

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BEYİNDE ÜRETİLEN YÖNE BAĞLI EEG
SİNYALLERİNİN ÖZNİTELİK ÇIKARIMI
YARDIMIYLA SINIFLANDIRILMASI**

DOKTORA TEZİ

Muhammet Serdar BAŞÇIL

**Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ**
Enstitü Bilim Dalı : ELEKTRONİK
Tez Danışmanı : Yrd. Doç. Dr. Ahmet Yahya TEŞNELİ

Haziran 2015

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BEYİNDE ÜRETİLEN YÖNE BAĞLI EEG
SİNYALLERİNİN ÖZİNİTELİK ÇIKARIMI
YARDIMIYLA SINIFLANDIRILMASI


DOKTORA TEZİ


Muhammet Serdar BAŞÇIL

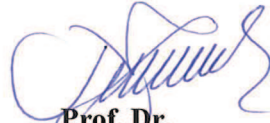
Enstitü Anabilim Dalı : ELEKTRİK-ELEKTRONİK
MÜHENDİSLİĞİ

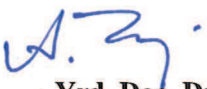
Enstitü Bilim Dalı : ELEKTRONİK


Bu tez 26/06/2015 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.


Prof. Dr.
Etem KÖKLÜKAYA
Jüri Başkanı


Prof. Dr.
Feyzullah TEMURTAŞ
Üye


Prof. Dr.
Nejat YUMUŞAK
Üye


Yrd. Doç. Dr.
Ahmet Yahya TEŞNELİ
Üye


Yrd. Doç. Dr.
Onursal ÇETİN
Üye

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Muhammet Serdar BAŞÇIL

26.06.2015

ÖNSÖZ

Son dönemlerde hem medyada hem de yazılı basın organlarında sıkça yer bulan beyinde oluşan yöne bağlı EEG sinyalleri ile gerçekleştirilen kontrol uygulamaları gün geçtikçe gelişmekte ve daha da önem kazanmaktadır. Bu uygulamalar sayesinde, insan beyninin elektriksel aktivitesi kaydedilmekte ve bu aktivite makine kontrol kodlarına dönüştürülebilmektedir. Bu sayede, motor sinir sistemi ve iskelet sistemi kullanılmaksızın yani her hangi bir istemli kas hareketi gerekmeksizin bir bilgisayar, elektromekanik bir kol veya çeşitli cihazların kullanımı olanaklı hale getirilebilmektedir. Hedef kitlesinde engelli insanlar bulunan bu sistemler, engelli kişiler için yeni bir haberleşme yöntemi sunar ve onların yaşamlarını daha kolay hale getirir. Bu tür sistemlerin genelleştirilmiş adı Beyin Bilgisayar Arayüzü (BBA) dır.

İÇİNDEKİLER

ÖNSÖZ	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	vi
ŞEKİLLER LİSTESİ	viii
TABLolar LİSTESİ	xiii
ÖZET.....	xiv
SUMMARY	xv

BÖLÜM 1.

GİRİŞ	1
1.1. Beyinde Üretilen Yöne Bağlı EEG Sinyallerinden Öznitelik Çıkarımı ve Sınıflandırma Üzerine Yapılan Çalışmalar	3

BÖLÜM 2.

BEYİNDE MEYDANA GELEN EEG SİNYALLERİNİN TEMELLERİ.....	13
2.1. Beynin Temel Yapısı ve Bölümleri	15
2.2. EEG Elektrotları ve EEG Kepleri.....	18
2.2.1. Dahili elektrotlar	18
2.2.2. Yüzey elektrotlar	19
2.2.2.1. Metal disk elektrotlar	20
2.2.2.2. Kulak elektrotu (Klips elektrot)	20
2.3. Elektrot Jelleri.....	21
2.4. EEG Kepleri.....	22
2.5. EEG Elektrot Yerleşim Sistemi.....	23
2.5.1. 10/20 Sisteminde elektrotların yerleşimi	23
2.5.2. Genişletilmiş 10/20 sisteminde elektrot yerleşimleri	25
2.5.3. Referans ve toprak elektrotlarının yerleşimi	26

2.6. EEG Kayıtlarını Bozucu Faktörler (Artifaktlar-Parazitler)	26
2.6.1. Biyolojik artifaktlar	26
2.6.1.1. Göz ve göz kapağının etkisi	26
2.6.1.2. Kardiyak artifaktlar (EKG etkisi)	27
2.6.1.3. Terlemenin etkisi	28
2.6.1.4. Kas kasılmasının etkisi	28
2.6.2. Harekete bağlı artifaktlar	29
2.6.3. Elektrotlara bağlı artifaktlar	29
2.6.4. Şebekeye bağlı artifaktlar	30
2.6.5. Cihazdan kaynaklanan artifaktlar	31
2.7. BBA Sistemlerinde EEG'nin Yeri	31
2.7.1. Sinyal ön işleme	32
2.7.1.1. EEG sinyallerinin kuvvetlendirilmesi	32
2.7.1.2. EEG sinyallerinin filtrelenmesi	33
2.7.1.3. EEG sinyallerinin dijitale dönüştürülmesi	34

BÖLÜM 3.

ÖZELLİK ÇIKARIM YÖNTEMLERİ ve BOYUT İNDİRGEME

ALGORİTMALARI	36
3.1. Ortalama Sinyal Gücü	36
3.2. Varyans ve Standart Sapma	37
3.3. Entropi	38
3.4. Hjorth Parametreleri	39
3.5. Fourier Analizi	40
3.6. Spektral Güç Yoğunluğu	42
3.7. Dalgacık Dönüşümü	43
3.8. Temel Bileşenler Analizi (PCA)	46
3.9. Bağımsız Bileşenler Analizi (ICA)	47

BÖLÜM 4.

MAKİNE ÖĞRENME ALGORİTMALARI	49
4.1. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFIS)	51
4.2. Öğrenmeli Vektör Kuantalama (LVQ)	53

4.3. Çok Katmanlı Yapay Sinir Ağı (MLNN).....	54
4.4. Olasılıksal Yapay Sinir Ağı (PNN).....	56
4.5. Karar Ağacı Algoritması (Decission Tree).....	57
4.6. Lineer Diskriminant Analiz (LDA).....	58
4.7. En Yakın k Komşuluğu Algoritması (kNN).....	60
4.8. Destek Vektör Makineleri (SVM).....	62

BÖLÜM 5.

AMAÇLANAN SİSTEMİN YAPISI.....	65
5.1. Micromed EEG Ölçüm Sistemi.....	65
5.2. Beyinde Yöne Bağlı EEG Sinyallerinin Oluşturulmasında İzlenen Yöntem.....	67
5.3. Yöne Bağlı Olarak Beyinde Ortaya Çıkan EEG Sinyallerindeki Yön Durumlarının Çıkarımı Amacıyla Kurulan Sistemin Yapısı.....	70
5.4. Yöne Bağlı Olarak Beyinde Ortaya Çıkan EEG Kayıtları.....	70

BÖLÜM 6.

YÖNE BAĞLI OLARAK BEYİNDE ORTAYA ÇIKAN EEG KAYITLARINDAN ÖZELLİK ÇIKARMA VE BOYUT İNDİRGEME.....	75
6.1. Ortalama Sinyal Gücü Özelliği Kullanılarak Yapılan Özellik Çıkarma.....	75
6.1.1. En başarılı katılımcı için elde edilen özellikler.....	76
6.1.2. En başarısız katılımcı için elde edilen özellikler.....	79
6.2. Entropi Özelliği Kullanılarak Yapılan Özellik Çıkarma.....	82
6.2.1. En başarılı katılımcı için elde edilen özellikler.....	82
6.2.2. En başarısız katılımcı için elde edilen özellikler.....	84
6.3. Hjorth Parametreleri Kullanılarak Yapılan Özellik Çıkarma.....	86
6.3.1. En başarılı katılımcı için elde edilen özellikler.....	87
6.3.2. En başarısız katılımcı için elde edilen özellikler.....	91
6.4. Fourier Analizi Kullanılarak Yapılan Özellik Çıkarma.....	95
6.4.1. En başarılı katılımcı için elde edilen özellikler.....	96
6.4.2. En başarısız katılımcı için elde edilen özellikler.....	100
6.5. Spektral Güç Yoğunluğu Kullanılarak Yapılan Özellik Çıkarma.....	104
6.5.1. En başarılı katılımcı için elde edilen özellikler.....	106

6.5.2. En başarısız katılımcı için elde edilen özellikler	108
6.6. DWT Dönüşümü Kullanılarak Yapılan Özellik Çıkarma	109
6.6.1. En başarılı katılımcı için elde edilen özellikler	110
6.6.2. En başarısız katılımcı için elde edilen özellikler	111
BÖLÜM 7.	
SONUÇLAR	113
7.1. 10 Katılımcıya Ait Makine Öğrenme Algoritması Doğrulukları	113
7.1.1. Ortalama sinyal gücü veya varyans özelliği için elde edilen sınıflandırma doğrulukları.....	113
7.1.2. Entropi özelliği için elde edilen sınıflandırma doğrulukları.....	115
7.1.3. Hjorth özellikleri için elde edilen sınıflandırma doğrulukları ...	116
7.1.4. Fourier özellikleri için elde edilen sınıflandırma doğrulukları..	118
7.1.5. Spektral Güç Yoğunluğu özellikleri için elde edilen sınıflandırma doğrulukları	119
7.1.6. Dalgacık özellikleri için elde edilen sınıflandırma doğrulukları	120
7.2. Tüm Katılımcılara Ait Sınıflandırma Doğruluklarının Ortalaması	122
7.3. Tüm Katılımcı Verileri için Makine Öğrenme Algoritması Doğrulukları	123
BÖLÜM 8.	
TARTIŞMA ve ÖNERİLER.....	125
KAYNAKLAR.....	130
ÖZGEÇMİŞ	141

SİMGELER VE KISALTMALAR LİSTESİ

ADC	: Analog dijital dönüştürücü
AID	: Otomatik etkileşim algılayıcı
ALN	: Adaptif mantık ağı
ANFIS	: Adaptif ağ tabanlı bulanık mantık çıkarım sistemi
ALS	: Amyotrofik lateral skleroz
AR	: Otoregresif
ASCII	: Amerikan standart kodlama sistemi
BBA	: Beyin bilgisayar arayüzü
BP	: Geri yayılım
CAR	: Laplas referans filtresi
CSP	: Ortak mekansal örüntü
dB	: Desibel
DSP	: Dijital sinyal işlem
DWT	: Ayrık dalgacık dönüşümü
EEG	: Elektroensefalogram
edf	: Avrupa data formatı
EMG	: Elektromiyogram
EOG	: Elektrookülogram
FT	: Fourier dönüşümü
FFT	: Hızlı fourier dönüşümü
Hz	: Hertz
ICA	: Bağımsız bileşenler analizi
ID3	: Tekrarlı ikilikçi ağacı
kNN	: En yakın k komşuluğu
KPLS	: Kernel tabanlı en küçük kareler yöntemi
LDA	: Lineer diskriminat analiz

LM	: Levenberg Marquardt algortiması
LMS	: En küçük kareler yöntemi
LVQ	: Öğrenmeli vektör kuantalama
LS-SVM	: En küçük karalar ile destek vektör makinesi
MLNN	: Çok katmanlı yapay sinir ağı
ms	: Mili saniye
MSE	: Ortalama karesel hata
mV	: Mili volt
OvsO	: Bire karşı bir yaklaşımı
OvsA	: Bire karşı tüm yaklaşımı
PC	: Taşınabilir bilgisayar
PCA	: Temel bileşenler analizi
PNN	: Olasılıksal yapay sinir ağı
PSD	: Spektral güç yoğunluğu
P300	: Uyarandan 300 mili saniye sonra ortaya çıkan beyin sinyali
s	: Saniye
STFT	: Kısa zamanlı fourier dönüşümü
SVM	: Destek vektör makinesi
WT	: Dalgacık dönüşümü
1-D	: Bir boyutlu
2-D	: İki boyutlu
μV	: Mikro volt
Ω	: Ohm

ŞEKİLLER LİSTESİ

Şekil 2.1. Delta dalgaları	13
Şekil 2.2. Teta dalgaları	14
Şekil 2.3. Alfa dalgaları	14
Şekil 2.4. Beta dalgaları	14
Şekil 2.5. Gama Dalgaları	15
Şekil 2.6. Beynin sağ ve sol yarı kürelerinin görevleri	16
Şekil 2.7. Beynin farklı kısımları (Loblar)	17
Şekil 2.8.a. Bir dahili elektrot, b. İstilacı yöntemde dahili elektrot yerleşimi	19
Şekil 2.9. Kablosuz verici düzenine sahip dahili elektrot	19
Şekil 2.10. Metal disk elektrotlar	20
Şekil 2.11. Kulak elektrotu (Klips Elektrot)	21
Şekil 2.12. EEG elektrotlarının jellenmesi	21
Şekil 2.13. Çeşitli boyutlardaki EEG başlıkları	22
Şekil 2.14. Çeşitli elektrot yuvalarına sahip EEG başlıkları	22
Şekil 2.15. 10/20 sistemine göre elektrot yerleşimi	24
Şekil 2.16. Genişletilmiş 10/20 sistemine göre elektrot konumları	25
Şekil 2.17. Göz ve göz kapağının etkisi ile oluşan artifaktlar	27
Şekil 2.18. Kardiyak artifaktlar	27
Şekil 2.19. Düşük ve yüksek genlikli pulsasyon artifaktları	28
Şekil 2.20. Terlemeye bağlı oluşan artifakt	28
Şekil 2.21. Çeşitli kas kasılmalarına bağlı oluşan artifaktlar	29
Şekil 2.22. Hareketlerine göre değişik artifaktlar	29
Şekil 2.23. Çeşitli elektrot artifaktları	30
Şekil 2.24. Şebekeye bağlı artifaktlar	30
Şekil 2.25. BBA sistemlerinin genelleştirilmiş gösterimi	31
Şekil 2.26. EEG sinyali önışleme süreci	32
Şekil 2.27. Yüksek geçiren filtre karakteristiği	33

Şekil 2.28. Alçak geçiren filtre karakteristiği	33
Şekil 2.29. Çentik filtre karakteristiği	34
Şekil 2.30. Analog sinyallerin dijital olarak gösterimi	34
Şekil 3.1. Fourier dönüşümü	40
Şekil 3.2. Kısa zamanlı fourier dönüşümü	41
Şekil 3.3. Dalgacık dönüşümü	44
Şekil 3.4. Daubechies (db10) dalgacığı.....	44
Şekil 3.5. DWT ile sinyalin alt parçacıklara ayrıştırılması (3 alt seviye)	45
Şekil 3.6. DWT ile 3. seviye ayrıştırılmış frekans bantları.....	46
Şekil 4.1. k katmanlı çapraz doğrulama yapısı	50
Şekil 4.2. Tasarlanan ANFIS yapısının blok diyagramı	51
Şekil 4.3. Sugeno bulanık çıkarımı temeline dayalı ANFIS yapısı.....	52
Şekil 4.4. EEG örüntülerinin tanınması için oluşturulan LVQ yapısı.....	53
Şekil 4.5. EEG örüntülerinin tanınması için oluşturulan MLNN yapısı	54
Şekil 4.6. Saklı katman sayısı ve nöron oranlarının MSE üzerine etkisi	55
Şekil 4.7. EEG örüntülerinin tanınması için oluşturulan PNN yapısı.....	56
Şekil 4.8. Örnek bir karar ağacı yapılanması	57
Şekil 4.9. İki sınıflı problemler için LDA karar bölgesi gösterimi	59
Şekil 4.10. İkidenden çok sınıflı problemler için LDA karar bölgesi gösterimi.....	60
Şekil 4.11. Üç sınıflı kNN örneği (k=5).....	61
Şekil 4.12. İdeal hiperdüzlem oluşturan lineer SVM yapısı	62
Şekil 5.1. Çalışmada kullanılan taşınabilir EEG ölçüm sistemi.....	65
Şekil 5.2. Micromed SMR32RFO sisteminin bilgisayar arayüzü.....	66
Şekil 5.3. Micromed SMR32RFO sistemi deri direnci ölçüm arayüzü	67
Şekil 5.4. EEG verileri kaydedilirken izlenen yol.....	68
Şekil 5.5. EEG verilerinin kaydedilme protokolü	69
Şekil 5.6. Amaçlanan BBA sistemi akışı	70
Şekil 5.7. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SAĞ yön).....	71
Şekil 5.8. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SOL yön).....	71
Şekil 5.9. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (YUKARI yön).....	72

Şekil 5.10. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (AŞAĞI yön).....	72
Şekil 5.11. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SAĞ yön).....	73
Şekil 5.12. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SOL yön).....	73
Şekil 5.13. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (YUKARI yön).....	74
Şekil 5.14. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (AŞAĞI yön).....	74
Şekil 6.1. En başarılı katılımcıya ait ortalama güç yoğunlukları (SAĞ yön).....	76
Şekil 6.2. En başarılı katılımcıya ait ortalama güç yoğunlukları (SOL yön).....	76
Şekil 6.3. En başarılı katılımcıya ait ortalama güç yoğunlukları (YUKARI yön).....	77
Şekil 6.4. En başarılı katılımcıya ait ortalama güç yoğunlukları (AŞAĞI yön).....	77
Şekil 6.5. En başarılı katılımcının ortalama güç özelliklerinin PCA ve ICA uzayındaki ağırlıkları.....	79
Şekil 6.6. En başarılı katılımcıya ait kafatası yoğunlukları.....	79
Şekil 6.7. En başarısız katılımcıya ait ortalama güç yoğunlukları (SAĞ yön).....	80
Şekil 6.8. En başarısız katılımcıya ait ortalama güç yoğunlukları (SOL yön).....	80
Şekil 6.9. En başarısız katılımcıya ait ortalama güç yoğunlukları (YUKARI yön).....	80
Şekil 6.10. En başarısız katılımcıya ait ortalama güç yoğunlukları (AŞAĞI yön).....	81
Şekil 6.11. En başarısız katılımcıya ait kafatası yoğunlukları.....	82
Şekil 6.12. En başarılı katılımcıya ait entropi dağılımları (SAĞ yön).....	83
Şekil 6.13. En başarılı katılımcıya ait entropi dağılımları (SOL yön).....	83
Şekil 6.14. En başarılı katılımcıya ait entropi dağılımları (YUKARI yön).....	83
Şekil 6.15. En başarılı katılımcıya ait entropi dağılımları (AŞAĞI yön).....	84
Şekil 6.16. En başarısız katılımcıya ait entropi dağılımları (SAĞ yön).....	85
Şekil 6.17. En başarısız katılımcıya ait entropi dağılımları (SOL yön).....	85
Şekil 6.18. En başarısız katılımcıya ait entropi dağılımları (YUKARI yön).....	85
Şekil 6.19. En başarısız katılımcıya ait entropi dağılımları (AŞAĞI yön).....	86
Şekil 6.20. En başarılı katılımcıya ait Hjorth değişkenliği (SAĞ yön).....	87
Şekil 6.21. En başarılı katılımcıya ait Hjorth karmaşıklığı (SAĞ yön).....	88
Şekil 6.22. En başarılı katılımcıya ait Hjorth değişkenliği (SOL yön).....	88

Şekil 6.23. En başarılı katılımcıya ait Hjorth karmaşıklığı (SOL yön).....	89
Şekil 6.24. En başarılı katılımcıya ait Hjorth değişkenliği (YUKARI yön)	89
Şekil 6.25. En başarılı katılımcıya ait Hjorth karmaşıklığı (YUKARI yön).....	90
Şekil 6.26. En başarılı katılımcıya ait Hjorth değişkenliği (AŞAĞI yön)	90
Şekil 6.27. En başarılı katılımcıya ait Hjorth karmaşıklığı (AŞAĞI yön)	91
Şekil 6.28. En başarısız katılımcıya ait Hjorth değişkenliği (SAĞ yön)	91
Şekil 6.29. En başarısız katılımcıya ait Hjorth karmaşıklığı (SAĞ yön)	92
Şekil 6.30. En başarısız katılımcıya ait Hjorth değişkenliği (SOL yön).....	92
Şekil 6.31. En başarısız katılımcıya ait Hjorth karmaşıklığı (SOL yön)	93
Şekil 6.32. En başarısız katılımcıya ait Hjorth değişkenliği (YUKARI yön).....	93
Şekil 6.33. En başarısız katılımcıya ait Hjorth karmaşıklığı (YUKARI yön)	94
Şekil 6.34. En başarısız katılımcıya ait Hjorth değişkenliği (AŞAĞI yön)	94
Şekil 6.35. En başarısız katılımcıya ait Hjorth karmaşıklığı (AŞAĞI yön).....	95
Şekil 6.36. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (SAĞ yön 14. kanal)	97
Şekil 6.37. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (SOL yön 16. kanal).....	98
Şekil 6.38. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (YUKARI yön 16. kanal).....	99
Şekil 6.39. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (AŞAĞI yön 16. kanal).....	100
Şekil 6.40. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (SAĞ yön 7. kanal)	101
Şekil 6.41. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (SOL yön 3. kanal).....	102
Şekil 6.42. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (YUKARI yön 3. kanal).....	103
Şekil 6.43. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans- Zaman sonuçları (AŞAĞI yön 4. kanal).....	104
Şekil 6.44. En başarılı katılımcıya ait PSD özelliklerinin PCA ve ICA uzayındaki ağırlıkları ve boyut indirgeme	105
Şekil 6.45. En başarılı katılımcıya ait spektral güç dağılımları (SAĞ yön).....	106
Şekil 6.46. En başarılı katılımcıya ait spektral güç dağılımları (SOL yön)	106

Şekil 6.47. En başarılı katılımcıya ait spektral güç dağılımları (YUKARI yön)	107
Şekil 6.48. En başarılı katılımcıya ait spektral güç dağılımları (AŞAĞI yön).....	107
Şekil 6.49. En başarısız katılımcıya ait spektral güç dağılımları (SAĞ yön)	108
Şekil 6.50. En başarısız katılımcıya ait spektral güç dağılımları (SOL yön)	108
Şekil 6.51. En başarısız katılımcıya ait spektral güç dağılımları (YUKARI yön) ...	109
Şekil 6.52. En başarısız katılımcıya ait spektral güç dağılımları (AŞAĞI yön)	109
Şekil 6.53. En başarılı katılımcıya ait 1. kanal ham EEG sinyali ve bu sinyalden ayrıştırılan alfa-beta çözümleri	111
Şekil 6.54. En başarısız katılımcıya ait 1. kanal ham EEG sinyali ve bu sinyalden ayrıştırılan alfa-beta çözümleri	112

TABLULAR LİSTESİ

Tablo 5.1. Diferansiyel elektrot çiftleri	68
Tablo 7.1. 10 katılımcının ortalama sinyal gücü özellikleri için makine sınıflandırma doğrulukları	114
Tablo 7.2. 10 katılımcının entropi özellikleri için sınıflandırma doğrulukları	115
Tablo 7.3. 10 katılımcının Hjorht değişkenlik özelliği için sınıflandırma doğrulukları	116
Tablo 7.4. 10 katılımcının Hjorht karmaşıklığı özelliği için sınıflandırma doğrulukları	117
Tablo 7.5. 10 katılımcının Fourier özelliği için sınıflandırma doğrulukları	118
Tablo 7.6. 10 katılımcının PSD özelliği için sınıflandırma doğrulukları	119
Tablo 7.7. 10 katılımcının alfa bandı enerjisi için sınıflandırma doğrulukları	120
Tablo 7.8. 10 katılımcının alfa bandı enerjisi için sınıflandırma doğrulukları (Devamı).....	121
Tablo 7.9. 10 katılımcının beta bandı enerjisi için sınıflandırma doğrulukları.....	121
Tablo 7.10. Tüm katılımcıların ortalama sınıflandırma doğrulukları	123
Tablo 7.11. Tüm verilerin sınıflandırma doğrulukları	124

ÖZET

Anahtar kelimeler: Beyin Bilgisayar Arayüzü (BBA), Elektroensefalogram (EEG), Sinyal Özellik Çıkarımı, Sınıflandırıcılar

Son 20 yıl içerisindeki teknolojik gelişmelere paralel olarak değişen ve hızla gelişen biyomedikal alanda, çok büyük yenilikler ortaya çıkmıştır. Bilim ve teknoloji, filmlere konu olmuş ve düşünce gücü ile makinelerin kontrolünün mümkün olabildiği bir seviyeye ulaşmıştır. Beyin Bilgisayar Arayüzü (BBA) denilen uygulamalar sayesinde, insan beyninin elektriksel aktivitesi kaydedilmekte ve bu aktivite makine kontrol kodlarına dönüştürülebilmektedir. Bu uygulamalar sayesinde, motor sinir sistemi ve iskelet sistemi kullanılmaksızın yani her hangi bir istemli kas hareketi gerekmeksizin bir bilgisayar, elektromekanik bir kol veya çeşitli cihazların kullanımı olanaklı hale getirilebilmektedir. BBA ların ortaya çıkmasındaki en temel düşünce, felçli veya Amyotrofik Lateral Skleroz (ALS) hastaları gibi kas hareketi yapamayan hastalara çevresel cihazları kullanabilme ve onların yaşamlarını daha kolay hale getirerek kendi ihtiyaçlarını kolaylaştırabilme imkanı sunmaktır.

Bu tez çalışması ile insan-makine arasında yeni bir iletişim tekniği olan BBA sistemi oluşturulması konu edinmiştir. Bu nedenle, BBA sistemlerin temelini oluşturan Elektroensefalogram (EEG) sinyalleri kafatası yüzeyinden uzman bir sistem yardımı ile kaydedilmiştir. Sinyal içerisindeki elektriksel bilgiyi ortaya çıkarmak için zaman alanında ortalama sinyal gücü, varyans, entropi ve hjorth parametreleri ve frekans alanında fourier ve hızlı fourier analizi, spektral güç yoğunluğu ve dalgacık enerjileri gibi özellik çıkarım yöntemleri kullanılmıştır. Bu özellik boyutlarının indirgenmesi ve temel sinyal bileşenlerinin elde edilmesi adına da temel bileşenler analizi (PCA) ve bağımsız bileşenler analizi (ICA) metotları kullanılmıştır. Sonrasında, özellikleri çıkarılan sinyalleri sınıflandırmak için adaptif ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS), öğrenmeli vektör kuantalama (LVQ), çok katmanlı yapay sinir ağı (MLNN), olasılıksal yapay sinir ağı (PNN), karar ağacı, lineer diskriminat analiz (LDA), en yakın k komşuluğu algoritması (kNN), lineer destek vektör makinesi (SVM) ve en küçük kareler destek vektör makinesi (LS-SVM) gibi algoritmalarından faydalanılmıştır. BBA sistemi oluşturabilmek için beyinde yöne bağlı olarak üretilen EEG sinyalleri kaydedilmiş, zaman ve frekans alanlarındaki sinyal özellikleri çıkarılmış ve bu sinyallerde saklı olan yön bilgileri, sınıflandırma algoritmaları yardımıyla tanınmıştır. Ayrıca tez çalışması, 10 farklı katılımcıdan alınan verilerin, tüm özellik yöntemleri ve tüm sınıflandırma algoritmaları kullanılarak iki boyutlu (2-D) imleç kontrolü üzerine oluşturulan BBA sisteminde çevrimdışı (offline) olarak değerlendirilmiştir. Sonuç olarak tüm yöntemlerin doğrulukları kendi aralarında kıyaslanmış ve amaçlanan BBA sistemi için en uygun yapının %98,61 sınıflandırma doğruluğuna sahip ICA+LS-SVM(OvsO) yapısı olduğu belirlenmiştir.

CLASSIFICATION OF EEG SIGNALS OCCURED IN THE BRAIN UNDER THE IMAGINATION OF THE DIRECTIONS WITH THE HELP OF FEATURE EXTRACTION

SUMMARY

Keywords: Brain Computer Interface (BCI), Electroencephalogram (EEG), Feature Extraction, Pattern Recognition and Classification

Within the last 20 years, great radical innovations have emerged in rapidly developing and growing biomedical science depending on the technological changes. Science and technology has reached a level as possible to control machines with only mind in which main subject of most of the science fiction. Human brain electrical activity is recorded and converted to machine control commands by the applications called Brain Computer Interface (BCI). They make possible to use a computer, an electromechanical lever or various assistive environmental devices without any voluntary movement. The basic idea for the emerge of the BCIs are to make available peripheral devices for people who can not muscle movements such as paralyzed or ALS patients to facilitate their needs and make their lives easier.

In this work, a BCI system which is a new communication way between man and machine has aimed. Therefore, electroencephalogram (EEG) signals which store brain electrical activity and are underlying the BCI systems were recorded by an expert acquisition system from the skull surface. To extract EEG signal features in time domain average signal power, variance, entropy and hjorth parameters and in frequency domain fouirer, fast fourier, spectral power density and wavelet energy were used. The size of these features was reduced and basic signal components were obtained by using Principle component analysis (PCA) and Independent component analysis (ICA) methods. Then, adaptive neural fuzzy inference system (ANFIS), learning vector quantization (LVQ), multi-layer neural network (MLNN), probabilistic nural network (PNN), decission tree, linear discriminant analysis (LDA), k nearest neighbour (kNN), linear support vector machine (SVM) and least squares support vector machine (LS-SVM) structures were performed to pattern recognition and signal classification. EEG signals occured in the brain under the imagination of the directions were recorded to create a BCI system, signal features were extracted in both time and frequency domain and hidden informations of directions stored in EEG were recognized by classification algorithms. Also, this study was evaluated as offline with 10 different subjects by all the feature extraction and classification algorithms under a BCI system created to control 2-D cursor movements. As a result, the accuracies of all methods were compared with each other and the most optimal system architecture was determined as ICA+LS-SVM(OvsO) with the accuracy of %98,61 for aimed BCI structure.

BÖLÜM 1. GİRİŞ

19. yüzyılın sonlarından itibaren biyomedikal alanda çok büyük yenilikler yapılmıştır. Bunlardan bazıları hastalıkları tedavi etmek amaçlı olmakla birlikte bazıları sadece akademik çalışma olarak kalmıştır. Son 30 yılda yapılan bilim kurgu filmlerine konu olmuş, düşünce ile makine kontrolü günümüzde gerçekleştirilmektedir. Kafatası yüzeyinden elektrotlarla alınan ve beynin elektriksel aktivitesi olarak adlandırılan Elektroensefalogram (EEG) sinyalleri işlenip sınıflandırılarak kişinin düşündüğü ve gerçekleştirmek istediği eylem, robot veya makineye yaptırılabilir [1].

İlk EEG sinyallerinin 1875 yılında İngiliz fizikçi R. Carton'un tavşan ve maymunlar üzerinde yaptığı deneyler ile başladığı düşünülmektedir. 1890'da Polonyalı fizyolog A. Beck tavşan ve köpek EEG leri üzerinde ışığa göre ritmik osilasyon değişimlerini gözlemiştir. 1912'de Rus fizyolog V. V. P. Neminsky memelilerin (köpekler) uyarılmış potansiyeller üzerine ilk EEG çalışmasını yayınladı ve 1914'te N. Cybulski ve J. Macieszyna bu uyarılmış EEG potansiyellerini deneysel olarak kanıtladı. 1924 tarihinde Alman psikiyatrist H. Berger insan beyninin elektriksel aktivitesi ve bu aktivitenin nasıl kaydedileceği üzerine çalışmalar yürütmüş ve ilk insan EEG kayıtlarını başarmıştır.

1934'te Fisher ve Lowenback ilk epileptik EEG sinyallerini inceledi. 1936 ya gelindiğinde Massachusetts General Hospital 'da ilk EEG laboratuvarı kuruldu. 1947'de ilk Amerikan EEG Derneği açıldı ve uluslararası EEG konferansı düzenlendi. 1950 yılında W. G. Walter beyin yüzeyindeki elektriksel aktivitenin haritalandırılması için EEG topoğrafyasını geliştirdi ve bu çalışma 1950-1980 yılları arasında popüler bir çalışma alanı haline geldi [2]. 1980-2000 yılları arasında EEG kayıtlarından yararlanarak erken hastalık teşhisi üzerine pek çok çalışma

gerçekleştirildi. 2000 yılı ve sonrasında, son zamanlarda popüler hale gelen beyin bilgisayar arayüzü çalışmalarının hız kazandığı görülmektedir [3-5].

Günümüzdeki kontrol amacıyla kullanılan zihinsel aktivitelerden yön çıkarım sistemleri derin ve yüzeysel Elektroensefalografi (EEG) kayıtları ile alınan beyin sinyallerinin işlenmesi ile gerçekleştirilmektedir. Bu amaçla kişiden alınan EEG sinyalleri kullanılmaktadır. Bu sistemler ile duyma, görme ya da hareket edebilme gibi hastalıkları olan bireylerin yaşayışlarını kolaylaştırmak için araştırmalar hala devam etmektedir [5,6].

İnsanın beyin etkinliği istilacı (invasive) ya da istilacı olmayan (non-invasive) yaklaşımlarla ölçülebilmektedir. İstilacı yaklaşımlarda beyindeki gri maddenin içine, ya da beyin dışına ancak kafatasının içine algılayıcı cihazlar yerleştirilir. İstilacı olmayan yaklaşımlarda ise ölçümler kafanın dışındaki algılayıcılarla yapılır. Kafa yüzeyinden yapılan bu ölçümlerde EEG işaretleri elde edilir. İstilacı olmayan yaklaşım, literatürde çok daha fazla çalışılmış ve daha kolay olan bir yaklaşımdır [7]. Beynimizi oluşturan çok sayıdaki sinir hücresi (nöronlar) elektrokimyasal etkileşimler ile birbirleriyle haberleşirler. Bu haberleşme sırasında, kafatası üzerine yerleştirilen elektrotlar sayesinde, meydana gelen iletişim hakkında bilgi edinmek mümkündür. Beynin, farklı işlemleri gerçekleştiren bölümlerden oluştuğunu düşündüğümüzde, ilgili bölüme yakın yere yerleştirilecek olan elektrotlar, o bölgeye ilişkin bir bilgi edinmemizi sağlarlar.

Zihinsel aktivitelerden yön çıkarım sistemleri ya da diğer adıyla Beyin Bilgisayar Arayüzü (BBA) sistemleri, beyin aktivitesi ile robot/makine arasındaki iletişimidir. BBA sistemlerinin ilk adımlarının, 1979 yılında maymunlar üzerinde yaptığı çalışmaları ile dikkat çeken Prof. Eberhard Fetz tarafından atıldığı kabul edilmektedir. Prof. Fetz maymunların kafatasına yerleştirilen elektrotlar sayesinde kayıtlanan EEG sinyalleri üzerinde çalışmalar yapmış ve maymunların görsel ve işitsel olarak uyarıldığı durum altındaki beyin dalgalarında meydana gelen farklılaşmaları gözlemleyerek beynimizin harici bir cihazı kontrol edebilme kabiliyetinin var olduğunu vurgulamıştır. Bundan tam 30 yıl sonra 1999'da John Chappin'in bilim dünyasında büyük yankı uyandıran çalışmasında, laboratuvarında

farelerle yaptığı çalışmalar sayesinde farelerin basit bir robotik cihazı sadece beyinlerini kullanarak kontrol edebildiklerini kanıtlamıştır. Böylece, BBA sistemlerinin normal yaşamada uygulanabilir olduğunun farkına varılması BBA sistemlerinin gelişimini hızlandırmıştır [8]. Bu sistemlerde kişilerin işlenen EEG sinyallerinden komut belirlenip buna uygun işlemler yapılır. Motor sinir sistemi kullanılmaksızın bir bilgisayarın, elektromekanik bir kolun ya da çeşitli elektronik cihazların kullanılması olanaklı hale getirilir. Yani BBA için herhangi bir kas hareketi gerekmemektedir. Bu sistemler farklı elektrot kombinasyonları ve bu elektrotlardan alınan elektriksel sinyallerin farklı şekillerde analiz edilmeleri ile gerçekleştirilirler. Bu sistemler, bir bilgisayarların ya da herhangi bir elektronik kontrol sisteminin beyinde oluşan EEG sinyalleri yardımıyla kullanılabilmelerini sağlayabilir [9].

1.1. Beyinde Üretilen Yöne Bağlı EEG Sinyallerinden Öznitelik Çıkarımı ve Sınıflandırma Üzerine Yapılan Çalışmalar

Bu konuda yapılmış çalışmaların 2000 yılı ve sonrasında hız kazandığı görülmekte olup bu çalışmaların bir özeti aşağıda verilmiştir;

Mcfarland ve çalışma arkadaşları, vücudun istemli kas hareketleri sonucunda sensörimotor kortekste meydana gelen ve “mu” ritimleri olarak adlandırılan EEG sinyallerini kaydetmişlerdir. Bu sinyaller bir video ekranı yardımıyla kullanıcının uyarılması sonucu kayıtlanmış ve bilgisayar imlecinin bir boyutlu (1-D) olarak hareket ettirilmesi amaçlanmıştır. EEG verileri, önceden eğitilmiş bir katılımcı üzerinden 64 kanallı dijital sinyal işleme kartı (DSP) kullanılarak kayıtlanmış ve kaydedilen datalardan kontrol komutları çıkartılmıştır. Bu komutlar elde edilirken, kaydedilen sinyalin 12Hz frekansındaki genlik farklılıklarından yararlanılmıştır. Kişinin imleci kontrol edebilmesi, sonuçların bilgisayar (PC) ekranı üzerinden kullanıcıya görsel olarak geribeslenmesi ile sağlanmıştır [10].

Kostov ve Polak, hem bir boyutlu (1-D) hem de iki boyutlu (2-D) olarak bilgisayar imlecinin EEG sinyalleri yardımıyla kontrolünün yapılabildiği bir sistem oluşturmak istemişlerdir. EEG sinyalleri, PC ekranı üzerindeki nesnenin zihinsel olarak

yönlenebilmesine yardımcı olmak amacıyla iki butona basılması anlarında, sadece 4 elektrot (C3, C4, P3, P4) üzerinden DSP yardımıyla kayıtlanmıştır. Sinyallerin, zaman alanındaki özellikleri çıkarılmış ve bu özelliklerden sinyallerin ait oldukları örüntülerin tanınması amacıyla Adaptif Mantık Ağı (Adaptive Logic Network - ALN) sınıflandırma algoritması kullanılmıştır. Bu algoritma ile imlecin zihinsel yön tayinleri belirlenmiş ve PC ekranındaki pozisyonu bir yönetici gözetiminde her 50ms de bir güncellenmek suretiyle yenilenmiştir. 1-D kontrolde neredeyse tüm denekler %100'e başarıya ulaşmış fakat iki kişi ile denenen 2-D kontrolde başarı oranının %63 ve %76 gibi çok düşük sonuçlarda ortaya çıkmışığı vurgulanmıştır [11].

Fabiani ve arkadaşların yaptığı çalışmada EEG sinyalleri, 1-D ve 2-D olarak imleç kontrolü için sensorimotor korteks üzerindeki farklı bölgelerden (FC₅, FC₃, FC₄, FC₆, C₃, C₂, C_Z, C₂, C₄, C₆, CP₃, CP₁, CP_Z, CP₂, CP₄) kayıtlamışlardır. Sinyallerin kayıtlanması ve sistemin çalışmasının değerlendirilmesi için önceden eğitilmiş katılımcılardan faydalanmışlardır. Sistem, hem offline hem de online olarak iki aşamada değerlendirilmiştir. Offline analizde, Mekansal Filtre (Spatial Filter) ve Laplas Referans Filtresi (Laplacian Reference Filter - CAR) kullanılarak sinyalin ağırlık matrisi elde edildikten sonra özellik çıkarımı için Burg algoritması yardımıyla AR katsayıları hesaplamışlardır. Esasen, farklı frekans değerlerindeki genlik farklılıklarından yararlanmışlardır. Elde edilen özelliklerden yön bulgularının çıkarımı için Lineer Diskriminant Analiz (Lineer Discriminant Analysis - LDA) yöntemi ve kendi geliştirdikleri lineer bir algoritma ile 7 farklı 3Hz genişliğindeki filtre yardımıyla 8-27Hz arası frekans bandını incelemişlerdir. Bu sonuçlar, online analiz ile değerlendirilmek için 100ms de bir yenilenerek monitörden kullanıcıya geribeslemeli olarak PC aracılığıyla sunulmuştur [12].

Bir diğer çalışmada, Wolpaw ve McFarland BBA çalışmalarını yaşları 23-41 arasında değişen 2 si daha önceki yaşlarda omurilik yaralanması geçirmiş, 2 si sağlıklı 4 farklı katılımcı ile yapmıştır. Tüm katılımcıların EEG verileri, PC ekranı üzerinde beliren bir imleç ikonu ve sonrasında gözüken bir yön hedefi ile kullanıcıların şartlandırılması sonucu 64 kanallı bir sistem üzerinden kaydedilmiş ve 2-D imleç hareketi yapabilmeleri amaçlanmıştır. EEG kayıtlarını, katılımcıların kolundan aldıkları EMG kayıtları ile birleştirerek hibrit bir sistem oluşturmuşlardır.

