomlarının serbest hale geçişleri sırasında ürettikleri elektromanyetik işaretlerin antenler ile ölçülmesiyle çalışmaktadır [31]. İnsan ve hayvan denemelerinde, güçlü manyetik alanların veya radyo dalgalarının canlıya bilinen bir zararı olmadığı için, canlıya zarar vermeden görüntüleme yapıldığı kabul edilmektedir [30]. MRG, hekimler tarafından tedaviyi belirlemek veya izlemek için ya da görüntülenen doku için değerlendirme yapmak için kullanılmaktadır. MRG, beyin görüntülemesinin yanında kol, bacak, kalp, akciğer gibi birçok organın değerlendirilmesinde bu teknikten faydalanılmaktadır.

### **1.6.8. Beyin Görüntüleme Yöntemlerinin Çözünürlüklerinin Karşılaştırılması**

Görüntülemede zamansal ve uzamsal olarak ne kadar bilgi alındığı çok önemlidir. EEG ve iEEG yöntemleri sayesinde zamansal olarak milisaniyelik değişimler

gözlemlenmektedir. Diğer yöntemlerde bu zaman saniyelere hatta dakikalara kadar çıkabilmektedir. EEG yönteminde, uzamsal olarak az sayıda elektrot kullanılmasından ve kafa içindeki beynin, BOS'un, kafatasının ve saçlı derinin farklı iletkenlik değerlerine sahip olmalarından dolayı ancak sınırlı sayıda bilgi elde edilebilmektedir [32]. Şekil 7'de farklı nörogörüntüleme yöntemlerinin uzamsal ve zamansal çözünürlükleri grafikte gösterilmiştir.



Şekil 7. Nörogörüntüleme yöntemlerinin uzamsal ve zamansal çözünürlükleri [33].

### 1.7. EEG Analiz Yazılımları

EEG analizi amacıyla ücretli ve ücretsiz olmak üzere birçok yazılım geliştirilmiştir [34]. Bunların başlıca örnekleri aşağıda listelenmiştir.:

- Brainstorm (University of Southern California, Los Angeles, CA)
- BESA Research (BESA GmbH)
- BIOPAC ACQKnowledge (BIOPAC Inc.)
- BrainVision Analyzer (Brain Products GmbH)
- BrainVoyager (Brain Innovation B.V.)
- Cartool Software (Biomedical Imaging Center Lausanne-Geneve)
- Curry 7 (Compumedics Limited)
- EEGLAB (Swartz Center for Computational Neuroscience, UCSD)
- LORETA (KEY Institute for Brain-Min Research, Zurich)

## 1.8. Beyin Bilgisayar Arayüzleri

Beyin Bilgisayar Arayüzleri (BBA) çok disiplinli çalışma alanlarından olup, bilgisayar, elektrik-elektronik, biyomedikal, psikoloji, sinirbilim ve rehabilitasyon gibi çeşitli mühendislik ve tıp alanlarıyla yakından ilişkilidir [35]. BBA ile; insan düşüncelerinin kontrol komutlarına dönüştürülmesi yoluyla, cihazların beyin gücüyle kullanılabilmesi amaçlanmaktadır.

BBA'lar, 1960'lı yılların sonlarında ve 1970'li yılların başlarında geliştirilmiştir. Bu yazılımlar basit yapıda tasarlanmıştır. Son yıllarda, EEG sinyallerinin alınmasını, işlenmesini ve dönüştürülmesini oldukça kolaylaştıran donanımlar ve yazılımlar gerçekleştirilmiştir. Artık, kullanıcı dostu arayüzler insan hayatına girmiştir. Bunlar, ilerleyen yıllarda, özellikle motor engelli bireylerin çevreyle iletişimleri ve rehabilitasyonları için geliştirilmiştir.

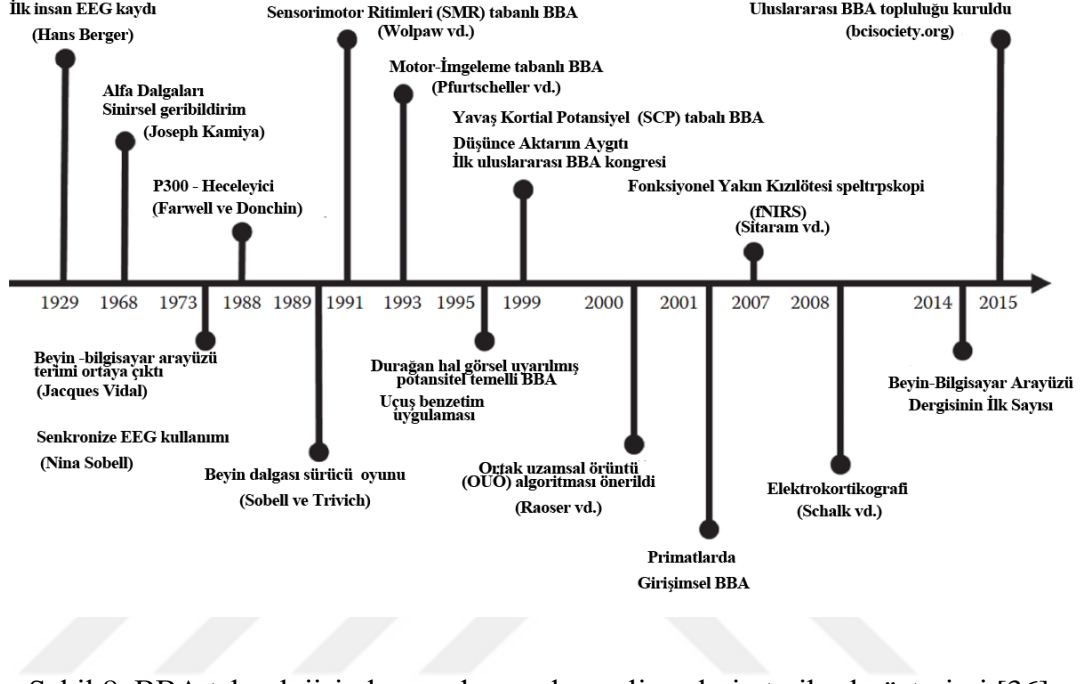
Özellikle son yıllarda nörobilimin, sinyal işlemenin, makine öğrenmesinin ve algılayıcı (sensör) teknolojisinin gelişmesi ile BBA alanında oldukça önemli çalışmalar ortaya çıkmaya başlamıştır. EEG teknolojisinin uygun maliyetle elde edilmesiyle birlikte, bu cihazlarla, farklı alanlarda farklı kişilerle belirli amaçlar için kayıtlar yapılmasını kolaylaştırmıştır.

### 1.8.1. BBA Nasıl Çalışır?

Günümüzde bilgisayarların ve diğer cihazların kontrolleri genellikle kas aktivitesi gerektirmektedir. Örneğin bilgisayarın klavyesinin, faresinin, dokunmatik yüzeyinin (touch pad) veya dokunmatik ekranının kullanımı, bilgisayara sesle veya göz hareketiyle komut verilmesi gibi eylemler, kas hareketi gerektiren işlemlerle yapılabilmektedir. Kas hareketleri beyinde gerçekleşen reaksiyonların sonucunda oluştuğu için bir miktar gecikmeyle ve enerji harcanmasıyla komut verilebilmektedir [25]. BBA'lar, EEG sinyalleri ile çalışmaları durumunda, daha hızlı ve daha az enerji ile çalışmaya olanak sağlayabilmektedirler. Sinyal direkt olarak beyinden alınıp işlenebilmektedir.

İnsan ile bilgisayar etkileşimi, teoride, en hızlı biçimde ve yüksek doğrulukla sağlanabilmektedir. Beyinden alınan sinyaller, farklı durumlar için değişkenlik göstermektedir. İşte bu sinyallerin alınarak, yorumlanarak bilgisayarın veya dış cihazın anlayabileceği komutlara dönüştürülmesi işlemi BBA'ların temel görevi olmaktadır.

Nöral aktiviteler beyinde elektriksel ve manyetik alanlar oluşturmakta ve kan akışında değişimlere sebep olmaktadır. Nöral aktiviteler bilinçli olarak veya bilinç dışında gerçekleşebilmektedir. Şekil 8’de BBA teknolojisinde 1929 tarihinden itibaren meydana gelen önemli gelişmeler gösterilmiştir.



Şekil 8. BBA teknolojisinde meydana gelen gelişmelerin tarihsel gösterimi [36]

### 1.8.2. BBA Performansını Etkileyen Parametreler

Bilişsel ve algısal yeteneklerin bilinmesi, etkileşimli sistem tasarımcıları için dikkat edilmesi gereken konuların başında gelmektedir [37, 38]. Araştırmacıların çok iyi bilmesi gereken bilişsel ve algısal alanlar aşağıda verilmiştir:

- Kısa süreli ve çalışan bellek
- Uzun süreli ve anlamsal bellek
- Problem çözme ve akıl yürütme
- Karar verme ve risk değerlendirmesi
- Dil iletişimi ve kavrama
- Arama, hayal ve duyu belleği
- Öğrenme, beceri geliştirme, bilgi edinimi ve konsept kazanımı



### 1.8.3. Girişimsel (İnvazif) BCI

Girişimsel BBA kayıtlarının alınabilmesi için özel cihazlar gerekmektedir. Bu özel aletler, beyne özel bir cerrahi işlem ile yerleştirilmektedirler. Beyin üzerinde tek bölgeden kayıt alınması istenirse buna tek ünite kaydı, birden fazla bölgede kayıt alınması istenirse de çoklu ünite kaydı adı verilmektedir [39, 40]. Girişimsel EEG kaydıyla ECoG sinyalleri elde edilmekte olup, deriden elde edilen EEG kaydına göre çok daha net sinyal kaydı yapılmaktadır. Ancak cerrahisinin zahmetli olması, enfeksiyona sebep olabilmesi ve dokularda iz bırakma ihtimalinin olması nedeniyle hastalar tarafından az tercih edilen bir yöntem olmaktadır.

### 1.8.4. Girişimsel Olmayan (Noninvazif) BBA

Cerrahi işlem gerektirmeyen BBA'lar, maliyeti ucuz olan ve sağlığa zararlı olmayan BBA tipidir. Bu yöntem zahmet gerektirmemesi ve cerrahi işlem içermemesi nedeniyle öncelikli tercih sebebi olmaktadır. Ancak bu yöntemle elde edilen sinyal, girişimsel ve yarı girişimsel yöntemlerle elde edilen sinyallere göre daha zayıf olmaktadır. Çünkü sinyal; beyin dokuları, BOS, kafatası ve son olarak da saçlı deriden geçerek ölçüm elektrotlarına ulaşmaktadır. EEG elektrotları bir jel yardımıyla kafa derisine yerleştirilmektedir. Elektrotlar genellikle kablolu olmaktadır. Son yıllarda kablosuz elektrotlar da geliştirilmiştir. Böylece kullanıcılara daha fazla hareket özgürlüğü sunulmak istenmektedir. Kullanılan elektrot sayısı da yine önemli bir parametredir. Yüksek uzamsal çözünürlük için elektrot sayısı artırılarak kullanılan cihazlar son yıllarda yaygınlaşmaktadır. Bazen kayıtlar az sayıda elektrot kullanılarak kayıtlar elde edilse de daha özel bölgelerden sinyaller elde edilebilmesi için çok sayıda elektrot kullanılması söz konusu olmaktadır. Böylece daha özel analizler yapılabilmektedir. Girişimsel olmayan kayıtların çoğu EEG kaydı ile elde edilmektedir.

### 1.8.5. Yarı Girişimsel BBA

Bu kayıtlama ile de beyin işaretleri kaydedilmektedir. Kayıt elektrotları kafatası üzerine koyulmaktadır. Böylece, sinyal kalitesi girişimsel BBA'lara göre daha düşük olsa

da, daha az bir cerrahi işlem gerekmektedir ve girişimsel olmayan BBA'ya göre daha net sinyaller elde edilmektedir.

Bireylerin algısal ve motor performansını etkileyen faktörlerin de göz önüne alınması önemlidir. Bu faktörlerin denekler arasında olabildiğince uyumlu olması, daha doğru analizler için anlamlı olacaktır [41]. Bu faktörler aşağıda verilmiştir:

- Uyarılma ve uyanıklık
- Yorgunluk ve uyku yoksunluğu
- Algısal (zihinsel) yük
- Sonuç bilgisi ve geri bildirim
- Monotonluk ve can sıkıntısı
- Duyusal yoksunluk
- Beslenme ve diyet
- Korku, kaygı, ruh hali ve duygu
- Uyuşturucu, sigara ve alkol kullanımı
- Fizyolojik ritimler

#### **1.8.6. Beyin Bilgisayar Arayüzlerinde Hesaplamalı EEG Analizi**

EEG sinyalleri, harici cihazlara aktif veya pasif olarak komutlar verecek şekilde, mühendislikle ayarlanabilmektedir. Ölçülen EEG sinyalleri ile bir program veya bir ortam kontrol edilebilmektedir. Burada en önemli kısım, EEG sinyallerinden elde edilen özelliklerin neye göre ve nasıl seçileceğinin en güzel şekilde belirlenebilmesini sağlamaktır.

#### **1.8.7. Beyin Bilgisayar Arayüzlerinde Neden EEG Tercih Edilmelidir?**

Bilişsel, algısal, dilbilimsel, duygusal ve motor süreçler çok hızlı oluşmaktadır [42]. Bu işlemlerin zamansal olarak yakalanabilmesi için zaman çözünürlüğünün yüksek olduğu bir yöntemle incelenmesi gerekmektedir. Bu işlemler saniyenin yüzde biri veya binde biri gibi çok küçük zaman dilimlerinde gerçekleşmektedir. EEG yöntemi, bu sinyallerin algılanabilmesine olanak tanımaktadır.

EEG yöntemi, beyindeki nöral aktivitelerin oluşturduğu elektrik akımlarının biyofizikçiler tarafından direkt olarak ölçülmesine olanak tanımaktadır. Nöral aktiviteler

yoğunlaşarak, dışarıdan ölçülebilen EEG sinyallerini oluşturmaktadır. Bu elektrik akımı değişiklikleri özel olarak hazırlanan EEG elektrotları tarafından kaydedilmektedir. Örneğin fMRG yönteminde nöral aktiviteler, oksijen kullanımına bakılarak, nöral aktiviteler dolaylı olarak ölçülmektedir.

### **1.8.7.1. Beyin Aktivitelerinin Ölçülmesi**

Ölçümler, girişimsel ve girişimsel olmayan olmak üzere iki kategoride yapılabilmektedir. EEG, MEG, fNIRS ve fMRG gibi yöntemler cerrahi işleme gerek duyulmadan beyin aktivitelerinin ölçülebilmesini sağlamaktadır. ECoG (Elektrokardiyogram) ise cerrahi işlem gerektirmektedir. Bu işlemde elektrotlar korteks üzerine konumlandırılmalıdır, bu yüzden cerrahi işlem zorunlu olmaktadır. Hatta elektrotlar beyin derinliğine de yerleştirilebilmektedir ve bunun yardımıyla hem konumsal hem de zamansal olarak önemli bilgiler elde edilebilmektedir. Ancak bu işlem hastanın enfeksiyon kapmasına sebep olabileceğinden, tıbbi laboratuvarlarda dikkatle ve hijyenik olarak yapılabilmektedir.

BBA kullanımında deneğin kafasına farklı sayılarda elektrotlar yerleştirilmektedir. Denekten, belirlenen bir görevi beyin gücüyle yapması istenmektedir. Alınan sinyaller işlenerek ve sınıflandırılarak harici cihazla iletişim sağlanmaktadır. Elektrotlarla birlikte deneğin çok özgür olamadığı söylenebilir. Deneğin kısıtlı bir hareket alanı vardır, ayrıca hareketler de bozucu etkilere sebep olmaktadır. Son yıllarda geliştirilen kablosuz elektrotlar ile kişiye daha özgür bir ortam sunulabilmektedir. Bu sayede insanlar da internetin bir parçası olmaktadır ve nesnelerin interneti (Internet of Things, IoT) artık insanları da kapsamaktadır [43].

BBA'ların yaygın olarak kullanıldığı alanlar aşağıda verilmiştir:

- Ekranda imleç kontrolü
- Tekerlekli sandalye kontrolü
- Oyun oynama

### 1.8.8. Motor Hayali (MH)

Kişi bir harekete niyet ettiğinde veya bir hareketi yaptığını hayal ettiğinde motor korteks üzerinde alfa ve beta sinyallerinde değişiklikler gözlemlenebilmektedir. Bu değişikliklere Olaya İlişkin Senkronizasyon (Event-Related Desynchronization (ERD) ve Olaya İlişkin Senkronizasyon (Event-Related Synchronization (ERS) adı verilmektedir.

Bu tezde, birçok farklı disiplinden makaleler ve kaynaklar harmanlanarak incelenmiştir. Bu çalışma alanı; mühendislerin, klinik tedavi uzmanlarının ve psikologların katkı verdiği çok disiplinli bir alandır. Bu alanda her yıl birçok araştırma yapılmaktadır.

Teknolojinin gelişmesiyle birlikte birçok makine insan hayatına girmiştir ve insanların daha rahat yaşamalarına olanak sağlamıştır. Ancak birçok kişi halen yaşlılık, hastalık veya yaralanmalar gibi nedenlerle bazı cihazları etkin olarak kullanamamaktadır. Bu yüzden bu bölümde BBA kullanım alanlarına örnekler verilecek ve motor hayalinde EEG seçiminin önemine değinilecektir.

Makinelerle birlikte insanlık büyük bir yol almış, yapılamayacak veya yapılması ciddi ölçüde zaman ve zahmet gerektirecek işlerin kolaylıkla yapılabilmesine olanak sağlanmıştır. Gökdelenler, köprüler, taşıtlar ve uzaya gönderilen cihazlar, son yıllarda makineler yardımıyla gerçekleştirilen en önemli nesnelere olmuştur. Ayrıca, makinelerin kullanılması için arayüzler sunulmuş olup; bilgisayarlar için klavye ve fare desteği, kara taşıtlarının sürülmesi ve durdurulması için pedal destekleri sağlanmıştır. Arayüzler, cihazları her cinsiyetteki, her yaştaki ve farklı vücut ölçülerindeki (kilo, boy) insanların kullanmasına olanak tanımaktadır.

Makineler kolay kullanılabilirliğe göre üretilseler de, kullanan kişilerin el ve ayak koordinasyonlarının yanı sıra hem görsel, hem de basınç ve hareket ile ilgili duyuşal (sensory) geri beslemelerinin uygun olması beklenmektedir [44]. Eğer kişide bu yeterliliklerin tamamı mevcut değilse, bu durumda kişiye yardımcı olabilecek sistemler geliştirilmektedir. Bu sistemler, literatürde BBA veya Makine İnsan Arayüzü adıyla yer almaktadır.

#### 1.8.8.1. Motor Hayalinde Neden EEG Tercih Edilmeli?

EEG işaretlerindeki değişimler milisaniyeler içinde gerçekleşmektedir. EEG, bilişin meydana geldiği zamanda, bilişsel dinamiklerin zaman diliminde yakalanmasına imkân

sağlamaktadır. Yani bu süreç, anlık olarak takip edilebilmektedir. Tez kapsamında üzerinde çalışılan motor hayali gibi duygusal, bilişsel, algısal ve dilsel süreçler de hızlıdır. Çoğu bilişsel süreç onlarca veya yüzlerce milisaniye gibi çok küçük zaman dilimlerinde gerçekleşmektedir. Bilişsel olaylar ise onlarca milisaniye ile birkaç saniye arasında sürebilmektedir. Bu yüzden hızlı, dinamik ve zamansal olan bilişsel sürecin anlaşılabilmesi için yüksek zamansal çözünürlüklü bir yöntem tercih edilmelidir. Hemodinamik yanıtın zamansal hassasiyeti ile elektro-fizyolojik yanıtınki karşılaştırılırsa, hemodinamik yanıtın daha yavaş olduğu gözlenecektir. Teta Bandı (4-8 Hz) salınımları, bellek ve bilişsel kontrol süreçlerinde aktif olan işarettir [42]. Bu işaret sinirbilimciler tarafından yavaş kabul edilse de aslında gerçek dünyada 4 Hz'lik bir işaret çok da yavaş sayılmayacaktır. Gama bandı (50-80 Hz) göz önüne alınacak olursa, Teta Bandı yine daha hızlı bir işarettir. Bunun yanında daha yüksek frekanslı işaretler de beyinde yer alabilmektedir. Bu örneklerden anlaşılabilmesi üzere biliş süreci de beyin işaretleri de hızlıdır. Bu işaretlerin görüntülenebilmesi ve anlaşılabilmesi için EEG gibi zamansal çözünürlüğü yüksek bir görüntüleme tekniğini kullanmak çok anlamlı olmaktadır.

Nörobilişsel süreçlerde EEG'den yararlanılmasının ikinci en önemli nedeni, EEG'nin nöral aktivitenin doğrudan ölçülmesine fırsat vermesidir. EEG ile voltaj değişimleri, MEG ile de manyetik alan değişimleri doğrudan ölçülebilmektedir. Elektrotlar yardımıyla ölçülen EEG sinyalleri, kortekste meydana gelen nöral salınımların doğrudan ölçülmesi ile elde edilen elektriksel voltaj değerleri olmaktadır. fMRG yönteminde aktiviteye bakılırken BOLD seviyesinde bakılmaktadır; bu, nöral aktivitenin doğrudan değil, dolaylı ölçümünün sonucudur.

EEG'nin üçüncü en önemli avantajı, elde edilen sinyallerin düşünülen daha fazla boyutlu bir işaret olmasıdır. Tıbbi kullanımda genellikle zaman-genlik eksenine göre bakılarak, başarılı yorumlamalar yapılabilmektedir. İşarete bakıldığında; zaman, uzamsallık, frekans ve güç-faz bilgileri olmak üzere en az dört boyutlu bilgi elde etmek mümkündür. Bu bilgiler gözle bir miktar takip edilebilirse de hassas değerlere mühendislik hesaplamaları ile ulaşılabilmektedir. Bu çok boyutluluk sayesinde hem nörofizyolojide hem de psikolojide birçok hipotezin belirlenmesine ve test edilmesine olanak sağlanmaktadır.

Beyin; bilgi işleme, bilgi sunma ve bilgi transferi yapan karmaşık bir biyolojik sistemden oluşmaktadır. EEG sayesinde cerrahi işlem olmadan elde edilen bilgilerle, beyin hakkındaki gizemler insana zarar verilmeden çözülmeye çalışılmaktadır [42].

## 1.9. Motor Hayali ile İlgili Beyin Bölgeleri

Motor işlevi istemli hareketi beyin tarafından programlanmakta ve yönetilmektedir. Motor işlevine beyin korteksi dışında omurilik, beyin sapı, bazal gangliyon ve beyincik de katkı sunmaktadır.

Beyin motor alanı frontal lobun hemen arkasında başlayan, beynin üçte birlik alanını kaplayan motor korteks tarafından oluşturulmaktadır. Bu alan; primer alan, premotor alan ve suplementer alan olmak üzere üç bölgeye ayrılmaktadır.

### 1.9.1. Primer Motor Korteks

Primer motor korteks, santral sulkusun önünde, frontal lobun ilk kıvrımında uzanmaktadır. Lateral olarak sylvian fisurden başlamakta, superiyor olarak beynin en üst kısımlarına yayılmakta ve sonra longitudinal fisur içindeki derinliğe dalmaktadır. Brodmann sınıflandırmasında bu alan dörde karşı gelmektedir [45]. Sylvian fisure yakın ağız ve yüz alanlarıyla başlar ve primer motor korteksin orta kısımlarında el ve kol alanları, beyin üst ucuna yakın kısımda gövde alanı, longitudinal fisure inen primer motor korteks kısmında ayak ve bacak alanlarıyla vücudun farklı kas alanlarının primer motor korteksteki topoğrafik temsil edilir. Bu alanlar şematik olarak Penfield ve Rasmussen tarafından haritalandırılmış olup farklı kas alanlarını göstermektedir [46]. Bu harita, cerrahi işlem uygulanan insanların beyinlerine yapılan elektriksel uyarımlara verilen tepkilere göre elde edilmiştir. Primer motor korteksin yarısından fazlası el ve konuşma kaslarıyla ilişkilidir. Tek bir motor korteks nöronunun uyarılması özel bir hareketi uyarmaktadır. Kas kalıpları uyarılınca, farklı kaslar kendi yönü, kas hareketinin gücü ile olduğu kadar kasılma sıralaması ile harekete katılır.

### 1.9.2. Premotor Alan

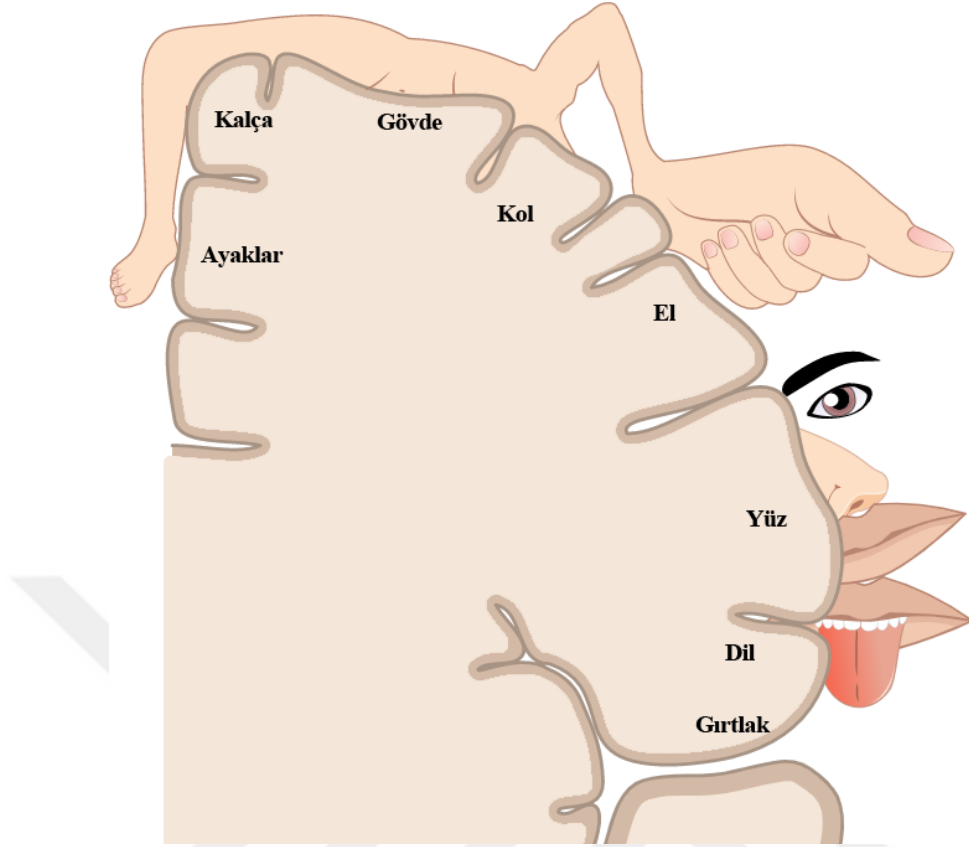
Premotor alan, primer motor korteksin hemen önünde yer almaktadır. Öne 1-3 cm kadar, aşağıya sylvian fisurun içine kadar ve yukarıya longitudinal fisure doğru uzanıp, suplementer motor alana dayanmaktadır. Premotor korteksin topoğrafik organizasyonu, primer motor korteksteki sıralama ile aynı gibidir. En lateralde ağız ve yüz alanları, sonra yukarıya doğru el, kol, gövde ve bacak alanları sıralanmaktadır. Premotor alandan ortaya

çıkan sinir sinyali, spesifik görevleri yapacak olan kas gruplarının hareketine neden olmaktadır. Örneğin, ellerin özel bir görevi yapabilmesi için omuz ve kolların uygun şekilde yönetilmesini bu birim sağlamaktadır. Premotor alanın ön bölümü, yapılacak bütün kas hareketinin "motor bir şablonu"nun oluşturulmasını sağlamaktadır [45]. Sonra bu şablon posteriyor sinyallerini, ya çok sayıda kas grubunu uyarmak üzere doğrudan doğruya premotor kortekse, ya da büyük olasılıkla bazal gangliyonlar yoluyla talamus üzerinden geriye primer motor kortekse göndermektedir. Bu sayede, premotor korteks, bazal gangliyonlar, talamus ve primer motor korteks, vücutta koordineli olarak kas aktivitesini düzenleyen bir sistem meydana getirmektedirler.

### **1.9.3. Suplemer Motor Alan**

Suplemer motor alan, motor fonksiyonunun kontrolünde farklı bir topoğrafik organizasyona sahiptir. Premotor alanın hemen üzerinde ve esas olarak longitudinal fisurde yer almaktadır, fakat lateral korteksin en üst kısmına doğru birkaç santimetre daha ileri uzanmaktadır. Bu alanın uyarılması ile elde edilen kasılmalar genellikle çift taraflı olmaktadır. Örneğin, uyarılma, sıklıkla, her iki elin eşzamanlı olarak bilateral kavrama hareketine yol açmaktadır. SMA, premotor alan ile uyum içinde çalışmaktadır ve vücudun farklı segmentlerinin fiksasyon hareketlerini, baş ve gözlerin pozisyon hareketlerini sağlamaya yardımcı olmanın yanı sıra, el ve kolların primer motor korteks ve premotor alanla hassas motor kontrolü sağlamalarına yardımcı olmaktadır [45].

Aşağıda Şekil 9'da [47] motor alanların, beyin kesitinde karşı düştükleri bölgeler sembolik olarak gösterilmiştir.



Şekil 9. Kas Gruplarının gösterimi

### 1.10. Literatür

EEG tabanlı BBA geliştirilmesi için birçok çalışma gerçekleştirilmiştir. Çalışmaların büyük bir kısmı, saçlı deriye yerleştirilen elektrotlardan ölçülen işaretler üzerinde yapılan özellik çıkarma işlemleri ve bunları takiben makine öğrenmesi ile yapılan sınıflandırmalar ile elde edilen başarımları ele almaktadır. EEG kaynak görüntülemesi ile yapılan çalışmalar da son yıllarda yaygınlaşmaktadır. EEG, nöral aktivitenin milisaniyeler içinde görüntülenmesine imkân veren zamansal çözünürlüğe sahipken, uzamsal olarak oldukça az bilgi sunabilmektedir. EEG kaynak görüntüleme ile EEG kayıtlarından gerçek nörogörüntüleme bilgisi elde edilebilmektedir [34].

2004 yılında Qin vd. tarafından, kaynak analizi kullanan bir pilot çalışma yayınlamışlardır [48]. Elektrot EEG sinyallerinin kaynak EEG sinyallerine dönüştürülmesinin motor hayal EEG işaretlerinin sınıflandırılmasına yardımcı olacağı bildirilmiştir. Bu alandaki ilk çalışmalardan biri olan bu çalışmada sağ el ve sol el motor



hayal işaretlerini içeren 59 kanalla kaydedilmiş veriler yer almaktadır. Çalışmada Bağımsız Bileşen Analizi (BBA) ve eşdeğer dipol analizi yöntemleri kullanılmıştır. Eşdeğer dipol ilgili beyin lobunda çıkarsa sınıflandırmanın doğru yapıldığı kabul edilmiştir. Bu mantıkla %80'lik sınıflandırma doğruluğuna erişilmiştir. Sol el hayalinde C4 elektrotu etrafında ve sağ el hayalinde C3 elektrotu civarında değişimler gözlemlendiği bildirilmiştir. Ayakların motor hayalinin ise Cz elektrotu civarında olduğu ancak alanların birbirine yakın olması nedeniyle motor hayalinin hangi ayağa ait olduğu noktasında karar vermenin zor olduğu bildirilmiştir.

2005 yılında Qin vd. tarafından, sol elin ve sağ elin motor hayaline dayalı işaretleri dipol yöntem kullanarak sınıflandırılmıştır [49]. 2005 yılında Wentrup vd. tarafından, sağ ve sol işaret parmakları için motor hayalinde Bağımsız Bileşen Analizi kullanarak kaynak yerelleştirmesi yapılmış olup, geleneksel makine öğrenmesine göre daha fazla hesaplama gerektirdiği bildirilmiştir [50]. Buna rağmen, kaynak lokalizasyonunun makine öğrenmesine iyi bir alternatif olabileceği öngörülmüştür. Sınıflandırma sonrasında %85'lik başarı sağlanmıştır. 2005 yılında Kamousi vd. dört denek üzerinde sağ el ve sol el motor hayalinde, kaynak lokalizasyon kullanımının ümit verici sonuçlar verdiğini bildirmişlerdir [51]. 2007 yılında Kamousi vd. tarafından, sol el ve sağ el motor hayal hayali için kortikal akım yoğunluğu geri dönüşüm yöntemi kullanılarak, başarı artırımı sağlanacağını bildirilmiştir [52]. 2008 yılında Yuan, istatistiki kaynak analizi çalışmalarında, motor hayalinde, maksimum korelasyonun sensorimotor alanda olduğunu bildirmiştir [53]. Lotte vd. 2009 yılında geri problem çözümü olarak sLORETA kullanarak ilgili bölgeleri ve frekans aralığını bulanık bir yöntemle belirlemişlerdir [54]. Sol ve sağ el parmağı ile klavye kullanımında; doğru el tespiti ve sağ el, sol el, dil ve ayak motor hayali olmak üzere dört sınıflı veriler içeren 2 farklı veri kümesi üzerinde sonuçlar elde edilmiştir. Geliştirilen yöntemle, diğer çalışmalara göre zaman zaman daha başarılı sonuçlar elde edildiği görülmüştür. Hwang vd. tarafından 2009 yılında motor hayali kayıt alınması öncesinde deneklerin eğitim sistemine tabi olması önerilmiştir [55]. Eğitim öncesi ve sonrası beyin aktivasyon haritalarına bakıldığında, eğitilmiş grubun daha başarılı olduğunu görülmüştür. Sensorimotor ritmin eğitim öncesi ve sonrası değiştiği ve sınıflama doğruluğunun da arttığı bildirilmiştir. Sol el ve sağ el için motor hayal çalışması yapılmıştır. Sonuçlar elektrot seviyesinde elde edilmiştir.

2010 yılında Arvaneh vd. tarafından, kanal seçimi ile farklı kanal kombinasyonları ile BBA sınıflandırma başarısının artırılacağı bildirilmiştir [56]. Bazı kayıt elektrotları

gürültülü veya ilgisiz bilgiler içerebilmektedir. İlgili çalışmada, karar ağaçları kullanılarak daha az kanal sayısı ile daha büyük başarı elde edildiği bildirilmiştir.