Günlük her biri 3sn süren 8 kez yapılan ve toplam veri kayıtlanmasının 2-4 hafta arasında zaman alan bir süreç olduğundan bahsetmişlerdir. EMG aktivitesine bağlı olarak oluşan EEG sinyallerinin yatay ve düşey imleç hareketinin beyinde sensörimotor kortekste (özellikle C3 ve C4) ve 12 ve 24Hz frekanslarında ortaya çıktığını savunmuşlardır. EEG aktivitesini sezmek amacıyla Laplas Filtresi (Laplacian Filter - LS) kullanmış ve bu frekans bantlarındaki genlik değişimlerini çıkarmak için AR analizinden faydalanmışlardır. En Küçük Kareler (Least-Mean-Square - LMS) algoritması yardımıyla çıkarılan sinyal özelliklerinden yön tayini yapılmaya çalışılmış ve her 50ms de bir ekran üzerindeki imleç hareketleri güncellenmiştir [13].

Trejo ve arkadaşları 1-D ve 2-D imleç kontrolünde, çok kanallı EEG kayıtlarındaki spektral örüntüleri ortaya çıkarmak için yeni bir kernel tabanlı en küçük kareler algoritması (kernel partial least squares classification – KPLS) olarak adlandırdıkları adaptif bir algoritma ortaya koymuşlardır. EEG sinyalleri, yaşları 25-35 arasında olan 3 farklı denekten “hedef egzersizi” olarak adlandırdıkları 1-D imleç kontrolü için 62 kanal olarak kaydedilmiştir. Bu sinyaller, PC ekranındaki imleç hareketini istemli kas hareketlerinin EEG spektrumu üzerinde oluşturduğu farklılıklardan yola çıkarak gerçekleyen ve kullanıcıya bu hareketlerin imleci nasıl etkilediğini öğreten bir tasarım oluşturmak için kullanmışlardır. Ayrıca, “hedef işaretçisi” denilen 2-D imleç hareketi için ise beynin oksipital lobu üzerine yerleştirilen (P₇, PO₇, PO₅, PO₃, PO_z, PO₄, PO₆, PO₈, P₈, O₁, O₂, Oz) 12 elektrot yardımıyla aldıkları sinyalleri kullanmışlardır. Bu sinyaller, PC ekranı üzerinde kullanıcının görsel olarak uyarıldığı durumda ortaya çıkan EEG potansiyelleri (Steady state visual evoked potentials - SSVEP) olarak kayıtlanmıştır. Ayrıca, daha sağlıklı bir EEG sinyali elde etmek amacıyla yatay ve düşey olarak Elektrokülogram (Electrooculogram - EOG) sinyallerini de kaydetmiş ve gözle ilgili artifaktları etkisizleştirmişlerdir. Her EEG kanalı için welch metodunu kullanarak 5-12Hz aralığındaki güç spektral yoğunluklarını, her 250ms de bir hesaplamışlardır ve imleç hareketlerinin belirlenmesinde KPLS algoritmasını sınıflandırıcı olarak kullanmışlardır. 6 hafta boyunca tekrarlanan denemeler sonucunda deneklerden birinin %100 doğruluğa ulaştığını, diğer deneklerin ortalama %65 ve %75’lik doğruluk oranlarında kaldıklarından bahsetmişlerdir [14].

Kayagil ve çalışma grubu, basit bir oyun mantığı içerisinde 32 kanallı bir EEG sistemi yardımıyla 2-D imleç kontrolü yapmayı hedeflemişler ve bu sayede tuzaklara yakalanmadan ızgara kareler arasında imleci hareket ettirmeyi başarmışlardır. Ayrıca göz hareketlerinin takibi için EOG ve sağ el hareketlerinin algılanması için EMG sinyallerini kaydetmişlerdir. Bu sistem içerisinde alfa ve beta frekans bandındaki sinyal güçleri beynin sağ sol yarı kürelerindeki değişimlerine göre sürekli olarak el hareketleri esnasında kıyaslanmıştır. Bu sayede evet-hayır mantığına dayalı, kontrol kısmının Matlab programı yardımı ile gerçekleştirildiği ve doğru hareket oranının %77,4'lere ulaştığı bir BBA sistemi oluşturmayı başarmışlardır [15].

Wilson ve arkadaşları, EEG sinyalleri ile sanal imleç kontrolü üzerinde durmuş ve genel amaçlı olarak üretilmiş olan BCI2000 sinyal işleme, sınıflandırma ve beyin haritalama yazılım platformundan faydalanarak bir BBA sistemi tasarımı ortaya çıkarmışlardır. Kontrol komutlarını sensorimotor kortekste ortaya çıkan istemli hareket ritimleri olarak bilinen, mu ve beta dalgaları üzerindeki güç dağılımlarının farklılığından yola çıkarak elde etmişlerdir. EEG sinyallerini özellikle C₃, CP₃, C₄, CP₄, Cz ve CPz noktalarından kayıtlamışlardır. Sistemin eğitimi için gereken veri, el ve ayakların her defasında 20 kez açılıp kapatılması durumlarında kaydedilmiştir. Kontrol aşamasında, bu uzuvların hareket ettirildiği düşüncesi esnasında alınan veriler ile gerçek hareket durumunda kayıtlanan veriler, 8-28Hz frekans bantlarındaki genlik değişimleri kıyaslanarak sistemin çalışması sağlanmıştır. Gerçek uzuv hareketleri ile bu hareketlerin hayal edildiği düşünce esnasında 10-12Hz aralığında gözle görülür bir değişim ortaya çıktığını vurgulamışlardır [16].

BBA üzerine yapılan diğer bir çalışmada Gentiletti ve arkadaşları, felç geçiren ve vücut fonksiyonlarını kullanamayan hastalar için EEG sinyallerindeki yön çıkarımları üzerine çalışmış ve tekerlekli bir sandalyenin bu sinyaller vasıtasıyla kullanılabilmesi olgusu üzerinde durmuşlardır. 6 kanaldan (Fz, Cz, Pz, Oz, C₃ ve C₄) ölçülen EEG sinyalleri BCI2000 platformu yardımıyla işlenerek sanal ortamda tasarlanan tekerlekli sandalyenin ev içinde bir odadan diğerine hareket ettirilmesini amaçlamışlardır. Simülasyon ekranının üzerinde mavi çizgi ile belirlenen bir yolun, EEG sinyalleri ile takip edilmesi sağlanmış ve başlangıçtan bitişe kadar geçen

sürenin çok zaman aldığı belirtilmiştir. Yön tayini için P300 (ekran üzerindeki görsel bir uyarıcının değiştikten 300ms sonra beyinde pozitif yönde değişen olay etkili potansiyel) sinyallerindeki değişimleri BCI200 platformu yardımıyla çıkarmış ve bu sayede amaçlanan BBA sistemlerini ortaya koymuşlardır [17].

Li ve çalışma grubu, EEG sinyallerinin 32 kanallı bir sistemi üzerinden kaydedilerek 22-30 yaş aralığında 6 denek yardımıyla gerçekleştirdikleri BBA sistemlerinde, mu/beta ve P300 sinyallerini birleştirerek hibrit bir tasarım oluşturarak 2-D imleç kontrolünü kendi tasarladıkları görsel bir arayüz ile PC ekranı üzerinde eş zamanlı olarak yapabilmeyi hedeflemişlerdir. Arayüz ekranını P300 sinyallerini oluşturmak kullanmışlardır. Ayrıca mu/beta ritimlerini oluşturmak amacıyla da deneklerin sağ ve sol el hareketlerinden yola çıkmışlardır. İmlecin düşey hareket kontrolünü P300, yatay hareket kontrolünü ise mu/beta sinyalleri vasıtasıyla sağlamıştır. Düşey hareket komutlarını oluşturmak amacıyla 0.1-20Hz arasında filtreledikleri sinyal bileşenleri üzerine Destek Vektör Makinesi (Support Vector Machine - SVM) örüntü tanıma algoritmasını kullanmışlardır. Mu/beta sinyallerinden yatay hareket komutlarının çıkarımı içinde, 8-13Hz aralığında CAR filtresi uygulayarak, Ortak Mekansal Örüntü (Common Spatial Pattern - CSP) formunu SVM ile birleştirmişlerdir. 80 deneme sonunda en iyi sonucun %97,5 ve imlecin bir baştan diğerine ortalama 24,8 saniyede hareket ettirebildiğini vurgulamışlardır [18].

Bir sonraki BBA uygulamasında Long ve arkadaşları, önceki çalışmalarını yaşları 22-32 arasında değişen, 9'u daha önce BBA çalışmalarına katkı sağlamış 11 denek ile yaptıkları güncelleştirmeler yardımıyla geliştirmeyi amaçlamışlardır. Önceki çalışmalarında kullandıkları yöntemi devam ettirmiş ancak kullanıcının ekran üzerinde beliren bir hedefi seçerek imleci ona doğru sürüklemesini daha hızlı ve etkin bir biçimde gerçekleştirmesini sağlamak amacıyla çıkarılan tüm özellikleri birlikte kullanmayı benimsemişlerdir. İmleç ve hedef, ekran üzerinde rastgele pozisyonlarda ortaya çıkmaktadır. Kullanıcı hedefi algılayıp imleci oraya ulaştırmayı başardığında hedef kırmızıya dönüşüp 2 saniye kadar yanıp söndükten sonra bir sonraki yeni denemeye geçilmektedir. Aksi halde imleç renk değiştirmeden yanıp söndükten 6 saniye sonra işlemler tekrarlanmıştır. Eş zamanlı olarak gerçekleştirdikleri sistem için önceki çalışmalarına göre 11 denek için ortalama

hedefe ulaşma süresi 19,25sn ve ortalama doğruluk oranının %93.99 gibi yüksek bir başarımla yapılabildiğini vurgulamışlardır [19].

Diğer bir çalışmada Ubeda ve grubu, pnömatisel bir robot kolunun 2-D hareketleri için EEG sinyallerinden yön komutlarını çıkarmayı hedefleyen bir BBA sistemi oluşturmayı amaçlamışlardır. Bu doğrultuda 16 kanallı EEG filtreleme ve sinyal işleme ortamı sunan gUSBamp cihazından yararlanmışlardır. Sağ ve sol hareket çıkarımı için sensörimotor korteks dalgaları yani, mu/beta ritimlerinden (FC₁, FC₂, C₃, Cz, C₄, CP₁ ve CP₂) yararlanmışlardır. Sinyallerin özellik çıkarımı için hızlı fourier dönüşümünden (Fast Fourier Transform-FFT) faydalanmış ve özellikle 8-12Hz bandında yoğunlaştıklarını bildirmişlerdir. Yön bulgularının çıkarımı için normalize edilmiş çapraz korelasyon (Normalized Cross Correlation) algoritmasından yararlanmışlardır. Matlab ileri düzey programlama ortamından faydalanarak deneysel bir arayüz programı oluşturmuş ve bu arayüz ekranı üzerinde yer alan yön işaretçileri ve yönergeleri izleyerek yön komutlarının bilgisayar üzerinden robot koluna aktarılması sonucu, robot kolu hareketini başarmışlardır. İlk olarak ekran üzerinde kullanıcıya kontrol etmek istediği düzlem sorulmuş ve sonrada bu düzleme ait yön hareketlerinin oluşturması istenmiş. Robot kolunun hareket ettirilmesi için gerekli minimum sürenin 10,8 saniye olduğunu vurgulamış ve karar doğruluğunun %88,2 olduğunu belirtmişlerdir [20].

Alomari ve arkadaşları, EEG mouse olarak isimlendirdikleri ve 100 katılımcının yer aldığı BBA çalışmalarında, bilgisayar üzerindeki imlecin kontrolünü kablosuz EEG başlığı ile uzaktan kontrol edebilmeyi hedeflemişlerdir. Sinyallerden yön bilgilerini elde edebilmek için dalgacık dönüşümü algoritmasını kullanmış ve genlik değişimlerinden faydalanmışlardır. EEG kayıtları için PhysioNet sinyal işleme sisteminden yararlanmış ve sadece sensörimotor korteks üzerinden 3 elektrot (C₃, Cz ve C₄) ile aldıkları “mu” ritimlerini kullanmışlardır. El ve ayak hareketleri yaparak mu ritimleri oluşturmanın yanında göz açıp kapatma durumlarını da hesaba katmışlardır. Sinyallerden yön bulgularının çıkarımı için SVM ve yapay sinir ağı algoritmalarını birlikte kullanmışlardır. Çıkarılan yön bilgilerinden bilgisayar imlecinin hareket ettirilmesi Matlab programı ile tasarlanan bir algoritma üzerinden yürütülmüştür. Gözlerin 2 saniye kapalı durması imlecin sağ tıklama işlemine, sol

elin yumruk yapıldığının düşünülmesi imlecin sola hareket etmesine, sağ elin yumruk yapıldığının düşünülmesi imlecin sağa hareket etmesine, iki elin yumruk yapıldığının düşünülmesi imlecin yukarı hareket etmesine ve iki ayağın da hareket ettirildiğinin düşünülmesi de imlecin aşağı hareket etmesine karşılık geldiğini ifade etmişlerdir. Ayrıca çalışmanın sonunda %99,87 oranında oldukça yüksek sınıflandırma doğruluğu elde edildiğine vurgu yapmışlardır [21].

Beyinde oluşan yöne bağlı EEG sinyallerinde saklı olan yön bilgilerinin çıkarımı ve bu yön bilgilerinin makine kodlarına dönüştürülerek bir makinenin, bir bilgisayarın, elektromekanik bir kolun ya da herhangi bir çevresel cihazın kontrolü maksadı ile kullanılması adına literatür çalışmalarının çoğunda, vücut uzuvlarının (el, kol, ayak vb.) kontrolünü sağlayan beynin motor korteks adı verilen bölgesinden kayıtlanan EEG sinyalleri kullanılmıştır. Bu sinyaller ya gerçek uzuvların hareketleri ya da bu hareketlerin yapıldığı düşünüldüğü durumlarda kayıtlanmıştır. Bazı çalışmalarda da kafatasının tümünden kayıtlanan EEG sinyalleri elektromiyogram (EMG) veya elektrookülogram (EOG) sinyalleri ile birleştirilmiştir [13-15]. Fakat bu şekilde kaydedilen sinyaller ile kurulan sistemler genel olarak sağlıklı kişiler için uygun olmaktadır. Felç geçirmiş ya da Amyotrofik Lateral Skleroz (ALS) hastaları gibi kas hareketi yapamayan hastaların vücut uzuvlarını hareket ettirmeleri imkansız olduğundan, bu kişiler için uygun değildir [22-24]. Ya da kontrol amacıyla bazı çalışmalar da var olduğu gibi beyinde yöne bağlı EEG sinyalleri oluşturmak adına görsel bir arayüz üzerinden kullanıcının uyarıldığı uygulamalar da mevcuttur [16-18]. Bu tür uygulamalarda altında kullanıcının beyinde oluşan P300 veya SSVEP potansiyellerinden hareketle yön çıkarımları sağlanmaktadır [14, 19, 20]. Ancak bu tür uygulamalar içinde, kullanıcıların yön amacı ile uyarılması gerekliliği doğmaktadır [25].

Dokunmatik ekran ve android işletim sistemi gibi yüzyılın yeni trendi ve tüm insanlığı merak içinde bırakan yenilik, düşünce gücü ile kontrol olacaktır. Yapılması düşünülen bu tez çalışması ile bireylerden alınan EEG ölçümleri ile bir BBA sistemi oluşturulması hedeflenmektedir. Şu anki aşamada, öznelik belirleme ve sınıflandırma yöntemleri üzerine çalışılması düşünülmektedir. Sınıflandırma yöntemlerinin kıyaslanması ve en iyi yöntemin belirlenerek makine öğrenme

algoritmalarına katkıda bulunularak BBA sistemlerinin geliştirilmesi hedeflenmektedir.

Bu tez çalışmasının birinci amacı, beyinde yöne bağlı EEG sinyalleri oluşturmak adına herhangi bir vücut hareketine ya da kullanıcıların herhangi bir görsel ya da işitsel uyarana bağlı olma gerekliliğini ortadan kaldırmaktır. Bu amaçla, sadece zihinsel yönelimler ve yön hareketlerinin düşünsel olarak gerçekleştirildiği durumda beyinde oluşan EEG sinyallerindeki yöne bağlı bilginin çıkarımı konu edinmiş olup, çalışma bu yönüyle literatürde var olan çalışmalardan ayrılır. Bu tez çalışmasında beyinde yöne bağlı EEG sinyalleri oluşturmak adına, bir bilgisayar imlecinin ana yönleri düşünsel olarak hareket ettirildiği düşüncesi benimsenmiş ve bu esnasında kayıtlanan EEG sinyalleri kullanılmıştır. Dolayısıyla, beynin tüm bölgelerinden EEG kayıtlanması yapılmıştır.

Literatür çalışmalarının ilk aşamalarını sinyal özellik çıkarım metotları oluşturduğu görülmektedir. Bazı çalışmalarda bir boyutlu (1-D, sağ ve sol) yön bilgilerinin çıkarımı bazılarının da ise iki boyutlu (2-D, sağ, sol, yukarı ve aşağı) yön bilgilerinin çıkarımı konu edinmiştir. Dört farklı ana yön olduğundan, 2-D özellik çıkarımları kontrol uygulamalarında daha çok tercih edilir. Dolayısıyla bu tez çalışmasında da 2-D özellik çıkarımları benimsenmiştir. Bazı çalışmalarda EEG sinyal özellikleri, zaman alanında bazılarında da frekans alanında değerlendirmiştir. Tez çalışması içerisinde kayıtlanan EEG sinyallerinin hem zaman hem de frekans alanındaki özellikleri çıkarılmıştır. EEG sinyal özelliklerinin zaman alanındaki incelemelerini içeren literatür çalışmalarında genel olarak yön hareketleri esnasında beyinde oluşan sinyallerdeki genlik farklılıkları ve güç değişimleri incelenmiştir. Çalışma içerisinde bu özelliklere ek olarak, EEG kanallarındaki bilgi içerikleri ve sinyallerdeki değişkenlikler de incelenmiştir. Frekans alanındaki incelemelerde ise genel olarak yön hareketleri esnasında oluşan sinyallerdeki frekans aralıklarının değişimleri, frekans aralıklarında oluşan genlik farklılıkları veya frekanslarda meydana gelen güç yoğunlukları kullanılmıştır. Bu çalışma içerisinde de literatürde amaçlanan özellik çıkarımlarına ek olarak EEG sinyallerinin zaman-frekans alanındaki değişimleri ve dalgacık enerjileri incelenmiştir. Zaman alanında en iyi sonuç %97,94 ile entropi

özelliği kullanılarak elde edilirken, frekans alanında beta bandı dalgacık enerjisi ile %98,61 oranında sınıflandırma doğruluklarına ulaşılmıştır.

Literatür çalışmalarının ikinci aşamasında, kayıtlanan EEG sinyallerinden zaman ve frekans alanlarında çıkarılan sinyal özellikleri yardımı ile sinyallerdeki yöne bağlı bilginin ortaya çıkarılması ve yön örüntülerinin tanınması için makine öğrenme algoritmalarının kullanımı yer almaktadır. Bu amaçla adaptif mantık ağı algoritması, en küçük kareler yöntemi, lineer diskriminant analizi, kernel tabanlı en küçük kareler algoritması ve destek vektör makineleri gibi çeşitli sınıflandırma yapıları kullanılmıştır. Bazı çalışmalar da ise BCI2000, gUSBamp ve PhysioNet gibi kontrol amacı ile geliştirilmiş hazır alt yapıların sağladığı sınıflandırma yöntemlerinden faydalanılmıştır. Bu tez çalışmasında ise literatürde kullanılan en küçük kareler yöntemi, LDA ve SVM yapılarına ek olarak ANFIS, LVQ, MLNN, PNN, kNN, karar ağacı algoritması gibi diğer önde gelen sınıflandırma yapıları ele alınmıştır. En başarılı sonuçlar, hem zaman hem de frekans alanlarında LS-SVM yapısı tarafından elde edilmiş olup %98,61 oranında oldukça yüksek doğruluk seviyesine ulaşılmıştır

Bu tez çalışmasının ikinci amacı da, beyinde oluşan yöne bağlı EEG sinyallerindeki yön bilgilerinin çıkarımı adına, zaman ve frekans alanlarındaki özellik çıkarım yöntemleri ile bütünleşen sınıflandırma algoritmaları için en verimli sistemi belirlemek olmuştur. Çünkü çoğu literatür çalışmasında zaman alanında ya da frekans alanında sadece bir özellik çıkarım yöntemi üzerinde durulduğu ve bir sınıflandırma algoritması ile çalışma sağlandığı görülmektedir. Bu tez çalışmasında beyinde oluşan yöne bağlı EEG sinyallerinin hem zaman hem de frekans alanındaki özellikleri incelenmiştir. Ayrıca çok çeşitli sınıflandırma yapılarının çalışma içerisindeki başarımları değerlendirilmiştir. ANFIS sınıflandırıcı, yapısı gereği 5 girişe izin vermekte olup sadece beş özelliği sınıflandırabilmiştir. Karar ağacı yapısının düşük sınıflandırma sonuçlarından dolayı EEG sinyal örüntülerinin tanınmasında pek uygun bir yöntem olmadığı anlaşılmıştır. MLNN yapısı ortalama karesel hata sonuçları sayesinde iki katmanlı olarak kurulmuştur. PNN ve kNN algoritmaları kümeleme tekniğine göre işlem yaptıklarından genel olarak birbirlerine yakın sonuçlar sağlamıştır. LDA yapısı ise sınıfları birbirinden maksimum düzeyde ayırmayı amaçlayarak veriyi daha anlaşılır bir forma dönüştürdüğünden diğer


yapılara nazaran daha başarılıdır. SVM ve LS-SVM yapıları en başarılı sınıflandırıcılar olmuştur. Ancak, SVM yapısının sınıflandırma süresi oldukça zaman almaktadır. Dolayısıyla en başarılı yapı LS-SVM olmuştur.

Bu tez çalışması soncunda ister sağlıklı ister engelli olsun tüm kullanıcılar, herhangi bir vücut hareketi ya da uyarana bağlı kalmaksızın sadece yöne bağlı düşünsel etkinlikleri sayesinde çevresel cihazları kontrol etme imkanına sahip olacaktır. Dolayısıyla bir bilgisayar imlecinin hareket, bir robot kolunun ya da bir motorun kontrolü veya çevresel cihazların sadece düşünsel olarak kumanda edilebilmesine imkan tanınmıştır.

BÖLÜM 2. BEYİNDE MEYDANA GELEN EEG SİNYALLERİNİN TEMELLERİ


Elektroensefalogram (EEG) işaretleri beyin yüzeyinden veya saç derisi üzerinden elektrotlarla ölçülen düşük genlikli (tepeden tepeye 1-400 μV) biyoelektrik işaretlerdir. Son 15 yılda EEG işaretlerinin incelenmesi hız kazanmış, bu işaretlerle hem hasta tedavi yöntemleri geliştirilmekte hem de bu işaretler yardımı ile bir BBA oluşturularak elektronik cihazlarla haberleşme sağlanmaktadır. EEG işareti geniş bir frekans bandına (0.5-100 Hz) sahip olmakla birlikte, klinik ve fizyolojik bilgi 0.5 ile 40 Hz arasına yoğunlaşmıştır. Bu frekans aralığı aşağıda özetlendiği gibi 5 frekans bandına ayrılmıştır [26-29].

Delta (δ) Dalgaları: Şekil 2.1’de gösterildiği gibi frekansları 0.5-4 Hz, genlikleri 20-400 μV arasında değişir. Derin uyku, genel anestezi gibi beynin çok düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.




Şekil 2.1. Delta dalgaları [2]

Teta (θ) Dalgaları: Şekil 2.2’de görüldüğü gibi frekansları 4-8 Hz, genlikleri 20-100 μV arasında değişir. Normal bireylerde; rüyalı uyku, orta derinlikte anestezi, stres gibi beynin düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.




Şekil 2.2. Teta dalgaları [2]

Alfa (α) Dalgaları: Şekil 2.3'teki gibi frekansları 8-14 Hz, genlikleri 20-60 μ V arasında değişir. Uyanık durumdaki bireylerin fiziksel ve zihinsel olarak tam dinlenimde bulunduğu, dış uyarılarının olmadığı, gözlerin kapalı olduğu durumlarda görülürler.




Şekil 2.3. Alfa dalgaları [2]

Beta (β) Dalgaları: Şekil 2.4'te görüldüğü üzere frekansları 15-40 Hz, genlikleri de 2-20 μ V arasında değişen işaretlerdir. Gözlerimiz açıkken, dinlerken, düşünürken, analitik bir problem çözerken, karar verme veya yargıya varma durumunda, etrafımızda olan biten bilgiyi işleme sırasında veya etkin konsantrasyon durumunda ortaya çıkan sinyaller olarak bilinmektedir.



Şekil 2.4. Beta dalgaları [2]

Gama(γ) Dalgaları: Şekil 2.5'teki gibi frekansları 40-100 Hz arasında, genlikleri de 3-5 μ V deęişir ve belirli motor fonksiyonlarının yürütülmesinde, yüksek uyarılma ve stres durumlarında ortaya çıkan beyin sinyalleridir.



Şekil 2.5. Gama Dalgaları [2]

EEG kayıtları istilacı olmayan yaklaşımlarla yani kafatası yüzeyinden daha kolay ve pratik olarak elde edilebilmesi yönüyle, BBA sistemlerinde en çok tercih yöntem haline gelmişlerdir. Çeşitli elektrotlar ile kafatasından alınan sinyaller önce bir biyopotansiyel yükseltici ile yükseltilir, ardından filtrelenerek bilgi boyutu daraltılır. Daha sonra kişilere gerçekleştirilmesi istenilen beyin aktivitesine göre çeşitli görevler verilir ve bu görevler esnasında yapılan EEG kayıtları sinyal işleme ve makine öğrenme algoritmaları için kullanılırlar [9].

EEG kayıtlarında elde edilen sinyallerin sağlıklı bir şekilde algılanabilmesi için beynin temel yapısı ve bölümlerinin, EEG kayıtlarında kullanılması gereken elektrot çeşitlerinin, keplerin ve buna baęlı olarak kaç farklı noktadan ölçüm yapılması gerektiğinin, bu ölçümler esnasında kullanılacak olan jellerin, EEG elektrotlarının kafatası üzerine nasıl yerleştirilmesi gerektiğinin ve ölçüm esnasında ne gibi bozucu durumlarla (artifakt-parazit) karşılaşılabilceğinin iyi bilinmesi gerekir.

2.1. Beynin Temel Yapısı ve Bölümleri

EEG işaretleri, kafatasının çeşitli yerlerinden aynı anda farklı elektrotlar ile yapılan kayıtlar sonucu elde edilir. BBA sistemlerinde hangi olgunun deęerlendirileceęi sistemin mantıksal çalışması için çok önemlidir. Bu nedenle EEG kayıtlarının beynin hangi bölgesinden ve hangi olguya yönelik olduğunun bilinmesi için beynin temel yapısının ve bölgelerinin mühendislik açısından bilinmesi gerekir.

Beyin temel olarak iki yarı-küreden meydana gelmektedir.

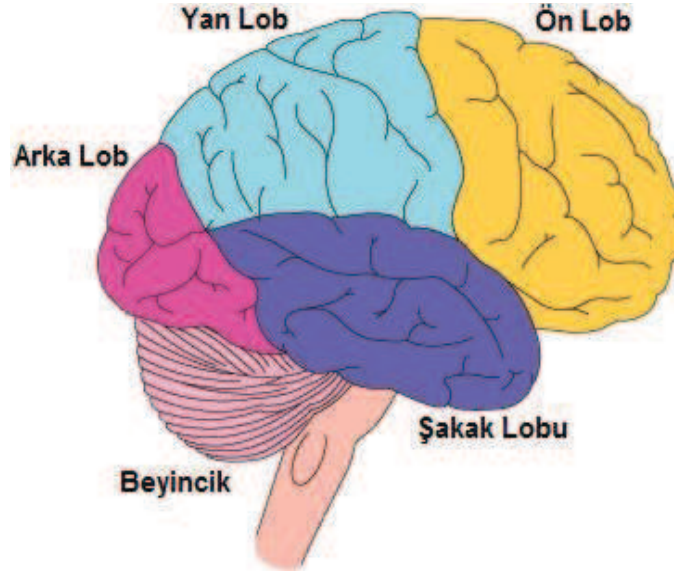
Sol yarı-küre: Mantıksal sıralama, karar verme, harfleri yorumlama, dil ile ilgili fikirlerin işlenmesi, düşüncelere yapı ve sıra verilmesi, fikirlerin sınıflandırılması, sayılarla ve hesaplarla ilgilenerek fikirlerin kritik analizinin yapılması ve vücudun sağ bölümünün kontrol edilmesi gibi işlevleri kontrol etmektedir.

Sağ yarı-küre: Görsel şekillerin ve imajların (grafikler, haritalar ve çizgiler), uzamsal bilginin, kendiliğinden rastlantısal, açık uçlu fikirlerin işlenmesi, sezginin kullanılması, yeniliklerle, belirsizliklerle ilgilenme ve vücudun sol bölgesini yönetme gibi işlevleri kontrol etmektedir. Beyin kabuğunun bağlantı kurucu alanları öğrenme, düşünme ve dil gibi yüksek beyin işlevleri ile ilgilidir [30].



Şekil 2.6. Beynin sağ ve sol yarı kürelerinin görevleri [31]

Temelde sağ ve sol yarı küre olarak iki kısma ayrılan insan beyninin yapısı, daha detaylı anlaşılabilmesi açısından lob adı verilen farklı parçalar halinde incelenmektedir. Mühendislik açısından bizleri ilgilendiren asıl kısımlar bunlardır ki, EEG ölçümlerinde elektrot yerleştirilmesi bu parçalara göre yapılır.



Şekil 2.7. Beynin farklı kısımları (Loblar) [32]

Düşünce, mantık ve soyutlama gibi karmaşık zihinsel eylemler bilinçli olarak beyin tarafından yönetilmektedir. İnsan beyni temel olarak beş ana loba ayrılmıştır [33-35].

Ön (Frontal) Lob: Alnın hemen arkasında yer alır ve insan beyninin yaklaşık yarısını oluşturur. Bilinçli düşünme merkezi olarak tanımlanan kısımdır. Dikkat süresinin düzenlenmesi, sonuç çıkartabilmek, mantık, eşleştirme yapmak, an ile gelecek arasındaki ilişkiyi düzenlemek, empati sağlamak ve zamanı organize etmek gibi faaliyetler beyin ön lobunda gerçekleştirilir.

Yan (Parietal) Lob: Her iki beyin yarı-küresinin tavanının arka kısmının yarısını işgal eder. Tüm vücudumuzdaki deri, kas ve eklemlerdeki duyu alıcılardan bilgi alır. Çeşitli duyu organlarından gelen bilgileri birleştirmede önemli rol oynar.

Arka (Occipital) Lob: Beyin yarı-kürelerinin en arka kısmında bulunur ve görsel bilgiyi alır işler. Çevremizdeki şekil, renk ve hareket deneyimlerini algıladığımız kısımdır.

Şakak (Temporal Lobu: Yüzlerin tanınması gibi karmaşık görsel görevlerde önemli bir rol oynar. Beyinde birincil koku merkezidir. Ayrıca, kulaklardan bilgiyi alır ve işler, dengeye katkıda bulunur ve kaygı, hoşnutluk ve kızgınlık gibi duyguları ve güdüleri düzenler.

Beyincik (Cerebellum): Beynin ikinci büyük parçasını oluşturur. Vücudun denge organlarından biridir ve kasların düzenli çalışmasını sağlar. Kısacası iskelet kaslarını kontrol ederek aktif hareketin düzenliliğini sağlar.

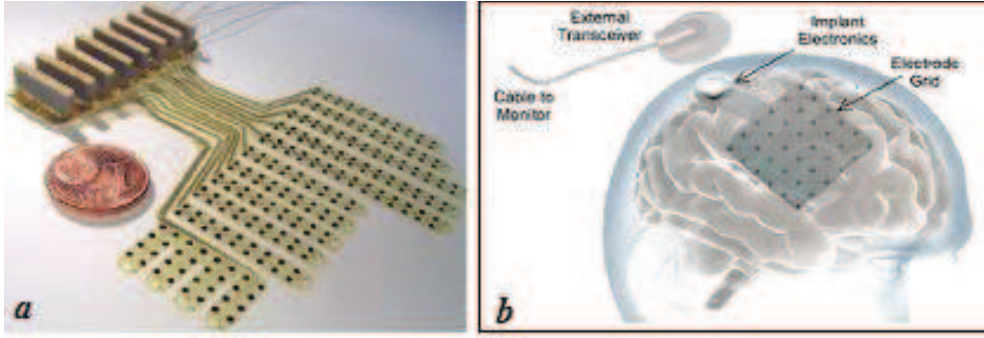
Beynin bu temel kısımlarının işleyişinin hangi amaca yönelik olarak geliştiğini bilmek, EEG kayıtlarının hangi olguya yönelik yapılması gerektiğini (hareket, hangi duyu organları, ruhsal durum, vb.) ve kafatası üzerinde hangi kısımlardan ölçümler alınması gerektiğini bilmemizi sağlamaktadır.

2.2. EEG Elektrotları ve EEG Kepleri

Elektrotlar, genel anlamda canlı organizmadaki elektriksel kökenli biyolojik işaretlerin algılanması için kullanılır. Bu işaretler EEG kayıt sistemlerinde, saçlı deri üzerine ya da kafatası içerisine yerleştirilen algılayıcılar ile elde edilmektedir. Kayıt aşamasında kullanılan çok sayıda elektrot çeşidi mevcuttur. Ancak, uygun ölçümün elde edilebilmesi açısından hangi elektrot tipinin kullanılacağı belirlenmelidir.


2.2.1. Dahili elektrotlar

Bu tip elektrotlar genelde istilacı(invasive) yaklaşım yöntemlerinde kullanılır ve biyopotansiyel işaretleri algılamak için vücut içine yerleştirilir. Ancak, bu süreç tıbbi bir müdahale gerektirdiğinden çok zordur ve tercih edilmez.



Şekil 2.8.a. Bir dahili elektrot, b. İstilacı yöntemde dahili elektrot yerleşimi [36]

Bu tip elektrotlar, beyindeki gri maddenin içine, ya da beyin dışına ancak kafatasının içine yerleştirilirler. Sinyal kalitesi ve bilgisi diğer elektrot tiplerine oranla çok daha kararlı bir seviyededir [36]. Bu tip elektrotlar da Şekil 2.9’da görüldüğü gibi çip şeklinde üretilerek vücut içine gömülen ve bir verici düzenine sahip olan çeşitleri de mevcuttur.



Şekil 2.9. Kablosuz verici düzenine sahip dahili elektrot [36]


2.2.2. Yüze elektrotlar

Bu tip elektrotlar genelde istilacı olmayan (non-invasive) yaklaşım yöntemlerinde kullanılır ve biyolojik işaretlerin deri yüzeyinden algılanmasını sağlar. BBA sistemlerinde bu yöntemden faydalanılmaktadır.

Yüze elektrotlarının birkaç farklı çeşidi mevcut olmasına rağmen, tez çalışması içerisinde, çalışmaya yönelik en uygun olan tipi metal disk elektrotlar olduğundan, EEG sinyali kayıtları bu elektrot çeşidi ile yapılmıştır.

2.2.2.1. Metal disk elektrotlar

Bu elektrotlar metal disk, metal plaka veya kep elektrotları olarak da adlandırılmaktadır. Özellikle EEG işaretlerini algılamada çok sık kullanılan bir elektrot türüdür.




Şekil 2.10. Metal disk elektrotlar [36]

Deri ile temas eden metalik bir yüzeyleri bulunur. Gerçekte saçlı deri ile mekaniksel yada elektriksel bir temas sağlamazlar. Temas, bir elektrolit pasta aracılığı ile olur. Metal plaka düz veya uygulanacak yüzeyin şeklini alacak şekilde bir silindir yüzey parçası biçimindedir. Genellikle nikel-gümüş, nikel-altın alaşımından yapılır. Genelde bu sınıfa giren elektrotların yüzeyleri büyük olduğundan empedansları küçüktür (2-10 K Ω). Elektrotların kolayca tanınabilmesi için Şekil 2.10'da görüldüğü üzere her bir telin yalıtımında farklı bir renk kullanılır [36].

2.2.2.2. Kulak elektrotu (Klips elektrot)

EEG ölçümlerinde kullanılan kulak elektrotları genellikle yaylı tip elektrotlardır ve kulak memesine yerleştirilirler. Ölçümlerin daha kararlı olmasında yardımcıdır. Referans veya topraklama sağlamak için kullanıldıklarında, toprak ya da referans elektrot olarak da isimlendirilirler. Ölçüm sırasında meydana gelen sinyal bozulmaları gibi özel durumlarda daha doğru sonuçlar elde edilmesi istendiği durumlarda kullanılır.




Şekil 2.11. Kulak elektrotu (Klips Elektrot) [37, 38]

Farklı elektrotlardan yapılan kayıtların neden olacağı elektriksel sorunlardan kaçınmak için kulak elektrotları da, kullanılan metal disk elektrotları ile aynı materyalden yapılmış olması gerekir.

2.3. Elektrot Jelleri

İnsan derisinin bir direnci vardır. Bu direnç, kişiden kişiye ve derinin özelliklerine göre farklılık gösterir. İnsan enstrümantasyon sisteminde ölçümün daha kaliteli ve net yapılabilmesi için hem deri direncinin hem de elektrotun temas yüzeyinde oluşturduğu direncin en aza indirilmesi gerekir. Elektrot jelleri (pasta), bu oluşan direnci azaltmak için kullanılır.



Şekil 2.12. EEG elektrotlarının jellenmesi [36]

Bu jeller, elektrotların vücuda daha iyi yapışmalarına da katkı sağlar ve koyu kıvamlıdır. Akışkan değildir. İmal edilirlerken hijyenik ve dermatolojik testlerden geçirilir [36].

2.4. EEG Kepleri

EEG kepleri, BBA sistemlerinde ve EEG kayıtlarında yaygın olarak kullanılan ve üzerinde elektrot yerleştirme yuvaları yer alan başlıklardır. Kafatasını tamamen sararak üzerinde yer alan bölmelerine metal disk elektrotları yerleştirilir. Genellikle silikon ya da kumaş türü malzemelerden yapılırlar.



Şekil 2.13. Çeşitli boyutlardaki EEG başlıkları [37]

İnsanın cinsiyetine ve yaşına göre değişen kafatası büyüklükleri için Şekil 2.13’de görüldüğü gibi farklı boyutlarda EEG kepleri mevcuttur. Boyutları genel olarak 58-34 cm aralığındaki standartlara göre değişmektedir. Başlık üzerinde görülen beyaz yuvarlak kısımlar metal disk elektrotların yerleştirildiği yuvalardır.



Şekil 2.14. Çeşitli elektrot yuvalarına sahip EEG başlıkları [36]


Ölçüm sisteminin hassasiyetine ya da inceleme yöntemlerine göre EEG keplerinde çeşitli sayıda elektrot yuvaları mevcuttur. Genel olarak bu sayı 8-128 arasında standartlaştırılmış EEG kepleri mevcuttur. Ayrıca Şekil 2.14'te görüldüğü gibi EEG kepi kullanılmadan da yapılabilen ölçümler mevcuttur. Bu tip ölçümlerde EEG elektrotları jeller aracılığı ile doğrudan saçlı deri üzerine yapıştırılmaktadır [39]. BBA sistemlerinde genel olarak kullanılan EEG kepleri, 20 ya da 32 kanallı olmaktadır. Bu nedenle çalışma içerisinde, 32 kanallı bir EEG başlığı tercih edilecektir.

2.5. EEG Elektrot Yerleşim Sistemi

EEG kayıtlarında, elektrotlar belirli bir düzen içerisinde standart bir koordinat sistemi dahilinde kafatası üzerine yerleştirilirler. Standardize edilmiş bu koordinat sistemleri 10/20, 10/10 ve 10/5 sistemleri olarak bilinir. En yaygın olarak kullanılanı, uluslar arası 10/20 sistemidir [40, 41]. EEG keplerindeki elektrot yerleştirme yuvaları da bu sistem doğrultusunda yapılır.

2.5.1. 10/20 Sisteminde elektrotların yerleşimi

21 elektrota sahip olan uluslar arası standartlarda bir sistemdir. Elektrot isimleri bir harf ve ona eşlik eden bir rakamdan oluşmuştur. Harfler elektrotların üzerinde yer aldığı beynin kısımlarını(lob) ifade etmektedir. Ayrıca, iki harfin kombinasyonu da, ara elektrot yerleşimlerini gösterir [42].



Şekil 2.15. 10/20 sistemine göre elektrot yerleşimi [43, 44]

Fp: frontal kutup (pole), F: frontal (ön lob), C: merkez (central), T: temporal (şakak lobu), P: parietal (yan lob), O: occipital (arka lob), A: kulak elektrotu.

İki harfin kombinasyonu ise ara elektrot yerleşimlerini yada lob merkezlerini göstermektedir.

FC: frontal ve santral elektrot yerleşimlerinin arasında yer alır.

PO: pariyetal ve oksipital elektrot yerleşimlerinin arasında yer alır.

Fz: frontal lob merkezi.


10/20 sistemindeki isimlendirmede ayrıca kafanın sağ tarafındaki elektrotlar tek sayılar ile sol tarafındaki elektrotlar ise çift sayılar ile isimlendirilirken orta hat üzerindeki elektrotlar da “z” harfi ile simgelenmiştir [45].

Elektrot yerleşimi için öncelikle burun kökü (nasion) ile protuberensiya oksipitalis (inion) arasındaki uzaklık ölçülür. Bu uzaklığın orta noktası Cz (verteks) olarak belirlenir. Cz'den burun kökü-protuberensiya oksipitalis arası uzaklığın %20 si kadar öne gidilerek Fz (orta hat frontal) bulunur. Cz'den %20 arkaya gidilerek Pz belirlenir. Pz den bir %20 daha arkaya doğru gidilince Oz bulunur. Cz den geçen iki dış kulak yolu (targus) arasındaki uzaklık ölçülür. Cz elektrotundan bu uzaklığın

%20 si kadar sola ve sağa gidilerek sırasıyla C3 ve C4 belirlenir. C3 ve C4'den %20 daha gidilerek T3 ve T4 bulunur. Fronto-polar elektrotların burun köküne uzaklığı, nasion-inion arası uzaklığın %10'u kadar olmalıdır. Frontopolar elektrotlardan Oz'e kadar giden hattaki elektrotlar Şekil 2.15'de gösterilen oranlara göre yerleştirilebilir [46].

2.5.2. Genişletilmiş 10/20 sisteminde elektrot yerleşimleri

Dijital sinyal işlemede kolaylık sağlaması açısından 21 elektrota sahip olan 10/20 sistemi, genişletilerek aşağıda gösterildiği gibi 32 elektrotlu bir sistem haline dönüştürülmüştür.



Şekil 2.16. Genişletilmiş 10/20 sistemine göre elektrot konumları [47]

Bu sistemde sıklıkla kullanılan elektrot isimleri; Oz, O1, O2, Pz, P3, P4, P7 (T5), P8 (T6), CP3, CPz, CP4, TP7, TP8, Cz, C3, C4, T7 (T3/C7), T8 (T4/C8), FC3, FCz, C4, FT7, FT8, Fz, F3, F4, Fp1, Fp2 olmaktadır.

2.5.3. Referans ve toprak elektrotlarının yerleşimi

Unipolar EEG kaydında referans her iki kulak memesine (Şekil 2.16 da A1 ve A2) yerleştirilen elektrotların birleştirilmesiyle elde edilebilir. Ayrıca, 2.2.2.2 başlığı altında anlatılan kulak elektrotu kullanılarak, EEG kaydı yapılan kişi her iki kulak memesinden topraklanır.

2.6. EEG Kayıtlarını Bozucu Faktörler (Artifaktlar-Parazitler)

EEG kayıtları sırasında, beynin dışındaki çeşitli ortamlardan kaynaklanan artifaktlar (parazit veya gürültü) doğru bir şekilde ölçüm yapılmasını engeller. Ölçümlerin daha net görülebilmesi için, elde sinyallerin işleme aşamasından önce bu artifaktların sinyalden ayıklanması gerekir [48].

Artifaktlar çeşitli nedenlere bağlı olarak oluşabilir. Bunlar kimi zaman deneğe, kimi zaman kayıt cihazına ve elektrik şebekesine bağlı olarak gelişir. Temel olarak; biyolojik Artifaktlar (göz hareketleri, EKG ve pulsasyon, terleme, kas kasılması), harekete bağlı artifaktlar, elektrotlara bağlı artifaktlar, şebekeye bağlı artifaktlar (radyo dalgaları, elektrostatik artifakt, şehir cereyanı gürültüsü) ve cihazından kaynaklanan artifaktlar şeklinde 5 gruba ayrılabilir.

2.6.1. Biyolojik artifaktlar

Biyolojik artifaktlar genelde göz ve göz kapağının hareketine, kalp atışlarına (EKG), terleme, kas kasılması gibi etkenlerden kaynaklanmaktadır [26, 49].

2.6.1.1. Göz ve göz kapağının etkisi


Göz ve göz kapağının hareketlerine bağlı olarak ortaya çıkan ve en sık karşılaşılan artefakt tipidir. Göz küresinin hareketiyle ortaya çıkar veya göz kırpma sırasındaki kas aktivitesine bağlı olarak oluşurlar. Göze ait hareketlerin etkisi daha çok beynin frontal lobunda meydana geldiği gibi parietal bölgede de görülebilmektedir.



Şekil 2.17. Göz ve göz kapağının etkisi ile oluşan artefaktlar [49]


2.6.1.2. Kardiyak artefaktlar (EKG etkisi)

Kardiyak artefaktlar içinde en sık görülen ve problem oluşturan kısım, QRS kompleksinden kaynaklanan EKG artefaktıdır. EKG nin bu kısmı EEG'ye yansiyarak çok hızlı bir keskin veya dikensi dalgaya benzer bir şekil alabilir.



Şekil 2.18. Kardiyak artefaktlar [49]


Ayrıca elektrot nabız veren bir damarın üzerine yerleştirildiğinde pulsasyon adı verilen EKG'ye bağlı bir diğer artefakt gözlenir. Bu durumda elektrodun yeri hafifçe değiştirilerek gerekli düzeltme yapılır.



Şekil 2.19. Düşük ve yüksek genlikli pulsasyon artefaktları [49]

2.6.1.3. Terlemenin etkisi


Ter bezlerinin aktivitesine bağlı olarak meydana çıkan artefaktlardır. 4 saniyede bir dalgalık (1/4 Hz) yavaş bir salınım şeklindedir.



Şekil 2.20. Terlemeye bağlı oluşan artefakt [49]

2.6.1.4. Kas kasılmasının etkisi


Hızlı ve ritmik elektriksel deşarj şeklindeki artefaktlardır. Frekansları 100 Hz e ulaşabilir. Sıklıkla beynin frontal ve temporal loblarında görülür. Ayrıca, kasılmış boyun kaslarına bağlı olarak occipital bölümde de görülebilir. Yutkunma hareketine ya da çiğneme kaslarına bağlı olarak oluştuğunda tüm EEG elektrotlarına yayılabilir.



Şekil 2.21. Çeşitli kas kasılmalarına bağlı oluşan artifaktlar [49]

2.6.2. Harekete bağlı artifaktlar

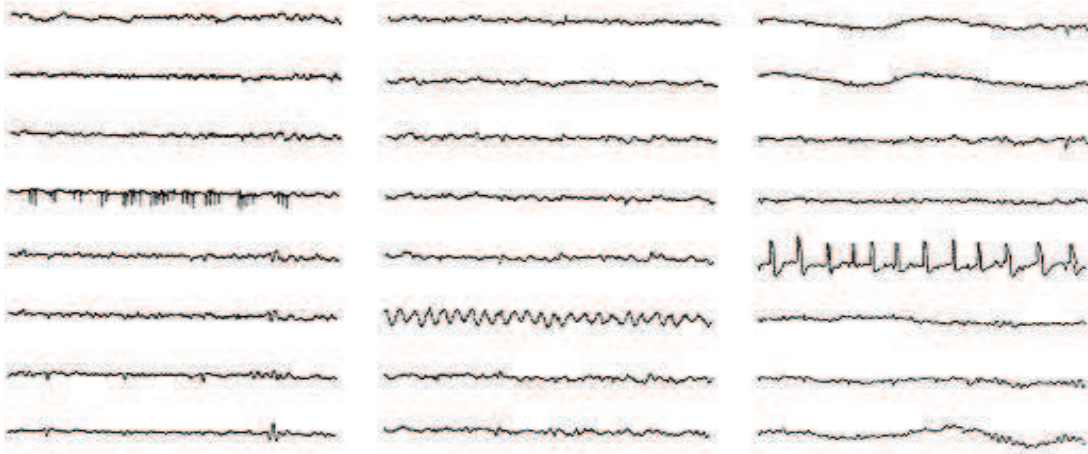
Gövde hareketi, ayak titremesi, kafa hareketi gibi vücut hareketlerine bağlı olarak gözlenen artifaktlardır. Vücut hareketleri kimi zaman kalbin vurumlarına bağlı olabilmektedir.



Şekil 2.22. Hareketlerine göre değişik artifaktlar [49]

2.6.3. Elektrotlara bağlı artifaktlar


Elektrotların bozuk ya da bağlantı kablosu hatalarından, kötü yerleştirilmelerinden, yerlerinden oynamalarından ya da aralarında meydana gelebilecek iletken bir köprü oluşumu gibi etkenlerden kaynaklanabilen artifaktlardır.



Şekil 2.23. Çeşitli elektrot artifaktları [49]

2.6.4. Şebekeye bağlı artifaktlar

Şehir elektriğindeki 50 Hz'lik salınımların EEG'ye yansması olarak tanımlanan artifaktlardır. Cihazın ya da hastanın kötü topraklanmasına bağlı olarak ortaya çıkabilir. Ayrıca elektromanyetik dalgalara bağlı artifaktlar da bu gruba dahildir. Teyp benzeri elektronik cihazlar çalıştırıldığında, elektrikli aletlerin açılıp kapatılmasıyla ya da bir asansörün hareketiyle oluşan bozucu etkilerdir. Bu gruba giren bir diğer etki de elektrostatik artifakt çeşitleridir. Elektrostatik yüklenebilen bir materyalin hızlı bir şekilde elektrotun yakınında ileri geri hareket ettirilmesi sonucu oluşur.



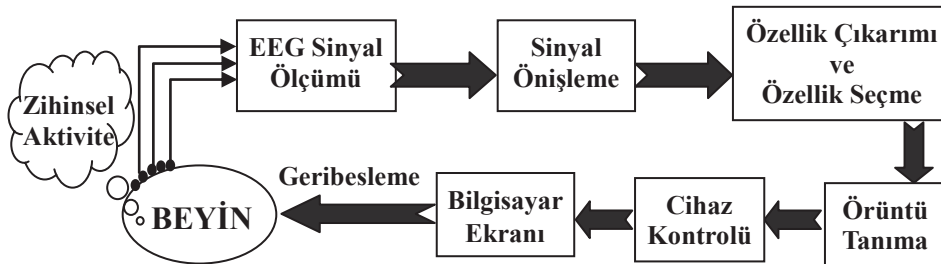
Şekil 2.24. Şebekeye bağlı artifaktlar [49]

2.6.5. Cihazdan kaynaklanan artifaktlar

Tüm diğer artifaktlar ortadan kaldırıldığında ve EEG aletinin toprak bağlantısı yapıldıktan sonra varlığını sürdüren artifaktlar cihazdan kaynaklanıyor olabilir. Bu gibi bir durumda yetkili servisten hizmet alınması gerekir.

2.7. BBA Sistemlerinde EEG'nin Yeri

BBA sistemleri kişilerin, insan beyninin doğal iletişim yolu olan çevresel sinir sistemini ve kaslarını kullanmadan dış dünya ile iletişim kurmalarını sağlama amacı taşıyan sistemlerdir. İdeal bir BBA sistemi, insanların sadece beyinlerindeki etkinliği kullanarak elektronik bir cihaza komut vermelerine olanak tanır. Bir BBA sisteminde kullanıcıların farklı beyin etkinlikleri ve bu etkinliklerin, otomatik olarak tanınması ve makine komutlarına dönüştürülmesi gerekir [50]. BBA sistemlerinin genel yapısı Şekil 2.25'de gösterildiği gibi oluşturulur.

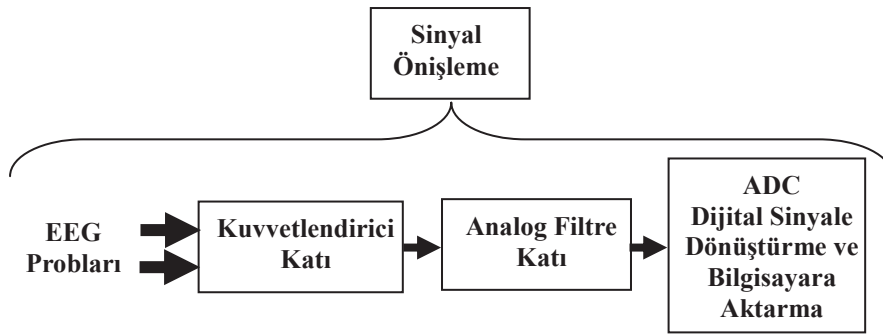


Şekil 2.25. BBA sistemlerinin genelleştirilmiş gösterimi

BBA sistemlerinde, EEG ölçümü ilk sırada yer alır. EEG sinyallerinin elde edilmesi, BBA sistemlerinin başlangıcını oluşturduğu gibi en önemli kısımlarındandır. EEG kayıtlarında sinyallerin doğru bir şekilde elde edilebilmesi çeşitli zorluklardan geçtikten sonra mümkün olmaktadır. Sinyaller elde edilirken yapılan herhangi bir yanlışlık tüm BBA sistemini temelden etkileyerek sağlıklı sonuçlara ulaşılmasını zorlaştırır. Bu nedenle EEG sinyallerinin elde edilmesi BBA sistemleri için önemli bir yer tutar [51, 52].

2.7.1. Sinyal ön işleme

BBA sistemlerinin bu kısmında, EEG sinyalleri analog sinyal olarak işlenir. Genlikleri çok düşük seviyede olduğu için sinyaller ilk olarak kuvvetlendirilir. Sinyaldeki artifaktların temizlenmesi için çeşitli filtre yapılarından geçirilir. Daha sonrada bilgisayar ortamına aktarılır. EEG sinyal ön işleme süreci genel olarak Şekil 1.26'da gösterildiği gibi gerçekleştirilir.



Şekil 2.26. EEG sinyali ön işleme süreci


2.7.1.1. EEG sinyallerinin kuvvetlendirilmesi

Kuvvetlendirici katında, μV seviyesindeki EEG sinyalleri, sinyal işleme sistemlerine uygun hale gelebilmesi ve daha detaylı analiz edilebilmesi açısından, mili volt (mV) veya volt (V) mertebelerine kadar yükseltmek zorundadır. Bu durumda uygun kuvvetlendiricinin seçilmesi, sinyali etkileyebilecek karışmaları engelleyecektir. Genellikle EEG gibi çok küçük sinyaller diferansiyel kuvvetlendiriciler yardımı ile yükseltilir. Optimum sinyal kalitesi ve sonraki sinyal işleme aşamaları için yeterli bir gerilim seviyesi sağlayabilmek ve sinyal gürültü oranını koruyabilmek amacıyla, kuvvetlendiricilerin 100 ile 100,000 arasında değişebilen bir kazanç seviyesi sağlayabilmesi uygun olacaktır [53]. Ayrıca, ortamdaki elektriksel gürültüleri bastırabilmek için diferansiyel kuvvetlendiricilerin ortak mod bastırma oranlarının (en az 100dB) ve giriş empedanslarının yüksek olması (en az 100M Ω) istenir [26].

2.7.1.2. EEG sinyallerinin filtrelenmesi


Sinyallere doğrudan etki eden DC bileşen, biyolojik artefakt (solunum, kan akışı gibi) ve şebeke gürültüleri gibi bozucu faktörlerin sinyallerden temizlenebilmesi amacıyla çeşitli filtre yapıları kullanılır. Klinik ve fizyolojik bilgi 0,5-40Hz arasında olduğu için genelde bu frekans değerlerini sağlayan filtre değerleri seçilir.

Yüksek geçiren filtre yapısı, sinyali bozabilecek olan solunum ve kan akışı gibi düşük frekans bileşenlerinin ve DC bileşen etkisinin bastırılması amacıyla kullanılır. Bu filtrelerin kesim frekansı (f_c) genellikle 0,1-0,7 Hz aralığında seçilir [26].




Şekil 2.27. Yüksek geçiren filtre karakteristiği

Alçak geçiren filtre, EEG sinyalini yüksek frekansların bozucu etkilerinden arındırmak amacıyla kullanılır. EEG bilgisi 0,5-40Hz aralığında olduğu için genelde kesim frekansları 40Hz olarak belirlenir. Ayrıca alçak geçiren filtre, sinyali örnekleme frekansının oluşturabileceği girişim etkilerinden de korumuş olur [26].



Şekil 2.28. Alçak geçiren filtre karakteristiği


DC bir kaynaktan beslenmeyen EEG sistemlerinde, şebekenin bozucu etkileri ölçülen sinyal üzerinde bozucu bir etki oluşturur. Çentik (Notch) filtre, sinyal üzerine etkileyen şebeke frekansı gürültüsünü (50Hz) bastırmak için kullanılır [26, 54].



Şekil 2.29. Çentik filtre karakteristiği

2.7.1.3. EEG sinyallerinin dijitale dönüştürülmesi

Analog sinyaller sürekli, dijital sinyaller ise ayrık zamanlı sinyal olarak bilinir. Dijitale dönüştürme işlemi, sinyalin belli zaman aralıklarıyla ölçülerek bit değerlerindeki karşılıklarının hesaplanması işlemidir. Analog sinyal genliğinin minimum ve maksimum değer aralığı, istenilen dijital çözünürlük seviyesine göre dijitale dönüştürülür [55, 56]. Şekil 1.30'da görüldüğü gibi T çözünürlük seviyesinin adımlarını ifade eder. 10 bit çözünürlük seviyesi için $2^{10}=1024$ tane T adımı mevcut olacaktır.



Şekil 2.30. Analog sinyallerin dijital olarak gösterimi [57]

EEG sinyallerinin dijitale dönüştürülmesinde dijital çözünürlük mertebesi minimum 12bit olarak seçilmelidir. Bu seviye EEG sinyalleri için $0,5\mu V$ 'luk değişimlerin yakalanabilmesi anlamını taşır [26, 55, 56]. Ayrıca örnekleme frekansı da dijitale

dönüştürülecek olan sinyal frekansının minimum 2 katı kadar olmak zorundadır (Nyquist teoremi) [57, 58].

EEG sinyallerinin elde edilmesindeki son aşamada, dijitale çevrilen sinyal verileri ileri seviyede sinyal işleme yöntemleri için bilgisayar ortamına aktarılarak kaydedilir

BÖLÜM 3. ÖZELLİK ÇIKARIM YÖNTEMLERİ ve BOYUT İNDİRGEME ALGORİTMALARI

Bu bölümde, amaçlanan sistem için kayıtlanan yön düşünel EEG sinyallerinin, hem zaman hem de frekans alanlarındaki özelliklerinin detaylı olarak incelenebilmesi amacıyla ileri düzey sinyal işleme teknikleri üzerinde durulacaktır.

İnsan beyninin odaklanma ve aktif zihinsel düşünce durumlarında, alfa ve beta frekans yoğunlukları baskın olduğu için [2, 59, 60], kaydedilen tüm sinyaller sinyal işleme ve sınıflandırma aşamalarından önce 8-30 Hz dijital band geçiren filtreden geçirilmiştir. Çalışma içerisinde sonraki tüm bölümlerde, ileri düzey sinyal işleme teknikleri için Matlab ileri düzey programlama [61] yazılımı ortamından yararlanılmıştır.

3.1. Ortalama Sinyal Gücü

Farklı zihinsel aktivasyonlar altında beynin elektriksel aktivasyonu farklılaşacaktır ve buna bağlı olarak EEG sinyallerinin ortalama güçleri de değişim gösterecektir [62]. Yön tayininin zihinsel aktivasyonlardan çıkarımının amaçlandığı bu tez çalışması içerisinde kayıtlanan EEG sinyal güçlerinin de, bilgisayar imlecinin her farklı yöne hareket ettiği düşünüldüğü durumlarda farklı olması gerektiği aşıkardır. Kayıtlanan her kanalın ortalama sinyal gücü yani sinyal enerji yoğunluğu aşağıda verildiği şekilde formüle edilir (Denklem 3.1).

$$OG = \sum_{n=1}^N \frac{X_n^2}{N} \quad (3.1)$$

Burada, X sinyalin zamandaki değerlerini, N ise sinyal uzunluğunu ifade etmektedir.

Bu yöntem ile sinyalin, zaman alanındaki güç yoğunluğu çıkarımı sağlamaktadır. Her kanaldan 2 saniyede, 4096 uzunluğunda kaydedilen EEG sinyalleri, bu yöntem sayesinde tek bileşen olarak ifade edilir. Böylece, her katılımcı için kayıtlanan 360x4096 uzunluklu zihinsel yön verileri, 360x18 boyutuna dönüştürülür.

3.2. Varyans ve Standart Sapma

İstatistikte olasılıksal bir dağılım olan varyans, bir veri setindeki her değerlerin ortalamaya göre dağılımlarını gösterir [63]. Verideki her değerlerin ortalamaya göre uzaklıklarının kareleri toplamının aritmetik ortalaması olarak formüle edilir (Denklem 3.2).

$$\sigma^2 = \frac{\sum_{i=1}^N (X_i - \mu)^2}{N} \quad (3.2)$$

Burada; X_i sinyalin zamandaki değerlerini, μ sinyal değişkenlerinin ortalamaya değerini, N ise sinyal uzunluğunu ifade etmektedir.

Varyansın sıfır olması demek veri seti içindeki tüm değerlerin aynı olduğu anlamını taşır. Sıfır olmayan tüm değerler pozitifdir. Büyük varyans değerleri veri setindeki değerlerin birbirinden ve ortalamadan uzak olduğunu ifade eder. Küçük varyans değerlerinde de bu olgunun tersi geçerlidir [63, 64].

Standart sapma ise varyansın karekökü olarak bilinmektedir (Denklem 3.3). Varyansta değerler kareleri ile ifade edilirken standart sapma ile işlem yapılırken orijinal değerler kullanılmış olur. Ortalamadan ne kadar sapma olduğunu ifadesidir. İstatistiksel olarak, standart sapmanın küçük olması ortalamadan sapmanın az olduğunu, büyük olması da ortalamadan sapmaların çok olduğunu ifade eder [65].

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (X_i - \mu)^2}{N}} \quad (3.3)$$

Zaman alanındaki EEG sinyallerinin varyans ve standart sapma değerleri, kafatasına yerleştirilen her elektrot bölgesinde farklı değerlerde olacaktır. Çünkü her zihinsel yön aktivitesi beynin farklı kısımlarında farklı seviyelerde elektriksel potansiyel meydana getirecektir. Varyansın ve dolayısıyla standart sapmanın büyük olması, kafatasına yerleştirilen elektrot bölgesindeki zihinsel aktivitenin daha yoğun olduğunu ve varyansın ve dolayısıyla standart sapmanın küçük olması ise o bölgede da daha düşük zihinsel aktivite meydana geldiğini ifade edecektir. Bu doğrultuda, varyans ve standart sapma değerleri çalışma için farklı birer belirleyici özellik yöntemleridir.

3.3. Entropi

Entropi kavramı, 1948’de elektronik mühendisi ve matematikçi olan Claude Elwood Shannon ile ortaya çıkmıştır [66]. Bilginin veya düzensizliğin matematiksel bir ifadesi olarak tanımlanabilir ve olasılık dağılımının bir fonksiyonu olarak hesaplanır. Shannon’un “H” ile ifade etmiş olduğu entropi aşağıda verildiği gibi formüle edilir (Denklem 3.4).

$$H(X) = - \sum_{i=1}^N p(X_i) \log p(X_i) \quad (3.4)$$

Burada, $p(X_i)$ mümkün olabilecek olan olasılıkları, N ise sinyal uzunluğunu ifade etmektedir.

BBA sistemlerinde entropi, sinyallerin karmaşıklık derecesinin doğrusal olmayan ölçüsü olarak ifade edilir [67]. Bir yörünge içerisinde her bir sinyalin diğer sinyal davranışlarına göre nasıl daha iyi ayırt edilebileceği bilgisini taşır. Yüksek entropi değerleri, daha karmaşık sistemleri buna bağlı olarak tahmin edilebilirlik seviyesinin azaldığını ifade ettiği gibi bu durumun tam terside geçerlidir [68]. Dolayısıyla, çalışma içerisinde zihinsel yön aktivitesi esnasında kayıtlanan EEG sinyal entropileri, her yön düşüncesinde bir diğerine göre daha az veya daha fazla olacak olup ayırt edilebilir bir özellik sağlayacaktır.

3.4. Hjorth Parametreleri

Hjorth parametreleri zamanda değişen sinyaller için etkinlik, değişkenlik ve karmaşıklık ile ifade edilen üç farklı terim olarak 1970'te Bo Hjorth [69] tarafından bilime kazandırılmıştır. Özellikle, EEG gibi sürekli zaman sinyallerinin istatistiksel özelliklerinin belirlenmesinde kullanılırlar [70] (Denklem 3.5, 3.6, 3.7).

$$Etkinlik = \text{var}(x(t)) \quad (3.5)$$

$$Değişkenlik = \sqrt{\frac{\text{var}\left(x(t) \frac{d_x}{d_t}\right)}{\text{var}(x(t))}} \quad (3.6)$$

$$Karmaşıklık = \frac{\text{Değişkenlik}\left(x(t) \frac{d_x}{d_t}\right)}{\text{Değişkenlik}(x(t))} \quad (3.7)$$

Burada; $x(t)$ sürekli zaman sinyali, $\text{var}()$ sinyalin varyansını, $\frac{d_x}{d_t}$ ifadesi de sinyalin 1. türevini ifade eder.

Hjorth parametrelerinin hesaplanması varyansa dayanmaktadır. Denklem 3.5'te görüldüğü gibi ilk parametre olan etkinlik parametresi, sürekli zaman sinyalinin ortalama gücünün bir ölçüsü olan varyansı ifade eder ve Denklem 3.2 ile aynıdır. Değişkenlik parametresi, sinyalin 1. türevinin varyansının, sinyalin varyansına oranının kareköküdür. Bu parametre, sinyalin ortalama frekansı ya da güç dağılımının standart sapma oranı hakkında bir tahminidir. Karmaşıklık parametresi ise sinyal türevinin değişkenliğinin, sinyal değişkenliğine oranıdır. Bu parametre değişkenlik parametresini içerdiğinden sinyalin 2. türevini kullanmaktadır ve sinyal frekansındaki değişimler ile ilgilidir [70-72].

Zamanda değişen EEG sinyallerindeki zihinsel yön aktivitesi özelliklerinin çıkarımı için varyans önemli bir parametredir. Hjorth parametreleri de varyans temelli

olduğundan, zaman alanı incelemeleri için varyansa göre daha sağlam bir sinyal işleme mantığına sahiptir.


3.5. Fourier Analizi

Bir sinyalin, bir fonksiyonun ya da matematiksel bir gösterimin zaman alanından frekans alanına dönüştürülmesini sağlayan kuram fourier dönüşümü (FT) olarak bilinir (Denklem 3.8).

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (3.8)$$

Burada; $X(f)$, $x(t)$ zaman sinyalinin frekans alanındaki fourier formunu ve $e^{-j2\pi ft}$ ise

Bu dönüşüm, sinyalin frekans bileşenlerinin belirlenmesi oldukça önemlidir. Ancak sinyal frekans alanına aktarıldığında zaman ifadesi kaybolup genliğe bağlı frekans değişimleri elde edilir. Fourier dönüşümü, özellikleri zaman alanında çok fazla değişmeyen sabit sinyaller olarak adlandırılan sinyaller için daha anlaşılır sonuçlar sağlar [73].



Şekil 3.1. Fourier dönüşümü


Fakat EEG sinyalleri gibi durağan olmayan, karakteristikleri sürekli değişen, sinyal başlangıç ve bitişleri belirli olmayan sinyallerin frekans analizlerinde, $X(f)$ 'nin tüm kayıtlarının frekans alanındaki dağılımlarını göstermek pek anlamlı olmayacaktır. Bu nedenle, EEG sinyallerinin fourier analizini daha anlamlı kılmak amacıyla Gabor (1946), pencereleme tekniği adı verilen daha küçük sinyal parçalarını ele alarak,

zamana bağılı olarak frekans deęişimlerini ortaya çıkarmak için fourier dönüşümünü uyarlamıştır. Bu çözüm $x(t)$ sinyalinin zamansal pencereleme fonksiyonu adı verilen “ h ” fonksiyonu ile çarpılmasıyla elde edilmekte olup (Denklme 3.9) ve kısa zamanlı fourier dönüşümü (STFT) olarak bilinmektedir [74-76].

$$STFT(t, f) = \int_{-\infty}^{+\infty} x(t)h(t - \tau)e^{-j\omega t} dt \quad (3.9)$$

Burada; $x(t)$ sürekli zaman sinyali, $h(t - \tau)$ pencere fonksiyonunu, $e^{-j\omega t}$ ise açısıl frekansın euler çarpanıdır.

STFT çözümü ile EEG sinyalleri hem zaman hem de frekans alanları üzerinde birlikte incelenmiş olur. Sinyal pencere boyutu kadar parçalara ayrılır ve her parçada FT dönüşümü hesaplanır.



Şekil 3.2. Kısa zamanlı fourier dönüşümü

STFT çözümünde zaman ve frekans çözünürlüklerinin, pencere genişliği (h) ile orantılı olduğu dikkate alınmalıdır. Zaman çözünürlüğü pencere adımlarıyla orantılı olarak deęiştirdiği gibi frekans çözünürlüğü de penceresinin band genişliği ile orantılı olarak deęişir. İyi bir zaman çözünürlüğü için kısa pencere boyutu, frekans çözünürlüğü elde etmek içinde daha uzun bir pencere boyut kullanımı uygun olacaktır [74, 77]. Çalışma içerisinde, zihinsel yön aktivitesi sinyallerinin frekans özelliklerinin her yön düşüncesi için etkin bir biçimde elde edilebilmesi için mümkün olan en uzun hamming pencere boyutu seçilmiştir.

3.6. Spektral Güç Yoğunluğu

Spektral güç yoğunluğu (PSD) ile zamanda değişen sinyaller, frekans alanına aktarılır ve sinyalin frekans aralıklarındaki güç dağılımları elde edilir [78] (Denklem 3.10).

$$P_{xx}(f) = \lim_{T \rightarrow \infty} \frac{1}{T} |X_T(f)|^2 \quad (3.10)$$

Burada; $x(n)$ ayrık zamanlı sinyali, $X(f)$ sinyalin fourier dönüşümünün ve N sinyal uzunluğunu ifade eder.

Literatürde en çok kullanılan bu PSD yaklaşımı periodogram olarak adlandırıldığı gibi [79], sinyalin PSD hesaplamaları için en çok kullanılan yöntemlerden biride Welch metodu olarak bilinmektedir [80]. Welch yaklaşımında, tek parçalı halindeki sinyaller birbiri ile çakışacak şekilde parçalara ayrılır. Bu sinyal parçaları aşağıda verildiği gibi elde edilir (Denklem 3.11).

$$x_i(n) = x(n - iD) \quad n=0, 1, \dots, M-1 \quad (3.11)$$

$$i=0, 1, \dots, L-1$$

Burada; n her parçanın uzunluğunu, i parça sayısını ve iD ise i . parçanın başlangıç noktasını ifade eder.

Denklem 4.11’de $D=M$ olduğu durumda, hiçbir parça bir diğeriyle üst üste çakışmaz. Yani, tüm sinyalden ilk parça çıkarıldığında diğer parça devam eden veri ile başlar. $D=M/2$ olduğu zaman her parça bir öncekine göre %50 oranında kaydırılarak elde oluşturulmuş olur. Yani ikinci parçanın tamamı birinci parçanın %50’lik kısmından oluşur. Aynı şekilde ardışık parçalarda bir önceki sinyal parçasının yarısını içerir. Bu olgu “overlapping” olarak isimlendirilmiştir [79, 81].

Parçalara ayrılan sinyallere, STFT yönteminde olduğu gibi pencereleme tekniği uygulanması durumunda Denklem 4.10'un formu değişmekte (Denklem 3.12) ve pencere parametresi aşağıdaki gibi formüle edilmektedir (Denklem 3.13).

$$\bar{P}_x^{(i)}(f) = \frac{1}{MU} \left| \sum_{n=0}^{M-1} x_i(n)w(n)e^{-j2\pi fn} \right|^2 \quad (3.12)$$


$$U = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (3.13)$$

Burada; M sinyal parçacığının uzunluğu, U pencere için normalizasyon parametresi ve $w(n)$ pencere fonksiyonudur.

Çalışma içerisinde Welch metodu ile birleştirilen PSD yöntemi, 8 parçaya ayrılan ve çakışmaların %50 olarak ayarlandığı durumda, EEG sinyallerinin alfa/beta frekans bandı aralığındaki spektral güç özelliklerinin çıkarımı için kullanılmıştır. EEG sinyalleri her farklı zihinsel yön aktivitesi için frekans alanı üzerinde farklı spektral güç yoğunlukları sağlayacağından, PSD metodu özellik çıkarımı için etkili bir yöntem olacaktır.

3.7. Dalgacık Dönüşümü

Dalgacık dönüşümü (WT) yöntemi, sinyallerini zamana bağlı frekans değişimlerini ele alan alternatif bir yöntem olup ilk olarak Dennis Morlet tarafından ortaya konmuştur. WT yöntemi, STFT'ye göre sinyal bileşenlerinin zaman-frekans alanındaki ilişkilerini çok daha derinlemesine ele alır [82, 83]. Özellikle EEG gibi durağan olmayan sinyaller üzerinde oldukça etkili bir yöntemdir. STFT'de çözümünde bir dezavantaj oluşturan pencere boyutu WT yöntemi sayesinde giderilir. Bu yöntemde, pencere boyutları ayarlanabilir ve sinyal boyunca değişik ölçeklerde kaydırılarak uygulanır [62].




Şekil 3.3. Dalgacık dönüşümü

WT'nin sürekli zamandaki matematiksel gösterimi şu şekilde formüle edilmiştir (Denklem 3.14).

$$W(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi^* \left(\frac{t-b}{a} \right) dt \quad (3.14)$$

Burada; $W(a, b)$ dalgacık katsayıları, $x(t)$ zaman sinyalini, $\psi(t)$ temel dalgacık fonksiyonu eşleniği, a ölçek parametresi ve b pozisyon parametresidir.



Şekil 3.4. Daubechies (db10) dalgacığı

WT yöntemi sürekli zaman sinyallerinin analizinde, çoklu genişleme ve dalgacık kaydırarak hesaplama yaptığı için çok yüksek sayıda frekans değerleri içerdiği zaman fazlalığı ve karmaşıklığı önleyemeyebilir. Bu noktada ayrık dalgacık dönüşümü yöntemi (DWT) devreye girer ve ana dalgacık fonksiyonunu belirli ayrık değerlerde dönüştürür ve genişletir [62, 84]. DWT hesaplamaları için sinyal, alçak ve yüksek geçiren filtrelerden geçirilerek alt parçacıklara ayrıştırılır ve dalgacık

katsayıları elde edilir. Bu filtreler ve aralarındaki bağıntı aşağıdaki gibi formüle edilmiştir (Denklem 3.15, 3.16, 3.17).

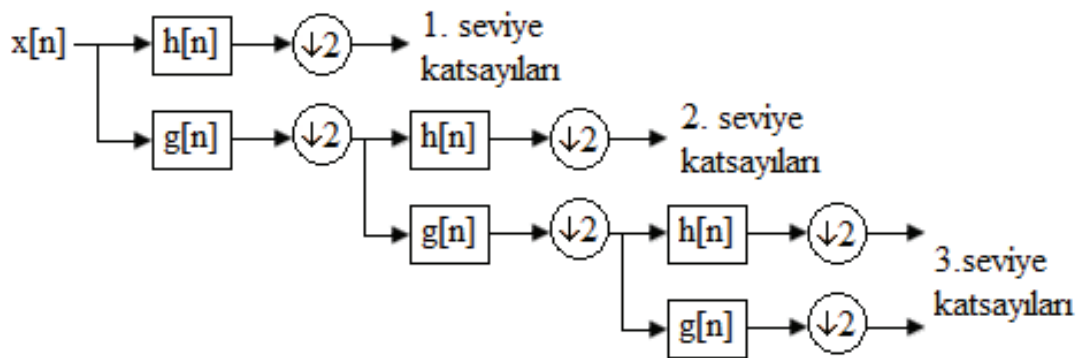
$$y_{lp}[n] = \sum_{k=-\infty}^{\infty} x[k]h[2n - k] \quad (3.15)$$

$$y_{hp}[n] = \sum_{k=-\infty}^{\infty} x[k]g[2n - k] \quad (3.16)$$

$$g(L - 1 - n) = (-1)^n h(n) \quad (3.17)$$


Burada; $x[k]$ ayrık zaman sinyali, n filtre derecesi, $h(\cdot)$ alçak geçiren filtre, $g(\cdot)$ yüksek geçiren filtre ve L filtre uzunluklarıdır.

Filtre çıkışlarında, sinyal 2 ile alt örnekleme yapılır. Yüksek geçiren filtre çıkışları istenilen band seviyesine değeriye ulaşılan kadar filtreden geçirilir. Bu sayede dalgacık katsayıları elde edilir. Alçak geçiren filtre çıkışları da ayrıntılı dalgacık katsayıları olarak bilinir [85, 86].



Şekil 3.5. DWT ile sinyalin alt parçacıklara ayrıştırılması (3 alt seviye)

Örnekleme frekansı 32Hz olan sinyal, DWT ile 3. seviyede parçacıklarına ayrılmak istendiği durumda, sinyal alt bantları Şekil 3.5'te görüldüğü gibi oluşacaktır.



Şekil 3.6. DWT ile 3. seviye ayrıştırılmış frekans bantları

Çalışma içerisinde, zihinsel yön aktivitelerinin çıkarımı için db10 dalgacığı kullanılmış ve sistemin örnekleme frekansı 2048Hz olduğundan, alfa-beta bantlarının dalgacık katsayılarını elde edebilmek amacıyla sinyal, 8. seviye alt bandına kadar ayrıştırılmıştır. Her kanal için alfa bandı dalgacık katsayıları 35 ve beta bandı dalgacık katsayıları 50 farklı değer olarak elde edilmiş olup bu bandların çıkarımı için sinyal yeniden elde edilmiştir

3.8. Temel Bileşenler Analizi (PCA)

İstatistiksel bir algoritma olan Temel bileşenler analizi (PCA), yüksek boyutlardaki verileri daha küçük boyutlara indirgemek amacıyla kullanılır ve BBA sistemlerinde çokça başvurulan bir algoritmadır. Yüksek boyutlu veri ve mekansal fazlalık verideki birkaç temel bileşenin kullanılması yoluyla azaltılır [87, 88].

PCA, kovaryans matrisin öz vektör ve öz değerlerini kullanarak X_t gibi bir data vektörünü, lineer olarak S_t gibi yeni bir vektör haline dönüştürür (Denklem 3.18, 3.19)

$$S_t = U^T X_t \quad (3.18)$$

$$C(X) = \sum_{i=1}^N \frac{(X_i X_i^T)}{N} \quad (3.19)$$

Burada; X_t sinyal vektörü, U^T öz değer vektörünün transpozisi, S_t temel bileşenler vektörü, N sinyal vektörünün uzunluğu, $C(X)$ kovaryans matrisidir.

PCA analizinde ilk olarak öz değer problemi çözümlenir ve temel bileşenler vektörünün öğeleri, sinyal vektörünün ortogonal bir dönüşümü olarak ilgili öz değerler yardımıyla hesaplanır (Denklem 3.20, 3.21). Sonuç olarak yeni hesaplanan $S_t(i)$ temel bileşenler vektörü olarak adlandırılır [89, 90].

$$\lambda_i u_i = C u_i, \quad i = 1, 2, \dots, m \quad (3.20)$$

$$S_t(i) = u_i^T X_t, \quad i = 1, \dots, m \quad (3.21)$$

Burada; λ_i kovaryans matrisinin kovaryans matrisinin (C) öz değerleri, u_i ilgili öz vektörlerdir.

PCA dönüşümü sinyali, mekansal ve zamansal fazlalıktan kurtarmış olur. Bu algorithmada veri değerleri, ortalamadan çıkarılarak merkezlenir ve temel bileşenler en büyük varyansa göre belirlenir. Çalışma içerisinde, temel bileşen analizi yardımıyla öz nitelikleri çıkarılan EEG verilerinin zamansal ve mekansal fazlalıkları temel bileşen analiz yardımıyla veriden atılmıştır. Bu sayede, verideki gereksiz fazlalık örüntü tanıma algoritmalarına ulaşmamış ve işlem yükü azaltılmıştır.