2015 yılında Handiru vd. EEG kaynak lokalizasyonu ile motor hayal anında beyin kortikal sinyallerinin aktivasyonunu görüntülemişlerdir, sağ ve sol el için motor hayalini sLORETA yöntemi ile ayırt etmek için çalışma yapmışlardır [57]. EEG tek başına nörogörüntüleme yöntemi olmadığı için, bahsedilen çalışmada, şablon kafa ve sLORETA geri problem çözümü ile kaynak EEG sinyallerini elde edilmiştir. 2015 yılında Abdulkader vd. BBA alanındaki uygulamalar ve kısıtlamalar hakkında geniş bir inceleme yayınlamışlardır [58]. 2016 yılında Handiru vd. yedi denek üzerinde, sağ elin kuzey, güney, batı ve doğu yönlerinde motor hareketini kaynak uzayında ve elektrot uzayında incelemişlerdir [59]. İlgili çalışmada, farklı yön hareketlerinin kaynak uzayında daha yüksek başarıyla sınıflandırıldığı bildirilmiştir.

Li vd. 2018 yılında EEG sinyallerinin kaynak uzayında az sayıda farklı Fisher Discriminant yöntemi ile dipoller seçilerek OUÖ yöntemiyle özellikler çıkarılmış ve DVM ile sınıflandırma yapmışlardır [60]. EEG kanalları kullanılarak yapılan sınıflandırmalarda, kanal seçimi çok önemlidir. Kanal seçimi iyi yapılamazsa, sınıflandırma doğruluğu azalacaktır, hesaplama karmaşıklığı ise artabilecektir. 2021 yılında Shi vd. ikili armoni arama algoritması kullanarak, tüm kanalların kullanılması durumuna göre daha başarılı sonuçlar elde etmişlerdir [61]. 2021 yılında Meng vd. elektrot seviyesinde EEG sinyalleri üzerinde Yinelemeli Çizim Evrişimsel Sinir Ağı ile sağ el ve sol el için sınıflandırma yapmışlardır [62]. 2021 yılında Singh vd. Motor hayal EEG alanında veri toplama, motor hayal eğitimi, sinyallerin ön işlenmesi, özellik çıkarma, kanal ve özelliklerin seçilmesi, sınıflandırma ve performans ölçümleri hakkında geniş bir inceleme yazısı yayımlamışlardır [63]. 2021 yılında Zhang vd. tarafından, otomatik kanal seçme yöntemiyle kanal seçimi yapılarak daha az EEG kanalının kullanılmasının, yalnızca hesaplama karmaşıklığını azaltmakla kalmayıp aynı zamanda motor hayalinde sınıflandırma performansını da artırdığı gösterilmiştir [64]. 2020 yılında Saxena vd. kaynak lokalizasyonu ile fonksiyonel beyin aktivasyonunu sağ el, sol el, iki ayak birlikte ve dil için araştırmışlardır, bulgularında beyin diğer kortikal alanlarına kıyasla premotor korteks, birincil motor korteks, postcentral girus ve posterior parietal korteksin önemli ölçüde aktive olduğunu gözlemlemişlerdir [65]. 2020 yılında Hou vd. EEG kaynak lokalizasyonu ile beyin üzerine yerleştirdikleri yamalardaki sinyallerden özellik çıkararak ve Evrişimsel Sinir Ağları ile sınıflandırma yaparak, sınıflandırma başarısını artırdıklarını bildirmişlerdir [66].

2014 yılında Frolov vd. tarafından; sol el, sağ el ve rahatlama olmak üzere deneklere 3 görev verilmiştir [67]. Motor hayalinde en etkili motor alanlarının bulunması hedeflenmiştir. Bu çalışmada fMRI ile de sonuçlar alınarak doğrulama yapılmıştır. Kaynak lokalizasyonu yapılan çalışmada kontra ve ipsilateral katkılar araştırılmıştır. Motor hayalinde ilgili elin, karşı lop Brodmann 3a alanı en etkili bölge olarak belirlenmiştir. 2016 yılında Edelman vd. tarafından; sağ elin bükülmesi, gerilmesi, içe bükülmesi ve dışa bükülmesi olmak üzere elin 4 tür motor hayali üzerine çalışılmıştır [68]. Çalışmada daha özel hareketlerin motor hayali icra edilmiştir. Çalışmada BBA teknolojisinin bir dış cihazı veya bir sanal cihazı 3 boyuta kadar çok iyi yönetebildiği ancak daha özel hareketlerin motor hayalinin anlaşılabilmesi için kaynak uzayından yararlanmanın faydalı olacağı bildirilmiştir. Elde edilen sonuçlara göre, elektriksel kaynak görüntüleme kullanılarak, kaynak uzayında bireysel olarak %18.6 ve ortalamada %12.7 başarı artışına erişilmiştir. Sonuç olarak kaynak görüntüleme ile çok daha başarılı BBA ortaya çıkabileceği bildirilmiştir. Shenoy vd. 2017 yılında sLORETA yöntemiyle geri problem çözümü yaparak elin 4 farklı dikey yönde hareketini sınıflandırmışlardır. Kaynak uzayında, danışmanlı faktör analitiği yöntemini kullanarak sınıflandırma yapmışlardır. Kaynak uzayındaki düşük frekanslı bileşenlerin, hareket kinematiğinde önemli olduğunu belirtmişlerdir.

2013 yılında ilk BBA dergisi çıkmıştır ve 2014 yılında ilk yayımına başlamıştır [69]. 2016 yılında 188 araştırma grubu ve kuruluşun katılımıyla, 400 kişilik BBA toplantısı gerçekleştirilmiştir [70]. 2015 yılında BBA topluluğu oluşturulmuştur [71]. 2014 yılında Gao vd. [72] görsel ve işitsel uyarımlar tabanlı BBA geliştirdiler. 2015 yılında Ang vd. [73] inme rehabilitasyonu için uygulama geliştirdiler. 2008 yılında Lecuyer vd. [74] ve 2009 yılında ise Nijholt vd. [75] oyun alanında BBA uygulaması geliştirdiler. Yeni geliştirilen BBA'lar ile bu alanın yetenekleri ve araştırma alanları da genişledi [76].

2017 yılında Handiru vd. [77] kaynak uzayında işlemler yaparak kol hareketinde %10'luk daha yüksek başarı elde etmişlerdir. İlgili çalışmada, sağ elin kuzey, güney, doğu ve batı olmak üzere 4 yönde hareketini algılamak için kaynak uzayında işlemler yapılmıştır. 118 kanalla kayıtlama yapılmıştır. Kaynak uzayında ise Brodmann alanlarından BA4a, BA4p ve BA6 bölgeleri üzerinde hesaplamalar yapılmıştır. Sonuç olarak %71 sınıflandırma doğruluğuna ulaşıldığı bildirilmiştir ve bu başarının elektrot seviyesindeki çalışmaya ait başarıya göre %10'un üzerinde daha yüksek olduğu rapor edilmiştir. 2019 yılında Yazıcı vd. sLORETA geri problem çözümü yöntemini kullanarak sağ el ve sağ ayak motor hayali sinyallerini sınıflandırmıştır. Çili motor hayal bölgeleri kombinasyonları denenmiş ayrıca

sağ lop ve sol lop için de sınıflandırma doğruluk değerleri hesaplanmıştır [78]. Beyin kaynaklarının yerini bulmada EEG, sınırlı uzamsal bilgi sunmaktadır. Geri problem çözümü ile EEG, artık nörogörüntüleme önemli bir yöntem dönüşmektedir.

### 1.11. Tezin Amacı

Bu tezin ana amacı, motor hayale dayalı BBA ile elde edilen sinyallerin, kaynak yeniden yapılandırılmasının kullanılmasına uygun olarak yeniden sınıflandırılmasıdır. EEG yönteminin uzaysal çözünürlüğünün düşük olması nedeniyle, EEG kaynak lokalizasyonu yöntemi tercih edilerek bu kısıtlamanın aşılması ve sınıflandırma başarısının artırılması hedef edinilmiştir. Motor Hayal EEG (MH-EEG) kodunun çözülmesi, Beyin-bilgisayar Arayüzü (BBA) sistemindeki biyosinyal işlemenin en önemli parçasıdır. Geleneksel yöntemlerde MH-EEG'nin uzamsal-zamansal özellik bilgisinin elektrot seviyesinde çıkarılması ve sınıflandırılması söz konusudur, ancak serebral kortikal nöronlardan türetilen bu beyin dinamik özellikleri, daha hızlı ve açık bir şekilde kaynak etki alanı yüksek uzaysal çözünürlükle yansıtılmaktadır. Nörobilimin gelişmesiyle birlikte, son teknoloji EEG Kaynak Görüntüleme (Electrical Source Imaging, ESI) teknolojisi, kafa derisi sinyallerini beyin kaynak alanına dönüştürmektedir ve MH-EEG'nin kaynak kod çözme yolunu açmaktadır [79].

Motor Hayalinde EEG kullanımı ile zamansal çözünürlüğü yüksek işaretler elde edilebilmektedir. Ancak bu işaretlerin uzamsal çözünürlüğü düşük olmaktadır. Motor hareket hayal edilince beyinde üretilen sinyaller üzerinde değişiklikler olmaktadır. Bu, sinyal olarak karşımıza çıkmaktadır. Ancak gri maddede meydana gelen nörolojik değişiklik ile beyin korteksi üzerinde hangi noktaların hassas olarak bu durumdan etkilendiğini belirlemek zordur.

Beyinde elektriksel aktivitenin yayılması hacimsel iletkenlik ile açıklanmaktadır. Saçlı deri EEG kaydı ölçülürken, beyinde oluşan elektriksel sinyal beyin, kafatası, Beyin Omurilik Sıvısı ve saçlı deri üzerinden geçerek elektrotlara ulaşmaktadır. Bu yüzden, ölçülen bilginin yanında, farklı kaynak noktalarındaki sinyaller de ölçüme dâhil olabilmektedir. Bu duruma en somut örnek olarak mikrofon ölçümleri verilebilir. Mikrofonu en yakın bulunan kişinin yanı sıra, daha uzaktaki kişilerin sesleri de mikrofondan alınan sinyale etki edebilmektedir.

Uzamsal çözünürlüğü artırmak ve daha hassas ölçümler yapabilmek için, literatürde ve pratikte daha fazla elektrot kullanılarak ölçümler yapılmıştır. Bu konuda, daha fazla elektrotlar yardımıyla daha hassas bilgilerin ölçülmesi önerilmektedir.

Bu bölümde Beyin Bilgisayar Arayüzlerine ve klinikte EEG sinyallerinin kullanımına değinilmiştir. BBA mimarisi, sinyallerin elde edilme yöntemleri ve yaklaşımları ayrıntılı olarak anlatılmıştır.



## 2. YAPILAN ÇALIŞMALAR

### 2.1. İleri ve Geri Problem Çözümü

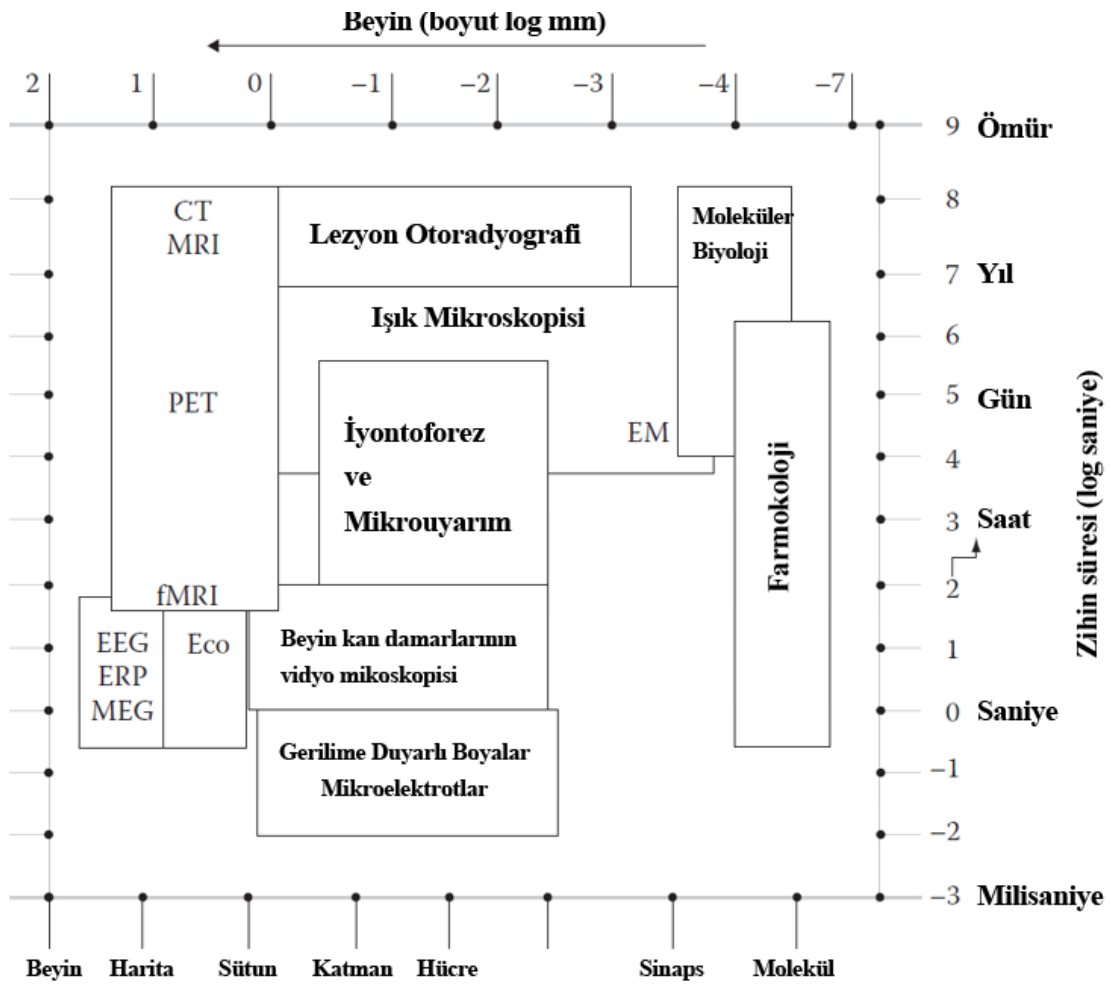
Fiziksel dünyada, eldeki model ve fiziksel durumlar dikkate alınarak değerler tahmin ediliyor veya sonuçlar bulunuyorsa buna simülasyon veya ileri problem çözümü adı verilmektedir. İleri problem çözümünde, model bilindiği için çözüm basit ve tek olmaktadır. Bu hesaplama için büyük hesaplama yükü gerekmemektedir.

Geri problem çözümü ise, eldeki veriler ışığında model tahminini gerektirmektedir. Birden fazla çözüm vardır, tek bir çözüm yoktur. Yani geri problem çözümünde farklı modeller kullanılarak da aynı çıkış üretilebilmektedir. İleri problem çözümünde ise tek model vardır ve çıkış tek olacaktır. Geri problem çözümü yapılıncaya bulunan model ile gerçek model arasında farklılık olabilmektedir. Bu yüzden tahmin verisi hata payı içermektedir.

EEG kaynak lokalizasyonu, kötü konumlanmış (ill-posed) bir problem olarak adlandırılmaktadır. Bilinmeyen parametrelerin sayısı, bilinenlerden çok daha fazladır. Kaynakların bulunabilmesi için EEG geri problem çözümü genel olarak 2 yöntemle gerçekleştirilmektedir. Birincisinde, sinyallerin az sayıda dipol kaynağı tarafından üretildiği varsayılmaktadır. Bu yaklaşıma eş değer akım dipolü adı verilmektedir. İkinci yaklaşımda, tüm olası kaynak bölgeleri eş zamanlı olarak dikkate alınmaktadır, buna doğrusal dağıtık yaklaşım adı verilmektedir. EEG geri problem çözümü için birçok yöntem önerilmiştir. Bazen tek yöntem, bazen de hibrit yöntemler kullanılmaktadır [80].

İnsan beyni aktifken elektriksel ve manyetik sinyaller üretmektedir. Bu sinyaller küçük genlikli olsalar da elektriksel olan işaretler EEG yöntemi ile manyetik işaretler ise MEG yöntemiyle ölçülmektedir. Elde edilen ölçüm sinyalleri beyinden ölçüm elektrotuna varıncaya kadar farklı dokulardan geçtikleri için zayıflamış olarak ölçülebilmektedir. Eldeki ölçüm verileri kullanılarak EEG sinyallerinin kaynak konumlarının, yönlerinin ve büyüklüklerinin bulunabilmesi için geri problem çözümüne ihtiyaç duyulmaktadır. Geri problem çözümününün diğer bir adı da kaynak kestirimidir. Bu yöntem; fizyolojik, patolojik, zihinsel ve fonksiyonel anormallikleri ve beynin bilişsel davranışsal çalışmasını anlamaya yardımcı olmaktadır [81].

EEG, nörogörüntüleme sıklıkla başvurulan bir tekniktir. 1929 yılında Alman doktor Hans Berger tarafından az sayıda elektrot ile beyin elektriksel aktivitesi kaydı yapılmıştır [82, 83]. Kornmuller ise çoklu kanal elektrotu ile geniş beyin bölgesinin kaydını alan ilk nörobilimcidir. EEG, beyin aktivitesinin, girişimsel veya girişimsel olmadan kaydedilebildiği, yüksek zamansal ve düşük uzamsal çözünürlük sunan bir tekniktir. Şekil 10'da nörogörüntüleme yöntemlerinin zamansal ve uzamsal çözünürlükleri gösterilmiştir.

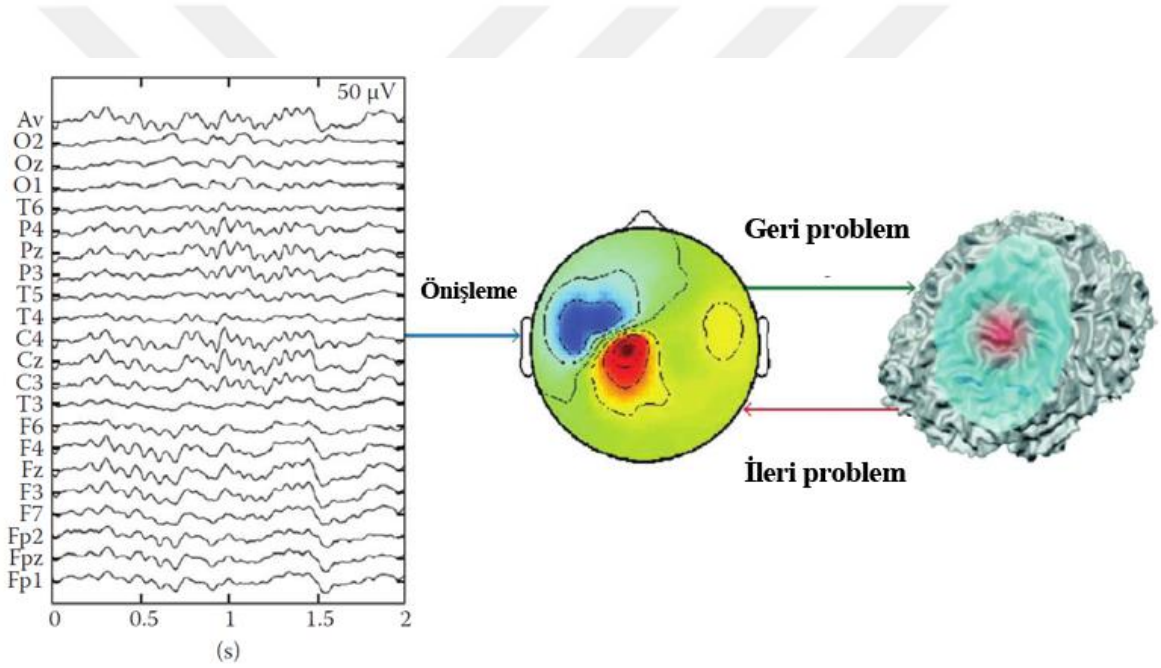


Şekil 10. Nörogörüntüleme yöntemlerinin zamansal ve uzamsal çözünürlüklerinin gösterimi [11]

EEG kaydı, nöral aktivitelerin direkt ve gerçek zamanlı görüntülenmesine izin vermektedir. Bu yöntem yardımıyla, elde edilen işaretler hızlı bir şekilde işlenebilmekte, hızlı bir algılama sistemi ile gerçek zamanlı çalışmalara yardımcı olunabilmektedir.

Kafatasının her 2 lobuna yerleştirilen elektrotlar yardımıyla, belli bir hareket hayalinde veya düşüncesinde, her 2 lopta da oluşan değişimleri gözlemlemek mümkündür.

EEG alanında uzun yıllardır üzerinde çalışılan ve çözümü zor olan problemlerin başında; EEG potansiyel kayıtları elde edilirken, beyinde aktif olan bölgelerdeki sinyallerden sorumlu elektriksel kaynakların bulunması gelmektedir. Bu problem, EEG kaynak lokalizasyonu olarak isimlendirilmektedir. Elde kafanın belirli bölümlerinden elde edilmiş olan EEG ölçüm verileri, kafa derisi üzerindeki elektrot konumları, kafa geometrisi ve farklı dokuların iletkenlik değerleri olduktan sonra, beyin korteksi üzerindeki akım kaynaklarının konumu, büyüklüğü ve yönü hesaplanmaya çalışılmaktadır [84]. Şekil 11’de ileri ve geri problem çözümü gösterilmiştir.



Şekil 11. İleri ve Geri Problem çözümü gösterimi [85]

### 2.1.1. İleri Problem Çözümü

Belirli sayıda nöral akım kaynaklarının kafa derisinde oluşturacağı gerilimin hesaplanmasını sağlamaktadır. Bu amaçla gerilim ve akım değerlerinin oluşturduğu elektromanyetik aktivitenin hesaplanmasında kullanılan matematiksel denklemler bu aşamada verilecektir.



Verilen model ve kaynak değerleri ile oluşacak olan algılayıcı değerlerinin bulunmasına EEG ileri problemi adı verilmektedir. Aktivite kaynağı varsayılan konumda, büyüklükte ve yönelimdeyken kafatasında oluşabilecek elektriksel işaretin bulunması ile EEG ileri problemi, manyetik alanın bulunması ile de MEG ileri problemi çözülmüş olacaktır. Tez konusu gereği burada EEG sinyalleri üzerinde durulacaktır.

Burada, elde model bulunduğu için, hesaplamalar sonucunda tek sonuç kolaylıkla elde edilebilmektedir. İleri problem çözümü için, akım kaynakları ile algılayıcılar arasındaki ilişki bilinmelidir. İleri problem çözümü, Maxwell denklemleri ve 4 tabakalı kafa modeli (beyin, BOS, kafatası ve saçlı deri) veya hastadan alınan gerçek MR görüntüsünden elde edilen gerçekçi kafa modeli yardımıyla gerçekleştirilmektedir. Kafa modelinde, farklı iletkenliklere sahip bölgeler ifade (2.1)'deki gibi tanımlanmaktadır [86].

$$M = AS + E \quad (2.1)$$

İfade (2.1)'de  $M$  ( $N_c \times N_t$ ), ölçüm değerini göstermektedir.  $A$  ( $N_c \times N_d$ ) ileri alandır ve  $(a_1, \dots, a_{N_d})$  i. sütun i. dipol ile tüm algılayıcılar arasındaki ilişkiyi tutmaktadır.  $S$  ( $N_d \times N_t$ ) akım kaynaklarını;  $N_c$ ,  $N_d$  ve  $N_t$  ise sırasıyla kanal sayısını, kaynak sayısını (dipol) ve örnek sayısını göstermektedir.  $E$ , gürültü terimidir ve bağımsız 0 ortalamalı Gauss dağılımına sahip olduğu varsayılmaktadır.

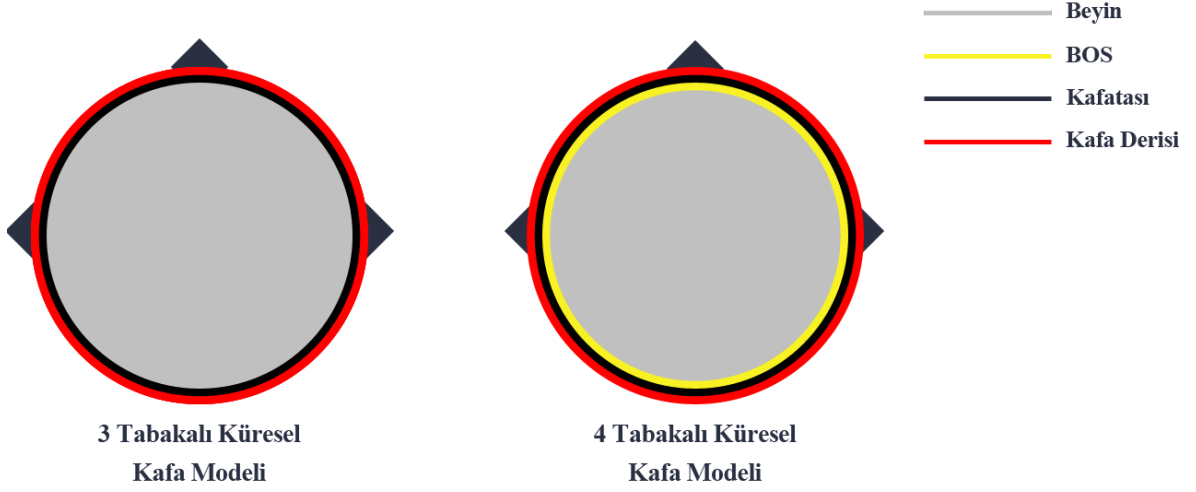
İleri alan belirlenmesinde kanalların kafa üzerindeki 3 boyutlu konumlarının doğru olarak bilinmesi çok önemlidir. Bu amaçla 3 boyutlu konumları veren sayısallaştırıcıların kullanıldığı klinikler ve laboratuvarlar vardır. Bu bilgi net olarak elde yoksa, bu durumda elektrotların uluslararası standartlara göre kafaya yerleştirilmesiyle en yakın koordinatların elde edilmesi gerekmektedir.

### 2.1.1.1. Kafa Modelleri

#### 2.1.1.1.1. Analitik (Küresel) Kafa Modelleri

En basit kafa modeli yapısıdır. Kafa, iç içe geçmiş küreler şeklinde temsil edilmektedir. 3-5 tabakalı küresel kafa modellerinde beyin, BOS, kafatası ve kafa derisi yer almaktadır. Bu modeller, basitlikleri nedeniyle klinikte ve araştırmalarda EEG kaynak

lokalisasyonu için kullanılmaktadır. Şekil 12’de üç ve dört tabakalı küresel kafa modelleri gösterilmiştir.



Şekil 12. Üç tabakalı ve dört tabakalı kafa modelleri

#### 2.1.1.1.2. Gerçekçi Kafa Modelleri

4 tabakalı kafa modeli, insan kafasının çok basit bir modelini ele almaktadır. İnsan kafası düzgün küresel yapıya sahip değildir. Kafa farklı dokular barındırdığı için, homojen olmayan ve eş yönsüz (yön olarak bağımlı olma) bir yapısı vardır. Bu yüzden, daha doğru çözüm için, gerçekçi kafa modellerinin kullanılması önerilmektedir.

Gerçekçi kafa modeli kullanan çalışmalar, hastadan elde edilen gerçek MR görüntülerini kullanmaktadırlar. Böylelikle, kafanın anatomik özellikleri, yüksek çözünürlüklü görüntüler yardımıyla elde edilmeye çalışılmaktadır. MR görüntülerinden beyin, kafatası ve kafa derisi görüntüleri elde edilmektedir. İleri seviye yazılımlar yardımıyla beyin farklı bölgelere bile ayrıştırılabilmektedir. Literatürde gerçekçi kafa modeli kullanan çeşitli yöntemler önerilmiştir. Bunlar sınır elemanlar yöntemi (Boundary Element Method, BEM), sınırlı elemanlar yöntemi (Finite Element Method, FEM) ve sonlu farklar yöntemi (Finite Difference Method, FDM) yöntemleridir. FEM kafa modelinde, kafa ayrıntılı olarak modellenmektedir. Bu yüzden bu model oldukça zaman alıcı ve büyük bir hesaplama karmaşıklığına sahiptir [87].

- Sınır Eleman Modeli (Boundary Element Method, BEM)

Bu kafa modeli oluşturulurken, üç tabaka gerçekçi kafa modelleri kullanılmaktadır. Bu tabakalar; kafa derisi, iç kafatası ve dış kafatasıdır. Bu yöntemin EEG kullanıcıları tarafından tercih edilmesinin ana nedeni, oluşturulan kafa modelinin, küresel kafa modellerine göre daha doğru sonuçlar vermesidir.

BEM yüzeylerinin oluşturulabilmesi için eğer deneğin gerçek MRG'si varsa, bu görüntü üzerinden kafa derisi, iç kafatası, dış kafatası ve kaynak uzayı (kortikal yüzey) bilgilerinin elde edilmesi gerekmektedir. Eğer elde deneğe ait olan gerçek MRG verisi yoksa, bu durumda ICBM152 gibi gerçekçi kafa modellerinden yararlanılabilmektedir. Brainstorm yazılımı deneğin korteksini, kafa yüzeylerini, ICBM152 modelinin iç ve dış kafatası yüzeylerini göz önüne alarak, matematiksel yaklaşımla, çakışmayan yüzeyler üretmektedir [88].

- Kafa modelinde köşe sayısı seçimi

Her bir yüzey için ne kadar fazla köşe noktası olursa, sonuçlar o kadar doğru biçimde üretilebilmektedir. Ancak bu durumda hesaplamalar daha fazla olacağı için, hesaplama karmaşıklığı, kullanılan bellek miktarı ve hesaplama süresi artacaktır. Brainstorm OpenMEEG yazılımında varsayılan (default) değer olarak yüzey başına 1922 köşe noktası kullanılmaktadır. Tez kapsamındaki hesaplamalar bu değer kullanılarak yapılmıştır.

- BEM İletkenlik Değerleri

Birçok çalışmada beyin ve kafa derisi iletkenlik değerleri birbirine eşit olarak seçilmektedir. İletkenlik değeri kafatası için düşük olmaktadır.  $\sigma_{beyin} = \sigma_{kafaderisi} = 1$  ve  $\sigma_{kafatası} = 0.0125$  olarak seçilmiştir.

## 2.1.2. Geri Problem Çözümü

### 2.1.2.1. EEG Sinyalleri Kullanılarak Beyin Kaynak Yerelleştirilmesi

Beyin bölgeleri aktif oldukları zamanlarda hem manyetik hem de elektriksel olarak işaretler üretmektedirler. Bu sinyallerin kaynak lokalizasyonunun yapılması ile yer ve yön bilgileri tahmin edilmeye çalışılmaktadır. Ölçüm değerleri üzerinden kaynak kestirimi, geri problem olarak da adlandırılmaktadır. Geri problem çözümüyle özellikle beyne dair bilişsel davranışlara ve fizyolojik, patolojik, zihinsel bilgilere ek olarak fonksiyonel anormallikler hakkında da bilgiler elde edilebilmektedir. Bu sayede özellikle epilepsinin ve tümörlerin belirlenmesi mümkün olabilmektedir.

EEG sinyalleri yardımıyla kaynak belirlenmesi, özellikle, epilepsi hastalarında nöbetlerden sorumlu epileptik bölgenin bulunabilmesi için yardımcı olmaktadır. Bu yöntem ile girişimsel müdahale olmadan epilepside cerrahi işlem uygulanabilecek alanın bulunması mümkün olabilmektedir. Bu amaçla, EEG geri problem çözümleri konusunda çok sayıda yayın yapılmıştır. Bu yayınların yarısından azında klinik olarak doğrulama görülebilmektedir [86].

Beyin kaynak görüntüleme birçok alanda kullanılabilmektedir. BBA çalışmalarında ilgili beyin bölgelerinin tespitinin yanında klinikte epilepsi, şizofreni, demans, tümör, stres ve depresyon gibi hastalıkların kaynaklandıkları yerlerin öğrenilebilmesi için kullanılabilmektedir.

EEG kaynak lokalizasyonu son 20-30 yıldır klinikte ve araştırmalarda kullanılmaktadır. Epileptik nöbetin başlaması için yeterli ve gerekli alan, Epileptojenik Alan (EA) olarak adlandırılmaktadır. Bu bölgenin belirlenmesi, doğru tedavinin uygulanabilmesi için ve eğer cerrahi müdahale gerekiyorsa, başarılı ve doğru ameliyatın yapılabilmesi için oldukça önemlidir.

Geri problemin çözülebilmesi için öncelikle ileri problem çözümü yapılmalıdır. İleri problem çözümünde BEM, FEM ve FDM yöntemleri, literatürde yaygın olarak kullanılmaktadır.

Geri problem çözümü, sınırlı sayıda ölçüm elemanları ve algılayıcılar yardımıyla, binlerce kaynağın (on binden fazla) bulunmasını hedeflemektedir. Bu yüzden geçerli önsel varsayımların yapılması gerekmektedir. Elektromanyetik kaynak görüntüleme, EEG'nin ölçümüne katkı sağlayan kaynakların konumlarının tahminini sağlamaktadır.

### 2.1.2.2. Sınır Elemanlar Yöntemi (Boundary Element Method, BEM)

Poisson eşitliğinin, gerçekçi kafa hacim iletim modeli kullanılarak çözüldüğü yöntemdir. Hastadan alınan MR görüntüsü kullanılarak BEM modeli üretilmektedir. Burada, diferansiyel ve integral eşitlikleri kullanılmaktadır. Sınır integral denklemleri, ileri problem üzerinden düzenlenmiştir. BEM kafa modellerinde, birden fazla ve farklı iletkenliklere sahip dokular temsil edilmektedir.

Geometrik modelde; kafa, üçgensel bölgelere ayrılmaktadır. EEG ölçümleri kullanılarak, bu ölçümleri meydana getiren 3 boyutlu elektriksel nöral aktivite kaynak dağılımı bulunmaya çalışılmaktadır. Bu problemin tek bir çözümü yoktur. Ancak önsel varsayımlar yapılarak çözüm teke indirilmeye çalışılmaktadır.

### 2.1.2.3. Minimum Norm Yerelleştirme Teknikleri

Bu yaklaşım Hamalainen ve Ilmoniemi tarafından 1984 yılında dağıtık, ayrık ve eşzamanlı EEG geri problem çözümü için önerilmiştir [89]. EEG geri problemi mevcut dağılımlar için; uç alanlar tahmini olarak, uç alanların doğrusal bir kombinasyonunu önererek çözüme ulaşmaya çalışılmaktadır.