3.9. Bağımsız Bileşenler Analizi (ICA)

Kaynak işaretleri ve bu işaretlerin birbirlerine nasıl karıştıkları bilinmediği durumlarda bağımsız bileşenler analizinden (ICA) faydalanılır. Bu nedenle, ICA kör kaynak ayrışımı yapılmasını sağlayan bir yöntem olarak bilinmektedir. ICA algoritması, elde edilen işaretlerin istatistiksel olarak birbirinden bağımsız olmasını sağlayacak şekilde bir koordinat sistemi oluşturur. PCA yönteminde olduğu gibi sinyaller arasındaki benzer ilişkileri ortadan kaldırmakla kalmayıp birbirleri ile olan istatistiksel bağımlılıklarını da yüksek derece azaltır. Bağımsız bileşen olarak adlandırılan saklı faktörlerin ortaya çıkarılması için çok güçlü bir yöntemdir [91, 92].

ICA, ölçülen sinyallerin nasıl üretildiğini ortaya koyan bir model olarak ta tanımlanabilir. Bu yaklaşım, ölçülen sinyallerin bağımsız kaynakların anlık lineer

kariřımlarının bir sonucu olduđunu varsayar [87]. Dolayısıyla ICA modeli, matematiksel olarak ařađıdaki gibi ifade edilebilir (Denklem 3.22, 3.23, 3.24).

$$x_i(t) = a_{i1}s_1(t) + a_{i2}s_2(t) + \dots + a_{in}s_n(t) \quad i = 1, 2, \dots, n \quad (3.22)$$

Burada; $x_i(t)$ n farklı deđiřken iin llen lineer sinyal kariřımları, a_{in} n farklı deđiřken iin rastgele deđiřen kariřım katsayıları ve $s_n(t)$ saklı bileřenlerdir.

Bu gsterim matrisel forma dnřtrldđnde;

$$\begin{bmatrix} x_1(t) \\ x_2(t) \\ \cdot \\ \cdot \\ \cdot \\ x_n(t) \end{bmatrix} = A \begin{bmatrix} s_1(t) \\ s_2(t) \\ \cdot \\ \cdot \\ \cdot \\ s_n(t) \end{bmatrix}, \quad A = [a_{i1}, a_{i2}, \dots, a_{in}] \quad (3.23)$$

Sinyal kariřımları x ile ve saklı bileřenler de s ile gsterildiđinde;

$$x = As \quad (3.24)$$

Denklem 3.23, ICA yaklařımının matematiksel modeli olarak gsterilir [85, 93].

Bu formlasyonda, ICA yaklařımının temel amacı rastgele deđiřen kariřım katsayılarını (A) ortaya ıkarmaktır. Bu katsayıların bilinmesi durumunda saklı bileřenler (s) basit bir biimde elde edilebilir (Denklem 3.25).

$$x = A^{-1}s \quad (3.25)$$

EEG sinyallerindeki saklı bileřenler, bađımsız bileřenler analizi yardımıyla ile ıkarılmaya alıřılmıřtır. Bu dođrultuda ICA, zihinsel yn aktivitelerinin ıkarımı iin kayıtlanan sinyallerin temel bileřenlerinin elde edilmesini ve ođu artifakların (kas, gz ve kafa hareketleri gibi) yok edilerek PCA da olduđu gibi hem boyut indirgemesini hem de daha kaliteli sinyal deđerlerinin elde edilmesini sađlamıřtır.

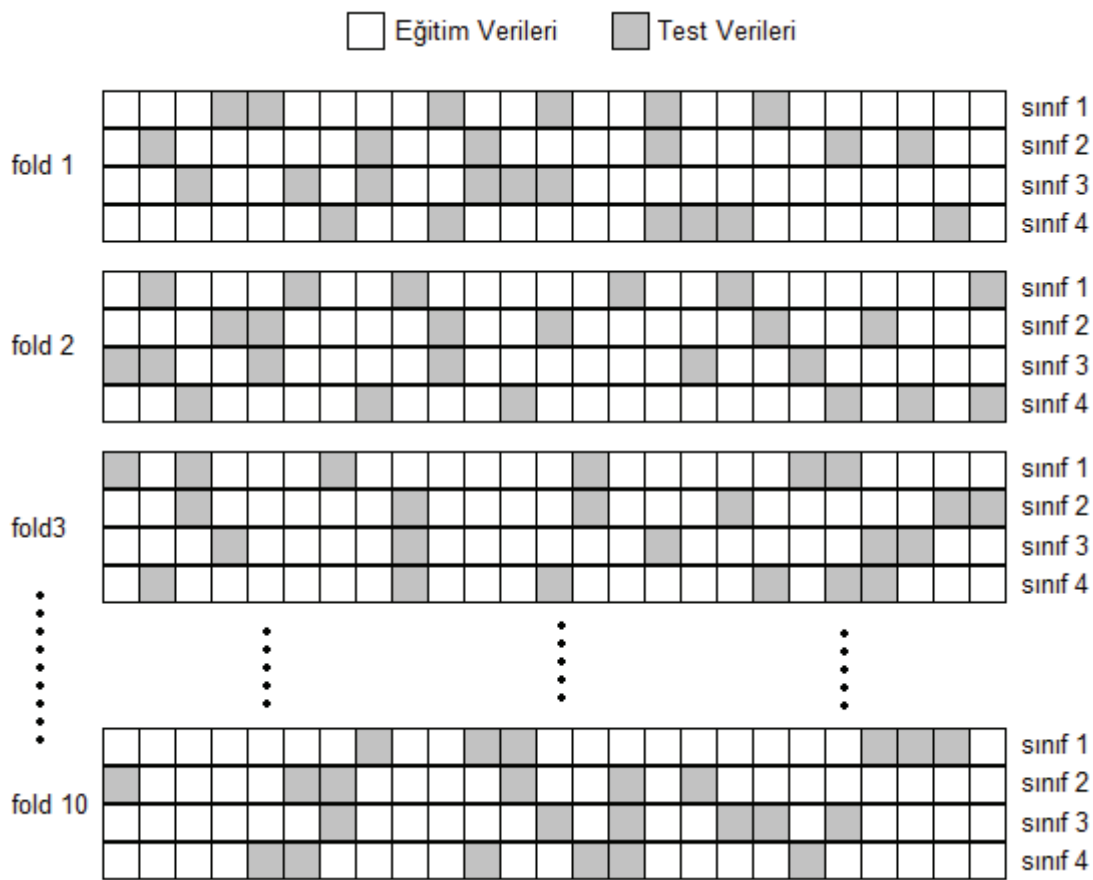
BÖLÜM 4. MAKİNE ÖĞRENME ALGORİTMALARI

Makine öğrenme algoritmaları, BBA sistemlerinin son kısmını oluşturan ve EEG sinyallerindeki örüntülerin tanınması için kullanılan bilgisayar öğrenme yöntemleridir. Kısaca insan öğrenme yetilerini bilgisayara kazandırmak olarak tanımlanabildiği gibi, bilgisayarlara karmaşık sinyal örüntülerini algılayabilme ve bu örüntülerin ait oldukları veriye dayalı bilgisayarın karar verebilme becerisi olarak ta açıklanabilir. Bu algoritmalar insan sezgisine dayalı olan gereksini ortadan kaldırır. Hesaplamalı istatistik ile yakından ilişkili olup karar verme yetisi üzerine uzmanlaşmış bir yöntemdir. Matematiksel optimizasyon metotları ve uygulamaları ile iç içe olduğu söylenebilir ve genel olarak hesaplama süreçlerinde kural tabanlı algoritma yaklaşımlarını kullanır. Çok fazla sayıdaki giriş değerleri için her birinin sahip olduğu özellik fonksiyonlarını gözleyerek ait oldukları sınıfları tahmin etme özelliğine sahiptirler. Hastalık teşhisi, medikal uygulamalar, beyin bilgisayar arayüzleri gibi uygulamalarda sinyal örüntülerinin tanınması için çokça kullanılırlar [94].

Makine öğrenme yöntemleri verinin yapısına göre ikiye ayrılabilir. Bunlardan ilki, örnek girişlere karşı istenen çıkışların verildiği yani hedef girdileri çıktılarla eşleştiren öğrenmeli yöntem kuralı üzerine kurulmuş olan denetimli ya da danışmalı öğrenme (supervised) yöntemidir. Diğeri ise, hedef girdilere karşı hiçbir çıktı verisi bulunmadığı durumda veri içerisindeki grupların belirlenmeye çalışıldığı denetimsiz ya da danışmasız öğrenme (unsupervised) yöntemidir. Bu konuda pek çok yaklaşım ve algoritma geliştirilmiş olup hepsi probleme yaklaşımlarına göre farklılık gösterir. Bu yüzden farklı problemlerde her algoritma farklı başarımlara sahiptirler. Dolayısıyla, çalışma içerisinde oluşturulması planlanan BBA sistemine en uygun olan makine öğrenme algoritmaları seçilmiş ve EEG sinyallerinden zihinsel yön aktivitelerinin çıkarımı için değerlendirilmiştir. Yararlanılan tüm makine öğrenme

algoritmaları danişmalı yani denetimli öğrenme yöntemleri üzerine kurulmuştur. Mevcut veriler kullanarak yeni kazanılan veri için en uygun model belirlenmek istenmiştir.

Ayrıca çalışma içerisinde faydalanılan tüm makine öğrenme algoritmalarında, alışıla gelmiş eğitim yöntemlerine göre (örneğin: %70 eğitim verisi, %30 test verisi) çok daha iyi ve daha güvenilir sonuçlar sağladığı için, Şekil 4.1'de gösterildiği gibi k katmanlı çapraz doğrulama (k-fold cross-validation) tekniği uygulanmıştır.



Şekil 4.1. k katmanlı çapraz doğrulama yapısı

Bu teknik ile toplam veri seti, yaklaşık olarak eşit olacak şekilde k sayıda parçaya ayrılır. Makine öğrenme yapıları k kez eğitilir ve test edilir. Her seferinde test edilecek data kısmı k parçalarının içerisinde alınır ve geri kalan tüm veriler makine öğrenme yapısının eğitimi için kullanılır. Bu doğrultuda k sayıda farklı test ve eğitim sonuçları oluşur. Bu sonuçların ortalaması, makine öğrenme yapıları için test sonuçlarını verir [94].

$k=10$ olarak seçildiği durumda makine öğrenme algoritmalarının doğrulukları, matematiksel olarak aşağı da gösterildiği gibi formüle edilir (Denklemler 4.1, 4.2, 4.3).

$$\text{doğruluk}(TS) = \frac{\sum_{i=1}^{|TS|} \text{tahmin}(n_i)}{|TS|}, \quad n_i \in TS \quad (4.1)$$

$$\text{tahmin}(n) = \begin{cases} 1 & \text{eğer } \text{tahmin}(n) = \text{sınıf} \\ 0 & \text{diğer} \end{cases} \quad (4.2)$$

$$\text{sınıflandırma doğruluğu} = \frac{\sum_{i=1}^{|k|} \text{doğruluk}(TS_i)}{|k|} \quad (4.3)$$

TS sınıflandırılacak olan test verisi (her bir k parçası), n test seti içindeki sınıflandırılacak olan her veri, sınıf test seti içindeki her n değerinin ait olduğu sınıf, $\text{tahmin}(n)$ makine öğrenme algoritmasının bulduğu sınıf değeridir.

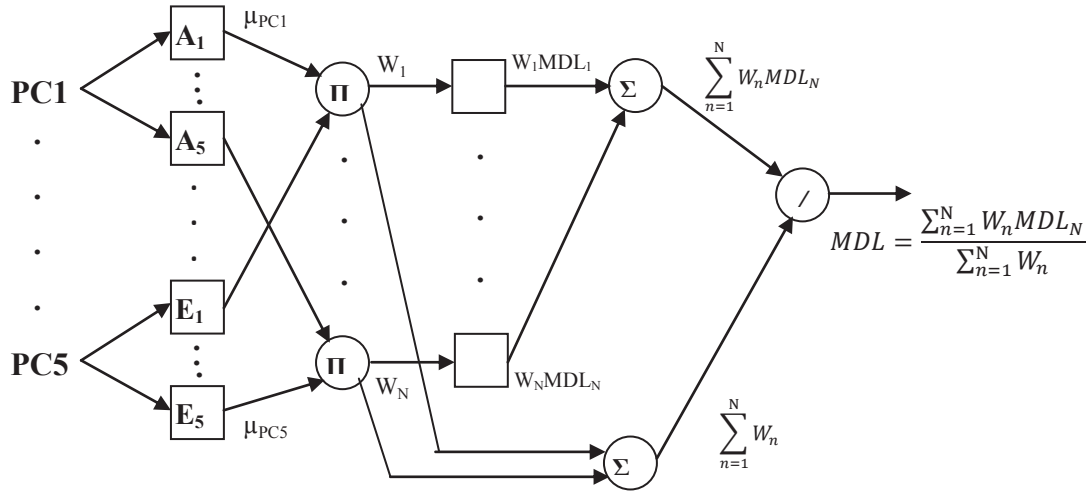
4.1. Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sistemi (ANFIS)

Adaptif ağ tabanlı bulanık mantık çıkarım sistemleri (ANFIS), yapay sinir ağları ve bulanık mantık çıkarım sistemlerini birleştiren ve her ikisinin de yeteneklerine sahip olan bir algoritmadır. İşlevsel olarak bulanık çıkarım sistemlerine eşdeğerdir. Akıllı kontrol, sinyal işleme, örüntü tanıma ve sınıflandırma uygulamaları gibi karmaşık problemlerinin çözümü için sistem parametrelerini girişlerin özelliklerine göre şekillendiren bir yapıya sahiptir [95]. Sugeno tipi bulanık mantık yapılarında çıkış üyelik fonksiyonları hem lineer hem de sabit olabildiğinden, ANFIS üyelik fonksiyonları ve sistem parametreleri genel olarak bu yapıyı kullanır [96]. EEG sinyallerindeki örüntülerden yön tayini yapılabilmesi için tasarlanan ANFIS yapısı, blok diyagram olarak aşağıda görüldüğü gibi oluşturulmuştur.



Şekil 4.2. Tasarlanan ANFIS yapısının blok diyagramı

Sabit çıkış üyelik fonksiyonu kullanan Sugeno bulanık çıkarım tabanlı ANFIS yapısı da Şekil 5.3’de verildiği gibidir.



Şekil 4.3. Sugeno bulanık çıkarımı temeline dayalı ANFIS yapısı

ANFIS yapısında girişler genel olarak en fazla 5 olabilmektedir. Daha fazla giriş değerinde, işlem yükü çok çok fazlaştığından ANFIS sonsuz döngüye girer. Dolayısıyla pek çok giriş barındıran sinyal işleme yöntemlerinde, ANFIS verimliliği ve sonuçlarının güvenilirliği düşük olacaktır. Çalışma içerisinde de zihinsel yön aktivitelerinin çıkarımı için kayıtlanan EEG sinyal özellikleri, PCA veya ICA yöntemleri ile 5’e indirgenmek zorunda kalmıştır. Buna bağlı olarak 5 giriş için ANFIS kuralları ve ilgili denklemler aşağıda veildiği gibi formüle edilir (Denklem 4.4, 4.5, 4.6, 4.7, 4.8).

Kural n : Eğer PC1 A_i olarak, PC2 B_j olarak, PC3 C_k olarak, PC4 D_l olarak ve PC5 de E_m olarak ifade edilebilirse;

$$MDL_n = p_n + q_n + r_n + s_n + t_n \quad (4.4)$$

$$\begin{aligned} \mu_{PC1}(n) &= A_i(PC1), \mu_{PC2}(n) = B_j(PC2), \mu_{PC3}(n) = C_k(PC3), \\ \mu_{PC4}(n) &= D_l(PC4), \mu_{PC5}(n) = E_m(PC5), \end{aligned} \quad (4.5)$$

$$W_n = \mu_{PC1}(n) \cdot \mu_{PC2}(n) \cdot \dots \cdot \mu_{PC5}(n) \quad (4.6)$$

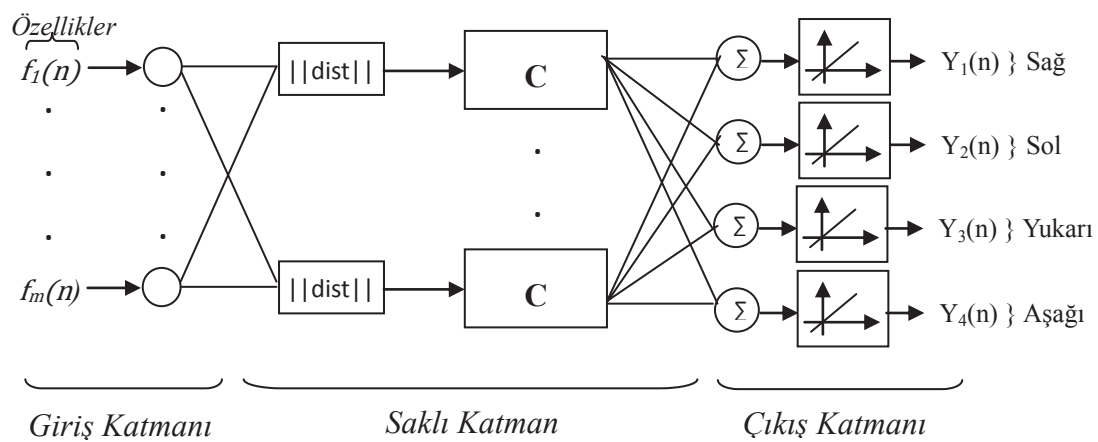
$$MDL = \frac{\sum_{n=1}^N W_n MDL_n}{\sum_{n=1}^N W_n} \quad (4.7)$$

$$C = \begin{cases} 1 & \text{eğer } MDL \leq 1 & \text{Sağ} \\ 2 & \text{eğer } 1 \leq MDL \leq 2 & \text{Sol} \\ 3 & \text{eğer } 2 \leq MDL \leq 3 & \text{Yukarı} \\ 4 & \text{eğer } 3 \leq MDL \leq 4 & \text{Aşağı} \end{cases} \quad (4.8)$$

Burada; $PC1$, $PC2$, $PC3$, $PC4$ ve $PC5$ örüntüsü çıkarılacak olan EEG girişlerini, MDL zihinsel yön seviyelerini, p_n , q_n , r_n , s_n ve t_n ANFIS tarafından tanımlanan parametreleri, A_i , B_j , C_k , D_l ve E_m bulanık mantık üyelik fonksiyonlarını, i , j , k , l , m üyelik fonksiyonları indeksini, N bulanık mantık kural sayısını ve C ANFIS tarafından bulunan zihinsel yön sonuçlarını (sağ, sol, yukarı, aşağı) ifade eder.

4.2. Öğrenmeli Vektör Kuantalama (LVQ)

Öğrenmeli vektör kuantalama (LVQ) yapay sinir ağı modellerinden biridir ve sınıflandırma algoritması, belirsiz bir veri seti ve bu veri setinden alınan örneklerinin benzerliği temeline dayanır. Bu yöntemde, eğitim verileri kümelere ayrılacak şekilde parçalara bölünür ve örnekler bu kümelere göre şekillendirilir [97].



Şekil 4.4. EEG örüntülerinin tanınması için oluşturulan LVQ yapısı

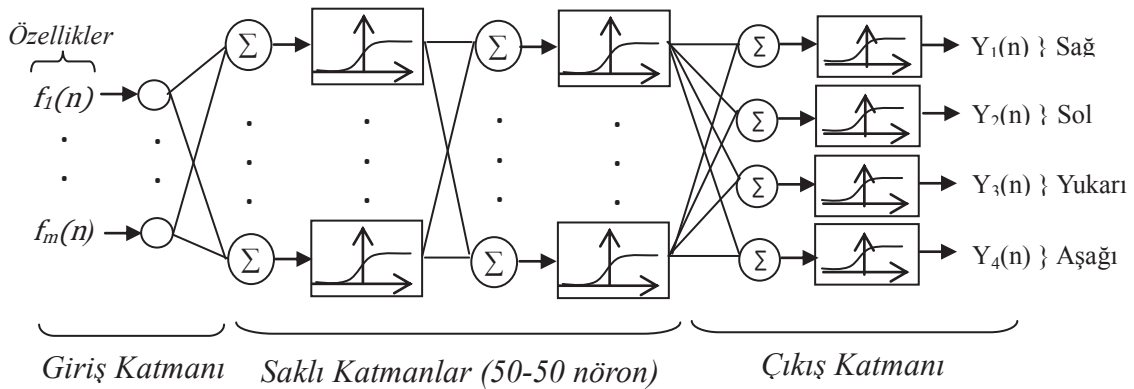
n farklı özelliğe sahip m farklı girişten oluşan giriş katmanı, saklı katman ve dört çıkışın (sağ, sol, yukarı, aşağı) gösterildiği çıkış katmanına sahip çok katmanlı bir

LVQ yapısı Şekil 5.3'de gösterildiği gibi oluşturulmuştur. Saklı katmanda, giriş vektörleri ve ağırlıklar arasındaki öklit mesafeleri ($||dist||$) hesaplanarak karşılaştırma fonksiyonları (C) tarafından giriş vektörlerinin sınıfları ağ tarafından öğrenilir. Öğrenilen değerler, lineer çıkış katmanı sayesinde ait olduğu sınıfa (zihinsel yön aktivitelerinin ait oldukları kümeye - sağ, sol, yukarı, aşağı) atanır [98-100].

4.3. Çok Katmanlı Yapay Sinir Ağı (MLNN)

Çok katmanlı yapay sinir ağı yapısı, Şekil 4.5'de görüldüğü gibi bir giriş katmanı, her katmanda 50 nöron bulunan iki katlı saklı katman ve bir çıkış katmanından oluşmakta olup, aktivasyon fonksiyonu olarak lineer olmayan sigmoid fonksiyonları kullanılmaktadır [99, 101].


Çoğu çalışmada, eğitim için geri yayılım (BP) algoritması kullanılır fakat bu algorithmada ağırlıklar dik iniş yöntemine göre güncellenir ve sık sık uygun olmayan çözümler ortaya koyar. Bu sebeple, çok katmanlı yapay sinir ağlarının eğitimi için daha güçlü bir algoritma olması, daha hızlı yakınsama ve daha iyi sınıflandırma doğruluğu sağlaması açısından Levenberg-Marquardt (LM) eğitim algoritması [102] başarılı bir şekilde uygulanmıştır [98, 103, 104].



Şekil 4.5. EEG örüntülerinin tanınması için oluşturulan MLNN yapısı

Lapedes ve Farber'in [105] çalışmaları incelendiğinde, MLNN yapılarındaki saklı katman sayısının iki olarak seçilmesi yeterli görülmektedir. Birinci saklı katman girişlere bağlı özel belirleyicilerin, ikinci saklı katman ise eğitim verilerindeki genel

belirleyicilerin ortaya çıkarılmasında kullanılmaktadır [103]. Ayrıca, iki saklı katmanın yeterli olduğu görüşü çalışma içerisinde kayıtlanan verilerden bazıları kullanılarak, ağ performans fonksiyonu olarak bilinen ortalama karesel hatanın (MSE) değişimi Şekil 4.6'da görüldüğü gibi farklı nöron sayıları ile hesaplanmıştır.



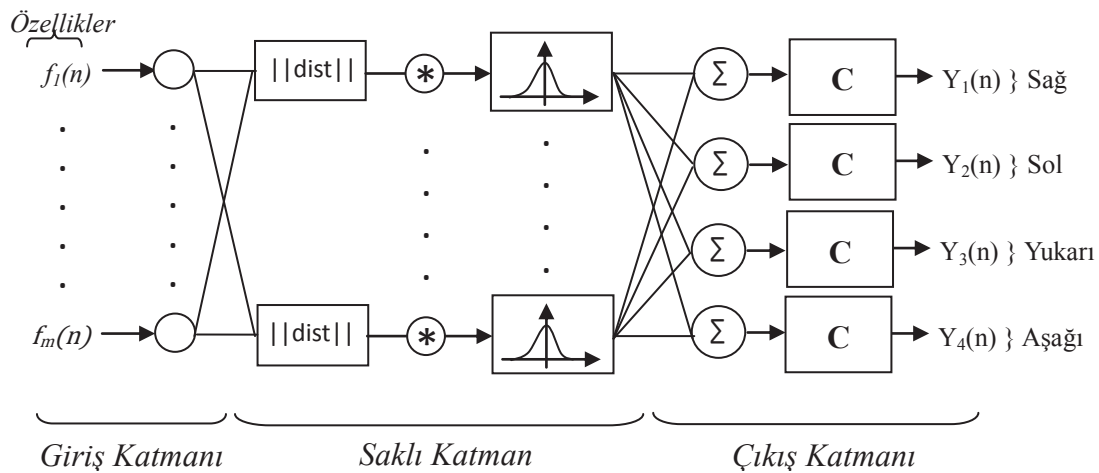
Şekil 4.6. Saklı katman sayısı ve nöron oranlarının MSE üzerine etkisi

En optimal sonucun yani ortalama karesel hatanın en küçük olduğu ilk noktanın iki saklı katmana sahip ağ yapısında ve her katmanda 50 nöron bulunduğu durumda elde edildiği görülmektedir. Bu durumda ortalama karesel hata 0.0517 olarak hesaplanmıştır. Aynı durum iki saklı katmanlı ağ yapısında 60 nöron kullanıldığı durumda da gerçekleşmekte ve ortalama karesel hata en küçük değere ulaşmaktadır. Ancak, nöron sayısı ve katman sayısı arttıkça ağ yapısı gereği eğitim süresi ve gereken depolama miktarı arttığından [106] iki saklı katmana sahip ve her katmanda 50 nöron bulunan MLNN yapıları uygun ve yeterlidir. Ayrıca, tek saklı katmana sahip ağ yapısı için 60 nöron kullanıldığı durumda hesaplanan ortalama karesel hata da 0.0556 olarak hesaplanmıştır. Bu sonuç en küçük değere oldukça yakındır ve eğitim için tek saklı katmana sahip 60 nöronlu ağ yapısı da kullanılabilir.

4.4. Olasılıksal Yapay Sinir Ağı (PNN)

Olasılıksal yapay sinir ağı (PNN), Donald Specht [107] tarafından istatistiksel olasılık yoğunluk fonksiyonunun çok katmanlı ağlara uygulanmasıyla oluşmuştur. Kazanan hepsini alır mantığı üzerine oluşturulan bir ağ yapısıdır. Rekabete dayalı öğrenme temelli olup Bayes teorisi olarak bilinen olasılık yoğunluk fonksiyonlarının Parzen yaklaşımları tarafından geliştirilen yapısını içerir [108]. Bir örüntü içindeki dağılım fonksiyonlarının iyileştirilmesi için ayrı bir kontrol eğitim seti kullanır [109,110].

Çalışma içerisinde kullanılan n farklı özelliğe sahip m farklı girişten oluşan PNN yapısı Şekil 4.7’de gösterildiği gibi bir giriş katmanı, bir saklı katman ve dört çıkışın ifade edildiği bir çıkış katmanından oluşmaktadır [110, 111]. Saklı katmanda, giriş vektörleri ve ağırlıklar arasındaki öklit mesafeleri ($\|dist\|$) hesaplanarak radyal temelli aktivasyon fonksiyonları üzerinden çıkış katmanına aktarılır. Ayrıca, saklı katmandaki en önemli parametrelerden biri sigma (σ) olarak adlandırılan düzgünleştirme parametresidir ve bu parametre ağın ortalama karesel hatasını minimize ederek performansında doğrudan etkilidir. Çalışma içerisinde sigma değeri hesaplamalı yineleme yöntemi kullanılarak 0.01-1 aralığında [112] Matlab ileri düzey programlama ortamı (Lisans numarası : 834260) yardımıyla sınıflandırma doğruluğu en yüksek değere ulaşıncaya kadar güncellenmiştir. Çıkış katmanında ise giriş vektörlerinin örüntü sonuçları karşılaştırma fonksiyonları (C) tarafından ait oldukları sınıflara atanır [98, 104].




Şekil 4.7. EEG örüntülerinin tanınması için oluşturulan PNN yapısı

4.5. Karar Ağacı Algoritması (Decision Tree)

Karar ağacı algoritması, giriş verilerinin ait oldukları sınıfların tanımlanabilmesi için oluşturulmuş bir karar mekanizması olarak tanımlanır. Sınıflandırma ağacı ya da ilkelleştirme ağacı olarak ta bilinir. Ağacın her düğümü, ya bir sınıf ismini belirtir ya da düğümdeki test verilerine ait mümkün olan çıkışlara göre örnek uzayını bölerek özel bir test kısmı meydana getirir. Bölünen her bir alt küme yeni bir alt ağaç tarafından çözülecek olan yeni bir alt sınıflandırma problemine karşılık gelir. Başka bir ifade ile karar ağacı yönetim organizasyonunda yaprak olarak adlandırılan düğümler (sonuç düğümü) sınıf ismini barındırır. Yaprak düğümü olmayan noktalar (karar düğümü), yeni bir özellik barındırır ve bu özelliklerin mümkün olan her değeri için tıpkı ağacın dalları gibi dallara ayrılarak başka bir karar ağacı meydana getirilir. Karar ağacı algoritmasının sınıflandırma problemlerinde böl ve yönet stratejisine dayandığı söylenebilir [113, 114].

Karar ağaçlarının çalışma işleyişi, hastalık tanısı üzerine kurgulanmış basit bir örnek ile aşağıdaki gibi ifade edilebilir [115].



Şekil 4.8. Örnek bir karar ağacı yapılanması

Bu örnek incelendiğinde;

EĞER Bademcik Şişmesi = Var ise SONRA Tanı = Boğaz Enfeksiyonu

EĞER Bademcik Şişmesi = Yok & Ateş = Var ise SONRA Tanı = Soğuk algınlığı

EĞER Bademcik Şişmesi = Yok & Ateş = Yok ise SONRA Tanı=Sağlıklı

Bademcik şişmesinin olduğu ilk durumda karar ağacının yaprağı oluşturulur ve sonuç tanı olarak ortaya konur. Bademcik şişmesinin olmadığı durumda ise yeni bir alt ağaç oluşturularak karar ağacının dallanması gerçekleştirilmiştir.

Karar ağacı algoritmalarının temeli AID (Automatic Interaction Detector – otomatik etkileşim algılayıcı) yöntemi olarak adlandırılan ilk modelleme ile başlamış ve sonrasında çeşitli yöntemler geliştirilmiştir. Quinlan tarafından geliştirilen ID3 (Iterative Dichotomiser 3 – tekrarlı ikilikçi ağacı) ve C4.5 yöntemleri literatürde çokça kullanılan ve hala popüler olan karar ağacı yöntemleridir [116]. Bu yapılar evet-hayır mantığında çalışır ve ağacın yayılması, entropi hesabına dayandırarak sağlanır. Her adımda, bilgi için en düşük entropiye sahip sonuçlar seçilir. Çalışma içerisinde de, C4.5 yapısından faydalanılarak karar ağacı yardımı ile EEG sinyallerindeki zihinsel yön örüntülerinden dört temel yönün çıkarımı amaçlanmıştır.

4.6. Lineer Diskriminant Analiz (LDA)

Lineer diskriminat analizi (LDA), istatistik, matematik ve genetik alanlarındaki çalışmalarıyla tanınan R.A Fisher tarafından iki sınıflı problemler üzerine formüle edilmiş [117] olup C.R. Rao tarafından ikiden fazla sınıf içeren problemler için geliştirilmiştir [118]. LDA, istatistik ve makine öğrenmesi alanlarında iki ya da daha fazla sınıfa sahip verilerin lineer kombinasyonlarının ayırt edilebilmesi amacıyla kullanılan bir metottur. Bu yöntem, veri seti içindeki sınıfları birbirinden maksimum düzeyde ayırmaya odaklı olup, sınıflar arasındaki varyans değerini maksimum yapmaya çalışan bir yapıya sahiptir ve sınıflar arasında bir karar bölgesi ortaya koyar. Ayrıca, veri dağılımlarının daha anlaşılabilir bir forma kavuşmasında etkilidir [119].

İki sınıflı problemler için LDA formu, giriş vektörünün lineer olduğu düşünüldüğünde en basit şekli ile şöyledir (Denklem 4.9, 4.10).


$$y(x) = w^T x + w_0 \quad (4.9)$$

$$C = \begin{cases} 1 & \text{eğer } y(x) \geq 0 \\ 2 & \text{eğer } y(x) < 0 \end{cases} \quad (4.10)$$

Burada; $y(x)$ diskriminant fonksiyonu, x giriş vektörü, w özellik vektörüne ait ağırlıklar, w_0 eşik değer (bias), C sınıflardır.

Ayrıca, $y(x) = 0$ olduğu durum, karar bölgesine karşılık gelecektir ve bölge sınırı aşağıdaki gibi formüle edilecektir [115] (Denklem 4.11).

$$\frac{w^T x}{\|w\|} = -\frac{w_0}{\|w\|} \quad (4.11)$$




Şekil 4.9. İki sınıflı problemler için LDA karar bölgesi gösterimi

LDA, ikiden fazla sınıfa sahip problemlerin çözümü için temel olarak iki sınıflı problem çözümü mantığını kullanır. k sayıda lineer fonksiyon içeren k sınıflı diskriminant çözümünü dikkate alır (Denklem 4.12).

$$y_k(x) = w_k^T x + w_{k0} \quad (4.12)$$

$y_k(x) > y_j(x)$ ise, x verilerinin sınıfı $j \neq k$ için C_k olacaktır. Böylece, C_k sınıfı ile C_j sınıfı arasındaki bölge sınırı $y_k(x) = y_j(x)$ olduğu durumda oluşur ve aşağıdaki gibi hesaplanır [115] (Denklem 4.13).

$$(w_k - w_j)^T x + (w_{k0} - w_{j0}) = 0 \quad (4.13)$$



Şekil 4.10. İki'den çok sınıflı problemler için LDA karar bölgesi gösterimi

Çalışma içerisinde de, EEG sinyallerindeki zihinsel yön örüntülerinden dört temel yönün çıkarımı amaçlandığından dolayı, ikiden fazla sınıflı problemlerin çözümü için uygun olan LDA yapısı kullanılmıştır.


4.7. En Yakın k Komşuluğu Algoritması (kNN)

En yakın k komşuluğu algoritması (kNN) T. Cover ve P. Hart tarafından geliştirilmiş en temel ve basit sınıflandırma yöntemlerinden biridir [120]. kNN algoritması, birbirine yakın olan veriler muhtemelen aynı kategoriye aittir mantığı üzerine kurulmuştur. Algoritmanın amacı, yeni bir örneği daha önceden sınıflandırılmış örneklerden faydalanarak sınıflandırmaktır. Bu sınıflandırma işlemi için yeni örneğin, daha önceden sınıflandırılmış örneklerden “k” tanesine olan yakınlığı incelenir. Yeni örneğin en yakınındaki k tane örnek, çoğunlukla hangi sınıfa aitse yeni örneğinde o sınıfa ait olduğu düşünülür [115, 121].

Yeni bir örneğin sınıflandırılmış örneklere olan uzaklıklarının hesabı için farklı yöntemler var olduğu gibi en bilinen yöntem, öklit uzaklık hesabıdır [122, 123] (Denklem 4.14).

$$D(p, x_i) = \sqrt{(p - x_i)^2} \quad (5.14)$$

Burada; $D(p, x_i)$ sınıflandırılacak olan yeni bir p örneğinin, en yakınındaki k komşuları x_i ($i= 1, 2, \dots, k$) arasındaki öklit mesafesidir.



Şekil 4.11. Üç sınıflı kNN örneği (k=5)

Yukarıdaki örnek incelendiğinde, kNN algoritmasının çalışma mantığı daha basit bir biçimde anlaşılacaktır. Burada, önceden sınıflandırılmış olan kare, üçgen ve daire sınıflarının içerisine yeni bir örnek eklenmiş ve en yakın komşuluk değeri $k=5$ olarak verilmiştir. Gruba yeni katılan bu örneğin en yakın 3 komşusu kare, 1 komşusu üçgen ve diğer 1 komşusu da daire olmaktadır. kNN algoritması bu bilgiler dahilinde, yeni katılan örnek sınıfının kare olması gerektiğini belirleyecektir.

kNN algoritmasının en büyük dezavantajı, belirlenecek olan sınıfın en yakın k komşu sayısına göre değişmesidir. Bu durumda, komşulara olan yakınlıkların belirlenmesi kullanışlı bir yöntem olacaktır. Daha yakın komşular, daha uzak olanlara göre daha ön planda tutulacaktır (Denklem 4.15).

$$D(p, x_i) = \sqrt{w_k(p - x_i)^2} \quad (4.15)$$

w_k komşulara ona yakınlıkların ağırlıklarıdır.


k 'nın küçük değerlerde seçilmesi, algoritmanın verimliliğini arttıracak ama bu artış algoritmanın gürültüden etkilenmesine sebep olarak güvenilirliğini azaltacaktır. Aynı

şekilde, k değerinin büyük seçildiği durumlarda algoritmanın gürültüye olan bağılılığı azalacak fakat sınıflar arasındaki belirginlikler azalacaktır. Bu sebeple, k parametresinin etkin bir biçimde hesaplanması için çok çeşitli sezgisel tarama yöntemleri geliştirilmiştir [115, 124, 125, 126].

Çalışma içerisinde k değeri, algoritmanın en iyi sonucu sağlayana kadar hesaplamalı yineleme yöntemi kullanılarak sürekli olarak güncellenmiştir ve en iyi sonuç $k=10$ komşuluk değerinde elde edilmiştir.

4.8. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri (SVM), C. Cortes ve V. Vapnik tarafından yeni bir makine öğrenme algoritması olarak iki guruplu sınıflandırma problemleri üzerine geliştirilmiştir [127]. SVM, kernel fonksiyon temelli sınıflandırma mantığına dayanır ve lineer olarak ayrılabilen iki sınıflı özellik uzayının eğitim verileri arasındaki ayrımı maksimize eder ve Şekil 4.12'de görüldüğü gibi karar yüzeyi olarak bilinen ideal bir hiperdüzlem oluşturur [128].



Şekil 4.12. İdeal hiperdüzlem oluşturan lineer SVM yapısı

Şekilde gösterildiği gibi lineer SVM yapısının matematiksel ifadeleri aşağıda gösterildiği gibi elde edilir (Denklem 4.16, 4.17, 4.18, 4.19).

$$\{x_i, y_i\}, \quad i = 1, 2, \dots, N, \quad y_i \in \{-1, +1\}, \quad x_i \in R^n \quad (4.16)$$

x_i eğitim verilerini, y_i buna bağlı sınıfları, N veri boyutunu belirtir. Bu doğrultuda ideal hiperdüzlem aşağıdaki gibi ifade edilir.

$$(w \cdot x_i + b) > 0 \quad (4.17)$$

w ideal hiperdüzlem ağırlıkları, b ise kernel sabitidir. SVM ideal hiper düzlemi sınıflar arasındaki ayrımı maksimum yapacak şekilde ayarlar ve sınıfları aşağıdaki gibi belirler.

$$\begin{aligned} T &= \{x \in \mathbb{R}^n \mid w \cdot x + b > 0\} \\ S &= \{x \in \mathbb{R}^n \mid w \cdot x + b < 0\} \end{aligned} \quad (4.18)$$

Çok geniş bir veri uzayı için sınıfların belirlenmesi genel olarak

$$\begin{aligned} S &= \{x \in \mathbb{R}^n \mid w \cdot x + b > 0\} \\ S &= \{x \in \mathbb{R}^n \mid w \cdot x + b < 0\} \end{aligned} \quad (4.19)$$

ile ifade edilir. Burada; ϕ dönüşürme fonksiyonu olarak bilinir. Giriş verilerini daha büyük boyutlu bir veri uzayına aktarır.

Şekil 4.12’de daire içerisine alınmış olan eğitim verileri hiperdüzleme en yakın olan veriler olup destek vektörleri olarak adlandırılır. Lineer destek vektör makinesi ile ilgili çok daha detaylı bilgi [127-130] referanslarında genişçe yer almaktadır. Son zamanlarda, BBA uygulamalarında EEG sinyal örüntülerinin tanınmasında ve sınıflandırılması amacıyla en çok kullanılan popüler algoritmalarından biri haline gelmiştir.

J. A. K. Suykens ve J. Vandewalle [131] lineer yani standart SVM algoritmasını güncellemiş ve iki veya daha fazla sınıfa sahip lineer sistemlerin çözümü için en küçük kareler yöntemini (LS-SVM) kullanarak yeniden formüle etmişlerdir (Denklem 4.20).

$$U = \{x \in \mathbb{R}^n \mid w \cdot x + b > 0\} \quad (4.20)$$

Hem lineer SVM hem de LS-SVM yapılarının çözümlerinde “Lagrange” formülasyonundan faydalanılmıştır. Daha detaylı bilgi [132, 133] referanslarında genişçe yer almaktadır.

SVM algoritmaları temel olarak iki sınıflı problemlerin çözümü için ortaya çıkmış yapılardır. İki'den fazla gruba sahip olan problemlerin çözümü için farklı yöntemler ortaya konmuş olup en bilinen yaklaşımlar bire karşı bir (OvsO - one against one) ve bire karşı tüm (OvsA - one against all) yaklaşımlarıdır [134].

Bire karşı bir yaklaşımda “C” mevcut sınıf sayısı olmak üzere $C(C-1)/2$ kadar sınıflandırıcı kullanılır. Yani her iki sınıf için ayrı ayrı sınıflandırıcılar oluşturulur. Yeni gelen örnek ikili sınıflandırıcılar ile test edilir ve bu sayede en çok hangi sınıfa dahil olduğu belirlenerek o sınıfa atanır. Bire karşı tüm yaklaşımda ise mevcut sınıf sayısı “C” kadar sınıflandırıcı oluşturulur. Bu yaklaşımda kazanan hepsini alır mantığına dayalı bir sınıflandırma söz konusudur. Yeni gelen örneğin sınıfı, oluşturulan sınıflandırıcılardan birine göre daha baskındır ve sonuçta bu örnek baskın olan sınıflandırıcının belirlediği sınıfa atanır [134, 135].

Bire karşı bir yaklaşımda sınıflandırma süresi, bire karşı tüm yaklaşımına göre daha kısa ve sınıflandırma doğruluğu daha iyi olduğundan [136, 137], çalışma içerisinde EEG sinyallerindeki zihinsel yön örüntülerinden dört temel yönün çıkarımı için bire karşı bir yaklaşımı benimsenmiş ve $4(4-1)/2=6$ farklı sınıflandırıcı yapısı kurulmuştur.


BÖLÜM 5. AMAÇLANAN SİSTEMİN YAPISI

Bu bölümde tez çalışması içerisinde oluşturulan sistemin yapısı ve beyinde yöne bağlı EEG sinyallerinin nasıl oluşturulduğu konusunda bilgiler yer almaktadır.

5.1. Micromed EEG Ölçüm Sistemi


Yöne bağlı olarak beyinde üretilen EEG sinyallerindeki yön bilgisinin çıkarımı amacıyla kurulan sistemin temelini oluşturan EEG sinyal kayıtları, çoğu literatür çalışmasında olduğu gibi profesyonel bir sistem yardımıyla elde edilmektedir.

Kullanılan EEG ölçüm sistemi Micromed firmasının üretmiş olduğu, 32 kanala sahip SMR32RFO EEG sinyal ölçüm ve kayıt cihazıdır. Çalışma içerisinde kullanılan bu sistem, Şekil 5.1'de gösterildiği gibi kurulmuştur.



Şekil 5.1. Çalışmada kullanılan taşınabilir EEG ölçüm sistemi

Sistem, kendine ait bir kuvvetlendirici katı (1600uV/cm), kesim frekansları (f_c) kullanıcı tarafından seçilebilen alçak ve yüksek geçiren filtreler (0.008 - 2000Hz), şebeke frekansını bastırmak için bir çentik filtre (50Hz), maksimum 2048Hz frekansında ve 16 bit çözünürlükte bir ADC katına sahiptir. Ayrıca EEG kanallarının unipolar ya da bipolar bağlantısını kullanıcı seçimi doğrultusunda gerçekleştirebilmektedir. Cihaz üzerinde uluslar arası 10-20 elektrot bağlantı şemasını gösteren bağlantı yuvaları ve standart bir EEG başlık bağlantı yuvası yer almakta olup, istenildiği taktirde bu elektrot bağlantı noktaları yada EEG başlık bağlantı yuvası kullanılabilir. EEG başlığı, 10/20 standartlarında üretilmiş olup elektrot jeli kullanılarak kafatasına yerleştirilir. Tüm bu özellikler, Şekil 5.2’de görülen kullanıcı arayüzü (System Plus Evolution) yardımıyla istenildiği gibi bilgisayar üzerinden değiştirilebilmektedir.

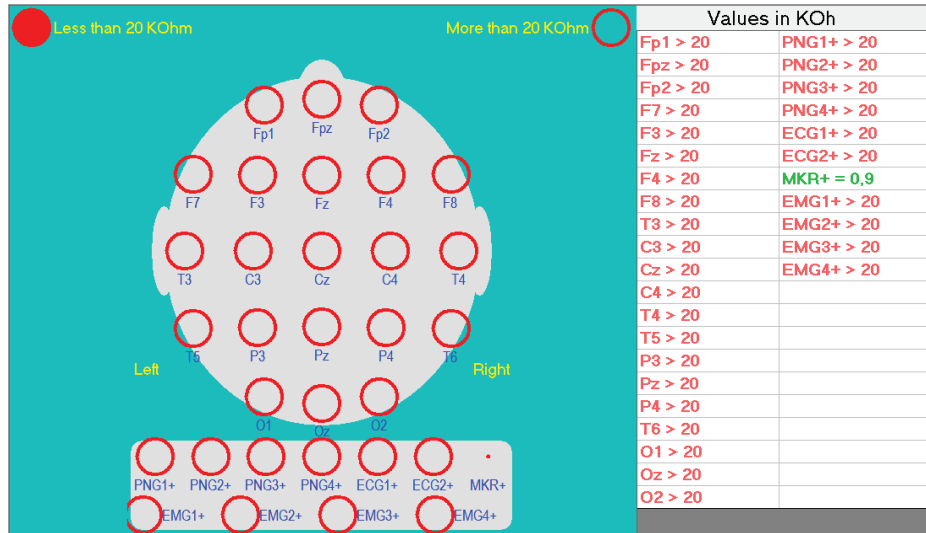


Şekil 5.2. Micromed SMR32RFO sisteminin bilgisayar arayüzü

Kayıtlanan EEG sinyalleri, seri haberleşme birimleri üzerinden bilgisayara aktarılmakta olup, bu yazılım sayesinde yukarıda görüldüğü gibi gerçek zamanlı olarak izlenebilmektedir. EEG Ölçümleri, “edf” (European Data Format) dosya formatında kaydetmektedir. Ancak sistemin tek dezavantajı gerçek zamanlı BBA kurguları için kayıtlanan sinyallerin gerçek zamanlı olarak kendi programı dışına çıkmasına imkan tanımamasıdır. Fakat EEG kayıtları bitirildikten sonra, ileri düzey sinyal işleme adımları için tüm kayıtlar ASCII dosya formatına

dönüştürülebilmektedir. Bu nedenle tez çalışması içerisinde amaçlanan zihinsel yön çıkarım sistemi kurgusunun gerçek zamanlı olarak simülasyonu yapılamamıştır.

Ayrıca, önceki bölümde açıklanan çoğu artifaktın ortadan kaldırılması ve EEG sinyallerinin daha kaliteli ve net bir biçimde yapılabilmesi için elektrotlar ile temas yüzeyleri arasındaki deri direnci değerini de Şekil 5.3’de görülen kendi arayüz ekranı üzerinden de ölçülebilmektedir.



Şekil 5.3. Micromed SMR32RFO sistemi deri direnci ölçüm arayüzü

Sağlıklı bir EEG sinyali elde edebilmek için bu direncin $5k\Omega$ 'dan düşük bir değerde tutulması gerekir [49].

5.2. Beyinde Yöne Bağlı EEG Sinyallerinin Oluşturulmasında İzlenen Yöntem

Çalışma içerisinde kullanılan EEG sinyalleri Şekil 5.4’de gösterilen ve Visual Studio ortamında tasarlanmış olan görsel arayüz üzerindeki bilgisayar imlecinin hareket düşüncelerinin hayali durumlarında kaydedilmiştir.



Şekil 5.4. EEG verileri kaydedilirken izlenen yol

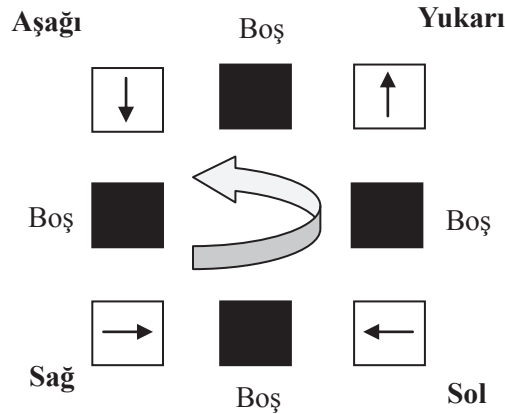
LCD monitörün orta kısmında mouse imleci ve bu imlecin sağ, sol, yukarı ve aşağı hareket ettirileceğini belirten yön çubukları yer almaktadır. Veriler, imlecin sağa hareket ettiği düşüncesinin zihinsel aktivitesi başlatıldığında kayda alınır ve sırasıyla sol, yukarı ve aşağı olarak devam eder.

Tablo 5.1. Diferansiyel elektrot çiftleri

Kanal İsimleri	Diferansiyel Elektrotlar
Kanal-1	Fp2-F4
Kanal-2	F4-C4
Kanal-3	C4-P4
Kanal-4	P4-O2
Kanal-5	Fp2-F8
Kanal-6	F8-T4
Kanal-7	T4-T6
Kanal-8	T6-O2
Kanal-9	Fz-Cz
Kanal-10	Cz-Pz
Kanal-11	Fp1-F3
Kanal-12	F3-C3
Kanal-13	C3-P3
Kanal-14	P3-O1
Kanal-15	Fp1-F7
Kanal-16	F7-T3
Kanal-17	T3-T5
Kanal-18	T5-O1

Sinyallerin kayıtlanması için tüm elektrotlar, empedansları 5 K Ω altında ve referans elektrotu sol kulakta (A1) olacak şekilde yerleştirilmiştir. Ölçümler diferansiyel (bipolar) olarak Tablo 5.1’de gösterildiği gibi uluslar arası 10/20 sistemine göre kayıtlanmıştır. Bipolar ölçüm bölgesel sinyal farklılıklarının belirlenmesi için çok daha uygun bir yöntemdir.

Çalışma içerisinde kullanılan EEG verileri, yaşları 25-32 arasında değişen sağ elini aktif kullanabilen 10 farklı erkek sağlıklı katılımcı üzerinden kayıtlanmıştır. Her bir örnek kayıt, 120sn’lik 9 kısımdan oluşmuştur. Her kısım, Şekil 5.5’de ifade edildiği LCD ekran üzerindeki imlecin hep sabit kaldığı ancak kullanıcının hareket yönü düşüncesini başlatmasını belirten yön bariyerlerinin yerinin 2 saniyede bir (sırasıyla sağ, sol, yukarı, aşağı) 1 saniye bekleme süresinden sonra yer değiştirdiği bölümler içermektedir. Bir çevrim toplam 12 sn sürmekte olup her bir kısımda kullanıcı toplam 10 kez yön döngüsünü devam ettirmektedir.

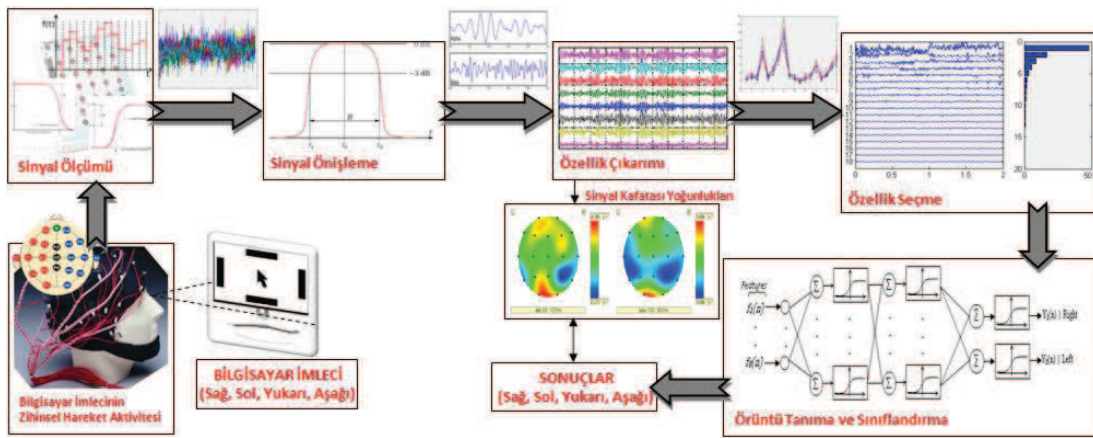


Şekil 5.5. EEG verilerinin kaydedilme protokolü

Bekleme süreleri çıkartıldığında her kısım her bir yön düşüncesinden 10, toplamda her yön düşünce aktivitesinden 90 farklı örneğin bulunduğu veri seti oluşturulmuştur. Toplamda her bir katılımcı için, 4096 örneğe sahip 18 farklı diferansiyel kanal verisi olan 360 farklı sağ, sol, yukarı ve aşağı düşünce aktivitesi içeren veri seti elde edilmiştir.

5.3. Yöne Bağlı Olarak Beyinde Ortaya Çıkan EEG Sinyallerindeki Yön Durumlarının Çıkarımı Amacıyla Kurulan Sistemin Yapısı

Amaçlanan yön çıkarım sisteminin akış diyagramı Şekil 5.6'da gösterildiği gibi oluşturulmuştur. Sinyal artefaktlarının giderilmesi için, her kanal $f_c=0.3\text{Hz}$ yüksek geçiren ve $f_c=40\text{Hz}$ alçak geçiren filtreler yardımı ile temizlenir, 16-bit çözünürlükte ve 2048Hz ile örneklenerek dijitalleştirilip kaydedilir. Ayrıca, şebeke frekansının bozucu etkisini ortadan kaldırmak için 50Hz çentik filtre kullanılır.




Şekil 5.6. Amaçlanan BBA sistemi akışı


Kayıtlanan sinyallerdeki bozucu etkiler önceki bölüm 2'de detaylı olarak ele alınan yöntemler ile sinyal ön işleme kısmında giderildikten sonra sırasıyla bölüm 3 ve bölüm 4'te detaylı bir biçimde açıklanan özellik çıkarımı ve özellik seçme yöntemleri ve örüntü tanıma algoritmaları yardımı ile EEG sinyallerindeki zihinsel yön bilgilerinin çıkarımı sağlanır.

5.4. Yöne Bağlı Olarak Beyinde Ortaya Çıkan EEG Kayıtları


Sistem yardımı ile en başarılı ve en başarısız katılımcıdan sağ, sol, yukarı ve aşağı yön zihinsel aktiviteleri esnasında kayıtlanan 18 kanal ham EEG sinyallerinin ilk 2 saniyelik bölümleri, örnek olması açısından sırasıyla devam eden şekillerde gösterildiği gibi düzgün bir biçimde elde edilmiştir.




Şekil 5.7. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SAĞ yön)




Şekil 5.8. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SOL yön)




Şekil 5.9. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (YUKARI yön)




Şekil 5.10. En başarılı katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (AŞAĞI yön)




Şekil 5.11. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SAĞ yön)



Şekil 5.12. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (SOL yön)



Şekil 5.13. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (YUKARI yön)



Şekil 5.14. En başarısız katılımcının 2 saniyelik 18 kanal ham EEG sinyalleri (AŞAĞI yön)

Örnek olarak verilen bu EEG sinyallerinden yön çıkarımlarının kestirimi imkansızdır. Kayıtlanan tüm sinyaller devam eden bölümler altında detaylı olarak irdelenerek kesin yargıya varılır.

BÖLÜM 6. YÖNE BAĞLI OLARAK BEYİNDE ORTAYA ÇIKAN EEG KAYITLARINDAN ÖZELLİK ÇIKARMA VE BOYUT İNDİRGE ME

Bu bölümde, 10 farklı kişiden zihinsel yön aktiviteleri esnasında (sağ, sol, yukarı, aşağı) kayıtlanan EEG verileri, bölüm 3'te detaylı olarak anlatılan özellik çıkarım yöntemleri ve boyut indirgeme algoritmaları ile Matlab ve System Plus Evolution programları yardımıyla ayrı ayrı incelenmiştir. Ayrıca, sinyal işleme yöntemlerine geçilmeden önce ham EEG sinyalleri Matlab ileri düzey programlama arayüzü yardımı ile 8-30Hz aralığında dijital olarak filtrelenmiştir. Tüm özellik çıkarım yöntemleri ve makine öğrenme algoritmaları her katılımcıdan kayıtlanan sinyaller üzerinde ayrı ayrı incelenmiştir.

Şekil karmaşasını ve fazlalığını önlemek adına, örnek olması amacıyla sadece en başarılı ve en başarısız katılımcılara ait sinyallerin, özellik çıkarım yöntemleri ile ön işleme sonuçları devam eden başlıklar altında verilmiştir.

6.1. Ortalama Sinyal Gücü Özelliği Kullanılarak Yapılan Özellik Çıkarma


Sinyal analizinde ortalama sinyal gücü kavramı, istatistik biliminde varyansa karşılık gelmektedir. Bu sebepten dolayı özellik çıkarım yöntemlerinde anlatılan varyans ve standart sapma özellikleri bu bölüm içerisinde ortalama güç ile birleştirilerek birlikte anılmıştır. Ortalama güç veya varyansın büyük olması, kafatasına yerleştirilen elektrot bölgesindeki zihinsel aktivitenin daha yoğun olduğunu, düşük olması ise o bölgede da daha düşük zihinsel aktivite meydana geldiğini ifade etmektedir.

Ortalama sinyal gücü özelliği ifadesi ile zamanda değişen 4096 uzunluğundaki 2 saniyelik sinyal değişimleri tek bir bileşen ile ifade edilebilmektedir. Bilgisayar imlecinin ana yönlere hareketlerinin düşünüldüğü esnada ortaya çıkan zihinsel


aktiviteler ve buna baęlı olarak elde edilen EEG sinyal enerjileri her katılımcı için saę, sol, yukarı ve ařaęı yön dūřüncelerinde sırasıyla ele alınmıřtır. Tūm katılımcılar için kayıtlanan EEG sinyalleri bōlūm 3’de aēiklandıęı gibi 18 farklı bipolar EEG kanalı üzerinden kaydedilmiřtir. Her yön dūřüncesi (saę, sol, yukarı, ařaęı) 90 farklı ōrnek barındırmaktadır.

6.1.1. En bařarılı katılımcı için elde edilen ōzellikler


En bařarılı katılımcı için zihinsel yön aktiviteleri altında kayıtlanan tūm sinyallere ait ortalama gūē daęlılımları devam eden řekillerde sıralı olarak verilmiřtir.




řekil 6.1. En bařarılı katılımcıya ait ortalama gūē yoęunlukları (SAĒ yön)



řekil 6.2. En bařarılı katılımcıya ait ortalama gūē yoęunlukları (SOL yön)



Şekil 6.3. En başarılı katılımcıya ait ortalama güç yoğunlukları (YUKARI yön)



Şekil 6.4. En başarılı katılımcıya ait ortalama güç yoğunlukları (AŞAĞI yön)


En başarılı katılımcının sağ yön zihinsel aktivitesinde en etkin kanalların 14 (P3-O1) ve 18 (T3-O1) olduğu açıkça görülebilmektedir. Ayrıca kanal 16 (F7-T3) da bir yoğunlaşma oluşmuştur. Sinyallerin bu kanallar üzerindeki yoğunlukların fazla olması, beynin o bölgedeki elektriksel aktivitesinin daha yoğun olduğu anlamına gelir. Dolayısıyla sağ yön aktivitesi için beynin sol kısmını ifade eden bu kanallarda etkinliğin oluşması normaldir. Katılımcının sol yön aktivitesinde ortaya çıkan ham sinyalleri ve buna bağlı tüm ortalama güç dağılımları da aşağıda gösterildiği gibi elde edilmiştir.

Sol yön aktivitesi için sinyal ortalama güç dağılımlarının en etkili olduğu kanallar 1 (Fp2-F4), 9 (Fz-Cz), 16 (F7-T3) ve 17 (T3-T5) dir. Beynin hem sol hem de sağ


kısımlarını ifade eden kanallarda deęişik ortalama güç daęılımların görölmekte olup, saę yön aktivitesinde meydana gelen sinyal daęılımları sol yön aktivitesi için tamamen farklılaşmıştır.

Yukarı yön aktivitesinde de en başarılı katılımcının 9, 14, 16 ve 18. kanallarda ve buna baęlı olarak bu beyin bölgelerinde daha etkin bir zihinsel yoğunluęa sahip olduęu görölmektedir. Bu durumda da beynin hem sol hem de saę kısımları farklı yoğunluklarda etkindir. Aşaęı yön aktivitesinde oluřan güç daęılımları da yine aynı beyin bölgelerinde fakat farklı yoğunluk seviyelerinde ortaya çıkmıştır. Saę, sol, yukarı ve aşağı yön aktiviteleri esnasında tüm güç daęılım çizimleri incelendięinde hepsinde bariz farklılıklar ön plana çıktığı görölmektedir. Dolayısıyla, en başarılı katılımcının zihinsel aktivitelerden yön çıkarımında iyi bir başarı elde ettięini söylemek yanlış olmaz.

Tüm zihinsel yön aktivitesi altında kayıtlanan örneklerin ortalama güç deęişimleri 360×18 boyutundaki özellik vektörü ile ifade edilmiştir. Boyut indirgemesi, PCA ve ICA uzaylarındaki veri aęırlıklarına bakılarak yapılar yani öz deęer ve öz vektörlerin hesaplanması ile ulaşılan varyans deęerleri önem taşır. Varyansı büyük olan veri ilk önceliklidir. En başarılı katılımcı için PCA ve ICA uzaylarındaki sinyallerin varyans deęişimleri Şekil 6.5’de verilmiştir. Bu yöntemler daha büyük boyutlardaki özellik vektörlerinin indirgenmesinde daha çok önem taşır. Özelliklerin varyans deęerleri birbirine yakın olduęundan sınıflandırıcıların etkilenmemesi için boyut indirgeme yapılmamış ancak sinyaller hem PCA hem de ICA uzayında dönüřtüröldükten sonra sınıflandırıcılara gönderilmiştir.



Şekil 6.5. En başarılı katılımcının ortalama güç özelliklerinin PCA ve ICA uzayındaki ağırlıkları




Şekil 6.6. En başarılı katılımcıya ait kafatası yoğunlukları


En başarılı katılımcıya ait kafatası yoğunluklarında, beynin odaklanma ve düşünce merkezi olan frontal lob üzerindeki zihinsel etkinlik durumlarında görülen beta frekansları oldukça belirgin bir biçimde ortaya çıkmıştır. Yani katılımcı, zihinsel yönelimi oldukça iyi bir biçimde meydana getirmiştir. Aynı şekilde oksipital lob üzerindeki alfa dağılımları da zihinsel yönelimlere bağlı hareket hayalinin güzel bir biçimde ortaya çıkarıldığını işaret etmektedir.

6.1.2. En başarısız katılımcı için elde edilen özellikler


En başarısız katılımcıya ait zihinsel yön aktiviteleri altında ortaya çıkan ortalama sinyal gücü değişimleri devam eden şekillerde sırası ile verilmiştir.




Şekil 6.7. En başarısız katılımcıya ait ortalama güç yoğunlukları (SAĞ yön)



Şekil 6.8. En başarısız katılımcıya ait ortalama güç yoğunlukları (SOL yön)



Şekil 6.9. En başarısız katılımcıya ait ortalama güç yoğunlukları (YUKARI yön)




Şekil 6.10. En başarısız katılımcıya ait ortalama güç yoğunlukları (AŞAĞI yön)

Sağ yön aktivitesi üzerine kayıtlanan sinyallerin oluşturduğu ortalama güç dağılımları incelendiğinde, en başarısız katılımcı için beyin sinyallerinin en aktif olduğu bölgenin 7. kanal civarı olduğu görülmektedir. Yani beynin sağ tarafı daha etkindir ancak bu istenen bir durum değildir. Sol yön aktivitesi için Şekil 6.8’de görüldüğü gibi beynin sağ kısımlarının aktif olduğu ön plana çıkmıştır. Ayrıca güç yoğunlukları sağa göre daha yüksek seviyelerde oluşmuştur.

Yukarı yön aktivitesinde ise güç değişimlerinin beynin hem sağ hem sol kısımlarını ifade eden kanallar üzerinde olduğu ancak bu oluşumun zaman zaman ortaya çıktığı görülmektedir. Genel olarak zihinsel aktivitenin durağan seyrettiğini söyleyebiliriz. Aşağı yön aktivitesinde ise güç yoğunlukları hem sağ hem de sol beyin kısımlarında daha belirginleşmiştir ve daha net değişimler ortaya çıkmıştır.

Genel olarak bu katılımcı için elde edilen güç dağılımları kıyaslandığında katılımcının her defasında beynin her iki kısmında da yoğunlaşan sinyal seviyeleri mevcuttur. Bu sebeple iyi bir yoğunlaşma ve zihinsel yön etkinliği sağlayamadığını söyleyebiliriz.

Ayrıca Şekil 6.11 ile gösterilen kafatası sinyal dağılımlarında da, en başarısız katılımcının hem alfa hem de beta dağılımlarının neredeyse tüm beyin bölgelerinde var olduğu görülmektedir. Bu durum zihinsel etkinliğin ve odaklanmanın düşüklüğünden kaynaklanır. Katılımcı oldukça başarısız bir uygulama geçirmiştir.



Şekil 6.11. En başarısız katılımcıya ait kafatası yoğunlukları

Çünkü frontal lobda gözlenen ve zihinsel etkinliklerde ortaya çıkan beta dalgaları temporal ve oksipital loblara kadar dağılmıştır. Aynı şekilde alfa dalgaları da hem frontal hem de temporal loblarda yoğunluk göstermiştir. Bu sonuçlara bakılarak, katılımcının uygulama sırasında dış ortamdan gelen uyarıcılardan etkilendiği, hareket ettiği veya hareket etme eğilimi gösterdiğinden bahsetmek mümkündür.


6.2. Entropi Özelliği Kullanılarak Yapılan Özellik Çıkarma

Shannon entropisi ile bir iletinin bilgi içeriği ölçülür ve sinyallerin karmaşıklık derecesinin doğrusal olmayan bir ölçüsüdür. Bir yörünge içerisinde her bir sinyalin diğer sinyal davranışlarına göre nasıl daha iyi ayırt edilebileceği bilgisini taşır.


Bu kısımda, bilgisayar imlecinin ana yönlere hareketlerinin düşünüldüğü esnada ortaya çıkan EEG aktivitelerinin entropi dağılımları her katılımcı için sırasıyla ele alınmıştır. Entropi özelliği ile 4096 uzunluğundaki 2 saniyelik sinyal değişimleri tek bir bileşen ile ifade edilir. Her yön düşüncesi (sağ, sol, yukarı, aşağı) 90 farklı örnek barındırmaktadır.

6.2.1. En başarılı katılımcı için elde edilen özellikler

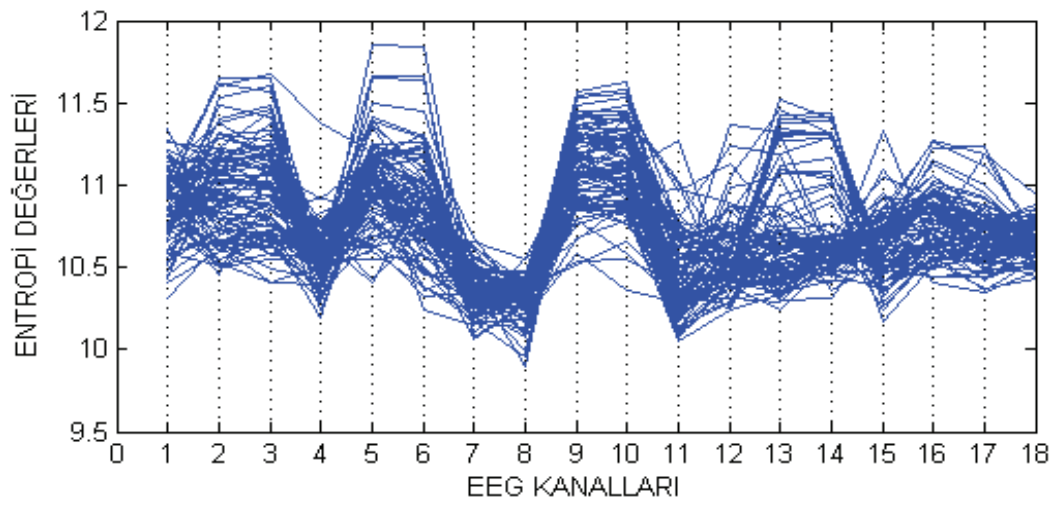
Zihinsel yön aktiviteleri üzerindeki entropi dağılımları en başarılı katılımcı için devam eden şekillerde sırasıyla gösterilmiştir.




Şekil 6.12. En başarılı katılımcıya ait entropi dağılımları (SAĞ yön)



Şekil 6.13. En başarılı katılımcıya ait entropi dağılımları (SOL yön)



Şekil 6.14. En başarılı katılımcıya ait entropi dağılımları (YUKARI yön)




Şekil 6.15. En başarılı katılımcıya ait entropi dağılımları (AŞAĞI yön)


Sağ yön aktivitesi için elde edilen sinyallerdeki entropi dağılımlarına bakıldığında bilgi içeriğinin 14 ve 18. kanallardan elde edilen sinyallerde oldukça yoğun olduğu görülmektedir. Ayrıca 1, 2, 5, 6, 9, 13 ve 16. kanallarda sinyal içerikleri değişen bir dağılım göstermektedir. Olması gerektiği gibi sağ zihinsel yön aktivite bilgisi yoğun olarak beynin sol kısımlarında baskın duruma gelmiştir. Aynı şekilde sol yön aktivitesinde de bilgi içeriğinin en belirgin olduğu bölüm 5. kanal etrafıdır. Bu da beynin sağ kısmını ifade eden bir bölgedir. 9 ve 10. kanallar etrafında da değişikliklere sahip bir bilgi ifadesi görülmektedir. Katılımcının motor hareketlerini ifade eden bir bilgi olduğu söylenebilir. Yukarı ve aşağı yön aktivitelerinde ise beynin hem sağ hem de sol kısımlarından elde edilen sinyal bilgilerinin varlığından söz etmek mümkündür. Sonuç olarak, en başarılı katılımcı için yöne bağlı oluşan zihinsel aktivitelerin farklı beyin bölgelerinde meydana geldiği görülmekte olup entropi bilgilerinden yola çıkarak katılımcının iyi bir uygulama ortaya koyduğunu söylemek yanlış olmayacaktır.

6.2.2. En başarısız katılımcı için elde edilen özellikler


Şekil 6.16, 6.17, 6.18 ve 6.19 sırasıyla sağ, sol, yukarı ve aşağı zihinsel yön aktivitesi durumlarında kayıtlanan EEG sinyallerinin en başarısız katılımcıya ait olan entropi dağılımlarını gösterir.




Şekil 6.16. En başarısız katılımcıya ait entropi dağılımları (SAĞ yön)



Şekil 6.17. En başarısız katılımcıya ait entropi dağılımları (SOL yön)



Şekil 6.18. En başarısız katılımcıya ait entropi dağılımları (YUKARI yön)



Şekil 6.19. En başarısız katılımcıya ait entropi dağılımları (AŞAĞI yön)

Sağ ve sol entropi dağılımları incelendiğinde bilgi içeriğinin en yoğun olduğu kanalların 7 ve 16. kanallar olduğu görülmektedir. Genel hatları ile iki farklı entropi dağılımları arasında küçük farklılıklar dışında gözle görülür bir değişiklik yoktur. Ancak sağ yön entropi değerleri sol yön değerlerine oranla daha düzgün bir dağılım sergilemekte olup katılımcının sağ yön üzerindeki aktivitesi sol yöne oranla daha başarılı sayılabilir.

Aynı şekilde yukarı yön aktivitesi içinde bilgi içeriği yine aynı kanallar etrafında meydana gelmiştir. Entropi dağılımları birbirlerine yakın bir duruş sergilemektedir. Tıpkı, ortalama güç özelliklerinde olduğu gibi katılımcının verimli bir zihinsel aktivasyon ortaya koyduğu söylenemez.

6.3. Hjorth Parametreleri Kullanılarak Yapılan Özellik Çıkarma


Hjorth parametreleri zamanda değişen sinyaller için etkinlik, değişkenlik ve karmaşıklık ile ifade edilmektedir. Bu parametrelerin temelinde varyans ya da ortalama güç dağılımları yer almaktadır. Etkinlik parametresi sinyallerin varyansını, değişkenlik parametresi ortalama frekansları ya da güç dağılımlarının standart sapma oranını ve karmaşıklık parametresi de sinyallerin lateralizasyonu (yerleşim) ile ilgilidir. 6.1 başlığı altında sinyal güç ya da varyans dağılımları incelendiğinden bu kısımda hjorth parametrelerinin değişkenlik ve karmaşıklık ifadeleri analiz edilmiştir. Zihinsel yön aktiviteleri esnasında kayıtlanan EEG sinyallerinin değişkenlik ve

karmaşıklık parametreleri, 4096 uzunluğundaki 2 saniyelik sinyal değişimlerinin tek bir bileşen ile ifade edilebilmesini sağlar.


Hjorth değişkenliğinin fazla olduğu bölgelerde karmaşıklık azalır. Dolayısıyla sinyal yerleşikliği düşük seviyelerde seyretmektedir ve bu durumun tam tersi de geçerlidir. Bu özelliğinden dolayı hjorth parametreleri durağan olmayan EEG sinyallerinde belirleyici bir özellik yöntemi olarak ele alınmaktadır. Hem değişkenliğin hem de karmaşıklığın zaman içindeki değişimleri katılımcılar için ayırt edici düzeydedir.

6.3.1. En başarılı katılımcı için elde edilen özellikler

Değişkenlik ve karmaşıklık parametrelerinin en başarılı katılımcıya ait hesaplamaları sonucu oluşan grafikler, sıralı olarak devam eden şekillerde gösterildiği gibi elde edilmiştir.

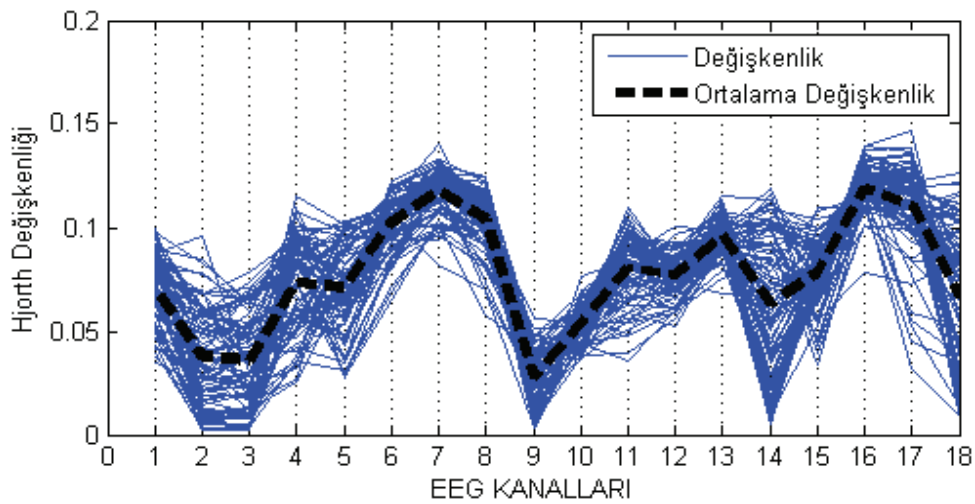


Şekil 6.20. En başarılı katılımcıya ait Hjorth değişkenliği (SAĞ yön)

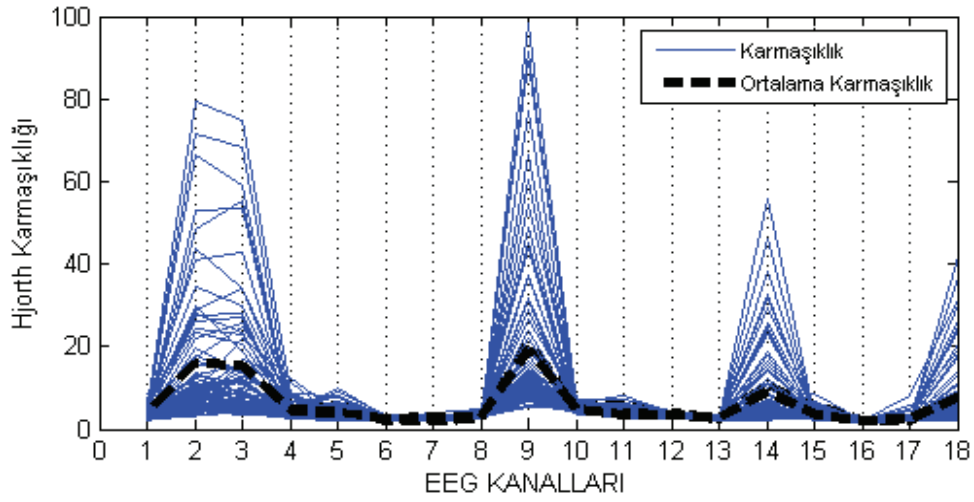


Şekil 6.21. En başarılı katılımcıya ait Hjorth karmaşıklığı (SAĞ yön)

Sağ yön üzerinde değişkenliğin etkin olduğu bölgeler 6, 7, 8 ve 16. kanallardır. Standart sapma bu bölgelerde an fazladır yani zihinsel etkinlik bu kısımlarda daha yoğundur. Karmaşıklık değerleri yani sinyal yerleşiklikleri de değişkenliği destekler nitelikte olup aynı kanallar üzerinde en küçük seviyelere kadar gerilediği görülmektedir.




Şekil 6.22. En başarılı katılımcıya ait Hjorth değişkenliği (SOL yön)




Şekil 6.23. En başarılı katılımcıya ait Hjorth karmaşıklığı (SOL yön)

En başarılı katılımcının sol yön aktivitesinin genel olarak sağ yön aktivitesinin gerçekleştiği kanallar üzerinde görülse de farklı değişkenlik ve karmaşıklık ortalamalarına sahiptir. Bu farklı değerler yön tayinleri için ayırt edici bir özellik taşır.




Şekil 6.24. En başarılı katılımcıya ait Hjorth değişkenliği (YUKARI yön)




Şekil 6.25. En başarılı katılımcıya ait Hjorth karmaşıklığı (YUKARI yön)

Aşağı ve yukarı yön değişim grafikleri incelendiğinde sinyal değişim ve yerleşimlerinin aynı kanallar üzerinde fakat farklı ortalama değerlerde meydana geldiği göze çarpmaktadır. Bu farklılık yön ayrımı için ilk bakışta belirleyici olabilir.




Şekil 6.26. En başarılı katılımcıya ait Hjorth değişkenliği (AŞAĞI yön)




Şekil 6.27. En başarılı katılımcıya ait Hjorth karmaşıklığı (AŞAĞI yön)

6.3.2. En başarısız katılımcı için elde edilen özellikler

En başarısız katılımcıya ait Hjorth hesaplamaları sonucu elde edilen şekiller sırasıyla aşağıda gösterilmiştir.




Şekil 6.28. En başarısız katılımcıya ait Hjorth değişkenliği (SAĞ yön)

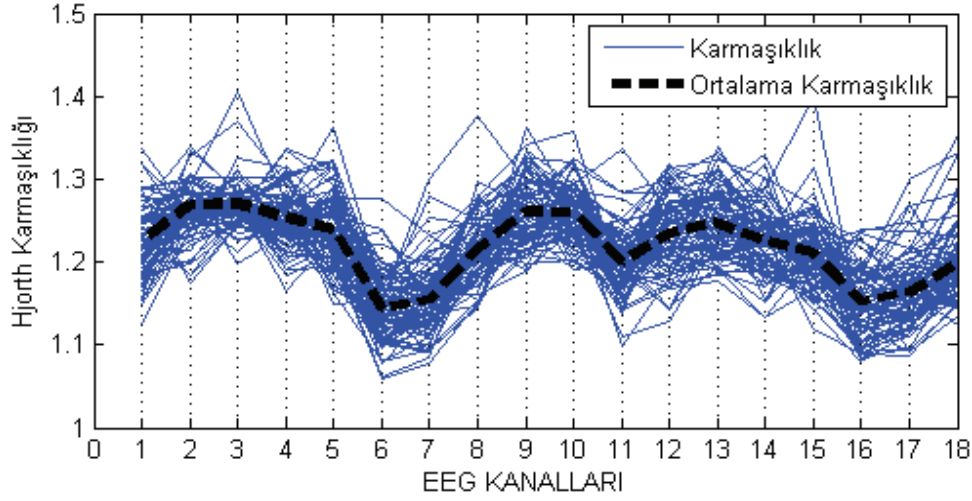


Şekil 6.29. En başarısız katılımcıya ait Hjorth karmaşıklığı (SAĞ yön)

Şekil 6.28 ve Şekil 6.29 incelendiğinde katılımcının sağ yön aktivitesi esnasında zihinsel olarak dalgalanmalar yaşadığını söyleyebiliriz. Ancak en yoğun aktivitenin 6, 7, 11 ve 15'te ortaya çıktığını söyleyebiliriz.




Şekil 6.30. En başarısız katılımcıya ait Hjorth değişkenliği (SOL yön)




Şekil 6.31. En başarısız katılımcıya ait Hjorth karmaşıklığı (SOL yön)

Sol yön zihinsel aktivite esnasında ise 16. kanalın ortalama değişkenlik ve karmaşıklık değerlerine bakıldığında, sağ yön aktivitesindeki orana oranla arttığını gözlemlenmiştir.