I konumunda yer alan bir uç alan  $L_i$  olarak gösterilmektedir.

$$J^P(r) = J_{tot}(r) - \sigma(r)E(r) \quad (2.2)$$

İfade (2.2)'de  $r$ , pozisyon vektörü,  $J_{tot}$  toplam akım yoğunluğu,  $\sigma$  iletkenlik ve  $E$  ise elektrik alanını ifade etmektedir.

$$B_i = \int L_i(r) \cdot J^P(r) dv \quad (2.3)$$

$$J_1 \in F, \quad J_2 \in F$$

Eşitlik (2.3)'te  $L_i$  ifadesi uç-alandır ve  $i$ . Manyetometre için dağıtılan hassasiyeti tanımlar. Manyetometre çıkışı ise  $B_i$  olarak tanımlanır.

Denklem (2.3)'te sağlanan iç çarpım, yalnızca mevcut  $F$  uzayının  $F'$  alt uzayında bulunan birincil akımlar hakkında bilgi sağlayabilir.  $F'$  alt uzayı, uç alanlar arasında yayılması ifade (2.4)'de verilmiştir.

$$F' = \text{span}(L_1, L_2, \dots, L_M) \quad (2.4)$$

$J'$  ifadesi uç alanların lineer kombinasyonu olarak tanımlanır.

$$J' = \omega^T L \quad (2.5)$$

İfade (2.5)'te  $\omega$  ifadesi, ölçümlerle değerlendirilen ağırlıklandırma skaler değeridir.  $J^{\wedge}$  tahmini için bir dizi denklem elde edilmiştir.

$$b = \Gamma \omega \quad (2.6)$$

$b = [B_1, \dots, B_M]^T$ ,  $\omega = [\omega_1, \dots, \omega_M]^T$  ve  $\Gamma \in \mathfrak{R}^{M \times M}$  uç alanların iç çarpımı vardır ve şöyle ifade edilir:  $\Gamma_{ij} = \langle L_i, L_j \rangle$

Burada  $\Gamma$ 'nin özdeğer ayrıştırması  $\omega$  'nın hesaplanmasında en büyük hataya katkıda bulunan çok küçük özdeğerlere sahip olduğunu göstermektedir. Çözümde, bu kararsızlığı ortadan kaldırmak için, çözümde, daha küçük özdeğerlere sahip özdeğerlerin daha az sinyal-gürültü değerlerine sahip oldukları için göz ardı edildiğini belirten düzenleme yapılır. Bu nedenle, özdeğer ayrıştırmasında yapılan değişikliklerle, Minimum Norm için düzenleme ile tahmini çözüm ifade (2.7)'de verilmiştir:

$$\hat{J}' = \left[ (\hat{\Gamma})^{-1} b \right]^T L \quad (2.7)$$

Manyetometrede görülen değerler, akım dağılımları ve uç alanlar arasındaki ilişki doğrusal olarak böyle ifade edilmektedir. Akım kaynaklarının bulabilmesi için, ölçüm değeri ile uç alanlar matrisinin yalancı tersinin çarpılması gerekmektedir.

Minimum norm çözümü hem gürültülü hem de bozucu etkilerden arındırılmış sinyaller için uygulanmıştır ve tahminler yapılmıştır. Minimum norm yönteminin başarısını artırmak

için, korteksteki entegrasyon alanını sınırlandırmak gibi önsel varsayımların veya bilgilerin kullanılması önerilmektedir.

Geri problem çözümü için ayrıca, kullanılan elektrot sayısı ile ilgili de çalışmalar yapılmaktadır. Daha fazla elektrot kullanımı ile daha doğru çözüm elde edileceği bildirilmektedir. Minimum norm yöntemi, çözünürlük ve akım kestirimini başarıyla yapmaktadır. Bu yöntemin başarısız olduğu bir işlem, derin kaynakların bulunmasıdır. Yani bu yöntemle korteks yüzeyine yakın kaynaklar başarıyla bulunabilirken, derinde yer alan kaynakları tespit edilememektedir.

#### 2.1.2.4. Standardized Low Resolution Brain Electromagnetic Tomography (sLORETA)

Bu yöntem akım yoğunluğunun standartlaşmasına dayanmaktadır. Bu amaçla EEG ölçümündeki gürültünün varyansı ile biyolojik olarak sinyalin varyansı da dikkate alınmaktadır. Biyolojik varyansın bağımsız ve aynı dağılımı dikkate alınınca kaynaklar en doğru biçimde elde edilmektedir.

Bu yöntem minimum norma benzese de standartlaşmada farklı yöntem kullanır. Aşağıda bu yöntemin hesabında kullanılan formüller verilmiştir [11].

$$F = \|Y - LJ - c_1\|^2 + \alpha \|J\|^2 \quad (2.8)$$

İfade (2.8)'de  $\alpha \geq 0$  düzenleme parametresidir. Bu ifade J ve c'ye göre L uç-alanı, Y voltaj ölçümleri ve düzenleme parametresi ( $\alpha$ )'ya göre minimize edilmelidir. Bu tür bir minimizasyon için kesin çözüm ifade (2.9)'da verilmiştir.

$$J' = TY, \quad T = L^T H [HLL^T H + \alpha H]^+ \quad (2.9)$$

Burada  $H \in \mathfrak{R}^{N_E \times N_E}$  merkezleme matrisidir ve ifade (2.10)'daki gibi hesaplanır:

$$H = I - \frac{11^T}{1^T 1} \quad (2.10)$$

Ancak  $I \in \mathfrak{R}^{N_E \times N_E}$  birim matrisidir ve  $1 \in \mathfrak{R}^{N_E \times 1}$  ise birlerden oluşan bir vektördür. Ölçümler için ortalama referans kullanılırsa (2.11)'deki ifade elde edilir:

$$F = \|Y - LJ\|^2 + \alpha \|J\|^2 \quad (2.11)$$

İfade (2.11)'deki çözüm yapılırsa:

$$J' = TY, T = L^T[LL^T + \alpha H]^+ \quad (2.12)$$

Çözümün standardizasyonu için  $J'$  değerinin varyansı bulunmalıdır.  $S_J \in \mathfrak{R}^{(3N_V) \times (3N_V)}$  birim matrise eşittir.

$$S_J = I, I \in \mathfrak{R}^{(3N_V) \times (3N_V)} \quad (2.13)$$

İfade (2.13)'te yer alan  $N_v$ , beyindeki voksel sayısıdır.

Potansiyel ölçümler, gürültüler nedeniyle varyansı ifade (2.14)'teki gibi verecektir.

$$S_Y^{noise} = \alpha H \quad (2.14)$$

Gerçek kaynak aktiviteleri ve gürültü bağımsız olarak ele alınırsa, elektrik potansiyel değişimi ifade (2.15)'teki gibi tanımlanacaktır.

$$S_Y = LS_J L^T + S_v^{noise} = LL^T + \alpha H \quad (2.15)$$

Böylece, tahmin edilen akım yoğunluğu ifade (2.16)'daki gibi olacaktır.

$$S_{J'} = TS_Y T^T = T(LL^T + \alpha H)T^T = L^T[LL^T + \alpha H]^+ L \quad (2.16)$$

Tahmin edilen sLORETA akım yoğunluğu ise ifade (2.17)'deki gibi olacaktır.

$$J' = TLJ = L^T(LL^T + \alpha H)^+ LJ = S_{J'} J \quad (2.17)$$



### 2.1.2.5. Dynamic Statistical Parametric Mapping (dSPM)

Dinamik İstatistiksel Parametrik Haritalama tekniği, geri problem çözümünde, derinlik yanılmasını telafi etmek için geliştirilen yöntemdir. Bu tekniğe Dale ve Liu [90] tarafından yapılan çalışmada yer verilmiştir. İfade (2.18)'de  $P$ , doğrusal ters operatörü Wiener operatörüne veya ilişkili gürültü-düzenli yalancı-ters operatöre karşı gelmektedir. Hesaplama bu ifadeyle yapılır [91].

$$P = C_s L^T (L C_s L^T + C_n)^{-1} \quad (2.18)$$

$C_s$  kaynak kovaryans matrisine karşılık gelmektedir ve birim (identity) matrisi olarak kabul edilmektedir.  $C_n$  gürültü kovaryans matrisi ve  $L$  ifadesi uç alanlar (Leadfield) matrisidir. Ardından, gürültü normalize edilmiş operatör, sabit yönelimli dipol durumunda ifade (2.19)'daki gibi hesaplanmaktadır.

$$P_{norm} = \text{diag}(v)^{-\frac{1}{2}} P \quad (2.19)$$

$v = \text{diag}(P C_n P^T)$ , dSPM'de geri çözüm operatörü  $P$  hesaplandıktan sonra gürültü normalizasyonu yapılmaktadır.

### 2.1.2.6. Dipolar Yöntem

Kafa derisinden elde edilen EEG kayıtları ile kaynakların ve konumlarının belirlenmesi için kullanılan bir yöntem de dipolar modeldir. Yaygın olarak kullanılmaktadır. Kaynak bilgisi ve konum bilgisi hem beyin bilgisayar uygulamaları için hem de epilepsi gibi klinik uygulamalar için faydalı olmaktadır.

Bu tezde, beynin işleyişinin daha iyi anlaşılabilmesi için, kaynak lokalizasyonu aracılığıyla beyindeki sinyaller elde edilmektedir. Bu sayede, motor hayali esnasındaki kayıt elektrot bilgileri yerine, EEG kaynak sinyal bilgileri kullanılarak sonuç elde edilmesi amaçlanmaktadır.

Kaynak modeli ve kafa modeli ne kadar doğru oluşturulursa, geri çözüm ve kaynakların tespiti de o kadar doğru olacaktır. Kafa modeli ve kaynak modeli sonucunda bulunmuş olan kaynağın, gerçek kaynağı temsil ettiği varsayılmaktadır [92].

Dipolar yöntemde, her bir kaynak adayı bölgeye bir dipol yerleştirilerek, dipol tarama haritası oluşturulmaktadır. Bu harita sayesinde, dipolün hangi zaman aralığında ve nerede oturduğunu gösterebilmektedir. Belirli bir zaman noktasında hangi dipolün aktif olduğunu anlamak için dipol arama kullanılabilir.

Dipolar kaynak yerelleştirmesinde, ölçüm ve model verileri arasındaki hatanın en minimuma ulaşabilmesi için kaynak parametrelerinde düzenleme yapılmaktadır.

- Her kaynağın konumu
- Her kaynağın yönü
- Her kaynağın gücü
- Dipol momenti, yön ve gücü birlikte barındırmaktadır ve doğrusal olarak hesaplanmaktadır
- Konum doğrusal olmayan yöntemle bulunmaktadır.
- Kaynak parametresi kestirimi önemlidir.

İfade (2.20)'de dipol hesaplamada kullanılan formüller verilmiştir [93]. Geri problem çözümü, kafa derisi üzerinde belirli bir potansiyele karşılık gelen, dipol kaynağının parametrelerinin bulunması işlemini gerçekleştirmektedir. Tek bir zaman anında  $M$  tane elektrot yardımıyla ölçülen EEG verileri, ifade (2.20)'deki gibi hesaplanmaktadır.

$$J = \|V - GM\|_F^2 \quad (2.20)$$

$\|\cdot\|_F$  Frobenius normuna karşı gelmektedir;  $V$ ,  $m \times 1$  uzunluğunda vektördür.  $G$ , transfer matrisidir.  $M$ ,  $3K \times 1$  uzunluğunda eş değer dipol (ECD) momentleri vektörüdür.  $m$ , elektrot sayısına;  $K$ , ilgili zaman anındaki eş değer dipol (ECD) sayısına karşı düşmektedir.

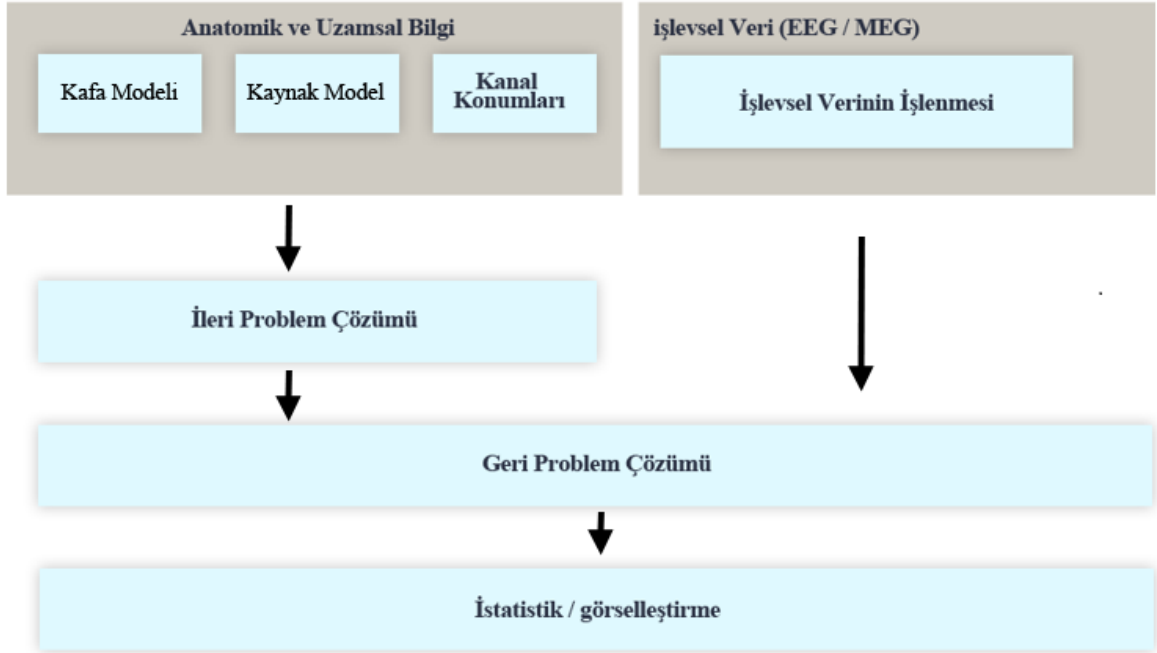
Dipol kaynak lokalizasyonunun karmaşıklığını azaltmak için, açık dipol momentlerini, normal eşitliğe dönüştürülür.  $M = G^+V$ , ve  $G^+ = (G^T G)^{-1}G^T$  ifadesi,  $G$  transfer matrisinin, Moore-Penrose Yalancı Ters ifadesi olarak bilinir.  $J$  maliyet fonksiyonu ifade (2.21)'deki gibi hesaplanmaktadır.

$$J = \|V - G(G^+V)\|_F^2 \quad (2.21)$$

## 2.2. Brainstorm Yazılımı ile Kaynak Lokalizasyonu Adımları

Çalışmada, kaynak lokalizasyonu için Brainstorm [94] yazılımı kullanılmıştır. Şekil 13'te Brainstorm yazılımı ile kaynak yeniden yapılandırma adımları verilmiştir. Brainstorm yazılımı ile kaynakların yeniden elde edilmesi için aşağıdaki adımlar takip edilmelidir:

- Anatomi dosyasının hazırlanması
- Kanal dosyasının hazırlanması
- Elektrotlar ile MRG görüntüsünün çakıştırılması
- Kafa modelinin oluşturulması ve eklenmesi
- Geri problem çözümünün elde edilmesi



Şekil 13. Kaynak Yeniden Yapılandırma Adımları [95]

### 2.3. İletkenlik Değerlerinin Tahmin Edilmesi

#### 2.3.1. Beyin İletkenlik Değeri

Beyinde iki doku ayırt edilir. Bunlar gri cevher ve ak cevherdir. Gri cevher nöronal hücre gövdelerinin oluşturduğu yapıdır. Kaydı alınabilen akımların kaynaklarının olduğu yerdir. Hücreler arası iletişim nöronların her bölgesi ile yapılır, bu iletişim noktaları sinapslardır. Hücre gövdesi ve aksonun dahil olduğu bağlantılardır. Ak cevher, hücre gövdesinden çıkan miyelinli aksonlardan oluşur ve perifere uzanır.

Sekino vd. 2005 yılında beyin gri ve beyaz maddelerinin izotropik yapısı üzerine araştırma yapmışlardır [96]. Araştırmaları sonucunda gri maddenin izotropik olduğu, beyaz maddenin ise izotropik olmadığı bulgularına erişmişlerdir. Yani, gri maddenin özellikleri her yönde aynıdır. İletkenlik açısından gri ve beyaz maddenin değerleri birbirine yakındır. Araştırmalar beyaz maddenin iletkenlik değerinin daha düşük olduğunu gösterse de simülasyon çalışmalarında, her iki maddenin iletkenlik birbirine eşit alınması önerilmektedir.  $\sigma_{brain} = 0.12 - 0.48$  S/m aralığında olduğu belirtilmektedir. Bu çalışmada beyin iletkenlik değeri Brainstorm yazılımında önerilen değer, 1 S/m olarak alınmıştır.

#### 2.3.2. Beyin Omurilik Sıvısı (BOS) CSF

BOS, diğer vücut sıvılarında olduğu gibi yüksek iletkenliğe sahiptir çünkü yapısında çözünmüş tuzlar barındırmaktadır. Farklı hastalar üzerinde yapılan ölçümlerde bu iletkenlik değerinin az miktarda değiştiği gözlemlenmiştir. Genellikle beyin beş katı iletkenlik değerine sahip olduğu kabul edilmektedir ve değer olarak  $\sigma_{BOS} = 1.5$  S/m civarında kabul edilmektedir.

#### 2.3.3. Kafatası (Skull)

Kafatası, hacim iletkenliğinde çok önemlidir çünkü diğer dokulara oranla en düşük iletim buradadır. 1968 yılında kafatası iletkenliği Rush ve Driscoll'un çalışması ile hesaplanmıştır [97]. Beyne oranla 1/80 seviyesinde iletimin olduğu düşünülmektedir. Bu hesaplama 3-küresel yapı üzerinde yapılmıştır. Sonraki yıllarda yapılan araştırmalarda bu

oranın 1/20 ile 1/72 arasında deęiřtięi farklı arařtırma grupları tarafından ortaya konulmuřtur [98].

### **2.3.4. Kafa Derisi (Scalp)**

Kafa derisi yumuřak ve yaęlı dokulardan meydana gelmektedir. İletkenlik deęerinin beyininkinden biraz fazla olduęu dūřnūlse de biręok ęalıřmada bu deęer beyninkine eřit kabul edilerek sonuęlar elde edilmektedir [99].

## **2.4. EEG Sinyallerinin Ön iřlenmesi**

EEG sinyalleri kayıt altına alınırken beyin sinyallerinin yanında fiziki ve ęevresel nedenlerden kaynaklanan sinyaller de ölçūme eklenmektedir. Kas hareketlerinden, göz hareketlerinden, kalp atıřlarından, cihazdan veya baęlantılardan kaynaklanan gürültülerin elimine edilmesi ęok önemlidir. Özellikle kas hareketleri nedeniyle meydana gelen gürültüler yüksek genlięe sahip olmaktadır ve elimine edilmeleri gerekmektedir [100].

### **2.4.1. Özellik Seçimi**

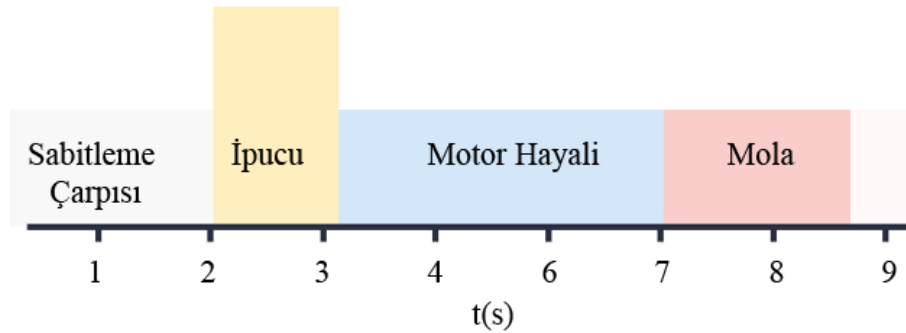
EEG paręalarından veya bir EEG kanalından birden fazla özellik vektörü elde edilmektedir. Bu vektörler EEG sinyallerini temsil etmektedir. Ancak bu vektörlerin boyutlarının ęok büyük olması sınıflandırma hızı için olumsuz etki meydana getirmektedir, ayrıca eğitim iřleminin de uzaması anlamına gelmektedir. Bu yüzden literatürde, özellik seçimi için ęeřitli yöntemler önerilmiřtir [101]. Özellik seçimi, makine öğrenmesiyle elde edilen özellik vektörlerinden, yüksek öneme sahip özelliklerin seçilmesi anlamına gelmektedir. Bu özelliklerin seçimi için farklı yöntemler önerilmiřtir. Genellikle özellikler önem sırasına koyulmaktadır ve bunların sıralamada deęerli görülen kısmı eğitim ve test iřlemlerine tabi tutulmaktadır.

## **2.5. Kullanılan Veri Tabanları**

Bu ęalıřmada farklı özelliklere sahip, 2 veri kümesi üzerinde sonuęlar elde edilmiřtir.

### 2.5.1. Veri Kümesi 2a Motor Hayali (Data sets 2a: 4-class motor imagery)

Bu veri kümesi 9 denekten alınan EEG motor hayaline dayalı olarak oluşturulmuştur [102]. Beyin Bilgisayar Arayüzü türlerinden ipucu tabanlı olarak çalışmaktadır. Veri kümesi; sol elin, sağ elin, iki ayağın ve dilin motor hayali verileri olmak üzere dört farklı motor hayaline dayalı verilerin kaydedilmesiyle oluşturulmuştur. 6 farklı seansta 48'er deneme (her bir sınıf için 12 kez) yer almaktadır. Toplamda 288 deneme vardır. Yani, her bir sınıf için elde 72'şer kayıt bulunmaktadır. Kayıtlar alınırken denekler rahat koltukta oturmuş olup  $t=0$  anında ekranda sabitleme çarpısı belirmiştir ve aynı zamanda hafif akustik tonda hafif uyarı işareti verilmiştir. Sabitleme çarpısı deneklerin ekrana odaklanmaları için verilen bir işaret olup, aynı zamanda deneyin başlamak üzere olduğunu da deneklere bildirmektedir. 2. saniye sonunda ipucu işareti ekranda gösterilerek motor hayalinin yapılması sağlanmaktadır. Sağa, sola, yukarıya ve aşağıya dönük ok işaretlerinin her biri farklı bir motor işareti (sağ el, sol el, iki ayak ve dil) karşılık gelmektedir. İpucu ekranda 1,25 saniye boyunca gözükmektedir. Bu sayede, motor hayalinde neyin düşünülmesi gerektiği deneye bildirilmiş olmaktadır. Kayıtlar esnasında geri bildirim alınmamıştır. Deneklerden, 6. saniyenin sonunda sabitleme çarpısı ekrandan kaybolana kadar motor hayaline devam etmeleri istenmiştir. Ardından kısa bir ara verilerek sonraki kayıtlara geçilmiştir. Bu çalışmada, sağ ele ve sol ele ait için olan kayıtlar üzerinde çalışılmıştır. Tez kapsamında el ve ayakla ilgili motor hayal işaretleri incelenmiş ve beynin hangi loplarında değişiklik meydana getirdiği üzerine çalışılmıştır. Bu deney esnasında iki ayağın birlikte hayali her iki lopta da değişiklik meydana getireceği için, iki ayağın birlikte motor hayali ve dil ile ilgili işaretlerin sınıflandırılmasına bu tez kapsamında yer verilmemiştir. Şekil 14'te kayıtlama yapılırken kullanılan paradigmanın zamanlama grafiği gösterilmiştir.



Şekil 14. Kayıtlar alınırken kullanılan paradigmanın zamanlama diyagramı

### 2.5.1.1. Veri Kaydı

EEG kaydı yapılırken 22 adet Ag/AgCl elektrot kullanılmıştır. Kayıtlar, 10-20 standardına göre alınmıştır. Sol mastoid tüm kanallar için referans olarak seçilip, monopolar kayıtlar yapılmıştır. Sağ mastoid ise toprak olarak seçilmiştir. Sinyaller 250 Hz ile örneklenmiş ve 0.5-100 Hz aralığında bant geçiren filtreleme yapılmıştır. Amplifikatör hassasiyeti 100  $\mu$ V olarak ayarlanmıştır. Hat gürültüsünü elimine etmek için 50 Hz çentik filtresi kullanılmıştır.

### 2.5.2. Veri Kümesi IVa (Data set IVa <motor imagery, small training sets>)

Bu veri kümesi 5 sağlıklı bireyden alınan EEG kayıtlarını içermektedir [103]. Kayıtlar 3 farklı motor hayali (sol el, sağ el ve sağ ayak) denemelerini içerse de yarışma için 2 farklı motor hayaline dayalı veriler (sağ el ve sağ ayak) kullanıma sunulmuş ve performans değerleri istenmiştir. Yapılması istenen motor hayalinin yaklaşık 3,5 saniye sürmesi istenmiş ve görsel ipucu kullanılmıştır. Deneklerden geri bildirim alınmamıştır. Deneklerin rahat bir koltuğa oturmaları ve dirseklerini koltuk yanlarına koymaları sağlanmıştır. İki tür görsel uyarım yapılmıştır. İlkinde sabitleme çarpısının içinde harf oluşmuş, bu şekilde göz hareketleri indüklenebilir olmuş; ikinci de ise rastgele olarak hareket eden nesneyle ilintisiz göz hareketleri ile görsel uyarımlar yapılmıştır.

118 adet EEG elektrotu kullanılarak kayıtlar elde edilmiştir. Her bir denek için toplamda 280 örnek alınmıştır. Denek isimleri 2 harfli kodlarla temsil edilerek, bireylerin kişisel verileri korunmuştur. Her bir denek için farklı sayıda eğitim ve test verileri sağlanmıştır. Az sayıda eğitim verisi olunca, yüksek başarı elde etmek daha zor olmaktadır. Denek ay incelendiğinde sadece 28 eğitim verisine sahip olduğu görülmektedir. Bu bireye dair 252 test verisi için sonuçlar verilmiştir.

Tablo 1. Veri kümesi 4a'da yer alan eğitim ve test örnek sayıları

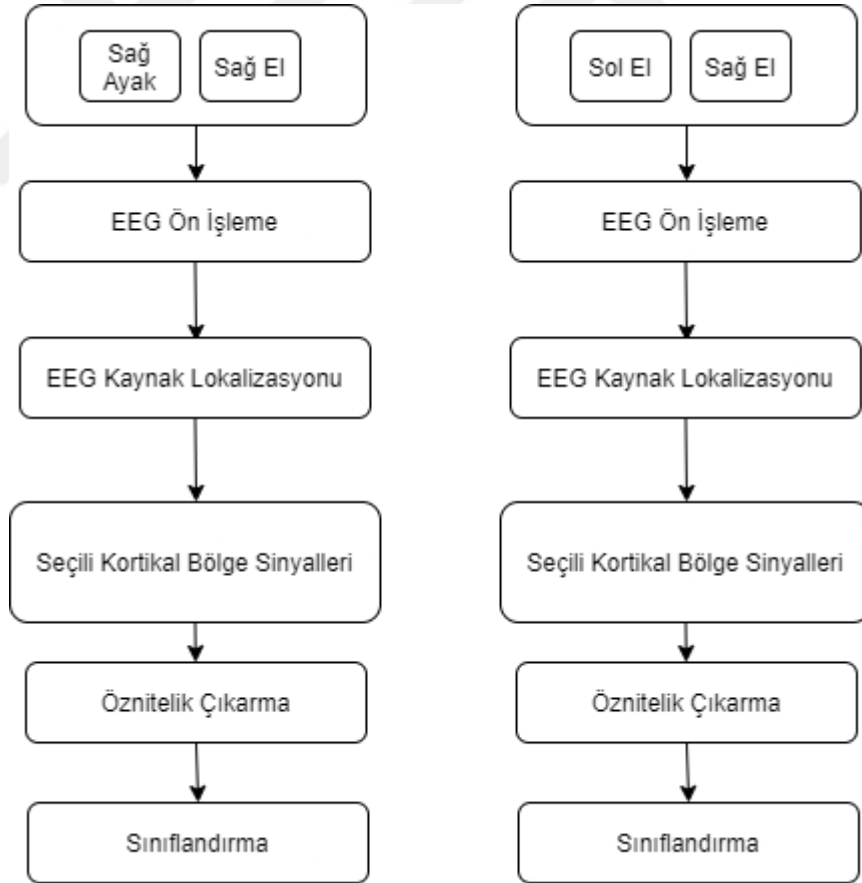
	#eğitim	#test
<b>aa</b>	168	12
<b>al</b>	224	56
<b>av</b>	84	196
<b>aw</b>	56	224
<b>ay</b>	28	252

### 2.5.2.1. Teknik Bilgiler

118 adet EEG kanalıyla 10-20 sisteminin genişletilmiş hâliyle kayıtlar alınmıştır. Veriler 0.05 Hz – 200 Hz aralığında bant geçiren filtreye tabi tutulmuştur. Veriler her ne kadar 1000 Hz ile örneklenerek elde edilmiş olsalar da, her onuncu örneklerinin alınması suretiyle 100 Hz ile örneklenmiş gibi kullanıma sunulmuştur.

### 2.6. Yapılan Çalışmaların Akış Diyagramı

Bu tezde Motor Hayali ile doğruluk değerlerinin bulunması ve yüksek doğruluk değerlerine ulaşılan bölgelerin tespit edilebilmesi için Şekil 15'te verilen iş akışları kullanılmıştır. Solda Veri Kümesi 4a için ve sağda Veri Kümesi 2a için akış diyagramları verilmiştir.



Şekil 15. Akış diyagramları Veri Kümesi 4a ve Veri Kümesi 2a



## 2.7. EMKG Çözümünün Başarılı ve Güvenilir Olması için Gerekli Parametreler

Doğru çözüm elde etmek adına önem taşıyan parametreler aşağıda verilmiştir. [32, 104].

- Kafa yüzeyine yerleştirilen elektrotların sayısı ve pozisyonu
- Referans elektrotun seçimi
- Elektrot tipi
- Motor hayali için uygun zaman pencerelerinin belirlenmesi
- Varsayımların geçerliliği
- Uygun gerçek kafa modeli oluşturulması
- Doğru MRG kesitinin seçilmesi
- Oluşturulan kafa modelindeki hacim iletkenlerinin öz-iletkenlikleri
- Kafa modeli ile elektrot pozisyonlarının ve MRG uzaylarının karşılaştırılması
- Geri problem algoritmasının seçilmesi
- Denek etkisi

### 2.7.1. Kafa Yüzeyine Yerleştirilen Elektrot Sayısı ve Pozisyonu

Klinik uygulamalarda ve BBA uygulamalarında, birbirinden farklı elektrot sayısının tercih edildiği çalışmalarla karşılaşılmaktadır. Bazı klinik çalışmalarda, referans ve toprak elektrotları dışında sadece tek bir elektrot ile yapılan kayıtlar yardımıyla araştırmalar yapılmakta ve anlamlı sonuçlar elde edilmeye çalışılmaktadır. Ancak çoğu EEG/ERP çalışmalarında, eş zamanlı olarak birden fazla beyin bölgesinden gelen sinyaller yardımıyla kayıtlamalar yapılmaktadır. Çok elektrotlu EEG kayıtlarına kıyasla veri farklı bileşenlere ayrılabilir, bazı bozucu etkiler belirlenebilmektedir ve özellik çıkarma işlemi optimize edilebilmektedir [105, 106].

Elektrot sayısının kaç olması gerektiği konusunda bilim insanları farklı görüşler ortaya koymuşlardır. Bazı araştırmacılar kayıt konumlarının sayısının, kafa derisi EEG kayıtlarında sunulan uzamsal frekansla ilişkili olabileceğini bildirmişlerdir [107]. Luck, 2014 [108] yılındaki çalışmasında, birçok deney için 32 elektrotun yeterli olabileceğini öne sürmüştür; daha fazla elektrot kullanılması ile bazı problemlerin tespitlerinin ve çözümlerinin daha zor olabileceğini, böylece EEG veri kalitesinin daha da düşebileceğini bildirmiştir. Teplan, 2002

yılında [109] çok sayıda 256'ya kadar yüksek yoğunluklu kayıt elektrotu kullanılması ile uzamsal çözünürlüğün artacağını bildirmiştir. Çoklu EEG kaydında, daha fazla elektrot kullanılması ile, elektrotların yerleştirilmesi için daha fazla zaman ve zahmet gerekecektir. Ayrıca, elde edilen kayıtların analizi daha fazla işlem gerektirecektir ve daha pahalı sistemler kullanmak gerekecektir.

EEG kaynak analizi çalışmaları incelendiğinde ise, elektrot sayısının az olmasının kaynak analizinde hatalara yol açabileceği, en az 64 EEG elektrotunun kullanımı ile kaynak analizlerinin daha yüksek doğrulukla yapılabileceği sonucuna ulaşılmaktadır [110, 111, 112, 113, 114].

### **2.7.2. Referans Elektrotun Seçimi**

Referans elektrot ile beyindeki aktif elektriksel kaynak arasındaki mesafe arttıkça, elde edilen kayıtlardaki gürültünün arttığı bildirilmiştir. Bu durumda, kaynak lokalizasyonunun başarısının azalabileceği bildirilmiştir. Bu durumda, elde edilecek olan kortikal EEG sinyallerinde de bir miktar hata olması beklenecektir.

Referans noktası değiştiği zaman EEG potansiyel değerlerinin farklılaştığı, ancak EEG topoğrafik haritasına bakıldığı zaman ise önemli bir değişikliğin olmadığı gösterilmiştir. Michel vd. 2004 yılındaki araştırmalarında, referans elektrot değişince 0 noktasının yer değiştirdiğini ancak topoğrafyada önemli bir değişiklik olmadığını göstermişlerdir [115].

### **2.7.3. Elektrot Tipi**

Elektrotlar, genel olarak kayıttaki görevlerine göre üç kategoriye ayrılmaktadır. Bunlar aktif elektrotlar, referans elektrotlar ve toprak elektrotlarıdır. Her bir EEG elektrotundaki değer, aktif elektrot ile referans elektrot arasındaki potansiyel farkın zaman eksenindeki değişimleri olarak kabul edilmektedir [109]. Teoride, referans elektrot uzak konumda olmalıdır ve mutlak potansiyeli 0 olmalıdır. Böylece, ölçümde A bölgesi görülebilecektir ve A-R farkı en güzel şekilde ölçülebilecektir. Ancak uygulamada, referans bölgesi çoğu durumda bu özelliklere sahip olamamaktadır. Bu yüzden ölçüm, aktif bölgeyi ve referans bölgesini içermektedir. Toprak elektrotu, toprak devresine yapılan bağlantının oluşturmuş olduğu gürültünün giderilmesinde kullanılmaktadır. Çoğu EEG kayıt sisteminde birden fazla

aktif elektrotla ve birer tane de referans elektrotu ve toprak elektrotuyla karşılaşılmaktadır [105].