Şekil 6.32. En başarısız katılımcıya ait Hjorth değişkenliği (YUKARI yön)




Şekil 6.33. En başarısız katılımcıya ait Hjorth karmaşıklığı (YUKARI yön)

Yukarı yön aktivitesi durumunda da bu kez 11. kanalın yanında, 15. kanalda belirgin değişimler gözlenmektedir.



Şekil 6.34. En başarısız katılımcıya ait Hjorth değişkenliği (AŞAĞI yön)



Şekil 6.35. En başarısız katılımcıya ait Hjorth karmaşıklığı (AŞAĞI yön)

Son olarak aşağı yön Hjorth parametreleri çok küçük farklılıklar dışında yukarı yöndekilere benzer şekilde karşımıza çıkmaktadır. Bu durumu da, katılımcının aşağı ve yukarı yön aktivitelerinde pek başarılı olamadığını söyleyebiliriz.

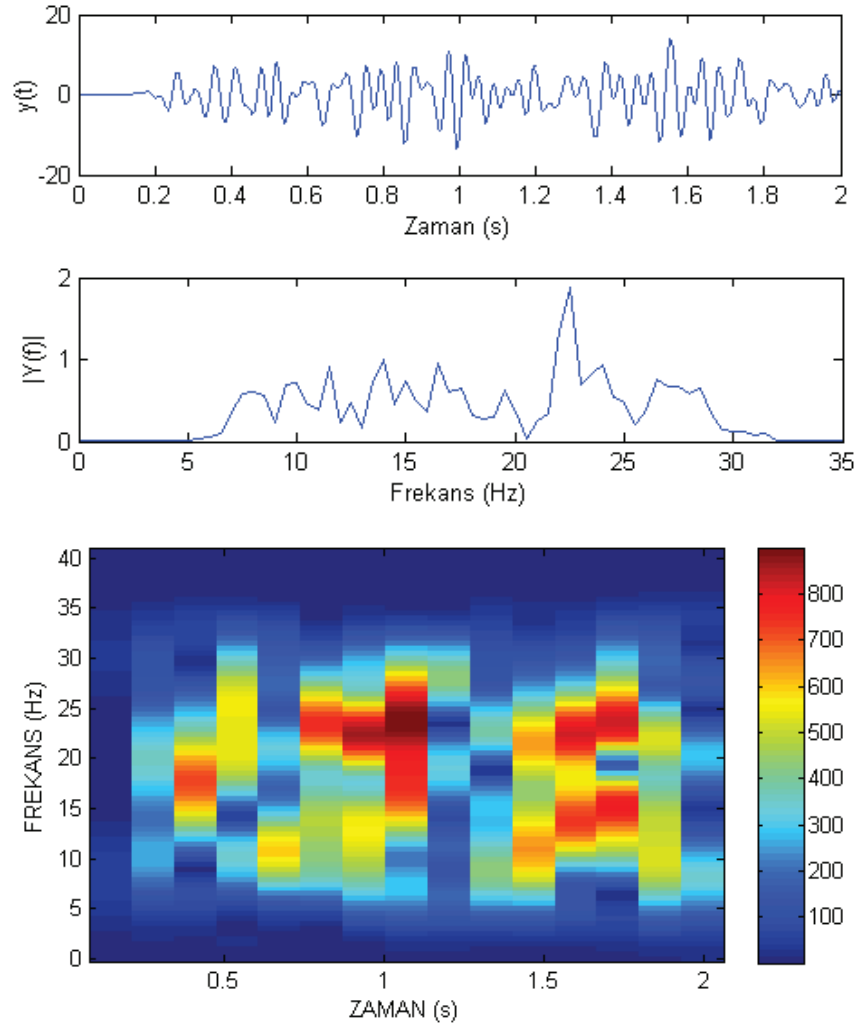
6.4. Fourier Analizi Kullanılarak Yapılan Özellik Çıkarma

Bu başlık altında zihinsel yönelimler esnasında alınan EEG sinyallerinin frekans bileşenleri üzerinde incelemeler yapılmıştır. Bu sinyallerin frekans alanındaki genlik değişimleri için FFT ve zamandaki frekans dağılımları için STFT yöntemi benimsenmiştir. Her yön aktivitesi 2 saniye süreyle kaydedilmiş 4096 uzunluklu bilgi içermekte olup, sinyal uzunluğu kadar pencere boyutu ile frekans özellikleri çıkarılmış ve STFT yöntemi ile 512 uzunluklu hamming pencere 256 adımda bir kaydırılarak işlenmiştir. Şekillerdeki karmaşayı engellemek adına en başarılı ve en başarısız katılımcılar için örnek olarak, her yön düşüncesinin ilk 2 saniyelik kısımlarda en yoğun olan EEG kanalının STFT değişimleri devam eden başlıklar altında gösterilmiştir. Frekans özellikleri çıkarılınca elde edilen özellik vektörü 360x1080 boyutuna sahiptir. PCA ve ICA algoritmaları sayesinde bu özellik vektörünün boyutu 360x175 seviyesine indirgenmiş ve elde edilen yeni özellik vektörü, tüm verilerin %99'unu kapsamıştır.

6.4.1. En başarılı katılımcı için elde edilen özellikler

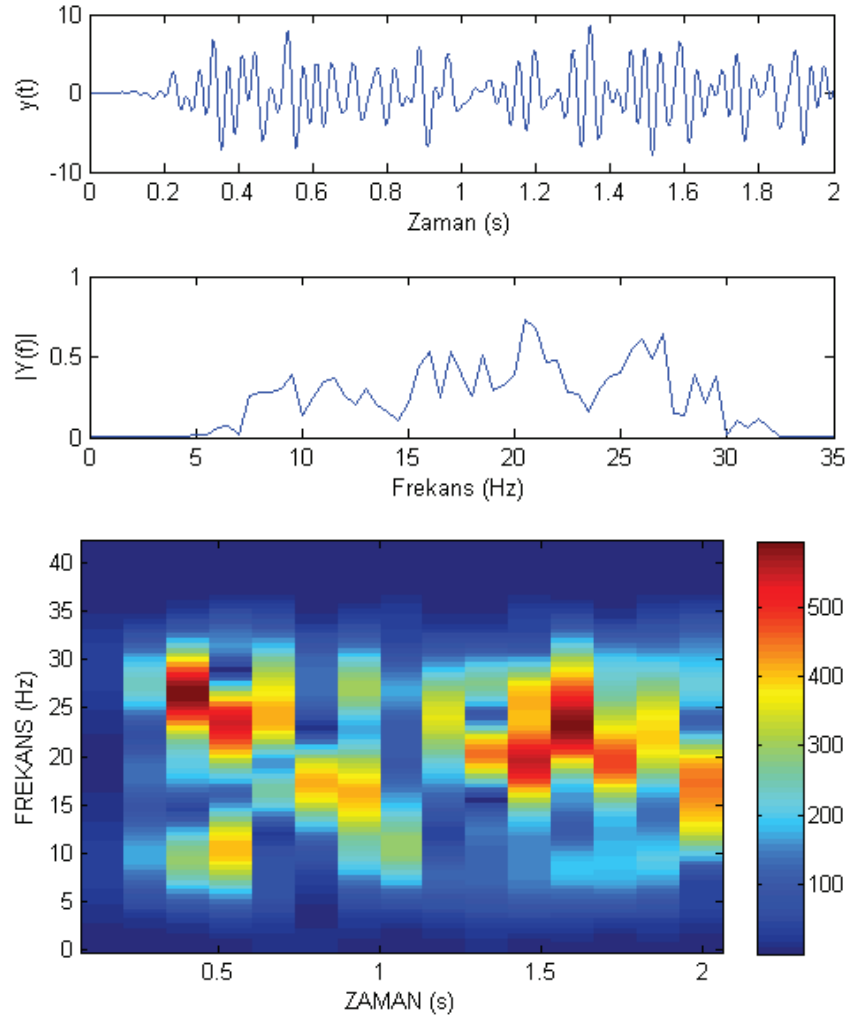
Devam eden şekillerde, en başarılı katılımcı için zihinsel aktivitenin en yoğun olduğu bölgeden kayıtlanan sinyallerin, 8-30Hz filtrelenmiş genlik-zaman, fourier dönüşümü sonucu oluşan genlik-frekans ve STFT çıkarımı olan frekans-zaman değişimleri gösterilmiştir.

Katılımcının sağ yön zihinsel aktivitesinde en yoğun olduğu beyin bölgesi ortalama güç özelliklerine göre 14. kanaldır. Bu kanal için elde edilen ilk örneğin oluşturduğu genlik-frekans ve frekans-zaman grafikleri incelendiğinde katılımcının beta badi yoğunlukları baskın bir şekilde ön plandadır. Dolayısıyla, bu örnek için sağ yön zihinsel aktivitesinin başarılı bir şekilde gerçekleştirildiği söylemek doğrudur. Aynı doğrultuda, Şekil 6.37'de ilk sol örneği için genlik-frekans ve frekans-zaman grafikleri incelendiğinde de, beta frekans bandı dağılımları hemen göze çarpmaktadır. Yine denilebilir ki katılımcı sol yön zihinsel aktivitesini de başarılı bir şekilde yerine getirmiştir.



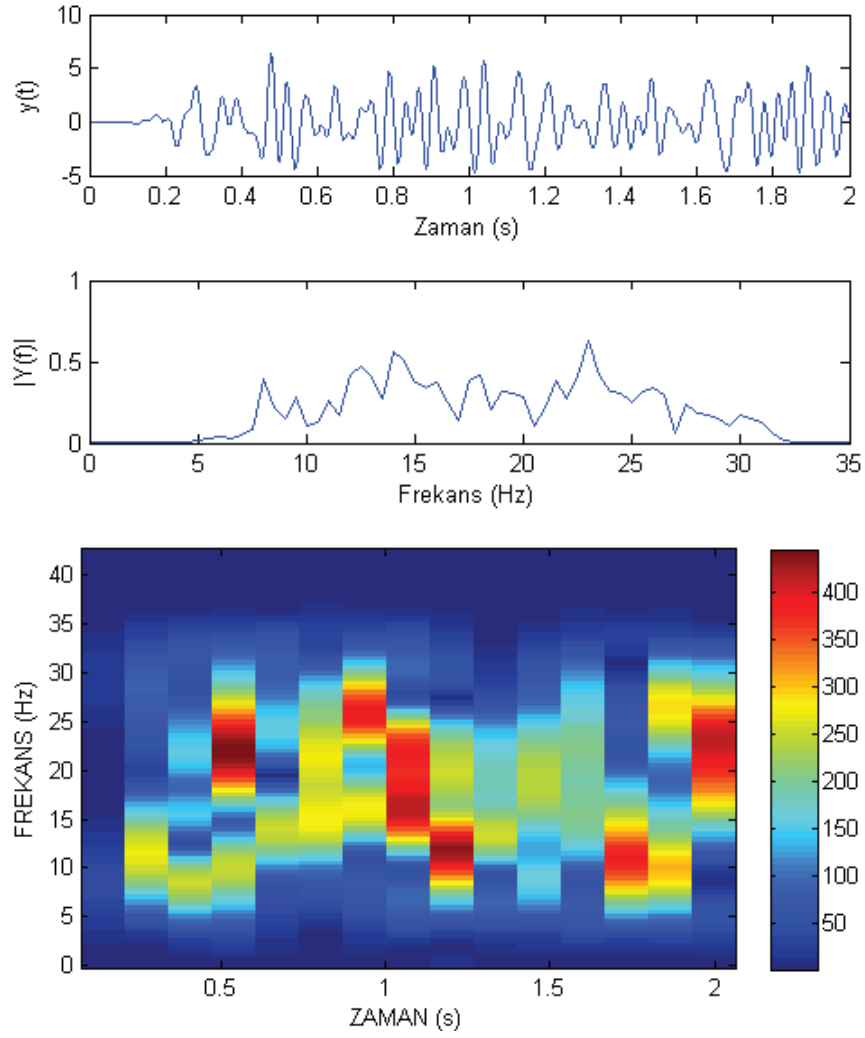
Şekil 6.36. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (SAĞ yön 14. kanal)

Yukarı yön zihinsel aktivitesi için kayıtlana ilk örnek için çıkarılan genlik-frekans ve frekans-zaman grafikleri de Şekil 6.38’de verildiği gibi elde edilmiştir. Burada belli zaman aralıklarında alfa bandı yoğunlukları gözlene de genel olarak beta bandı dağılımlarının daha fazla olduğu görülmektedir. Yani katılımcı bazen kısa süreli olarak zihinsel odaklanmasını kaybetmiş olsa da bu örnek için iyi bir zihinsel aktivite sergilemiştir.

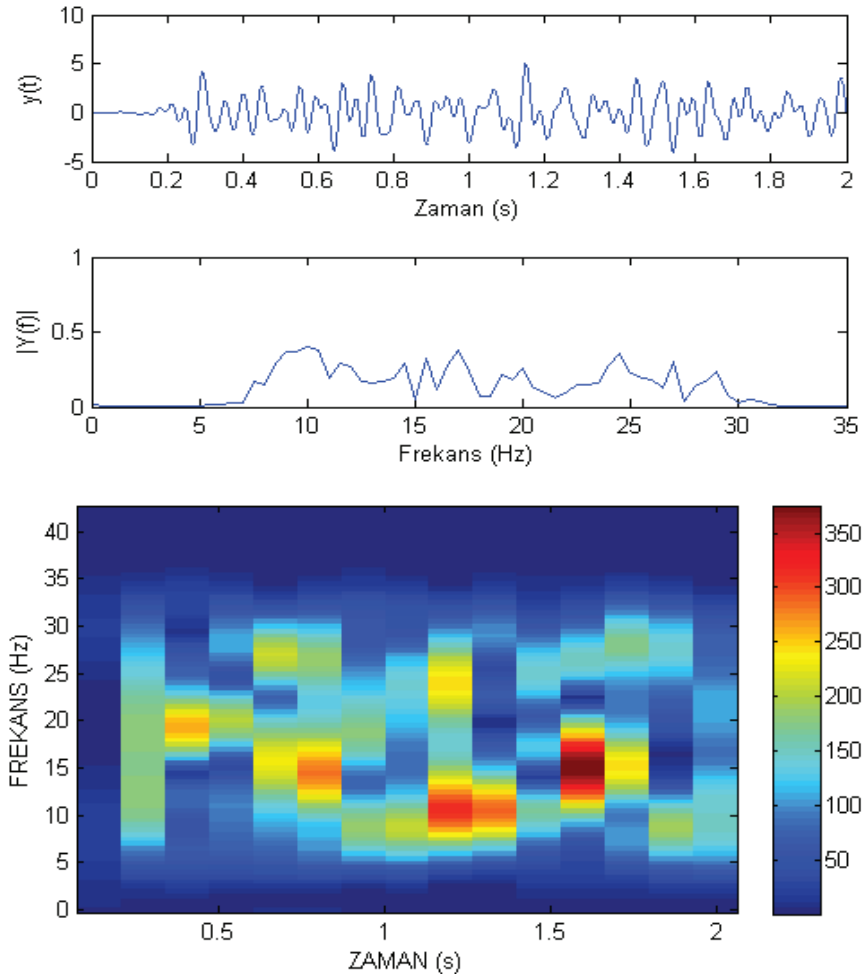


Şekil 6.37. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (SOL yön 16. kanal)

5. katılımcı için son olarak Şekil 6.39’da verilen grafiklere bakıldığında, aşağı yön zihinsel aktivitesinde alfa frekanslarının daha fazla ön plana çıktığı görülmektedir. Yani bu örnek için katılımcının uzun süreli bir odaklanma sağlayamamış olduğu söylenebilir. Genel olarak bu örnekler üzerinde katılımcının başarılı bir zihinsel etkinlik sergilediğini söylemek yanlış olmayacaktır.



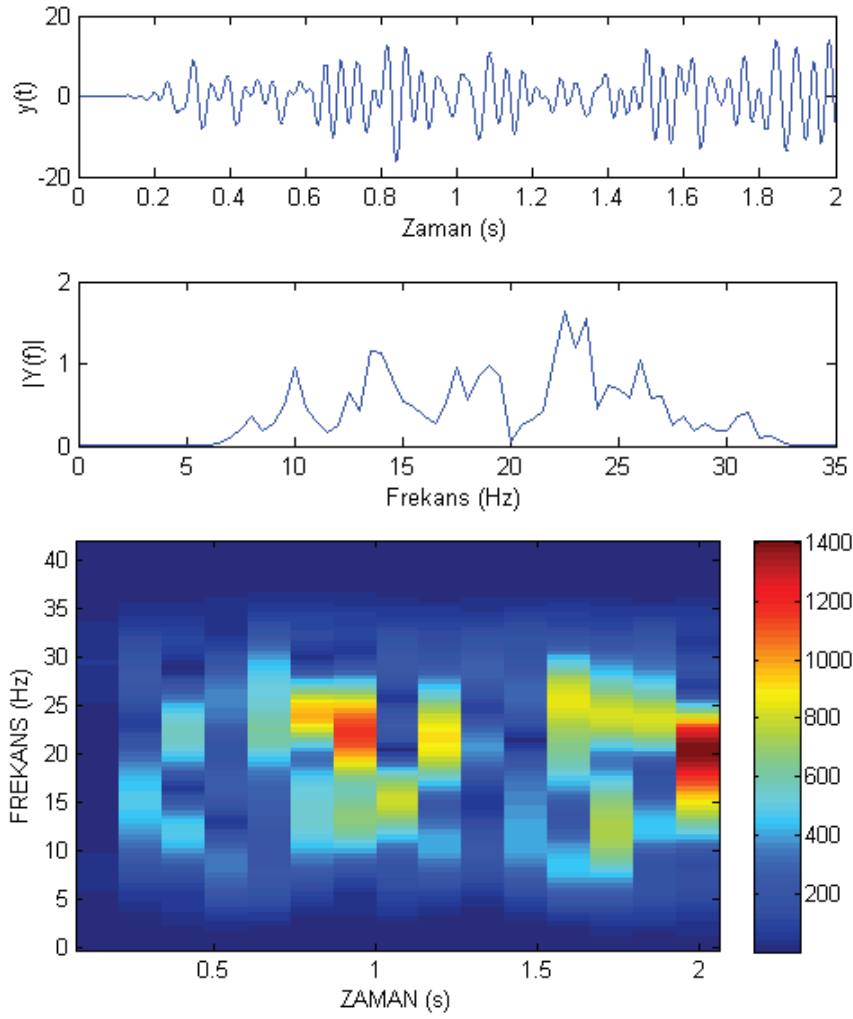
Şekil 6.38. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (YUKARI yön 16. kanal)



Şekil 6.39. En başarılı katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (AŞAĞI yön 16. kanal)

6.4.2. En başarısız katılımcı için elde edilen özellikler

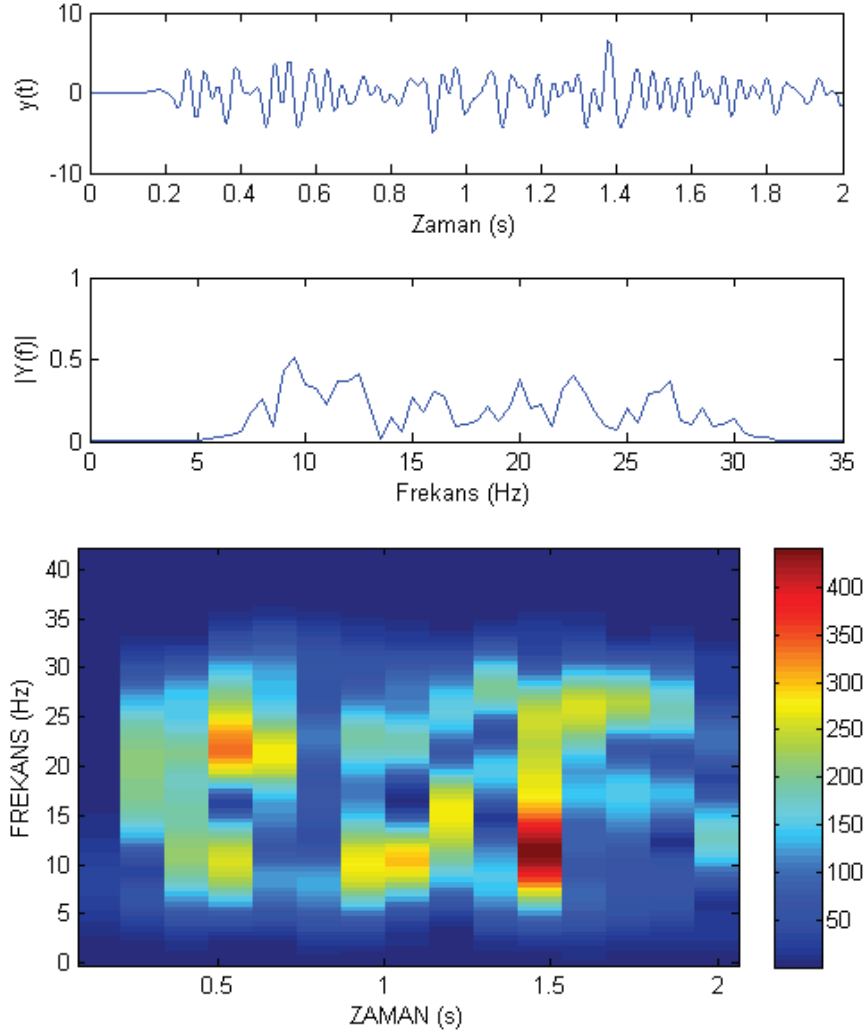
En yoğun ortalama sinyal gücü dağılımlarınının 7., 3. ve 4. kanallar etrafında ortaya çıktığı en başarısız katılımcının her zihinsel aktivite durumunda bu kanallara ait ilk 2 saniyelik örnekler altında meydana gelen genlik-zaman, genlik-frekans ve frekans-zaman değişimlerine aşağıdaki şekillerde sıralı olarak yer verilmiştir.



Şekil 6.40. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (SAĞ yön 7. kanal)

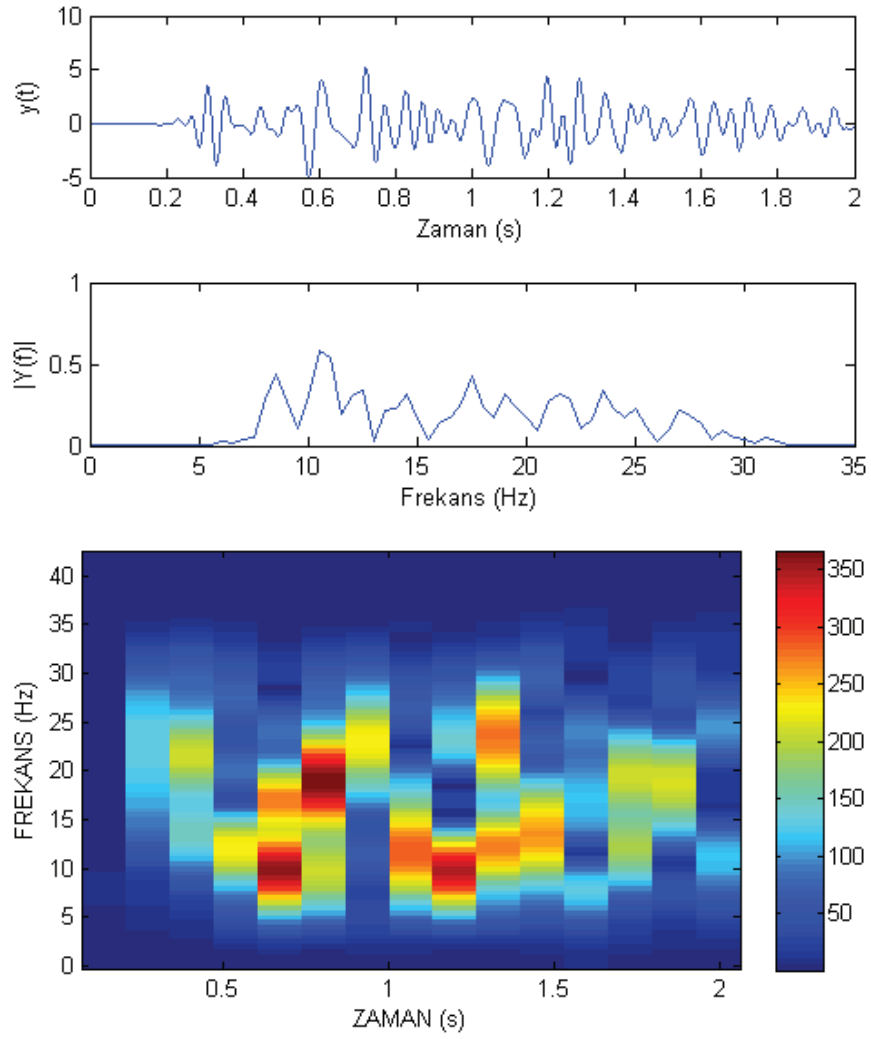
Yukarıda gösterilen ilk sağ yön düşüncesinden çıkarılan genlik-frekans ve frekans-zaman değişimleri incelendiğinde, beta frekanslarının oldukça etkili olduğu açıktır. Dolayısıyla katılımcı sağ yön zihinsel aktivitesi üzerinde bu örneğe göre çok başarılı bir uygulama sağlamıştır.

Ancak Şekil 6.41’de gösterilen ilk örnek için sol yön zihinsel aktivitesinde ortaya çıkan değişimler incelendiğinde katılımcının frekans seviyeleri ara ara beta bantlarına çıkmış olsa da alfa bandının baskınlığı seçilebilmektedir. Bu sebeple katılımcının sol yön zihinsel aktivitesinde sağ yöne oranla çok daha etkisiz kaldığı söylenebilir.



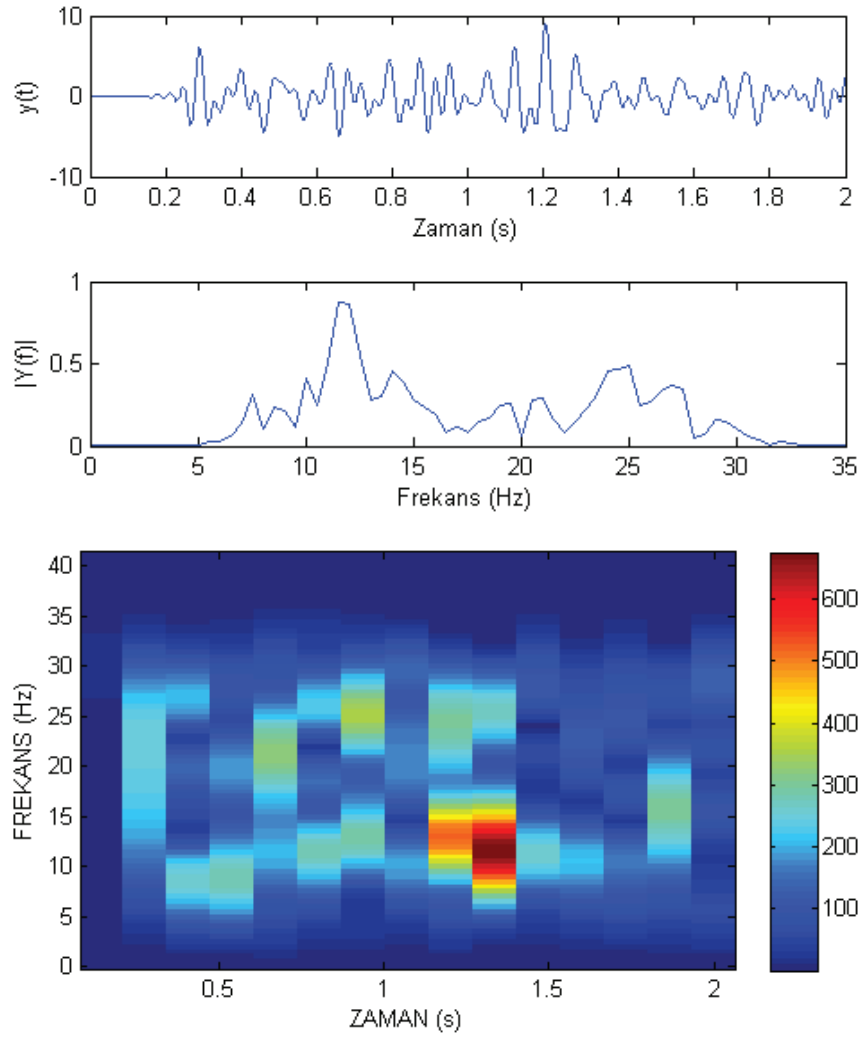
Şekil 6.41. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (SOL yön 3. kanal)

Yukarı yön esnasında kayıtlanan ilk örneğin genlik-frekans ve frekans-zaman değişimleri de Şekil 6.42'deki gibi ortaya çıkmıştır. Bu örnek için her iki bandında ağırlıkta olduğu görülmektedir. Katılımcı belirli zaman aralıklarında iyi bir zihinsel etkinlik sergilemiş ama bazen de bu etkinliğini sürdürmemiştir. En başarısız katılımcı için yukarı yön zihinsel aktivitesinin etkili bir biçimde ortaya konamadığı söylenebilir.



Şekil 6.42. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (YUKARI yön 3. kanal)

Aşağı yön aktivitesi için çıkarılan sonuçlarda devam eden son şekilde gösterildiği gibi oluşmuştur. Genlik-frekans ve frekans-zaman değişimlerine bakıldığında katılımcının beta frekanslarının yok denecek kadar az olduğu ve baskın olarak alfa bandının ortaya çıktığı görülmektedir. Bu sebeple aşağı yön aktivitesinde katılımcı bu örnek için oldukça başarısızdır.



Şekil 6.43. En başarısız katılımcı için Genlik-Zaman, Genlik-Frekans ve Frekans-Zaman sonuçları (AŞAĞI yön 4. kanal)



Genel olarak katılımcının ilk örnekler için genlik-frekans ve frekans-zaman değişimleri göz önüne alındığında zihinsel yön eğilimlerinin başarılı geçmediğini ve etkin bir düşünce ve odaklanma gerçekleştirmediğini söyleyebiliriz.

6.5. Spektral Güç Yoğunluğu Kullanılarak Yapılan Özellik Çıkarma

Spektral güç yoğunluğu, tıpkı zamanda değişen sinyallerin ortalama güç dağılımları gibi frekans alanındaki güç dağılımlarının ifadesidir. Bu başlık altında katılımcılardan zihinsel yönelimler esnasında alınan EEG sinyallerinin frekans alanındaki güç dağılımları gözlenmiştir. Çalışma içerisinde welch metodundan faydalanılmış ve 4096 uzunluklu EEG sinyalleri, 1024 boyutlu hamming pencere ile

çakışmaların %50 olarak ayarlanması sonrasında incelenmiş ve güç değişimleri ortaya çıkarılmıştır. Spektral güç özellik matrisi 360x270 boyutuna sahiptir. PCA ve ICA algoritmaları sayesinde bu özellik vektörünün boyutu 360x115 seviyesine indirgenmiş ve elde edilen yeni özellik vektörü, tüm verilerin %99'unu kapsamıştır. Şekillerdeki karmaşayı engellemek adına en başarılı ve en başarısız katılımcılar için örnek olarak, her yön düşüncesinin ilk 2 saniyelik kısımları için tüm EEG kanallarının PSD değişimleri devam eden başlıklar altında gösterilmiştir.

Spektral güç yoğunluğu özelliği sayesinde zihinsel yön aktivasyonları için kayıtlanan sinyallerden 360x270 uzunluğunda bir özellik matrisi elde edilmiştir. 270 uzunluğundaki özellik uzayı hem PCA hem de ICA analizi sayesinde aşağıda gösterildiği gibi 115'e indirgenmiştir ve bu sayede sınıflandırıcıların gereksiz bilgi ile uğraşmaları önlenmiştir.




Şekil 6.44. En başarılı katılımcıya ait PSD özelliklerinin PCA ve ICA uzayındaki ağırlıkları ve boyut indirgeme


Burada ilk 115 özellik, tüm sinyal bilgisinin yaklaşık %99'unu içerdiğinden 270 özellik 115 özellik ile karşılanabilir.

6.5.1. En başarılı katılımcı için elde edilen özellikler


En başarılı katılımcının zihinsel yön aktivasyonu esnasında kayıtlanan EEG sinyallerinin ilk 2 saniyelik bölümlerinin spektral güç dağılımları aşağıdaki şekillerde sırasıyla gösterilmektedir.



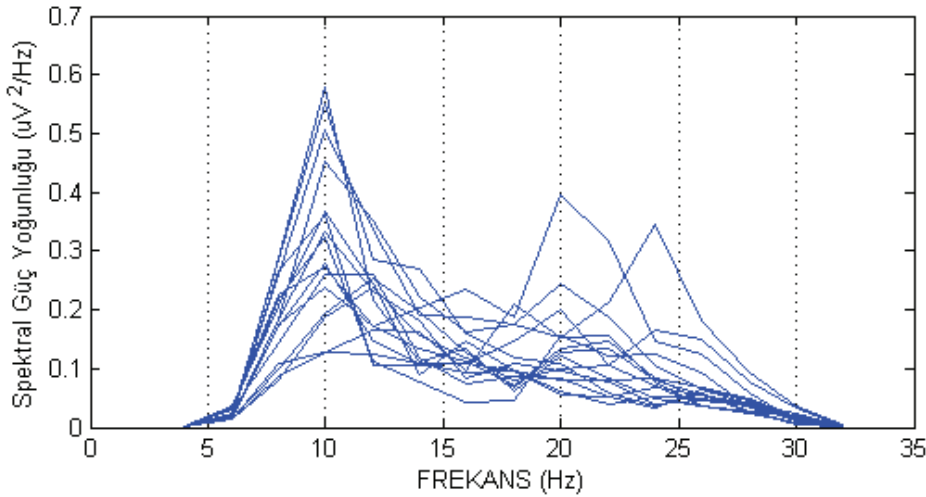
Şekil 6.45. En başarılı katılımcıya ait spektral güç dağılımları (SAĞ yön)



Şekil 6.46. En başarılı katılımcıya ait spektral güç dağılımları (SOL yön)



Şekil 6.47. En başarılı katılımcıya ait spektral güç dağılımları (YUKARI yön)




Şekil 6.48. En başarılı katılımcıya ait spektral güç dağılımları (AŞAĞI yön)


Sağ yön spektral güç dağılımlarında beta frekansları baskın olsa da alfa dağılımlarının da yükseldiği görülmektedir. Zihinsel etkinliğin daha ön planda olduğu söylenebilir. Sol yön için beta dağılımları çok daha baskındır. Bu nedenle katılımcı sol yön aktivitesi üzerinde bu örnekler için daha başarılıdır ve daha iyi bir zihinsel yönelim gerçekleştirmiştir. Yukarı ve aşağı spektral güç yoğunluklarında ise beta frekanslarının yanında daha baskın olan frekansların alfa olduğu görülmektedir. Yani katılımcının hem yukarı hem de aşağı yön zihinsel aktivasyonlarında bu örneklere bakılınca etkinliğinin az olduğu söylenebilir.

6.5.2. En başarısız katılımcı için elde edilen özellikler

En başarısız katılımcının zihinsel yön aktivasyonları esnasında kayıtlanan EEG sinyallerinin ilk 2 saniyelik bölümleri için elde edilen spektral güç dağılımları Şekil 5.49, 5.50, 5.51 ve 5.52’de sırasıyla gösterilmiştir.




Şekil 6.49. En başarısız katılımcıya ait spektral güç dağılımları (SAĞ yön)




Şekil 6.50. En başarısız katılımcıya ait spektral güç dağılımları (SOL yön)

Kullanıcının sağ yön aktivitesi için elde edilen güç yoğunluklarında beta frekanslarının üstünlüğünden söz edebiliriz. Dolayısıyla katılımcının sağ yön zihinsel aktivasyonunda başarı kaydettiği söylenebilir. Sol yön için ise alfa bant yoğunlukları ön plandadır. Aynı yargıyı sol yön içinde söylemek oldukça zordur.



Şekil 6.51. En başarısız katılımcıya ait spektral güç dağılımları (YUKARI yön)



Şekil 6.52. En başarısız katılımcıya ait spektral güç dağılımları (AŞAĞI yön)

Yukarı ve aşağı yön için elde edilen spektral güç dağılımlarında da tamamen alfa frekansları ağırlıktadır ve katılımcının bu durumda etkili bir zihinsel aktivitesinden söz edilemez. Bu örnekler için elde edilen güç dağılımları bir bütün olarak incelendiğinde, katılımcının zihinsel etkinliğinin ve odaklanmasının oldukça aşağılarda ve zihinsel yöneliminin başarısız olduğunu söylenebiliriz.


6.6. DWT Dönüşümü Kullanılarak Yapılan Özellik Çıkarma

EEG ölçüm sisteminin örnekleme frekansı 2048Hz olması sebebiyle, DWT yöntemi yardımıyla alfa ve beta bantlarının çıkarımı için db10 ana dalgacık fonksiyonu

kullanılarak ham EEG sinyalleri 8. seviye alt parçacıklara ayrıştırılmıştır. 7. seviye dalgacık katsayıları kullanılarak ham sinyaldeki alfa dalgaları ve 8. seviye dalgacık katsayıları kullanılarak ta beta dalgaları ortaya çıkarılmıştır. Zihinsel yön aktivasyonları esnasında ortaya çıkan bu dalgaların enerjileri hesaplanarak hem alfa hem de beta frekans bandı için toplamda 360x18 boyutunda özellik matrisi elde edilmiştir. Her bir katılımcı için elde edilen alfa-beta bantlarına ait sinyal enerjileri kıyaslanmış ve makine öğrenme algoritmaları tarafından sinyal örüntüleri tanımlanmıştır. Şekillerdeki karmaşayı engellemek adına en başarılı ve en başarısız katılımcılar için örnek olması açısından sağ yön zihinsel aktivasyonu esnasında kayıtlanan ham EEG sinyallerinin ilk 2 saniyelik kısımlarının birinci kanalına ait değişimler ve bu kanala ait alfa ve beta sinyal çıkarımları devam eden şekillerde sırasıyla gösterilmiştir.

6.6.1. En başarılı katılımcı için elde edilen özellikler

Sağ yön zihinsel aktivasyonu için en başarılı katılımcının ilk 2 saniyelik ham EEG sinyallerinin 1. kanaldan elde edilen kaydı ve bu sinyale ait 7. seviye DWT ayrıştırma sonucu oluşan beta bandı ve 8. seviye ayrıştırma ile oluşan alfa bandı sinyalleri Şekil 6.53'te gösterilmiştir.




Şekil 6.53. En başarılı katılımcıya ait 1. kanal ham EEG sinyali ve bu sinyalden ayrıştırılan alfa-beta çözümleri

Bu katılımcıya ait tüm örneklerden elde edilen alfa ve beta değişimleri her yön durumun için 90×4096 uzunluğunda alfa ve beta frekans çıkarımlarına sahiptir. Her frekans bandının enerjisi hesaplandığında her yön için 90×18 ve toplamda 360×18 uzunluğunda alfa ve beta frekans enerjilerini içeren özellik vektörü oluşturulmuştur.

6.6.2. En başarısız katılımcı için elde edilen özellikler

Aynı şekilde, en başarısız katılımcı içinde sağ yön zihinsel aktivasyonu sırasında birinci kanalda oluşan ilk 2 saniyelik ham EEG sinyali ve bu sinyale ait DWT ile ayrıştırılan alfa ve beta bandı sinyalleri aşağıda gösterilmiştir.



Şekil 6.54. En başarısız katılımcıya ait 1. kanal ham EEG sinyali ve bu sinyalden ayrıştırılan alfa-beta çözümleri

Her zihinsel yön aktivasyonu esnasında kayıtlanan EEG sinyallerinin alfa-beta bandı enerjilerini içeren 360×18 uzunluğundaki özellik vektörü için makine öğrenme algoritmalarının sınıflandırma doğrulukları da Tablo 5.57’de gösterildiği gibi elde edilmiştir.

Bu bölümde tüm katılımcılar için beyinde oluşan yöne bağlı EEG sinyallerindeki özellikler, tüm özellik çıkarım yöntemleri ile uygulamalı olarak incelenmiş ancak örnek olması açısından en başarılı ve en başarısız katılımcılar için elde edilen uygulama sonuçlarına yer verilmiştir.

Sonraki bölümde her katılımcının zihinsel yönelimleri altında elde edilen özellikler, makine öğrenme algoritmaları yardımıyla sınıflandırılacak ve elde edilen sınıflandırma doğrulukları her katılımcı için ayrı ayrı ele alınacaktır.

BÖLÜM 7. SONUÇLAR

Bu bölümde, bölüm 3'te detaylı olarak açıklanan ve önceki kısımda en başarılı ve en başarısız katılımcılar için uygulama sonuçları verilen özellik çıkarım yöntemleri ile ham EEG sinyallerinden çıkarılan ve yön düşüncesi içeren özellik matrisleri üzerine bölüm 4'te detaylı olarak incelenen makine öğrenme algoritmaları uygulanmıştır. Böylece, 10 katılımcı için her bir özellik başlığı altındaki sınıflandırma doğrulukları çıkarılmış ve beyinde oluşan yöne bağlı EEG sinyallerindeki yön örüntülerinin, makine öğrenmesi ile çıkarımı başarılmıştır.

7.1. 10 Katılımcıya Ait Makine Öğrenme Algoritması Doğrulukları

Katılımcıların sağ, sol, yukarı ve aşağı yön zihinsel eğilimleri altında kayıtlanan ham EEG sinyallerden çıkarılan özellikler üzerinden yön tayini yapılabilmesi ve bu sinyallerin kontrol amacıyla kullanılabilmesi için o sinyalin hangi sınıfa ait olduğunun bilinmesi gerekir. Bu noktada makine öğrenme algoritmaları devreye girer ve özellikleri çıkarılan ham EEG sinyallerini ait olduğu sınıfa atayarak örüntü tanıma işlemi sağlar ve güvenilir sonuçlar üretir.

Devam eden başlıklar altında her bir özellik çıkarım yöntemi sonucu, 10 katılımcı için elde edilen makine öğrenme algoritmalarının sınıflandırma doğrulukları verilmiştir.

7.1.1. Ortalama sinyal gücü veya varyans özelliği için elde edilen sınıflandırma doğrulukları

Bu yöntem ile zaman alanındaki ortalama güç yoğunluğu diğer bir ifade ile varyans değişimleri her kanaldan 2 saniyede 4096 uzunluğunda kaydedilen EEG sinyaller tek

bileşen olarak ifade edilir. Böylece, her katılımcı için kayıtlanan 360x4096 uzunluklu zihinsel yön verileri 360x18 boyutuna dönüştürülür. Bu özellik matrisi, bölüm 4'te açıklanan ANFIS, LVQ, MLNN, PNN, Karar Ağacı, LDA, kNN, SVM ve LS-SVM yöntemleri ile yön çıkarımı üzerine sınıflandırılmıştır. Elde edilen sonuçlar aşağıdaki tabloda detaylıca yer almaktadır.

Tablo 7.1. 10 katılımcının ortalama sinyal gücü özellikleri için makine sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%81,15	%80	%81,22	%82,5	%68,94	%85,32	%87,77	%88,05	%89,88
	ICA	%83,95	%80,66	%82,94	%83,33	%65,55	%86,66	%89,44	%88,89	%90,55
2. Katılımcı	PCA	%87	%88,13	%87,27	%87,44	%73,83	%91,38	%87,66	%91,94	%94,16
	ICA	%88,34	%87,55	%88,44	%88,38	%75,66	%92,22	%89,05	%93,11	%95,27
3. Katılımcı	PCA	%76,66	%80,05	%82,94	%82,82	%67,22	%85,27	%81,83	%84,94	%86,05
	ICA	%78,61	%83,12	%84,34	%84,5	%70,88	%86,22	%82,5	%85,33	%87,77
4. Katılımcı	PCA	%72,22	%73,05	%74,44	%75,33	%62,27	%71,11	%75,27	%78,88	%79,22
	ICA	%74,09	%74,67	%75,77	%76,94	%66,44	%73,33	%78,05	%80,33	%81,11
5. Katılımcı	PCA	%86,72	%86,83	%88,38	%88,83	%75,55	%91,77	%88,61	%93,44	%95,94
	ICA	%89	%87,66	%89,44	%90,1	%78,88	%92,5	%90,27	%94,83	%97,22
6. Katılımcı	PCA	%77,33	%63,88	%65,33	%67,15	%55,12	%73,27	%66,94	%76,18	%77,33
	ICA	%79,77	%65,12	%67,66	%67,38	%57,27	%75,05	%68,11	%77	%78,38
7. Katılımcı	PCA	%70,87	%74,11	%76,44	%77,05	%58,22	%73,05	%76,94	%78,11	%78,83
	ICA	%72,55	%76,66	%78,16	%78,88	%60,27	%75,55	%78,16	%79,33	%81,05
8. Katılımcı	PCA	%72,83	%77,77	%77,94	%80,88	%69,15	%82,72	%81,66	%82,77	%84,72
	ICA	%75,55	%79,38	%81,77	%82,22	%71,11	%84,44	%83,55	%84,94	%86,38
9. Katılımcı	PCA	%66,55	%56,05	%58,44	%60,22	%48,27	%66,88	%59,33	%69,05	%70,5
	ICA	%68,88	%58,33	%60,12	%61,77	%50,38	%68,22	%61,18	%70	%71,38
10. Katılımcı	PCA	%67,05	%77,38	%77,33	%79	%66,88	%80,33	%79,94	%80,88	%83,11
	ICA	%68,94	%76,27	%78,72	%80,61	%68,44	%82,5	%81,16	%82,38	%84,72
Ortalama	PCA	%76,84	%75,72	%76,97	%78,12	%64,55	%80,11	%78,60	%82,42	%83,97
	ICA	%77,97	%76,94	%78,74	%79,41	%66,49	%81,67	%80,15	%83,61	%85,38

Tablo 7.1 incelendiğinde, ortalama sinyal gücü özellikleri ile elde edilen sınıflandırma doğruluklarına göre en başarılı katılımcı 5 ve en başarısız katılımcı da 9 dur. Tüm sınıflandırma doğruluklarına bakıldığında en yüksek değerlerin ICA+LS-SVM(OvsO) yöntemi sayesinde elde edildiği gözlenmektedir. Aynı şekilde ortalama doğruluklara göre de en iyi yöntem ICA+LS-SVM(OvsO) dur. ICA algoritması, PCA ya göre sınıflandırma doğruluklarını yaklaşık %2 civarında arttırmaktadır.

Zihinsel aktivitelerdeki yön örüntülerinin tanınmasında en düşük sınıflandırma doğrulukları da karar ağacı algoritması ile elde edilmiştir.

7.1.2. Entropi özelliği için elde edilen sınıflandırma doğrulukları

Entropi özelliği ile zaman alanında değişen 4096 uzunluğundaki 2 saniyelik sinyal değişimleri tek bir bileşen ile ifade edilir. Her yön düşüncesi (sağ, sol, yukarı, aşağı) 90 farklı örnek barındırmakta olup dört farklı yön düşüncesi için toplamda 360x18 boyutunda zihinsel yön verileri içeren bir özellik matrisi elde edilir. Bu özelliklerin ait olduğu sınıfları tanımlamak amacıyla, her katılımcı için ayrı ayrı yürütülen makine öğrenme algoritmalarının sınıflandırma doğrulukları aşağıdaki tabloda verilmiştir.

Tablo 7.2. 10 katılımcının entropi özellikleri için sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%78,88	%87,11	%87,94	%89,88	%69,55	%90,05	%91,38	%90	%91,77
	ICA	%77,29	%88,61	%90,55	%91,11	%71,83	%91,11	%92,25	%91,94	%93,16
2. Katılımcı	PCA	%80,55	%85,33	%86,22	%87,38	%68,11	%91,44	%87,55	%93,33	%94,44
	ICA	%82,44	%87	%88,55	%89,16	%69,94	%93,61	%89,05	%95,22	%96,11
3. Katılımcı	PCA	%84,44	%82,88	%85,66	%86,11	%68,38	%80,5	%85,77	%85,33	%86,66
	ICA	%86,05	%85,22	%87,44	%88,05	%70,88	%83,88	%87,44	%87,56	%88,61
4. Katılımcı	PCA	%79,94	%71,18	%74,05	%74,22	%64,82	%77,33	%77,05	%80,83	%81,55
	ICA	%81,66	%73,16	%75,55	%76,05	%66,33	%79,94	%79,61	%82,12	%83
5. Katılımcı	PCA	%87,33	%85,94	%88,88	%89,11	%77,44	%82,22	%90,5	%93,88	%95,55
	ICA	%89,44	%87,66	%90,12	%91,94	%79,88	%94,77	%92,33	%95,55	%97,94
6. Katılımcı	PCA	%78,72	%68,16	%68,55	%68,88	%60,05	%77,72	%67,77	%79,94	%92,22
	ICA	%80,38	%70,11	%70,5	%71,66	%62,73	%80,22	%70,72	%81,38	%93,61
7. Katılımcı	PCA	%67,94	%75,55	%77,66	%78,22	%59,94	%80,15	%78,94	%79,33	%80,55
	ICA	%70,16	%77,33	%79,05	%79,88	%61,84	%81,27	%80,16	%81,77	%82,44
8. Katılımcı	PCA	%74,22	%76,66	%80,44	%81,33	%69,94	%82,22	%82,88	%83,44	%84,77
	ICA	%76,55	%79,94	%82,05	%82,5	%71,77	%84,88	%83,94	%85,22	%86,88
9. Katılımcı	PCA	%68,33	%56,56	%62,22	%63,15	%52,38	%70,05	%63,88	%71,16	%72,22
	ICA	%70,5	%58,22	%64,11	%65,05	%54,44	%72,77	%65,33	%73,89	%75,55
10. Katılımcı	PCA	%70,77	%79,33	%81,44	%82,27	%68,15	%86,88	%83,27	%85,5	%88,05
	ICA	%72,12	%81,94	%83,05	%84,88	%69,94	%88,05	%85,33	%87,72	%89,44
Ortalama	PCA	%77,11	%76,87	%79,31	%80,06	%65,88	%81,86	%80,90	%84	%86,78
	ICA	%78,66	%78,92	%81,10	%82,03	%67,96	%85,05	%82,62	%86,24	%88,67

Entropi özellikleri sayesinde elde edilen sınıflandırma doğrulukları, sonuçların ortalamaları kıyaslandığında ortalama güç özelliklerine göre yaklaşık %3 daha iyi bir performans sağlamıştır. Dolayısıyla entropi özellik çıkarım yönteminin zaman alanı incelemelerinde ortalama güç veya varyans dağılımlarına göre daha iyi bir özellik çıkarım yöntemi olduğu söylenebilir.

7.1.3. Hjorth özellikleri için elde edilen sınıflandırma doğrulukları

Hjorth parametrelerinin zamanda değişen sinyaller için değişkenlik ve karmaşıklık ifadeleri incelenmiştir. Zihinsel yön aktiviteleri esnasında kayıtlanan EEG sinyallerinin değişkenlik ve karmaşıklık parametreleri, 4096 uzunluğundaki 2 saniyelik sinyal değişimlerinin tek bir bileşen ile ifade edilebilmesini sağlar.

Tablo 7.3. 10 katılımcının Hjørth değişkenlik özelliği için sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%73,56	%74,11	%75,44	%76,16	%64,88	%77,12	%76,83	%79,22	%80,55
	ICA	%75,12	%77,77	%79,05	%79,38	%67,16	%80,77	%80,11	%81,57	%83,38
2. Katılımcı	PCA	%74,15	%74,83	%76,22	%77,56	%65,22	%80,64	%81,88	%81,15	%82,94
	ICA	%78,5	%76,44	%79,33	%80,17	%69,14	%83,55	%84,13	%83,88	%85,33
3. Katılımcı	PCA	%64,88	%66,66	%67,11	%68,05	%59,16	%70,77	%75,94	%75,44	%76,22
	ICA	%67,94	%68,61	%70,14	%70,89	%62,77	%73,33	%78,05	%78,15	%78,88
4. Katılımcı	PCA	%62,44	%63,33	%65,16	%66,55	%58,84	%68,88	%67,27	%70,11	%72,44
	ICA	%65,15	%67,88	%69,15	%70	%61,44	%72,56	%70,22	%73,46	%75,33
5. Katılımcı	PCA	%76,83	%76,66	%78,16	%79,88	%68,38	%81,22	%80,15	%84,66	%85,5
	ICA	%80,13	%79,22	%80,55	%81,16	%71,61	%84,44	%82,77	%88,11	%88,88
6. Katılımcı	PCA	%68,22	%72,72	%75,87	%76,77	%62,88	%77,05	%76,44	%78,16	%79,72
	ICA	%70,05	%74,16	%76,55	%78,94	%65,11	%79,94	%78,83	%80,88	%81,66
7. Katılımcı	PCA	%62,16	%62,77	%63,88	%64,46	%55,05	%66,87	%66,33	%68,38	%70,15
	ICA	%65,05	%66,22	%67,16	%67,77	%57,33	%68,88	%68,56	%70,44	%72,94
8. Katılımcı	PCA	%67,22	%67,66	%69,11	%69,94	%61,88	%72,44	%70,5	%74,16	%75,33
	ICA	%70,5	%71,13	%72,05	%72,5	%65,77	%75,27	%73,33	%77,64	%78,88
9. Katılımcı	PCA	%61,16	%60,15	%62,88	%63,46	%51,38	%64,22	%63,61	%66,56	%68,16
	ICA	%63,44	%62,22	%64,16	%65,05	%53,13	%66,56	%65,44	%68,94	%70,12
10. Katılımcı	PCA	%70,55	%71,11	%72,87	%73,56	%60,44	%74,66	%74,15	%77,22	%78,84
	ICA	%72,83	%73,61	%75,11	%75,77	%63,21	%76,44	%76,16	%78,88	%80,11
Ortalama	PCA	%68,12	%69,00	%70,67	%71,64	%60,81	%73,39	%73,31	%75,51	%76,99
	ICA	%70,87	%71,73	%73,33	%74,16	%63,67	%76,17	%75,76	%78,20	%79,55

Hem Hjorth değişkenliğinde hem de Hjorth karmaşıklığında önceki sonuçlarda olduğu gibi en başarılı katılımcı 5, en başarısız katılımcıda 9 dur. Ancak, Hjorth değişkenliğinin sınıflandırma doğrulukları, karmaşıklığına göre daha yüksek sonuçlar sağlamaktadır. Değişkenlik, sinyallerdeki ortalama frekans değişimlerini ifade ettiği düşünüldüğünde katılımcıların belli bir frekans bandı aralığında sinyal değişimlerine sahip olduğunu ve bu yüzden değişiklik sonuçlarının yüksek çıktığını söyleyebiliriz. Karmaşıklık ifadesi ise frekanstaki değişimleri ifade ettiği ve EEG sinyallerinin durağan olmadığı düşünüldüğünde sınıflandırma doğruluklarında düşüş meydana gelmesi normaldir. Zaman alanında incelenen Hjorth parametreleri daha önceki başlıklar altında incelenen ortalama güç veya varyans ve entropi özellikleri ile kıyaslandığında zihinsel aktivitelerdeki yön çıkarımı için yetersiz kalmaktadır.

Tablo 7.4. 10 katılımcının Hjorth karmaşıklığı özelliği için sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%64,05	%63,88	%65,44	%67,16	%54,77	%66,15	%66,56	%68,33	%69,22
	ICA	%65,56	%65,14	%66,94	%69,22	%57,27	%68,33	%68,88	%70,22	%71,55
2. Katılımcı	PCA	%63,55	%64,27	%66,15	%66,83	%53,16	%67,94	%67,22	%68,38	%70,64
	ICA	%66,16	%66,88	%68,56	%69,27	%55,88	%70,5	%70,15	%71,94	%73,88
3. Katılımcı	PCA	%54,33	%54,44	%56,83	%57,16	%52,05	%60	%58,38	%64,77	%65,16
	ICA	%56,11	%56,55	%57,15	%59	%53,22	%62,77	%60,61	%66,44	%67,22
4. Katılımcı	PCA	%55,27	%54,76	%56,94	%57,33	%51,14	%59,15	%58,88	%62,16	%63,77
	ICA	%56,94	%56,66	%58,36	%59,22	%52,16	%61,44	%60,05	%63,33	%65,15
5. Katılımcı	PCA	%66,38	%66,84	%67,77	%68,55	%56,05	%66,94	%69,11	%71,38	%72,55
	ICA	%69,44	%69,16	%70	%71,05	%58,11	%68,33	%71,38	%74,16	%75,22
6. Katılımcı	PCA	%61,33	%60,88	%61,94	%62,77	%53,5	%64,38	%63,66	%66,27	%67,38
	ICA	%63,16	%62,22	%63,05	%64,16	%55,33	%66,77	%65,15	%67,64	%69,22
7. Katılımcı	PCA	%54,83	%54,33	%55,05	%56,88	%52,64	%56,56	%57,33	%58,46	%59,84
	ICA	%56,5	%56,15	%55,77	%57,22	%54,16	%58,44	%58,88	%60,22	%61,56
8. Katılımcı	PCA	%58,46	%57,18	%60,22	%58,16	%54,22	%63,15	%58,72	%63,94	%65,05
	ICA	%61,33	%60,77	%63,55	%61,23	%56,94	%65	%60,27	%65,88	%66,38
9. Katılımcı	PCA	%53,27	%51,38	%52,27	%52,94	%48,16	%53,78	%53,05	%54,56	%56,11
	ICA	%54,66	%52,22	%52,88	%53,33	%50,15	%54,44	%54,12	%55,88	%57,44
10. Katılımcı	PCA	%55,33	%56,78	%58,46	%59,27	%51,44	%58,38	%60,05	%66,16	%66,77
	ICA	%56,55	%58,94	%60	%61,05	%53,11	%60,83	%61,61	%67,94	%68,61
Ortalama	PCA	%58,68	%58,47	%60,11	%60,71	%52,71	%61,64	%61,30	%64,44	%65,65
	ICA	%60,64	%60,47	%61,63	%62,48	%54,63	%63,69	%63,11	%66,37	%67,62

7.1.4. Fourier özellikleri için elde edilen sınıflandırma doğrulukları

Ham EEG sinyallerinin STFT yöntemi ile 512 uzunluklu hamming pencere 256 adımda bir kaydırılarak işlenmesi sonucu elde edilen özellik vektörü 360x1080 boyutuna sahiptir. Bu özellikler tüm özellik vektörünün %99'unu kapsayacak şekilde PCA ve ICA algoritmaları sayesinde 360x175 seviyesine indirgenmiş ve makine öğrenme algoritmaları tarafından her katılımcı için ayrı ayrı aşağıdaki tabloda verildiği gibi sınıflandırılmıştır.

Tablo 7.5. 10 katılımcının Fourier özelliği için sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%73,15	%78,83	%81,11	%82,33	%60,56	%82,05	%83,16	%82,94	%83,88
	ICA	%75,66	%81,22	%83,77	%84,88	%63,44	%84,22	%85,11	%85,33	%86,05
2. Katılımcı	PCA	%75,12	%79,27	%80,46	%81,33	%61,17	%85,33	%80,17	%87,46	%88,12
	ICA	%77,15	%81,61	%82,22	%83,56	%63,33	%87,11	%82,44	%89,33	%90,55
3. Katılımcı	PCA	%80,37	%76,88	%79,44	%80,05	%61,96	%75,13	%77,94	%79,38	%80,11
	ICA	%82,55	%79,94	%81,5	%82,22	%64,55	%77,61	%80,66	%81,15	%82,77
4. Katılımcı	PCA	%73,38	%67,15	%67,58	%69,38	%58,88	%71	%70,05	%74,87	%75,14
	ICA	%76,11	%69,27	%70,44	%71,22	%61,44	%73,15	%72,55	%77,05	%77,77
5. Katılımcı	PCA	%79,15	%80,37	%85,94	%85,16	%62,77	%86,66	%84,15	88%27	%89,22
	ICA	%80,66	%82,56	%88,88	%87,61	%65,55	%88,38	%86,22	%90,88	%91,44
6. Katılımcı	PCA	%72,27	%62,87	%63,55	%63,88	%56,26	%72,94	%64,12	%72,27	%73,56
	ICA	%74,41	%65,55	%66,88	%66,11	%58,33	%75,77	%66,66	%75,15	%76,44
7. Katılımcı	PCA	%68,38	%69,96	%70,33	%70,77	%55,16	%72,55	%71,14	%72,33	%73,88
	ICA	%70,77	%72,33	%73,05	%73,55	%57,77	%75,12	%73,94	%75,88	%76,41
8. Katılımcı	PCA	%68,56	%70,11	%72,88	%73,94	%62,55	%76,33	%74,68	%76,77	%78,46
	ICA	%71,44	%73,86	%76,22	%76,83	%65,14	%79,05	%77,33	%79,66	%81,15
9. Katılımcı	PCA	%65,33	%58,77	%61,11	%62,05	%51,11	%65,46	%60,88	%66,27	%67,77
	ICA	%68,42	%61,94	%63,55	%64,44	%53,33	%68,89	%63,22	%69,44	%70,33
10. Katılımcı	PCA	%67,55	%74,05	%75,87	%79,5	%59,88	%78,33	%77,68	%80,12	%81,94
	ICA	%70,88	%76,94	%78,44	%82,22	%62,56	%81,11	%80,44	%83,67	%84,55
Ortalama	PCA	%72,33	%71,83	%73,83	%74,84	%59,03	%76,58	%74,40	%76,93	%79,21
	ICA	%74,81	%74,52	%76,50	%77,26	%61,54	%79,04	%76,86	%80,75	%81,75

Frekans özelliklerinden çıkarılan sınıflandırma doğruluklarına göre en başarılı ve en başarısız katılımcılar ve en iyi sınıflandırma yöntemi değişmemiştir. Ayrıca yine ICA algoritmasının sınıflandırma doğruluklarını yaklaşık %2 civarında artırdığı söylenebilir. Sınıflandırma doğruluğu yüksek olan katılımcılar için zihinsel yönelim

ve odaklanmada başarıya ulaştığını söylemek mümkündür. Bu katılımcılar için zihinsel etkinlikler altında görülen beta yoğunlukları baskındır. Aynı şekilde sınıflandırma doğrulukları düşük olan katılımcılar içinde tam tersi geçerlidir ve bu katılımcılar da zihnin dinlendiği durumda görülen alfa frekanslarının baskınlığından söz edilebilir.

7.1.5. Spektral Güç Yoğunluğu özellikleri için elde edilen sınıflandırma doğrulukları

Kayıtlanan EEG sinyallerinden welch metodu yardımı ile çıkarılan spektral güç özellik matrisi 360x270 boyutuna sahiptir. PCA ve ICA algoritmaları sayesinde bu özellik matrisinin boyutu 360x115 seviyesine indirgenmiş ve elde edilen yeni özellik matrisi tüm verilerin %99'unu kapsamıştır.

Tablo 7.6. 10 katılımcının PSD özelliği için sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%72,87	%82,26	%84,55	%85,05	%65,27	%84,16	%85,55	%85,88	%87,05
	ICA	%75,29	%84,61	%86,94	%87,22	%68,83	%87,77	%88,33	%88,15	%89,44
2. Katılımcı	PCA	%78,22	%82,05	%83,11	%83,88	%62,16	%88,44	%83,22	%90,05	%90,88
	ICA	%80,55	%84,44	%85,94	%86,16	%66,33	%90,88	%85,55	%92,22	%93,15
3. Katılımcı	PCA	%78,96	%79,33	%80,56	%81,14	%64,05	%77,77	%80,11	%81,16	%82,77
	ICA	%83,55	%83,11	%84,44	%85,05	%67,77	%80,88	%83,55	%84,44	%86,38
4. Katılımcı	PCA	%75,46	%67,14	%69,89	%70,15	%61,66	%74,05	%73,83	%77,05	%78,22
	ICA	%78,88	%70,27	%72,22	%73,88	%66,05	%77,11	%76,66	%79,66	%81,33
5. Katılımcı	PCA	%82,22	%84,46	%86,16	%86,55	%57,13	%88,89	%88,05	%89,94	%91,16
	ICA	%83,61	%86,94	%88,44	%89,11	%59,61	%91,55	%90,33	%92,22	%94,44
6. Katılımcı	PCA	%72,11	%71,55	%72,88	%73,46	%55,87	%74,46	%74,27	%74,66	%75,05
	ICA	%75,88	%74,44	%76,15	%76,77	%58,11	%78,66	%78,05	%78,88	%79,94
7. Katılımcı	PCA	%77,16	%66,16	%66,77	%67,27	%58,22	%76,77	%66,14	%76,56	%78,11
	ICA	%78,05	%68,55	%68,61	%69,05	%60,44	%79,11	%68,88	%78,94	%80,66
8. Katılımcı	PCA	%71,46	%72,27	%74,96	%75,5	%63,88	%78,14	%77,38	%78,67	%79,22
	ICA	%74,5	%75,33	%77,94	%78,38	%66,12	%80,55	%79,44	%81,11	%81,94
9. Katılımcı	PCA	%68,33	%61,87	%64,16	%65,42	%54,56	%68	%67,05	%68,94	%70,38
	ICA	%70,44	%65,94	%66,55	%67,88	%56,12	%70,33	%68,44	%71,38	%72,55
10. Katılımcı	PCA	%68,38	%77,67	%78,44	%79,15	%62,27	%80,22	%79,94	%81,44	%83,11
	ICA	%70,12	%80,05	%81,61	%82,11	%64,55	%83,38	%82,44	%84,88	%86,55
Ortalama	PCA	%74,52	%74,48	%76,15	%76,76	%60,51	%79,09	%77,55	%80,44	%81,60
	ICA	%77,09	%77,37	%78,88	%79,56	%63,39	%82,02	%80,17	%83,19	%84,64

Tablo 7.6, PCA ve ICA algoritmaları ile boyutu azaltılan spektral güç yoğunluğu özellikleri için her katılımcıya göre detaylı olarak sınıflandırma doğruluklarını gösterir.

Frekans alanındaki ikinci özellik yöntemi olan PSD özellikleri ile elde edilen sınıflandırma doğrulukları sonuçlarına göre en başarılı ve en başarısız katılımcı sonuçlarının yükseldiği görülmektedir. Ortalama doğruluk sonuçlarına göre de bu özellik çıkarım yöntemi STFT özelliğine göre zihinsel etkinliklerdeki yön çıkarımları adına yaklaşık % 3 daha fazla bir sınıflandırma doğruluğu kazandırdığında frekans alanındaki incelemelerde daha önce tercih edilmelidir. Ayrıca ICA algoritması da PCA algoritmasına göre oranla tüm sınıflandırma doğruluklarında yaklaşık %3 civarı bir performans artışı sağlamıştır. Burada 7. katılımcıya ait ANFIS sınıflandırma doğruluğu diğer bazı sınıflandırıcılara göre şartıcı bir şekilde oldukça yüksek bir sonuç sağlamıştır. Ancak ANFIS yapısı en fazla 5 giriş içerebildiğinden elde edilen sınıflandırma doğruluğu pek güvenilir olmayacaktır.

7.1.6. Dalgacık özellikleri için elde edilen sınıflandırma doğrulukları

Ayrık dalgacık dönüşümü yöntemi yardımıyla 7. seviye dalgacık katsayıları kullanılarak ham sinyaldeki alfa dalgaları ve 8. seviye dalgacık katsayıları kullanılarak ta beta dalgaları ortaya çıkarılmıştır.

Tablo 7.7. 10 katılımcının alfa bandı enerjisi için sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%71,38	%73,14	%75,96	%76,56	%58,33	%76,88	%77,44	%76,05	%77,56
	ICA	%72,27	%75,5	%77,44	%78,12	%60,55	%78,33	%79,16	%78,88	%80,44
2. Katılımcı	PCA	%70,05	%73,77	%74,38	%75,33	%53,56	%73,27	%71,94	%76,55	%78,38
	ICA	%72,33	%77,12	%78,77	%79,66	%55,44	%77,14	%75,05	%79,88	%81,05
3. Katılımcı	PCA	%72,66	%71,77	%74,14	%74,94	%57,27	%70,05	%72,15	%73,96	%74,55
	ICA	%75,5	%74,16	%76,55	%77,77	%59,94	%72,44	%75,66	%76,37	%77,41
4. Katılımcı	PCA	%60,05	%58,87	%60,66	%61,11	%56,38	%63,67	%62,22	%66,88	%70,11
	ICA	%62,22	%60,94	%62,44	%63,88	%58,55	%67,22	%65,94	%69,33	%72,44
5. Katılımcı	PCA	%65,88	%69,27	%71,11	%71,56	%55,77	%74,33	%72,14	%75,27	%76,55
	ICA	%67,05	%71,13	%74,05	%74,88	%56,66	%77,44	%75,94	%78,33	%79,16

Tablo 7.8. 10 katılımcının alfa bandı enerjisi için sınıflandırma doğrulukları (Devamı)

6. Katılımcı	PCA	%60,46	%59,88	%60,16	%60,94	%57,12	%65,55	%64,12	%67,66	%70,12
	ICA	%62,72	%61,44	%62,94	%63,33	%58,66	%67,72	%66,44	%69,88	%72,94
7. Katılımcı	PCA	%67,46	%64,33	%66,67	%67,15	%51,05	%68,05	%68,66	%70,11	%70,46
	ICA	%70,77	%66,94	%68,88	%69,94	%51,88	%71,05	%70,16	%71,27	%72,33
8. Katılımcı	PCA	%68,11	%68,88	%70,22	%71,96	%57,15	%72,88	%72,22	%74,27	%75,05
	ICA	%69,33	%70,66	%72,88	%73,13	%60,44	%75,22	%74,94	%76,15	%77,33
9. Katılımcı	PCA	%65,05	%58,77	%60,46	%61,94	%52,11	%66,14	%64,05	%68,22	%70,15
	ICA	%66,94	%60,14	%62,22	%63,66	%53,33	%68,22	%65,88	%70,05	%72,27
10. Katılımcı	PCA	%59,88	%69,56	%70,15	%74,22	%58,15	%76,55	%75,44	%77,14	%78,77
	ICA	%61,88	%71,5	%72,44	%76,55	%60,94	%78,66	%77,15	%79,66	%81,44
Ortalama	PCA	%66,10	%66,82	%68,39	%69,57	%55,69	%70,74	%70,04	%72,61	%74,17
	ICA	%68,10	%68,95	%70,86	%72,09	%57,64	%73,34	%72,63	%74,98	%76,68

Tablo 7.9. 10 katılımcının beta bandı enerjisi için sınıflandırma doğrulukları

Katılımcılar		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
1. Katılımcı	PCA	%75,55	%85,38	%87,44	%88,27	%68,46	%88,05	%89,22	%88,56	%90,22
	ICA	%77,29	%88,61	%90,55	%91,11	%71,83	%91,11	%92,25	%91,94	%93,16
2. Katılımcı	PCA	%80,38	%85,77	%86,38	%87,22	%67,22	%91,77	%87,16	%93,38	%94,55
	ICA	%83,05	%88,38	%89,66	%90,16	%70,55	%94,44	%89,94	%96,15	%97,22
3. Katılımcı	PCA	%84,96	%84,05	%86,12	%87,24	%68,27	%81,38	%84,66	%85,22	%86,16
	ICA	%87,22	%86,66	%88,44	%89,33	%71,11	%84,77	%87,94	%88,05	%89,88
4. Katılımcı	PCA	%80,38	%71,55	%74,11	%75,16	%68,66	%78,66	%77,38	%80,22	%81,77
	ICA	%82,94	%74,27	%76,66	%77,55	%70,13	%81,05	%80,44	%83,55	%84,12
5. Katılımcı	PCA	%84,44	%87,77	%89,88	%90,27	%74,44	%92,66	%91,55	%93,11	%95,26
	ICA	%86,5	%90,44	%92,16	%93,33	%77,15	%95,33	%94	%96,77	%98,61
6. Katılımcı	PCA	%79,76	%69,88	%70,46	%71,11	%62,67	%80,44	%70,12	%80,54	%81,33
	ICA	%81,94	%72,05	%72,33	%73,88	%64,72	%82,72	%72,38	%82,44	%84,61
7. Katılımcı	PCA	%75,55	%76,11	%77,27	%77,66	%60,33	%80,27	%78,56	%79,38	%80,22
	ICA	%77,88	%78,77	%80,33	%80,55	%62,27	%82,16	%81,44	%82,33	%83,05
8. Katılımcı	PCA	%75,14	%77,42	%79,87	%80,14	%69,77	%82,96	%81,38	%83,11	%84,33
	ICA	%78,66	%80,22	%83,05	%83,33	%72,88	%85,55	%84,77	%86,05	%87,44
9. Katılımcı	PCA	%70,11	%65,05	%66,27	%67,55	%58,46	%72,44	%68,16	%73,05	%73,56
	ICA	%73,15	%67,22	%69,11	%70,05	%60,44	%75,77	%71,33	%76,89	%77,44
10. Katılımcı	PCA	%70,56	%79,56	%80,16	%84,33	%67,22	%85,66	%85,05	%86,55	%88,88
	ICA	%73,12	%82,44	%83,88	%87,05	%70,15	%88,38	%87,77	%89,33	%91,11
Ortalama	PCA	%77,68	%78,25	%79,80	%80,90	%66,55	%83,43	%81,32	%84,31	%85,63
	ICA	%80,18	%80,91	%82,62	%83,63	%69,12	%86,13	%84,23	%87,35	%88,68

Zihinsel yön aktivasyonları esnasında ortaya çıkan bu dalgaların enerjileri hesaplanarak hem alfa hem de beta frekans bandı için ayrı ayrı 360x18 boyutunda

özellik matrisi elde edilmiştir. Her bir katılımcı için elde edilen alfa-beta bantlarına ait sinyal enerjilerinin makine öğrenme algoritması doğrulukları sırasıyla Tablo 7.7 ve Tablo 7.9'de verilmiştir.

Sınıflandırma doğrulukları incelendiğinde ICA yöntemi PCA'ya göre daha yüksek sonuçlar sağlamaktadır. Ayrık dalgacık dönüşümü sonucu çıkarılan alfa bandına ait enerjilerin sınıflandırma doğrulukları incelendiğinde en başarısız katılımcı değişmezken en başarılı katılımcı %81,44 ile 10. katılımcıdır. Beta bandı enerjilerine ait sınıflandırma doğruluklarında ise en başarılı ve en başarısız katılımcıların çalışmanın başından beri olduğu gibi değişmediği görülmektedir.

Ancak alfa-beta enerji dağılımlarını bir bütün olarak ele almak gereklidir. Tablo 7.9'daki en başarılı katılımcının beta enerjisi sınıflandırma doğruluğu ile bu katılımcının Tablo7.9'daki alfa doğrulukları arasındaki fark %98,61-%79,16=%19,45 tir. Bu fark tüm katılımcılar arasında en fazla olandır. Aynı şekilde, Tablo 7.9'daki en başarısız katılımcının beta enerjisi sınıflandırma doğruluğu ile bu katılımcının Tablo7.7'deki alfa enerjisi doğrulukları arasındaki fark %77,44-%72,33=%5,11 dir ve bu fark tüm katılımcılar arasında en az olandır. Alfa-beta enerjileri arasındaki sınıflandırma doğruluklarının fazla olması daha doğrusu beta enerji yoğunluğunun yüksek alfa enerji yoğunluğunun düşük olması katılımcının başarı bir zihinsel etkinlik gösterdiği ve bu olgunun tam terside başarısız bir uygulama orta çıktığını ifade etmektedir. Alfa-beta enerji dağılımlarındaki fark göz önüne alındığında en başarılı ve en başarısız katılımcı değişmemiştir.

7.2. Tüm Katılımcılara Ait Sınıflandırma Doğruluklarının Ortalaması

Her katılımcıya ait makine öğrenme algoritması doğrulukları önceki alt başlıklar altında her özellik çıkarım yöntemi için tek tek incelenmiştir. Tablo 7.10'da verilen tabloda ise her özellik yöntemi için tüm katılımcıların ortalama sınıflandırma doğrulukları bir arada verilmiştir.

Tablo 7.10. Tüm katılımcıların ortalama sınıflandırma doğrulukları

Özellik Çıkarım Yöntemleri		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
Ort.Güç-Varyans	PCA	%76,84	%75,72	%76,97	%78,12	%64,55	%80,11	%78,60	%82,42	%83,97
	ICA	%77,97	%76,94	%78,74	%79,41	%66,49	%81,67	%80,15	%83,61	%85,38
Entropi	PCA	%77,11	%76,87	%79,31	%80,06	%65,88	%81,86	%80,90	%84	%86,78
	ICA	%78,66	%78,92	%81,10	%82,03	%67,96	%85,05	%82,62	%86,24	%88,67
Hjorth Değişkenlik	PCA	%68,12	%69,00	%70,67	%71,64	%60,81	%73,39	%73,31	%75,51	%76,99
	ICA	%70,87	%71,73	%73,33	%74,16	%63,67	%76,17	%75,76	%78,20	%79,55
Karmaşıklık	PCA	%58,68	%58,47	%60,11	%60,71	%52,71	%61,64	%61,30	%64,44	%65,65
	ICA	%60,64	%60,47	%61,63	%62,48	%54,63	%63,69	%63,11	%66,37	%67,62
FFT	PCA	%72,33	%71,83	%73,83	%74,84	%59,03	%76,58	%74,40	%76,93	%79,21
	ICA	%74,81	%74,52	%76,50	%77,26	%61,54	%79,04	%76,86	%80,75	%81,75
PSD	PCA	%74,52	%74,48	%76,15	%76,76	%60,51	%79,09	%77,55	%80,44	%81,60
	ICA	%77,09	%77,37	%78,88	%79,56	%63,39	%82,02	%80,17	%83,19	%84,64
DWT Alfa Enerjisi	PCA	%66,10	%66,82	%68,39	%69,57	%55,69	%70,74	%70,04	%72,61	%74,17
	ICA	%68,10	%68,95	%70,86	%72,09	%57,64	%73,34	%72,63	%74,98	%76,68
DWT Beta Enerjisi	PCA	%77,68	%78,25	%79,80	%80,90	%66,55	%83,43	%81,32	%84,31	%85,63
	ICA	%80,18	%80,91	%82,62	%83,63	%69,12	%86,13	%84,23	%87,35	%88,68

Çalışma içerisinde kullanılan tüm özelliklerin sınıflandırma doğruluğunun gösterildiği tablo incelendiğinde, zaman alanı için en iyi özellik çıkarım yönteminin %88,67 ile entropi dağılımlarının, frekans alanında da %88,68 ile beta frekans bandı enerjisinin olduğu görülmektedir. Bu özelliklere ait sınıflandırma sonuçlarının ortalaması hemen hemen eşit olsa da, sonuçlar Tablo 7.2 ve Tablo 7.9 a bakılarak en başarılı katılımcı için ayrı ayrı incelenecek olursa, beta bandı enerjisinin %4,17'lik bir farkla daha üstün olduğu görülmektedir. Dolayısıyla çalışma için en verimli yöntem olarak dalgacık dönüşümü özelliğinin ICA+LS-SVM(OvsO) yöntemi ile sınıflandırılması olacaktır. Ayrıca en düşük sınıflandırma ortalamasına sahip karar ağacı algoritması ve hjorth çıkarımlarının tercih edilmesi uygun değildir.

7.3. Tüm Katılımcı Verileri için Makine Öğrenme Algoritması Doğrulukları

10 katılımcıya ait tüm veriler birleştirildiğinde, ortalama güç-varyans, entropi, hjorth parametreleri ve dalgacık özellikleri için 3600x18, fouruier özelliği için 3600x175 ve spektral güç yoğunluğu için 3600x115 boyutunda özellik matrisleri elde edilmiştir.

Tablo 7.11’de elde edilen yeni özellik matrisi için her bir özellik çıkarım yöntemine ait sınıflandırma doğrulukları yer almaktadır.

Tablo 7.11. Tüm verilerin sınıflandırma doğrulukları

Özellik Çıkarım Yöntemleri		Makine Öğrenme Algoritması Sınıflandırma Doğrulukları								
		ANFIS (5 Özellik)	LVQ	MLNN	PNN	K. Ağacı (20 Düğüm)	LDA	kNN (k=10)	SVM (OvsO)	LS-SVM (OvsO)
Ort.Güç-Varyans	PCA	%63,27	%62,96	%64,14	%65,05	%52,22	%65,05	%65,55	%66,11	%66,88
	ICA	%66,44	%66,12	%67,5	%67,94	%54,88	%66,66	%67,33	%67,05	%68,27
Entropi	PCA	%63,78	%63,11	%64,44	%65,05	%52,33	%65,27	%65,96	%66,66	%67,94
	ICA	%66,55	%65,94	%67,15	%67,66	%54,14	%67,14	%68,88	%69,38	%70,22
Hjorth Değişkenlik	PCA	%53,33	%55,11	%56,66	%57,16	%51,05	%56,33	%58,05	%58,94	%59,38
	ICA	%56,44	%58,38	%59,22	%59,94	%53,66	%60,44	%58,77	%60,11	%61,55
Hjorth Karmaşıklık	PCA	%51,96	%52,05	%53,16	%53,88	%48,22	%51,96	%54,27	%55,05	%55,77
	ICA	%55,05	%54,94	%55,55	%56,05	%48,87	%55,38	%56,66	%57,17	%58,33
FFT	PCA	%56,46	%55,11	%56,33	%57,12	%49,38	%59,05	%58,33	%59,11	%60,66
	ICA	%58,05	%58,33	%59,94	%60,88	%51,46	%62,05	%61,22	%63,16	%64,44
PSD	PCA	%57,94	%57,94	%58,56	%59,88	%49,67	%59,33	%60,05	%62,11	%63,22
	ICA	%60,22	%60,77	%61,38	%62,16	%50,44	%63,16	%63,77	%65,05	%66,05
DWT Alfa Enerjisi	PCA	%52,14	%53,05	%53,88	%53,94	%51,11	%56,22	%55,05	%58,27	%61,56
	ICA	%54,72	%54,44	%56,55	%56,33	%53,66	%59,72	%59,44	%64,88	%64,94
DWT Beta Enerjisi	PCA	%61,46	%64,11	%63,16	%66,05	%56,12	%66,55	%69,94	%69,33	%70,14
	ICA	%63,23	%66,58	%65,27	%68,61	%59,02	%70,13	%73,19	%72,45	%73,61

Tüm katılımcıların verilerine ait sınıflandırma doğrulukları incelendiğinde en başarılı sonucun, beta bandı enerjisi sayesinde %78,61 doğruluk oranı ile ICA+LS-SVM(OvsO) yapısı tarafından elde edildiği görülmektedir. Ancak bu özellik çıkarım yöntemi üzerinden değerlendirilecek olursa, Tablo 7.10’daki tüm katılımcıların ortalama sınıflandırma doğrulukları %88,68 olduğu görülmekte ve tüm verilerin sınıflandırma doğruluğu bu değerden %10,07 oranında daha düşük olduğu karşımıza çıkmaktadır. Tablo 7.9’deki en başarılı katılımcıya göre de bu değer %15 oranında daha düşüktür. Dolayısıyla, bu tez çalışmasında amaçlanan zihinsel aktivitelerdeki yön bilgisinin çıkarımı için katılımcıların bireysel başarısının daha üstün olduğunu ve amaçlanan yapının kişisel kullanıma daha yatkın olduğunu söylemek daha doğru olacaktır.