Sinyalin daha kaliteli olması için kullanılan elektrotlar da önemlidir. Bu nedenle genellikle gümüş ve gümüş klorür içeren elektrotlar genellikle tercih edilmektedir. EEG’de küçük bir zaman değişimiyle birlikte küçük potansiyel değişimlerinin de hassas bir şekilde kaydedilebilmesi önem taşımaktadır. Bu yüzden birçok kayıt sisteminde Ag/AgCl kayıt elektrotları kullanılmaktadır. Temiz ve kaliteli kayıtlar için kafa derisi ile elektrot arasındaki boşluğu kapatmak için özel jeller kullanılmaktadır. Böylece daha doğru ölçümler yapılabilmektedir.

Genel olarak elektrot tipleri şu şekildedir [116]:

- Geleneksel Islak Ag/AgCl Elektrotlar (Wet)
- Aktif Kuru Tek Altın Pim Bazlı Elektrotlar (BP Gold)
- Hibrit Kuru Çoklu Sivri Tabanlı Elektrotlar (Quasar)
- Pasif Kuru Katı-Jel Bazlı Elektrotlar (BP Katı)

Bu çalışmada elektrotların değerleri karşılaştırılmayacaktır, ancak, bu elektrotların fiyat, kullanım kolaylığı, üretimlerinin daha kolay olmaları gibi özelliklerinden daha çok elektriksel davranışları dikkate alınacaktır. Bu noktada bu sistemlerin en az zaman gecikmesine ve zayıflamaya sahip olması gerekmektedir. Bu ise elektrotların deri ile temasta oluşturdukları empedansın, kapasitif, endüktif ve rezistif değerlerinin en düşük seviyede olmasını gerektirmektedir.

Bu tez kapsamında kullanılan veri kümelerinde tercih edilen EEG elektrotları Ag-AgCl olup, bu durumun ölçümlerin güvenilir olmasına katkı sağladığını söylemek mümkündür.

#### **2.7.4. Epok Belirleme**

EEG kayıtları çok kısa sürebildiği gibi, saatlerce hatta günlerce de sürebilmektedir. Analizlerin yapılabilmesi için belirli bir zaman aralığındaki kayıtlar seçilmekte ve hesaplamalar bu pencere veya pencereler için yapılmaktadır [117, 118]. Pencere seçiminde uzman görüşü oldukça önemlidir. Motor hayaline dayalı bir uygulamada, kaydın her anında deneğin aynı konsantrasyonda olması oldukça zordur. Bu yüzden, deneğin konsantre olduğu

anların seçilmesi, başarı artırıcı bir etken olacaktır. Bunun yanında, epilepsi üzerindeki çalışmalarda epileptik nöbetin başlama anının hassas olarak seçilebilmesi oldukça önemlidir.

Klinikte uyku EEG verileri göz önüne alındığında, farklı uyku tiplerinin belirlenerek seçilen pencereler yardımıyla işlem yapılması yine daha uygun olacaktır. Pencerelemede, başlangıç anının seçilmesi ve pencere uzunluğunun belirlenmesi yine sonuca etki edebilecek olan önemli parametreler olmaktadır [119].

### **2.7.5. Varsayımların Geçerliliği**

Beyindeki EEG sinyallerinin kaynağının bulunabilmesi için EEG geri problemi çözülmelidir; ancak bu problemin birçok bilinmeyen parametresi vardır [115]. Sonuç üretebilmek için belli önsel varsayımlar yapılmalıdır. Bu amaçla anatomik, fizyolojik, biyofiziksel, istatistiki ve matematiksel bazı varsayımlar yapılmaktadır. Bu önsel varsayımlar sonucunda geri problem çözümüne ulaşılmaktadır.

EEG kaynak analizinin en doğru biçimde çözümü için önsel varsayımların gerçeğe en yakın olması oldukça önemlidir. Bu tez kapsamında farklı metotlarla çözümler yapılmış ve gerçek kafa modeli olmadığı için, gerçeğe en yakın kafa modellerinden ICBM152 [120] tercih edilmiştir.

### **2.7.6. Kafa Modelinin Uygun Seçimi**

Kaynak seviyesinde EEG sinyallerinin elde edilmesinde deneklerden veya hastadan elde edilen gerçek MRG ile hesaplanan gerçek kafa modeli veya küresel kafa modelleri kullanılabilir. Literatürde, kafa modellemelerinde beyin, beyin omurilik sıvısı, kafatası ve saçlı deri olmak üzere 4 tabaka kafa modelinde göz önüne alınmaktadır [121].

Basitliği ve hızlı matematiksel işlem yapılabilmesi sayesinde küresel kafa modelleri tercih edilebilmektedir [122]. Bu durumda kafanın homojen iç içe 3 veya 4 tabakadan oluştuğu varsayılmakta ve işlemler bu doğrultuda yapılmaktadır. İleri problem çözümleri hızlı ve kolayca gerçekleştirilmektedir. Ancak MRG incelendiğinde, insan kafa yapısının homojen olmadığı ve küresel formda olmadığı görülmektedir. Bu yüzden, küresel kafa modeliyle elde edilen sonuçlarda bir miktar hata olması beklenmektedir. Daha yüksek doğruluk için gerçekçi kafa modelleri önerilmektedir.

Son yıllarda MRG yönteminin yaygınlaşması ve hesaplamalarda kullanılan bilgisayar donanımlarının daha güçlü, hızlı ve ucuz olmasıyla birlikte birçok çalışma artık gerçekçi kafa modeline dayanmaktadır. En sık kullanılan yöntemler BEM, FEM ve FDM'dir.

Eğer elde hastanın veya deneye gönüllü katılan deneğin gerçek MRG görüntüsü varsa, gerçekçi kafa modelinin bu görüntüden oluşturulması hesaplamaların doğruluğu için oldukça faydalı olacaktır. Eğer MRG görüntüsü mevcut değilse, bu durumda, literatürde şablon olarak sunulan MRG'ler kullanılarak işlem yapılması daha anlamlı olacaktır.

### **2.7.7. Doğru MRG Kesitinin Seçilmesi**

MR görüntü kalitesi de yapılacak işlemler için oldukça önemlidir. Eğer görüntü yeterince net değilse veya görüntü gürültülü ise kafa bölümleri net olarak seçilemeyecektir. Bu yüzden, net görüntünün olduğu ve kafa dokularının rahatça seçilebileceği MRG kesitlerinin seçilmesi önem taşımaktadır.

### **2.7.8. Öziletkenlik Değerleri**

Kafa modelinde yer alan farklı dokular için farklı öz iletkenlik değerleri vardır. Bu değerlerin ne olması gerektiği hakkında farklı literatür çalışmaları vardır ve bu çalışmalarda farklı değerlerle karşılaşılabilmektedir. Ayrıca bu değerler kişiden kişiye de farklılıklar gösterebilmektedir.

Bu değerler kişinin yaşına, cinsiyetine, daha önce geçirmiş olduğu hastalıklara, beslenmesine, bünyesine, vücut sıcaklığına ve çevresel faktörlere bağlı olarak değişiklik gösterebilmektedir. Bu nedenle, kafa modelindeki farklı dokulara dair öz iletkenliklerin her birey için ayrıca ölçülmesinde yarar vardır [32, 123]. Doku öz iletkenlik değerlerinin hesaplanabilmesi için biyoelektromanyetik uyarım ve ölçüm tekniklerinden faydalanmak mümkündür [124, 125, 126, 127].

### **2.7.9. Elektrot Konumları ve Kafa Modelinin Çakıştırılması**

Geri problem çözümünde önemli parametrelerden bir tanesi de elektrotların konumlarıdır. Daha doğru çözümler için elektrotların doğru konumlandırılması çok

önemlidir. Kafa modeli hazırlandıktan sonra, ölçümlerin alındığı EEG elektrotlarının bulunduğu konumlar giriş verisinde yer almalıdır. Elektrot konumları 3 boyutlu sayısallaştırıcılar ile örneklenerek tam konumları verilebilmektedir. Ancak çoğu EEG çekiminde bu cihazlar kullanılmamaktadır. Bu durumda EEG elektrot konumlarını, kafa üzerinde en uygun bölgelere karşılık gelecek şekilde belirlemek mümkündür.

EEG ölçümleri yapılırken eğer bir veya birden fazla elektrotun konumunda değişiklik yapılmışsa, bu bilgiye göre elektrot konumlarının güncellenmesi gerekecektir.

### **2.7.10. Geri Problem Algoritmasının Seçilmesi**

Geri problemde amaç, var olan EEG ölçüm kayıtları kullanılarak, beyin korteksi üzerindeki kaynakların konumlarının, büyüklük ve doğrultularının bulunmasıdır. EEG geri problem çözümü için birçok algoritma önerilmiştir. Bunları dipolar ve dağıtık yöntemler olmak üzere başlıca 2 grupta toplamak mümkündür.

### **2.7.11. Denek Etkisi**

Motor hayaline dayalı EEG kaydı alınırken, deneklerin deneye konsantre olmaları da bir diğer önemli değişken olmaktadır. Kişinin, örneğin sağ elinin hareketini hayal ettiği durumda, sadece bu duruma konsantre olması arzulanan davranıştır. Kişinin aklındaki farklı düşünceler veya bu hayale tam konsantre olamaması, elde edilen EEG kayıtlarının yetersizliğine ve bu kayıtlardan elde edilecek olan özniteliklerin az anlamlı veya anlamsız olmasına neden olabilmektedir.

## **2.8. Özellik Çıkarma**

### **2.8.1. Ortak Uzamsal Örüntüler Yöntemi (OUÖ, Common Spatial Patterns, CSP)**

Ortak Uzamsal Örüntüler yöntemi, farklı motor hayaline dayalı EEG sinyallerinin ayırt edilmesinde yaygın olarak kullanılan uzamsal bir filtreleme yöntemidir [128, 129, 130].

Bu yöntem, 2 farklı sınıfa ait verilerin ayırt edilmesi için geliştirilmiştir. OUÖ ile iki sınıfa ait ortalama kovaryans matrislerinin eş zamanlı köşegenleştirilmesi ile elde

edilmektedirler. Sınıf ortalama değerleri arasında güç bakımından en büyük farklılığın bulunduğu iz düşüm eksenleri üzerine iz düşürülmüş olmaktadır. Bu yöntem yardımıyla, görevi verilen bir motor hareket hayalini içeren EEG kaydı verisinin hangi sınıfa dâhil olduğu, daha yüksek bir başarımla bulunabilmektedir [131].

OUÖ yöntemi danışmanlı öğrenmeye dayanmaktadır. OUÖ yöntemi literatürde yüksek başarıma sahip olması ve hesaplamasının kolay olması nedeniyle sıklıkla tercih edilen bir yöntem olmaktadır. OUÖ yöntemi bir sınıfın varyansını maksimum yaparken aynı anda diğer sınıfın varyansını minimum yapan uzamsal filtreler vermektedir [132].

EEG için her bir uzvun motor hayalinin bir sınıf olarak kabul edilmesiyle işlemler yapılabilmektedir. İki deneme fazla uzuvdan alınan sinyal varsa farklı matematiksel modeller gerçekleştirmek gerekecektir.

Bir EEG epokunun normalleştirilmiş uzaysal kovaryans matrisi ifade (2.22) ile hesaplanır:

$$M = \frac{DD^T}{\text{trace}(DD^T)} \quad (2.22)$$

Burada D, C×S matrisi olan bir denemeyi göstermektedir. (C, kanal sayısını ve S örnek sayısını ifade etmektedir.). trace ifadesi ise  $(DD^T)$  çarpımının köşegen elemanlarının toplamıdır. Uzamsal kovaryans matrisi ise, her sınıfın denemeleri üzerinde ortalama alınarak hesaplanmaktadır. Sonra ortaya çıkan iki matris (biri sınıf 1 için, diğeri sınıf 2 için) toplanarak birleşik kovaryans matrisi ifade (2.23)'deki gibi hesaplanır.

$$M_C = \overline{M}_1 + \overline{M}_2 \quad (2.23)$$

$M_C$  ifadesi özvektör çarpanlarına ifade (2.24)'deki gibi ayrıştırılır.

$$M_C = E_C \lambda_C E_C^T \quad (2.24)$$

Burada  $E_C$  özvektörler matrisini ve  $\lambda_C$  ise özdeğerlerin köşegen matrisidir. Daha sonra özümsaydaki varyansları eşitleyen bir beyazlatma dönüşümü olan (W) ifadesi (2.25)'deki gibi hesaplanır.

$$W = \sqrt{\lambda_C^{-1} E_C^T} \quad (2.25)$$

W, ortalama kovaryans matrislerini dönüştürmek için ifade (2.26)'daki gibi kullanılmıştır.

$$K_1 = W \overline{M_1} W^T \quad K_2 = W \overline{M_2} W^T \quad (2.26)$$

$K_1$  ve  $K_2$  ortak özvektörleri paylaşır ve ilgili iki matrise karşılık gelen özdeğerlerin toplamı her zaman 1'e eşittir. Bu durum ifade (2.27)'de verilmiştir.

$$\begin{aligned} K_1 &= U \lambda_1 U^T & K_2 &= U \lambda_2 U^T \\ \lambda_1 + \lambda_2 &= I \end{aligned} \quad (2.27)$$

I ifadesi birim matristir. Son olarak  $P = (U^T W)^T$  iz düşüm matrisinde  $P^{-1}$  sütunları ortak uzamsal örüntülerdir ve zamanla değişmeyen EEG kaynak dağılım vektörleridir. P iz düşüm matrisi ile bir EEG denemesi olan D'nin ayrıştırılması ifade (2.28)'deki gibi hesaplanır.

$$Z = PD \quad (2.28)$$

Karşılık gelen özdeğerlerin toplamı her zaman bir olduğu için, Z değerinin ilk ve son satırlarının varyansları sınıflandırma için uygun özelliklerdir.

Varyans ifade (2.29)'daki gibi hesaplanmıştır:

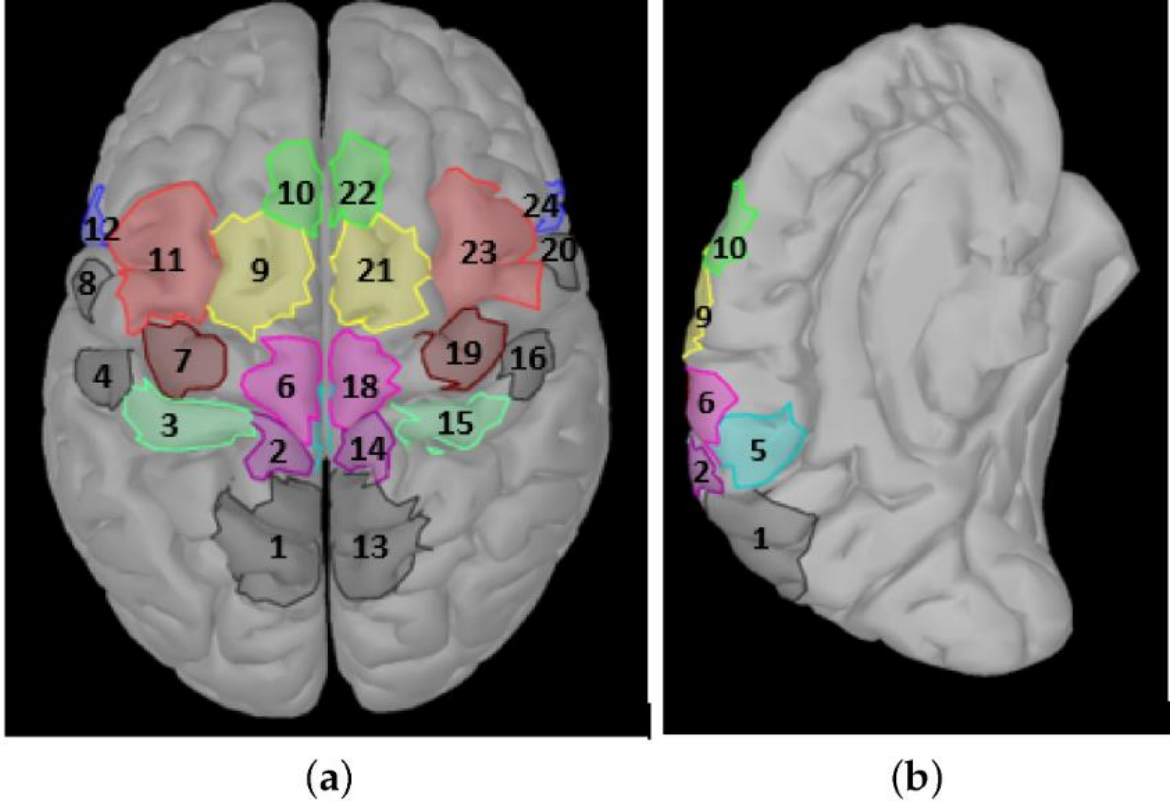
$$V = \frac{\sum (Z_R - \overline{Z_R})^2}{L - 1} \quad (2.29)$$

$Z_R$ , Z'nin bir satırıdır ve L ise bu satırın uzunluğuna karşı düşmektedir.



## 2.9. İlgili Bölge Seçimi

Motor hayalinde ilgili beyin bölgelerinin bulunması için klinik anatomi ve fizyoloji bilgileri kullanılmıştır. Beyin üzerinde motor hayali aktif olunca belirli beyin bölgelerindeki sinyallerde değişiklik gözlemlendiği, günümüzde nörogörüntüleme yöntemleri ile gösterilmektedir. Anatomik olarak yapılan incelemeler ile beyin ve çalışması hakkında temel bilgi hekimler tarafından bilinmektedir. Nörogörüntüleme ile hem bu bilgiler doğrulanmıştır hem de ufuk açıcı ve daha güncel bilgilere de erişilmiştir. Şekil 16'da motor hayalinde ilgilenilen bölgeler verilmiştir.



Şekil 16. Motor hayali ile ilgili kullanılan ilgili bölgeler Anastasiou vd. [133]

1. somatosensory association cortex (SAC),
2. primary foot somatosensory area (S1F),
3. primary hand somatosensory area (S1H),
4. secondary somatosensory area (S2),
5. cingulate motor area (CMA),

6. primary foot motor area (M1F),
7. primary hand motor area (M1H),
8. primary lip motor area (M1L),
9. supplementary motor area (SMA),
10. presupplementary motor area (pSMA),
11. dorsal premotor cortex (PMd),
12. ventral premotor cortex (PMv) areas.

## 2.10. Geri Problem Çözümü

EEG kaynak lokalizasyonu probleminde, bilinmeyen parametrelerin sayısı, bilinen parametrelerin sayısından çok fazladır. Bu yüzden bu problem hastalıklı (ill posed) olarak adlandırılmaktadır. Bu problemin çözümü için genellikle 2 yaklaşım vardır. Bunlar, parametrik yöntem ve parametrik olmayan yöntemlerdir. Bu iki yöntem arasındaki temel fark, sabit sayıda dipolün önceden kabul edilip edilmediğidir [134]. Parametrik yöntemde, en iyi dipol pozisyonları ve yönleri aranmaktadır. Parametrik olmayan yöntemde ise sabit konumda ve muhtemelen sabit yönde oldukları varsayılan dipoller tüm kortikal yüzeye dağıtılarak işlemler yapılır. Bu dipollerin genlikleri ve yönleri tahmin edilmeye çalışılır. Dipol konumu tahmin edilmediği için, doğrusal bir problemdir. EEG kayıtları ve kafa modeli kullanılarak, aktif kortikal kaynakların bulunması amaçlanır. Nörogörüntüleme yöntemleri sayesinde beynin algısal, bilişsel ve motor işlevlerinin anlaşılması sağlanmaktadır [135].

## 2.11. Sınıflandırma Yöntemleri

### 2.11.1. Destek Vektör Makineleri

Çekirdek tabanlı makine öğreniminde en iyi bilinen yaklaşım Destek Vektör Makineleri'dir. DVM, Vapnik ve arkadaşları tarafından 1992 yılında geliştirilen bir danışmanlı öğrenme modelidir [136]. İki sınıftan oluşan bir eğitim verisi DVM'ye verilirse artık bundan sonra gelen verileri uygun olarak ilgili sınıfa atayabilir. Bu yöntem ile 2 sınıfi ayıran en iyi doğru bulunmaya çalışılır. Amaç 2 sınıfa da en uzak olacak şekilde, doğrunun çizilmesidir. DVM ile bu doğrunun en uygun çizilmesi amaçlanmaktadır. Bu yöntem, iki


sınıf için geliştirilmiş olsa da günümüzde eklenen yeni yaklaşımlarla (bire-karşı-hepsi) DVM'ler ikiden çok sınıflı veriler için de kullanılabilir. Ayrıca geliştirilen yeni yöntemlerle doğrusal olarak ayrılabilen verilerin de sınıflandırılabilmesi sağlanmıştır.

DVM'nin sınıflandırma problemlerine uygulanabilmesi kolaydır. Verilerin uzayda dağılımı ile ilgili önsel bilgi veya varsayım yoktur. Eğitim seti üzerinde giriş ve çıkış değerleri işlenir. Böylece karar fonksiyonları elde edilir. Bu işlemin ardından test için verilen veya yeni değerler için çıktılar elde edilmeye çalışılır.

m tane örneğin bulunduğu eğitim kümesinin bulunduğunu farz edelim;  $\mathcal{T}_{\text{eğitim}} = \{(x_i, y_i)\}_{i=1}^m$  burada  $x_i \in \mathbb{R}^d$ ; d boyutlu giriş vektörüdür ve  $y_i \in \{-1, 1\}$  hedef sınıfları temsil etmektedir. Akla gelebilen en basit ikili sınıflandırıcı, doğrusal sınıflandırıcı olmaktadır, burada aradığımız parametreler ( $w \in \mathbb{R}^d, b \in \mathbb{R}$ ) öyle ki

$$\hat{y}(x) = \text{sign}(w \cdot x + b) \quad (2.30)$$

Eğitim kümesinin, doğrusal olarak ayrılabilirliği söylenirse, Formül (2.30)'u sağlayan sonsuz tane ( $w \in \mathbb{R}^d, b \in \mathbb{R}$ ) çözümü olabilmektedir. Bu nedenden dolayı DVM yaklaşımı iki sınıf arasında marjini maksimuma çeken parametreleri bulmaya çalışır, marjin ifadesi, ayırıcı hiper düzlem ile her bir sınıfın noktaları arasındaki en küçük mesafelerin toplamıdır [137]. Bu kavram Şekil 17'de gösterilmektedir.



Şekil 17. Destek Vektör Makinelerinde destek vektörlerin örnek bir gösterimi [138]

Bu durum, aşağıdaki denklem (2.31) optimizasyon problemi ile ifade edilebilir.

$$\min_{w,b} \frac{1}{2} \|w\|^2 \quad (2.31)$$

$$\text{koşulu ile } \forall_i y_i(w \cdot x_i + b) \geq 1$$

Burada minimizasyonu yapılacak ifade marjinin tersi ile ilişkili bir terim iken koşul ifadesi bütün örneklerin kendi sınıfında ve 2 birimlik marjin dışında yer aldığını gösterir. Bu ifadenin çözümü zor olduğu için, aşağıdaki ikili formülasyon hesaplama açısından daha verimlidir. İfade (2.32)'de verilmiştir.

$$\max_{\alpha} \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n y_i y_j \alpha_i \alpha_j x_i \cdot x_j \quad (2.32)$$

$$\text{koşulu ile } \begin{cases} \forall_i \alpha_i \geq 0 \\ \sum_{i=1}^m \alpha_i y_i = 0 \end{cases}$$

Burada  $\alpha_i, i=1, \dots, n$  Lagrange çarpıcıları temsil etmektedir. Bu formülasyonla ilgili bir sorun, eğer problem doğrusal olarak ayrılabilir değilse, ona çözüm bulunamayabilir. Bu nedenle marjini maksimize etmek ve eğitim hataları sayısını en alt düzeye indirmek arasındaki dengelemeyi kurabilecek olan ek bir C düzenleme parametresi kullanılarak hatalara izin verilerek, kısıtlamalar gevşetilebilir [139].

$$\min_{w,b} \frac{1}{2} \|w\|^2 + C \sum_i \xi_i \quad (2.33)$$

$$\text{koşulu ile } \begin{cases} \forall_i y_i(w \cdot x_i + b) \geq 1 - \xi_i \\ \forall_i \xi_i \geq 0 \end{cases}$$

İfade (2.33)'te  $\xi_i, i=1, \dots, n$  pozitif pay değişkenidir. Yukarıdaki ifade ikili formülasyonla şu şekli alır:

$$\begin{aligned} \max_{\alpha} \quad & \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^n y_i y_j \alpha_i \alpha_j x_i \cdot x_j \\ \text{koşulu ile} \quad & \left\{ \begin{array}{l} \forall_i \ 0 \leq \alpha_i \leq C \\ \sum_{i=1}^m \alpha_i y_i = 0 \end{array} \right. \end{aligned} \quad (2.34)$$

Formül (2.34) ile (2.32) beraber incelenirse yumuşak marjin DVM'nin orijinal DVM'den farkının Lagrange çarpıcılara C üst sınırının getirilmesi olduğu görülmektedir.

Doğrusal olmayan çözümler aramak için  $x$ 'in yerine  $x$ 'in doğrusal olmayan uzaydaki karşılığı olan  $\phi(x)$  konulabilir.

$x$  ifadesi Formül 2.34'te sadece noktasal çarpımda görünmektedir. Bu nedenle  $\phi(x_i) \cdot \phi(x_j)$  çarpımının çekirdek fonksiyonu  $k(x_i, x_j)$  ile değiştirilmesi önerilmiştir.  $k(\cdot, \cdot)$  tekrar tekrar üretilebilen çekirdek Hilbert uzayında var olduğu sürece,  $\phi(\cdot)$  fonksiyonunun var olduğunu garanti edilebilir.

$$k(x_i, x_j) = \phi(x_i) \phi(x_j)$$

Böylece,  $\phi(x)$ ,  $x$ 'i çok yüksek (muhtemelen sonsuz) boyutlu bir uzayda yansıtmasına rağmen,  $k(x_i, x_j)$  verimli olarak hesaplanabilir. Formül (2.34) standart 2. dereceden optimizasyon araçları kullanılarak çözülebilir.

Eğitim gerçekleştirildikten sonra yeni bir  $y$  örneğinin DVM sınıflandırma sonucu formül (2.35) ile hesaplanır:

$$\hat{y}(x) = \text{sign} \left( \sum_{i=1}^m y_i \alpha_i k(x_i, x) + b \right) \quad (2.35)$$

### 2.11.2. Yapay Sinir Ağları (YSA)

YSA, beyinde bulunan biyolojik nöronların yapısına benzer bilgi işlenmesinin sağlanması için tasarlanmış yapay modeldir. Beyin, nöronlar sayesinde hatırlama, fikir yürütme ve önceki tecrübelerini uygulama yeteneğine sahip olmaktadır [140]. Beyinde yaklaşık 100 milyar nöron vardır. İnsan beyninin üstün olmasının nedeni bu çok büyük nöron sayıları ve aralarındaki çoklu bağlantılar sayesinde [141]. YSA, düğümleri, yapay nöron

olarak kabul ederek beyni taklit etmeye çalışır. Karmaşık ve doğrusal olmayan bilgileri, paralel, dağıtılmış veya yerel olarak işleme yeteneğine sahiptir. YSA, beyin sistemlerinin mimari yapısını, mantık yöntemlerini ve işleme tekniklerini simüle eder [142]. YSA'nın temeli 1943 yılına dayanmaktadır. McCulloch ve Pitts, nöronların iki durumu olduğunu ve eşik değerine göre duruma karar verildiğini kanıtladılar [143]. McCulloch ve Pitts, ilk yapay nöron modelini geliştirdiler ve bu icat, akıllı makineler için yeni fırsatlar oluşturdu. YSA, tıp, mühendislik ve fizik gibi birçok alanda uygulandı.

Dijital bilgisayarlar sıralı programlama yapabilirken, sinir ağları paralel işlem yapabilmektedir. Dijital bilgisayarlar programlar çalıştırırken, sinir ağları ilişkisel öğrenme kurallarını kullanır. Bilgisayarlar hesaplamada başarılı olmaktadır, ancak sinir ağları örüntü tanıma, bir dili anlama gibi bilişsel işlemlerde oldukça iyidir [144]. İnsanlardaki konuşma, anlama, karar verme ve problem çözme gibi üstün bilişsel yeteneklerin, YSA aracılığıyla makinelere bu özelliklerin kazandırılabilmesi ana amaçlardan biri olmaktadır.

### **2.11.2.1. YSA'ların Çalışma Mantığı**

Biyolojik bir nöron girdileri alır ve onlar üzerinde işlem gerçekleştirmek için birleştirir ve sonuçta son çıktı elde edilir. Biyolojik nöronlar incelendiğinde; dendritler, hücre gövdesi, akson ve sinapslar olmak üzere dört ana bileşen bulunmaktadır. Dendritler, hücre gövdesine gelen sinyallerin kabul edilmesinden sorumludur. Gelen elektrik sinyalleri daha sonra hücre gövdesi tarafından işlenir ve nihai çıktıya dönüştürülür. Elde edilen çıkış sinyali daha sonra hücre gövdesinden, aksonlar vasıtasıyla diğer nöronlara iletilir. Nöronlar ve dendritler arasında bulunan noktalara sinaps adı verilir ve sinapslar, nöronlardan aldığı girdilerin toplanmasından sorumludur.

YSA modelinde, girdiler yapay bir nöronun gövdesine giriş olmaktadır. Girişler  $x(n)$  ile ifade edilmektedir; bu girdi değerleri, girdinin bağlantı gücünün bir ölçüsü olan ve  $w(n)$  ile sembolize edilen ilgili ağırlıkları ile çarpılır. Ağırlıklı girdi değerlerine, hata payı eklenerek toplama fonksiyonuna gönderilir. Nihai sonuca, gelen toplama fonksiyonunun değerine göre aktivasyon fonksiyonu çıkışa karar vermektedir.

Çok sınıflı problemler için iki sınıflı problemlerde kullanılan lojistik fonksiyonunun genellemesi olan softmax fonksiyonu kullanılmaktadır ve aşağıdaki verilen eşitlik (2.36) ile ifade edilmektedir [145]:

$$f(x_1) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (2.36)$$

Burada,  $i, j = 0,1,2, \dots c$  ve  $x_i, c$  adet birbirini dışlayan sınıfa karşılık gelen  $c$  rastgele gerçek değerlerin her birini temsil eder. Softmax, lojistik fonksiyona benzer şekilde giriş değerlerini  $(0,1)$  aralığına sıkıştırır. Ancak, çıktılar için, sıkıştırılmış tüm çıktılarının toplamının 1'e eşit olması gibi ek özelliğe sahiptir. Bu sayede, Softmax çıktılarını, sınıfların normalleştirilmiş bir olasılık dağılımı olarak yorumlayabiliriz.

### 2.11.2.2. Ağ Eğitimi

Ağırlıklar, bir sinir ağı modelindeki parametrelerdir. Ağın ilerleyen aşamalarda kullanılabilmesi için bu parametrelerin tahmin edilmesi gerekir. Sinir ağı eğitimi, modeldeki ağırlıkların belirlendiği süreci ifade eder ve dolayısıyla ağın öğrenmesi bu şekilde mümkün olmaktadır. Danışmanlı öğrenmede, sınıflandırma ve tahmin problemleri için bilinen çıktılar ve bunlarla ilişkili girdilerin ağa sunulması yoluyla ağ eğitimi gerçekleştirilir [146].

Bir sinir ağını eğitmenin temel süreci şöyle olmaktadır. İlk olarak ağ, bir dizi girdiden ve bunların istenen çıktılardan oluşan eğitim örnekleriyle beslenir. Sonra, her eğitim modeli için, girdi değerleri ağırlıklandırılarak ve her gizli katman düğümünde toplanır ve uygun bir transfer fonksiyonundan geçirilerek gizli düğümün çıktı değerine iletilir. Bu sonuç, çıktı katmanı düğümlerine girdi haline gelir. Ardından, ağ çıktı değerleri elde edilir ve ağ çıktılarının istenen çıktılarla ne kadar eşleştiğini belirlemek için hedef değerlerle karşılaştırılır. Son olarak, ağın istenen çıktıya daha iyi yakınsayabilmesi için bağlantıdaki ağırlıklar güncellenir. Bu işlem bu haliyle, ağ çıktı değerleri ile tüm eğitim modelleri için bilinen hedef değerler arasındaki farklar olabildiğince yakın olana kadar birçok kez tekrar eder [146].

Eğitimi kolaylaştırmak için, ortalama karesel hatalar (OKH, mean square error (MSE)) veya karesel hataların toplamı (Sum of Squared Errors, SSE) gibi bazı genel hata ölçütleri bir amaç/maliyet/hata fonksiyonu veya performans ölçütü olarak kullanılır. Örneğin OKH şu şekilde tanımlanabilir:

$$OKH = \frac{1}{M} \frac{1}{N} \sum_{m=1}^M \sum_{j=1}^N (d_{mj} - y_{mj})^2 \quad (2.37)$$

İfade (2.37)'de  $d_{mj}$ , j'inci eğitim modeli için m'inci düğümde istenen (hedef) değeri ve  $y_{mj}$  ise ağıın üretmiş olduğu çıktı değerini temsil etmektedir. M, çıktı düğümlerinin sayısıdır ve N, eğitim örneği sayısını göstermektedir. Eğitimin amacı, amaç fonksiyonunu minimuma indiren ağırlık değerlerini bulmaktır. Bu nedenle, ağı eğitimi aslında sınırlandırılmamış doğrusal olmayan bir optimizasyon problemidir. Doğrusal olmayan optimizasyon problemlerini çözmek için genellikle sayısal yöntemlere ihtiyaç duyulmaktadır [146].

### 2.11.2.2.1. Geri Yayılım Algoritması

Ağı modellenirken ağırlıkların ayarlanabilmesi en önemli problemlerden biridir. Eğitim örneklerine ve istenen çıkış değerlerine uygun olarak ağırlıklar güncellenmelidir. Geri yayılım algoritması, danışmanlı ağı eğitiminde yaygın olarak kullanılan basit ve genel bir yöntemdir. Diğer yöntemlerden yavaş olması bir dezavantaj olsa da ağı öğrenmesinde en başarılı yöntemlerden biridir. Bu yöntem, LMS (Least Mean Square) yönteminin bir uzantısıdır. Hata, çıkış biriminde istenen çıktı ile gerçek çıktı arasındaki farkın karesiyle orantılıdır. Üç katmanlı bir ağı için hata bulunurken gizli katmandan çıkış katmanına olan ağırlıklar üzerinden hesaplanır ve bu basit bir işlemdir [148].

Giriş katmanından, gizli katmana olan ağırlıklar, doğrusal olmayan dönüşümü yönetir. Bu ağırlıkların belirlenmesi önemli bir işlemdir. Gizli birim için uygun çıktılar bilinirse, girdiden gizli katmana yaklaşık ağırlıklar bulunabilir. Gizli katman çıktısının ne olacağı konusunda açık bir kural yoktur. Bu, kredi atama problemi olarak adlandırılır. Geri yayılımın gücü, her gizli birim için etkin bir hata hesaplamamıza ve böylece girdi-gizli ağırlıklar için bir öğrenme kuralı türetmemize izin vermesidir [148].

Ağların 2 temel çalışma prensibi vardır: ileri besleme ve öğrenme. İleri beslemeli ağı, giriş birimlerine bir şablon sunar ve sinyalleri ağı üzerinden geçirerek çıkış biriminden çıktı değeri almaktadır. Danışmanlı öğrenmede ise giriş modelinin yanında istenen, öğretilen veya hedef modeli de sunularak, ağı ağırlıkları güncellenir, böylece gerçek çıkışımız hedeflenen çıktıya yakınsayınca kadar işlemler sürdürülür [148].



### 2.11.2.3. Normalizasyon

Normalizasyon, makine öğrenmesinde, verileri ağa vermeden önce yapılan bir hazırlık safhasıdır. Bu işlemin yapılması her zaman uygun olmayabilir. Özellikle ağa verilen giriş değerleri arasında büyük farklar varsa, bu durumda normalizasyon ile değerlerin belli aralıklara ölçeklenmesi istenebilir. Hata fonksiyonunun, farklı parametrelere karşı hassasiyetli olması öğrenmeyi zorlaştırmaktadır. Bu durum özelliklerin ölçeklenmesi ile kontrol edilebilir [147]. Özellik normalizasyonu ile kötü koşullanmalar önlenir ve gradyan inişi çok daha yumuşak sağlanır. Literatürde farklı normalizasyon yöntemleri önerilmiştir. Ancak, min-maks normalizasyonu (0,1) aralığında yaygın olarak tercih edilmektedir.  $min_j$  ve  $max_j$  j. özneliğin sırasıyla minimum ve maksimum değerleri olsun. Ardından i. noktanın j. boyutu için her  $x_{ij}$  öznelik değerinin min-maks normalizasyonu hesaplanmasında formül (2.38)'den yararlanılarak hesaplanır.

$$x_{ij} = \frac{x_{ij} - min_j}{max_j - min_j} \quad (2.38)$$

### 2.11.2.4. Ağıın Öğrenmesi

Öğrenmede temel yaklaşım, eğitimsiz bir ağla, yani ağırlıkları rastgele değerler ile başlatarak, girdi eğitim modeline sunulur ve çıkış belirlenir. Hata fonksiyonunda, belirlenen çıkış değerleri ağırlıklarla ilişkilidir ve gerçek çıkış değerlerine yaklaşıncaya hata değeri azalır. Ağırlıklar ayarlanarak bu hata fonksiyonu minimuma indirilmeye çalışılır [148].

Geri yayılım öğrenmesinde kural gradyan inişine dayanmaktadır. Bu yöntemde ilk ağırlıklar rastgele olarak başlatılır ve hatayı azaltacak yönde değiştirilir.

$$\Delta v = -\eta \frac{\partial J}{\partial w} \quad (2.39)$$

Bu formül bileşenler formunda ise formül (2.40)'de verilmiştir.

$$\Delta \omega_{mn} = -\eta \frac{\partial J}{\partial \omega_{mn}} \quad (2.40)$$

$\eta$  öğrenme oranıdır ve sadece ağırlıklardaki değişim oranının göreceli boyutunu belirtmektedir. (2.39) ve (2.40) formülleri çok hatalı durumlar haricinde öğrenmenin duracağını garanti etmektedir ve hiçbir zaman negatif değere düşmemektedir. Ağırlık uzayında, hata fonksiyonunu düşürecek bir adım atmamızı sağlamaktadır. Bu iteratif algoritma ağırlık vektörü alır ve algoritmanın  $m$ . iterasyonda ağırlık vektörünü güncellemesi aşağıdaki formül (2.41)'da verilmiştir.

$$w(m + 1) = w(m) + \Delta w(m) \quad (2.41)$$

$m$  belirli modelin indeksinin gösterimidir.

Üç katmanlı ağ yapısı kullanılırsa (2.40) formülü aşağıdaki forma dönüşür. Gizli katmandan çıkış katmanına ağırlık  $\omega_{jk}$  ile ifade edilmektedir. Burada hata açıkça  $\omega_{jk}$ 'ya bağlı olmadığı için, zincir kuralından yararlanılmış olup, formül (2.42)'deki gibi hesaplanmaktadır.

$$\frac{\partial J}{\partial \omega_{kj}} = \frac{\partial J}{\partial net_k} \frac{\partial net_k}{\partial \omega_{kj}} = \delta_k \frac{\partial net_k}{\partial \omega_{kj}} \quad (2.42)$$

$k$ . birimin duyarlılığının hesaplanması formül (2.43) ile verilmiştir.

$$\delta_k \equiv -\partial J / \partial net_k \quad (2.43)$$

birimin aktivasyonuna göre genel hatanın değişimini tanımlamaktadır.  $\delta_k$  için çıkış aşağıda formül (2.44)'te verilmiştir.

$$\delta_k \equiv -\frac{\partial J}{\partial net_k} = -\frac{\partial J}{\partial z_k} \frac{\partial z_k}{\partial net_k} = (t_k - z_k) f'(net_k) \quad (2.44)$$

Denklem (2.42)'daki son türev ifadesi dikkate alındığında ifade (2.45) elde edilir.

$$\frac{\partial net_k}{\partial \omega_{kj}} = y_j \quad (2.45)$$

Formüller birlikte ele alındığında, gizli katmandan çıkış katmanına ağırlık güncellemesi (öğrenme kuralı), formül (2.46)'te verilmiştir.

$$\Delta\omega_{kj} = \eta\delta_k y_j = \eta(t_k - z_k)f'(net_k)y_j \quad (2.46)$$

Giriş katmanından gizli katmana ağırlık güncellemesinin çözümü daha zordur. Kredi atama probleminin çözümünün kaynağıdır. Zincir kuralı kullanılarak, formül (2.47)'deki hesaplama yapılır.

$$\frac{\partial J}{\partial \omega_j} = \frac{\partial J}{\partial y_j} \frac{\partial y_j}{\partial net_j} \frac{\partial net_j}{\partial \omega_{ji}} \quad (2.47)$$

Formül (2.47)'deki eşitliğin sağ tarafındaki ilk terim ifadesi, formül (2.48)'de verilmiştir.

$$\begin{aligned} \frac{\partial J}{\partial y_j} &= \frac{\partial}{\partial y_j} \left[ \frac{1}{2 \sum_{k=1}^c (t_k - z_k)^2} \right] \\ &= - \sum_{k=1}^c (t_k - z_k) \frac{\partial z_k}{\partial y_j} \\ &= - \sum_{k=1}^c (t_k - z_k) \frac{\partial z_k}{\partial net_k} \frac{\partial net_k}{\partial y_j} \\ &= - \sum_{k=1}^c (t_k - z_k) f'(net_k) \omega_{jk} \end{aligned} \quad (2.48)$$

Yukarıda ikinci adım için zincir kuralını kullanmak gerekir. Eşitlik (2.48)'deki çıkış birimindeki nihai toplamlar, gizli katman çıkışları  $y_j$ 'nin her bir çıktı düğümünde hatayı nasıl etkilediğini açıklar. Gizli katmanın hassasiyetinin hesaplanması formül (2.49)'da verilmiştir.

$$\delta_j \equiv f'(net_j) \sum_{k=1}^c \omega_{kj} \delta_k \quad (2.49)$$

İfade (2.50) kredi atama probleminin ana çözümüdür: gizli katmanın duyarlılığı, çıkış birimindeki her bir hassaslığın, gizli-çıkış ağırlıkları  $\omega_{kj}$  ile çarpımlarının toplamının,  $f'(net_j)$  ile çarpımıdır. Böylece öğrenme kuralı, girişten gizli katmana ağırlıklar için formül (2.50)'de verilmiştir.

$$\Delta\omega_{ji} = \eta\chi_i\delta_j = \eta\chi_i f'(net_j) \sum_{k=1}^c \omega_{kj}\delta_k \quad (2.50)$$

(2.50) ve (2.46) denklemleri geri yayılım algoritmasını veya daha özel olarak “hataların geri yayılımı” algoritmasını vermektedir. Çünkü eğitim boyunca hata ( $\delta_k$  hassaslığı), Denklem (2.50) ile girdiden gizli katmana ağırlıkların öğrenilmesini gerçekleştirebilmek için, çıktı katmanından gizli katmana geri yayılmalıdır. Temel olarak geri yayılım, sürekli fonksiyonlar aracılığıyla zincir kuralının tüm model parametreleri yani ağırlıklar hususunda kriter fonksiyonunun türevlerinin hesaplanmasına izin verdiği katmanlı modellerde sadece gradyan inişidir.

- Çapraz Entropi Kaybı

Yapay Sinir Ağlarında diğer bir amaç fonksiyonu, çapraz entropi kaybı olarak tanımlanır. YSA, tahmini sınıf olasılığı ile gerçek sınıf dağılımı farklarını karşılaştırır. Gerçek dağılım genellikle “tek-sıcak-kodlanmış” (one-hot-encoded) vektör olarak seçilir, burada gerçek sınıf olasılığı 1 iken, diğer sınıflar 0 olasılığına sahiptir [145]. Çapraz entropi kaybı aşağıda formül (2.51) ile verilmiştir.

$$H(p, q) = - \sum_{i=1}^c p_i(x) \log(q_i(x)) \quad (2.51)$$

Burada  $q_i(x)$ , çıkışın  $i$ . sınıfa ait olma olasılığını (toplam  $n$  sınıf içinde) göstermektedir.  $p_i(x)$  ise gerçek olasılığdır.  $p_i(x)$  için tek sıcak kodlanmış yöntemi kullanılırsa, sadece hedef sınıf 1 değerini alır ve geri kalan tüm sınıflar 0 değerini alır.

İnsan beyninden ilham alınarak gerçekleştirilen bu sınıflandırıcılar, ağırlıklı düğümler kullanarak dağıtık olarak bir araya getirilen bir sistemdir. Yapay sinir sisteminde, biyolojik sinir sistemi şu şekilde taklit edilmiştir: nöronlar, işlemci elemana; dendritler toplama

fonksiyonuna, hücre gövdesi transfer fonksiyonuna; aksonlar, yapay nöron çıkışına ve sinapslar da ağırlık değerlerine karşı düşmektedir. Beynin biyolojik olarak çalışmasından yararlanılarak oluşturulduğu bildirilmiştir. YSA ile örnekler ve oluşması gereken çıktı değerleri verilir ardından yeni gelen örnekler için, oluşturulan ağ öğrendiği bilgiler ışığında çıktı hesaplaması yapar ve karar verilir.

Yapay Sinir Ağları deneyimlerden yararlanabilir. Diğer yöntemlerde ise algoritmalara göre çıkış değerleri verilmektedir.

YSA'nın avantajları aşağıda maddeler halinde verilmiştir [149].

- Tüm ağda bilgi depolanır.
- Eksik bilgi ile çalışabilme becerisi
- Hata toleransı iyidir.
- Dağıtılmış bellek kullanılabilir.
- Kademeli olarak yavaşlar
- Öğrenerek karar verme becerisi vardır.
- Paralel işleme yeteneği vardır.

Çalışmamızda “tek sıcak kodlama” (one hot encoder) ve karar katmanında aktivasyon fonksiyonu olarak softmax'tan yararlanılmıştır. Softmax fonksiyonu sigmoid'e benzemektedir. Girdinin belirli sınıflara ait olma olasılığına 0-1 aralığında bakarak karar vermektedir. Olasılıksal olarak bir karar verme gerçekleştirilmiştir.

Adam (Adaptive Moment Estimation, Uyarlanabilir Moment Tahmini) optimizasyon algoritması modelin hata oranını en aza indirmek için kullanılır. Adam, her parametre için öğrenme tahminini hesaplayan bir optimizasyon işlevidir. Geçmiş kare gradyanların üstel olarak azalan ortalamasının tutulmasına ek olarak, Adam yönteminde momentuma benzer şekilde  $m(t)$  geçmiş gradyanların üstel olarak azalan ortalama değerleri de saklanmaktadır. Her iki değişken ortalama da 0'dan başlatılır ve bu da moment tahminlerinin 0'a eğilimli olmasına sebep olur. Bu durum genellikle azalan parametreler  $\beta_1$  ve  $\beta_2$ 'nin 1'e yakın değer aldığı başlangıç aşamasında meydana gelir.  $m(t)$  ve  $v(t)$  için değiştirilen tahminler yapılarak bu durum ortadan kaldırılır. Literatürde yaygın olarak kullanıldığı için Adam yöntemi bu çalışmada tercih edilmiştir. Adam yöntemi diğer yöntemlerle karşılaştırıldığında yakınsaması daha hızlı olmakta ve eğitimin daha kısa sürede tamamlanmaktadır. Diğer optimizasyon yöntemlerindeki hata fonksiyonunu etkileyebilecek yavaş yakınsama ve

parametrelerin yüksek varyans değerlerine sahip olması gibi sorunlar, Adam yöntemi tercih edildiğinde karşımıza çıkmamaktadır.

Adam optimizasyonu parametreleri, Keras'ta önerilen değerler olarak seçilmiştir. Aşağıda bu kod parçasına yer verilmiştir.

```
tf.keras.optimizers.Adam(
    learning_rate=0.001,
    beta_1=0.9,
    beta_2=0.999,
    epsilon=1e-07,
    amsgrad=False,
    name="Adam",
    **kwargs
)
```

Çalışmada gizli katman sayısının ve düğüm sayısının belirlenebilmesi için ortalama başarımları gösteren ve ne az ne de çok sayıda eğitim örneğine sahip uygun bir denek seçilerek üzerinde sırasıyla 1, 2 ve 3 gizli katmanla denemeler yapılmış ve her bir gizli katman 10, 15 ve 20 nöronla testler yapılarak doğruluk değerleri elde edilmiştir. Başarımları açısından modelin analizi yapılmıştır. Denemeler sonucunda tek gizli katman ve 10 nöronla birlikte daha başarılı sonuç alındığı için, model bu şekilde seçilmiştir. Düşük karmaşıklığa sahip modellerle daha iyi sonuç alınmıştır. Bunun, eğitim kümesinde bulunan örnek sayılarının sınırlı olmasından kaynaklandığı düşünülmektedir. Optimizasyon yöntemi olarak Adam, aktivasyon fonksiyonu olarak gizli katman için *hiperbolik tanjant (tanh)* ve çıkış katmanı için softmax tercih edilmiştir. Elde edilen sonuçlara bakıldığında aktivasyon fonksiyonu olarak tanh seçilince, ReLU kullanımına göre daha başarılı sonuçlar elde edilmiştir.

Bu çalışmada sonuçlar elde edilirken, 5-katlamalı-çapraz doğrulama (5-fold cross validation) kullanılmıştır. Eğitim kümesi 5 parçaya bölünerek, her defasında doğrulama kümesi değişecek şekilde, %80'i ile eğitim ve kalan %20'lik kısım ile doğrulama yapılmıştır. Böylece beş kez elde edilen sonuçların ortalaması alınarak, tek kez çalıştırmaya göre, daha güvenilir sonuçlar elde edilmiştir.

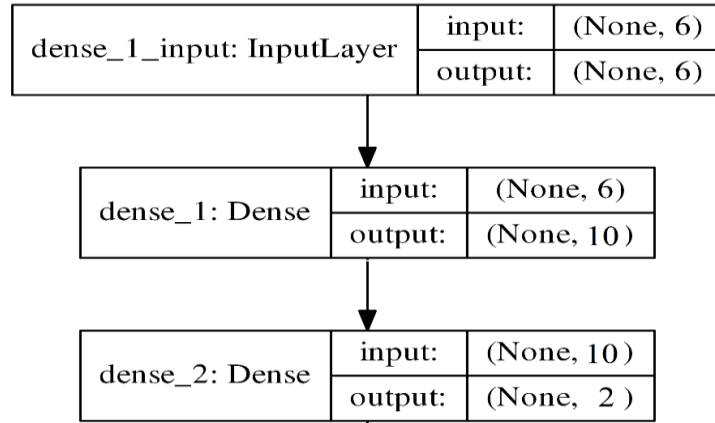
YSA eğitiminde ezberlemenin önüne geçmek için ve uzun epokların daha kısa sürede doğru eğitim yapabilmesi amacıyla, erken durdurma uygulanmıştır. Bu çalışmada erken

durdurma koşulu olarak sınır (patiance) parametresi, doğrulama kaybı için 50 yineleme seçilmiştir. Hata fonksiyonu olarak çapraz entropi (cross entropy) tercih edilmiştir. Patiance parametresi önceleri küçük değerler seçilince, bu durumda erken durdurma sebebiyle doğruluk değerleri arasında standart sapmanın fazla olduğu görülmüştür. Bu değer 50 seçilince grafikler ve doğruluk değerlerinin kabul edilebilir düzeylerde oldukları görülmüştür.


- Çapraz Doğrulama

Sinir ağı modeli seçiminde temel çapraz doğrulama işleminden yararlanılmıştır. Verilen eğitim kümesinin %80'i eğitim için ve %20'si doğrulama için olmak üzere 5-katlı çapraz doğrulama işlemi kullanılmıştır. YSA parametreleri eğitim örnekleri üzerinden tahmin edilirken, modelin gösterdiği performans doğrulama verileri ile gözlemlenir ve değerlendirilir. Doğrulama kümesinde en yüksek başarıya ulaşan model, en iyi model olarak kabul edilmiştir. Bu çalışmada en iyi model seçimi yapıldıktan sonra, veri kümesinde bulunan eğitim ve doğrulama için ayırdığımız iki parçanın tamamı, gerçek eğitim kümesini oluşturmaktadır. Bu tüm eğitim seti üzerinden tekrar eğitim yapılmıştır. Model oluşturulurken test aşamasında kullanılacak olan bir örneğin, model oluşturulurken eğitim aşamasında kullanılmaması çok önemlidir. Bu çalışmada veri kümesinde belirlenen tüm eğitim kümesi ile eğitim yapıldıktan sonra modelin hiç görmediği test kümesi üzerinde sınıflandırma doğruluğu elde edilmiştir. Çapraz doğrulama ile model seçimi ve doğrulama ile performans ölçümü yapılıyorsa, model başarısı doğrulama performansı değil, test kümesi ile elde edilecek olan başarı değeri olacaktır. Beş parça halinde doğrulama kümesi değiştirildiği için, bu çalışmada test kümesi üzerinde elde edilen başarı değerleri 5 kez elde edilmiş ve bulunan sonuçların ortalaması sınıflandırma doğruluğu olarak kabul edilmiştir.

Bu çalışmada karar verilen ağ modelinin Keras çıktısı ve graf gösterimi Şekil 18'de verilmiştir.



A



B

Şekil 18. Çalışmada kullanılan YSA modeli a) Keras çıktısı b) Graf gösterimi [150]

## 2.12. Performans Ölçütü

Çalışmada sınıflandırma performanslarının belirlenmesinde doğruluk değeri kullanılmıştır. YSA sınıflandırmasında 5-katlı çapraz doğrulama yapıldığı için bulunan doğruluk değerlerinin ortalaması alınmıştır. Formül (2.52)'de doğruluk hesaplama formülü verilmiştir.



$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif} + \text{Doğru Negatif} + \text{Yanlış Negatif}}$$

$$\text{Doğruluk} = \frac{DP + DN}{DP + YP + DN + YN} \quad (2.52)$$



### 3. BULGULAR VE İRDELEME

Tez çalışmasında 2 farklı veri tabanı için 4 farklı geri problem çözümü (dipolar, dSPM, Minimum Norm ve sLORETA) ve 2 farklı sınıflandırma yöntemi (DVM ve YSA) uygulanarak bulgular elde edilmiştir. Her bir yöntemde en başarılı sonuç ve bu sonucun ortaya çıkmasını sağlayan beyin bölgeleri kombinasyonları grafiklerle şekilsel olarak gösterilmiştir.

DVM sınıflandırma sonucu bulunurken çekirdek fonksiyonu olarak doğrusal (linear) ve radyal tabanlı fonksiyon (Radial Basis Function, RBF) kullanılmıştır. MATLAB programında fitsvm() fonksiyonu kullanılarak sonuçlar elde edilmiştir [151]. OUÖ özellik çıkarma işleminde kullanılmıştır ve filtre çifti 3 seçilince daha iyi sonuçlar elde edilmiştir. Filtre çifti parametresi deneysel olarak belirlenmiştir.

Girişimsel olmayan, kullanımı kolay, kullanıcı dostu, portatif ve yüksek başarıma sahip EEG tabanlı BBA geliştirmek nörobilim alanında hala önemli bir çalışma alanıdır. Gelişen donanımlarla birlikte, geliştirilen algoritmalar ve yeni yöntemlerle BBA'ların laboratuvarlar dışında gerçek hayatta da oldukça yaygınlaşması beklenmektedir. Daha yüksek doğruluk ve kişilerin düşündüklerinin tam olarak anlaşılabilmesi için sinyal işleme alanında ve makine öğrenmesinde yeni yöntemler geliştirilmesi ve uygulanması faydalı olacaktır. Daha hızlı çalışan yöntemler ve daha hızlı çalışan donanımlar sayesinde daha güçlü ve gerçek zamanlı çalışmalar mümkün olabilecektir [2].

- Daha konforlu kullanım
- Portatif taşınabilir olsun
- Hareket özgürlüğü sağlasın
- Yüksek doğruluklu olsun, hayati tehlike olmasın
- Kalibrasyon süresi yüksek olan cihaz ve elektrotlar olmalı
- Jel kullanımı olmaması hijyen için daha iyi olacaktır.
- Doğru zaman dilimlerinin yakalanması ve analiz edilmesi
- Ön işlem, özellik çıkarma, seçme ve sınıflandırma en iyi şekilde yapılmalı

### 3.1. Veri Kümesi 2a ile Elde Edilen Doğruluk Oranları

Bu aşamada mü bandındaki (8-13 Hz) sinyaller için, sağ el ve sol elin motor hayalinde, seçili bölge kombinasyonları kullanılarak elde edilebilen en yüksek doğruluk oranları verilmiştir. M1H\_L ve M1H\_R bölgeleri motor hayalinde en etkin olmaları beklenen bölgeler oldukları için tüm kombinasyonlarda yer almışlardır. Geri kalan bölgelerin tüm dörtlü kombinasyonları ile doğruluk değerleri hesaplanmış ve en yüksek doğruluk değerleri aşağıdaki tabloya eklenmiştir. Bu tez kapsamında yapılan deneysel çalışmalarda, altı bölge kullanımı ile kabul edilebilir sonuçlar elde edildiği gözlemlenmiştir. Daha fazla bölge ile daha yüksek başarı elde edilebilecek durumlar olsa da bu çalışmada en az sayıda bölge kullanılarak, motor hayalinde hangi uzvun hayal edildiği bulunmaya çalışılmıştır. Tablo 2’de elde edilen sınıflandırma doğruluk oranları verilmiştir. Bulunan değerler referans çalışması ile karşılaştırılmıştır. Referans yayında elektrot seviyesinde OUÖ özellik çıkarma yöntemi ve aynı veri kümesi kullanıldığı, tez çalışmasında da kaynak seviyesinde OUÖ özellik çıkarma kullanıldığı için karşılaştırmada bu yayın seçilmiştir [152].

Tablo 2. Veri Kümesi 2a DVM sonuçları 12 bölgenin 4’lü kombinasyonu ve M1H\_L ve M1H\_R’nin eklenmesiyle elde edilen en başarılı sonuçları (mü bandı)

	dipolar		dSPM		MN		sLORETA		Referans
	Linear	RBF	Linear	RBF	Linear	RBF	Linear	RBF	Yayın [152]
Denek1	72.22	68.75	79.17	72.22	76.39	72.92	77.78	73.61	88.89
Denek2	63.19	64.58	67.36	65.28	64.58	63.19	63.19	63.89	51.39
Denek3	92.26	89.58	87.50	86.11	86.11	87.50	89.58	90.28	96.53
Denek4	68.06	65.97	70.83	70.14	71.53	68.75	70.83	69.44	70.14
Denek5	61.81	57.64	63.89	63.19	59.72	61.11	59.72	60.42	54.86
Denek6	65.28	63.89	66.67	65.28	66.67	63.89	65.97	65.97	71.53
Denek7	71.53	67.36	70.14	67.36	69.44	66.67	68.06	68.75	81.25
Denek8	84.72	81.25	93.75	91.67	94.44	92.36	95.14	92.36	93.75
Denek9	86.11	82.64	86.11	84.03	84.03	82.64	86.81	84.03	93.75

Tablo 3’te 0.5-30 Hz bandındaki sinyaller için en yüksek doğruluk değerine ulaşan değerler DVM yöntemi kullanılarak verilmiştir. Tablo 2’nin hazırlanması ile aynı işlem adımları uygulanmıştır. 12 bölgenin 4’lü bütün kombinasyonları sonucunda en yüksek

doğruluklu sonuçlar ve ilgili bölgeler her denek için ayrı ayrı hesaplanmıştır. Tablo 2 ve Tablo 3 kıyaslandığında mü bandında çok daha iyi sonuçlar elde edildiği görülmüştür.

Tablo 3. Veri Kümesi 2a DVM sonuçları 12 bölgenin 4'lü kombinasyonu ve M1H\_L ve M1H\_R'nin eklenmesiyle elde edilen en başarılı sonuçları (0.5-30 Hz bandı bandı)

	dipolar		dSPM		MN		sLORETA		Referans Yayın [152]
	Linear	RBF	Linear	RBF	Linear	RBF	Linear	RBF	
Denek 1	59.72	62.50	59.72	62.50	54.17	56.94	57.64	59.72	88.89
Denek 2	56.25	62.50	57.64	59.72	58.33	63.19	60.42	60.42	51.39
Denek 3	61.81	63.89	62.50	58.33	62.50	60.42	59.72	60.42	96.53
Denek 4	59.03	62.50	66.67	63.89	62.50	60.42	59.72	60.42	70.14
Denek 5	57.64	60.42	62.50	63.89	62.50	65.28	60.42	60.42	54.86
Denek 6	61.11	61.81	58.33	61.81	58.33	62.50	56.94	61.81	71.53
Denek 7	65.28	64.58	61.81	61.81	61.81	62.50	60.42	63.19	81.25
Denek 8	63.89	62.50	59.72	60.42	64.58	60.42	59.03	63.19	93.75
Denek 9	64.58	63.89	63.89	68.06	64.58	63.19	70.14	63.89	93.75

Yukarıda 2 farklı bant aralığında yapılan hesaplamalar, bu kez YSA için yapılmıştır. Mü bandı sonuçları daha yüksek ve anlamlı olduğu için YSA aşamasında sadece mü bandı ile elde edilen sonuçlar verilmiştir. Veri kümesinde az sayıda örnek olduğu için 5 katlı çapraz doğrulama yapılmıştır. Makine öğrenmesinde, tüm eğitim kümesini kullanmak yerine eğitim-doğrulama bölünmesi yapılarak, YSA aşamasında en uygun model seçimi yapılması önerilmektedir. Veri kümesinde verilen eğitim örnekleri beş parçaya bölünmüş, 4 parçası ile eğitim yapılırken, bir parçasıyla doğrulama yapılmıştır. Tablo 4'te çapraz doğrulama sonuçlarının 5'e bölünmesiyle elde edilmiş olan ortalama değerler verilmiştir.

Tablo 4. Veri Kümesi 2a YSA sonuçları 12 bölgenin 4'lü kombinasyonu ve M1H\_L ve M1H\_R'nin eklenmesiyle elde edilen en başarılı sonuçları (mü bandı)

	dipolar	dSPM	MN	sLORETA	Referans Yayın [152]
Denek 1	72.22	75.69	76.67	77.50	88.89
Denek 2	62.64	65.28	63.19	64.44	51.39
Denek 3	92.36	87.64	85.69	89.17	96.53
Denek 4	66.94	70.00	70.00	70.69	70.14
Denek 5	58.06	60.42	58.47	62.08	54.86
Denek 6	63.33	65.42	65.97	66.39	71.53
Denek 7	70.14	66.25	69.03	66.94	81.25
Denek 8	84.31	93.19	93.33	94.17	93.75
Denek 9	85.97	86.39	85.28	86.81	93.75

Veri Kümesi 2a üzerinde sağ ve sol elin motor hayali doğruluk değerleri incelendiğinde 4 denek için daha başarılı sonuçlar elde edilmiştir ancak 5 denekte daha düşük başarı elde edilmiştir. Başarısız daha düşük olan deneklerde yöntemimize ait başarının da düşük kalmasının, kişilerin motor hayaline yeterince konsantr olamamaları veya dikkat eksikliği nedeniyle; motor hayalinde etkili beyin bölgelerini yeterince aktif edememeleri ile ilişkili olabileceği ilk olarak düşünülmektedir. Veri kümesi 2a kayıt alınması 22 elektrot kullanılarak yapılmaktadır. Literatürde 2003 yılında Lantz vd. EEG kaynak lokalizasyonunda en az 64 elektrot kullanılmasının hata azaltılması için gerekli olduğunu bildirmiştir [111]. Bu veri kümesi üzerinde çıkarılan anlamlı özellikler ve sınıflandırma için en uygun parametreler belirlenmesi sayesinde, az elektrotlu sisteme rağmen, 4 denek için daha iyi sonuçlar elde edilmesi önemli bulunmuştur.

Mü bant sonuçlarının, 0.5-30 Hz sonuçlarına göre oldukça başarılı olduğu gözlemlenmiştir. Motor hayalinde bu frekansın aktif olduğu literatürde bildirilmektedir. Ayrıca ciddi başarı düşüşlerinin yaşanmasında 22 elektrotlu kayıt sisteminin kullanılmasının da ek neden olmuş olabileceği düşünülmektedir. Kaynak lokalizasyonundan daha anlamlı bilgiler çıkarılması için daha çok kanallı elektrot sisteminin kullanımı önerilmektedir.

### 3.2. Veri Kümesi 4a ile Elde Edilen Doğruluk Oranları

Aşağıda dipolar, dSPM, Minimum Norm ve sLORETA için DVM ve YSA yöntemleri ile elde edilen sonuçlar verilmiştir. Elde edilen sonuçlar veri kümesi 4a için 1820 kombinasyon içinde en yüksek başarımları göstermektedir. Eğer farklı kombinasyonlarla birlikte birden fazla kez en yüksek başarımlar elde edilmişse, bu durum tabloda gösterilmiştir. Bu deneyde amaç sağ el ve sağ ayak motor hayali için doğru tahmini yapabilmektir. Beş farklı denek için testler yapılmıştır. Deneklerden sadece Denek al'in solak, geri kalanların ise sağ el kullandıkları veri kümesinin sahibi Benjamin Blankertz tarafından e-posta yoluyla tarafımıza bildirilmiştir.

Tablo 5 incelendiğinde Denek al için başarımlar dSPM, Minimum Norm ve sLORETA için %100'e ulaştığı görülmüştür. Denek aw için başarımlar %90, Denek ay için ise %92'nin üzerinde bir başarımlar elde edilmiştir. İki denek için Denek aa ve Denek av için başarımlar %71 civarında olmuştur.

Tablo 5. DVM sınıflandırıcı ile mü bandı sonuçları

	dipolar		dSPM		MN		sLORETA		Ref. Yayın [152]
	Linear	RBF	Linear	RBF	Linear	RBF	Linear	RBF	
Denek aa	66.96	65.18	68.75	66.96	71.43	67.86	69.64	66.07	66.07
Denek al	96.43	96.43	100	100	100	100	100	100	96.43
Denek av	70.41	70.41	71.94	68.37	66.84	67.86	68.37	66.84	47.45
Denek aw	74.11	75	88.84	90.18	90.18	90.18	89.29	90.18	71.88
Denek ay	90.48	82.94	92.86	84.92	92.46	81.35	92.46	82.54	49.60

Tablo 6'da 0.1-30 Hz bandı için DVM sınıflandırıcısı kullanılarak elde edilen sonuçlar verilmiştir.

Tablo 6. DVM sınıflandırıcı ile 0.1-30 Hz bandı sonuçları

	dipolar		dSPM		MN		sLORETA		Ref. Yayın [152]
	Linear	RBF	Linear	RBF	Linear	RBF	Linear	RBF	
Denek aa	65.18	66.07	63.39	64.29	63.39	64.29	66.07	66.07	66.07
Denek al	83.93	83.93	83.93	82.14	82.14	82.14	83.93	82.14	96.43
Denek av	62.24	63.27	60.20	61.22	60.71	63.27	60.20	61.73	47.45
Denek aw	64.29	60.71	64.73	60.27	65.18	64.29	64.29	62.50	71.88
Denek ay	57.14	56.75	58.73	58.73	61.51	57.94	59.13	57.14	49.60

Tablo 7’de mü bandı için YSA sınıflandırıcısı kullanılarak elde edilen en yüksek doğruluk değerleri verilmiştir.

Tablo 7. YSA sınıflandırıcı için mü bandı sonuçları

	dipolar	dSPM	MN	sLORETA	Ref. Yayın [152]
Denek aa	66.07	68.04	70.54	69.64	66.07
Denek al	94.64	100	100	100	96.43
Denek av	71.73	69.29	67.45	66.73	47.45
Denek aw	73.75	88.75	89.64	88.57	71.88
Denek ay	91.43	92.78	91.67	91.90	49.60

Veri Kümesi 4a’da en yüksek doğruluk değerleri ve bu değere karşılık düşen bölgeler irdelenmiştir. Fizyoloğumuzun önerisiyle bu çalışma 18 bölge üzerinde yapılmıştır. İki bölge M1H\_L ve M1F\_L bölgeleri her durumda yer almak üzere geri kalan 16 gözlem noktası için olası tüm 4 bölgeli kombinasyonlar denenmiştir. M1H\_L ve M1F\_L bölgeleri motor hareketten birinci derece sorumlu alan olup, bu bölgede motor hayalinde ayırt edici sinyaller beklenmektedir. Böylece 1820 deneme içinde en yüksek doğruluk değeri ve bu doğruluk değerine karşı düşen bölgeler elde edilmiştir. Eğer en yüksek doğruluğu veren birden fazla bölge kombinasyonu varsa, tüm bu bölge kombinasyonları tablolara eklenmiştir.

Bir sonraki aşamada sağ el ve sağ ayak motor hayalinde sağ ve sol lobun etkisini araştırmak için testler yapılmıştır. M1H\_L ve M1F\_L bölgeleri kombinasyonda yer almak

üzere, geri kalan 4 bölge sadece sağ lop kombinasyonlarından seçilerek, sonra sadece sol lop kombinasyonlarından dörtlü bölge seçilerek sonuçlar elde edilmiştir. Bu testler sayesinde, sağ el veya sağ ayak motor hayalinde lopların birbirine göre tanımada ne kadar daha başarılı olabileceği belirlenebilmektedir. mü bandında sadece sağ lopta seçili 9 bölgenin dörtlü kombinasyonu alınmış, sol lopta ise M1H\_L ve M1F\_L her kombinasyonda zaten yer aldığı için geri kalan 7 bölgenin dörtlü kombinasyonları üzerinde hesaplamalar gerçekleştirilmiştir. Bu aşamada mü bandında sadece sağ lopta ve sadece sol lopta yer alan seçili bölge kombinasyonları üzerinde en başarılı sonuçlar elde edilmiştir.

Aşağıda M1F\_L (6. bölge) ve M1H\_L (7. bölge) kombinasyonda yer alacak şekilde sağ loptan 4 bölge eklenmesi ve sol loptan gelebilecek olası tüm 4 bölgeler için en yüksek doğruluklu sonuçlar verilmiştir.

Tablo 8. DVM sınıflandırıcı ile sağ lop bölge kombinasyonlarının 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri

	Dipolar		dSPM		MN		sLORETA	
	Linear	RBF	Linear	RBF	Linear	RBF	Linear	RBF
Denek aa	63.39	64.29	67.86	64.29	66.07	61.61	68.75	63.39
Denek al	91.07	91.07	100	100	100	100	100	100
Denek av	70.41	68.37	64.80	64.80	64.80	62.24	65.82	62.24
Denek aw	70.98	70.98	83.48	83.48	82.14	82.14	83.04	83.04
Denek ay	90.48	76.59	82.14	69.05	79.76	65.87	79.76	65.48

Tablo 9. YSA sınıflandırıcı ile sağ lop dörtlü bölge kombinasyonlarının 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri

	dipolar	dSPM	MN	sLORETA
Denek aa	60.71	68.21	64.11	67.14
Denek al	92.5	100	100	100
Denek av	68.98	64.18	63.06	63.47
Denek aw	71.79	82.95	83.04	83.57
Denek ay	91.27	79.37	82.3	78.89



Tablo 10’da ise 6. ve 7. bölgelere, diğer sol loptan gelen bölge kombinasyonları eklenerek, en yüksek doğruluk değerleri DVM sınıflandırıcı kullanılarak elde edilmiştir.

Tablo 10. DVM sınıflandırıcı ile sol lop bölge dörtlü kombinasyonlarına, 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri

	dipolar		dSPM		MN		sLORETA	
	Linear	RBF	Linear	RBF	Linear	RBF	Linear	RBF
Denek aa	58.93	65.18	65.18	66.07	65.18	64.29	65.18	65.18
Denek al	89.29	89.29	100	100	100	100	100	100
Denek av	68.88	68.37	66.33	62.76	62.76	64.29	66.33	61.22
Denek aw	71.88	72.32	84.82	84.82	85.71	86.61	84.82	85.71
Denek ay	86.11	79.37	91.67	79.76	91.67	80.95	92.46	80.16

Tablo 11’de ise 6. ve 7. bölgelere, diğer sol loptan gelen bölge kombinasyonları eklenerek, en yüksek doğruluk değerleri YSA sınıflandırıcı kullanılarak elde edilmiştir.

Tablo 11. YSA sınıflandırıcı ile sol lop bölge dörtlü kombinasyonlarına, 6 ve 7. bölgelerin eklenmesi ile oluşan en yüksek doğruluk değerleri

	dipolar	dSPM	MN	sLORETA
Denek aa	60.36	64.46	64.64	64.64
Denek al	90	100	100	100
Denek av	68.06	66.73	67.24	66.73
Denek aw	71.07	84.73	86.7	85.36
Denek ay	89.68	91.66	91.43	91.11

Tablo 8-11 aralığı incelendiğinde ortaya çıkan önemli bir nokta da sağ lobun da sol lop gibi başarılı bölgelere katkı vermesi olup, bu durum oldukça anlamlıdır. Normalde sağ el ve sağ ayak motor hayali için, beynin sol lobunda aktivite artışı beklenmektedir. Ancak beyin yarım küreleri haberleşmekte ve sol lobun yanında sağ lobun da aktif olması ve zaman

zaman çok önemli ayırt edilebilir veriler taşıdığı anlaşılmaktadır. Tezde elde edilen sonuçların ilerde yapılacak beyin araştırmalarına katkı sağlayacağı düşünülmektedir.

BBA üzerinde yapılan yeni çalışmalarla, BBA'lar daha üstün özelliklere ulaşmaktadır. Bu tez çalışmasında, motor hayaline dayalı EEG sinyallerinin sınıflandırılması problemi üzerinde çalışılmıştır. Yapılan çalışma ile girişimsel olmayan EEG çalışmalarına katkı sağlanması amaçlanmıştır. Ayrıca, EEG kaynak lokalizasyonu ile EEG bir nörogörüntüleme aracına dönüştürülmüş olup, fMRG gibi pahalı bir teknolojiye gerek duyulmadan beyin bölgelerinin çalışması hakkında anlamlı yorumlar yapılabilmesi sağlanmıştır.

EEG sinyalleri üzerindeki birçok çalışma elektrot seviyesinde yapılmaktadır. Bu tezde algılayıcı EEG verileri, EEG kaynak lokalizasyonu yöntemi ile kortikal alana karşı düşürülmüş, ardından eğitim ve test işlemleri bu sinyaller ile yapılmıştır. EEG kaynak görüntüleme yöntemiyle kafa derisinden kaydedilen sinyallerin, kortikal aktivasyonlara karşı düşürülmesiyle, EEG sinyallerinin en önemli dezavantajı olan uzamsal çözünürlüğün düşük olması aşılmıştır. Bu sayede bu tez kapsamında EEG yönteminden nörogörüntüleme olarak yararlanılmıştır. EEG motor hayali esnasında, beyin bölgelerinden motor, somato ve premotor alanlarının hangilerinin daha etkili olabileceği üzerine çalışılmıştır. Binlerce bölge kombinasyonu arasında sınıflandırmada en etkili bölge kombinasyonları belirlenmeye çalışılmıştır.

EEG geri problem çözümünde farklı yöntemler kullanılmıştır. Bu çalışmada 4 farklı yöntem olan dipolar, dSPM, Minimum Norm ve sLORETA ile kaynak sinyalleri elde edilmiş ve her bir yöntem için en yüksek doğruluklar elde edilmeye çalışılmıştır.

EEG kaydının çok elektrotla yapılması daha çok bilgi içermektedir. Ancak fazla kanal olunca işlem karmaşıklığı da artmaktadır. Önerilen yama tabanlı kaynak EEG sinyalleri ile çok daha anlamlı analizler yapılabilmektedir. 118 kanal kullanılan sistemde sadece 6 yama (patch) yardımıyla oldukça başarılı sonuçlar elde edilebilmiştir.

Bu çalışma ile, DVM ve YSA sınıflandırıcılarını karşılaştırma fırsatı da sunulmaktadır. Sınıflandırmada DVM yöntemi birçok kez YSA'lara göre daha başarılı olmuştur.

Motor hayalinde denekler arası performans farkları bulunabilmektedir. Bunun olası nedenleri tez içinde tartışılmıştır. Ayrıca farklı zamanlarda aynı kişiden alınan motor hayali tabanlı BBA performansı da değişkenlik gösterebilmektedir. Bu çalışmada, kişiler hayal kurarken, beynin farklı bölgelerinin, etkin olabildiği en başarılı sonuçlarda elde edilmiştir. Bu durumda kişinin hayal durumunda etkin olan beyin bölgelerini değerlendirmenin daha

faydalı olabileceği düşünülmektedir. Bireyler arası küçük farklar olabildiği için kişiye özgü tasarımlar yapılmasının daha uygun olacağı kanaatine varılmıştır. Bu durumda, algılayıcılardan gelen verilerde en ilişkili bölgelere yakın olan EEG elektrotlarından gelen verilerin kullanılmasının başarıyı artırabileceği düşünülmektedir.


### 3.3. Veri Kümesi 2a Üzerinde Mü Bandı ile DVM Sınıflandırıcı Sonuçları

Bu aşamada veri kümesi üzerinde sağ el ve sol el motor hayaline dayalı sinyaller için doğruluk değerleri her bir denek için ayrı ayrı hesaplanmıştır. Her bir denek için en yüksek doğruluk değerini veren bölgeler kombinasyonu aşağıda grafiklerde gösterilmiştir. Yani grafiklerde en yüksek doğruluk değerini oluşturan bölge kombinasyonlarına yer verilmiş ve tüm denekler için benzer ve farklı bölgeler tespit edilmiştir. Beynin çapraz çalışma ilkesi nedeniyle sağ el motor hayali için M1H\_L bölgesi ve sol el hareketinin motor hayali için M1H\_R bölgesinin aktif olması beklenmektedir. Bu 2 bölge, kombinasyonların tamamında yer almak üzere geri kalan sol lopta seçili bölgeler (S1H\_L, CMA\_L, SMA\_L, pSMA\_L, PMd\_L ve PMv\_L) ve bu bölgelerin sağ loptaki karşılıkları olan (S1H\_R, CMA\_R, SMA\_R, pSMA\_R, PMd\_R ve PMv\_R) bölgeleri ile birlikte 12 bölgenin dörtlü kombinasyonu seçilerek, her bir denek için 495'er kez ilgili tüm kombinasyonlar için doğruluk (accuracy) sonuçları elde edilmiştir. En yüksek doğruluk değerine karşılık gelen bölgeler her bir yöntem için bulunarak aşağıdaki grafiklerde gösterilmiştir.

Özetle, denenen tüm kombinasyonlar içinde, en yüksek doğruluk değerine ulaşan tüm sonuçlar listelenmiş, ardından bu en yüksek doğruluk değerine veya değerlerine karşılık gelen bölge kombinasyonları aşağıda grafiklerde gösterilmiştir. Eğer en yüksek değere ulaşan birden fazla bölge kombinasyonu varsa, tablodaki bölgeler normalize edilerek verilmiştir.

#### 3.3.1. Dipolar Yöntem

Şekil 19'da mü bandında, dipolar geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 19. Veri Kümesi 2a dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar

Grafik incelendiğinde mü bandında S1H\_L, S1H\_R, CMA\_L ve PMd\_R bölgeleri en başarılı bölgeler arasında 5 denekte ortak olarak gözlenmiştir.

### 3.3.2. dSPM Yöntemi

Şekil 20'de mü bandında, dSPM geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.


Mü bandında S1H\_R ve CMA\_R 5 denekte, SMA\_L ve PMv\_L 4 denekte ortak olarak en başarılı alanda yer almıştır.



Şekil 20. Veri Kümesi 2a dSPM yöntem ile mü bandı ve DVM ile elde edilen sonuçlar

### 3.3.3. Minimum Norm Yöntemi

Şekil 21’de mü bandında, MN geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 21. Veri Kümesi 2a Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar

Grafik incelendiğinde CMA\_R bölgeleri 7 denekte ortak olarak karşımıza çıkmaktadır. Bu bölgenin ardından SMA\_L bölgesi 6 denekte ve S1H\_R ve PMv\_L bölgesi 5 denekte ortak olarak en başarılı bölgelerde yer almışlardır.

### 3.3.4. sLORETA Yöntemi

Şekil 22’de mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



Şekil 22. Veri Kümesi 2a sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar

CMA\_L bölgesi tam 6 denekte ortak olarak en başarılı bölgeler içinde yer almıştır. Bu bölgenin dışında S1H\_L, S1H\_R ve PMv\_L bölgeleri 5 denekte ortak olarak en yüksek başarıya katkı sunmuştur.

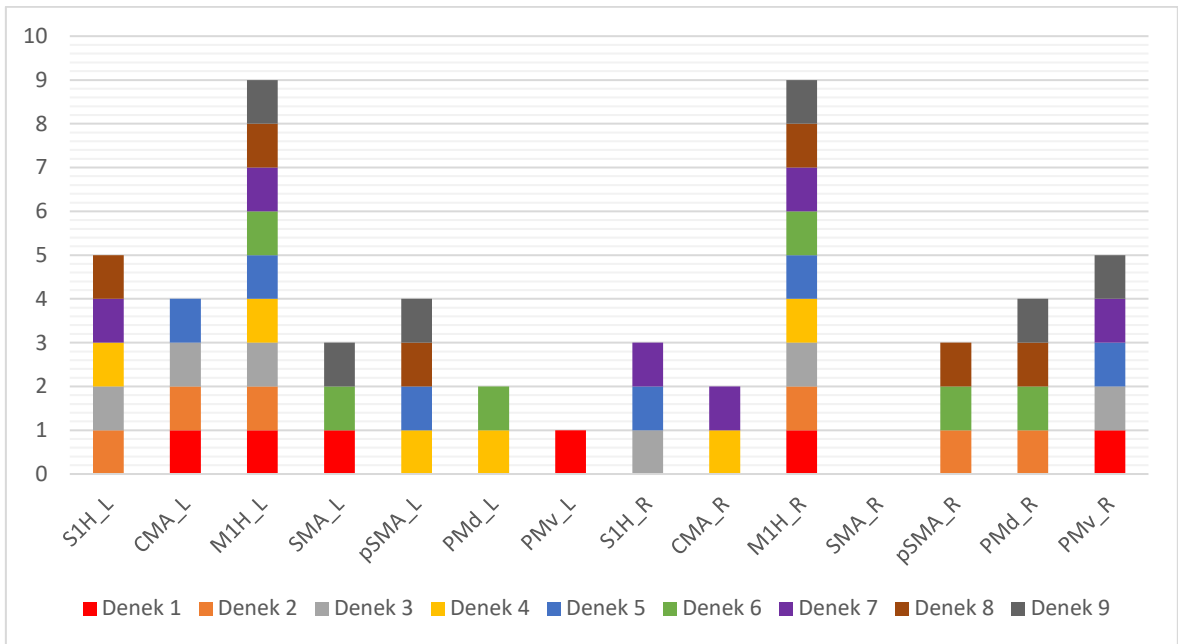
### 3.4. YSA Sınıflandırıcı ile Veri Kümesi 2a Sonuçları

Elde edilen özellik vektörleri bu aşamada YSA yöntemi sınıflandırılmıştır.

### 3.4.1. Dipolar Yöntem


Şekil 23'te mü bandında, dipolar geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

S1H\_L ve PMv\_R bölgesi 5 denekte en başarılı bölgeler arasında yer almıştır. Bu bölgeleri 4 denekte ortak olarak gözlemlenen CMA\_L, pSMA\_L ve PMd\_R bölgeleri takip etmektedir.



Şekil 23. Veri Kümesi 2a Dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar

### 3.4.2. dSPM Yöntemi



Şekil 24. Veri Kümesi 2a dSPM yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

Şekil 24'te mü bandında, dSPM geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

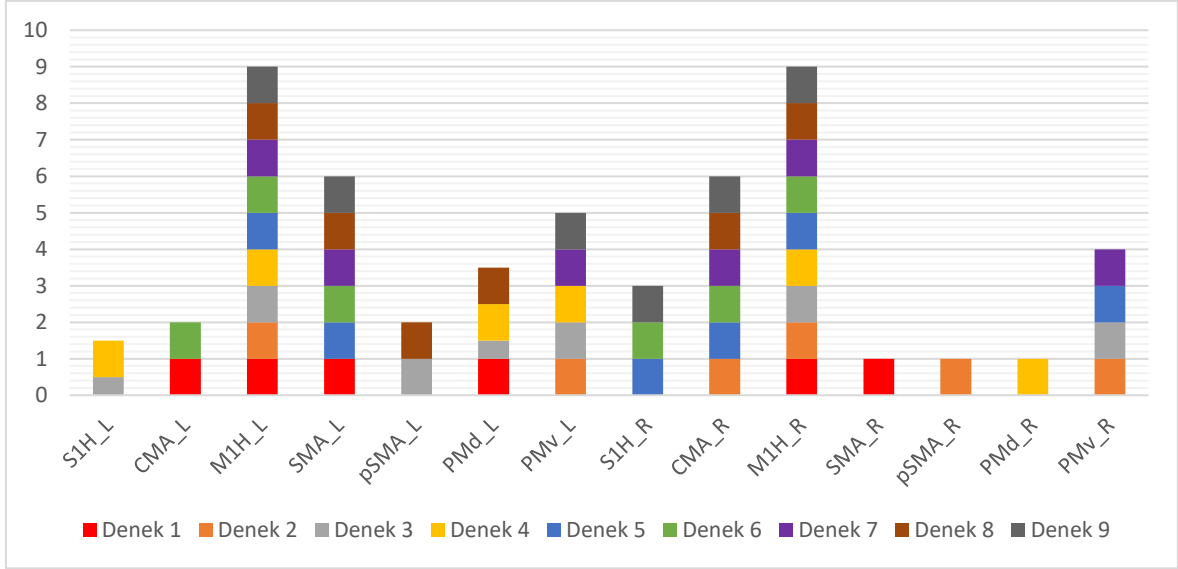
S1H\_L ve CMA\_R bölgeleri 5 denekte ortak olarak yer alırken, CMA\_L, pSMA\_L, PMd\_L ve S1H\_R bölgeleri ise 4 denekte en başarılı bölgeler arasında yer almıştır.

### 3.4.3. Minimum Norm Yöntemi

Şekil 25'te mü bandında, MN geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

SMA\_L ve CMA\_R bölgeleri 6 denek için en başarılı bölgelerde yer almışlardır. Bu bölgelerden sonra PMv\_L bölgesi 5 ortak denekte en başarılı kombinasyonlar içinde yer almıştır.






Şekil 25. Veri Kümesi 2a Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

#### 3.4.4. sLORETA Yöntemi

Şekil 26'da mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



Şekil 26. Veri Kümesi 2a sLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

S1H\_R bölgesi 6 denek için en başarılı bölgede yer almıştır. Bu bölge dışında CMA\_L bölgesi 5 denek için en başarılı bölgeler içinde yer almıştır.


### 3.5. DVM Sınıflandırıcı ile Veri Kümesi (Dataset) 4a Sonuçları

Bu veri kümesinde amaç, sağ el ve sağ ayak olmak üzere verilen motor hayali işaretlerinin en yüksek doğrulukla sınıflandırılmasıdır. Beynin çapraz mantıkla çalışması gereği, sağ el için M1H\_L ve sağ ayak için M1F\_L bölgeleri olmak üzere, bu 2 bölge denenecek tüm kombinasyonlarda yer almıştır. Bu 2 bölgenin dışında, sol loptaki bölgeler (S1F\_L, S1H\_L, CMA\_L, SMA\_L, pSMA\_L, PMd\_L ve PMv\_L) ve bunların simetrik sağ lop karşılıkları (S1F\_R, S1H\_R, CMA\_R, SMA\_R, pSMA\_R, PMd\_R ve PMv\_R) olmak üzere 14 bölge ve ilk başta seçilen primer motor alanların simetrik bölgeleri M1H\_R ve M1F\_R ile birlikte 16 bölge üzerinde araştırmalar yapılmıştır. Elimizdeki 16 bölgenin tüm dörtlü kombinasyonlarına M1H\_L ve M1F\_L bölgeleri eklenerek, 5 denek için doğruluk değerleri hesaplanmıştır. 16 bölgenin dörtlü kombinasyon sayısı 1820'ye eşit olmaktadır. Bu yüzden her bir denek için her bir yöntem 1820 kez çalıştırılarak en yüksek doğruluk değeri ve bu değere karşılık düşen bölge kombinasyonları araştırılmıştır.

#### 3.5.1. Dipolar Yöntem

Şekil 27'de mü bandında, dipolar geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.


pSMA\_L, PMv\_L, M1F\_R ve pSMA\_R bölgeleri 3 denek için ortak olarak en başarılı sonuçlarda yer almaktadır.



Şekil 27. Veri Kümesi 4a Dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar

### 3.5.2. dSPM Yöntemi

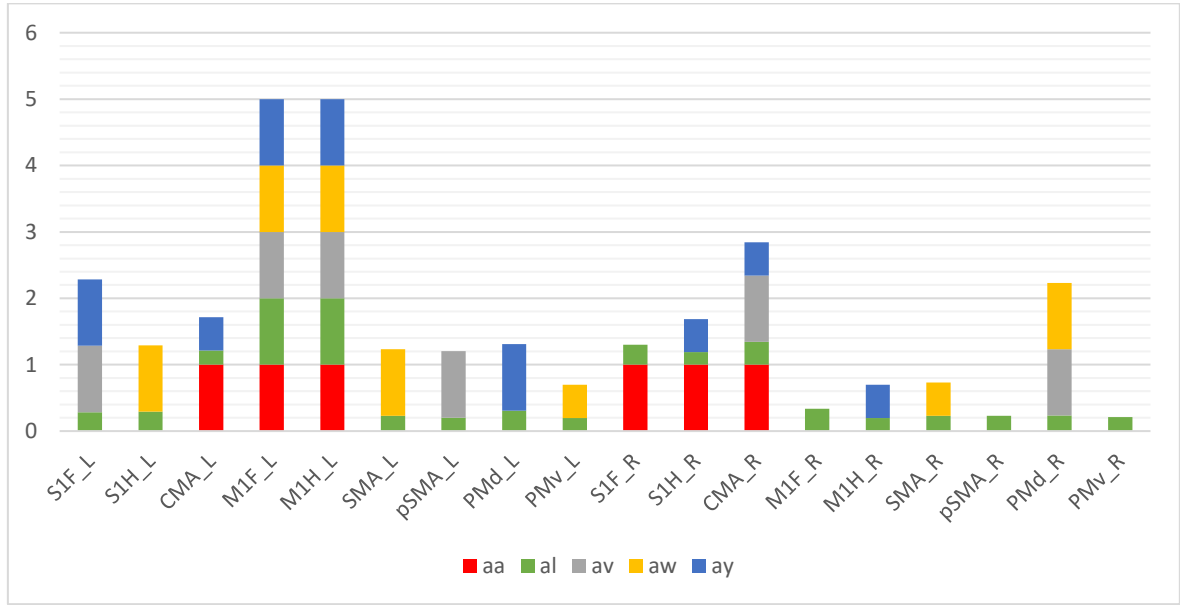
Şekil 28’de mü bandında, dSPM geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



Şekil 28. Veri Kümesi 4a dSPM yöntem ile mü bandı ve DVM ile elde edilen sonuçlar

Yukarıdaki grafik incelendiğinde CMA\_L bölgesi 4 denek için en başarılı bölge kombinasyonlarında yer almıştır.

### 3.5.3. Minimum Norm Yöntemi



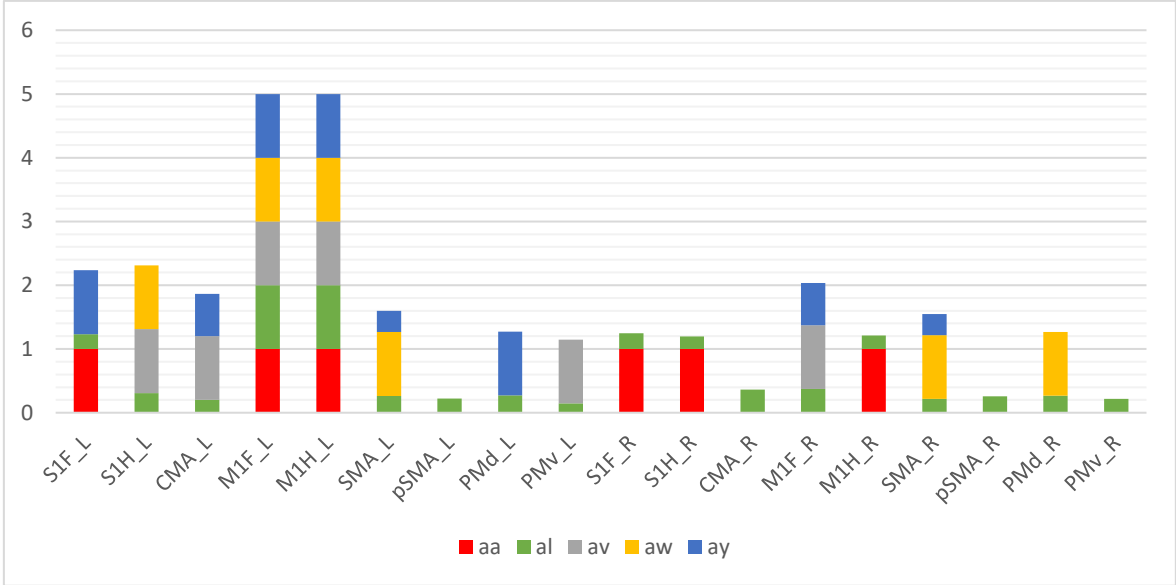
Şekil 29. Veri Kümesi 4a Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar

Şekil 29’da mü bandında, MN geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

CMA\_R bölgesi 4 denek için en başarılı kombinasyonda yer almıştır. Bu bölgeyi S1F\_L, CMA\_L, S1H\_R ve PMd\_R bölgeleri üçer denekte en başarılı bölgeler içinde yer alarak takip etmektedir.

### 3.5.4. sLORETA Yöntemi

Şekil 30’da mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



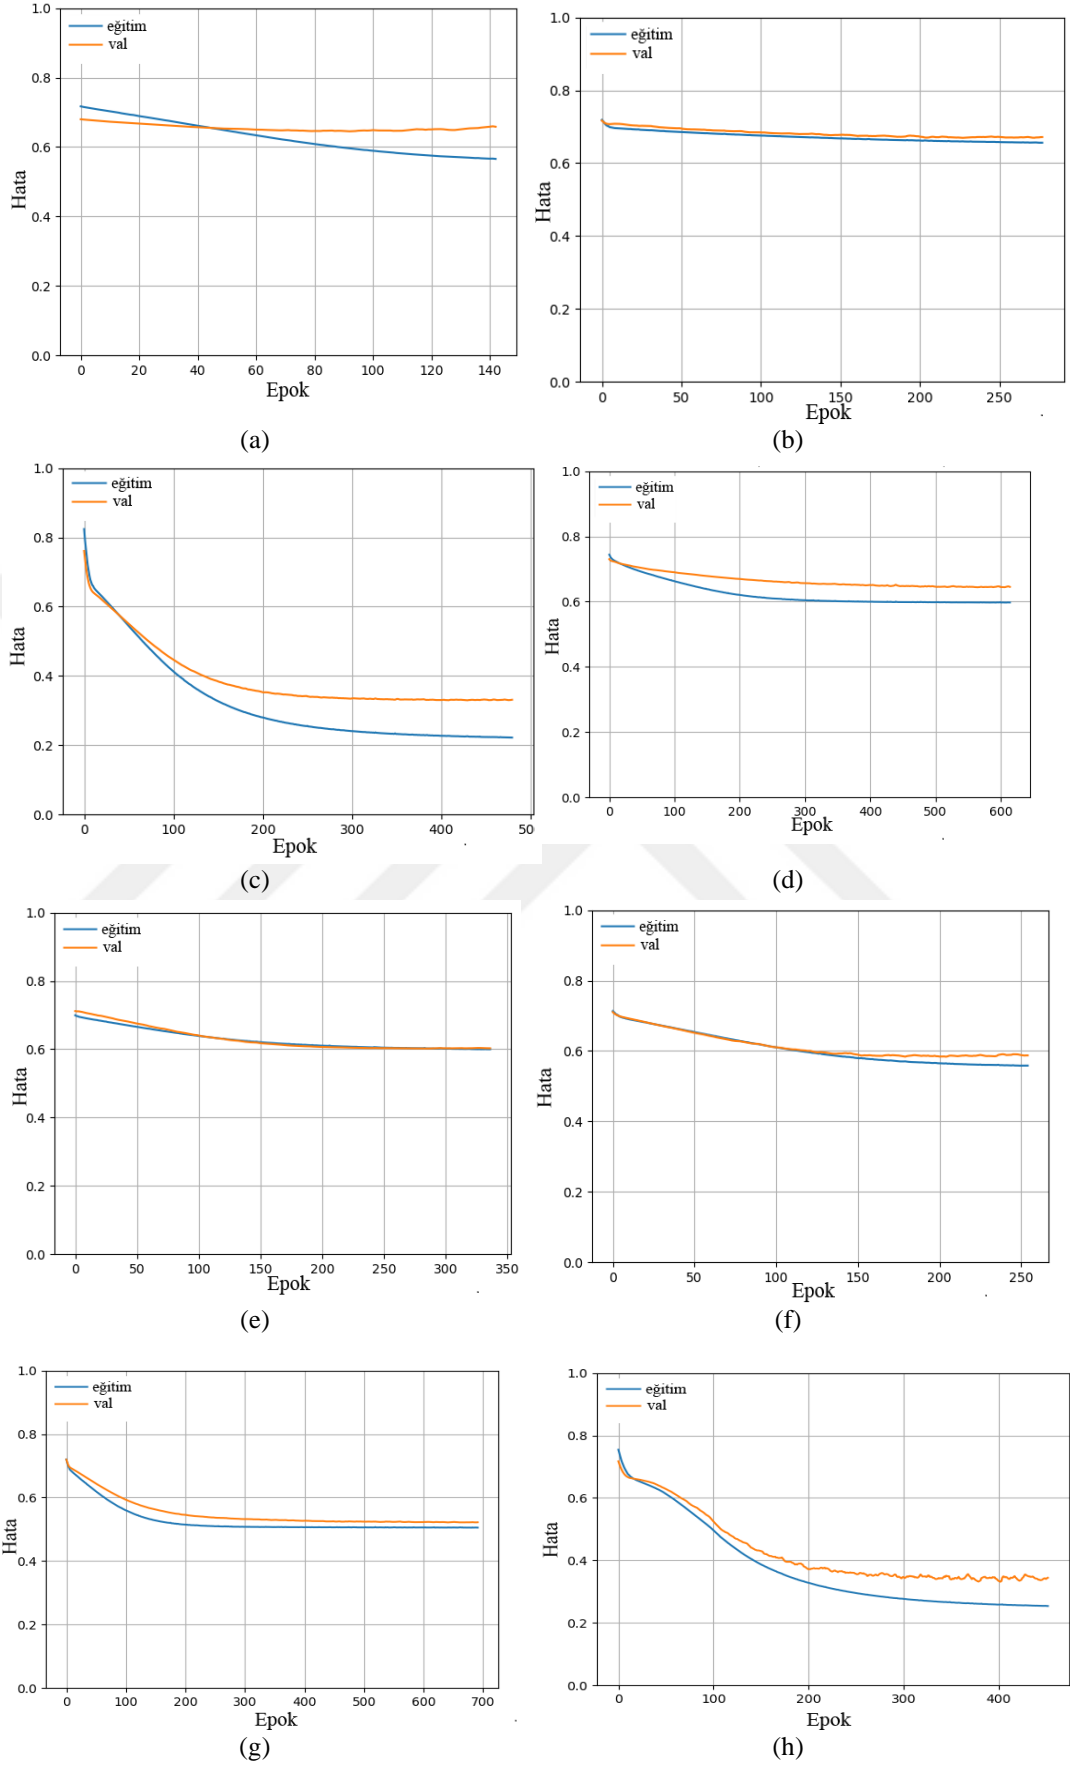
Şekil 30. Veri Kümesi 4a sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar

S1F\_L, S1H\_L, CMA\_L, SMA\_L, M1F\_R ve SMA\_R bölgeleri üçer kez en fazla başarıya katkı sağlayan bölge içinde yer almaktadır.

### 3.5.5. Veri Kümesi 2a Üzerinde YSA Eğitimi Esnasında Oluşan Eğitim-Doğrulama için Hata-Epok Eğrileri


Bu aşamada, YSA eğitim sürecinin doğru zamanda tamamlanabildiğini göstermek amacıyla Şekil 31’de Veri Kümesi 2a eğitim-doğrulama verileri üzerinde elde edilmiş olan hata-epok eğrileri grafikleri verilmiştir.

Grafikler incelendiğinde hata (loss) değeri bazı grafiklerde düşükken, bazı grafiklerde ise beklenen değerden yüksek olduğu görülmüştür. Beklendiği üzere hata değeri düşük olan durumlarda, çok daha yüksek doğruluk değerlerine ulaşılmıştır. Bu durumda, eğitim verilerinin bir kısmının iyi örnekler olmadığı kanaatine varılmıştır. Denek performansı birçok değişkenden etkilenmektedir. Deneğin, verilen göreve konsantre olması çok önemli olmaktadır.



Şekil 31. a-i) Denek 1-9 için eğitim ve doğrulama (val) veri setlerine bağlı epok-hata grafikleri


Şekil 31'in devamı



### 3.6. YSA Sınıflandırıcı ile Veri Kümesi 4a Sonuçları

#### 3.6.1. Dipolar Yöntem


Şekil 32'de mü bandında, dipolar geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



Şekil 32. Veri Kümesi 4a Dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar

S1H\_L, M1F\_R, M1H\_R, pSMA\_R ve PMd\_R bölgeleri 3 denek için en başarılı bölgeler olarak karşımıza çıkmaktadır.

### 3.6.2. dSPM Yöntemi



Şekil 33. Veri Kümesi 4a dSPM yöntem ile mü bandı ve YSA ile elde edilen sonuçlar


Şekil 33'te mü bandında, dSPM geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

Yukarıdaki grafik değerlendirildiğinde S1H\_L bölgesi 4 denek için, pSMA\_L ve CMA\_R bölgeleri 3 denek için en başarılı kombinasyonlarda yer almaktadır.

### 3.6.3. Minimum Norm Yöntemi

Şekil 34'te mü bandında, MN geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.






Şekil 34. Veri Kümesi 4a Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

Yukarıdaki grafiğe bakıldığında CMA\_L ve PMv\_L bölgeleri 4 denekte ve en başarılı bölge olarak karşımıza çıkmaktadır.

### 3.6.4. sLORETA Yöntemi

Şekil 35'te mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

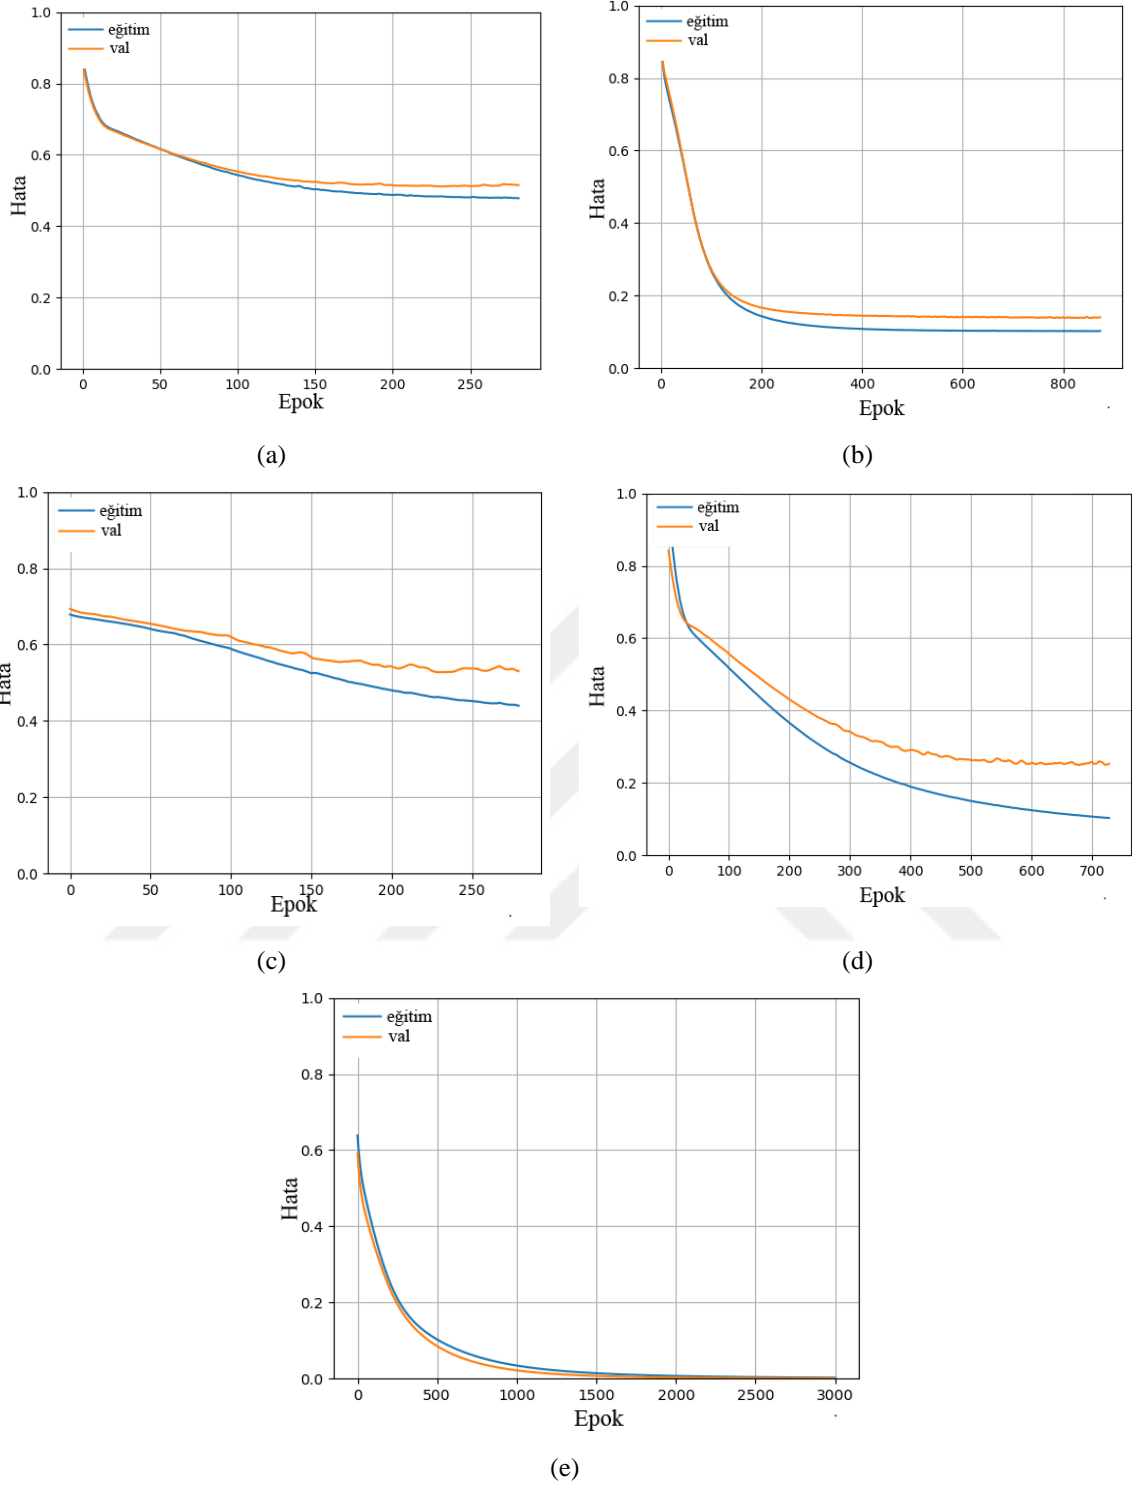
S1F\_L ve S1H\_L bölgeleri en başarılı bölgeler olarak 4 denekte ortak olarak karşımıza çıkmıştır. Bu bölgeleri CMA\_L, S1F\_R ve S1H\_R bölgeleri üçer denekle takip etmektedir.



Şekil 35. Veri Kümesi 4a sLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

### 3.6.5. Veri Kümesi 4a Üzerinde YSA Eğitimi Esnasında Oluşan Eğitim-Doğrulama için Hata-Epok Eğrileri

Bu bölümde Veri Kümesi 4a üzerinde elde edilen örnek hata-epok eğrileri Şekil 36'da verilmiştir. Eğitim verisi kendi içinde 5'e bölünerek %80'i eğitim ve %20'si doğrulama olmak üzere ayrılmıştır. Bu aşamada test verileri ağa hiç sunulmamıştır. Eldeki eğitim-doğrulama için hata-epok eğrileri elde edilmiştir. Bu grafik eğrileri, eğitimin ezberleme olmadan ve doğru olarak yapıldığını göstermektedir.



Şekil 36. Denek aa, al, av, aw ve ay için eğitim ve doğrulama (val) veri setlerine bağlı epok-hata grafikleri

Grafikler incelendiğinde Şekil 36b, 36d ve 36e için daha başarılı hata eğrileri elde edilmiştir. Bu deneklerde çok daha başarılı sonuçlar elde edilebilmiştir. Bu veri kümesinde

EEG kaydının 118 elektrotla yapılması ve deneklerin genel başarısının özellikle denek al, aw ve ay için yüksek olması, başarılı grafikler elde edilebilmesine olanak sağlamıştır.


### **3.7. DVM Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sağ Lop bölge Kombinasyonları ile Elde Edilen Başarı**

Bu aşamada M1F\_L ve M1H\_L bölgeleri her kombinasyonda yer almak üzere, sadece sağ loptan gelen dörtlü kombinasyonlarla birlikte toplamda 6 bölge kullanılarak doğruluk değerleri hesaplanmıştır. Sağ lopta yer alan S1F\_R, S1H\_R, CMA\_R, M1F\_R, M1H\_R, SMA\_R, pSMA\_R, PMd\_R ve PMv\_R bölgelerinin dörtlü kombinasyonlarına M1F\_L ve M1H\_L eklenerek doğruluk değerleri hesaplanmıştır. Bu değere karşılık gelen bölge kombinasyonları aşağıda her bir yöntem için ayrı ayrı grafiklerle gösterilmiştir.

#### **3.7.1. DVM Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular**

Bu aşamada M1F\_L ve M1H\_L bölgeleri her kombinasyonda yer almak üzere, sağ loptan gelen dörtlü kombinasyonlar ile en yüksek doğruluk değerine ulaşan bölgeler için normalize sonuç değerleri gösterilmiştir.

Şekil 37’de mü bandında, dipolar geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 37. Veri Kümesi 4a sağ lop kombinasyonları, dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar

Grafik incelendiğinde, S1H\_R, M1F\_R, SMA\_R, pSMA\_R ve PMv\_R bölgeleri dörder denek için en başarılı sonuçlar arasında yer almıştır.

### 3.7.2. DVM Sınıflandırıcı ve dSPM Yöntem ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular

Şekil 38'de mü bandında, dSPM geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 38. Veri Kümesi 4a sağ lop kombinasyonları, dSPM yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar

Şekil 38 değerlendirildiğinde, S1F\_R, S1H\_R ve SMA\_R bölgeleri dörder kez olarak en başarılı deneklerde yer almışlardır.

### 3.7.3. DVM Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular

Şekil 39'da mü bandında, MN geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 39. Veri Kümesi 4a Sağ Lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar

Yukarıdaki grafik incelendiğinde primer sağ ayak motor bölgesi M1F\_R tüm denekler için en anlamlı bölge olmuştur. Bu bölgeyi S1F\_R, CMA\_R ve M1H\_R takip etmektedir.

#### 3.7.4. DVM Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular

Şekil 40'ta mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

Şekil 40 incelendiğinde CMA\_R bölgesi tüm denekler için ortak olarak en başarılı bölgede yer almıştır. Bu bölgeyi S1F\_R ve S1H\_R bölgeleri dörder denekle takip etmektedir.



Şekil 40. Veri Kümesi 4a sağ lop kombinasyonları, sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar


### 3.8. DVM Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sol Lop bölge Kombinasyonları ile Elde Edilen Başarı

Bu aşamada M1F\_L ve M1H\_L bölgeleri her kombinasyonda yer almak üzere, sadece sol lopta yer alan seçili bölge kombinasyonları kullanılarak, M1F\_L ve M1H\_L bölgeleri dışında, geri kalan 7 bölgenin (S1F\_L, S1H\_L, CMA\_L, SMA\_L, pSMA\_L, PMd\_L ve PMv\_L) dördü kombinasyonları ile sadece sol lop bölgeleri kullanılarak en başarılı bölgeler belirlenmiştir.

#### 3.8.1. DVM Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için ile Elde Edilen Bulgular

Şekil 41’de mü bandında, dipolar geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sol loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.






Şekil 41. Veri Kümesi 4a sol lop kombinasyonları, dipolar yöntem ile mü bandı ve DVM ile elde edilen sonuçlar

Yukarıdaki grafikte CMA\_L bölgesi 5 denekte ve pSMA\_L bölgesi ise 4 denekte en başarılı sonuçlar içinde yer almıştır.

### 3.8.2. DVM Sınıflandırıcı ve dSPM Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular

Şekil 42’de mü bandında, dSPM geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sol loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 42. Veri Kümesi 4a sol lop kombinasyonları, dSPM yöntem ile mü bandı ve DVM ile elde edilen sonuçlar

Şekil 42 incelendiğinde, S1F\_L ve PMd\_L bölgeleri 5 denekte, CMA\_L bölgesi 4 denekte en başarılı bölge kombinasyonu içinde yer almıştır.

### 3.8.3. DVM Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular

Şekil 43'te mü bandında, MN geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sol loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 43. Veri Kümesi 4a sol lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar

Şekil 43 incelendiğinde S1F\_L, SMA\_L ve PMd\_L bölgeleri dörder denekle en başarılı sonuçlarda yer almıştır.

### 3.8.4. DVM Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular

Şekil 44'te mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak DVM sınıflandırılması ile sol loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



Şekil 44. Veri Kümesi 4a sol lop kombinasyonları, sLORETA yöntemi ile mü bandı ve DVM ile elde edilen sonuçlar


Grafik incelendiğinde S1F\_L, S1H\_L, CMA\_L, SMA\_L ve PMd\_L bölgeleri dörder denek için en başarılı sonuçlarda yer almıştır.

### 3.9. YSA Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sağ Lop Bölge Kombinasyonları ile Elde Edilen Başarılar

Bu aşamada, M1F\_L ve M1H\_L bölgeleri sabit olmak üzere, sadece sağ lopta yer alan S1F\_R, S1H\_R, CMA\_R, M1F\_R, M1H\_R, SMA\_R, pSMA\_R, PMd\_R ve PMv\_R bölgelerinin dördü kombinasyonlarına M1F\_L ve M1H\_L eklenerek doğruluk değerleri YSA sınıflandırıcı yardımıyla hesaplanmıştır. Bu değere karşılık gelen bölge kombinasyonları aşağıda her bir yöntem için ayrı ayrı grafiklerle gösterilmiştir.

#### 3.9.1. YSA Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular

Şekil 45'te mü bandında, dipolar geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 45. Veri Kümesi 4a sağ lop kombinasyonları, dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar

Yukarıdaki grafikte PMd\_R bölgesi dört denek için en başarılı sonuçta yer almaktadır.

### 3.9.2. YSA Sınıflandırıcı ve dSPM Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular

Şekil 46'da mü bandında, dSPM geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.


S1F\_R, S1H\_R ve CMA\_R bölgeleri dörder denekte en başarılı bölgeler içinde yer almaktadır.



Şekil 46. Veri Kümesi 4a sağ lop kombinasyonları, dSPM yöntem ile mü bandı ve YSA ile elde edilen sonuçlar

### 3.9.3. YSA Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular

Şekil 47’de mü bandında, MN geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 47. Veri Kümesi 4a sağ lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

S1F\_R ve M1F\_R bölgeleri tüm deneklerde en başarılı bölgeler arasında yer almıştır. Bu bölgeleri CMA\_R bölgesi 4 denek için en başarılı bölgeler arasında yer alarak takip etmektedir.

### 3.9.4. YSA Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sağ Lop için Elde Edilen Bulgular

Şekil 48’de mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



Şekil 48. Veri Kümesi 4a sağ lop kombinasyonları, SLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar


S1F\_R ve CMA\_R bölgeleri beşer denekte ortak olarak en başarılı bölgeler içinde yer almaktadır.

### 3.10. YSA Sınıflandırıcı ile Veri Kümesi 4a Üzerinde Sol Lop Bölge Kombinasyonları ile Elde Edilen Başarılar

Bu aşamada, YSA sınıflandırıcı kullanılarak, M1F\_L ve M1H\_L bölgeleri her kombinasyonda yer almak üzere, geri kalan 7 bölgenin (S1F\_L, S1H\_L, CMA\_L, SMA\_L, pSMA\_L, PMd\_L ve PMv\_L) dörtlü kombinasyonları ile sadece sol lop için en başarılı bölgeler belirlenmiştir.

#### 3.10.1. YSA Sınıflandırıcı ve Dipolar Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular

Şekil 49'da mü bandında, dipolar geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sol loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.




Şekil 49. Veri Kümesi 4a sol lop kombinasyonları, dipolar yöntem ile mü bandı ve YSA ile elde edilen sonuçlar

Yukarıdaki grafikte CMA\_L ve pSMA\_L bölgeleri dörder denekte en başarılı bölgeler içinde yer almıştır.

### 3.10.2. YSA Sınıflandırıcı ve dSPM Yöntem ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular

Şekil 50’de mü bandında, dSPM geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sol loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.



Şekil 50. Veri Kümesi 4a sol lop kombinasyonları, dSPM yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar


Yukarıdaki grafikte S1F\_L, S1H\_L ve PMd\_L bölgeleri dörder denek için en başarılı bölgeler arasında yer almıştır.

### 3.10.3. YSA Sınıflandırıcı ve Minimum Norm Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular

Şekil 51’de mü bandında, MN geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sol loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.


S1F\_L, PMd\_L ve PMv\_L bölgeleri dörder denekte en başarılı bölgeler içinde yer almıştır.





Şekil 51. Veri Kümesi 4a sol lop kombinasyonları, Minimum Norm yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

### 3.10.4. YSA Sınıflandırıcı ve sLORETA Yöntemi ile Veri Kümesi 4a Üzerinde Sol Lop için Elde Edilen Bulgular



Şekil 52. Veri Kümesi 4a Sol lop kombinasyonları, sLORETA yöntemi ile mü bandı ve YSA ile elde edilen sonuçlar

Şekil 52’de mü bandında, sLORETA geri problem çözüm yöntemi kullanılarak YSA sınıflandırılması ile sağ loptan gelen bölgelerin en başarılı doğruluk değerlerinde bulunma sıklıkları tüm denekler için gösterilmiştir.

Yukarıdaki grafikte S1H\_L ve PMd\_L en başarılı bölgeler içinde dörder denek için yer almıştır.

#### 4. SONUÇLAR

Bu çalışmada BBCI yarışması için kaydedilmiş olan ve araştırmacıların serbest erişimine açılmış EEG sinyalleri, geri problem çözümü yardımıyla kortikal kaynak uzayındaki sinyallere dönüştürülmüştür. Elde edilen sinyallerin bölgesel ortalamaları üzerinde OUÖ özellik çıkarma ve sınıflandırma işlemi yapılarak, bireyin motor hayal anında hangi uzvunu hareket ettirmeyi hayal ettiği belirlenmeye çalışılmıştır.

Bu tez çalışmasının katkıları şu şekilde özetlenebilir:

- Bölge kombinasyonları kullanılarak, motor hayalinde en yüksek doğruluğa ulaştıran bölgeler kombinasyonu araştırıldı.
- Geri problem çözümünde dipolar, dSPM, Minimum Norm ve sLORETA olmak üzere dört farklı geri çözüm ile sonuçlar elde edildi.
- Motor hayalinde ipsilateral katkıların yanında kontralateral katkıların da önemli olduğu ortaya çıkarıldı.

İnsan beyninin daha iyi anlaşılabilmesi için disiplinler arası birçok çalışma yapılmaktadır. Motor hareketi de günlük hayatta beyin kontrol ettiği önemli hareketlerden biridir. Beynin hasar görmesi veya farklı bir nedenle motor hareketini yapamayan hastalar için, motor hayalinden kişinin düşüncesinin okunabilmesi, hasta yaşam kalitesinin artması açısından çok önemlidir. Bu çalışmada 2 farklı veri kümesi üzerinde, belirli uzuvların motor hayali esnasında, insan beyninde kontrolünden en fazla katkı sunan bölgeleri araştırıldı.

EEG kayıtlarında epoklar alınırken en ilgili epokun alınması da istenen bir durumdur. Motor hayali süresince bir deneğin hep aynı konsantrasyon ve dikkatle motor hayali yapması beklenmemektedir. Bu durumda en anlamlı zaman aralıklarının belirlenmesi de literatürde önemli çalışmalar arasında yer almaktadır. EEG kaynak lokalizasyonu ile aktif bölgeler bulununca, aktif olan bölgeler eğer uzman fizyologlar tarafından beklenen bölgeler değilse, bu durumda motor hayalinin yeterince sağlıklı yapıldığı söylenemez. En ilgili kayıt anlamlarının alınması ile daha yüksek başarımlı BBA'lar gerçekleştirilebilir.

Deneklerin başarımlı durumlarına baktığımız zaman, bazı deneklerin bazı motor hayallerinde çok daha fazla yetenekli oldukları gözlemlenmiştir. Bu durumda kişiye özgü BBA tasarlanırken bu durumun da dikkate alınmasında fayda olacağı düşünülmektedir.

Son yıllarda daha başarılı BBA sistemleri geliştirilmesine rağmen, halen ticari olarak güvenilir çok az sayıda ürün bulunmaktadır. Fizyologla birlikte gerçekleştirdiğimiz bu çalışmamızla, kişiler arası farklılıkların dikkate alınmasıyla çok daha başarılı ürünlerin ortaya çıkabileceğine inanılmaktadır. BBA sistemleri, disiplinler arası bir alan olup, bu alanda mühendisler, fizyologlar, nörolog ve psikologların önerileriyle, dikkate alınacak parametrelerin daha net belirlenmesiyle ileride daha güçlü ve güvenilir cihazlara kavuşulabileceği düşünülmektedir.

Bu tez çalışmasında kaynak yerelleştirimi yapılması ile elde edilen kaynak EEG sinyalleri yardımı ile BBA geliştirilmiştir. Bu sayede beyin çalışması hakkında da bilgiler elde edilmiştir. EEG kaynak lokalizasyonu ile EEG yöntemi bir nörogörüntüleme amacıyla kullanılmıştır.

Geri problem çözümünde 4 farklı yöntem denenmiştir. Böylece farklı yöntemlerin kaynak yerelleştirilmesine sınıflandırma başarısı açısından değerlendirilmesi sağlanmıştır. Kaynak yerelleştirimi ve BBA'yı etkileyen parametreler ayrıntılı olarak irdelenmiştir. Çalışmamızda gerçekçi kafa modeli kullanılmış ve Brainstorm yazılımından yararlanılmıştır. Beyin korteksinde yer alan farklı işlevden sorumlu alanlarla birlikte detaylı olarak en başarılı kombinasyonlar araştırılmıştır. Motor hayalinde en etkili alanlar bulunmaya çalışılmıştır.

Bu çalışmada, kaynak yerelleştirimi motor hayali işlevi için gerçekleştirilmiştir. Kullandığımız yöntemler EEG ile çalışan diğer araştırmacılar için farklı problemlere de uygulanabilir.

Motor hayali yapılırken, beyin motor alanlardaki sinyalleri en önemli kabul ederek, bunlara yardımcı bölgeler elde edilmeye çalışıldı. Kişiler arası farklılıklar olabilmektedir. Kafa derisi EEG sinyalleri, kaynak görüntüleme yöntemiyle kortikal bölgeler üzerindeki aktivasyonlara dönüştürülmüştür ve ardından bu sinyaller üzerinde eğitim ve test işlemleri yapılmıştır. Sınıflandırılan işaretler sağ el, sağ ayak ve sol el gibi temel motor hareket hayalleridir.

Özellikle el ile ilgili bölgenin en başarılı sonuçlar içinde yer alması dikkat çekmektedir. Deneklerin bazı motor hayallerini daha kolay yapabilmekte olduğu kanaatine varılmıştır. El günlük hayatta daha fazla kullanımda olduğu için, motor hayalinin de daha kolay yapılabildiği düşünülmektedir.

Sağ el ve sağ ayak ile ilgili çalışmamızda beynin sağ lobu, sol lobu ve her iki lobunu içeren araştırmalar yapılmıştır. Beklendiği üzere sağ el veya sağ ayak motor hayalinde

beynin sol lobu daha yüksek doğruluklu sonuçlar vermiştir. Ancak her 2 lobu dikkate aldığımızda, en yüksek doğruluğa hem sol hem de sağ lobun birlikte olmasıyla ulaşılmıştır. Yani motor hayalinde beynin her 2 yarım küresi de haberleşince daha yüksek başarılı sonuçlar elde edilebilmektedir.

Motor hareketin yapılması aşamasında hareketin planlanması, programlanması ve gerçekleştirilmesi olmak üzere 3 aşaması vardır. Motor hareketin planlanması ve programlanması ile motor alanda ayırt edilebilir sinyaller ortaya çıktığı gözlemlenmiştir. Ayrıca en iyi başarımlarında kişiler arası farklı planlama ve programlama alanlarının etkin olabildiği görülmüştür. Bu duruma beyin işlem hızlarının kişiden kişiye farklılık gösterebildiği veya kişiler arası yolak farklarının bulunabilmesi durumlarının neden olabileceği düşünülmektedir.

EEG tabanlı BBA gelişimine mühendisler, hekimler, nörobilimciler ve cihazı kullananların yer aldığı geniş bir disiplinler arası alana hitap etmektedir. Son yıllarda yapılan çalışmalarla çok ümit verici sonuçlar elde edilmiştir. BBA'lar için yeni modellerin önerilmesinin yanında sinyal alımı, işlenmesi ve yorumlanması alanında yapılan yenilikler ile çok daha güçlü, yüksek performanslı ve doğruluklu cihazlara ve uygulamalara sahip olunması beklenmektedir.

Laboratuvar ortamında başarıyla çalışan cihazların gerçek dünyada kullanıma geçirilmesi çok önemlidir. Nöromusküler veya motor eksikliği olan bireylerin çevresiyle iletişiminin sağlanması hem bireyler için hem çevresindeki kişiler için olumlu sonuçlar oluşturacaktır. EEG tabanlı BBA'lar sinirbilimde bireylerin çevresiyle gerçek zamanlı olarak iletişim kurmasına yardımcı olabilecek arayüzler içinde en güçlü aday olarak gözükmektedir.

Çalışmada ilgili sağ ve sol primer motor alanlar başta olmak üzere, toplam 6 bölge kullanılarak sonuçlar mü ve diğer bantları içerecek frekanslarda (0.1-30 Hz ve 0.5-30 Hz) bantlarında elde edildi. Tablo 1 incelendiğinde mü bandında çok daha başarılı sonuçlar üretilmiştir. Veri Kümesi 4a için denekler arası başarımlar mü bandı ve 0.1-30 Hz bandı için Tablo 5 ve Tablo 6'ya bakıldığında beş denek için sırasıyla %5, %16, %7, %9 ve %31 oranlarında mü bandı ile daha başarılı sonuçlar elde edilmiştir.

Geri problem çözümünde dipolar, dSPM, minimum norm ve sLORETA yöntemleri ile en yüksek doğruluk değerine ulaşılmaya çalışılmıştır. Yöntemlerin başarımlarını denekler arasında farklılık gösterebilmektedir. Veri kümesi 4a için bakıldığında DVM yönteminde sLORETA, YSA için Minimum Norm; Denek 2 için her iki yöntemde de dSPM, Minimum

Norm ve sLORETA, Denek 3 için DVM yönteminde dSPM, YSA için dipolar yöntem; Denek 4 için DVM'de dSPM, Minimum Norm ve sLORETA yöntemleri ve YSA için Minimum Norm yöntemi ve son olarak Denek 5 için her iki sınıflandırıcıda da dSPM yöntemi en başarılı sonuca katkı vermiştir. DVM kullanımında toplamda 4 denek için dSPM öne çıkmıştır. Ancak diğer yöntemler de başarılı sonuçlar verebilmektedir. Bireyler üzerinde farklı geri problem çözümü denendikten sonra, denek için uygun yönteme karar verilmesi önerilmektedir.

Veri Kümesi 4a üzerinde sağ, sol ve her iki yarı birlikte olacak şekilde farklı kombinasyonlara bakılmıştır. Sağ el veya sağ ayak motor hayalinde sol lobun daha başarılı sonuçlar vermesi beklenmektedir. Bu bağlamda sol lop, sağ loba göre başarısı yüksek deneklerde gerçekten de daha başarılı sonuçlar vermiştir. Ancak her iki lop birlikte kullanılıncaya en yüksek doğruluk değerlerine ulaşılmıştır. Tablo 8, 9, 10 ve 11 incelendiğinde daha yüksek başarıya ulaşan Denek 2, 4 ve 5 için sol lop daha başarılı olmuştur. Denek 2 için %100 başarı varken, Denek 4 için %3 ve Denek 5 için %1 sol lop, sağ loba göre daha iyi sonuç sağlanmıştır. Ancak Denek 1 ve Denek 3 için bu sefer sağ lop, sol loptan yaklaşık %2 daha iyi sonuç vermiştir. Daha yüksek başarıya ulaşan yani daha iyi deneye konsantre olduğu düşünülen bireylerde sol lop bölgeleri, sağ lop bölgelerinden daha başarılı sonuçlar vermiştir. Sonuçlar bulunurken M1F\_L ve M1H\_L bölgeleri bütün kombinasyonlarda yer almaktadır. Geri kalan 4 bölgenin sağ veya sol loptan seçilerek yani toplam 16 bölgenin 4'lü kombinasyonları alındığında başarı değerleri Tablo 5'te verilmiştir. Seçilen bölgelere hem sağ ve hem de sol lop katkısı olduğunda başarı, en iyi sınıflandırıcı sonucuna göre Denek 1 için sağ loba göre %3, sol loba göre %5 daha yüksek olmaktadır. Denek 2 için, tüm durumlarda %100 başarıya ulaşılabilmiş, Denek 3 için sağ loba göre %1 ve sol loba göre %3 daha iyi başarı sağlanmış, Denek 4 için sağ loba göre %7, sol loba göre %4 ve Denek 5 için ise sağ loba göre %2, sol loba göre %0.4 iyileşme olmuştur. Beynin iki lobu birlikte kullanılarak çok daha iyi sonuçlar elde edilmiştir.

Literatürde, deneklere özel kanal seçimi öneren çalışmalar mevcuttur. Bu çalışmalarda, aynı yöntem kullanılsa da farklı bireyler için özel kanal seçimlerinde en yüksek başarıya ulaşıldığı bildirilmiştir. Fakat çalışmamızda farklı bir yaklaşım geliştirilmiş ve bu bağlamda kortikal bölgeler dikkate alınarak elde edilen sonuçlar, farklı bireyler için farklı bölgelerle daha yüksek başarıya ulaşabileceğini göstermiştir. Bu sonuçlar, literatürde bireye özgü (subject specific) kanal bulma çalışmalarını hem desteklemekte hem de kortikal

seviyesinde de başarımın iyi olduğunu göstermektedir. Bu bilgilere ek olarak, farklı kanalların bireye özel olarak çıkmasının nedenini de ortaya koymaktadır.

Literatürde epilepsi hastalığında konum bulunabilmesi için minimum 64 kanal kullanılması önerilmektedir. Böylece geri problem çözümü daha doğru yapılabilmektedir. Çalışmamızda 118 kanal kullanımında, beş denek için de aynı veri kümesini kullanan elektrot seviyesinde sınıflandırma yapan çalışmalara göre daha başarılı sonuçlar elde edilmiştir. Ancak 22 kanalla kayıt yapılan Veri Kümesi 2a üzerinde ise dört denek için daha başarılı, beşinde daha az başarılı sonuçlar elde edilmiştir. Kanal sayısının fazla olmasıyla daha hassas ve daha güvenilir geri problem çözümü yapılabilmektedir. Sonuçlarımız da fazla sayıda kanal kullanımı ile daha yüksek doğruluğa erişilebileceğini ortaya koymaktadır.



## 5. ÖNERİLER VE TARTIŞMA

Bu tez kapsamında kortikal EEG sinyalleri üzerinde motor hayaline dayalı sinyallerin ayırt edilebilmesi için çalışılmıştır. Sonuçlar EEG nörogörüntülemenin beyni daha iyi anlamamıza olanak tanıyacağını göstermektedir. Bu çalışma gelecekte fNIRS veya fMRG gibi çalışmalarla birlikte yapılırsa daha kapsamlı olarak beyin araştırmalarına olanak sağlanabilir.

EEG kaynak sinyalleri bulunurken literatürdeki en gerçekçi kafa modelleri kullanılmıştır. Yapılan çalışmalarda gerçek kafa MRG görüntüleri ve kaynak lokasyonlarının tam ölçülmesiyle elde edilen veriler kullanılarak daha hassas sonuçlar elde edilebilir. Hastanede veya klinik merkezlerinde EEG kaydı alınan hastaların veya deneklerin, gerçek MR görüntüleri genellikle alınmamaktadır. Bu bireylerin gerçek MR görüntülerinin kullanılmasıyla ileri ve geri problem çözümünde gerçek kafa modeli kullanılabilir ve bu sayede daha başarılı sonuçlar elde edilebilir.

Daha yüksek doğruluklu BBA elde edilebilmesi için, EEG sinyallerinin kaydedilmesinin doğru bir şekilde yapılması ve sinyallerin kaliteli olması çok önemlidir. EEG sinyalleri daha yüksek hızda örneklenir ve daha yüksek dinamik aralıklı A/D dönüştürücülerle elde edilirse sonuçlar daha hassas olarak elde edilebilir. Yani, EEG sinyalleri daha yüksek çözünürlüklü olarak alınabildiği cihazlar tercih edilirse sonuçlar daha hassas olarak elde edilebilir. Veri kaydı yapılırken kullanılan elektrotların daha kaliteli olması da başarının yükselmesine katkı sunabilir.

EEG yönteminin girişimsel ve yüksek maliyetli olmaması sonucunda çoğu sağlık merkezinde bulunması araştırmacılar için büyük kolaylık sağlamaktadır. Gelecek çalışmalarda daha fazla uzvun motor hayalleri üzerine çalışmalar yapılabilir. Bazı deneklerin belirli uzvun motor hayalinde daha başarılı olabildiği görülmektedir. Kişiler arası başarımlar da farklı olabilmektedir. Çalışmamızda başarılı denekler için motor hayalinde, aktif olması daha fazla beklenen lop ve bölgelerin aktif olabildiği gözlemlenmiştir. Hem kişilerin belirli motor hayalinde daha başarılı olabilmesi, hem de kişiler arası farklılıklar oluşabilmesi nedeniyle, tasarlanacak olan BBA'nın kişiye özgü olması önerilmektedir.

Önerilen kaynak uzayında EEG sınıflandırılmasının gerçek zamanlı olarak yapılabilmesi, el, ayak veya dil gibi hayal edilen organın belirlenebilmesi motor engelli bireylerin kendilerini anlık olarak ifade edebilmeleri ve biyomekanik cihazları anlık olarak

kullanabilmeleri için çok önemlidir. Motor Hayal BBA tasarımında yaygın olarak kullanılan yüzey elektrot tabanlı sınıflandırmanın yerini, geri problem dönüşümünün ardından kortikal kaynak uzayında sınıflandırma alabilir.

EEG sınıflandırılması yapılırken en uygun kanalların belirlenmesi çalışmalarında, kişi için uygun kanallar belirlendiğinde, bireyler arası farklılıklar olduğu bildirilmiştir. Bu çalışmada Brodmann alanlarında elde edilen ortalama sinyaller üzerinde elde edilen özellikler ve sınıflandırma sonucunda farklı bireylerin, farklı kombinasyonlarda en yüksek sınıflandırma doğruluğuna ulaşabildiği görülmüştür. Daha fazla sayıda denek kullanılarak, belirli uzuvların ve motor hayalinde en etkili olan beyin bölgeleri hakkında istatistiki bilgiler elde edilebilir.

EEG kaynak görüntüleme ile elde edilen işaretlerde, daha fazla elektrot ile elde edilen veri kümesinde çok daha başarılı sonuçlar elde edilmiştir (Tablo 5 ve Tablo 7). Kaynak EEG çalışması yapmak isteyen araştırmacıların, fazla elektrot ile yüksek çözünürlüklü kayıt düzeneği kullanmaları önerilmektedir [111].

Bir uzvun motor hayali esnasında sağ lop ve sol lop için ipsilateral ve kontralateral olarak motor hayalinde sınıflandırma doğruluğu elde edilmiştir. Her iki lobun birlikte kullanımı ile daha yüksek başarımlar elde edilmiştir. Hareketle ilgili beyin bölgelerinin araştırılmasının yanında kortikal ağ yapısı göz önüne alınarak, motor hayali esnasında oluşan ağ yapısının detaylı olarak elde edilebilmesi beynin çalışmasını daha iyi anlamamızı sağlayabilir.

Nöroprotez geliştirmek için, gerçek zamanlı olarak motor hayalinin algılanabilmesi ve cihaza bilgi verilebilmesi çok önemlidir. Bu amaçla en doğru bilgiyi veren ve az sayıda bölge kullanımı çok faydalı olabilir. Az sayıda bölge kullanımı ile daha hızlı hesaplama yapılabilir.

Denekler arasında en yüksek doğruluklara bakıldığında, standart sapmanın yüksek olduğu gözlemlenmiştir. Deneyi başarıyla gerçekleştirme oranı bireyden bireye farklılık göstermektedir. Bu konuda daha iyi özellik çıkarma ve daha iyi sınıflandırıcıların ortaya çıkması akla ilk gelen değerlendirmeler olmaktadır. Bunun yanı sıra deneklerden veri kaydedilmeden önce, eğitime tabi tutulmaları, daha yüksek doğruluklu kayıtlar yapılmasına olanak sağlayabilir. Ayrıca bireyler arası yaş, cinsiyet gibi farklılıklar da deney başarısını etkileyebilmektedir. Deneklerden veri kaydı yapılmadan önce tezde 1. bölümde değinilen uyku durumları, beslenme durumları, zihinsel yükleri, geri bildirim verme durumları, alkol ve sigara kullanma durumları ve ruh halleri gibi parametrelere dikkat edilerek kayıt



yapılması, deneklerin başarı oranlarının hem daha yüksek olmasına hem de birbirlerine daha yakın çıkmasına yardımcı olabilir.

EEG cihazlarının yanında fNIRS, MEG veya fMRG gibi ek bir nörogörüntüleme yönteminin kullanılması aktif beyin bölgelerinin tespitinde hem bir doğrulama hem de eşzamanlı bir nörogörüntüleme yöntemiyle beynin çalışmasının daha iyi anlaşılmasına katkı sunabilir. MEG ve fMRG yöntemleri beynin çalışmasının anlaşılmasına çok önemli katkılar sunmaktadır. Ancak bu cihazlarının büyük yer kaplaması ve maliyetlerinin de fazla olması nedeniyle araştırmacıların kolayca erişememesine neden olmaktadır. Bu yüzden fNIRS gibi daha kolay taşınabilen bir cihaz yardımıyla EEG-fNIRS kaydı birlikte yapılarak beyin çalışması hakkında bilgiler verilebilir.

Tez çalışmasında sağlıklı bireylerin yer aldığı, tüm araştırmacılara açılmış olan veri kümeleri kullanılmıştır. Bu nedenle farklı çalışmalarla sonuçların karşılaştırma yapılabilmesine olanak sağlanmaktadır. Motor hayalinde ana amaçların başında engelli bireylerin beyin gücüyle, cihazları kullanması ve yaşam kalitelerinin artması amaçlanmaktadır. Bu nedenle, etik form ve hasta onam formu alınarak, engelli bireylerden alınacak olan kayıtların kullanılması da oldukça önemlidir. Bu sayede hem sağlıklı bireylerden alınan verilerle karşılaştırmaların yapılması hem de hedef grubun daha iyi anlaşılması ve onlara yardım edilebilmesi için engelli bireylerle çalışılması önerilmektedir. Bu bireylere motor imgeleme veya rehabilitasyon eğitimleri verilmeden önceki alınan veriler ve bu eğitimler sonrası alınan verilerle yapılabilecek olan çalışmaların bu alanda önemli katkı sunabileceği düşünülmektedir.

Motor Hayal tabanlı BBA sistemlerinin ticari uygulamalar için kullanılması dünya genelinde önemli bir hedeftir. Ancak %100 başarıma ulaşamaması ve kullanıcılar için hayati risk doğurabilecek durumların olması nedeniyle, bu cihazlar halen ticari kullanımdan uzak gözükmemektedir. Daha başarılı BBA geliştirilebilmesi için mühendislerin, fizyologların, nörologların, nörobilimcilerin ve psikologların yakın iş birliğiyle disiplinler arası çalışmalar yapılması gerekmektedir.

## 6. KAYNAKLAR

1. Haufe, S., Tomioka, R., Dickhaus, T., Sannelli, C., Blankertz B., Nolte ve G., Müller, K.-R., Localization of class-related mu-rhythm desynchronization in motor imagery based Brain-Computer Interface sessions. 32nd Annual International Conference of the IEEE EMBS, Buenos Aires, 2010.
2. Bansal, D. ve Mahajan, R., EEG-Based Brain-Computer Interfaces: Cognitive Analysis and Control Applications. Academic Press, 2019.
3. Chamola, V., Vineet, A., Nayyar, A. ve Hossain, E., Brain-Computer Interface-Based Humanoid Control: A Review. Sensors, 20, 13 (2020) 1-23.
4. Rao, R. P. N., Brain-Computer Interfacing. New York: Cambridge University Press., 2013.
5. Blinowska, K. ve Durka, P., Electroencephalography (EEG). Wiley Encyclopedia of Biomedical Engineering. American Cancer Society, 2006.
6. Freeman, W. ve Quiroga, R. Q., Imaging Brain Function With EEG. Springer, 2013.
7. Boron, W. F. ve Boulpaep, E. L., Medical Physiology A Cellular and Molecular Approach. Saunders Elsevier, 2005.
8. [https://commons.wikimedia.org/wiki/File:Neuron\\_la.svg](https://commons.wikimedia.org/wiki/File:Neuron_la.svg). 1 Temmuz 2021.
9. Sanei, S. ve Chamvers, J. A., EEG Signal Processing. John Wiley & Sons, 2013.
10. <https://openclipart.org/detail/241365/realistic-brain-cross-section>. 1 Temmuz 2021.
11. Jatoi, M. A. ve Kamel, N., Brain Source Localization Using EEG Signal Analysis. CRC Press Taylor & Francis Group, 2018.
12. [https://commons.wikimedia.org/wiki/File:Figure\\_35\\_03\\_03.png](https://commons.wikimedia.org/wiki/File:Figure_35_03_03.png). 1 Temmuz 2021
13. Sharma, A. ve Weintraub, A., Neuroimaging, Encyclopedia of Clinical Neuropsychology. Springer International Publishing, 2017.
14. Liu, S., Cai, W., Liu, S., Zhang, F., Fulham, M., Feng, D., Pujol, S. ve Kikinis, R., Multimodal neuroimaging computing: a review of the applications in neuropsychiatric disorders. Brain Informatics, 2 (2015) 167–180.

15. Hosseini, S. A. H., Sohrabpour, A. ve He, B., Electromagnetic source imaging using simultaneous scalp EEG and intracranial EEG: An emerging tool for interacting with pathological brain networks. Clinical Neurophysiology, 129, 1 (2018) 168-187.
16. Zhang, Y., Drongelen, W. v., Kohrman, M. ve He, B., Three-dimensional brain current source reconstruction from intra-cranial ECoG recordings. NeuroImage, 42, 2 (2008) 683-695.
17. Clément, C., Brain-Computer Interface Technologies: Accelerating Neuro-Technology for Human Benefit. Springer, 2019.
18. Hamal, A. Q. ve Rehman, A. W. b. A., Artifact Processing of Epileptic EEG Signals: An Overview of Different Types of Artifacts. 2013 International Conference on Advanced Computer Science Applications and Technologies, Kuching, Malaysia, 2013.
19. Bastos-Filho, F. T., Introduction to Non-Invasive EEG-Based Brain-Computer Interfaces for Assistive Technologies. Taylor & Francis Group, 2020.
20. Klem, G. H., Lüders, H. O. ve Jasper, H. H., The ten-twenty electrode system of the International Federation. Recommendations for the practice of clinical neurophysiology: guidelines of the International Federation of Clinical Neurophysiology. Electroencephalography and Clinical Neurophysiology, 52 (1999) 3-6.
21. Jasper, H. H., The Ten-Twenty Electrode System of the International Federation. Electroencephalography and Clinical Neurophysiology, 10 (1958) 371-375.
22. Seeck, M., Koessler, L., Bast, T., Leijten, F., Michel, C., Baumgartner, C., He B. ve Beniczky, S., The standardized EEG electrode array of the IFCN. Clinical Neurophysiology, 128, 10 (2017) 2070-2077.
23. Oostenveld, R. ve Praamstra, P., The five percent electrode system for high-resolution EEG and ERP measurements. Clinical Neurophysiology, 112 (2001) 713-719.
24. [https://en.wikipedia.org/wiki/Functional\\_magnetic\\_resonance\\_imaging](https://en.wikipedia.org/wiki/Functional_magnetic_resonance_imaging). 10 Eylül 2020
25. Paszkiel, S., Analysis and Classification of EEG Signals for Brain-Computer Interfaces. Springer, 2020.
26. Lameka, K., Farwell, M. D. ve Ichise, M., Chapter 11 - Positron Emission Tomography. Handbook of Clinical Neurology. Elsevier, 209-227, 2016.
27. Muehllehner, G., Karp, J. S., Advances in SPECT and PET. IEEE Transactions on Nuclear Science, 35, 1 (1988) 639-643.

28. Haines, D. E. ve Mihailoff, G. A., *FUNDAMENTAL NEUROSCIENCE for Basic and Clinical Applications*. Elsevier, 2018.
29. Tsai, L. L., K G., Aaron, J. M., Koenraad, Kung, J. W. ve Smith, M. P., A Practical Guide to MR Imaging Safety: What Radiologists Need to Know. *Radiographics*, 35, 6 (2015) 1722-1737.
30. Storey, P., *Introduction to Magnetic Resonance Imaging and Spectroscopy. Magnetic Resonance Imaging Methods and Biologic Applications*. Totowa, New Jersey: Humana Press, 3-58, 2006.
31. Liang, Z.-P. ve Lauterbur, P. C., *Principles of Magnetic Resonance Imaging: A Signal Processing Perspective*. Wiley-IEEE Press, 2000.
32. Akdeniz, G., 2013. Cerrahi Adayı Epilepsi Hastalarında Epileptojenik Bölgenin Yüzeysel EEG Kaynak Yerleştirimi İle Belirlenmesi, Doktora Tezi, İstanbul Üniversitesi Sağlık Bilimleri Enstitüsü, İstanbul.
33. He, B. ve Liu, Z. (2008). Multimodal functional neuroimaging: integrating functional MRI and EEG/MEG. *IEEE reviews in biomedical engineering*, 1 (2008) 23–40.
34. Michel, C. M. ve Brunet, D., EEG Source Imaging: A Practical Review of the Analysis Steps. *Frontiers in Neurology*, 10 (2019) 1-18.
35. Vaughan, T. M., Guest Editorial Brain–Computer Interface Technology: A Review of the Second International Meeting. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 11, 2 (2003) 94-109.
36. Nam, C. S., Nijholt, A. ve Lotte, F., *Brain–Computer Interfaces Handbook*. New York: CRC Press, 2018.
37. Ashcraft, M. H. ve Radvansky, G. A., *Cognition*. Pearson, 2013.
38. Shneiderman, B., Plaisant, C., Cohen, M., Jacobs, S., Elmqvist N. ve Diakopoulos, N., *Designing the User Interface: Strategies for Effective Human-Computer Interaction*. Pearson, 2018.
39. Hassanien, A. E. ve Azar, A. T., *Brain-Computer Interfaces Current Trends and Applications*. Springer, 2015.
40. Wolpaw, J., Birbaumer, N., McFarland, D., Pfurtscheller, G. ve Vaughan, T., Brain–computer interfaces for communication and control. *Clinical Neurophysiology*, 113 (2002) 767–791.
41. Im, C.-H., *Computational EEG Analysis: Methods and Applications*. Springer, 2018.
42. Cohen, M. X., *Analyzing Neural Time Series Data*. The MIT Press, 2014.

43. Nijholt, A., *Brain Art Brain-Computer Interfaces for Artistic Expression*. Springer, 2019.
44. Kumar, D. K. ve Arjunan, S. P., *Human Computer Interface Technologies for the Motor Impaired*. CRC Press. 2015.
45. Guyton, A. C. ve Hall, J. E., *Tıbbi Fizyoloji (Onuncu Edisyon)*. YÜCE yayımları a.ş. & Nobel Tıp, 2001.
46. Penfield, W. ve Rasmussen, T., *The cerebral cortex of man; a clinical study of localization of function*. Macmillan, 1950.
47. [https://commons.wikimedia.org/wiki/File:1421\\_Sensory\\_Homunculus.jpg](https://commons.wikimedia.org/wiki/File:1421_Sensory_Homunculus.jpg). 24 Nisan 2021.
48. Qin, L., Ding, L. ve He, B., Motor imagery classification by means of source analysis for brain-computer interface applications. *Journal of Neural Engineering*, 3, 1 (2004) 135-141.
49. Qin, L., Ding, L. & He, B., Motor Imagery Classification by Means of Source Analysis for Brain Computer Interface Applications. *Journal of Neural Engineering*, 4, 2 (2005) 65-72.
50. Wentrup, M. G., Gramann, K., Wascher, E. ve Buss, M., EEG Source Localization for Brain-Computer-Interfaces. 2nd International IEEE EMBS Conference on Neural Engineering, Washington D.C., 2005.
51. Kamousi, B., Liu, Z. ve He, B., Classification of motor imagery tasks for brain-computer interface applications by means of two equivalent dipoles analysis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 13, 2 (2005) 166-171.
52. Kamousi, B., Amini, A. N. ve He, B., Classification of motor imagery by means of cortical current density estimation and Von Neumann entropy. *Journal of Neural Engineering*, 4, 2 (2007) 17-25.
53. Yuan, H., Doud, A., Gururajan, A. ve He, B., Cortical Imaging of Event-Related (de)Synchronization During Online Control of Brain-Computer Interface Using Minimum-Norm Estimates in Frequency Domain. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 16, 5 (2008) 425-431.
54. Lotte, F., Lecuyer, A. ve Arnaldi, B., FuRIA: An Inverse Solution Based Feature Extraction Algorithm Using Fuzzy Set Theory for Brain-Computer Interfaces. *IEEE Transactions on Signal Processing*, 57, 8 (2009) 3253-3263.

55. Hwang, H.-J., Kwon, K. ve Im, C.-H., Neurofeedback-based motor imagery training for brain-computer interface (BCI). Journal of Neuroscience Methods, 179, 1 (2009) 150-156.
56. Arvaneh, M., Guan, C., Ang, K. K. ve Quek, H. C., EEG Channel Selection Using Decision Tree in Brain-Computer Interface. Proceedings of the Second APSIPA Annual Summit and Conference, Biopolis, 2010.
57. Handiru, V. S., Vinod, A. ve Guan, C., Cortical Source Localization for Analysing Single-Trial Motor Imagery EEG. 2015 IEEE International Conference on Systems, Man, and Cybernetics, Hong Kong, 2015.
58. Abdulkader, S. N., Atia, A. ve Mostafa, M.-S. M., Brain computer interfacing: Applications and challenges. Egyptian Informatics Journal, 16, 2 (2015) 213-230.
59. Handiru, V. S., Vinod, A. P. ve Guan, C., Multi-direction hand movement classification using EEG-based source space analysis. 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Orlando, FL, 2016.
60. Li, M., Zhang, C., Jia, S. ve Sun, Y., Classification of Motor Imagery Tasks in Source Domain. 2018 IEEE International Conference on Mechatronics and Automation (ICMA), Changchun, 2018.
61. Shi, B., Wang, Q., Yin, S., Yue, Z., Huai, Y. ve Wang J., A binary harmony search algorithm as channel selection method for motor imagery-based BCI. Neurocomputing, 443 (2021) 12-25.
62. Meng, X., Qiu, S., Wan, S., Cheng, K. ve Cui, L., A motor imagery EEG signal classification algorithm based on recurrence plot convolution neural network. Pattern Recognition Letters, 146 (2021) 134-141.
63. Singh, A., Hussain, A. A., Lal, S. ve Guesgen, H. W., A Comprehensive Review on Critical Issues and Possible Solutions of Motor Imagery Based Electroencephalography Brain-Computer Interface. Sensors, 21, 6 (2021) 1-35.
64. Zhang, H., Zhao, X., Wu, Z., Sun, B. ve Li, T., Motor imagery recognition with automatic EEG channel selection and deep learning. Journal of Neural Engineering, 18, 1 (2021) 1-12.
65. Saxena, M., Sareen, E. ve Gupta, A., Understanding Functional Brain Activation using Source Localization of EEG Signals in Motor Imagery Tasks. 2020 International Conference on COMMunication Systems & NETWORKS (COMSNETS), Bengaluru, 2020.

66. Hou, Y., Zhou, L., Jia, S. ve Lun, X., A novel approach of decoding EEG four-class motor imagery tasks via scout ESI and CNN. Journal of Neural Engineering, 17, 1 (2020) 1-15.
67. Frolov, A. A., Husek, D., Bobrov, P. D., Mokienko, O. A., Chernikova, L. A. ve Konovalov, R. N., Localization of brain electrical activity sources and hemodynamic activity foci during motor imagery. Human Physiology, 40 (2014) 273-283.
68. Edelman, B. J., Baxter, B. ve He, B., EEG Source Imaging Enhances the Decoding of Complex Right-Hand Motor Imagery Tasks. IEEE Transactions on Biomedical Engineering, 63, 1 (2016) 4-14.
69. [www.tandfonline.com/loi/tbci20](http://www.tandfonline.com/loi/tbci20). 20 Eylül 2020
70. Huggins, J. E., Guger, C., Ziat, M., Zander, T. O., Taylor, D., Tangermann, M., Soria-Frisch, A., Simeral, J., Scherer, R., Rupp, R., Ruffini, G., Robinson, D., Ramsey, N. F., Nijholt, A., Müller-Putz, G., McFarland, D. J., Mattia, D. ve Lance B. J., Workshops of the Sixth International Brain-Computer Interface Meeting: brain-computer interfaces past, present, and future. Brain Computer Interfaces (Abingdon), 4, ((1-2)) (2017) 3-36.
71. <https://bcisociety.org/>. 20 Eylül 2020.
72. Gao, S., Wang, Y., Gao, X. ve Hong, B., Visual and auditory brain-computer interfaces. IEEE Transactions on Biomedical Engineering, 61, 5 (2014) 1436-1447.
73. Ang, K. K. ve Guan, C., Brain-Computer Interface for Neurorehabilitation of Upper Limb After Stroke. Proceedings of the IEEE, 103, 6 (2015) 944-953.
74. Lécuyer, A., Lotte, F., Reilly, R. B., Leeb, R., Hirose M. ve Slater, M., Brain-Computer Interfaces, Virtual Reality, and Videogames. Computer, 41, 10 (2008) 66-72.
75. Nijholt, A., Bos, D. P.-O. ve Reuderink, B., Turning shortcomings into challenges: Brain-computer interfaces for games. Entertainment Computing, 1, 2 (2009) 85-94.
76. Lotte, F., Nam, C. S. ve Nijholt, A., Introduction: Evolution of Brain-Computer Interfaces. Brain-Computer Interfaces Handbook Technological and Theoretical Advances. Boca Raton, CRC Press, 1-8, 2018.
77. Handiru, V. S., Vinod, A. P. ve Guan, C., EEG source space analysis of the supervised factor analytic approach for the classification of multi-directional arm movement. Journal of Neural Engineering, 14, 4 (2017) 046008.

78. Yazıcı, M., Ulutaş, M. ve Okuyan, M., A Comprehensive sLORETA Study on the Contribution of Cortical Somatomotor Regions to Motor Imagery. Brain Sciences, 12, 9 (2019) 1-14.
79. Li, M.-A., Wang, Y.-F., Jia, S.-M., Sun, Y.-J. ve Yang, J.-F., Decoding of motor imagery EEG based on brain source estimation. Neurocomputing, 339 (2019) 182-193.
80. Sneider, R. ve Trampert, J., Inverse Problems in Geophysics. International Centre for Mechanical Sciences (Courses and Lectures), vol 398. Springer, Vienna, 1999.
81. Kamel, N. ve Malik, A. S., EEG/ERP Analysis, Methods and Analysis, CRC Press, 2015
82. Tudor, M., Tudor, L. ve Tudor, K. I., Hans Berger (1873-1941)--the history of electroencephalography. cta medica Croatica : casopis Hravatske akademije medicinskih znanosti, 59, 4 (2005) 307-313.
83. Yamada, T., The objective and perspective of recording electrical activity form the central nervous system. Rinshō Shinkeigaku, 35 (1995) 1323–1331.
84. Zhukov, L., Weinstein, D. ve Johnson, C., Independent component analysis for EEG source localization. IEEE Engineering in Medicine and Biology Magazine, 19 (2000) 87-96.
85. Wendel, K., Väisänen, O., Malmivuo, J., Gencer, N. G., Vanrumste, B., Durka, P., Magjarević, R., Supek, S., Pascu, M. L., Fontenelle H. ve Menendez, R. G. d. P., EEG/MEG source imaging: methods, challenges, and open issues. Computational Intelligence and Neuroscience, Hindawi, 2009 (2009) 1-12.
86. Stahlhut, C., 2008. EEG Source Localization using a Hierarchical Bayesian Approach, MSc Thesis, Technical University of Denmark Informatics and Mathematical Modelling, Lyngby.
87. Tek, M. N. ve Gencer, N. G., A new 3D FEM formulation for the solution of potential fields in magnetic induction problems. Proceedings of the 19th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 'Magnificent Milestones and Emerging Opportunities in Medical Engineering', Chicago, IL, 1997.
88. <https://neuroimage.usc.edu/brainstorm/Tutorials/TutBem>. 26 Haziran 2020.
89. Hämäläinen, M. S. ve Ilmoniemi, R. J., Interpreting magnetic fields of the brain: minimum norm estimates. Medical & Biological Engineering & Computing, 32, 1 (1994) 35-42.



90. Dale, A. M., Liu, A. K., Fischl, B. R., Buckner, R. L., Belliveau, J. W., Lewine, J. D. ve Halgren, E., Dynamic statistical parametric mapping: combining fMRI and MEG for high-resolution imaging of cortical activity, Neuron, 26, 1 (2000) 55-67.
91. [http://www.scholarpedia.org/article/Source\\_localization](http://www.scholarpedia.org/article/Source_localization). 14 Eylül 2020.
92. Cuffin, B. N., EEG Dipole Source Localization. IEEE Engineering in Medicine and Biology Magazine, 17, 5 (1998) 118-122.
93. Bai, X. ve He, B., On the Estimation of the Number of Dipole Sources in EEG Source Localization. Clinical Neurophysiology, 116, 9 (2005) 2037-2043.
94. Tadel, F., Baillet, S., Mosher, J. C., Pantazis D. ve Leahy R. M., Brainstorm: a user-friendly application for MEG/EEG analysis. Computational Intelligence and Neuroscience, Hindawi, 2011 (2011) 1-13.
95. [https://www.fieldtriptoolbox.org/tutorial/headmodel\\_meg/](https://www.fieldtriptoolbox.org/tutorial/headmodel_meg/). 1 Ekim 2020.
96. Sekino, M., Inoue, Y. ve Ueno, S., Magnetic Resonance Imaging of Electrical Conductivity in the Human Brain. IEEE Transactions on Magnetics, 41, 10 (2005) 4203-4205.
97. Rush, S. ve Driscoll, D. A. M. E. E., Current Distribution in the Brain From Surface Electrodes. Anesthesia & Analgesia, 47, 6 (1968) 717-723.
98. Bashar, R., Li, Y. ve Wen, P., EEG Analysis on Skull Conductivity Perturbations Using Realistic Head Model. Rough Sets and Knowledge Technology. Springer Berlin Heidelberg, 208-215, 2009.
99. Wang, G. ve Ren, D., Effect of Brain-to-Skull Conductivity Ratio on EEG Source Localization Accuracy. BioMed Research International, 2013 (2013) 1-10.
100. Bigdely-Shamlo, N., Mullen, T., Kothe C., Su, K.-M. ve Robbins K. A., The PREP pipeline: standardized preprocessing for large-scale EEG analysis. Frontiers in Neuroinformatics, 9 (2015) 1-16.
101. Visalakshi, S. ve Radha, V., A literature review of feature selection techniques and applications: Review of feature selection in data mining. 2014 IEEE International Conference on Computational Intelligence and Computing Research, Coimbatore, 2014.
102. C. Brunner, Leeb, R., Müller Putz, Schlögl A. ve Pfurtscheller, G., BCI Competition 2008 – Graz data set A, 2008. [http://www.bbci.de/competition/iv/desc\\_2a.pdf](http://www.bbci.de/competition/iv/desc_2a.pdf) 17 Şubat 2021.

103. Blankertz, B., Müller, K. R., Krusienski, D. J., Schalk, G., Wolpaw, J. R., Schlögl, A., Pfurtscheller, G., Millán Jdel, R., Schröder, M. ve Birbaumer, N., The BCI competition III: Validating alternative approaches to actual BCI problems. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 14, 2 (2006) 153-159.
104. Yazici, M. ve Ulutaş, M., Effect of noise and number of sensors on EEG source localization in dipole fitting method. 25th Signal Processing and Communications Applications Conference (SIU), Antalya, 2017.
105. Hu, L. ve Zhang, Z., EEG Signal Processing and Feature Extraction. Springer, 2019.
106. Picton T. W., Bentin S., Berg P., Donchin E., Hillyard S. A., Johnson R. Jr., Miller G. A., Ritter W., Ruchkin D. S., Rugg M. D. ve Taylor M. J., Guidelines for using human event-related potentials to study cognition: recording standards and publication criteria. Psychophysiology. 37, 2 (2000) 127-152.
107. Srinivasan, R., Tucker, D. M. ve Murias, M., 1998. Estimating the spatial Nyquist of the human EEG. Behavior Research Methods, Instruments, & Computers, 30 (1998) 8-19.
108. Luck, S. J., An Introduction to the Event-Related Potential Technique, The MIT Press, 2014.
109. Teplan, M., Fundamentals of EEG Measurement. IEEE Measurement Science Review, 2 (2002) 1-11.
110. Sohrabpour, A., Lu, Y., Kankirawatana, P., Blount, J., Kim, H. ve He, B., Effect of EEG electrode number on epileptic source localization in pediatric patients. Clinical Neurophysiology, 126, 3 (2015) 472-480.
111. Lantz, G., Grave de Peralta, R., Spinelli, L., Seeck, M. ve Michel C. M., Epileptic source localization with high density EEG: how many electrodes are needed?. Clinical Neurophysiology, 114, 1 (2003) 63-69.
112. Lascano, A. M., Perneger, T., Vulliemoz, S., Spinelli, L., Garibotto, V., Korff, C. M., Vargas, M. I., Michel, C. M. ve Seeck, M., Yield of MRI, high-density electric source imaging (HD-ESI), SPECT and PET in epilepsy surgery candidates. Clinical Neurophysiology, 127, 1 (2016) 150-155.
113. Brodbeck, V., Spinelli, L., Lascano, A. M., Wissmeier, M., Vargas, M. I., Vulliemoz, S., Pollo, C., Schaller, K., Michel, C. M. ve Seeck, M., Electroencephalographic source imaging: a prospective study of 152 operated epileptic patients. Brain, 134, 10 (2011) 2887-2897.
114. Acharya, V. J. ve Acharya, J. N., Localization with high-density EEG: Complexity of analysis versus accuracy. Clinical Neurophysiology Practice, 5 (2020) 10-11.

115. Michel, C. M., Murray, M. M., Lantz, G., Gonzalez, S., Spinelli, L. ve Grave de Peralta, R., EEG Source Imaging. Clinical Neurophysiology, 115, 10 (2004) 2195-2222.
116. Di Flumeri, G., Aricò, P., Borghini, G., Sciaraffa, N., Di Florio, A. ve Babiloni, F., The Dry Revolution: Evaluation of Three Different EEG Dry Electrode Types in Terms of Signal Spectral Features, Mental States Classification and Usability. Sensors, 19, 6:1365 (2019) 1-21.
117. Ergün, E. ve Aydemir, Ö., Improving Classification Accuracy of Motor Imagery EEG Signals via Effective Epochs. Pamukkale University Journal of Engineering Sciences, 24, 5 (2018) 817-823.
118. Kalantar, G., Mirgholami, M., Asif, A. ve Mohammadi, A., Improving the Performance of Motor Imagery EEG-Based BCIs Via an Adaptive Epoch Trimming Mechanism. 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP), Anaheim, CA, 2018.
119. Yan, M. M., Xu, X. H., Huang, Z. L., Yao, M. H. ve Qu, W. M., Selection of optimal epoch duration in assessment of rodent sleep-wake profiles. Sleep and Biological Rhythms, 9 (2011) 46–55.
120. Fonov, V. S., Evans, A. C., McKinstry, R. C., Almlı, C. R. ve Collins D. L., Unbiased nonlinear average age-appropriate brain templates from birth to adulthood. NeuroImage, 47, 1 (2009) 102.
121. Acar, Z. A. ve Makeig, S., Effects of Forward Model Errors on EEG Source Localization. Brain Topography, 26 (2013) 378-396.
122. Vatta, F., Meneghini, F., Esposito, F., Mininel, S. ve Di Salle, F., Realistic and Spherical Head Modeling for EEG Forward Problem Solution: A Comparative Cortex-Based Analysis. Computational Intelligence and Neuroscience, 2010 (2010) 1-11.
123. Şengül, G., 2008. Fotogrametrik Elektrot Konumlama Yöntemi ve İstatistiksel Önbilgili Parametre Kestirimi ile Kaynak Yerelleştirimi Yapan EEG Sistemi Geliştirilmesi, Elektrik ve Elektronik Mühendisliği Anabilim Dalı Doktora Tezi, Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
124. Haueisen, J., Tuch, D.S., Ramon, C., Schimpf, P.H., Wedeen, V.J., George, J.S. ve Belliveau, J.W., The Influence of Brain Tissue Anisotropy on Human EEG and MEG. NeuroImage, 15, 1 (2002) 159-166.
125. Ueno, S. ve Iriguchi, N., Impedance magnetic resonance imaging: A method for imaging of impedance distributions based on magnetic resonance imaging. Journal of Applied Physics, 83 (1998) 6450-6452.

126. Ferree, T. C., Eriksen, K. J. ve Tucker, D. M., Regional head tissue conductivity estimation for improved EEG analysis. IEEE Transactions on Biomedical Engineering, 47, 12 (2000) 1584-1592.
127. Gonçalves, S., de Munck, J. C., Heethaar, R. M., Lopes da Silva, F. H. ve van Dijk, B. W., The application of electrical impedance tomography to reduce systematic errors in the EEG inverse problem - a simulation study. Physiological Measurement, 21, 3 (2000) 379-393.
128. Lee, K.-Y. ve Kim, S., Designing discriminative spatial filter vectors in motor imagery brain-computer interface. International Journal of Imaging Systems and Technology, 23 (2013) 147-151.
129. Grosse-Wentrup, M. ve Buss, M., Multiclass Common Spatial Patterns and Information Theoretic Feature Extraction, IEEE Transactions on Biomedical Engineering, 55,8 (2008) 1991-2000.
130. Aydemir, Ö., Common Spatial Pattern-Based Feature Extraction From the Best Time Segment of BCI Data. Turkish Journal of Electrical Engineering and Computer Science, 24, 5 (2016) 3976-3986.
131. Duman, M. E., 2016. Sınıf İçi ve Sınıflar Arası Saçılmaya Duyarlı Ortak Uzamsal Örüntüler İle Motor Hareket Hayalinin Tanınması. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
132. Ramoser, H., Muller-Gerking, J. ve Pfurtscheller, G., Optimal Spatial Filtering of Single Trial EEG During Imagined Hand Movement. IEEE Transactions on Rehabilitation Engineering, 8, 4 (2000) 441-446.
133. Xygonakis, I., Athanasiou, A., Pandria, N., Kugiumtzis, D. ve Bamidis, P. D., Decoding Motor Imagery through Common Spatial Pattern Filters at the EEG Source Space. Computational Intelligence and Neuroscience, 2018 (2018) 1-10.
134. Grech, R., Cassar, T., Muscat, J., Camilleri, K. P., Fabri, S. G., Zervakis, M., Xanthopoulos, P., Sakkalis V. ve Vanrumste B., Review on solving the inverse problem in EEG source analysis. Journal of NeuroEngineering and Rehabilitation, 5 (2008) 1-33.
135. Morita, T., Asada, M. ve Naito, E., Contribution of Neuroimaging Studies to Understanding Development of Human Cognitive Brain Functions. Frontiers in Human Neuroscience, 10 (2016) 1-14.
136. Boser, B. E., Guyon, I. M. ve Vapnik, V. N., A Training Algorithm for Optimal Margin Classifiers. Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory, Pittsburgh Pennsylvania, 1992.

137. Keshet, J. ve Bengio, S., Automatic Speech and Speaker Recognition. Wiley, 2009.
138. [https://commons.wikimedia.org/wiki/File:SVM\\_margin.png](https://commons.wikimedia.org/wiki/File:SVM_margin.png). 1 Temmuz 2021.
139. Cortes, C. ve Vapnik, V., Support-Vector Networks. Machine Learning, 20 (1995) 273-297.
140. Imran, M. ve Alsuhaibani, S. A., A Neuro-Fuzzy Inference Model for Diabetic Retinopathy Classification. Intelligent Data Analysis for Biomedical Applications. Academic Press, 147-172, 2019.
141. Bangal, B. C., Automatic Generation Control of Interconnected Power Systems Using Artificial Neural Network Techniques, Bharath University, Department of Electrical Engineering, 2009.
142. Suparta, W. ve Alhasa, K. M., Modeling of Tropospheric Delays Using ANFIS, Springer, 2016.
143. McCulloch, W. S. ve Pitts, W., A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics, 5, 4 (1943) 115-133.
144. Yu, F. T., Yu, E. H. ve Yu, A. G., The Art of Learning Neural Networks and Education. Boca Raton, FL, CRC Press, 2019.
145. Vasilev, I., Slater, D., Spacagna, G., Roelants, P. ve Zocave V., Python Deep Learning: Exploring deep learning techniques and neural network architectures with PyTorch, Keras, and TensorFlow. Birmingham: Packt Publishing, 2019.
146. Zhang, G., Neural Networks For Data Mining. Boston: Springer, 2008.
147. Aggarwal, C. C., Linear Algebra and Optimization for Machine Learning. Springer International Publishing, 2020.
148. Duda, R. O., Hart, P. E. ve Stork, D. G., Pattern Classification, 2nd Edition. Wiley, 2000.
149. <https://www.folio3.ai/blog/advantages-of-neural-networks/>. 24 Eylül 2020.
150. <https://www.mathworks.com/help/stats/fitcsvm.html>. 17 Haziran 2021.
151. <https://alexlenail.me/NN-SVG/index.html>. 18 Temmuz 2021.
152. Lotte, F., Regularizing Common Spatial Patterns to Improve BCI Designs: Unified Theory and New Algorithms. IEEE Transactions on Biomedical Engineering, 58, 2 (2011) 355-362.

## ÖZGEÇMİŞ

İlköğrenimini Trabzon İskenderpaşa İlköğretim Okulunda ve ortaöğrenimini Trabzon Kanuni Anadolu Lisesinde tamamladı. 2005 yılında başladığı Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünden 2009 yılında Bilgisayar Mühendisi unvanı ile mezun oldu. 2009 yılı güz döneminde Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. Aynı yıl, Bilgisayar Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. 2012 yılında yüksek lisanstan mezun olarak Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. Hâlen Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümünde Araştırma Görevlisi olarak çalışmaya devam etmektedir. Yabancı dil olarak İngilizce bilmektedir.