BÖLÜM 8. TARTIŞMA ve ÖNERİLER

Bu tez çalışmasında, beyinde oluşan yöne bağlı EEG sinyallerinde saklı olan yön bilgisinin ortaya çıkarılması hedeflenmiştir. Bu amaç ile çalışma içerisinde yaşları 25-32 arasında değişen ve sağ el kullanan 10 farklı sağlıklı erkek katılımcıdan bilgisayar ekranında yer alan imlecin ana yönlere hareketinin zihinsel olarak tahayyül edildiği durumlar altında kayıtlanan EEG sinyalleri üzerinde çalışılmıştır.

Çalışmanın ilk aşaması, veri toplama ve EEG sinyallerine etki eden bozucu etkileri ortadan kaldırma üzerine kurulmuştur. Bu amaçla, kayıtlar esnasında kullanılan Micromed EEG ölçüm sistemi sayesinde standart 10/20 elektrot yerleşimleri kullanılarak kayıtlanan EEG sinyallerinin, bölüm 2’de açıklanan bozucu etkilerden arındırılması ve düzgün bir sinyal elde edilmesi sağlanmıştır. Ayrıca, beyinde yöne bağlı EEG sinyalleri oluşturmak adına Şekil 5.5’te gösterilen akış diyagramına sahip bir arayüz oluşturulmuş ve her yön düşünce aktivitesi altında her biri 2 saniye uzunluğunda olan 90 farklı örneğe sahip toplamda sağ, sol, yukarı ve aşağı yön aktivitelerinde her katılımcı için 360 farklı veri seti elde edilmiştir.

İkinci aşamada, kayıtlanan ham EEG verilerinin hem zaman hem de frekans alanına ait sinyal özelliklerinin çıkarımı için çalışılmıştır. Sinyallerin işlenmesi sırasında Matlab ileri düzey programlama ortamından yararlanılmıştır. Her katılımcının yön düşünce aktivitesi esnasında kayıtlanan EEG sinyallerinde saklı olan yön bilgilerinin çıkarımı adına, zaman alanında ortalama sinyal gücü, varyans, entropi ve Hjorth parametrelerinden ve frekans alanında da Fourier ve kısa zamanlı Fourier dönüşümü başta olmak üzere, spektral güç yoğunluğu ve dalgacık dönüşümlerinin etkileri ayrı ayrı incelenmiştir. Ancak çalışma içerisinde karmaşıklığı önlemek adına sadece en başarılı ve en başarısız katılımcılara ait uygulama sonuçlarına verilmiştir.

Ayrıca bu aşamada elde edilen özelliklerin boyut indirilmesi ve gürültü gibi gereksiz bileşenlerin eliminasyonu için istatistiksel birer yaklaşım olan PCA ve ICA algoritmalarından faydalanılmıştır. Bu algoritmalar sayesinde EEG verilerindeki temel ve bağımsız bileşenler ayrıştırılmış ve sınıflandırıcıların daha net ve zihinsel etkinlikleri daha doğru olarak ifade eden sinyaller üzerinde işlemesi sağlanmış ve yüksek boyuttaki veri seti daha küçük boyutlara indirilmiştir. Boyut indirme işlemi Şekil 6.5 ve 6.44'te örnek olarak gösterildiği gibi her iki algoritmaya göre de varyans dağılımlarına göre belirlenmektedir. Bu yöntemler sayesinde, 360x1080 boyutundaki fourier özellik matrisi 360x175 boyutuna, 360x275 boyutundaki PSD özellik matrisi 360x115 boyutuna indirilmiştir. Ayrıca bu algoritmalar sonraki aşamada kullanılan sınıflandırıcıların gereksiz bilgiyle uğraşp hesap yoğunluklarının artmasını engellemiştir. PCA yapısı bir kaç temel bileşen ayrımı üzerine işlem yürütürken, ICA yaklaşımında ölçülen sinyallerin nasıl üretildiği sorusunun yanıtını aradığından sinyallerin temeline ulaşmayı amaçlayan bir yapıya sahiptir. Bu yönüyle bölüm 7'de verilen sınıflandırma doğruluklarında ICA algoritma ile birleştirilen sınıflandırıcıların PCA ile birleştirilen sonuçlara kıyasla %1-4 arasında daha başarılı olduğu görülmektedir.

Çalışmanın son aşamasında ise beyinde oluşan yöne bağlı EEG sinyallerinden çıkarılan özellikler kullanılarak, bu sinyallerdeki yön bilgilerini içeren örüntülerin tanınması, yön bulgularının elde edilmesi ve yön bilgilerinin tayini amacıyla Matlab programla ortamı yardımıyla ANFIS, LVQ, MLNN, PNN, Karar Ağacı, LDA, kNN, SVM ve LS-SVM gibi makine öğrenme algoritmalarından yararlanılmıştır. Bu algoritmaların doğruluk hesaplamaları adına k katmanlı çapraz doğrulama (k-fold validation) tekniğinden yararlanılmıştır. Bu teknik ile sınıflandırılacak veri geleneksel yöntemlerde olduğu gibi bir eğitim ve test setine ayrılmayıp, k=10 parçaya bölünmüştür. Literatür çalışmalarında genel olarak 3, 5, 10 gibi parçalar olarak belirlenen k parça sayısı bu çalışma içinde de 10 olarak belirlenmiştir. Her algoritma, k=10 kez eğitilmiş ve test edilmiş olup her seferinde bu k parçalardan rastgele oluşturulan biri ($360/10=36$) test verisi geri kalan 9 parçada eğitim verisi olarak kullanılmış ve elde edilen 10 farklı sonucun ortalaması gerçek sınıflandırma doğruluğu olarak alınmıştır. Geleneksel yöntemlerde eğitim ve test için ayrılan veriler %100 sınıflandırma doğruluğu sağlayana kadar istenildiği gibi kullanıcı

tarafından şekillendirilebilirken, bu yöntem sayesinde eğitim ve test verileri her defasında rastgele seçilmiştir ve bölüm 7’de verilen sınıflandırma doğrulukları daha güvenilir bir duruma kavuşmuştur. Ayrıca, 4 farklı yönün çıkarımı amacıyla bire karşı bir (OvsO) yaklaşımı sayesinde her sınıfın değerine olan üstünlüğü çıkarılmış ve bu sayede 6 farklı sınıflandırıcı yapısının tek bir sınıflandırma algoritması içinde kullanılması, sonuçlarının güvenilirliğini bir kat daha arttırmıştır.

Sınıflandırma algoritmalarından ilki olan ANFIS sınıflandırıcı yapısı gereği en fazla 5 özellik ile sınıflandırma yapabildiğinden dolayı, hem PCA ve hem de ICA ile tüm özelliklerin en fazla bilgi içeren 5 tanesi alınarak kullanılmıştır. Bazı durumlarda örneğin Tablo 7.6’da PSD özellikleri üzerine uygulanan sınıflandırıcı doğrulukları incelendiğinde 7. katılımcıya ait ANFIS sınıflandırma doğruluklarının diğer bazı sınıflandırıcılara göre şaşırtıcı bir şekilde oldukça yüksek bir sonuç sağladı kaydedilmiştir. Ancak bu 5 özellik tüm özelliklerin %75-95 arasında değişen bilgi içeriğine sahip olduğundan bu sonuçların doğrulukları pekte güvenilir olmamaktadır.

Bölüm 7’de verilen özellik çıkarım yöntemleri üzerine uygulanan makine öğrenme algoritmalarının sınıflandırma doğrulukları incelendiğinde en iyi sonuca ICA algoritması yardımı ile boyut indirgendikten sonra LS-SVM(OvsO) yapısı tarafından ulaşıldığı tüm sonuçlarda görülmektedir. Ayrıca Tablo 7.10’da verilen sonuçlar incelendiğinde, tüm katılımcıların ortalama sınıflandırma doğrulukları, yöne bağlı zihinsel etkinlikler altında kayıtlanan EEG sinyallerinde saklı olan yön bilgilerinin ortaya çıkarılmasında en başarılı özellik çıkarım yöntemlerinin, zaman alanında entropi özelliği ve frekans alanında ayrık dalgacık dönüşümü ile ayrıştırılan sinyal enerjilerinin olduğunu açıkça ortaya koymuştur.

Zaman alanında en iyi yöntem olan entropi özelliğine ait sınıflandırma sonuçlarının gösterildiği Tablo 7.2’de en başarılı katılımcının zihinsel aktivitelerinde %97,94 ve en başarısız katılımcının %75,55 doğruluk seviyelerinde kaldığı ve frekans alanında en iyi özellik çıkarım yöntemi olan beta dalgacığı enerjisi soncunda Tablo 7.9’da görüldüğü gibi en başarılı kullanıcının zihinsel aktivitelerini %98,61 oranında başarılı bir şekilde yönlendirdiği ama en başarısız katılımcının zihinsel aktivite konusunda %77,44 seviyelerine kadar düşen bir başarı oranında kaldığı

gözlenmektedir. Dolayısıyla sistemin başarı yüzdesi katılımcıların zihinsel aktivitelerine bağlı olarak değişebilmektedir. Yani imleç hareketini zihinsel olarak başarılı bir şekilde gerçekleştirebilen katılımcı için sınıflandırıcı sonuçları yüksek değerler sağlarken bu başarıya ulaşmayan katılımcılarda sonuçlar düşük seviyelerde kalmaktadır.

Bilinçli düşünme ve odaklanma merkezi olan frontal lobda zihinsel etkinlikler sırasında beta dalgalarının ve hareket hayalinin zihinsel olarak algılanması sırasında da oksipital lobda alfa dalgalarının oluşması beklenen bir sonuç olmaktadır. En iyi katılımcı için Şekil 6.6'da verilen kafatası dağılımları ile en başarısız katılımcı için Şekil 6.11'de verilen kafatası dağılımları kıyaslandığında, en başarılı katılımcının frontal lobdaki beta dağılımları dikkat çekmektedir. Yani bu katılımcının zihinsel etkinliklerde başarılı olduğunu gösterir ve oksipital lobdaki alfa dağılımları da imleç hareketinin hayal edilebildiği şeklinde yorumlanır. Ancak en başarısız katılımcı için aynı şeyleri söylemek mümkün değildir. Beta yoğunluklarının kafatası dağılımlarında temporal veya oksipital loblara yayılması katılımcının uygulama esnasında sıkılması, dış ortamdan gelen ses veya uyarıcılara yönelmesi ya da vücudun hareket ettiği ya da hareket etme isteğinde bulunduğu yargılarını çağrıştırmaktadır. Bu katılımcılara ait sınıflandırma doğrulukları da bu yaklaşımları desteklemektedir.

Ayrıca tez çalışması içerisinde kayıtlanan tüm verilerin birleştirilmesi ile elde edilen sınıflandırma doğruluklarının verildiği Tablo 7.11 ile ortalama sınıflandırma doğruluklarını gösteren Tablo 7.10 en başarılı katılımcı üzerinden kıyaslandığında beta enerjisinin %88,68 gibi bir ortalama değerden %73,61 gibi bir seviye gerilediği görülmektedir. Yani tüm verilerin birleştirilmesi %10,07 oranında bir düşüşe yol açmıştır. Dolayısıyla, bu tez çalışmasında amaçlanan zihinsel aktivitelerdeki yön bilgisinin çıkarımı için katılımcıların bireysel başarılarının daha üstün olduğunu ve amaçlanan yapının kişisel kullanıma daha yatkın olduğunu söylemek daha doğru olacaktır.

Sonuç olarak, bu tez çalışması ile yöne bağlı zihinsel etkinlikler altında beyinde oluşan EEG sinyallerindeki yön bilgisi, tüm katılımcılar için sağ, sol, aşağı ve yukarı

yön durumları altında hem zaman ve hem de frekans alanında, sinyal öznitelikleri çıkarılarak tek tek incelenmiş ve makine öğrenme algoritmaları yardımı ile sınıflandırılmıştır. Elde edilen grafiksel değerler ve sonuçlar en başarılı ve en başarısız katılımcılar üzerinden bu tez kapsamında değerlendirilmiştir. İmleç kontrolünün zihinsel olarak üretilen EEG sinyalleri ile düşünsel olarak yapılabilmesini sağlayacak olan bir BBA sistemi için en iyi yapının ICA+LS-SVM(OvsO) olduğu ve bu amaçla en iyi özellik çıkarım yöntemlerinin zaman alanında entropi ve frekans alanında da dalgacık enerjilerinin olduğu kanısına varılmış ve oldukça yüksek başarımların elde edilebildiği gösterilmiştir.

Ayrıca, tez çalışması içerisinde incelenen yöntemler EEG kayıt sisteminin kısıtlamaları nedeniyle çevrimdışı olarak denenmiştir. İlerleyen dönemlerde EEG kayıtlarının gerçek zamanlı olarak yapılabildiği sistemler yardımı ile çalışmanın performansı daha net bir şekilde ortaya konabilecek ve her katılımcının bilgisayar imlecini gerçek zamanlı olarak hareket ettirebilmesi sağlanacaktır.

KAYNAKLAR

- [1] Polat, D. & Çataltepe, Z., Feature Selection and Classification on Brain Computer Interface (BCI) Data, 20th Signal Processing and Communications Applications Conference (SIU), pages:1-4, Turkey, 2012.
- [2] <http://en.wikipedia.org/wiki/Electroencephalography>, Erişim Tarihi: 26.06.2015.
- [3] Shih, J. J., Krusienski, D. J., Wolpaw, J. R., Brain-computer interfaces in medicine. Mayo Clinic Proceedings, 87(3):2638-279, 2012.
- [4] Nicolas-Alonso, L. F., & Gomez-Gil, J., Brain computer interfaces, a review. Sensors, 12(2):1211-1279, 2012.
- [5] Hwanga, H. J., Kimb, S., Choia, S., Ima, C. H., EEG-Based Brain-Computer Interfaces: A Thorough Literature Survey. International Journal of Human-Computer Interaction, 29(12):814-826, 2013.
- [6] Fouad, M. M., Amin, K. M., El-Bendary, N., Hassanien, A. E., Brain Computer Interface: A Review. Brain-Computer Interfaces-Intelligent Systems Reference Library, 74:3-30, 2015.
- [7] Çetin, M., Beyin Bilgisayar Arayüzü (BBA) Sistemleri için Elektroensefalografi (EEG) Sinyal Analizi Yöntemlerinin Geliştirilmesi, 107E135 nolu Tübitak projesi, 2011.
- [8] <http://www.acikbilim.com/2012/04/dosyalar/beyin-makine-arayuzleri.html>
Erişim Tarihi: 26.06.2015
- [9] Argunşah, A. Ö., beyinden bilgisayara bir yol: BEYİN BİLGİSAYAR ARAYÜZÜ, Sabancı Üniversitesi Yapay Görme ve Örüntü Analizi Laboratuvarı Dergisi, İstanbul, 2007.
- [10] McFarland, D. J., Lefkowicz, A. T., and Wolpaw, J. R., Design and operation of an EEG-based brain-computer interface with digital signal processing technology. Behavior Research Methods, Instruments, & Computers, 29(3):337-345, 1997.
- [11] Kostov, A. and Polak, M., Parallel man-machine training in development of EEG-based cursor control. IEEE Transactions on Rehabilitation Engineering, 8(2):203-205, 2000.

- [12] Fabiani, G. E., McFarland, D. J., Wolpaw, J. R., Pfurtscheller, G., Conversion of EEG activity into cursor movement by a brain-computer interface (BCI). *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 12(3):331-338, 2004.
- [13] Wolpaw, J. R., and McFarland, D. J., Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the National Academy of Sciences of the United States of America*, 101(51):17849-17854, 2004.
- [14] Trejo, L. J., Rosipal, R., and Matthews, B., Brain-computer interfaces for 1-D and 2-D cursor control: designs using volitional control of the EEG spectrum or steady-state visual evoked potentials. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, , 14(2):225-229, 2006.
- [15] Kayagil, T., Bai, O., Lin, P., Furlani, S., Vorbach, S., Hallett, M., Binary EEG control for two-dimensional cursor movement: An online approach. *IEEE/ICME International Conference on Complex Medical Engineering*, 1542-1545, 2007.
- [16] Wilson, J. A., Schalk, G., Walton, L. M., and Williams, J. C., Using an EEG-based brain-computer interface for virtual cursor movement with BCI2000. *Journal of visualized experiments*, 29, 2009.
- [17] Gentiletti, G. G., Gebhart, J. G., Acevedo, R. C., Yáñez-Suárez, O., Medina-Bañuelos, V., Command of a simulated wheelchair on a virtual environment using a brain-computer interface. *Irbm*, 30(5):218-225, 2009.
- [18] Li, Y., Long, J., Yu, T., Yu, Z., Wang, C., Zhang, H., Guan, C., An EEG-based BCI system for 2-D cursor control by combining Mu/Beta rhythm and P300 potential. *IEEE Transactions on Biomedical Engineering*, 57(10):2495-2505, 2010
- [19] Long, J., Li, Y., Yu, T., Gu, Z., Target selection with hybrid feature for BCI-based 2-D cursor control. *IEEE Transactions on Biomedical Engineering*, 59(1):132-140, 2012.
- [20] Ubeda, A., Azorin, J. M., Garcia, N., Sabater, J. M., Pérez, C., Brain-machine interface based on EEG mapping to control an assistive robotic arm. *The 4th International Conference on Biomedical Robotics and Biomechatronics*, 1311-1315, 2012.
- [21] Alomari, M. H., AbuBaker, A., Turani, A., Baniyounes, A. M., Manasreh, A., EEG Mouse: A Machine Learning-Based Brain Computer Interface. *International Journal of Advanced Computer Science and Applications*, 5(4), 2014.

- [22] Allison, B. Z., McFarland, D. J., Schalk, G., Zheng, S. D., Jackson, M. M., Wolpaw, J. R., Towards an independent brain-computer interface using steady state visual evoked potentials. *Clinical neurophysiology*, 119(2):399-408, 2008.
- [23] Amiri, S., Fazel-Rezai, r., Asadpour, V., A Review of Hybrid Brain-Computer Interface Systems. *Advances in Human-Computer Interaction Volume 2013*, Article ID 187024, 8 pages, 2013.
- [24] Dhillon, H. S., Singla, R., Rekhi, N. S., Jha, R., EOG and EMG based virtual keyboard: A brain-computer interface. *2nd IEEE International Conference on Computer Science and Information Technology*, 259-262, 2009.
- [25] Middendorf, M., McMillan, G., Calhoun, G., Jones, K. S., Brain-computer interfaces based on the steady-state visual-evoked response. *IEEE Transactions on Rehabilitation Engineering*, 8(2):211-214, 2000.
- [26] Teplan, M., Fundamentals of EEG measurement. *Measurement science review* 2(2):1-11, 2006.
- [27] Duffy, Frank H., Vasudeva G. Iyer, and Walter W. Surwillo., *Brain Electrical Activity: An Introduction to EEG Recording. Clinical Electroencephalography and Topographic Brain Mapping*. Springer New York, 1-10, 1989.
- [28] Al-Kadi, M. I., Mamun B. I. R., and Mohd A. M. A., Evolution of electroencephalogram signal analysis techniques during anesthesia. *Sensors* 13(5):6605-6635, 2013.
- [29] Aydemir, Ö. & Kayıkçıoğlu, T., *Akademik Bilişim'09 - XI. Akademik Bilişim Konferansı Bildirileri*, Türkiye, 2009.
- [30] http://www.aktuelpsikoloji.com/haber.php?haber_id=4402, Erişim Tarihi: 26.06.2015.
- [31] <http://www.kayserimentalhafıza.com/sag-ve-sol-beynin-islevleri/>, Erişim Tarihi: 26.06.2015.
- [32] <http://www.braininjury.com/symptoms.shtml>, Erişim Tarihi: 26.06.2015.
- [33] http://www.newscientist.com/article/dn9969-introduction-the-human-brain.html?full=true#.VWW50M_tmko, Erişim Tarihi:28.05.2015.
- [34] <http://www.ethemkocabas.com/?pnun=49&pt=Beynimizi%20ke%C5%9Ffedelim>, Erişim Tarihi: 26.06.2015.
- [35] http://tr.wikipedia.org/wiki/Beyin_loblar%C4%B1, Erişim Tarihi: 26.06.2015.

- [36] MEGEP (Mesleki Eğitim ve Öğretim Sisteminin Güçlendirilmesi Projesi), “Biyomedikal Cihaz Teknolojileri-ELEKTROTLAR”, Ankara, 2007.
- [37] <http://www.medelek.com.tr/kulak-elektrodu/-1151242/310/tr-TR/Details.aspx>, Erişim Tarihi:26.06.2015.
- [38] <http://www.jarisupply.com/non-sterile-reusable-ear-clip-electrodes-for-eeg.html>, Erişim Tarihi:26.06.2015.
- [39] Lofuede, J., Seoane, F., Thordstein, M., Soft Textile Electrodes for EEG Monitoring. 10th IEEE International Conference on Information Technology and Applications in Biomedicine (ITAB), 1-4, 2010.
- [40] Mahmud, M., EEG Based Brain-Machine Interface for Navigation of Robotic Device. International Conference on Biomedical Robotics and Biomechatronics, The University of Tokyo, Tokyo, Japan, September 26-29, 2010.
- [41] Jasper H (1958) The ten twenty electrode system of the international federation. *Electro. and Clin. Neuro.* 10(2):370-375.
- [42] Herwig, U., Satrapi, P., Schönfeldt-Lecuona, C., Using the International 10-20 EEG System for Positioning of Transcranial Magnetic Stimulation. *Brain Topography*, 16, 2, 2003.
- [43] <http://www.diytdcs.com/tag/1020-positioning/>, Erişim Tarihi:26.06.2015.
- [44] <http://www.bem.fi/book/13/13.htm>, Erişim Tarihi:26.06.2015.
- [45] Paulraj M P, Abdul Hamid Adom, Hema C R, Divakar Purushothaman, “Brain Machine Interface for Physically Retarded People using Colour Visual Tasks”, 6th International Colloquium on Signal Processing & Its Applications (CSPA), 2010.
- [46] Jurcak, V., Tsuzuki, D., Dan, I., “10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems”, *NeuroImage*, 34, 1600-1611, 2007.
- [47] Al-Kadi, M. I., Reaz, M. B. I., and Ali, M. A. M., Evolution of electroencephalogram signal analysis techniques during anesthesia. *Sensors*,13(5):6605-6635, 2013.
- [48] Wu, J., Ifeachor, E.C., Allen, E.M., Wimalaratna, S.K., Huson, N.R., “Intelligent artefact identification in electroencephalography signal processing”, *IEEE Proceedings of Science, Measurement and Technology*, 144, 5, 193-201, 1997.
- [49] Fisch, B., EEG Artifacts. LSU Medical Center.

- [50] Çetin, M., Beyin Bilgisayar Arayüzü (BBA) Sistemleri için Elektroensefalografi (EEG) Sinyal Analizi Yöntemlerinin Geliştirilmesi. 107E135 nolu Tübitak projesi, 2011.
- [51] Rodríguez-Bermúdez, G., García-Laencina PJ., Automatic and Adaptive Classification of Electroencephalographic Signals for Brain Computer Interfaces. *Journal of Medical Systems*, 36(1):51-63, 2012.
- [52] Zhou, P., Cao, H., Ge', J., Zhao, X., Wang. M., "An Automatic Optimum Data selection Method For EEG-based Brain-computer Interface", IEEE/ICME International Conference on Complex Medical Engineering, 1515-1518, Beijing, 2007.
- [53] Nagel, J. H., Biopotential amplifiers. *The Biomedical Engineering Handbook*, 2000.
- [54] Bai, Y. W., Chu, W. Y., Chen, C. Y., Lee, Y. T., Tsai, Y. C., & Tsai, C. H., Adjustable 60Hz noise reduction by a notch filter for ECG signals. *Proceedings of the 21st IEEE Conference In Instrumentation and Measurement Technology, IMTC 04*, 3:1706-1711, 2004.
- [55] Gotman J., *Digital EEG From Basics to Advanced Analysis*. McGill University, Montreal Neurological Institute, 2009.
- [56] Gray, N., *Abcs of ADCs*. National Semiconductor Corporation, 2003.
- [57] <http://elektronikhobi.net/analog-sinyallerin-orneklenmesi-sampling-ve-nyquist-teoremi/>, Erişim Tarihi:26.06.2015.
- [58] Ferree, T. C., Luu, P., Russell, G. S., Tucker, D. M., Scalp electrode impedance, infection risk, and EEG data quality. *Clinical Neurophysiology*, 112(3):536-544. 2001.
- [59] <http://mentalhealthdaily.com/2014/04/15/5-types-of-brain-waves-frequencies-gamma-beta-alpha-theta-delta/>, Erişim Tarihi:26.06.2015.
- [60] <http://www.brainworksneurotherapy.com/what-are-brainwaves>, Erişim Tarihi: 26.06.2015.
- [61] Matlab Documentation (2009), Version 7.8, Release 2009a, The MathWorks, Inc. (Lisans numarası : 834260)
- [62] Sleight J, Pillai P, Mohan S., Classification of executed and imagined motor movement EEG signals. *Ann Arbor: University of Michigan*, 1-10, 2009.
- [63] Byford, G. H., Signal variance and its application to continuous measurements of EEG activity. *Proceedings of the Royal Society of London, Series B. Biological Sciences*, 161(984):421-437, 1965.

- [64] Machavarapu, S. C., Mukul, M. K., Kumar, D., EEG classification based on variance. IEEE International Conference on Green Computing Communication and Electrical Engineering, 1-4), 2014.
- [65] Linden, M., Habib, T., Radojevic., A controlled study of the effects of EEG biofeedback on cognition and behavior of children with attention deficit disorder and learning disabilities. Biofeedback and self-regulation, 21(1):35-49,1996.
- [66] Shannon, C. E., Communication theory of secrecy systems. Bell system technical journal, 28(4):656-715, 1948.
- [67] Dinh Phung, Dat Tran, Wanli Ma, Phuoc Nguyen and Tien Pham, Using Shannon Entropy as EEG Signal Feature for Fast Person Identification. European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, 2014.
- [68] Sleight, J. W., Olofsen, E., Dahan, A., De Goede, J., Steyn-Ross, D. A., Entropies of the EEG: The effects of general anaesthesia. 2001.
- [69] Hjorth, B., EEG analysis based on time domain properties. Electroencephalography and clinical neurophysiology, 29(3):306-310, 1970.
- [70] Vourkas, M., Micheloyannis, S., Papadourakis, G., Use of ann and hjorth parameters in mental-task discrimination. First international conference on Advances in medical signal and information processing, 327-332, 2000.
- [71] Oh, S. H., Lee, Y. R., and Kim, H. N., A Novel EEG Feature Extraction Method Using Hjorth Parameter. International Journal of Electronics and Electrical Engineering, 2(2):106-110, 2014.
- [72] Vidaurre, C., Krämer, N., Blankertz, B., Schlögl, A., Time domain parameters as a feature for EEG-based brain-computer interfaces. Neural Networks, 22(9):1313-1319, 2009.
- [73] Bashashati, A., Fatourechi, M., Ward, R. K., Birch, G. E., A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. Journal of Neural engineering, 4(2):R32, 2007.
- [74] Ochoa, J. B., EEG signal classification for brain computer interface applications. Ecole Polytechnique Federale De Lausanne, 7:1-72, 2002.
- [75] Suleiman, A. B. R., and Fatehi, T. A. H., Features Extraction Techniques of EEG Signal for BCI Applications. Faculty of Computer and Information Engineering Department College of Electronics Engineering, University of Mosul, Iraq, 2007.
- [76] Nicolas-Alonso, L. F., and Gomez-Gil, J., Brain computer interfaces, a review. Sensors, 12(2):1211-1279, 2012.

- [77] Guerrero-Mosquera, C., and Navia Vazquez, A., New approach in features extraction for EEG signal detection. Annual International Conference of the IEEE In Engineering in Medicine and Biology Society, 13-16, 2009.
- [78] Hekim, M., ANN-based classification of EEG signals using the average power based on rectangle approximation window. *Przeglad Elektrotechniczny (Electrical Review)*, 88, 2012.
- [79] Proakis JG, Manolakis DG., *Digital Signal Processing-Principles, Algorithms and Applications*. 3rd ed. New Jersey: Prentice-Hall; 1996 [chapter 12].
- [80] Welch, P., D., The Use of Fast Fourier Transform for the Estimation of Power Spectra: A Method Based on Time Averaging Over Short, Modified Periodograms. *IEEE Trans. Audio Electroacoustics*, AU-15:70-73, 1967.
- [81] Stoica P, Moses R., *Spectral Analysis of Signals*. New Jersey: Prentice-Hall International, 2005.
- [82] Murenzi, R., Combes, J. M., Grossman, A., and Tchmitchian, P., (Eds), *Wavelets*, Springer-Verlag, Berlin, Heidelberg, New York, 1988.
- [83] Franaszczuk, P. J., Bergey, G. K., and Durka, P. J., Time–frequency analysis of mesial temporal lobe seizures using the matching pursuit algorithm. *Soc. Neurosci. Abstr.*, 22,184, 1996.
- [84] Hubbard, B.B., *The World According to Wavelets: The Story of a Mathematical Technique in the Making*; A.K. Peters: Natick, MA, USA, 1998.
- [85] Semmlow, J. L., *Biosignal and Biomedical Image Processing. Matlab based Application*. Marcel Dekker. USA, 443, 271-301, 2004.
- [86] Chang, C. J., *Time frequency analysis and wavelet transform tutorial. Time frequency analysis for biomedical engineering*, National Taiwan University.
- [87] Boudria Y, Feltane A, Besio W. Significant improvement in one-dimensional cursor control using Laplacian electroencephalography over electroencephalography. *J. of Neural Eng.*, 11(3):035014, 2014.
- [88] Rambabu C, Murthy B. R., EEG Signal with Feature Extraction using SVM and ICA Classifiers. *Int. J. of Comp. App.*, 85(3):1-7, 2014.
- [89] Cao L., J, Chua K., S., Chong W., K., Lee H., P., Gu Q., M., A comparison of PCA, KPCA and ICA for dimensionality reduction in support vector machine. *Neurocomputing* 55(1):321-336, 2003.
- [90] Kavita, M., Vargantwar M.,R., Sangita, M.,R., Classification of EEG using PCA, ICA and Neural Network. *Int. J. of Eng. and Advan. Tech.*, 1:1-4, 2011.

- [91] Mozaffar, S., and Petr, D., Artifact extraction from EEG data using independent component analysis. Information Telecommunication and Technology Center, University of Kansas, Lawrence, KS, Tech. Rep. ITTC-FY2003-TR-03050-02, 2002.
- [92] Sezer, O. G., Erçil, A., Keskinöz, M., Destek vektör makinesi kullanarak bağımsız bileşen tabanlı 3B nesne tanıma= Independent component based 3D object recognition using support vector machines.2005.
- [93] Christian Jutten, Jeanny Herault, Blind separation of sources, part I: An adaptive algorithm based on neuromimetic architecture *Signal Processing*, 24(1):1-10, 1991.
- [94] Saraoglu, H. M., Temurtas, F., Altikat, S., Quantitative classification of HbA1C and blood glucose level for diabetes diagnosis using neural networks. *Aust. Phy. And Eng. Sci. in Med.* 36(4):397-403, 2013.
- [95] Jang, J. S. R., ANFIS: adaptive-network-based fuzzy inference system,” *IEEE Trans. on Syst., Man and Cyber.*, Vol. 23(3):665–685, 1993.
- [96] Gulbag, A., Temurtas, F., A study on quantitative classification of binary gas mixture using neural networks and adaptive neuro-fuzzy inference systems. *Sensors and Actuators B*, 115:252-262, 2006.
- [97] Kohonen, T., Improved versions of learning vector quantization. In *Proc. of the IEEE Int. Joint Conf. on N. N.* 545-550 New York, 1990.
- [98] Temurtas, F., A comparative study on thyroid disease diagnosis using neural networks. *Exp. Sys. with App.* 36:944-949, 2009.
- [99] Rumelhart D. E., Hinton G. E., Williams R.J., Learning internal representations by error propagation. In Rumelhart D. E., McClelland J. (Eds.), *Parallel Distributed Processing*, 1:318-362, MIT Press, Cambridge, 1986.
- [100] Kohonen, T., *Learning Vector Quantization*. Springer series in Inf. Sci., 30:203-217, 1997.
- [101] Temurtas, H., Yumusak, N., Temurtas, F., A comparative study on diabetes disease diagnosis using neural networks. *Exp. Sys. with App.* 36:8610-8615, 2009.
- [102] Hagan M. T., Menhaj M., Training feed forward networks with the Marquardt algorithm, *IEEE Trans. Neural Networks*, 5:989-993, 1994.
- [103] Chester, D. L., Why two hidden layers are better than one. *Intern. Joint Conf. on Neural Networks*, 265-268, 1990.

- [104] Bascil, M. S., Temurtas, F., A Study on Hepatitis Disease Diagnosis Using Multilayer Neural Network with Levenberg Marquardt Training Algorithm. *J. of Med. Sys.* 35(3):433-436, 2011.
- [105] Lapedes, A. S. and Farber, R. M., How neural nets work. *Neural Information Processing Systems*, 442-456, 1998.
- [106] Hunter, D., Yu, H., Pukish, M. S., Kolbusz, J., Wilamowski, B. M., Selection of Proper Neural Network Sizes and Architectures-A Comparative Study. *IEEE Trans. on Ind. Inf.* 8(2):228-240, 2012.
- [107] Specht, D. F., Probabilistic neural networks. *Neural Networks.* 3:109-118, 1990.
- [108] Hazrati, M. Kh., Erfanian, A., An online EEGbased brain-computer interface for controlling hand grasp using an adaptive probabilistic neural network. *Med. Eng. and Phy.* 32(7):730-739, 2010.
- [109] Haykin, S., *Neural Networks: A Comprehensive Foundation*. Macmillan, New York, 1994.
- [110] Bascil, M. S., Oztekin, H., A Study on Hepatitis Disease Diagnosis Using Probabilistic Neural Network. *J. of Med. Sys.* 36(3):1603-1606, 2012.
- [111] Nasehi, S., Pourghassem, H., An Optimal EEG-based Emotion Recognition Algorithm Using Gabor. *WSEAS Trans. on Sign. Proc.* 3(8):87-99, 2012.
- [112] Ward Systems Group., *NeuroShell 2 User's Manual Help (Apply PNN Network)*. Ward Systems Group, Inc., Dr. Frederic, MD Maryland 21703, 2008.
- [113] Utgoff, P. E., *Decision Trees*, 1998.
- [114] Kamber, M., Winstone, L., Gong, W., Cheng, S., Han, J., Generalization and decision tree induction: efficient classification in data mining. *Seventh International Workshop on Research Issues in Data Engineering*, 111-120, 1997.
- [115] Emel, G. G., ve Taşkın, Ç., Veri Madenciliğinde Karar Ağaçları ve Bir Satış Analizi Uygulaması. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 6(2), 2005.
- [116] J. R. Quinlan., *C4.5: Programs for Machine Learning*. Morgan Kaufmann, 1993.
- [117] Fisher, R. A., The use of multiple measurements in taxonomic problems. *Annals of eugenics*, 7(2):179-188, 1936.

- [118] Rao, C. R., The utilization of multiple measurements in problems of biological classification. *Journal of the Royal Statistical Society. Series B (Methodological)*, 10(2):159-203, 1948.
- [119] Balakrishnama, S., and Ganapathiraju, A., *Linear discriminant analysis-a brief tutorial*. Institute for Signal and information Processing, 1998.
- [120] Cover, T., and Hart, P., Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1):21-27, 1967.
- [121] Fukunaga, K., and Narendra, P., M., A branch and bound algorithm for computing k-nearest neighbors. *IEEE Transactions on Computers* 24, 750-753, 1975.
- [122] Khan, M., Ding, Q., Perrizo, W., k-nearest neighbor classification on spatial data streams using P-trees. In *Advances in Knowledge Discovery and Data Mining*, Springer Berlin Heidelberg, 517-528, 2002.
- [123] Lu, W., Shen, Y., Chen, S., Ooi, B. C., Efficient processing of k nearest neighbor joins using mapreduce. *Proceedings of the VLDB Endowment*, 5(10):1016-1027, 2012.
- [124] Nigsch, F., Bender, A., Van Buuren, B., Tissen, J., Nigsch, E., Mitchell, J. B., Melting point prediction employing k-nearest neighbor algorithms and genetic parameter optimization. *Journal of Chemical Information and Modeling* 46(6): 2412–2422, 2006.
- [125] Coomans, D., and Massart, D. L., Alternative k-nearest neighbour rules in supervised pattern recognition : Part 1. k-Nearest neighbour classification by using alternative voting rules. *Analytica Chimica Acta* 136:15-27, 1982.]
- [126] Hall, P., Park, B. U., Samworth, R. J., Choice of neighbor order in nearest-neighbor classification. *Annals of Statistics* 36(5):2135-2152, 2008.
- [127] Cortes, C., Vapnik, V., *Support-Vector Networks*. *Machine Learning*, 20:273-97, 1995.
- [128] Gunn, S. R., *Support Vector Machines for classification and regression*. Technical Report: University of Southampton; 1998.
- [129] Vapnik V., *Statistical Learning Theory*, New York: John Wiley & Sons Inc.; 1998.
- [130] Burges, C. J. C., A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2):121-67, 1998.
- [131] Suykens, J. A. K., Vandewalle J., Least squares support vector machine classifiers. *Neural Processing Letters*, 9(3):293-300, 1999.

- [132] Suykens, J. A. K., Vandewalle, J., Optimal Control by Least Squares Support Vector Machines. *Neural Networks*, 14(1):23-35, 2001.
- [133] Gestel, T. V, Suykens J. A. K., Baesens, B., Viaene, S., Vanthienen, J., Dedene, G., De Moor, B., Vandewalle, J., Benchmarking least squares support vector machine classifiers. *Machine Learning*, 54:5-32, 2004.
- [134] Hsu, C. W., and Lin, C. J., A comparison of methods for multiclass support vector machines. *Neural Networks, IEEE Transactions on*, 13(2):415-425, 2002.
- [135] Weston, J., and Watkins, C., Multi-class support vector machines. In M. Verseley, editor, *Proceedings of ESANN99*, Brussels, D. Facto Press, 1999.
- [136] Pal, M., Multiclass approaches for support vector machine based land cover classification. *arXiv preprint arXiv:0802.2411*, 2008.
- [137] Milgram, J., Cheriet, M., and Sabourin, R., “One Against One” or “One Against All”: Which One is Better for Handwriting Recognition with SVMs?. In *Tenth International Workshop on Frontiers in Handwriting Recognition*. Suvisoft, 2006.

ÖZGEÇMİŞ

Muhammet Serdar BAŞÇIL, 16.01.1983 de Kilis'te doğdu. İlk, orta ve lise eğitimini burada tamamladı. 2001 yılında Kilis Lisesi, Süper Lise Bölümünden mezun oldu. Aynı yıl başladığı Selçuk Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nü 2006 yılında bitirdi. 2006-2008 yılları arasında özel bir şirkette teknik sorumlu olarak çalıştı. 2008-2009 yılları arasında vatani hizmetini tamamladı. 2009 yılında Sakarya Üniversitesi Fen Bilimleri Enstitüsü'nde başladığı Yüksek Lisansını 2011 yılında tamamladı. Aynı yıl Doktora programına kaydoldu. Halen Bozok Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır.