

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**İMLECİN İKİ BOYUTLU HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ
EEG İŞARETLERİNİN KARAR AĞAÇ YAPISI ESASLI SINIFLANDIRILMASI**

DOKTORA TEZİ

Elektronik Yük. Müh. Önder AYDEMİR

**NİSAN 2013
TRABZON**

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**İMLECİN İKİ BOYUTLU HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ
EEG İŞARETLERİNİN KARAR AĞAÇ YAPISI ESASLI SINIFLANDIRILMASI**

Elektronik Yüksek Mühendisi Önder AYDEMİR

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
“DOKTOR (ELEKTRONİK MÜHENDİSLİĞİ)”
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

Tezin Enstitüye Verildiği Tarih : 26.02.2013

Tezin Savunma Tarihi : 01.04.2013

Tez Danışmanı : Prof. Dr. Temel KAYIKÇIOĞLU

Trabzon 2013

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Ana Bilim Dalında
Önder Aydemir Tarafından Hazırlanan

İMLECİN İKİ BOYUTLU HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ
EEG İŞARETLERİNİN KARAR AĞAÇ YAPISI ESASLI SINIFLANDIRILMASI

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 12 / 03 / 2013 gün ve 1497 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda

DOKTORA TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Temel KAYIKÇIOĞLU
Üye : Prof. Dr. Mahmut Kemal KIYMIK
Üye : Doç. Dr. Ali GANGAL
Üye : Doç. Dr. Cemal KÖSE
Üye : Doç. Dr. Murat EKİNCİ


.....
.....
.....
.....
.....

Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Bu doktora tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektronik Mühendisliği Bilim Dalı Doktora Programı'nda ve Trabzon Klinik Araştırmalar Etik Kurul Başkanlığı'nın 08.01.2010 tarih ve 72 sayı numaralı izni ile hazırlanmıştır.

Bu tez çalışmasında beyin bilgisayar arayüzü uygulamalarına yönelik bilgisayar imlecinin yukarı, aşağı, sağa ve sola hareket ettirilmesinin hayal edilmesi sırasında kaydedilmiş EEG işaretlerinin, çıkarılan özniteliklere dayalı sınıflandırılması konusu işlenmiştir.

Tez çalışmam süresince bilimsel desteği ve değerli düşünceleriyle bana her aşamada yardımcı olan danışmanım Sayın Prof. Dr. Temel KAYIKÇIOĞLU'na, ve yine tez çalışmam süresince değerli katkılarından ötürü Doç. Dr. Ali GANGAL'a, Doç. Dr. Cemal KÖSE'ye ve Arş. Gör. Mehmet ÖZTÜRK'e teşekkür ederim.

EEG verilerinin toplanması aşamasında çalışmama gönüllü olarak katılan Hüseyin KAZAZ ve Mustafa MUTLU'ya desteklerinden ve sabırlarından ötürü çok teşekkür ederim.

Tez çalışmamı maddi olarak destekleyen Karadeniz Teknik Üniversitesi Bilimsel Araştırma Projeleri Birimi'ne (Proje No: 2008.112.04.3), Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TUBİTAK)'a (Proje No: 110E035), Türkiye Bilişim Derneği'ne ve Turkcell Akademi'ye sonsuz teşekkürü bir borç bilirim.

Tüm eğitim-öğretim hayatım boyunca maddi ve manevi desteklerini esirgemeyen aileme, sevgili eşim Tuğba AYDEMİR'e ve oğlum Furkan Alper AYDEMİR'e teşekkür ederim.

Bu tezin, bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Önder AYDEMİR

Trabzon 2013

TEZ BEYANNAMESİ

Doktora Tezi olarak sunduđum “İmlecın İki Boyutlu Hareketinin Hayali Sırasında Kaydedilmiř EEG İřaretlerinin Karar Ađa Yapısı Esaslı Sınıflandırılması” bařlıklı bu alıřmayı bařtan sona kadar danıřmanım Prof. Dr. Temel KAYIKIOĐLU’nun sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, bařka kaynaklardan aldıđım bilgileri metinde ve kaynakada eksiksiz olarak gösterdiđimi, alıřma süresince bilimsel arařtırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya ıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 25/02/2013

Önder AYDEMİR

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VIII
SUMMARY.....	IX
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ.....	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Beynin Nöronal Yapısı.....	1
1.3. EEG'nin Kısa Tarihçesi.....	2
1.4. EEG İşaretlerinin Özellikleri.....	3
1.5. EEG'de Artifaktlar.....	5
1.6. EEG İşaretlerinin Ölçüm Yöntemi.....	8
1.7. Uyarılmış Potansiyeller.....	11
1.8. EEG Tabanlı Beyin Bilgisayar Arayüzü.....	13
1.9. EEG Tabanlı Beyin Bilgisayar Arayüzünün Temel Bileşenleri.....	14
1.9.1. Sinyalin Alınması.....	15
1.9.2. Önileme.....	15
1.9.3. Öznitelik Çıkarma.....	15
1.9.4. Sınıflandırma.....	16
1.9.5. Uygulama Arayüzü.....	17
1.10. Uyarılmış Potansiyeller Bakımından BBA Çeşitleri.....	18
1.10.1. Görsel Olarak Tetiklenen Potansiyeller.....	18
1.10.2. Yavaş Kortikal Potansiyeller.....	18
1.10.3. P300 Tetiklenen Potansiyeller.....	19

1.10.4.	μ ve β Ritmleri.....	19
1.10.5.	Kortikal Nöronlar	20
1.11.	Literatür Araştırması	20
1.12.	Tezin Kapsamı	20
2.	YAPILAN ÇALIŞMALAR.....	26
2.1.	Materyal.....	26
2.1.1.	Kullanılan EEG Cihazı	26
2.1.2.	EEG Verilerinin Kaydedilmesi.....	28
2.2.	Yöntem	37
2.2.1.	Öznitelik Çıkarma Yöntemleri	37
2.2.1.1.	Dalgacık Dönüşümü	37
2.2.1.2.	Özbağlanım Metodu	41
2.2.1.3.	Çarpıklık ve Ortalama Türev	42
2.2.2.	Sınıflandırma Yöntemleri	42
2.2.2.1.	k-En Yakın Komşuluk Yöntemi	42
2.2.2.2.	Destek Vektör Makineleri	44
2.2.2.2.1.	Doğrusal Destek Vektör Makineleri.....	45
2.2.2.2.2.	Doğrusalca Ayrılabilir Veri	49
2.2.2.2.3.	Doğrusalca Ayrılamayan Veri.....	51
2.2.2.2.4.	Doğrusal Olmayan Destek Vektör Makineleri Sınıflandırıcıları.....	52
2.2.2.3.	Doğrusal Ayırma Ayırıcı	53
2.2.3.	Sınıflandırıcı Eğitimi Metotları	56
2.2.4.	Çoklu Sınıflandırma	56
2.2.5.	Sınıflandırma Performansı Ölçütleri	58
3.	BULGULAR	61
3.1.	Öznitelik Parametreleri.....	61
3.2.	F1 ve F2 Özniteliklerinin k-EYK ile Sınıflandırılması	62
3.3.	F3 Özniteliğinin k-EYK ile Sınıflandırılması	65
3.4.	F4 ve F5 Özniteliklerinin k-EYK ile Sınıflandırılması	66
3.5.	Tüm Özniteliklerin k-EYK ile Sınıflandırılması	67
3.6.	Karar Ağacı Yapısı	69

3.7.	MM Kişisine Ait Ağaç Yapısı	70
3.8.	HK Kişisine Ait Ağaç Yapısı	75
3.9.	OA Kişisine Ait Ağaç Yapısı	79
3.10.	Özniteliklerin Farklı Anlardaki Kombinasyonları ile Sınıflandırma Doğruluğunun Arttırılması.....	85
3.11.	Kararlılık Analizi.....	87
3.12.	Görevlerin İkili Sınıflandırma Doğrulukları	88
3.13.	Hesaplama Karmaşıklığı	89
3.14.	Performans Karşılaştırması	90
4.	SONUÇLAR.....	93
5.	ÖNERİLER VE TARTIŞMA.....	96
6.	KAYNAKLAR.....	99
7.	EKLER	106

ÖZGEÇMİŞ

Doktora Tezi

ÖZET

İMLECİN İKİ BOYUTLU HAREKETİNİN HAYALİ SIRASINDA KAYDEDİLMİŞ
EEG İŞARETLERİNİN KARAR AĞAÇ YAPISI ESASLI SINIFLANDIRILMASI

Önder AYDEMİR

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim dalı
Danışman: Prof. Dr. Temel KAYIKÇIOĞLU
2013, 105 Sayfa, 14 Ek Sayfa

EEG tabanlı Beyin bilgisayar arayüzü (BBA) sistemlerinin giriş işaretleri doğası gereği durağan değildir, düşük işaret gürültü oranına sahiptirler, fiziksel ve düşünsel uygulamalardan etkilenirler ve elektromiyogram ve elektrookülogram gibi çeşitli artifaktlardan bulanırlar. Tüm bu dezavantajlar araştırmacıları beyin ile BBA'nın çıkış cihazı arasındaki iletişim sisteminin tüm elemanlarının hızını ve doğruluğunu arttırmaya motive etmektedir. Bundan dolayı, hızlı ve doğru bir BBA sistemi gerçekleştirmek için en uygun sınıflandırma algoritmasını ve düşük boyutlu öznitelik seti kullanmak önemlidir. Diğer taraftan, BBA sistemlerinin kullanımda pratik yapmak için sınıflandırıcıların farklı seanslarda kaydedilmiş sinyalleri ayrıştırma kabiliyetinin olması da çok önemlidir. Bu tezde, bilgisayar imlecinin yukarı, aşağı, sağa ve sola hareket ettirilmesinin hayal edilmesi sırasında kaydedilmiş EEG işaretlerinin sınıflandırılması için hızlı ve sınıflandırma doğruluğu yüksek metotlar önerilmiştir. Veri kümeleri, yaşları 24-29 arasında değişen sağlıklı erkek bireylerden farklı günlerde iki seansta kaydedilmiştir. Dalgacık dönüşümü katsayıları, özbağlanım parametreleri, yamukluk ve ortalama türev değerlerine dayalı çıkarılan öznitelik vektörleri, k-en yakın komşuluk, destek vektör makineleri ve doğrusal ayırma ayırıcı ile sınıflandırılmışlardır. Önerilen metotlar, veri setine başarılı bir şekilde uygulanmış ve test verilerinde üç kişi üzerinde %60.53, % 62.50 ve %84.21 sınıflandırma doğruluğu elde etmişlerdir.

Anahtar Kelimeler: EEG, Beyin bilgisayar arayüzü, Öznitelik çıkarma, Sınıflandırma, Bilgisayar imleci hareketinin hayali

PhD. Thesis

SUMMARY

DECISION TREE BASED CLASSIFICATION OF EEG SIGNALS RECORDED
DURING TWO DIMENSIONAL CURSOR MOVEMENT IMAGERY

Önder AYDEMİR

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Program
Supervisor: Prof. Dr. Temel KAYIKÇIOĞLU
2013, 105 Pages, 14 Appendix Pages

Input signals of a EEG based Brain computer interface (BCI) system are naturally non-stationary, have poor signal to noise ratio, dependent on physical or mental tasks, and contaminated with various artifacts, such as electromyogram and electrooculogram. All these disadvantages motivate the researchers substantially improve the speed and accuracy of all components of the communication system between the brain and a BCI output device. Hence, it is significant to use optimal classification algorithm and low dimensional feature set to implement a fast and accurate BCI system. On the other hand, it is very important that the classifiers have the ability for discriminating signals which are recorded in different sessions to make brain computer interfaces practical in use. In this thesis, we propose fast and accurate classification methods for classifying of up/down/right/left computer cursor movement imagery EEG data. Data sets were acquired from three healthy human subjects in age group of between 24 and 29 years old and on different days in two sessions. Extracted feature vectors based on continuous wavelet transform coefficients, autoregressive parameters, skewness and average value of derivative of the EEG signals were classified by k-nearest neighbor, support vector machine and linear discriminant analysis algorithms. The proposed methods were successfully applied to our data sets and achieved 60.53%, 62.50% and 84.21% classification accuracy rate on the test data of three subjects.

Key Words: EEG, Brain computer interface, Feature extraction, classification, computer cursor movement imagery

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Nöronun yapısı	2
Şekil 1.2. Hans Berger tarafından kaydedilen ilk EEG işareti.....	3
Şekil 1.3. Tipik bir EEG işareti	4
Şekil 1.4. Farklı frekans bandındaki EEG dalgaları	5
Şekil 1.5. Gözün sağa hareketi ile ortaya çıkan artifaktlı EEG	6
Şekil 1.6. Gözün sola hareketi ile ortaya çıkan artifaktlı EEG	7
Şekil 1.7. Dişin sıkılması ile ortaya çıkan artifaktlı EEG	7
Şekil 1.8. Gözün kırılması ile ortaya çıkan artifaktlı EEG	8
Şekil 1.9. 10/20 sistemine göre elektrot yerleşimi.....	9
Şekil 1.10. Elektriksel sinyalin elektrota ulaşması	10
Şekil 1.11. Beynin bölgeleri.....	11
Şekil 1.12. BBA sisteminin temel bileşenleri	14
Şekil 1.13. Bir sınıflandırma yönteminin genel akış diyagramı	17
Şekil 2.1. EEG sistemi	26
Şekil 2.2. Ortamdaki elektromanyetik dalganın şiddetli olduğu EKG işareti	27
Şekil 2.3. Ortamdaki elektromanyetik dalganın şiddetinin düşük olduğu EKG işareti....	27
Şekil 2.4. Elektrotların saç derisine yerleşim düzeni.....	28
Şekil 2.5. Mustafa Mutlu ile deney esnasından bir fotoğraf.....	30
Şekil 2.6. Hüseyin Kazaz ile deney esnasından bir fotoğraf	30
Şekil 2.7. Ekranın 19x19'luk beyaz renkte ızgaralar ile bölünmesi	31
Şekil 2.8. Motivasyon 1 aşaması senaryosu	32
Şekil 2.9. Motivasyon 2 aşaması senaryosu	33
Şekil 2.10. Eğitim verilerinin alınması aşaması senaryosu.....	34
Şekil 2.11. Elektrotların empedansları	34
Şekil 2.12. Tipik EEG verileri	36
Şekil 2.13. Bir Meksican Hat dalgacığının zaman ekseni boyunca ötelenmesi.....	39
Şekil 2.14. Bir Meksican Hat dalgacığının zaman ekseni boyunca ölçeklenmesi.....	39
Şekil 2.15. Morlet dalgacığına ait frekans-ölçek ilişkisi.....	40

Şekil 2.16.	k-EYK yöntemi için basit bir örnek.....	43
Şekil 2.17	Maksimum marjlinli hiperdüzlem	44
Şekil 2.18	Doğrusal ayrılabilen veri	50
Şekil 3.1.	Teta bandına ait SD sonuçları	62
Şekil 3.2.	Alfa bandına ait SD sonuçları	63
Şekil 3.3.	Beta bandına ait SD sonuçları	63
Şekil 3.4.	Alfa+beta bandına ait SD sonuçları	64
Şekil 3.5.	Teta+alfa bandına ait SD sonuçları	64
Şekil 3.6.	Teta+alfa+beta bandına ait SD sonuçları	65
Şekil 3.7.	F3 özneliğinin k-EYK ile sınıflandırılması.....	66
Şekil 3.8.	Ağaç yapısı esaslı sınıflandırmanın gereği.....	68
Şekil 3.9.	Oluşturulabilecek karar ağacı yapıları.....	69
Şekil 3.10.	MM Kişisi için G1G3-G2G4 sınıflarına ait öznelikler.....	71
Şekil 3.11.	MM Kişisi için G2-G4 sınıflarına ait öznelikler	72
Şekil 3.12	MM kişisi için oluşan ağaç yapısı	73
Şekil 3.13	HK kişisi için G1-G4 sınıflarına ait öznelikler.....	76
Şekil 3.14	HK kişisi için oluşan ağaç yapısı.....	77
Şekil 3.15.	OA Kişisi için G1-G2G3G4 sınıflarına ait öznelikler.....	80
Şekil 3.16.	OA Kişisi için G4-G2G3 sınıflarına ait öznelikler.....	82
Şekil 3.17.	OA kişisi için oluşan ağaç yapısı.....	83

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 2.1. Kanal isimlerinin numaralandırılması	29
Tablo 2.2. Gönüllü bireyler ile yapılan deneme sayıları	35
Tablo 2.3. Alt bantlara ait ölçek aralıkları.....	40
Tablo 2.4. Hata matrisi	58
Tablo 3.1. Çıkarılan Öznitelikler	61
Tablo 3.2 F1 ve F2 özniteliklerinin k-EYK ile sınıflandırma sonuçları.....	65
Tablo 3.3. Tüm özniteliklerin k-EYK ile sınıflandırılması	68
Tablo 3.4. MM ağaç yapısında MM hata matrisi	73
Tablo 3.5. HK ve OA işaretlerinin MM ağaç yapısına uygulanmasına ait bulgular	74
Tablo 3.6. MM ağaç yapısında HK hata matrisi	74
Tablo 3.7. MM ağaç yapısında OA hata matrisi	74
Tablo 3.8. HK ağaç yapısında HK hata matrisi.....	78
Tablo 3.9. MM ve OA işaretlerinin HK ağaç yapısına uygulanmasına ait bulgular	78
Tablo 3.10. HK ağaç yapısında MM hata matrisi.....	78
Tablo 3.11. HK ağaç yapısında OA hata matrisi.....	79
Tablo 3.12. OA ağaç yapısında OA hata matrisi.....	83
Tablo 3.13. MM ve HK işaretlerinin OA ağaç yapısına uygulanmasına ait bulgular	84
Tablo 3.14. OA ağaç yapısında MM hata matrisi.....	84
Tablo 3.15. OA ağaç yapısında HK hata matrisi	84
Tablo 3.16. MM ağaç yapısında yeni MM hata matrisi	86
Tablo 3.17. HK ağaç yapısında yeni HK hata matrisi	86
Tablo 3.18. OA ağaç yapısında yeni OA hata matrisi	87
Tablo 3.19. Kararlılık analizi.....	88
Tablo 3.20. MM kişisi için ikili sınıflandırma doğrulukları.....	88
Tablo 3.21. HK kişisi için ikili sınıflandırma doğrulukları	88
Tablo 3.22. OA kişisi için ikili sınıflandırma doğrulukları	89
Tablo 3.23. Hesaplama süreleri	90
Tablo 3.24. Performans karşılaştırması	91

Tablo 3.25. Sık kullanılan yöntemlerin SD sonuçları	92
Tablo 4.1. Ortalama sınıflandırma doğrulukları	93

SEMBOLLER DİZİNİ

AR	:	Özbağlanımlı
ALS	:	Amiyotrofik lateral sklerozis
B	:	Band genişliği parametreleri
BBA	:	Beyin bilgisayar arayüzü
BCI	:	Brain computer interface
BIUP	:	Beyinsapı İşitsel Uyarılmış Potansiyeller
bkz	:	Bakınız
BTO	:	Bilgi transfer oranı
Ç	:	Çarpıklık
DAA	:	Doğrusal ayırma ayıracı
DC	:	Doğru akım
DD	:	Dalgacık dönüşümü
DV	:	Destek vektörü
DVM	:	Destek vektör makinaları
ECoG	:	Elektrokortikogram
ECG	:	Elektrokardiyogram
EEG	:	Elektroensefalogram
EOG	:	Elektrookulogram
ERD	:	Ayırt edilebilir örüntüler
F1	:	1. Öznitelik
F2	:	2. Öznitelik
F3	:	3. Öznitelik
F4	:	4. Öznitelik
F5	:	5. Öznitelik
FD	:	Fourier dönüşümü
fMRI	:	Functional magnetic resonance imaging
G1	:	Yukarı imleç hareketi
G2	:	Sağ imleç hareketi
G3	:	Aşağı imleç hareketi

G4	:	Sola imleç hareketi
GSY	:	Güç spektral yoğunluğu
GTP	:	Görsel tetiklenen potansiyel
GUP	:	Görsel Uyarılmış Potansiyeller
HK	:	Hüseyin Kazaz kişisi
Hz	:	Hertz
K	:	Kanal
k-EYK	:	k-En yakın komşuluk
KFZD	:	Kısa zamanlı Fourier dönüşümü
KVS/D	:	Deneme başına düşen karar verme süresi
LFP	:	Yerel alan potansiyelleri
MEG	:	Magnetoensefalography
MM	:	Mustafa Mutlu kişisi
N	:	Özbağlanım derecesi
NIRS	:	Near Infrared Spectroscopy
OA	:	Önder Aydemir kişisi
OT	:	Ortalama türev
ÖHS	:	Öznitelik hesaplama süresi
P300	:	Beynin yaklaşık 300 ms sonra ürettiği pozitif potansiyeldir
PCA	:	Principal Component Analysis
RBF	:	Radial basis function
SCP	:	Slow cortical potentials
S	:	Süre
SD	:	Sınıflandırma doğruluğu
sn	:	Saniye
SS	:	Sınıflandırma süresi
SUP	:	Somatosensoriyel uyarılmış potansiyeller
VC	:	Vapnik-Chervonenkis
YKP	:	Yavaş kortikal potansiyel
YRM	:	Yapısal risk minimizasyonu
σ	:	sigma
μ	:	mü ritmi
α	:	Alfa dalgası

β : Beta dalgası
 θ : Teta dalgası
 δ : Delta dalgası

1. GENEL BİLGİLER

1.1. Giriş

Bilim adamları insanların hayatlarını kolaylaştırabilmek ve yaşam standartlarını yükseltebilmek için pek çok yeni teknolojiler geliştirmeye devam etmektedirler. Günümüzde, beyin bilgisayar arayüzü (BBA) teknolojisi geliştirilmeye çalışılan teknolojiler içerisinde tüm insanlığı heyecanlandıran popüler çalışma konularının başında gelmektedir. BBA, insanların düşüncelerini ve isteklerini dış dünyaya iletirken beynin olağan iletim sistemleri olan motor sinir sistemlerini kullanmak yerine, beyin bünyesinde bulunan biyomedikal sinyal türlerinin aktivasyonları tespit edilerek, bunların dış ortama bir bilgisayar vasıtasıyla aktarılmasıyla sağlanan bir iletişim sistemidir. Bu sayede kişilerin kas sistemlerini kullanmadan, kişilerin sadece düşünceleri ile bir bilgisayarı, elektromekanik bir kolu ya da çeşitli nöroprotezleri kullanmalarını olanaklı hale getirilebilmektedir. Özellikle bu sistemler amiyotrofik lateral sklerozis (ALS), beyin kökü travması, beyin ya da omurilik yaralanması, serebral palsi, kas distrofileri veya çoklu skleroz gibi hastalarının hayatlarına ışık tutabilmesi açısından oldukça önemli bir teknolojik gelişmedir [1], [2]. Ancak önemli olan şey bu tür hastalıkların sadece ve sadece motor nöronları etkilediği, yani hastanın bilişsel işlevlerine bir zarar vermediği gerçeğidir. Hafıza, zeka ve kişilik korunur. Hastalar görebilir, duyabilir, koklayabilir ve dokunsal uyaranları yorumlayabilirler.

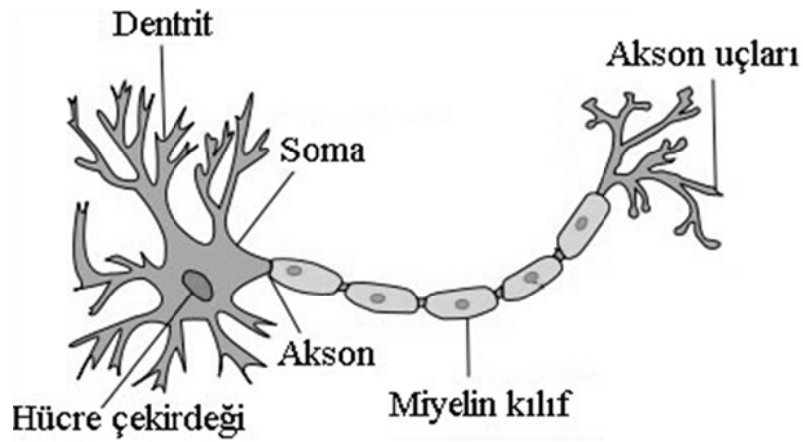
BBA uygulamalarında elektroensefalogram (EEG), tek hücre kayıtlamaları, fonksiyonel manyetik rezonans görüntüleme (fMRI), yerel alan potansiyelleri (LFP), yakın kızılötesi spektroskopisi (NIRS), elektrokortikografi (ECoG), magnetoensefalografi (MEG) gibi teknikler kullanılmaktadır. Bu teknikler içerisinde BBA sistemleri için genel olarak pratik olarak elde edilmesi, acı vermeyen bir yöntem olması ve uygulanmasının kolay olması açısından EEG potansiyelleri tercih edilmektedir [3], [4].

1.2. Beynin Nöronal Yapısı

Sinir hücresi ya da nöron, sinir sisteminde bilgi iletimini sağlayan en temel parçacıktır. Sinir hücresi üç ana bölümden oluşmaktadır; dentritik köprü; giren bilgiyi hücreye iletir, vücut (ya da soma); bilgiyle kaynaşır, akson; diğer nöronlara bilgiyi taşır.

Her nöron, akson ve dentritlerinden, diğer nöronlara bağlı haldedirler. Bundan dolayı her bir nöron, sinir sisteminde bağdaştırıcı parça olarak nitelendirilmektedir. Bir nöronun yapısı Şekil 1.1’de gösterilmektedir.

Nöronların birbirleriyle bağlandığı alana sinaps adı verilmektedir. Bir nöronun aksonu, bir kaç ya da binlerce sinapsda sona ermektedir. Akson başına ortalama olarak, bin sinaptik terminal tahmin edilmiştir. Tek bir nöronun dentritleri ve somaları, birkaç yüzden, 15000 aksona kadar sinaptik bağ kurabilir. Bir kişinin beyinde, yaklaşık 10^{10} nöron ve buna göre 10^{14} sinaptik birleşme bulunmaktadır.




Şekil 1.1. Nöronun yapısı

Beynin herhangi iki ucu arasında en uzak mesafe kabaca 17cm’dir ve örneğin önden arkaya doğru gidildiğinde, bölge bölge nöronal fonksiyon birimleri görülmektedir. Bu bölgelerde var olan yoğun nöronlar grubuna, nükleı adı verilmektedir. Beyin herhangi belli bir görevi yaparken, görevle alakalı nükleı aktive olur, bilgiyi işler ve gönderir [5]. Bu aktivite durağan olmayan işaret olarak gözlenir ve bu birçok nöronun, aynı anda gösterdiği dentritik potansiyellerin cebirsel toplamına EEG adı verilmektedir.

1.3. EEG’nin Kısa Tarihçesi

EEG’nin tarihsel gelişimi, Richard Caton’un 1875 yılında hayvanlar üzerinde yaptığı deneyler sonucunda beyinde bir takım elektriksel faaliyetlerin var olduğunu bulmasıyla başlamıştır. İlk defa 1929 yılında, Alman Hans Berger tarafından insan beyinin aktivitesinin varlığı, kafaya yerleştirilen elektrotlar ve bunlara bağlı bir galvanometre

yardımıyla ortaya koyuldu. Bu gelişme bilim dünyasında devrimsel bir buluş olmuştur. Hans Berger tarafından ilk kaydedilen EEG örneği Şekil 1.2’de gösterilmiştir [5]. Berger, 1930 yılında EEG adı verilen bu dalgaların gözün açılıp kapanmasıyla değiştiğini göstermiştir.




Şekil 1.2. Hans Berger tarafından kaydedilen ilk EEG işareti

Elektronik bilimindeki gelişmelerden faydalanarak 1934 yılında Edgar Douglas Adrian ve Brian Matthews elektrotlarla alınan EEG işaretlerini kuvvetlendirip kaydedilmesini sağlamışlardır. 1939 yılında Pauline Davis, uyanık bir insanın EEG’sinde, sese karşı uyarılan yanıtların (Evoked Potentials) olduğunu bulmuştur. Hallowell Davis ve arkadaşları, uyuyan insanda da aynı olayın meydana geldiğini aynı yıl içinde göstermişlerdir [5].

Gelişen teknolojiyle birlikte, EEG işaretlerinde çok miktarda bilgi saklandığı yapılan çalışmalarla ortaya çıkmaktadır. Klinik tanılarda, nörolojik rahatsızlıkların çözümünde bu bilgilere çokça başvurulur. Günümüze gelindiğinde EEG, tıpta, başta epilepsi (sara hastalığı) olmak üzere birçok beyin rahatsızlıklarının teşhisinde ucuz ve hastaya acı vermeyen bir yöntem olduğu için yaygın olarak kullanılır. EEG’yi oluşturan beyin dalgalarının değerlendirilmesi ile bu rahatsızlıkların yeri ve şekli hakkında bilgi edinilir. Bunun yanında biyomedikal alanında beynin dinamiklerini ortaya koymak için ve bir beyin bilgisayar arayüzü oluşturmak için kullanılırlar.

1.4. EEG İşaretlerinin Özellikleri


EEG, saç derisi üzerinden elektrotlarla algılanan düşük genlikli biyoelektrik işaretlerdir. EEG’nin değişim şekli çok karmaşıktır ve yorumlanması oldukça zordur. Genlikleri tepeden tepeye 1-400 μ V ve frekans bandı ise 0.5-100 Hz’dir. EEG işaretleri periyodik değildir, genlik, faz ve frekansları sürekli değişmektedir. Günümüz teknolojisi ile kaydedilmiş tipik bir EEG işareti Şekil 1.3’te gösterilmektedir.



Şekil 1.3. Tipik bir EEG işareti

EEG işaretleri her ne kadar 0.5-100 Hz'lik bir frekans bandına sahip olsa da, klinik ve fizyolojik ilgi 0.5 ile 30 Hz arasına yoğunlaşmıştır. Bu frekans aralığı 4 frekans bandına ayrılmıştır. Bunlar şunlardır:

1. Delta(δ) Dalgaları: Frekansları 0.5-4Hz, genlikleri 20-400 μ V arasında değişir. Derin uyku, genel anestezi gibi beynin çok düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.
2. Teta (θ) Dalgaları: Frekansları 4-8 Hz, genlikleri 5-100 μ V arasında değişir. Normal bireylerde; rüyalı uyku, orta derinlikte anestezi, stres gibi beynin düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.
3. Alfa (α) Dalgaları: Frekansları 8-13 Hz, genlikleri 2-10 μ V arasında değişir. Uyanık Bireylerin; fiziksel ve zihinsel olarak tam dinlenimde bulunduğu, dış uyarılarının olmadığı, gözlerin kapalı olduğu durumlarda görülürler.
4. Beta (β) Dalgaları: Frekansları 13 Hz fazla olanlar, genlikleri 1-5 μ V arasında değişir. Odaklanmış dikkat, zihinsel iş, duyuşal enformasyon işleme, uykunun hızlı göz hareketleri evrelerinde karşılaşılmaktadır. Beta dalgaları en yüksek aktivite düzeyine karşılık gelir. Şekil 1.4'te tüm dalgalara ait EEG örnekleri gösterilmiştir [6].

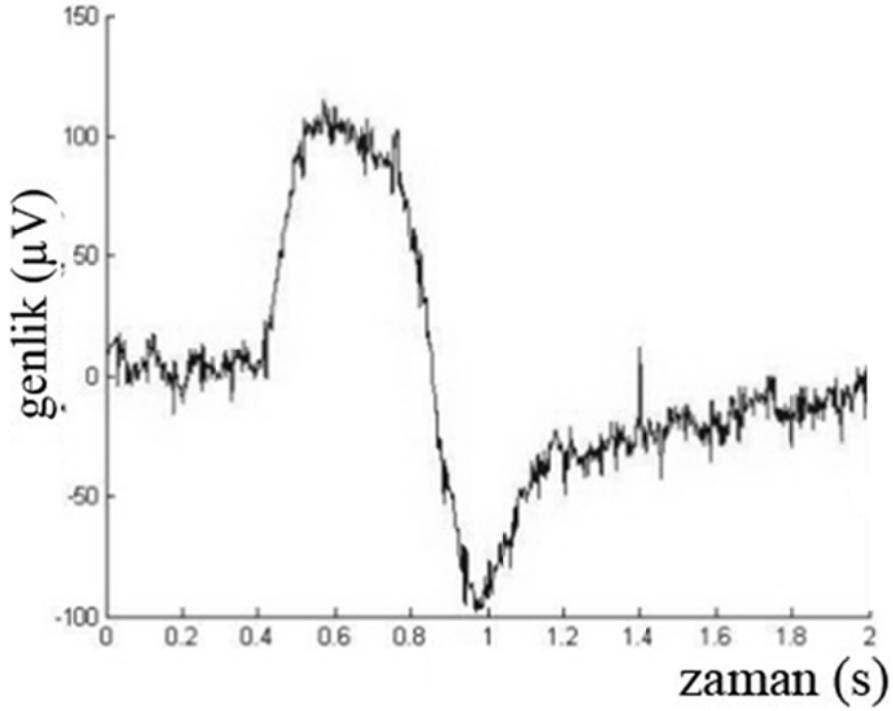


Şekil 1. 4. Farklı frekans bandındaki EEG dalgaları

1.5. EEG'de Artifaktlar

Beynin karmaşık yapısı ve kontrol ettiği karmaşık işlemlerle birlikte, algılanan işaretlerin düşük genlikli olması, EMG ve elektrokülogram (EOG) gibi artifaktlardan ve ortamdaki elektromanyetik dalgalardan kolayca etkilenebilmesi bu bilgilere ulaşılmasını zorlaştırmaktadır. Şekil 1.5, Şekil 1.6, Şekil 1.7 ve Şekil 1.8'de 4 farklı EEG işareti ve bu işaretlere karışmış bazı EMG ve EOG artifaktları gösterilmiştir. Bu işaretler, bu tez çalışmasında EEG verilerini kaydetmek için kullanılan ve detayları Yapılan Çalışmalar başlığı altında verilen EEG cihazı ile 2 saniye süre ile ve F7 numaralı elektrot noktasından (bkz 1.6. EEG İşaretlerinin Ölçüm Yöntemi) kaydedilmiştir. Şekil 1.5'de kişinin gözünü sağa doğru, Şekil 1.6'te sola doğru hareket ettirdiği sırada ortaya çıkan EOG artifaktları gösterilmiştir. Şekil 1.7'de kişinin dişlerini sıkması ile ortaya çıkan EMG artifaktı gösterilirken, Şekil 1.8'de kişinin gözünü üç defa kırpması ile ortaya çıkan artifaktlı EEG gösterilmiştir. Bu artifaktlı EEG işaretleri ile artifakt karışmamış bir EEG işaretinin

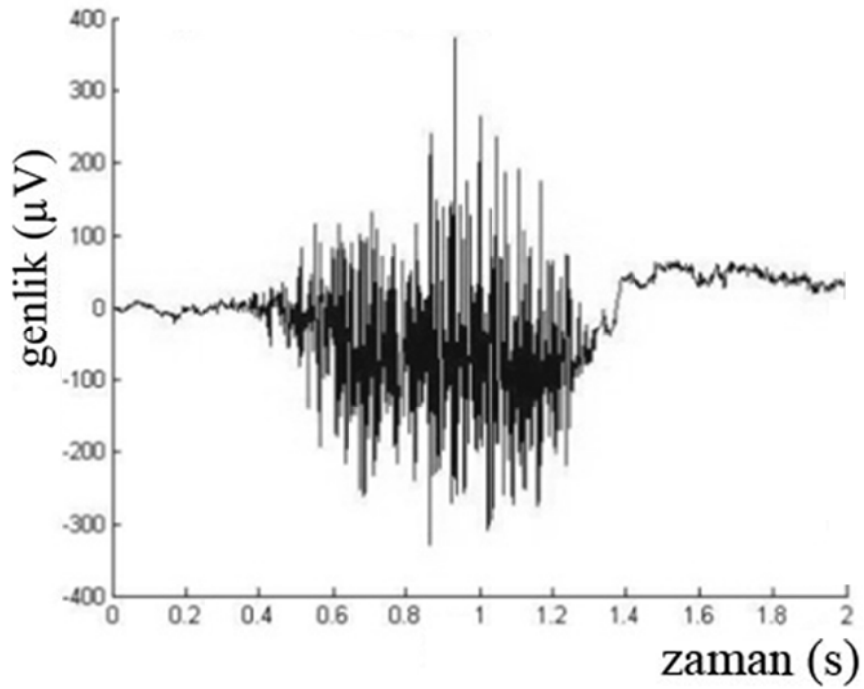
kıyaslanabilmesi için Şekil 1.3'te normal yani EOG ve EMG artifaktı karışmamış bir EEG işareti gösterilmiştir. Artifakt karışmış ve karışmamış şekillerinden de görüldüğü gibi kişinin yaptığı EMG ve EOG hareketleri EEG işaretinin örüntüsünü tamamen değiştirmekte ve genliğini önemli ölçüde arttırmaktadır. Örnek olarak gösterilen bu işaretlerden başka soluk alıp verme, kalp atışı, yutkunma gibi ortaya çıkabilecek çok çeşitli kas hareketlerinin de olabileceğini belirtmek gerekir.



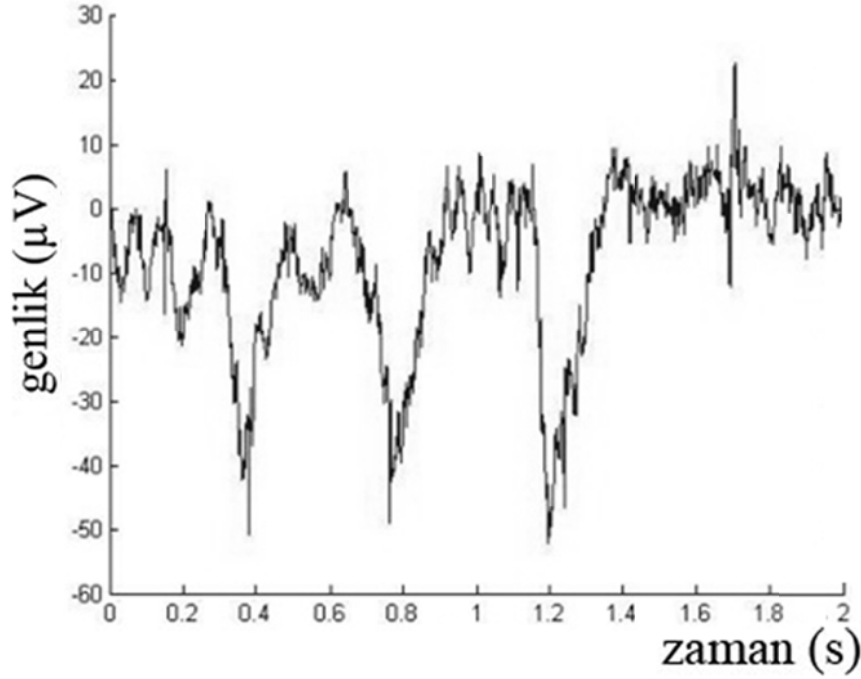
Şekil 1.5. Gözün sağa hareketi ile ortaya çıkan artifaktlı EEG



Şekil 1.6. Gözün sola hareketi ile ortaya çıkan artifaktlı EEG



Şekil 1.7. Dişin sıkılması ile ortaya çıkan artifaktlı EEG



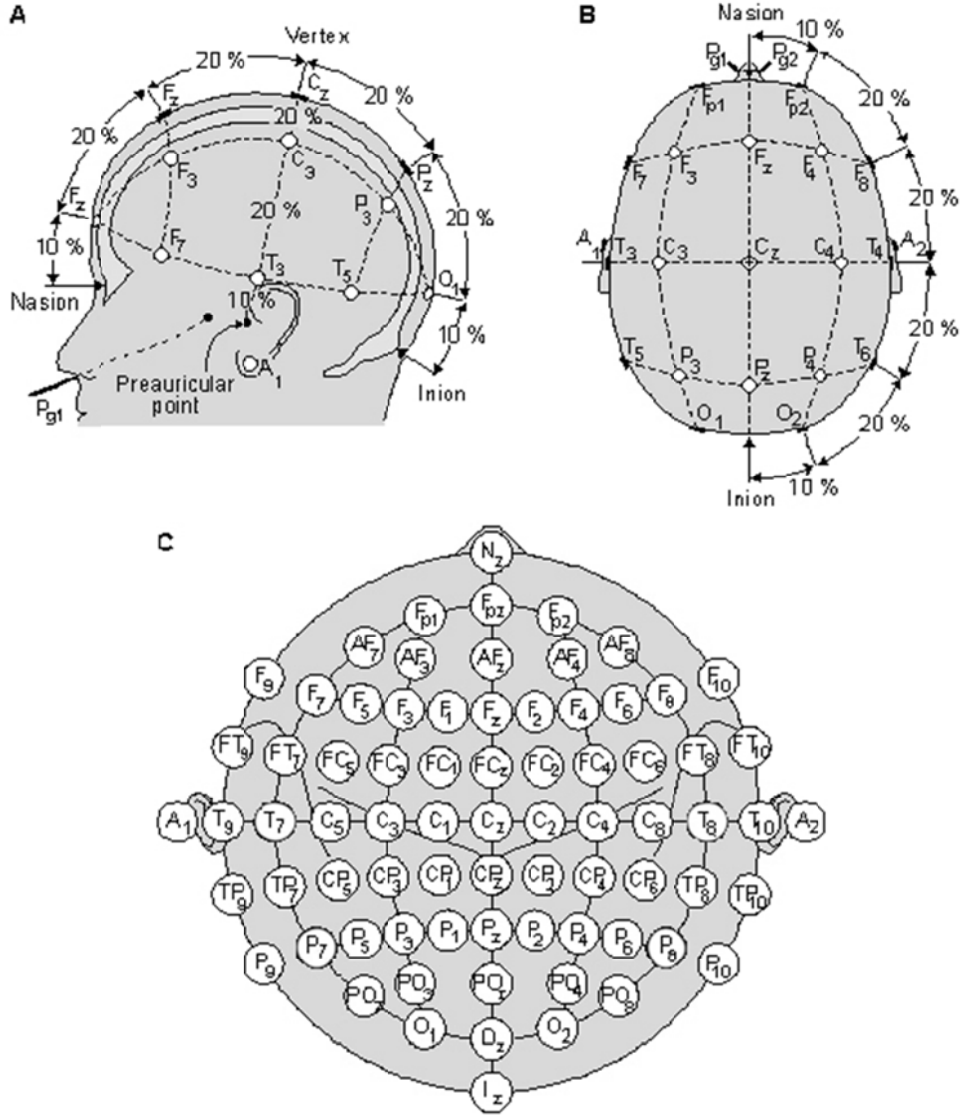
Şekil 1.8. Gözün kırılması ile ortaya çıkan artifaktlı EEG

Kişinin fiziksel hareketlerine bağlı ortaya çıkan artifaktlı EEG işaretlerinin yanı sıra, daha önce belirtildiği gibi ortamdaki elektromanyetik dalgalarda EEG işaretlerinde bozucu etki yaratabilir. Doğal olarak elektromanyetik dalgaların şiddetine ve kullanılan EEG cihazının ve elektrotların kalitesine bağlı olarak biyolojik işaretlerin bozulma miktarı değişebilir. Dolayısıyla EEG ölçümü veya kaydı yaparken tüm bahsedilen bu EEG artifakt kaynaklarının asgariye indirilmesi daha sonra yapılacak analizler için çok büyük önem arz etmektedir.

1.6. EEG İşaretlerinin Ölçüm Yöntemi


Elektrotların kafa derisine yerleştirilmesi için kullanılan standart metot Uluslararası EEG Federasyonu Birliği (*International Federation of EEG Societies*) tarafından belirlenmiş olan 10-20 elektrot sistemidir. Bu yerleşme şeklinde baş dört standart noktayla işaretlenmiştir. “Nasion” , burun; “inion” , kafanın arka kısmı; sağ ve sol preauriküler. “nasion” ve “inion” arası % 10- 20- 20-20- 20 ve 10 olacak şekilde bölünerek elektrotlar yerleştirilmiştir. Diğer elektrotlar, bu elektrotlarla birlikte bir daire oluşturacak şekilde yerleştirilirler. Böylece 19 elektrot kafa üzerine yerleştirilmiş olur. Kulak memesine yerleştirilen 20. elektrot ise toprak elektrotu olarak kullanılır. Bu sisteme göre elektrot

yerleşimleri Şekil 1.9'da gösterilmiştir [6]. Daha çok sayıda elektrot yerleşimi için ise genişletilmiş 10/20 sistemi veya eş uzaklıklı sistemler kullanılır.



Şekil 1.9. 10/20 sisteminde elektrot yerleşimi, A: soldan kafaya bakış
B:Üstten kafaya bakış, C: Genel gösterim

Şekil 1.10'da piramitsel hücrelerin beyin üst kısmında nasıl yerleştikleri ve EEG sinyal algılaması ve kaydedilmesi için elektrotlara yakın buldukları şematik olarak gösterilmektedir [6].



Şekil 1.10 Elektriksel sinyalin elektrotu ulaşması

Elektrot isimleri harfe eşlik eden bir rakamdan oluşur. Harfler elektrotun üzerinde bulunduğu beyin loblarını ifade eder. Buna göre:

Fp: frontal kutup (pole)

F: frontal

C: santral (central)

T: temporal

P: pariyetal


O: oksipital

İki harfin kombinasyonu ise ara elektrot yerleşimlerini gösterir, örneğin:

FC: frontal ve santral elektrot yerleşimlerinin arasında yer alır.

PO: pariyetal ve oksipital elektrot yerleşimlerinin arasında yer alır.

Kafanın sol tarafındaki elektrotlar tek sayılar ile, sağ tarafındaki elektrotlar çift sayılar ile, orta hat elektrotları ise küçük "z" harfi ile gösterilir. Şekil 1.11 beynin bu loblarını göstermektedir.



Şekil 1.11. Beynin bölgeleri

Beynin her lobunun sorumlu olduğu işlevler farklı farklıdır. Pariyetal lob; somatosensoriyel bilgiler için unimodal bağlantı alanları içerir, görsel bilgiler için unimodal bağlantı alanları içerir, somatosensoriyel ve görme duyularının bütünleştirilmesini sağlayan multimodal bağlantı alanları içerir, çalışma belleği için frontal korteksteki multimodal bağlantı alanlarına çıktı verir, motor planlama için motor bağlantı alanlarına çıktı verir. Oksipital lob; görsel uyarıların işlenmesi, bütünleştirilmesi ve yorumunu yapar. Temporal lob; birincil işitme merkezidir, görsel ve işitsel nesne tanıma, duygu ve bellek bölgesidir [5].

1.7. Uyarılmış Potansiyeller

Uyarılmış potansiyeller merkezi sinir sisteminin başlıca duyu yollarının bütünlüğünü kontrol eden elektrofizyolojik incelemelerdir. Duyusal uyarıların yokluğunda doğal fon şeklindeki normal EEG aktivitesi üzerine, ışık veya ses gibi uyarılar etkisiyle ortaya çıkan uyarılmış aktiviteler eklenir. Uyarılma sonucu, beyinde ilgili özel merkezlerin yanıtları olan bu uyarılmış aktiviteler, doğal fon aktivitesinden çok daha küçük olduklarından doğal fon içinde kaybolurlar. Uyarılmış aktiviteyi doğal fondan ayırabilmek için "sinyal ortalaması alma" teknikleri kullanılır. Görsel Uyarılmış Potansiyeller (GUP), Beyinsapı İşitsel Uyarılmış Potansiyeller (BİUP) ve Somatosensoriyel Uyarılmış Potansiyeller (SUP) yaygın olarak kullanılan yöntemlerdir.

GUP, görme yollarının görme sinirinden başlayarak beyin kabuğunda temsil edildiği alana kadar olan bölümünü test eder. Bunun için hasta bir ekran karşısında doktorun önceden belirlediği bir mesafede oturarak genellikle dama tahtası şeklinde hazırlanmış ekranın orta noktasına bakar. İnceleme bu ekranın önceden belirlenen aralıklarla otomatik olarak kayması yani karelerin bu kaymayla birlikte yer değiştirmesi ile başlar. Her kayma ile birlikte göz sinirinde uyarılan ve buradan ilgili beyin kabuğu bölümüne ulaşan bioelektrik potansiyeller, başa takılan elektrotlar yardımıyla toplanır. Toplanan ve ortalaması alınan bu potansiyeller alet yardımı ile büyütülerek görünür hale gelir. Bu inceleme diğer göz kapatılarak her iki göz için ayrı ayrı uygulanır ve yine her iki göz için en az iki kez tekrarlanarak yanıtların rastlantısal şekiller olmadığı gösterilir. İncelemede en çok dama tahtası yöntemi kullanılmakla birlikte aralıklı ışık uyararı, kayan çubuklar, renkli çubuklar da kullanılmaktadır. İnceleme, bebeklere ışık uyararı veren gözlükler yardımıyla uygulanmaktadır. Böylece, erişkinlere uygulanan göz muayenesine uyumlu olmayan bebeklerin görüp görmediği hakkında ciddi yardımları olmaktadır.

BİUP, işitme yollarının işitme sinirinden başlayarak beynin derin yapılarında ve son olarak ilgili beyin kabuğunda temsil edildiği yere kadar olan bölümünü test eder. İnceleme sırasında hastaya belli frekans aralığında klik ses uyararı bir kulaktan verilir. Bu sırada saçlı deri üzerinden kayıt yapılır. İncelemede, ilk 10 ms içerisinde bahsedilen beyin yapılarının bazı bölümlerinden kaynaklandığı bilinen ve bu yapılarda bir rahatsızlığı olmayan bireylerde her seferinde aynı şekilde ve aynı aralıklarla tekrarlanan bazı yanıtlar elde edilir. Bu yanıtlar yüksek sayıda tekrarlanarak ortalama bir şekil elde edilir. Bu şekil içerisinde beklenen yanıtlar işaretlenir. Yanıtların zamana göre dağılımları, genlikleri ve şekillerine bakılarak normal değerler ve diğer kulaktan elde edilen değerler ile karşılaştırma yapılır. Aynı işlem diğer kulak için de tekrarlanır.

SUP, bu incelemede de sinir sisteminin diğer ikisine göre daha geniş fakat yine de işleve sınırlı bir bölümü kontrol edilir. Burada uyararı kol, bacak, yüz veya vücudun diğer bir alanındaki motor veya duyu sinirlere ardı sıra elektrik uyarısı olarak verilir. Her verilen uyarı karşılığında uyarılan sinirin vücuttaki gidiş yolu üzerinden ve uyararının sonlandığı beyin bölgesine uyan saçlı deriden belli yanıtlar kaydedilir. Bu yanıtların tekrarlanan uyarılarla ortalaması alınır. Çeşitli işaretlemeler yapılarak yanıtların zamana göre dağılımı, genlikleri ve şekilleri kontrol edilir. Uyarılan sinir yolu üzerinde herhangi bir sorun varsa beklenen yanıt gecikebilir, genliği düşebilir, şekli bozulabilir ve hatta tamamen kaybolabilir.

1.8. EEG Tabanlı Beyin Bilgisayar Arayüzü

"Beyin bilgisayar arayüzü" terimini ilk kullanmış olanlardan biri Jacques J. Vidal'dir [7]. Vidal, 1973 yılındaki çalışmasında EEG sinyallerini algılayıp, çözümleyip belli örüntüleri bulup bunları önceden tanımlanmış hareket komutları olarak yorumlayan karmaşık bir bilgisayar sistemi geliştirmiştir. "Bağımlı BBA" olarak tanımlanan bu sistemdeki bu sistem aşağıda daha detaylı incelenecektir, kullanıcının göz hareketlerini kontrol etme kabiliyetine dayanıyordu. Vidal'e göre kafatası yüzeyi elektriksel potansiyellerinin ana kaynağı kafatasının hemen altındaki beynin dış kabuğunu meydana getiren serebral korteksteki elektriksel etkinliktir. Serebral korteks, sinir hücreleri (nöronlar) içeren gri maddeden oluşan ince bir tabakadır. Bu hücrelerin bir kısmı (piramit hücreleri) apik dendritlere sahiptir. Yani beyin yüzeyine doğru uzanır ve yanlamasına genişlerler. Bunun sonucunda ince bir beyaz madde yüzeyi oluşur ve burada da yoğun şekilde iç içe geçmiş ince dendrit uzantıları diğer komşu dendritlerle bağlantı kurarlar. Dendritler elektrik alanı nöron merkezine ileten elektrolitik bağlantı araçlarıdır. Hücre merkezine ulaşan elektrik sinyali hücre zarını depolarize ederek hücre atımını tetikler ve böylece sinyal yeniden diğer bir tür hücrelerarası bağlantı elemanı olan akson üzerinden ilerler. Gözlemlenen yüzey potansiyelleri piramitsel hücrelerin tepedeki dendritlerinde ve hücre merkezinde üretilir. Bu potansiyeller hücre içindeki polarizasyon ve depolarizasyona karşılık gelir (bu elektrik potansiyel değişimleri sinaps sonrası olarak nitelendirilir çünkü nöronlararası sinaps etkileşiminde gerçekleşir). Hücrelerarası alanda dikey olarak ilerleyen elektrik akımlarının aynı zamanda dendritler ile derinlerdeki hücreler arasında bir tür geribesleme bağlantısı sağladıkları da düşünülmektedir. Yüzeydeki pozitif olarak kaydedilen bir değişim derin bölgelerdeki bir depolarizasyona (daha yüksek uyarılabilirlik) karşılık gelir ve bunun tersi de doğrudur.

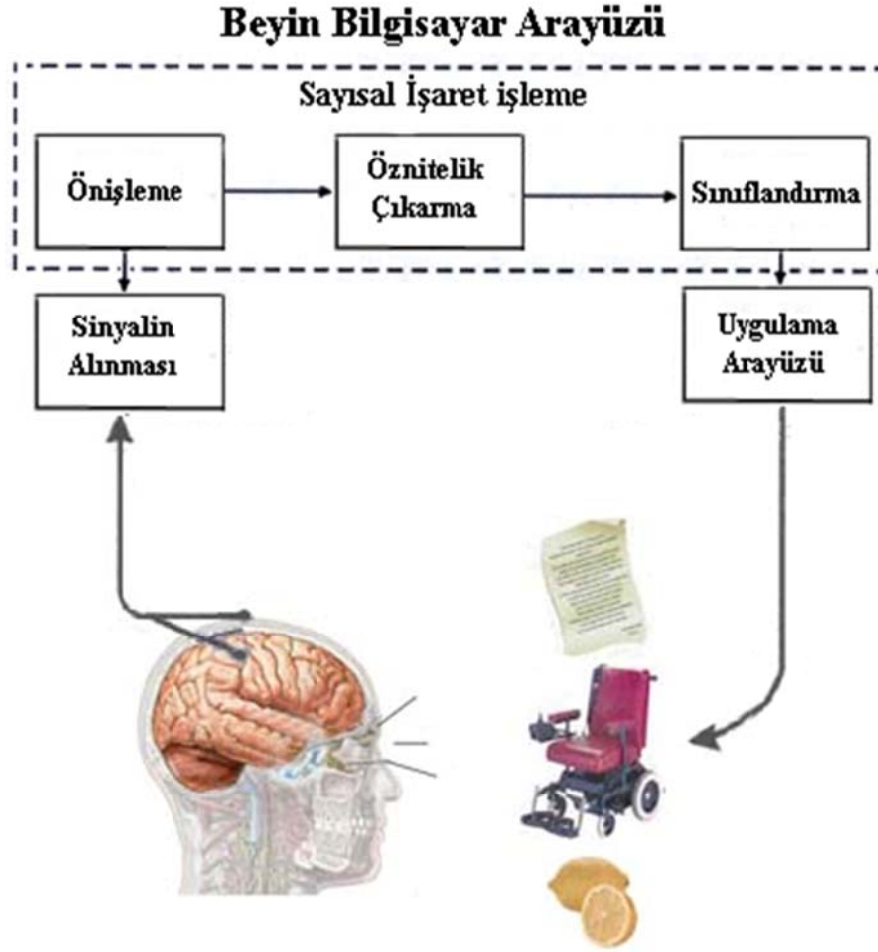
Modern hali ile EEG tabanlı BBA sistemleri kişinin saç derisi üzerinde yerleştirilen elektrotlarla kaydedilen elektriksel beyin aktivitelerini analiz eder ve kişinin niyetine karar vermek için bu aktivitelerden öznitelik çıkarır. Daha sonra, çıkarılan öznitelikleri kontrol edilecek harici cihaz için komut sinyallerine dönüştürür [3], [8]. Aşağıda EEG tabanlı beyin bilgisayar arayüzünün temel bileşenleri ayrıntılı olarak açıklanmıştır.

1.9. EEG Tabanlı Beyin Bilgisayar Arayüzünün Temel Bileşenleri

Modern bir BBA sistemi beş alt bileşene bölünebilir:

1. Sinyal alınması
2. Önleme
3. Öznitelik çıkarma
4. Sınıflandırma
5. Uygulama arayüzü

Bu bileşenlerin işleyişi Şekil 1.12’de gösterilmektedir.



Şekil 1.12. BBA'nın temel bileşenleri

1.9.1. Sinyalin Alınması

BBA uygulamaları için kullanılacak EEG sinyalleri belirli bir işleyişe göre alınır. Bu işleyiş görsel ve işitsel ekipmanlarla desteklenerek kişinin uygulamaya motivasyonu güçlendirilebilir. EEG sinyallerinin kayıtları sırasında EEG işaretlerinin kas hareketlerinden etkilenmemesi için kişi hiç hareket etmemesi gerekir. Bunlardan başka çevresel gürültü kaynaklarından izole edilmiş bir ortamda da verilerin alınması EEG verilerinin bozulmaya uğramaması açısından çok önemlidir.

1.9.2. Önileme

EEG işaretleri doğası gereği mikro voltlar mertebesinde çok küçük genlik seviyelerine sahip olduklarından ötürü fiziksel ve çevresel bazı gürültü kaynaklarından çok kolay etkilenebilmektedir.

Her ne kadar EEG sinyallerinin alınması esnasında kişinin hareket etmemesi istense de istemsiz yapılan göz kırpma, soluk alıp verme gibi kas hareketleri EEG sinyallerinde bozucu etki yapmaktadır. Bunların yanında çevresel etkenlerden kaynaklanan nedenlerden dolayı da EEG sinyalleri bozulmaya uğrayabilmektedir.

Tüm bu fiziksel ve çevresel gürültü kaynaklarını önlemek için çeşitli önileme teknikleri EEG sinyalleri uygulanmaktadır.

1.9.3. Öznitelik Çıkarma

Öznitelik çıkarma, farklı düşünce durumunda kaydedilen EEG işaretlerinin önemli özelliklerinin çıkarılıp öznitelik vektörünün elde edilmesi işlemidir. Örneğin BBA teknoloji bir tekerlekli sandalyenin kullanıcısı aracını ileri götürmek istediği durumda EEG işaretleri nasıl bir örüntü oluşturuyor sorusunun cevabını bulmak bir öznitelik çıkarma işlemidir. Bu aşama BBA sisteminde önemli ve kritik bir aşamadır. Çünkü çıkarılan özniteliklerin kullanışlılığı direkt olarak sınıflandırıcının performansını, dolayısıyla da BBA'nın çalışma performansını etkiler.

Öznitelik çıkarma işleminde çok farklı yöntemler kullanılabildiği için EEG işaretini tanımlayan farklı öznitelikler elde edilebilmektedir. Çıkarılan her öznitelik vektörü işareti tanımlayabilir fakat sınıflandırma aşamasında hiç biri yüzde yüz doğruluk vermeyebilir. Bundan dolayı, yüksek sınıflandırma başarımı elde etmek için farklı özniteliklerin birlikte

kullanımı gerekli olmuştur. Bu şekilde çok sayıda öznitelik kullanan sınıflandırma işlemleri daha iyi sonuçlar vermektedir.

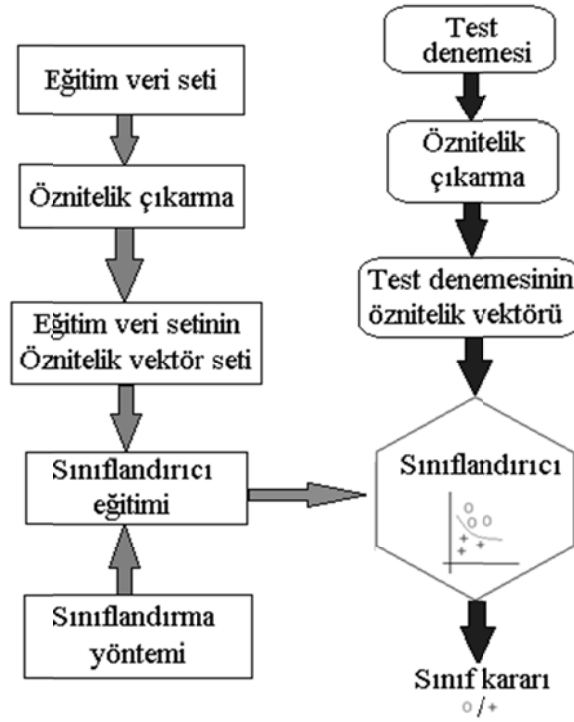
Çoklu elektrot kullanılarak kaydedilen EEG verileri incelenirken, hangi elektrot öznitelik çıkarma için daha uygundur konusu da önemlidir. Beynin farklı bölgeleri farklı görevler için daha duyarlıdır. Örneğin dokunma duyuları beynin yankafa lobunda beden duyumu bölgesi adı verilen bölgeyle algılanıp yorumlanır. Bunun gibi koklama, işitme, hayal kurma, matematiksel işlemler yapma gibi farklı görevler beynin farklı bölgelerinde daha fazla etki yaratır. Dolayısıyla, çoklu elektrotlu EEG verilerinde tüm elektrotlardan (kanallardan) elde edilen verileri kullanmak yerine, yapılan uygulamaya göre beyinsel aktivitenin yoğun olduğu bölgelerden alınan verileri kullanmak hem sınıflandırma için çıkartılacak en iyi özneliğin bulunmasını, hem de sınıflandırma aşamasında karar verme süresinin kısılmasını sağlar [2].

Literatürde öznitelik çıkarma konusunda birçok yayın mevcuttur. Ancak, mevcut yöntemlerle veya özgün geliştirilecek bir yöntemle, kullanışlı öznitelikler çıkarmak uzun araştırma gerektirmektedir.

1.9.4. Sınıflandırma

Sınıflandırma işlemi, değerlendirilen EEG işaretinin çıkarılan öznitelik vektörü göz önüne alınarak önceden belirlenmiş bir sınıfa atama işlemidir. Bu aşama sonucunda kişinin düşüncesine karar verilir. İşaretin hangi sınıfa ait olduğuna karar verme hem hızlı hem de doğru olmalıdır. Bunun için literatürde çeşitli sınıflandırma yöntemleri değişik yaklaşımlarla önerilmektedir.

Bir sınıflandırma yönteminin genel akış diyagramı Şekil 1.13'te verilmektedir. Her bir denemeden o denemeyi temsil etmek için kullanılacak öznitelik vektörü çıkarılır. Her bir eğitim denemesinden çıkarılan öznitelik vektörleri ile bir öznitelik vektör seti oluşturulur. Bu set ile sınıflandırıcı eğitilir. Test aşamasında, eğitilen sınıflandırıcı ilgili test denemesinden çıkarılan öznitelik vektörüne göre denemenin hangi sınıfa ait olduğuna karar verir. Bu tez çalışmasında sınıflandırma yöntemleri ile bu akış diyagramına göre işlemler yapılmıştır.



Şekil 1.13. Bir sınıflandırma yönteminin genel akış diyagramı

Her türlü problem için her zaman en iyi sınıflandırma sonucunu veren bir sınıflandırma yöntemi yoktur. Farklı problemler için sınıflandırma yöntemlerinin performansları farklılık gösterebilmektedir. Ancak, öznitelik verisinin genel dağılımı bilindiğinde bir takım öngörülerde bulunabilmek mümkündür.

1.9.5. Uygulama Arayüzü

EEG tabanlı BBA alanında yapılan araştırmalardaki temel amaçlardan biri, mevcut yöntemlerden daha yüksek sınıflandırma oranına ve beyin-bilgisayar arayüzleşme veri hızına sahip bir yöntem geliştirmektir.

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

İşletim protokolü sistemin genel olarak davranışını ve kullanımını belirleyen kurallar bütünüdür. Protokol sistemin ne tür bir iletişim kullanacağını, ne tür beyin sinyallerinin analiz edileceğini ve sistem ile kullanıcı arasındaki etkileşim şekillerini belirler.

Uzman arařtırmacıların ve BBA teknisyenlerinin hazır bulunup kullanıcıya ya da hastaya yardımcı oldukları bir laboratuvar ortamında bu protokol çok detaylı ya da önemli olmayabilir. Ancak, eęer BBA sistemi gerek hayat ortamında bir hasta tarafından tek başına kullanılacaksa ve hasta kendisi cihazı açıp kapatmak, komut vermek zorunda ise protokol detayları had safhada önem arz eder.

1.10. Uyarılmış Potansiyeller Bakımından BBA eřitleri

BBA sistemleri kullanılan EEG iřaret türüne göre gruplandırılırlar. Bu gruplar ařaęıdaki alt başlıklarda kısaca özetlenmiřlerdir [5].

1.10.1. Görsel Olarak Tetiklenen Potansiyeller

Görsel Olarak Tetiklenen Potansiyeller (GTP), kiřinin oksipital korteksinin uyarılması sonucunda oluşur. Yanıp sönen harfleri ya da benzeri görsel uyarınları gösteren bir bilgisayar monitörü beyinde bu tür elektrik potansiyel farklılıklarına yol açar. 1970'lerde Vidal tarafından BBA arařtırmalarında kullanılan ilk sinyal türü GTP idi. Ancak bu BBA sistemi baęımlı BBA olup kiřinin az da olsa gözünü bir yere odaklayabilmesini gerektiriyordu. Burada önemli olan nokta dikkat seviyesi ve bakışın yöneldięi yer ile bilginin tamamen EEG ile toplanıyor olmasıdır yani hiçbir řekilde gözün kendisi üzerinden bir ölçüm yapılmamaktadır. GTP kullanan modern bir BBA sistemine örnek olarak Middendor gösterilebilir. Kullanıcı ekrandaki düęmelerden birini bakışlarını oraya odaklayarak seçebilir [10]. Bu tez alışmasında oluşturulan BBA örneęi GTP potansiyellere dayalı gerekleřtirilmiřtir.

1.10.2. Yavaş Kortikal Potansiyeller

Yavaş kortikal potansiyel (YKP) biyoelektriksel beyin sinyalindeki potansiyel kaymadır. Negatif YKP'ler genellikle kortikal etkinlięe yol açan hareket ve benzeri iřlevlerle baęlantılı iken pozitif YKP'ler de seviyesi düşen kortikal etkinlikle ilgilidir. Negatif kaymalar genellikle beynin primer görsel korteksinin görsel uyarana karřı verdięi elektriksel tepkidir. Bu tür sinyaller EEG verisindeki çok yavaş voltaj deęiřimleri olarak algılanır. Bu deęiřiklikler 0.5 ile 10 saniye arasında gerekleřir.

Yavaş kortikal potansiyellerle ilgili en önemli nokta, insanların bunları kullanmak üzere biyogeribesleme aracılığı ile eğitilebilmeleridir. Dolayısı ile YKP'ler BBA operasyonunun temelini oluşturur.

1.10.3. P300 Tetiklenen Potansiyeller

P300 tetiklenen potansiyeli alakasız bir uyarın dizisi içine gömülmüş dikkat çekici bir uyarın ile karşılaşın beynin yaklaşık 300 ms sonra ürettiği pozitif potansiyeldir. Tipik bir P300 dalga formu Gauss dağılımını andırır, yarı genişliği 150 ms olup şiddeti 100 mikrovolta kadar çıkar. Genellikle temiz bir P300 dalgası elde edebilmek için pek çok denemenin ortalamasını almak gerekmektedir ve bunun sebebi de sinyalin, gürültü başına düşen sinyal oranının düşük olmasıdır.

P300 potansiyellerini kullanan BBA sistemlerinin kullanımları daha çok yenidir. Yapılan bir çalışmada sistemin kullanıcıları bilgisayar monitöründe yanıp sönen harflere bakarak istedikleri harfi seçebilmektedir. Sistemin performansı dakikada yaklaşık 1 kelime kadardır. P300 tabanlı BBA sistemlerinin avantajlarından biri kullanıcının eğitilmesine pek gerek duyulmamasıdır yani sistem çok kısa sürede kullanılır hale gelmektedir. Bu tür çalışmalar çok yeni olduğundan P300 BBA'ların kullanıcı beyninin sisteme alışmasından kötü etkilenip etkilenmeyeceği henüz bilinmemektedir.

1.10.4. μ ve β Ritimleri

Normalde insanlar uyanıkken ve belli bir şey yapmıyorken beyinleri α EEG sinyalleri yayar. Bu dalgalar 8-12 Hz frekans aralığındadır. μ ritimleri aynı aralıkta olup α dalgalarındaki ufak tefek değişiklikler şeklinde kendilerini gösterirler. Buradaki önemli nokta şudur: μ ritimleri, kişi hafifçe motor korteksini hareketlendirecek şekilde bir şeye konsantre olduğunda ortaya çıkan α dalgalarıdır. β ritimleri ise 18-25 Hz aralığındadır ve bunlar da istemli hareket ve etkin odaklanma ile bağlantılıdır.

Gerçek ve hayal edilen hareketleri kıyaslayarak ve temel bileşen analizi kullanarak bu ritimler çözümlenmiş ve hem gerçek hareketlerin hem de hayal edilen hareketlerin μ ve β ritim desenkronizasyonları ile bağlantılı olduğu tespit edilmiştir.

1.10.5. Kortikal Nöronlar

BBA için daha ender kullanılan yöntemlerden biri ise müdahaleci bir yöntemdir ve bu yöntemde beyin yüzeyine elektrotlar yerleştirilir. Bu yönteme elektrokortigogram (ECoG) denilir ve hastalığı ileri derecede olan kişilere uygulanır. Bu şekilde tek tek nöronların eylem potansiyelleri ve tetiklenme oranları kaydedilebilmektedir. Kortikal nöronlara müdahale ederek oluşturulan BBA sistemleri de vardır.

Özetleyecek olursak; kişiler, BBA sistemlerini kullanarak çok basit kelime işlem uygulamalarını çalıştırabilmekte, etraflarındaki cihazları açıp kapatabilmekte, cihazları belli bir ölçüye kadar ayarlayabilmektedirler.

BBA sistemlerinin gelişimi uyarlanabilir dönüştürme algoritmalarının geliştirilmesine ve beynin işleyişi hakkındaki bilgilerimizin artmasına bağlıdır. İşaret işleme teknikleri gelişirken bir yandan da fiziksel boyutları düşen bilgisayarlar BBA açısından önemli bir avantajdır çünkü bu sayede sistemleri daha taşınabilir yapmak ve böylece BBA kullanan kişilerin hareket özgürlüklerini artırmak mümkün olmaktadır.

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

1.11. Literatür Araştırması

BBA teknolojisi özellikle 1999 yılında yapılan kortikal nöronların direkt olarak robotik bir kolu kontrol edebildiğini gösterir ilk deneysel çalışmadan sonra büyük bir aşama kat etmiştir [10]. Bu çalışmadan sonra bu alanda muazzam araştırmalar yapılmaya başlanmıştır[11]. Özellikle son 15 yılda BBA'ya olan ilgi artarak devam etmektedir. Bu alanda birçok yenilikçi çalışmalar yapılmaktadır. Dünyada özellikle bu alanda öne çıkan belli başlı kuruluşlar şunlardır: Benjamin Blankertz ve Klaus-Robert Müller başkanlığında Almanya'da Berlin Teknik Üniversitesi, Gert Pfurtscheller başkanlığında Avusturya'da Graz Teknik Üniversitesi, A.B.D'de Jonathan R. Wolpaw başkanlığında Wadsworth Merkezi (ABD, NY), yine Almanya'da Niels Birbaumer başkanlığında Tübingen Üniversitesi.

EEG işaretlerinin çok küçük genlikli olması bu işaretlerin çeşitli gürültüden rahatlıkla etkilenmesine yol açar. Bu bakımdan öznitelik çıkarma ve sınıflandırma işlemlerinden önce bir ön işleme ara birimi ile EEG işaretlerine karışan gürültüler giderilmeye çalışılmaktadır. Literatürde gürültüleri EEG işaretlerinden arındırmak için çeşitli yöntemler kullanılmaktadır. En yaygın olanları bağımsız bileşenler analizi [12], [13], [14] ve filtreleme (lineer ve lineer olmayan) [15], [16] teknikleridir. Dalgacık dönüşümü [17], [18], temel bileşenler analizi [19], kaynak dipol analizleri [20] gibi yöntemler de nörolojik bilgiyi kaybetmeden gürültü arındırma yöntemi olarak kullanılmaktadır. Literatürdeki çalışmalarda en fazla giderilmeye çalışılan gürültü kaynağı göz kırpmasından ileri gelen gürültüdür. Bu gürültü özellikle göze yakın ve oksipital bölgelere konumlandırılmış elektrotlardaki işaretlere karışır. Gürültülerin yok edilmesinden başka bazı durumlarda başvuru alan ortalamaya alma, eşik değeri belirleme, işaret iyileştirme gibi işlemler de ön işlemeyi oluşturmaktadır. Gürültü arındırma işlemi orijinal işaretin bozulmasına neden olması öznitelik çıkarma ve sınıflandırma adımlarını da olumsuz etkileyeceğinden bu adım oldukça önemli bir konudur [17, 19, 20].

EEG tabanlı BBA alanında yapılan çalışmalardaki genel amaç, mevcut yöntemlerden daha yüksek sınıflandırma oranına ve beyin-bilgisayar arayüzleşme veri hızına sahip bir yöntem geliştirmektir. Literatürde bu konuda yayınlanmış birçok çalışma mevcuttur. Öznitelik çıkarma işlemi bazen oldukça zaman alıcı işaret analizleri gerektirebilmektedir. Mevcut BBA'lar çoğunlukla çıkış komutu üretmek için şu bilgileri kullanırlar: μ (8-12 Hz) ve/veya yüksek beta (18-26 Hz) ritim genlikleri gibi frekans domeni bilgileri, P300 ve yavaş kortikal potansiyelleri (YKP) veya DC potansiyeller gibi zaman domeni dalga formları [21], [22], izgel güç yoğunluğu (power spectral density) değerleri [23], [24] özbağımlı (autoregressive, AR) ve uyarlamalı özbağımlı parametreler [25], [26]. Eğitim verilerinin zaman domeni ortalamalarına bakarak farklı düşünce durumlarında kaydedilen işaretlerin potansiyellerinin birbirinden farklılık gösterip göstermemesine göre YKP'lerin kullanıp kullanılmayacağı hakkında bir fikir alınabilir. Yine eğitim verilerinin frekans domeni ortalamalarına bakarak hangi frekans bölgesinin (delta, teta, alfa, beta) farklılık gösterdiği incelenerek öznitelik çıkarılabilir, böylece frekans bandı konusunda da bir öngöründe bulunmak mümkündür [27].

Farklı düşünsel ve görsel durumlarda kaydedilen EEG işaretlerini elde edilen öznitelik vektörlerine göre sınıflandırma BBA teknolojisinde çok önemli bir konudur. İşaretin hangi sınıfa ait olduğuna karar verme hem hızlı hem de doğru olmalıdır.

Literatürde birçok sınıflandırma yöntemleri mevcuttur. Bunlardan en çok kullanılanları destek vektör makineleri (DVM), k -en yakın komşuluk (k -EYK), doğrusal ayırıcı analizi (DAA), sinir ağları, Bayes sınıflandırıcısıdır. Aynı tür uygulamada değişik sınıflandırma algoritmaları farklı sonuçlar verebilmektedir [28]. Bu yöntemlerden k -EYK büyük boyutlu öznitelik vektörlerinde etkin olmamakla [29], [30], [31] birlikte düşük boyutlu öznitelik vektörleri ile etkin olabilmektedirler [28], [32]. 1960'ların sonlarında V. Vapnik tarafından bulunan istatistiksel bir algoritma olan DVM [33] özellikle yüksek boyutlu öznitelik elde edilen EEG işaretlerinin sınıflandırılması aşamasında sıklıkla kullanılır ve geleneksel metotlardan çok daha iyi sonuçlar vermektedir. Yapısal risk minimizasyonu prensibi etrafında formüle edilmiştir ve beklenen riskin üst sınırını küçükmeye çalışır [8]. DAA ise, basit ancak BBA alanında sıklıkla başvurulan ve iyi sonuçlar verebilen bir yöntemdir [28]. DVM de k -EYK gibi sınıflandırma işlemi sırasında öznitelik vektörlerin zamansal bilgilerini dikkate almaz bu bakımdan statiktirler. Diğer taraftan DVM sınıflandırıcısında eğitim kümesindeki küçük değişimler sınıflandırma performansını etkilemez bu bakımdan kararlılık özelliği vardır. Sınıflandırma işlemlerinde karşılaşılan bir zorlukta aşırı eğitim (*overtraining*) durumudur. Bu durumda eğitilen ağ eğitim örneklerini mükemmel olarak uygulaştırır fakat test setindeki örneklerde doğru sonuçlar vermeyebilir.

BBA alanında çalışmalarını sürdüren üniversite ve araştırma enstitüleri farklı düşünsel ve görsel durumlara ait deneyler yapmaktadırlar. Yapılan deneylerin konusunu, genelde kas sistemlerini hareket ettiremeyen hasta insanların ihtiyaç duyacağı temel hareketler oluşturmaktadır. Örneğin sağ/sol kol hareketi, bilgisayar imlecinin yukarı/aşağı hareketi, tekerlekli sandalyenin ileri/geri/durması üzerine yapılan deneyler gibi. Wenjie Xu ve diğerleri "BCI competition 2003" [34] yarışmasında sunulan verilerden sağ ve sol parmağın hareketine ait olan EEG verileri üzerine çalışmış ve yarışmada elde edilen %84'lük başarıya karşılık yavaş kortikal potansiyeller ile temel bileşenler analizi yöntemlerini birlikte kullanarak bu başarıyı destek vektör makineleri sınıflandırma yöntemi ile % 90 oranında bir başarıyla sağlamıştır [35]. Başka bir çalışmada Shang-Ming Zhou ve diğerleri "BCI competition 2003" [34] yarışmasında Graz Üniversitesi tarafından sunulan sağ ve sol el motor hareketlerine bağlı kaydedilmiş EEG işaretlerinden ikili tayfa bağlı öznitelik çıkarımı ve bu özelliklere göre sınıflandırma yapma yoluna gitmişlerdir. Sınıflandırmayı DAA, DVM ve yapay sinir ağı kullanarak denemişlerdir. Elde ettikleri sonuç söz konusu yarışmada elde edilen en iyi sonuçtan daha iyi olmuştur. En iyi %90 sınıflandırma başarımını DVM algoritması ile elde etmişlerdir [36].

Literatürde BBA alanında mevcut çalışmaların çoğu ikili problemleri sınıflandırmaya yöneliktir. İkili sınıflandırma problemlerinde %70-%95'ler seviyesinde sınıflandırma doğruluklarına erişilmiştir [37]. Sınıflandırma doğruluğunun yüksek olması kullanılan yöntemlerden başka, sistemin çevrimdışı çalışıp çalışmadığına, EEG verilerinin sağlıklı bireylerden [4] ve eğitim ve test verilerinin aynı seans içerisinde kaydedilmesine ve bir biriyle ilişkisiz görevlere bağlı EEG verilerinin sınıflandırılmasına da bağlıdır [38]. Yapılan çalışmalarda sınıflandırma probleminin boyutu arttıkça sınıflandırma başarısının da azaldığı görülmektedir. Bu durum, ikili sınıflandırma problemlerinde rasgele oluşturulmuş bir BBA sistemi %50 oranında sınıflandırma doğruluğu elde edebilirken, dört sınıflı problemlerde bu oranın %25'e düşecek olmasından da anlaşılmaktadır. Sınıflandırma doğruluğunun tanımı *2.2.5 Sınıflandırma Performansı Ölçütleri* başlığı altında yapılmıştır.

Dört sınıflı sınıflandırma problemlerinde G. Townsend ve diğerleri çevrimdışı yaptıkları çalışmalarında 4 sınıflı problemde sağ el, sol el, ayak ve dil hareketlerinin düşünülmesi sırasında 4 gönüllüden tek oturumda kaydedilmiş toplam 1600 denemesi olan EEG verilerini sınıflandırmışlardır [39]. Karmaşık band gücü yöntemi ile 8 boyutlu öznitelikler çıkararak Mahalanobis uzaklığı yöntemi ile işaretleri sınıflandırmışlardır. Sınıflandırıcı performansını Kappa değeri ile ölçerek ortalama 0.5875 olarak bulmuşlardır. Bu değer, dört sınıflı problemlerde yaklaşık % 65 değerinde bir sınıflandırma doğruluğuna karşılık gelmektedir. Aynı tür görevlerle yapılan başka bir 4 sınıflı problemde X. Lei ve diğerleri çalışmalarında iki ayrı veri seti kullanmışlardır [40]. Her iki veri grubunda da 3 gönüllü bireye ait veriler olup, veri setlerinden birini kendi laboratuvarlarında oluştururken diğerini BCI Competition 2005 yarışmasından (Data Set IIIa) temin etmişlerdir. Her bir veri seti toplam 1080 deneme içermektedir. Beta ve mü bant güçlerine ait özniteliklerle kendi veri setleri için Bayes DAA sınıflandırıcısı ile ortalama 0.5618 Kappa değeri elde ederken, Data Set IIIa veri seti için ortalama 0.8086 Kappa değeri elde etmişlerdir. Bu değerler dört sınıflı problemlerde sırasıyla, yaklaşık % 63 ve %85 değerlerinde sınıflandırma doğruluklarına karşılık gelmektedir.

Literatürde bilgisayar imlecinin iki yönlü hareketinin sınıflandırılmasına dair birçok çalışma mevcuttur [4], [41-54]. Ancak, sadece dört yönlü bilgisayar imlecinin hareketinin hayaline dayalı EEG işaretlerinin sınıflandırılmasına yönelik çalışmalar ayrıntılı incelenmemiştir. Bazı çalışmalarda imlecini sağa hareketi için sağ kolun hareketinin hayali, sola hareketi için sol kolun hareketinin hayali gibi uygulamalar yapılmıştır [45-48].

Kayagil ve diğerleri bilgisayar imlecini bilgisayar ekranında dört yönlü hareket ettirebilmek için EEG cihazı ile kaydettikleri EMG işaretleri ile gerçekleştirmişlerdir [49]. Çalışmalarında, kişi bir monitörde bilgisayar imlecini sağ kolunu hareket ettirmek sureti ile yönlendirmektedir. Sağ kolunu hareket ettirdiği sırada EEG potansiyellerinin genliği artmakta (EMG artifaktı ile) ve sistem kişinin sağ kolunu hareket ettirdiğini bu sayede algılamaktadır. 4 katılımcı ile çalışmalarının sonucunda ortalama %86.1 oranında bir sınıflandırma doğruluğu elde etmişlerdir. Aynı çalışmada, bir katılımcı ile yaptıkları el hareketi olmadan sadece düşünceye bağlı EEG işaretleri ile %53.1 oranında bir sınıflandırma doğruluğu elde etmişlerdir. Kayagil ve diğerleri gibi benzer yaklaşımla yapılmış çalışmalar başka araştırmacılar tarafından da işlenmiştir [50-53].

BBA konusunda ileri gelen araştırma grupları belirli yıllarda düzenledikleri uluslararası BBA yarışmaları (BCI Competitions) ile bu tür EEG deneyleri ile elde ettikleri işaretleri araştırmacılara sunarak, yarışmacıların işaretleri sınıflandırmalarını istemektedirler [54], [55], [56]. Yapılan deneyler sağlıklı veya felçli kişilerle yapıldığı gibi bazende her iki grup gönüllü deneklerde de yapılabilmektedir [57], [58], [59]. Yarışmalarda sunulan veriler daha sonraki yıllarda farklı yöntemlerle etkin öznitelik çıkarma çalışmaları ile incelenerek yarışma sonucunda elde edilen sınıflandırma başarımından daha iyi sonuçlarında çeşitli bilimsel dergilerde ve sempozyumlarda yayınlanmaktadır [35], [60], [61], [62].

EEG tabanlı BBA'ların özellikle güvenli, acı vermeyen ve kullanımının kolay olması gibi avantajlarının yanında sınıflandırma başarımındaki yetersizlik, veri bit hızının yavaş olması, etkin öznitelik vektörlerinin bulunmasının zaman alması bu alanda dikkat çeken olumsuzluklardır. Literatürde mevcut çalışmalarda ulaşılan sınıflandırma doğrulukları ve erişilen veri bit hızı oranı yeterli düzeyde değildir. Ayrıca BBA konusunun yeni bir çalışma sahası olmasından dolayı yapılan deneylerin çeşitliliği çok fazla değildir. Bir başka önemli konu ise yapılan deneysel çalışmaların çoğunda verilerin tümü aynı seansta kaydedilmektedir. Oysaki BBA sistemlerinin kullanımda pratik yapmak için sınıflandırıcıların farklı seanslarda kaydedilmiş sinyalleri ayrıştırma kabiliyetinin olması da çok önemlidir.

1.12. Tezin Kapsamı

Bu tez çalışmasında, bilgisayar imlecinin farklı seanslarda yukarı, aşağı, sağa ve sola hareket ettirilmesinin hayal edilmesi sırasında kaydedilmiş EEG işaretlerinin sınıflandırılması için hızlı ve sınıflandırma doğruluğu yüksek bir yaklaşım önerilmiştir. Veri kümeleri, yaşları 24-29 arasında değişen sağlıklı üç erkek bireyden farklı günlerde iki seansta kaydedilmiştir. Tezin ilk bölümünde verilen Genel Bilgiler 'den sonra veri kümesinin tanıtımı detaylı olarak verilmiştir. Yöntem başlığı altında ise bu tez çalışmasında önerilen öznitelik çıkarma (Dalgacık dönüşümü katsayıları, özbağlanım parametreleri, yamukluk ve ortalama türev) ve sınıflandırma (k-en yakın komşuluk, destek vektör makineleri ve doğrusal ayırma ayırıcı) yöntemlerinin matematiksel teorisi detaylı bir şekilde açıklanmıştır. Önerilen öznitelik ve sınıflandırma yöntemleri ile farklı düşünce durumunda kaydedilen EEG işaretleri karar ağaç yapısı esaslı sınıflandırılmıştır. Burada karar ağaç yapısından kastedilen literatürde bilinen karar ağacı (decision tree) algoritması değil, 4 sınıflı problemin 2'li alt gruplar halinde dallandırılarak çözülmesidir. Bu yaklaşım 3.6 Karar Ağaç Yapısı başlığı altında açıklanmıştır. Daha sonra, Bulgular başlığı altında EEG verilerinin eğitim ve test kümelerinden çıkarılan öznitelikler ve elde edilen sınıflandırma doğrulukları verilmiştir. Sonuçlar kısmında ise elde edilen bulgular yorumlanmış ve literatürde mevcut motor hayaline dayalı BBA uygulamalarının sonuçları ile detaylı bir şekilde karşılaştırılmıştır. Ayrıca, bu tez çalışmasında önerilen matematiksel yöntem, literatürde sıklıkla kullanılan BCI Competition III Data Set IIIa isimli veri kümesine uygulanarak sonuçlar bu başlık altında performans karşılaştırması için sunulmuştur. Çalışmanın son kısmında ise bu teze ait bazı önemli öneriler verilmiş ve sonuçlar tartışılmıştır.

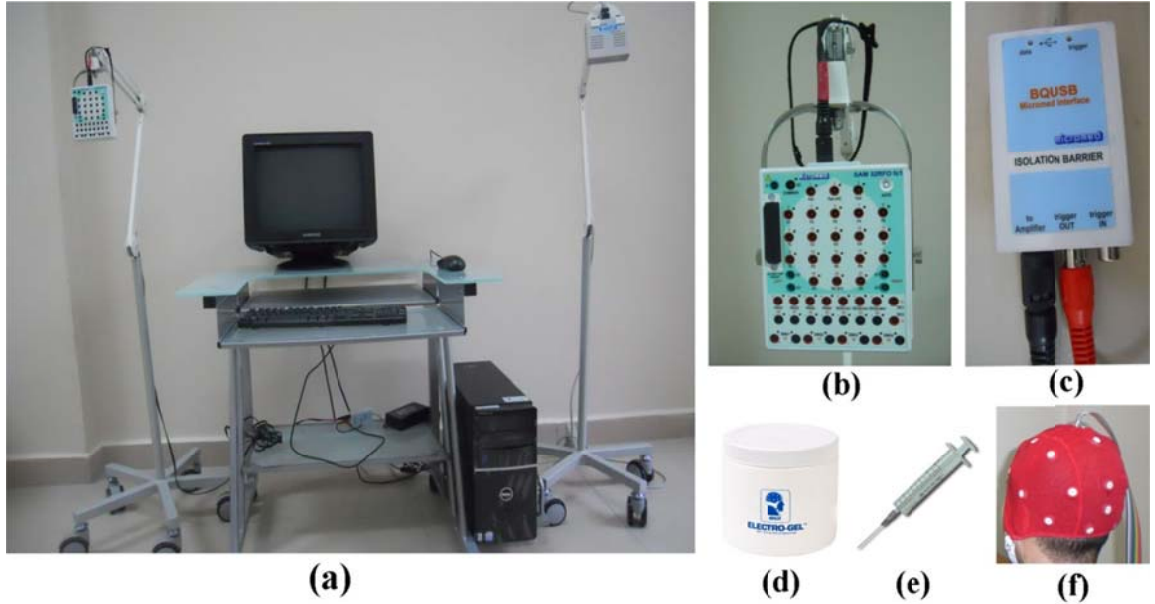
2. YAPILAN ÇALIŞMALAR

2.1. Materyal

Bu tezde kullanılan verilerin tanıtımı aşağıda detaylı olarak açıklanmaktadır.

2.1.1. Kullanılan EEG Cihazı ve Deney Ortamı

Verilerinin kaydedildiği cihaz Micromed marka BrainQuick model 32 kanal ile kayıt yapabilen bir EEG ölçüm cihazıdır.




Şekil 2.1. EEG sistemi, (a) Sistemin genel görünüşü, (b) Yükselteç, (c) İzolasyon katı, (d) Elektrot jeli, (e) Enjektör, (f) Elektrot şapkası


Kullanılan EEG sistemi Şekil 2.1’de gösterilmektedir. Veriler kaydedilmeye başlanmadan önce bireyin başına elektrot şapkası yerleştirilir. Enjektör ile elektrot jeli kullanılacak elektrot noktalarından enjekte edilerek saç derisi ile EEG sistemi arasındaki empedans uygunluğu sağlanır. Ayrıca deneye katılan bireylerin EEG sistemi tarafından elektriksel bir etkiye maruz kalmamaları için kullanılan sistemde izolasyon katı bulunmaktadır.

Elektromanyetik dalgaların biyolojik işaretlere olan bozucu etkisini ortaya koymak için elektromanyetik dalganın şiddetli olduğu ve bu şiddetin düşük olduğu ortamlarda yapılan EKG ölçümü sırasıyla Şekil 2.2 ve Şekil 2.3’te gösterilmiştir. Biyolojik işaretler

içerisinden EKG'nin seçilmesi bu işaretin örüntüsünün bilinmesidir. Bu sayede elektromanyetik dalgaların bozucu etkisi daha kolay anlaşılır. Şekil 2.2. KTÜ Elektrik-Elektronik Mühendisliği Bölümü 1. katında TRT Trabzon radyosu anteninden yaklaşık 1000 metre uzaklıkta (Google Earth ile ölçülen uzaklık sonucudur) ve radyonun antenini direk olarak gören bir odada TRT Trabzon radyosunun yayın yaptığı sırada kaydedilerek elde edilmiştir. Şekil 2.3 ise aynı bölümün zemin katında ve TRT Trabzon radyosunun yayın yapmadığı (saat 10:00 - 13:00 arası) sırada kaydedilerek elde edilmiştir. Görüldüğü gibi elektromanyetik dalganın şiddetli olduğu bir ortamda EKG işaretlerinde gürültü seviyesi, elektromanyetik dalganın şiddetinin az olduğu ortamdaki EKG işaretine göre çok daha fazla gürültülüdür. Bu EKG işaretleri tez çalışmasında kullanılan EEG cihazının EKG ölçüm özelliği kullanılarak kaydedilmiştir.




Şekil 2.2. Ortamdaki elektromanyetik dalganın şiddetli olduğu EKG işareti



Şekil 2.3. Ortamdaki elektromanyetik dalganın şiddetinin düşük olduğu EKG işareti

2.1.2. EEG Verilerinin Kaydedilmesi

EEG verileri Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği bünyesinde kurulan EEG Araştırma Laboratuvarı'nda kaydedilmiştir. EEG verilerinin alınmasında, yerleşimleri Uluslararası 10-20 Sistemi'ne göre olmak üzere, 18 elektrot kullanılmıştır. Elektrotların yerleşimleri ve isimleri Şekil 2.4'te gösterilmiştir.



Şekil 2.4. Elektrotların saç derisine yerleşim düzeni

Şekilde siyah daire içerisinde gösterilen Cz noktası referans nokta olarak alınmıştır. Kullanılan elektrotların isimleri Tablo 2.1'de gösterildiği şekilde numaralandırılmıştır. Bu elektrotlardan Fp1, Fp2, O1 ve O2 elektrotlarına ait işaretler EOG artifaktlarından etkilenebileceği için öznitelik çıkarmak için kullanılmamışlardır.

Tablo 2.1. kanal isimlerinin numaralandırılması

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

Deneylere toplam 3 gönüllü sağlıklı erkek birey iştirak etmiştir. Örnekleme frekansı 2 gönüllü birey için 2048 Hz seçilmiş, 1 gönüllü birey için ise 256 Hz seçilmiştir. Örnekleme frekansının bu çalışmaya etkisinin olup olmadığını, varsa ne kadar etkilediğini de değerlendirebilmek için farklı örnekleme frekanslarında kayıt yapılmıştır. Ancak, verilerin değerlendirilmesi aşamasında 2048 Hz’de yapılan değerlendirmelerin çok zaman almasından ötürü bu işaretler 256 Hz’e matematiksel olarak indirilmiştir. Bu işlem ilerleyen kısımlarda açıklanmıştır. Deneyler esnasında, birey rahat bir koltukta oturmakta, yazı yazmak için kullandığı eli ile bilgisayar faresini tutarken diğer eli serbest bir şekilde önündeki masanın üstünde durmaktadır ve birey karşısındaki LCD monitöre bakmaktadır. Bu durum Şekil 2.5 ve Şekil 2.6’da gösterilmiştir.



Şekil 2.5. Mustafa Mutlu ile deney esnasından bir fotoğraf




Şekil 2.6. Hüseyin Kazaz ile deney esnasından bir fotoğraf

Veriler 4 aşamada MATLAB ortamında hazırlanan bir yazılımla ve 2 seansta kaydedilmiştir. Seanslar arasında yaklaşık 1 hafta ara verilmiştir. 1. seansta aşamalardan üçü gerçekleştirilmiştir. Bu aşamalardan ilk ikisi bireyin deneye motive olabilmesini amaçlamaktadır. 3. aşama eğitim verilerinin alınmasıdır. 2. seans ise son aşama olan test verilerinin alınması aşamasıdır. Bu tez çalışmasında elde edilen tüm bulgular ve sonuçlar eğitim ve test aşamasında kaydedilen verilerle elde edilmiştir. Aşağıda söz konusu 4 aşama sırasıyla detaylı olarak açıklanmaktadır.

I. Motivasyon1 Aşaması

Motivasyon1 aşamasının bir denemesine ait senaryo şu şekildedir:

- Başlangıçta ekran Şekil 2.7'de gösterildiği 19x19'luk beyaz renkte ızgaralar ile bölünmüştür ve boştur.




Şekil 2.7. Ekranın 19x19'luk beyaz renkte ızgaralar ile bölünmesi

- Birey bilgisayar faresinin sol tuşuna tıklayarak denemeyi başlatma komutu verir ve ekranın ortasında gerçek imleç ile görüntü imleç belirir.
- 2 saniye (sn) sonra başlama sesi duyulur.
- Başlama sesi 1 sn sürer.
- Başlama sesinin bitiminden 1sn sonra rastgele bir yönde (yukarı/aşağı/sağ/sol) hedef görünür.

- 2 sn sonra imleç görüntüsü hedefe doğru otomatik sürüklenmeye başlar ve bu esnada birey gerçek imleç ile bu imleç görüntüsünü takip eder. İmleç görüntüsünün hedefe varması 5sn sürmektedir.

- İmleç görüntüsü hedefe vardığı anda denemenin bittiğini belirten bitiş sesi duyulur.
- Bir sonraki denemeye geçmek için birey, yine bilgisayar faresinin sol tuşu ile denemeyi başlatma komutu verir.

Şekil 2.8’de bu aşamaya ait senaryo gösterilmektedir.



Şekil 2.8. Motivasyon1 aşaması senaryosu

II. Motivasyon2 Aşaması

Motivasyon2 aşamasının bir denemesine ait senaryo şu şekildedir:

- Başlangıçta ekran Şekil 2.7’de gösterildiği gibi boştur.
- Birey bilgisayar faresinin sol tuşuna tıklayarak denemeyi başlatma komutu verir ve ekranın ortasında sadece görüntü imleci belirir.

- 2 sn sonra başlama sesi duyulur.

- Başlama sesi 1 sn sürer.


- Başlama sesinin bitiminden 1 sn sonra rastgele bir yönde (yukarı/aşağı/sağ/sol) hedef görünür.

- 2 sn sonra imleç görüntüsü hedefe doğru otomatik sürüklenmeye başlar ve bu esnada birey görüntü imleci kendi hareket ettiriyormuş gibi imlece odaklanır. İmleç görüntüsünün hedefe varması 5 sn sürmektedir.

- İmleç görüntüsü hedefe vardığı anda denemenin bittiğini belirten bitiş sesi duyulur.

• Bir sonraki denemeye geçmek için birey, yine bilgisayar faresinin sol tuşu ile denemeyi başlatma komutu verir.

Şekil 2.9'da bu aşamaya ait senaryo gösterilmektedir.




Şekil 2.9. Motivasyon 2 aşaması senaryosu

III. Eğitim Verilerinin Alınması Aşaması

Bu aşamada bu tezde kullanılan eğitim veri setinin kaydı yapılmıştır. Eğitim verilerinin alınması aşamasına ait bir denemenin senaryosu şu şekildedir:

- Başlangıçta ekran Şekil 2.7'de gösterildiği şekilde boştur.
- Birey bilgisayar faresinin sol tuşu ile denemeyi başlatma komutu verir ve ekranın ortasında sadece görüntü imleci belirir.
- 2 sn sonra başlama sesi duyulur.
- Başlama sesi 1 sn sürer.
- Başlama sesinin bitiminden 1 sn sonra rasgele bir yönde (yukarı/aşağı/sağ/sol) hedef görünür.
- Birey bu imleci hedef yönünde sürüklediğini 8sn boyunca hayal eder.
- Denemenin bittiğini belirten bitiş sesi duyulur.
- Bir sonraki denemeye geçmek için birey, yine bilgisayar faresinin sol tuşu ile denemeyi başlatma komutu verir.

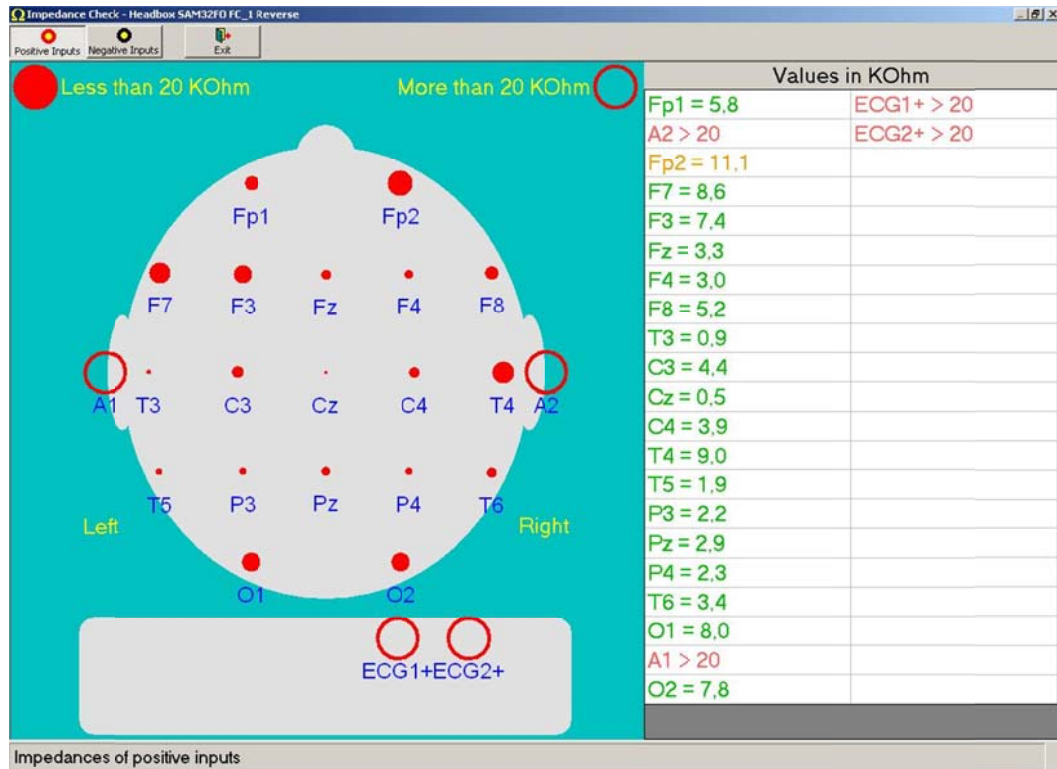
Şekil 2.10'da bu aşamaya ait senaryo gösterilmektedir.



Şekil 2.10. Eğitim verilerinin alınması aşaması senaryosu

IV. Test Verilerinin Alınması Aşaması

Bu aşamanın işleyişi yukarıda açıklanan *Eğitim Verilerinin Alınması Aşaması* ile işleyiş açısından tamamen aynıdır. Eğitim verilerinin alınmasından yaklaşık 1 hafta sonra gerçekleştirilen aşamadır. Şekil 2.5 ve Şekil 2.6'da deneyler esnasında çekilmiş 2 fotoğraf gösterilmektedir.



Şekil 2.11. Elektrotların empedansları


Deney sırasında elektrotların saç derisine tam teması elektrot ile saç derisi arasına sürülen jel ile sağlanmıştır. Şekil 2.11’de jelden sonra elektrotların empedansları gösterilmektedir. Kullanılan elektrotların direnç değerleri 20 KOhm’dan düşük olmalıdır. Şekil 2.11’de A1, A2 ECG1+ ve ECG2+ elektrotların direnç değerleri bu elektrotlar deneyde kullanılmadığından dolayı 20 KOhm’dan büyük olduğu gösterilmektedir.

Bu tez çalışmasında eğitim ve test aşamalarında 4 oturum gerçekleştirilmiştir. Her oturumda hedefin görülme yeri rastgele ortaya çıkmak üzere toplam 40 deneme gerçekleştirilir. Bu 40 denemede hedefin görülme yerleri (yukarı/aşağı/sağ/sol) sayısı eşittir. Bazı denemeler deneye katılan bireyin o denemeye motive olamadığını hissetmesi üzerine kendi isteğiyle iptal edilmiş ve veri tabanından silinmiştir. Tablo 2.2’de 3 gönüllü birey ile yapılan denemelerin sayıları verilmiştir. Toplam 1024deneme yapılmıştır. Eğitim ve test denemelerinde hedefin görülme yeri dağılımları eşittir.

Tablo 2.2. Gönüllü bireyler ile yapılan deneme sayıları

Gönüllü Bireyin		Örnekleme Frekansı	Motivasyon 1	Motivasyon 2	Eğitim	Test	Toplam Deneme Sayısı
Adı,Soyadı	Yaşı						
Mustafa Mutlu (MM)	24	2048 Hz	30	20	140	152	342
Hüseyin Kazaz (HK)	24	2048 Hz	20	20	148	152	340
Önder Aydemir (OA)	29	256 Hz	21	21	148	152	342

Aşağıda Şekil 2.12’de Önder Aydemir ile yapılan deneye ait C3 elektrotundan kaydedilmiş tipik EEG verileri gösterilmektedir.



Şekil 2.12. Tipik EEG verileri, (a) Yukarı imleç hareketi, (b) Aşağı imleç hareketi, (c) Sağ imleç hareketi, (d) Sol imleç hareketi

2.2. Yöntem

2.2.1. Öznitelik Çıkarma Yöntemleri

Daha önce belirtildiği gibi öznitelik çıkarma işleminde çok farklı yöntemler kullanılabilirdi için EEG işaretini tanımlayan farklı öznitelikler elde edilebilmektedir. Bu başlık altında bu tezde EEG işaretlerini temsil etmek için kullanılan matematiksel yöntemler detaylı bir şekilde açıklanmıştır.

2.2.1.1. Dalgacık Dönüşümü

Birçok işaret genellikle zamanın bir fonksiyonu ile elde edilir. Zaman tanım alanında elde edilmiş bir işaretle zaman ve genlik olmak üzere iki bilgi mevcuttur. Bazı işaret işleme uygulamalarında bu iki bilgi, işaretlerden gerekli bilgiye ulaşmak için yeterli olamamaktadır. Uygulamalar için gerekli olan asıl bilgi, işaretin içerdiği frekans bilgisinde saklı olabilmektedir. Bu durumda işaretin zaman-genlik gösterimi yerine frekans spektrumunun incelenmesi daha uygun olmaktadır. Frekans spektrumu, işaretin içerdiği farklı frekans bileşenlerini ve bu frekanslara ait genlik büyüklüklerini içermektedir. Bu amaçla işaretlerdeki frekans bilgisini kullanmak için Fourier dönüşümü (FD) yaklaşımı geliştirilmiştir. FD, zaman tanım alanındaki işareti frekans tanım alanına çeviren ve bir işaretin ihtiva ettiği frekansları gösterebilen oldukça iyi bilinen matematiksel bir araçtır. Bir $x(t)$ sinyali için, FD şu şekilde verilebilir:

$$X(f) = \int_{-\infty}^{\infty} x(t)e^{-j2\pi ft} dt \quad (2.1)$$

FD, sonuçları frekans bileşenlerinin yerel zaman, başlangıç veya bitiş bilgileri hakkında kesin bilgiler sağlamaz. Çünkü bu bilgi Fourier spektrumu boyunca yayılmıştır yani, işareti bütün bir zaman eksenini boyunca alır, işaretin tamamı üzerinde dönüşüm yapar ve böylece işaretin tamamına ait bilgileri verir. Bunun sebebi Fourier temel fonksiyonlarının (sinüs ve kosinüs) tam dayanaklı olmamalarıdır. Bundan dolayı durağan işaret uygulamalarında FD iyi sonuç verebilmektedir [63]. Fakat geçici durum veya anlık değişim analizlerinde istenilen neticeleri verememektedir. FD'nin bu sınırlı yaklaşımını gidermek için kısa zaman Fourier dönüşümü (KFZD) yaklaşımı geliştirilmiştir. KFZD'nin avantajı, analiz için sabit uzunluğa sahip keyfi $g(t)$ penceresi kullanarak gerçekte durağan

olmayan sinyalleri yaklaşık durağan gibi kabul etmesidir. KZFD, $x(t)$ sinyalini, farklı τ zamanları için $g(t)$ kayan penceresi kullanarak iki boyutlu zaman-frekans gösterimi $S(\tau, f)$ haline getirir. Böylece pencerelenmiş $x(t)g^*(t - \tau)$ işaretinin Fourier dönüşümü, KZFD olarak sonuçlanır. Bu durum aşağıdaki eşitlikle ifade edilebilir:

$$KZFD_x(\tau, f) = \int_{-\infty}^{\infty} x(t)g^*(t - \tau)e^{-j2\pi ft} dt \quad (2.2)$$

KZFD için bir $g(t)$ penceresi seçildiğinde, aynı pencere bütün frekanslarda kullanılacağı için tüm zaman-frekans eksenini boyunca zaman-frekans çözünürlüğü aynı olacaktır. Bu, KZFD'de zaman çözünürlüğü ile frekans çözünürlüğü arasında daima bir seçim yapmayı gerektirmektedir [64], [65].

Hem FD hem de KFZD'nin sınırlı yaklaşımlarını gidermek için son yıllarda birçok işaret işleme alanında uygulanan ve popüler bir yaklaşım olan dalgacık dönüşümü (DD) yöntemi geliştirilmiştir. DD düşük frekanslar için geniş, yüksek frekanslar için dar olacak şekilde değişen pencere boyutları ile odağı ayarlanabilen matematiksel bir mikroskop gibi davranarak bütün frekans aralıklarında optimum zaman-frekans çözünürlüğü sağlayabilmektedir [66], [67], [68]. Bu sayede analiz edilen işaret hem frekans bölgesinde hem de zamana bölgesinde incelenebilmektedir.

DD genel olarak daraltılıp, genişletilebilen bir dalgacık fonksiyonu $\psi(t)$ ile analiz edilecek bir $x(t)$ işaretinin evrişimi ile tanımlanır. Eşitlik 2.3 dalgacık fonksiyonunu, Eşitlik 2.4 ise evrişim işlemini ifade etmektedir. Dalgacık fonksiyonunun bir özelliği Eşitlik 2.5'te gösterildiği gibi sıfır ortalamaya sahip olmasıdır.

$$\psi_{\tau, s} = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (2.3)$$

$$DD_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (2.4)$$


$$\int_{-\infty}^{\infty} \psi_{\tau, s}(t) dt = 0 \quad (2.5)$$

Burada $s, \tau \in R (s > 0)$ olmak üzere t, τ ve s sırasıyla zaman, öteleme ve ölçek parametreleridir. Eşitlik 2.4 ile dalgacık katsayılarının bir kümesi elde edilir. Bu katsayılar, işaretin temel fonksiyona ne kadar benzediğini göstermektedir. Dalgacıklar, ölçekleme faktörünün büyüklüğüne orantılı olarak sıkıştırılır ya da genişletilirler. Bir Meksican Hat

dalgacığının ötelenmesi Şekil 2.13'te ve ölçeklenmesi $s_1 > s_2 > s_3$ olmak üzere Şekil 2.14'te, gösterilmiştir.



Şekil 2.13 Bir Meksican Hat dalgacığının zaman eksenini boyunca ötelenmesi




Şekil 2.14. Bir Meksican Hat dalgacığının zaman eksenini boyunca ölçeklenmesi

Birçok BBA veri analiz uygulamalarında öznitelik aramak için DD kullanılmaktadır [69], [70], [71]. Ancak, dalgacık analizinde önemli bir husus dalgacık fonksiyonunun seçimidir. Dalgacık dönüşümlerinde kullanılan bazı dalgacık fonksiyonları, Morlet, Symlet, Daubechies, Meyer, Haar, Meksican Hat dalgacıklarıdır.

Morlet dalgacığının frekans tanım alanında yerel uyarlamasının iyi olması, EEG işaretlerine benzerliğinin bulunması ve öznitelik çıkarma uygulamalarında çoğunlukla tercih edilmesinden dolayı bu tez çalışmasında dalgacık fonksiyonu olarak Morlet dalgacığı seçilmiştir [37], [72]. Morlet dalgacığının denklemi Eşitlik 2.6'da verilmiştir.

$$\psi(t) = e^{-t^2} \cos\left(\pi \sqrt{\frac{2}{\ln 2}} t\right) \quad (2.6)$$

Sürekli dalgacık dönüşümünde mümkün olan tüm ölçekte dalgacık katsayılarının hesabı gereksiz birçok veri üretilmesine neden olabilmektedir. Bunun için dalgacık ölçeği 4-20 Hz arasını kapsayan tam sayı değerlerinden seçilmiştir. Sürekli dalgacık dönüşümü Matlab’da *cwt* fonksiyonu kullanılarak gerçekleştirilmiştir. Şekil 2.15’te 256 Hz örnekleme frekansına sahip işaretin Morlet dalgacığına ait frekans-ölçek ilişkisi verilmiştir.



Şekil 2.15. Morlet dalgacığına ait frekans-ölçek ilişkisi

256 Hz’lik işaretin alt bantlarına ait ölçek aralıkları Tablo 2.3’te verilmiştir

Tablo 2.3. Alt bantlara ait ölçek aralıkları

Band	Ölçek Aralığı
Teta (4-8 Hz)	26-52
Alfa (8-13 Hz)	16-26
Beta (13-20 Hz)	10-16
4-20 Hz bandı	10-52

2.2.1.2. Özbağlanım Metodu

Birçok ayrık zamanlı sistemlerde, veri olarak yalnızca çıkış değerlerinin yardımıyla sistemin modellenmesi gerekir. Bu tür sistemler özbağlanımlı (autoregressive, AR) olarak modellenebilir. Model-tabanlı parametrik yöntemler $x(n)$ veri dizisinin rasyonel bir sistem tarafından karakterize edilen lineer bir sistemin çıkışı olarak modellenmesi temeline dayanır. Model-tabanlı yöntemlerde güç spektral yoğunluğu (GSY) tahmini, veri dizisi ve tahmin edilen yöntem parametreleri kullanılarak hesaplanır. AR modelleme yönteminde, işaretin belli bir anındaki genliği daha önceki örneklenmiş kısımların örneklerinin genliklerinin farklı oranlarda toplanması ve bu toplama bir tahmin hatasının eklenmesi sonucu elde edilir.

AR model parametreleri doğrusal denklemlerin çözümüyle elde edildiği için AR yöntemi çok yaygın kullanıma sahiptir. Veri, girişi beyaz gürültü olan nedensel, tüm kutuplu ayrık filtre çıkışı olarak modellenebilir. Derecesi p olan AR model,

$$x(n) = -\sum_{k=1}^p a(k)x(n-k) + e(n) \quad (2.7)$$

ifadesiyle verilir. Bu eşitlikte $y(n)$ çıkış dizini, $e(n)$ varyansı σ^2 olan beyaz gürültü dizini, $a(k)$ ise özbağlanım (AR) parametrelerini belirtmektedir. AR(p) modeli, $\{a[1], a[2], \dots, a[p], \sigma^2\}$ AR model parametreleri ile karakterize edilir. Bu durumda GSY:

$$P_{AR}(f) = \frac{\sigma^2}{|A(f)|^2} \quad (2.8)$$

eşitliği ile bulunur. Burada

$$A(f) = 1 + a_1 e^{-j2\pi f} + a_2 e^{-j2\pi f} + \dots + a_p e^{-j2\pi f} \quad (2.9)$$

şeklindedir. Özbağlanım metodu Matlab'da *ar* fonksiyonu kullanılarak uygulanmıştır.

2.2.1.3. Çarpıklık ve Ortalama Türev

Öznitelik çıkarma için dalgacık dönüşümü katsayıları ve özbağlanım parametrelerinden başka iki adet yöntem daha kullanılmıştır. Bunlardan birincisi sinyallerin ortalama türev değerleridir. Aşağıdaki eşitlikte bu ortalama türev (OT) değerin nasıl hesaplandığı verilmektedir. Bu değer Matlab ortamında $mean(diff(y))$ fonksiyonu ile hesaplanmıştır.

$$OT = \frac{\sum_{n=1}^{L-1} x(n+1) - x(n)}{L-1} \quad (2.10)$$

Burada, x ; işareti, L ; işaretin örnek sayısını, yani uzunluğunu ifade etmektedir.

İkinci yöntem ise sinyalin çarpıklık (ζ) değeridir. Yamukluk değeri aşağıdaki eşitlikle tanımlanmaktadır ve Matlab ortamında $skewness$ fonksiyonu ile hesaplanmıştır.

$$\zeta = \frac{\frac{1}{L} \sum_{i=1}^L (x_i - \bar{x})^3}{\left(\frac{1}{L} \sum_{i=1}^L (x_i - \bar{x})^2 \right)^{3/2}} \quad (2.11)$$

Burada, x ; işareti, \bar{x} ; işaretin ortalama değerini, L ; işaretin örnek sayısını ifade etmektedir.


2.2.2. Sınıflandırma Yöntemleri

Bu tez çalışmasında, beyin bilgisayar arayüzü çalışmalarında sıklıkla kullanılan k -en yakın komşuluk, destek vektör makineleri, doğrusal ayırma ayırıcı yöntemleri sınıflandırma için kullanılmıştır. Aşağıdaki alt başlıklarda bu yöntemler detaylı bir şekilde açıklanmaktadır.

2.2.2.1. k -En Yakın Komşuluk

Literatürde yaygın bir şekilde kullanılan k -EYK yöntemi, bir test örneğinin sınıfına kendisine en yakın k adet eğitim örneğinin ağırlıklı sınıfına bakarak karar veren denetlemeli bir öğrenme algoritmasıdır [9]. Şöyle ki; yeni bir test örneğini sınıflandırabilmek için test örneğine ait öznitelik vektörü ve eğitim kümesinin öznitelik vektörleri kullanılır. Bir test örneği verilir, bu test noktasına en yakın k tane eğitim noktası hesaplanır. Sınıflandırma ise bu k tane eğitim örneğinin sınıflarından en fazla olanı ile

yapılır. Bu durum, Şekil 2.16'da iki boyutlu öznitelik vektörlerine sahip ve iki sınıflı (*kırmızı* ve *mavi*) örnek veri değerleri ile basit bir şekilde gösterilmektedir. Bu örnekte $k=5$ olarak seçilmiştir. Etiketsiz test örneği, kendisine en yakın 5 eğitim verisi içerisinde 4 tanesi *kırmızı* sınıf, 1 tanesi ise *mavi* sınıf olduğu için *kırmızı* olarak etiketlendirilecektir.



Şekil 2.16. k-EYK yöntemi için basit bir örnek

k -EYK yönteminin performansı iki temel hususa bağlıdır. Bunlardan birincisi; test örneğine en yakın eğitim örneklerinin hesaplanmasında kullanılacak olan uzaklık hesaplama yöntemidir. İkincisi ise belirlenecek k parametresinin değeridir.

Uzaklık hesaplamak için öklit, kosinüs, hamming, şehir blok mesafesi (city-block), korelasyon yöntemleri içerisinde en sık kullanılanı Öklidyen uzaklığı hesabıdır. Bu tez çalışmasında da bu uzaklık ölçütü kullanılmıştır.


Eğitim kümesi öznitelikleri kullanılarak en iyi k parametresi belirlemek için ise çeşitli yaklaşımlar mevcuttur. Bu yaklaşımlardan hemen hemen tüm danışıklı öğrenme metodlarında başvurulan K-kat çapraz onaylama (K-fold cross-validation), birini dışarda bırak çapraz onaylama (*leave one-out cross-validation*) ve rasgele alt örnekleme çapraz onaylama (*random subsampling cross-validation*) sıklıkla kullanılır. Bu yöntemler *Sınıflandırıcı Eğitimi Metotları* başlığı altında detaylı olarak açıklanmıştır. Bu üç eğitim metodundan başka k parametresini belirlemek için Eşitlik 2.12'de verilen yaklaşımda kullanılmaktadır.

$$k = \text{Round}(\sqrt{M}) \quad (2.12)$$

Burada M , eğitim kümesindeki deneme sayısını ifade etmektedir. *Round* ise ondalık sayıyı en yakın tam sayı değerine yuvarlama fonksiyonudur. Bu yaklaşımla k parametresi uzun vakit alan eğitim aşamalarına tabi tutulmadan kolaylıkla belirlenebilmektedir.

2.2.2.2. Destek Vektör Makineleri

DVM istatistiksel öğrenme teorisinde iyi şekilde kurulmuş bir teoriye sahiptir ve sınıflandırma ile regresyon problemlerine çözüm için uygundur. Vapnik'in teorisi eğitim kümesindeki arıza ile VC (Vapnik-Chervonenkis)-boyutuna göre ifade edilen hipotez uzayının karmaşıklığının her ikisini de küçükleyen çözümün bulunduğunu göstermektedir [33]. Bu bakımdan, DVM ile bulunan fonksiyon, veriye yakınlık ve çözümün karmaşıklığı arasındaki geçiştir. Özellikle iki sınıflı sınıflandırma probleminde DVM iki sınıf arasındaki sınırı büyükleyen optimal ayırt etme yüzeyini belirlemekte, yani eğitim kümesi ile ayırt etme yüzeyine en yakın noktaların arasındaki mesafeyi en büyüklemektedir. Şekil 2.17'te verilen iki ayrı kümeyi birbirinden ayırmak için sonsuz sayıda optimal olmayan hiperdüzlem çizilebilir. Ancak DVM bu iki kümeyi ayırmak için maksimum marjini (en yakın eğitim noktalarının uzaklığı) sağlayan optimal hiperdüzlemi arar.



Şekil 2.17. Maksimum marjli hiperdüzlem

Şekil 2.17'de ayırıcı düzlem olarak sınıflar arasında birçok doğrunun çizilebilme ihtimali vardır. Hata toleransını en düşük hale getirmek için çizilebilecek doğrular arasında her iki sınıfa en uzak olacak şekilde çizilen doğru bulunmalıdır. DVM ile sınıflandırma

mantığının temeli her iki sınıfın uç noktalarında bulunan ve eğitime örneklerinin arasından seçilen destek vektörlerdir. Ayrıca düzlemin optimum olmasıyla genelleme yeteneği de maksimum düzeyde olacaktır. Fakat bu verileri iki sınıfa ayıracak çok fazla sayıda ayırıcı düzlem bulunmaktadır. Öncelikle bu ayırıcı düzlem sayısı sınıflar arası mesafe ölçüsüyle sınıf genişliği çarpımı 1 alınarak sınıflandırılmıştır. Sonrada bu ayırıcı düzlemler arasında optimum olanının bulunması gerekir. Optimum ayırıcı düzlem ise, her iki sınıfın en uç verileri arasındaki mesafenin (iki sınıfın destek vektörleri arasındaki mesafe) maksimum olduğu durumu sağlayan ayırıcı düzlemdir. Bu ayırıcı düzlem bahsedilen aralığın tam ortasından geçmelidir.

DVM, optimum ayırıcı düzlemi bulunurken önce optimizasyon problemini formüleştirebilir sonra ikinci dereceli programlama adı verilen metotları kullanarak onu çözer. DVM öğrenme metodu teorik olarak VC boyutu ve yapısal risk minimizasyonu (YRM) prensiplerine uygun olarak tasarlanmıştır.

Şekil 1.13'te verilen akış diyagramı tüm makine öğrenmesi sınıflandırıcı metotları için geçerli olan bir mimaridir. Sınıflandırma işlemi yapılırken eldeki verilerin bir kısmı eğitime için kalan kısmı ise test için ayrılır. Çünkü eğitime verilerinin sınıflandırıcının doğruluk tahmininde de kullanılmasını iyimser (gerçek uygulamalara göre daha yüksek olan) sonuçlar elde etmemize sebep olur. Bu verilerin birbirine oranı sınıflandırma işleminin doğruluk oranını (aynı zamanda hata oranını) doğrudan etkilemektedir. Doğruluk oranını etkileyen bir diğer faktör de verilerin sahip olduğu dağılımdır. Matematiksel olarak DVM, dağılımından bağımsız formül yapısı üzerine kurulur. DVM tekniğinde de önce eğitim verileri alınıp DVM eğitilerek sınıflandırıcı model oluşturulur. Daha sonra çıkış değerini önceden bildiğimiz test verileri için sistemin hesaplayacağı çıkış değeri belirlenir. Sonra bu iki değer arasındaki farklılık oranına göre DVM'nin sınıflandırma performansı değerlendirilir. Öznitelik vektörlerinin dağılımına (doğrusal/doğrusal olmayan) göre DVM parametreleri değişir.

2.2.2.2.1. Doğrusal Destek Vektör Makineleri

DVM'lerin en basit modeli en büyük sınırlı sınıflandırma olarak bilinmektedir. DVM'lerin bu kısmı sadece doğrusal olarak ayrılabilen öznitelik uzayı için geçerlidir. Bu nedenle, çoğu gerçek dünya uygulamalarında kullanılması oldukça zor bir yöntemdir. Ama anlaşılması en kolay algoritmadır ve daha karmaşık DVM için temel kısmı inşa etmektedir.

DVM için geçerli olan çoğu anahtar özellikleri içinde bulundurur. Giriş verilerinin Kernel fonksiyonlarından geçirilip öznitelik uzayına düşürülmesine gerek yoktur. Sadece verileri birbirinden en iyi şekilde ayıran ve en büyük sınırlı sınıflandırmayı yapan hiperdüzlemi bulmak yeterli olacaktır.

Hiperdüzlem tarafından ayrılan veriler x^+ ve x^- ise,

$$\langle w \cdot x^+ \rangle + b = +1 \quad (2.13)$$

$$\langle w \cdot x^- \rangle + b = -1 \quad (2.14)$$

olur. Sınıflandırıcının sınırını γ ile gösterecek olursak;

$$\gamma = \frac{1}{2} \left(\left\langle \frac{w}{\|w\|_2} \cdot x^+ \right\rangle - \left\langle \frac{w}{\|w\|_2} \cdot x^- \right\rangle \right) \quad (2.15)$$

$$= \frac{1}{2\|w\|_2} (\langle w \cdot x^+ \rangle - \langle w \cdot x^- \rangle) \quad (2.16)$$

$$= \frac{1}{\|w\|_2} \quad (2.17)$$

ifadesi geometrik sınırı verecektir.

$S = ((x_1, y_1), \dots, (x_n, y_n))$ ile verilmiş bir doğrusal olarak ayrılabilen eğitim kümesinde optimizasyon problemini çözen (w, b) hiperdüzlemini en büyük değerli sınırlı hiperdüzlemin geometrik sınırı;

$$\gamma = \frac{1}{\|w\|_2} \quad (2.18)$$

olarak hesaplanır.

Yukarıdaki denklemlerle verilen ifadelerin çözümü zor olacağından bu problemi uygun bir ikili forma çevirmek iyi olacaktır.

$$L(w, b, \alpha) = \frac{1}{2} \langle w, w \rangle - \sum_{i=1}^n \alpha_i [y_i (\langle w, x_i \rangle + b) - 1] \quad (2.19)$$

Burada $\alpha_i \geq 0$ değerli Lagrange çarpanlarıdır. (42) eşitliğinde w ve b 'ye göre türev alınacak olursa,

$$\frac{\partial L(w, b, \alpha)}{\partial w} = w - \sum_{i=1}^n y_i \alpha_i x_i = 0, \quad (2.20)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = \sum_{i=1}^n y_i \alpha_i = 0, \quad (2.21)$$

Bu iki ifadeyi birleştirirsek;

$$w = \sum_{i=1}^n y_i \alpha_i x_i, \quad (2.22)$$

$$0 = \sum_{i=1}^n y_i \alpha_i \quad (2.23)$$

ifadeleri bulunur. Hesaplanan bütün bu değerler birleştirilirse;

$$L(w, b, \alpha) = \frac{1}{2} \langle w, w \rangle - \sum_{i=1}^n \alpha_i [y_i (\langle w, x_i \rangle + b) - 1] \quad (2.24)$$

$$= \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle - \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle + \sum_{i=1}^n \alpha_i \quad (2.25)$$

$$= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \quad (2.26)$$

ifadesi elde edilir. $S = ((x_1, y_1), \dots, (x_n, y_n))$ ile verilen doğrusal olarak ayrılabilen bir eğitim kümesinde α^+ parametrelerinin ikinci dereceden bir optimizasyon problemini çözdüğünü düşünürsek,

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i x_j \rangle \quad (2.27)$$

$$\sum_{i=1}^n y_i \alpha_i = 0, \quad \alpha_i \geq 0, \quad i = 1, \dots, n \quad (2.28)$$

Ağırlık vektörü $w^* = \sum_{i=1}^n y_i \alpha_i^* x_i$ en büyük sınırlı hiperdüzlemin geometrik sınırı

$\gamma = \frac{1}{\|w^*\|_2}$ olarak hesaplanır. b değeri ikili problemde bulunmamaktadır. Bu nedenle

birincil sabitler kullanılarak b^* değeri bulunmalıdır.

$$b^* = -\frac{\max_{y_i=-1} \langle w^* . x_i \rangle + \min_{y_i=1} \langle w^* . x_i \rangle}{2} \quad (2.29)$$

Karush-Kuhn-Tucker şartları kullanılarak,

$$\alpha_i^* [y_i (\langle w^* . x_i \rangle + b^*) - 1] = 0, \quad i = 1, \dots, n \quad (2.30)$$

ifadesi bulunur. Hiperdüzleme en yakın noktalar yani destek vektörü (DV) için α_i^* değerleri 0 değildir. Diğer noktalar için bütün α_i^* değerleri 0'a eşittir. Bu nedenle ağırlık vektörü w için sadece DV'lerin α_i^* değerleri geçerlidir.

Bu açıklamalardan sonra optimal hiperdüzlem şu şekilde verilir:

$$f(x, \alpha, b^*) = \sum_{i=1}^n y_i \alpha_i^* \langle x_i . x \rangle + b^* \quad (2.31)$$

$$= \sum_{i \in DV}^n y_i \alpha_i^* \langle x_i, x \rangle + b^* \quad (2.32)$$

$j \in DV$ için,

$$y_j f(x_j, \alpha^*, b^*) = y_j \left(\sum_{i \in DV}^n y_i \alpha_i^* \langle x_i, x_j \rangle + b^* \right) = 1 \quad (2.33)$$

$$\langle w^*, w^* \rangle = \sum_{i,j=1}^n y_i y_j \alpha_i^* \alpha_j^* \langle x_i, x_j \rangle \quad (2.34)$$


$$= \sum_{j \in DV} \alpha_j^* y_j \sum_{i \in DV} y_i \alpha_i^* \langle x_i, x_j \rangle \quad (2.35)$$

$$= \sum_{j \in DV} \alpha_j^* (1 - y_j b^*) \quad (2.36)$$

$$= \sum_{i \in DV} \alpha_i^* \quad (2.37)$$

2.2.2.2. Doğrusal Ayrılabilir Veri

Doğrusal ayrılabilir veri durumunda her biri $y_i = \{-1, 1\}$ ile gösterilen sınıflardan birine ait olan, \mathbb{R}^n 'in elemanı olan x_i 'ler, $i=1, \dots, N$, kümesi S verilmiştir. Amaç, veri kümesini verilen etiketlere göre bir alt düzlemlerle ayırıp, aynı sınıfa ait bütün veri noktalarını alt düzlemin aynı tarafında bırakmaktır.



Şekil 2.18. Doğrusal ayrılabilen veri (a) İki sınıflı veriyi ayıran bir alt düzlem, (b) en iyi alt düzlem ve marjları

Bir x_i 'ler veri kümesi, eğer $i=1, \dots, N$ için

$$y_i(w \cdot x_i + b) \geq 1 \quad (2.38)$$

koşulunu sağlayan bir w varsa doğrusal ayrılabilir. Burada (w, b) aşağıdaki denkleme sahip bir alt düzlem tanımlamaktadır;

$$w \cdot x + b = 0 \quad (2.39)$$

ve ayıran alt düzlem olarak adlandırılır ve Eşitlik 2.38'deki çarpım, veri noktası ile etiketinin alt düzlemin aynı tarafında olmasını belirler. Şekil 2.18'de iki sınıflı ayıran böyle alt düzlemlerden biri gösterilmiştir. Tabii ki, iki sınıflı ayırabilen sonsuz sayıda alt düzlem vardır. Şimdi alt düzlemden bir veri noktası x_i 'ye olan bir d_i uzaklık ölçüsü tanımlayalım:

$$d_i = \frac{w \cdot x_i + b}{\|w\|} \quad (2.40)$$

Eğer Eşitlik (2.38) ve (2.40) birleştirilirse aşağıdaki denklemi elde ederiz:

$$y_i d_i \geq \frac{1}{\|w\|} \quad (2.41)$$

Burada $1/\|w\|$ 'nin (w,b) alt düzlemi ile x_i veri noktası arasındaki uzaklığın bir alt sınırı olduğunu gözlüyoruz. Dolayısıyla, eğer veri noktaları kümesi içinde bu alt sınırı eşitlikle sağlayan bir x_i noktası bulabilirsek, bu alt düzleme en yakın noktayı bulduğumuz anlamına gelir. Aynı zamanda, en iyi alt düzlemi elde etmek için alt düzlemle en yakın veri noktası arasındaki uzaklığı enbüyütmemiz gerekir ve bu marj gerçekten de $1/\|w\|$ değerine karşılık gelir. Dahası, bu marjı enbüyütmek w 'nin düzgesi $\|w\|$ 'i enküçültmeye karşılık gelir. Bu marjı enküçültmek ile elde edilen w ve b kullanarak sınıflandırma problemi, x gelen veri olmak üzere,

$$w \cdot x_i + b \quad (2.42)$$

yukarıdaki denklemin işaretini bulmaya indirgenir. Böylelikle, karar fonksiyonumuz;

$$f(x) = \text{sign}(w \cdot x + b) = \text{sign}(\langle w, x \rangle + b) \quad (2.43)$$

olur.

2.2.2.2.3. Doğrusal Ayrılamayan Veri

Gerçek hayatta karşılaşılan çoğu problemler ya doğrusal ya da doğrusal olmayan durumlarda ayırt edilemezler. Genellikle mümkün olduğu kadar sınıfları ayırabilen giriş kümeleri bulmaya çalışılır, fakat çoğunlukla ilgili girişler kayıptır, veri tam değildir, güvenilir değildir veya gürültülüdür. Doğrusal DVM'lerin ayırt edilemez durumuna genişletilmesi Cortes ve Vapnik tarafından yapılmıştır. Temel olarak, problem formülasyonlarında ek serbestlik değişkenleri olarak yapılmıştır. Doğrusal olarak ayırt edilebilen sınıflar hipotezi pratik uygulamalar için oldukça sınırlıdır. Bu nedenle önceki sonuçları düzenlemeye gerek vardır. Bu durum, $y_i(w \cdot x_i + b) + \xi_i < 1$ ifadesini sağlayacak şekilde bir takım $(x_i, y_i) \in S$ noktalarının var olduğu anlama gelir. Negatif olmayan bir ξ_i serbestlik değişkeninin girilmesi $y_i(w \cdot x_i + b) \geq 1$ ile aynı formda doğru şekilde sınıflandırılmamış bir nokta için kısıt belirtmeye ve doğrusal olarak ayırt edilemeyen

eğitim kümesi durumunda önceki analizleri genişletmeye izin verir. Bu amaçla, aşağıdaki ifadeyi sağlayacak şekilde N adet negatif olmayan serbestlik değişkeni (S'teki her nokta için) $\xi = (\xi_1, \xi_2, \dots, \xi_N)$ verilirse;

$$y_i(w.x_i + b) + \xi_i \geq 1, \quad i = 1, 2, \dots, N \quad (2.44)$$

x_i noktası doğru bir şekilde sınıflandırılmış ise $\xi_i = 0$ eşitliğine göre $y_i(w.x_i + b) + \xi_i \geq 1$ 'dir ve $y_i(w.x_i + b) + \xi_i \geq 1$ sınırlaması $y_i(w.x_i + b) \geq 1$ 'e dönüşür. x_i noktası doğru bir şekilde sınıflandırılmamış ise $y_i(w.x_i + b) + \xi_i \geq 1$ 'in sağlanması için serbestlik değişkenine uygun şekilde bir $x_i > 0$ değeri varsayılacaktır. Doğrusal metottan, doğrusal olmayan tekniğe geçişi yapabilmek için Vapnik giriş verisini çok boyutlu özellik uzayına haritalamayı gerçekleştirmiştir. Giriş değerleri özellik uzayına düşürülerek doğrusal ayırıcı hiperdüzlem yapılmıştır.

$K(x, z) = \Phi(x)\Phi(z)$ uygulaması sıklıkla Kernel oyunu diye adlandırılır. Bu bize kesin hesaplamalar yapmadan çok boyutlu özellik uzayında çalışma kolaylığı sunar. Bu Kernel oyununu uyguladıktan sonra hesaplamalar başka uzayda gerçekleştirilir. DVM'lerde $\Phi(\cdot)$ dönüşümleri yapılarak çok boyutlu özellik uzayında formülasyonlar yapılır.

2.2.2.2.4. Doğrusal Olmayan Destek Vektör Makineleri Sınıflandırıcıları

Doğrusal Destek Vektör Makineleri Sınıflandırıcılarından doğrusal olmayan DVM sınıflandırıcılara genişletme basittir. x ile $\Phi(x)$ biçimsel olarak yer değiştirebilir ve Kernel oyunu uygulanabilir.

Doğrusal olmayan DVM'leri tasarımı için temel fikir, giriş uzayındaki verileri yüksek boyutlu özellik uzayına düşürmektir.

$$x \in R^n \rightarrow z(x) = [a_1\phi_1(x), a_2\phi_2(x), \dots, a_n\phi_n(x)]^T \in R^f \quad (2.45)$$

Yukarıdaki gösterimde $n \times f \in R \otimes R$ 'e bir dönüşüm gösterilmiştir. Bir $f(x)$ eşleştirmesi önceden seçilen, sabit bir fonksiyondur. Bir x -giriş uzayı, x giriş vektörünün x_i

bileşenlerinden oluşur ve bir f-özellik uzayı (z-uzayı) z vektörünün $\phi_i(x)$ bileşenlerinden oluşur. Bu dönüşüm yapıldıktan sonra z-uzayında doğrusal algoritma uygulanarak çözüme ulaşılabilmektedir.

Bir x-giriş uzayından, yüksek dereceli z-uzayına düşürme işleminde iki problemle karşılaşabiliriz: $\phi_i(x)$ eşleştirmesinin seçimi ve eğer f özelliklerinin sayısı çok fazla ise hesaplanması gözü korkutan bir $z^T(x).z(x)$ skaler çarpımının hesaplama işlemidir. Bu işlemlerden de kurtulabilmenin yolu Kernel fonksiyonlarının kullanımınıdır.

Bir özellik uzayındaki $\phi^T(x_i).\phi(x_j)$ skaler çarpımlarını, herhangi bir Kernel fonksiyonu seçildikten sonra $K(x_i, x_j)$ hesaplamasını yaparak bulabiliriz. Bu çok uğraştırıcı bir işlem değildir [73], [74].

En çok kullanılan Kernel fonksiyonları şunlardır:

$$K(x, y) = (x.y)^d \text{ (polinomal Kernel)} \quad (2.46)$$

$$K(x, y) = \tanh(K(x, y) + \Phi) \text{ (sigmoid Kernel)} \quad (2.47)$$

$$K(x, y) = \exp\left(-\|x - y\|^2 / (2\sigma^2)\right) \text{ (RBF Kernel)} \quad (2.48)$$

RBF Kernel birçok çalışmada iyi sonuçlar vermesinde dolayı tercih edilen bir çekirdek fonksiyonudur [75], [76]. Bundan dolayı bu tez çalışmasında DVM'ye dayalı bulunan sonuçlar RBF Kernel fonksiyonu kullanılarak hesaplanmıştır.

2.2.2.3. Doğrusal Ayırma Ayırıcı

Doğrusal ayırıcı analizi (linear discriminant analysis), BBA, alanında yaygın kullanılan bir yöntemdir [77], [78]. Bu yöntem, önceden belirlenmiş iki veya daha fazla sınıfın ortalama niteliklerinin istatistiksel olarak anlamlı bir farklılık gösterip göstermediğini ve grupların farklılıklarını ayırt etmede en fazla katkıyı hangi değişkenlerin yaptığını test etmekte kullanılan bir sınıflandırma tekniğidir ve bu yöntemin çalışma mantığı, mevcut verilerin bileşkesi olan yeni bir değişken üretmesi şeklindedir. İlk tanımlanan sınıfların yeni değişkene göre aralarındaki farklılıklar maksimumlaştırılır.

DAA, bir bağımlı değişkenin diğer özelliklerin veya kıstasların doğrusal bileşeni olarak ifade edildiği yöntemler olan varyans analizi ve regresyon analizi ile de yakından ilgilidir. Fakat bu iki yöntemde bağımlı değişken sayısal bir büyüklük olmasına rağmen, DAA'da bu sınıf etiketi gibi kategorik bir değişkendir.

DAA'da gruplar arası farkı belirleyen ayırıcı fonksiyonu hesaplandıktan sonra bu fonksiyon kullanılarak gözlemlerin sınıf üyelikleri tahmin edilir. Fonksiyon belirlendikten sonra sınıflandırma aynı veri grubu üzerinde yapılabilmekte fakat bu durumda sınıflandırma fonksiyonunun belirlendiği ve test edildiği veriler aynı olduğu için, sınıflandırma sonuçları olduğundan daha başarılı gözükme riskini taşımaktadır. Veri seti yeterli olduğunda verileri, eğitim grubu ve test grubu olarak ikiye ayırmak daha sağlıklı sonuç vermektedir. DAA uygulanabilmesi için bir takım varsayımlarının geçerli olması gereklidir. Bu varsayımlar: her sınıf çok değişkenli normal dağılım gösteren bir ana küleden alınmış olmalı; değişkenler arasında çoklu bağıntı olmamalı ve her grup için kovaryans matrisleri eşit olmalıdır.

EEG sinyallerinden elde edilen öznitelikler, bir test sinyali gönderildiğinde, eğitim kümesindeki öznitelikler ile karşılaştırıldıktan sonra, o sinyalin hangi göreve ait olduğu tespit edilmeye çalışılmıştır. DAA'nın ilk amacı, farklı sınıflara ait noktaları başka bir düzleme birbirlerinden en ayrı olacak şekilde iz düşürmektir. Bunun için her bir sınıftaki her bir x noktası $y_i = V^T x$ olacak şekilde değiştirilmiştir. V izdüşüm matrisini, T transpozeyi temsil etmektedir. Sınıf sayısının ikiden fazla olduğu durumlarda DAA'nın genişletilmiş hali olan çoklu sınıflandırma kullanılabilir. İkili sınıflandırmada olduğu gibi, burada da projeksiyon matrisi büyük boyutlu uzaydan küçük boyutlu uzaya taşınacak şekilde oluşturulur ve yine sınıflar arası mesafe maksimum ve sınıf içi mesafe minimum olacak şekilde düzenlenir. Yalnız burada her sınıf arasındaki mesafe maksimum yapılıdır.

n sınıftan oluşan bir veri grubu için,

n_i : i . sınıfa ait işaretlerin sayısı

n : toplam işaret sayısı

c : sınıf parametresi

μ_i : i . sınıfa ait noktaların ortalama değeri

μ : tüm sınıflara ait noktaların ortalama değerini göstermek üzere:

$$\mu_i = \frac{1}{n_i} \sum_{x \in \text{sınıf}_i} x \quad (2.49)$$

$$\mu = \frac{1}{n} \sum_{x \in \text{EğitimKümesi}} x_i \quad (2.50)$$

olarak ifade edilir. Buradan sınıf içi kovaryans matrisi S_W ve sınıflararası kovaryans matrisi S_B , (2.51) ve (2.52) denklemleri ile hesaplanır.

$$S_W = \sum_{i=1}^c \sum_{x_k \in \text{sınıf}_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (2.51)$$

$$S_B = \sum_{i=1}^c n_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (2.52)$$

Projeksiyon matrisi V ise, (2.53) eşitliğinden elde edilir.

$$S_B V = \lambda S_W V \quad (2.53)$$

V nin bulunması için $S_W^{-1} S_B$ 'nin öz vektörleri hesaplanır. V bulunduktan sonra, eğitim setindeki EEG sinyallerini sentezlemek için kullanılan her bir parametre vektörü, V matrisi kullanılarak DAA uzayına taşınmıştır. Bir test sinyali geldiğinde, sentezlenen sinyalin C parametrelerinin hangi sınıfa ait olduğunun bulunması için öncelikle hesaplanan V matrisi kullanılarak C parametresi DAA uzayına geçirilir. DAA uzayında bu noktanın her bir sınıfa olan uzaklığı hesaplanır. Uzaklık hesabı için Öklid uzaklık bağıntısı kullanılmıştır. Bu uzaklık, iki boyutlu uzayda Pisagor Teoreminin bir uygulaması olarak karşımıza çıkmaktadır. i ve j noktaları için (2.54) eşitliği ile ifade edilir.

$$d(i, j) = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (2.54)$$

Daha sonra bu uzaklığa göre veri uygun gruba sınıflandırılır.

2.2.3. Sınıflandırıcı Eğitimi Metotları

Kullanılacak sınıflandırıcının en uygun parametreleri eğitim verileri kullanılarak hesaplanır. Bu işleme sınıflandırıcının eğitimi denilir. Literatürde sıklıkla kullanılan üç eğitim yaklaşımı vardır. Bunlardan birincisi K-kat çapraz onaylama yöntemidir. Bu yöntemde eğitim kümesi K eşit alt kümeye eşit olarak bölünür. K-1 alt küme eğitim için ve 1 alt kümede test (onaylama ya da validasyon da denilir) kümesi olarak kullanılır. Bu dağılım için sınıflandırıcının en uygun parametresi aranır. Bu işlem her bir alt küme en az bir kez validasyon kümesi olarak kullanılıncaya kadar tekrarlanır. Çoğu çalışmada K değeri 10 olarak seçilir [79], [80]. Bu yöntemde rasgele dağılımdan kaynaklanan bir takım problemlerle karşılaşılabilir. Bir diğer dezavantajı da mevcut eğitim verisinin hepsini eğitim için kullanmayışıdır.

İkinci sınıflandırıcı eğitim metodu rasgele alt örnekleme çapraz onaylama metodudur. Bu metotta eğitim kümesi eğitim ve validasyon kümesi olarak rasgele ikiye bölünür ve en uygun sınıflandırıcı parametresi aranır. Bu metotta da rasgele seçim ve eğitim verisinin hepsini eğitim için kullanmayışından kaynaklanan dezavantajlarla karşılaşılabilir.

Üçüncü eğitim metodu ise birini dışarıda bırak çapraz onaylama metodudur. Bu metod K-kat çapraz onaylama metodunun özel bir durumudur. Validasyon kümesinin boyutu 1 olacak şekilde yukarıdaki prosedürün uygulanması ile gerçekleştirilir. Bu metodun mevcut eğitim verisinin en uygun kullanmasından ve rasgele seçim problemlerinden etkilenmemesinden dolayı [8] bu tez çalışmasında sınıflandırıcılar birini dışarıda bırak çapraz onaylama yöntemi ile eğitilmişlerdir. Bu yöntemin MATLAB kodları EKLER bölümünde verilmiştir (bkz sayfa 112 ve 113).

2.2.4. Çoklu Sınıflandırma

Çoklu sınıflandırma durumu ikiden fazla sınıfın bir problemde olması durumunda ortaya çıkar. Bu tür çoklu sınıf problemlerinde ikili sınıf problemleri için üretilmiş DVM ve DAA gibi iyi sonuçlar verebilen sınıflandırma algoritmaları direkt olarak kullanılamamaktadır. Yapay sinir ağları, k-EYK gibi sınıflandırma algoritmaları ile çıkarılan özniteliklere dayalı sınıflandırmalar yapılabilmektedir. DVM ve DAA gibi sınıflandırıcıları da kullanabilmek adına çoklu sınıflandırma problemlerini çözmek için literatürde birkaç yaklaşım bulunmaktadır. Bunlardan en sık kullanılanları; bire-karşı-hepsi

(*one versus all*), bire-karşı-bir (*one versus one*) ve böl-ve-fethet (*divide and conquer*) yöntemleridir.

$M > 2$ olmak üzere M sınıflı bir sınıflandırma problemi olduğunu varsayalım. Sınıf kümesi de $\{1, 2, \dots, d-1, d+1, \dots, M\}$ olarak verilsin. Bire-karşı-hepsi yönteminde her bir sınıfın diğer sınıflardan ayırt edildiği M adet bağımsız sınıflandırıcı tüm eğitim kümesi eğitilir. Bir test örneği bu ikili sınıflandırıcıların sonuçlarına göre bir sınıfa atanır. İkili sınıflandırıcının çıkışı 1 ya da -1 sınıfıdır. 1 sınıfı test örneğinin sınıf d 'ye ait olduğunu, buna karşın -1 sınıfı ise test örneğinin geri kalan $M-1$ sınıflarına ait olduğunu ifade etmektedir. Bu yöntemde test örneğini sınıflandırırken karşılaşılmak istenen durum bir ikili sınıflandırıcının çıkışının 1 diğerlerinin -1 olmasıdır. Böylece, test örneğinin sınıfı çıkışı 1 olan sınıf seçilir. Ancak, istenilen bu durum bu yöntemle ortaya çıkmamakta ve bazı eşitlik durumları ile karşılaşılmaktadır. Bu eşitlik durumu iki şekilde ortaya çıkabilmektedir. Birincisi, iki ya da daha fazla sınıflandırıcının çıkışının 1 olması durumu veya her sınıflandırıcının çıkışının -1 olması durumudur. Eşitlik durumları bu yönteme ekstra külfet getirmekte ve bu durumu gidermek için çeşitli yaklaşımları algoritmaya dahil etmek zorunda bırakmaktadır. Örneğin k -EYK ile $k=1$ seçilerek eşitlik durumunda karar verilebilmektedir.

Bire-karşı-bir yönteminde ise $d < m$ ve $d, m \in \{1, 2, \dots, M\}$ olmak üzere öncelikle her bir sınıf (d, m) şeklinde ikili gruplandırılarak $\frac{M(M-1)}{2}$ adet ikili sınıflandırıcı eğitilir. Bir test örneği için her bir sınıflandırıcı test örneğinin hangi sınıfa ait olması gerektiğine dair bir sonuç verir. Bu sonuca oy da denebilir. En fazla oyu olan sınıf o test örneğinin atanacağı sınıf olarak belirlenir. Ancak bu yöntemde de eşitlik durumları olabilir. Bire-karşı-hepsi yönteminde olduğu gibi bu durum çeşitli yaklaşımlarla giderilebilir.

Böl-ve-fethet yöntemi karar ağacı yapısına benzer bir yaklaşımdır. Bu yöntemde en büyük bilgi kazancını veren özneliliklerden arama yapmak için sınıflandırma doğruluğu kullanılır. Bu amaçla karar ağacı yapısını oluşturmak için eğitim seti küçük alt setlere ayrılır. Böl-ve-fethet yönteminin ana fikri sınıfları her bir alt sette sadece tek bir sınıf kalıncaya kadar alt kümelere bölmektir. Bu yöntemde göre sınıf sayısı, M , arttıkça ortaya çok farklı alt set olasılıkları çıkabilir. Karar ağacı yapısının kökten dallara kadar nasıl oluşturulacağı eğitim kümesi verileri kullanılmak üzere tüm ortaya çıkabilecek olasılıkların değerlendirilmesi ile belirlenmelidir. Bu durum yukarıda anlatılan bire-karşı-hepsi ve bire-karşı-bir yöntemlerine göre eğitim aşamasında zaman kaybı daha fazla olabilmektedir. Bu tez çalışmasında olduğu gibi 4 sınıflı bir problemde bire-karşı-hepsi 4 sınıflandırıcı, bire-

karşı-bir 6 sınıflandırıcı ve böl-ve-fethet en fazla 3 sınıflandırıcıya ihtiyaç duymaktadır. Ayrıca, böl-ve-fethet yönteminde eşitlik durumunun ortaya çıkma ihtimali yoktur ve bu yöntemde karar ağacının her bir düğümünde aynı öznitelik çıkarma yöntemi kullanılmak zorunda değildir. Bu avantajlarının olmasından dolayı bu tez çalışmasında böl-ve-fethet yöntemi 4 sınıflı problemi çözmek için tercih edilmiştir. Bu çalışmada; G1: imlecin yukarı doğru hayaline, G2: imlecin sağa doğru hayaline, G3: imlecin yukarı aşağı doğru hayaline, G4: imlecin sola doğru hayaline ait görevi ifade etmektedir. Bu görevlerin bitişik olarak gösterilmesi ise bunların aynı sınıfta içerisinde birlikte yer aldığını göstermektedir.

2.2.5. Sınıflandırma Performansı Ölçütleri

Tüm görevlere ait (G1, G2, G3 ve G4) test denemeleri sınıflandırma işlemine tabi tutulduktan sonra, sınıflandırıcının performansını ölçmek için sınıflandırma doğruluğu, duyarlılık, seçicilik, Kappa katsayısı, ayırma gücü, hata matrisi, ROC eğrisi gibi çeşitli yaklaşımlar literatürde kullanılmaktadır. Bunlardan sınıflandırma doğruluğu (SD) ve hata matrisi en sık kullanılanların başında gelmektedir. Duyarlılık, seçicilik, Kappa katsayısı, ROC eğrisi ve ayırma gücü ölçütleri daha çok ikili sınıflandırma problemlerinde kullanılmaktadır. Bu tez çalışmasında sınıflandırma problemi dört sınıflı olduğundan ve SD, hata matrisi ve bilgi transfer oranı (BTO) ölçütlerinin sınıflandırıcı performansını göstermekte gerekli ayrıntıyı içerdiğinden ve literatürde sıklıkla tercih edilmelerinden dolayı bu üç yaklaşım sınıflandırıcıların performanslarını ölçmekte kullanılmıştır.

Dört sınıflı bir problemde (G1, G2, G3 ve G4) sınıflandırıcının vereceği olası 4 çıkış (G1, G2, G3 ve G4), 16 farklı durum meydana getirebilir. Bu 16 farklı durum 4x4'lük bir hata matrisi ile gösterilebilir. Tablo 2.4'te verilen hata matrisi bu 16 olası durumu göstermektedir.

Tablo 2.4. Hata matrisi

	Gerçek (olması gereken) Sınıf				
		G1	G2	G3	G4
Sınıflandırıcı Çıkışı	G1	G ₁₁	G ₁₂	G ₁₃	G ₁₄
	G2	G ₂₁	G ₂₂	G ₂₃	G ₂₄
	G3	G ₃₁	G ₃₂	G ₃₃	G ₃₄
	G4	G ₄₁	G ₄₂	G ₄₃	G ₄₄

Bu tabloda gösterilen kısaltmalar aşağıda açıklanmaktadır:

G₁₁: Gerçekte G1 sınıfına ait ve sınıflandırıcının doğru olarak G1 sınıfına atama yaptığı deneme sayısı

G₂₁: Gerçekte G1 sınıfına ait, ancak sınıflandırıcının yanlış olarak G2 sınıfına atama yaptığı deneme sayısı

G₃₁: Gerçekte G1 sınıfına ait, ancak sınıflandırıcının yanlış olarak G3 sınıfına atama yaptığı deneme sayısı

G₄₁: Gerçekte G1 sınıfına ait, ancak sınıflandırıcının yanlış olarak G4 sınıfına atama yaptığı deneme sayısı

G₁₂: Gerçekte G2 sınıfına ait, ancak sınıflandırıcının yanlış olarak G1 sınıfına atama yaptığı deneme sayısı

G₂₂: Gerçekte G2 sınıfına ait ve sınıflandırıcının doğru olarak G2 sınıfına atama yaptığı deneme sayısı

G₃₂: Gerçekte G2 sınıfına ait, ancak sınıflandırıcının yanlış olarak G3 sınıfına atama yaptığı deneme sayısı

G₄₂: Gerçekte G2 sınıfına ait, ancak sınıflandırıcının yanlış olarak G4 sınıfına atama yaptığı deneme sayısı

G₁₃: Gerçekte G3 sınıfına ait, ancak sınıflandırıcının yanlış olarak G1 sınıfına atama yaptığı deneme sayısı

G₂₃: Gerçekte G3 sınıfına ait, ancak sınıflandırıcının yanlış olarak G2 sınıfına atama yaptığı deneme sayısı

G₃₃: Gerçekte G3 sınıfına ait ve sınıflandırıcının doğru olarak G3 sınıfına atama yaptığı deneme sayısı

G₄₃: Gerçekte G3 sınıfına ait, ancak sınıflandırıcının yanlış olarak G4 sınıfına atama yaptığı deneme sayısı

G₁₄: Gerçekte G4 sınıfına ait, ancak sınıflandırıcının yanlış olarak G1 sınıfına atama yaptığı deneme sayısı

G₂₄: Gerçekte G4 sınıfına ait, ancak sınıflandırıcının yanlış olarak G2 sınıfına atama yaptığı deneme sayısı

G₃₄: Gerçekte G4 sınıfına ait, ancak sınıflandırıcının yanlış olarak G3 sınıfına atama yaptığı deneme sayısı

G₄₄: Gerçekte G4 sınıfına ait ve sınıflandırıcının doğru olarak G4 sınıfına atama yaptığı deneme sayısı

Bu hata matrisinden faydalanarak SD yüzde değer olarak aşağıdaki eşitlikle hesaplanır. Özetle SD, sınıflandırıcı tarafından doğru sınıfa atanan deneme sayılarının tüm deneme sayılarına oranının 100 ile çarpılması ile hesaplanır.

$$SD = \frac{\sum_{i=1}^4 G_{ii}}{\sum_{i=1}^4 G_{i1} + \sum_{i=1}^4 G_{i2} + \sum_{i=1}^4 G_{i3} + \sum_{i=1}^4 G_{i4}} \cdot 100 \quad (2.55)$$

Deneme başına düşen bit cinsinden BTO aşağıdaki gibi hesaplanmıştır.

$$BTO = \log_2 M + P \log_2 P + (1 - P) \log_2 \frac{1-P}{M-1} \quad (2.56)$$

Burada, P sınıflandırma doğruluğunu, M ise görev sayısını ifade etmektedir.

3. BULGULAR

Bu kısımda çıkarılan öznitelikler ilk olarak k-EYK algoritması ile sınıflandırılmıştır. Burada k-EYK çoklu sınıflandırıcılar için uygulamasının kolay olmasından başka, hızlı ve doğruluğu yüksek bir yöntem olmasından dolayı seçilmiştir [4], [8], [37]. Daha sonra bu çalışmanın savı olan karar ağacı yapısı yaklaşımı ile görevler (G1, G2, G3, G4) eğitim kümesindeki denemelerden çıkarılan özniteliklerin kombinasyonlarında k-EYK, DVM ve DAA sınıflandırıcılarının sağladığı en yüksek sınıflandırma doğruluğuna göre ikili alt gruplara otomatik olarak dallandırılmıştır. Test aşamasında ise oluşturulan ağaç yapısına göre denemeler sınıflandırılmıştır. Bu yöntemler aşağıda detaylı olarak açıklanmaktadır.

3.1. Öznitelik Parametreleri

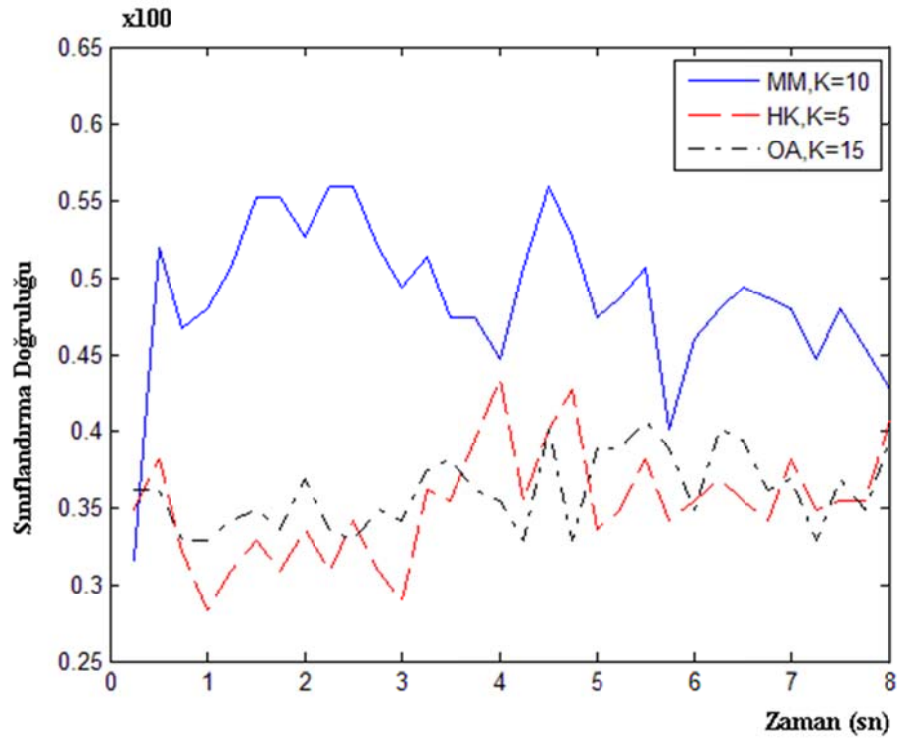
Öznitelik Çıkarma Yöntemleri başlığı altında detaylı açıklanan matematiksel yöntemlerle Tablo 3.1’de açıklamaları verilen öznitelikler EEG işaretlerinden çıkarılmıştır. Bu tabloda K: kullanılan kanalı (elektrotu), S: kullanılan EEG işaretinin veri uzunluğunu yani süresini, B: EEG işaretinin bandını, N: özbağlanım modelinin derecesini ve F3 özniteliğinin boyutunu belirtmektedir. En uygun N parametresi değeri 1-10 arasında 1’er aralıklarla aranmıştır. En uygun S değeri işaretin 0.25-8 saniyelik kısmında 0.25 saniyelik aralıklara aranmıştır. Öznitelik çıkarma süresinin zaman almaması açısından MM ve HK kişilerine ait 2048 Hz’de kaydedilen işaretlerin örnekleme frekansları 8. dereceden alçak geçiren Chebyshev filtresinden geçirilerek 256 Hz’e düşürülmüştür. Özniteliklerin hesaplanmasına dair Matlab kodları EKLER bölümünde verilmiştir (bkz. sayfa 114-116).

Tablo 3.1. Çıkarılan öznitelikler ve özniteliklerin parametreleri


Öznitelik	Öznitelik Çıkarma Yöntemi	Parametreleri	Boyutu
F1	Dalgacık dönüşümü katsayılarının ortalaması	K, S, B	1
F2	Dalgacık dönüşümü katsayılarının standart sapması	K, S, B	1
F3	Özbağlanım katsayıları	K, S, N	N kadar
F4	Ortalama türev	K, S	1
F5	Çarpıklık	K, S	1

3.2. F1 ve F2 Özniteliklerinin k-EYK ile Sınıflandırılması

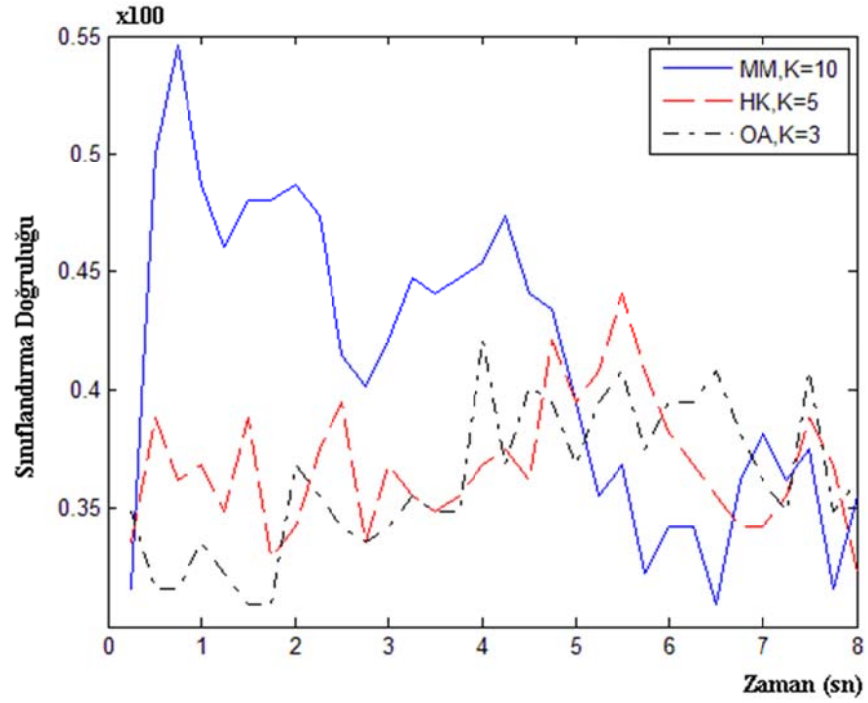
DD ile EEG işaretlerinin teta, alfa, beta, alfa+beta, teta+alfa ve teta+alfa+beta bantlarından çıkarılmış F1 ve F2 öznitelikleri kullanılarak k -EYK sınıflandırıcısı ile G1, G2, G3 ve G4 görevleri sınıflandırılmıştır. Şekil 3.1, Şekil 3.2, Şekil 3.3, Şekil 3.4, Şekil 3.5 ve Şekil 3.6 sırasıyla bu bantlara ait sınıflandırma sonuçlarını göstermektedir. Şekillerde yatay eksen zamanı, dikey eksen SD sonucunu göstermektedir. Bu şekillerde sadece en yüksek SD'yi veren kanala ait sonuçlar verilmektedir.




Şekil 3.1. Teta bandına ait SD sonuçları




Şekil 3.2. Alfa bandına ait SD sonuçları




Şekil 3.3. Beta bandına ait SD sonuçları



Şekil 3.4. Alfa+beta bandına ait SD sonuçları



Şekil 3.5. Teta+alfa bandına ait SD sonuçları



Şekil 3.6. Teta+alfa+beta bandına ait SD sonuçları

Bu sonuçlara göre en yüksek SD değerleri Tablo 3.2’de verilmiştir. Tabloda verilen k değeri k -EYK sınıflandırıcısının k parametresidir.


Tablo 3.2. F1 ve F2 özniteliklerinin k -EYK ile sınıflandırma sonuçları

Kişi	B	S	K	k değeri	SD (%)	BTO
MM	Alfa+beta	1.25	10	25	56.58	0.33
HK	Beta	5.5	5	23	44.08	0.12
OA	Alfa	4.25	10	23	45.39	0.14
	Alfa+beta	5.25	14	20	45.39	0.14

3.3. F3 Özniteliğinin k -EYK ile Sınıflandırılması

Özbağlanım modelinin derecesinin 1 ile 10 arasında değiştirilmek sureti ile çıkarılmış F3 özniteliği kullanılarak k -EYK sınıflandırıcısı ile G1, G2, G3 ve G4 görevleri sınıflandırılmıştır. Kişiler için en yüksek SD’yi veren derece ve kanala ait bulgular Şekil

3.7’de verilmiştir. Bu şekilde yatay eksen zamanı, dikey eksen SD sonucunu göstermektedir.



Şekil 3.7. F3 özneliğinin k-EYK ile sınıflandırılması

Şekil 3.7’den de görüldüğü gibi F3 özneliği ile MM, HK ve OA için elde edilen en yüksek SD’ler sırasıyla N=5, K=10, S=1.25 sn’de %44.74, N=5, K=6 ve S=5.25 sn’de %46.71 ve N=8, K=16 ve S=2.75 sn’de %40.79 olarak hesaplanmıştır.

3.4. F4 ve F5 Özneliklerinin k-EYK ile Sınıflandırılması

F4 ve F5 öznelikleri kullanılarak k-EYK sınıflandırıcısı ile G1, G2, G3 ve G4 görevleri sınıflandırılmıştır. Kişiler için en yüksek SD’yi veren kanala ait bulgular şu şekildedir: MM, HK ve OA için elde edilen en yüksek SD’ler sırasıyla K=10 ve S=2 sn’de %54.61, K=13 ve S=2.5 sn’de %38.16 ve K=3 ve S=4.75 sn’de %38.82 olarak hesaplanmıştır.

3.5. Tüm Özniteliklerin *k*-EYK ile Sınıflandırılması

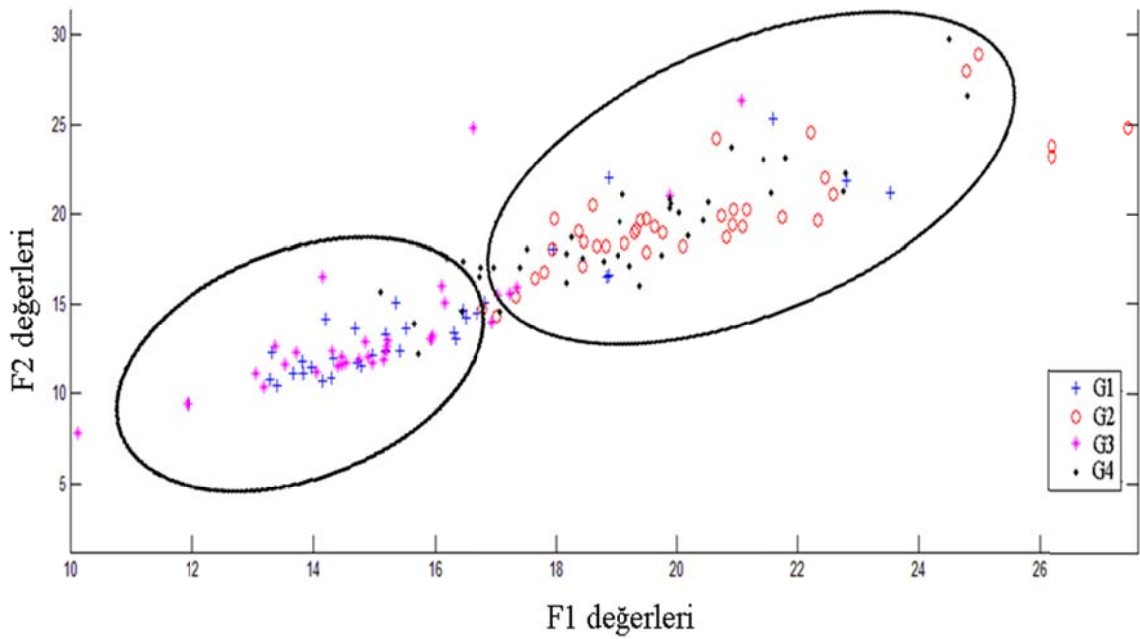
Yukarıda F1, F2, F3, F4 ve F5 öznitelikleri kullanılarak elde edilmiş en yüksek SD'yi veren öznitelik parametreleri (K, S, B, N) göz önünde bulundurularak *k*-EYK sınıflandırıcı ile G1, G2, G3 ve G4 görevleri sınıflandırılmıştır. Elde edilen bulgular Tablo 3.3'te verilmektedir. Bu tablodan görüldüğü gibi tüm özniteliklerin birlikte kullanımı ve *k*-EYK ile sınıflandırılması durumunda MM, HK ve OA kişileri için sırasıyla %67.11, %33.55 ve %41.45 oranında SD'ler elde edilmiştir. Bu sınıflandırma işlemi kişiye özel parametreler belirlenerek gerçekleştirilmiştir. Bu parametreler yukarıda bu özniteliklerin ayrı ayrı kullanımları durumunda elde edilen en yüksek SD değerleri göz önüne alınarak belirlenmiştir.

Tablo 3.3. Tüm özniteliklerin *k*-EYK ile sınıflandırılması

Kişi	SD (%)	Öznitelik Parametreleri
MM	67.11	F1&F2: K=10, S=1.25 B=8-20 F3: K=10, S=1.25, N=5 F4&F5: K=10, S=2
HK	33.55	F1&F2: K=5, S=5.5, B=13-20 F3: K=6, S=5.25, N=5 F4&F5: K=13, S=2.5
OA	41.45	F1&F2: K=14, S=5.25, B=8-20 F3: K=16, S=2.75, N=8 F4&F5: K=3, S=4.75

Şekil 3.8'de MM kişisine ait eğitim verilerinden çıkarılan F1 ve F2 öznitelik değerleri birlikte verilmiştir. Bu şekilde görüldüğü gibi genel görünüş itibari ile G1 ve G3 sınıflarına ait denemeler birlikte bir küme oluştururken, bu kümeden ayrı bölgede toplanmış olan G2 ve G4 sınıflarına ait denemeler birlikte başka bir küme oluşturmuşlardır. Bu şekilde dağılım gösteren 4 sınıflı bir problemin tek bir düğümde sınıflandırılması yerine, ağaç yapısı esaslı olarak en uygun öznitelik (sınıflar arası en fazla ayrışmayı sağlayan öznitelik) ve en uygun sınıflandırıcı (en yüksek sınıflandırma doğruluğunu veren sınıflandırıcı) ile alt dallara ayırarak sınıflandırmanın daha yüksek sınıflandırma doğruluğu sağlayacağı açıktır. Bu örnek şekil için ilk düğümde G1 ve G3'ün tek bir sınıf, G2 ve G4'ün de tek bir sınıfmış gibi düşünülerek sınıflandırılması daha uygundur. Ağaç yapısında görevlerin dallanma biçimi, en uygun öznitelik yöntemi ve en uygun sınıflandırıcı göz önünde bulundurularak otomatik olarak oluşturulmaktadır. Her

kişi için, o kişinin eğitim aşamasında kaydedilen verileri kullanılarak en iyi dallanma biçimini veren öznitelik yöntemi ve sınıflandırıcı ile farklı bir ağaç yapısı oluşturulmaktadır. Burada en iyi dallanma biçiminden kasıt her bir düğüm için en yüksek sınıflandırma doğruluğunu verecek şekilde görevlerin alt gruplara ayrıştırılmasıdır. İlk bakıldığında bu sınıflandırma yaklaşımının kişi özel bir sınıflandırma biçiminde olduğu düşünülse de, aslında her kişinin eğitim verilerini kullanarak bu 4 sınıflı problem için önerilmiş sabit öznitelik yöntemleri ve sınıflandırıcıların seçiminin otomatik yapılması ile genelleştirilmiş bir sınıflandırma yaklaşımı olduğu söylenebilir.

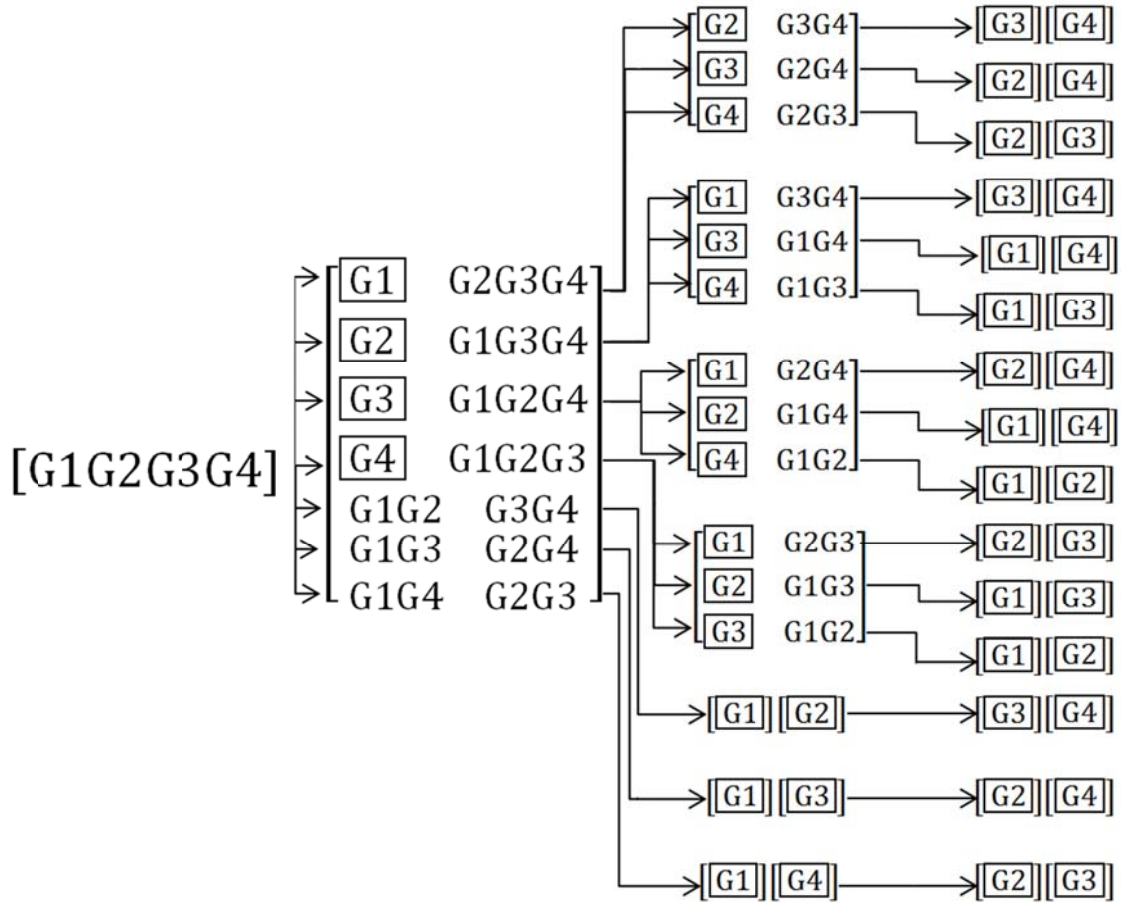


Şekil 3.8. Ağaç yapısı esaslı sınıflandırmanın gereği

3.6. Karar Ağacı Yapısı

Bu tez çalışmasında bilgisayar imlecinin 4 yöne hareket ettirildiğinin düşünülmesi sırasında kaydedilen EEG işaretleri böl-ve-fethet yaklaşımı ile oluşturulan karar ağacı yapısı ile sınıflandırılmaktadır. 4 sınıflı bu problem için oluşturulabilecek ağaç yapıları Şekil 3.9'da gösterilmektedir. Bu şekilden de görüldüğü gibi 4 sınıflı bir sınıflandırma problemi için 15 farklı ağaç yapısı oluşturulabilir. En başarılı ağaç yapısı, her bir düğümde oluşabilecek olası dallanma şekli eğitim verileri ile sınamak sureti ile oluşturulmuştur. Eğitim verileri üzerinde en yüksek sınıflandırma doğruluğunu veren öznitelikler ve sınıflandırıcı ilgili düğümün öznitelik çıkarma ve sınıflandırma yöntemine karar verilmesini sağlamaktadır.

Çıkarılan özniteliklere göre deneye katılan 3 gönüllü bireye ait en iyi ağaç yapısı özniteliklerin kombinasyonları ile eğitim verileri üzerinden elde edilmiştir. Aşağıda bu bulgular verilmektedir.




Şekil 3.9. Oluşturulabilecek karar ağacı yapıları

3.7. MM Kişisine Ait Ağaç Yapısı


MM kişisine ait eğitim verileri üzerinde yapılan araştırmalar neticesinde F1 ve F2 özniteliklerinin birlikte kullanımları ile $K=10$, $S=1.75$ ve $B=4-13$ Hz olduğu durumda G1G3-G2G4 ayrımı en yüksek eğitim sınıflandırma doğruluğu DVM sınıflandırıcısı ile $\sigma=0.6$ hesaplanarak %78.57 olarak elde edilmiştir. Bundan dolayı ağaç yapısının ilk düğümünün G1G3-G2G4 olmasına karar verilmiştir. Bu şartlar altında test verisi üzerinde DVM ile yapılan sınıflandırma sonucu %92.76 oranında bir doğruluk oranı elde edilmiştir. Bu düğüm için eğitim ve test verilerinden çıkarılan öznitelikler Şekil 3.10'da verilmiştir. Bu şekilde yatay eksen F1 düşey eksen F2 özniteliğini göstermektedir.

Birinci düğümün G1G3-G2G4 olması ağaç yapısının nasıl şekilleneceğini tamamen ortaya çıkarmıştır. Bu durumda tek olasılık vardır. Buda G1-G3 ve G2-G4 görevlerinin ayrı ayrı düğümlerde sınıflandırılmasıdır.

Yine eğitim verileri üzerinde yapılan araştırmalar neticesinde G1-G3 için F3 özniteliğinin $K=11$, $S=5.75$ ve $N=8$ olduğu durumda DAA ile ve G2-G4 için F4 ve F5 özniteliklerinin $K=10$, $S= 1.75$ olduğu durumda DVM ile en yüksek sınıflandırma doğrulukları elde edilmiştir. Bunlar sırasıyla %61.43ve %80'dir. Bu şartlar altında tüm G1-G3 görevlerinin test verisi üzerinde DAA ile yapılan sınıflandırma sonucu %77.63 ve tüm G2-G4 görevlerinin test verisi üzerinde DVM ile yapılan sınıflandırma sonucu %96.05 olarak elde edilmiştir. G1-G3 düğümü için öznitelik vektörü 8 boyutlu olduğundan dolayı öznitelik vektörleri gösterilmemiştir. G2-G4 görevlerine ait F4 ve F5 öznitelikleri Şekil 3.11'de verilmiştir. Bu şekilde yatay eksen F4, düşey eksen F5 özniteliğini göstermektedir.




(a)




(b)

Şekil 3.10. MM kişisi için G1G3-G2G4 sınıflarına ait öznelilikler, (a) Eğitim seti, (b) Test seti



(a)




(b)

Şekil 3.11. MM Kişisi için G2-G4 sınıflarına ait öznitelikler, (a) Eğitim seti, (b) Test seti

Şekil 3.12 MM kişisi için oluşan ağaç yapısını göstermektedir. Bu ağaç yapısı eğitilmiş sınıflandırıcılarla test veri setine uygulandığında dört görevi tanımlamada

%82.24'lük bir sınıflandırma doğruluğu ve BTO 1.04 olarak elde edilmiştir. Bu sınıflandırma doğruluğuna ait hata matrisi Tablo 3.4'te verilmektedir.



Şekil 3.12 MM kişisi için oluşan ağaç yapısını

Tablo 3.4. MM ağaç yapısında MM hata matrisi

Görev	G1	G2	G3	G4
G1	27	0	6	1
G2	2	35	1	1
G3	7	1	27	0
G4	2	2	4	36

Aynı ağaç yapısı, öznitelikler ve ilgili parametrelerinden sadece S parametresi kişilere özel en uygun hesaplanıp değiştirilerek HK ve OA kişilerine ait işaretlere

uygulandığında Tablo 3.5’te verilen bulgular elde edilmiştir. Bu tabloda 2, 3 ve 4. sütunlar sırasıyla G1G3-G2G4, G1-G3 ve G2-G4 görevlerini en iyi sınıflandıran sınıflandırıcıyı, sınıflandırma doğruluğunu ve hesaplanan S parametresini gösterirken, son sütun test verisinin ağaç yapısına uygulandığında hesaplanan sınıflandırma doğruluğunu göstermektedir.

Tablo 3.5. HK ve OA işaretlerinin MM ağaç yapısına uygulanmasına ait bulgular

Kişi	G1G3-G2G4	G1-G3	G2-G4	SD (%)	BTO
HK	k-NN (k=4) %64.47 S=5.25 sn	DAA %72.37 S=3 sn	k-NN (k=19) %64.47 S=4.75 sn	46.05	0.15
OA	k-NN (k=7) %64.47 S=1.5 sn	k-NN (k=3) %65.79 S=2.25 sn	DVM ($\sigma=0.1$) %72.37 S=2.25 sn	47.37	0.16

HK ve OA işaretlerinin MM ağaç yapısına uygulanması ile elde edilen hata matrisleri sırasıyla Tablo 3.6 ve Tablo 3.7’de verilmektedir.

Tablo 3.6. MM ağaç yapısında HK hata matrisi

Görev	G1	G2	G3	G4
G1	19	6	7	0
G2	6	12	6	6
G3	4	9	14	7
G4	9	11	11	25

Tablo 3.7. MM ağaç yapısında OA hata matrisi

Görev	G1	G2	G3	G4
G1	13	2	2	4
G2	7	16	5	3
G3	9	8	18	6
G4	9	12	13	25

Bu sonuçlarla MM ağaç yapısında elde edilen ortalama sınıflandırma doğruluğu aşağıdaki eşitlikte verildiği gibi %58.55 olarak hesaplanmıştır.


$$MM_{Ort} = \frac{82.24+46.05+47.37}{3} = 58.55 \quad (3.1)$$

3.8. HK Kişisine Ait Ağaç Yapısı


HK kişisine ait eğitim verileri üzerinde yapılan araştırmalar neticesinde F3 özniteliğinin parametrelerinin $K=6$, $S=6$ ve $N=4$ olduğu durumda G2-G1G3G4 ayrımı için en yüksek eğitim sınıflandırma doğruluğu DVM sınıflandırıcısı ile $\sigma=1.2$ hesaplanarak %77.03 olarak elde edilmiştir. Bundan dolayı ağaç yapısının ilk düğümünün G2-G1G3G4 olmasına karar verilmiştir. Bu şartlar altında G1G2G3G4 test verileri üzerinde DVM ile yapılan sınıflandırma sonucu %82.89 oranında bir doğruluk oranı elde edilmiştir. Bu düğüm için eğitim ve test verilerinden çıkarılan öznitelikler 4 boyutlu olduklarında gösterilememiştir.

Birinci düğümün G2-G1G3G4 olması bundan sonraki düğümün Şekil 3.9'dan da görüldüğü gibi 3 olası durumu vardır. Bunlar; G1-G3G4, G3-G1G4 veya G4-G1G3'tür. G1G3G4 eğitim verileri üzerinde yapılan araştırmalar neticesinde G3-G1G4 için F3 özniteliğinin parametrelerinin $K=6$, $S=3.5$ ve $N=5$ olduğu durumda DVM ($\sigma=1.8$) sınıflandırıcısı ile en yüksek eğitim sınıflandırma doğruluğu %66.68 olarak elde edilmiştir. Dolayısıyla ağaç yapısının ikinci düğümü G3-G1G4 olarak belirlenmiştir. Bu şartlar altında G1G3G4 test verileri üzerinde DVM ile yapılan sınıflandırma sonucu %79.82 oranında bir doğruluk oranı elde edilmiştir. Bu düğüm için eğitim ve test verilerinden çıkarılan öznitelikler 5 boyutlu olduklarında gösterilememiştir.

İkinci düğümün G3-G1G4 olarak belirlenmesinden sonra üçüncü ve son düğümün G1-G4 olacağı kesinleşmiştir. Bu iki görevi birbirinden en yüksek sınıflandırma doğruluğunda ayırt edecek özniteliklerin ve sınıflandırıcının sırasıyla F1 ve F2 öznitelik parametrelerinin $K=5$, $S=5$ ve $B=13-20$ Hz (beta bandı) ve sınıflandırıcının k-EYK ($k=25$ olarak hesaplanmıştır) olduğu hesaplanmıştır. Bu durumda elde edilen G1G4 eğitim kümesine ait sınıflandırma doğruluğu %64.87 olarak hesaplanmıştır. Bu şartlar altında G1G4 test verileri üzerinde k-EYK ile yapılan sınıflandırma sonucu %80.26 oranında bir doğruluk oranı elde edilmiştir. G1-G4 görevlerine ait F1 ve F2 öznitelikleri Şekil 3.13'te verilmiştir. Bu şekilde yatay eksen F1, düşey eksen F2 özniteliğini göstermektedir.




(a)



(b)

Şekil 3.13. HK kişisi için G1-G4 sınıflarına ait öznitelikler, (a) Eğitim seti, (b) Test seti

Şekil 3.14 HK kişisi için oluşan ağaç yapısını göstermektedir. Bu ağaç yapısı eğitilmiş sınıflandırıcılarla test veri setine uygulandığında dört görevi tanımlamada %57.90'lık bir sınıflandırma doğruluğu ve BTO 0.35 olarak elde edilmiştir. Bu sınıflandırma doğruluğuna ait hata matrisi Tablo 3.8'de verilmektedir.



Şekil 3.14. HK kişisi için oluşan ağaç yapısı

Tablo 3.8. HK ağaç yapısında HK hata matrisi

Görev	G1	G2	G3	G4
G1	28	19	14	5
G2	0	13	1	0
G3	0	4	14	0
G4	10	2	9	33

Aynı HK ağaç yapısı, öznelilikler ve ilgili parametrelerinden sadece S parametresi kişilere özel en uygun hesaplanıp değiştirilerek MM ve OA kişilerine ait işaretlere uygulandığında Tablo 3.9’da verilen bulgular elde edilmiştir. Bu tabloda 2, 3 ve 4. sütunlar sırasıyla G2-G1G3G4, G3-G1G4 ve G1-G4 görevlerini en iyi sınıflandıran sınıflandırıcıyı, sınıflandırma doğruluğunu ve hesaplanan S parametresini gösterirken, son sütun test verisinin ağaç yapısına uygulandığında hesaplanan sınıflandırma doğruluğunu göstermektedir.

Tablo 3.9. MM ve OA işaretlerinin HK ağaç yapısına uygulanmasına ait bulgular

Kişi	G2-G1G3G4	G3-G1G4	G1-G4	SD (%)	BTO
MM	DVM ($\sigma=0.2$) %76.32 S=6.5 sn	k-NN (k=8) %71.93 S=1.75 sn	k-NN (k=25) %65.79 S=7 sn	42.11	0.10
OA	DAA %76.97 S=2 sn	DVM ($\sigma=2$) %72.81 S=5 sn	k-NN (k=9) %80.26 S=5.5 sn	46.71	0.16

MM ve OA işaretlerinin HK ağaç yapısına uygulanması ile elde edilen hata matrisleri sırasıyla Tablo 3.10 ve Tablo 3.11’de verilmektedir. Bu tablolarda dikkat çekici nokta G4 görevinin tanınırlığının diğer görevlere oranla yüksek oluşudur.

Tablo 3.10. HK ağaç yapısında MM hata matrisi

Görev	G1	G2	G3	G4
G1	18	10	11	6
G2	0	2	0	0
G3	6	2	15	3
G4	14	24	12	29

Tablo 3.11. HK ağaç yapısında OA hata matrisi


Görev	G1	G2	G3	G4
G1	26	10	13	5
G2	1	5	0	1
G3	1	5	8	0
G4	10	18	17	32

Bu sonuçlarla HK ağaç yapısında elde edilen ortalama sınıflandırma doğruluğu aşağıdaki eşitlikte verildiği gibi %48.91 olarak hesaplanmıştır.


$$HK_{Ort} = \frac{42.11+57.90+48.91}{3} = 48.91 \quad (3.2)$$

3.9. OA Kişisine Ait Ağaç Yapısı

OA kişisine ait eğitim verileri üzerinde yapılan araştırmalar neticesinde F1 ve F2 öznitelik parametrelerinin $K=7$, $S= 3.5$ ve $B=8-13$ Hz olduğu durumda G1-G2G3G4 ayrımı için en yüksek eğitim sınıflandırma doğruluğu DVM sınıflandırıcısı ile $\sigma=0.1$ hesaplanarak %77.03 olarak elde edilmiştir. Bundan dolayı ağaç yapısının ilk düğümünün G1-G2G3G4 olmasına karar verilmiştir. Bu şartlar altında G1G2G3G4 test verileri üzerinde DVM ile yapılan sınıflandırma sonucu %80.92 oranında bir doğruluk oranı elde edilmiştir. Bu düğüm için eğitim ve test verilerinden çıkarılan öznitelikler Şekil 3.15'te gösterilmektedir.



(a)




(b)

Şekil 3.15. OA Kişisi için G1-G2G3G4 sınıflarına ait öznelilikler, (a) Eğitim seti, (b) Test seti


Birinci düğümün G1-G2G3G4 olması bundan sonraki düğümün Şekil 3.9'dan da görüldüğü gibi 3 olası durumu vardır. Bunlar; G2-G3G4, G3-G2G4 veya G4-G2G3'tür. G2G3G4 eğitim verileri üzerinde yapılan araştırmalar neticesinde G4-G2G3 için F1 ve F2 öznitelik parametrelerinin $K=7$, $S= 3.5$ ve $B=8-13$ Hz olduğu durumda DVM ($\sigma=1.3$) sınıflandırıcısı ile en yüksek eğitim sınıflandırma doğruluğu %64.87 olarak elde edilmiştir. Dolayısıyla ağaç yapısının ikinci düğümü G4-G2G3 olarak belirlenmiştir. Bu şartlar altında G2G3G4 test verileri üzerinde DVM ile yapılan sınıflandırma sonucu %78.07 oranında bir doğruluk oranı elde edilmiştir. Bu düğüm için eğitim ve test verilerinden çıkarılan öznitelikler Şekil 3.16'da gösterilmiştir.

İkinci düğümün G4-G2G3 olarak belirlenmesinden sonra üçüncü ve son düğümün G2-G3 olacağı kesinleşmiştir. Bu iki görevi birbirinden en yüksek sınıflandırma doğruluğunda ayırt edecek F3 ve öznitelik parametrelerinin $K=5$, $S=3.25$ ve $N=5$ ve sınıflandırıcının DAA olduğu hesaplanmıştır. Bu durumda elde edilen G2G3 eğitim kümesine ait sınıflandırma doğruluğu %78.38 olarak hesaplanmıştır. Bu şartlar altında G2G3 test verileri üzerinde DAA ile yapılan sınıflandırma sonucu %80.26 oranında bir doğruluk oranı elde edilmiştir. Bu düğüm için eğitim ve test verilerinden çıkarılan öznitelikler 5 boyutlu olduklarında gösterilememiştir.

Şekil 3.17 OA kişisi için oluşan ağaç yapısını göstermektedir. Bu ağaç yapısı eğitilmiş sınıflandırıcılarla test veri setine uygulandığında dört görevi tanımlamada %55.92'lik bir sınıflandırma doğruluğu ve BTO 0.31 olarak elde edilmiştir. Bu sınıflandırma doğruluğuna ait hata matrisi Tablo 3.12'de verilmektedir.




(a)



(b)

Şekil 3.16. OA Kişisi için G4-G2G3 sınıflarına ait öznelilikler, (a) Eğitim seti, (b) Test seti



Şekil 3.17. OA kişisi için oluşan ağaç yapısı

Tablo 3.12. OA ağaç yapısında OA hata matrisi

Görev	G1	G2	G3	G4
G1	9	0	0	0
G2	10	24	1	9
G3	14	12	36	13
G4	5	2	1	16

Aynı OA ağaç yapısı, öznelilikler ve ilgili parametrelerinden sadece S parametresi kişilere özel en uygun hesaplanıp değiştirilerek MM ve HK kişilerine ait işaretlere uygulandığında Tablo 3.13'te verilen bulgular elde edilmiştir. Bu tabloda 2, 3 ve 4. sütunlar sırasıyla G1-G2G3G4, G4-G2G3 ve G2-G3 görevlerini en iyi sınıflandıran sınıflandırıcıyı, sınıflandırma doğruluğunu ve hesaplanan S parametresini gösterirken, son sütun test verisinin ağaç yapısına uygulandığında hesaplanan sınıflandırma doğruluğunu göstermektedir.

Tablo 3.13. MM ve HK işaretlerinin OA ağaç yapısına uygulanmasına ait bulgular

Kişi	G1-G2G3G4	G4-G2G3	G2-G3	SD (%)	BTO
MM	DVM ($\sigma=0.1$) %76.97 S=8 sn	k-NN (k=6) %71.93 S=6.75 sn	DAA %68.42 S=4.25 sn	40.79	0.09
HK	DVM ($\sigma=0.7$) %76.32 S=1.75 sn	DVM ($\sigma=0.1$) %68.42 S=7.5 sn	DAA %78.95 S=6.75 sn	42.11	0.10

MM ve HK işaretlerinin OA ağaç yapısına uygulanması ile elde edilen hata matrisleri sırasıyla Tablo 3.14 ve Tablo 3.15'te verilmektedir. Bu tablolarda dikkat çekici nokta G1 görevinin tanınırlığının diğer görevlere oranla çok düşük oluşudur.

Tablo 3.14. OA ağaç yapısında MM hata matrisi

Görev	G1	G2	G3	G4
G1	4	0	1	0
G2	15	23	11	6
G3	14	12	22	19
G4	5	3	4	13

Tablo 3.15. OA ağaç yapısında HK hata matrisi

Görev	G1	G2	G3	G4
G1	2	0	0	0
G2	11	25	3	3
G3	25	13	35	33
G4	0	0	0	2

Bu sonuçlarla OA ağaç yapısında elde edilen ortalama sınıflandırma doğruluğu aşağıdaki eşitlikte verildiği gibi %46.27 olarak hesaplanmıştır.

$$OA_{Ort} = \frac{40.79+42.11+55.92}{3} = 46.27 \quad (3.3)$$

3.10. Özniteliklerin Farklı Anlardaki Kombinasyonları ile Sınıflandırma Doğruluğunun Arttırılması

Kişiyeye özgü oluşturulan ağaç yapılarında sınıflandırma doğruluğunu arttırmak için çıkarılan özniteliklere farklı anlar ve farklı kanallardan çıkarılan ilave öznitelikler eklenmiştir. Buna göre kişiler için ağaç yapısı aynı kalmak üzere 3 düğüm için yeniden oluşturulan öznitelik vektörleri ve bu öznitelik vektörlerine ait parametreler aşağıda koyu renkli olarak verilmiştir.

MM kişisine ait düğüm parametreleri şöyledir:

1. düğüm öznitelikleri: Değişmemiştir (F1 ve F2 (K=10, S=1.75, B=4.13))
1. düğüm sınıflandırıcısı: DVM ($\sigma=0.6$), SD %92.76 olarak aynı kalmıştır.
2. düğüm öznitelikleri: F3 +**F4, F5 (K=8, S=1.75)**
2. düğüm sınıflandırıcısı: Değişmemiştir (DAA), SD %80.26 olmuştur.
3. düğüm öznitelikleri: F4, F5 +**F3 (K=12, S=5.75, N=10)**
3. düğüm sınıflandırıcısı: k-NN (k=6), SD %97.37 olmuştur.

Düğümlere ait özniteliklerden boyutları 2'den fazla olanlara ait örnek öznitelik değerleri EKLER başlığı altında verilmiştir. Tablolarda her görevden 10 adet örnek öznitelikler verilmiştir. Bu bölümde, Tablo 7.1'de MM için 2. düğüm öznitelikleri verilmiştir. Bu tabloda ilk 8 sütun F3'e ait AR katsayılarını ve son 2 sütun F4 ve F5 özniteliklerini göstermektedir. Tablo 7.2'de ise MM için 3. düğüm öznitelikleri verilmiştir. Bu tabloda ilk 2 sütun F4 ve F5 özniteliklerini, son 10 sütun ise F3'e ait AR katsayılarını göstermektedir. Bu sonuçlara göre MM için elde edilen sınıflandırma doğruluğu %82.24'ten %84.21'e, BTO ise 1.03'ten 1.11'e çıkarılmıştır. Elde edilen yeni SD'ye göre MM hata matrisi aşağıdaki gibi hesaplanmıştır.

Tablo 3.16. MM ağaç yapısında yeni MM hata matrisi

Görev	G1	G2	G3	G4
G1	28	0	5	1
G2	1	36	0	1
G3	6	1	28	0
G4	3	1	5	36

HK kişisine ait düğüm parametreleri şöyledir:

1. düğüm öznitelikleri: F3 (K=6, S=6.75, N=4) + F1 ve F2 (K=6, S=6.75, B=13-20)

1. düğüm sınıflandırıcısı: DVM ($\sigma=1.9$), SD %83.55 olmuştur.

2. düğüm öznitelikleri: Bu düğümde S ve N değişmiştir, F3 (K=6, S=5.25, N=10)

2. düğüm sınıflandırıcısı: DVM ($\sigma=1.8$), SD %79.82 olarak aynı kalmıştır.

3. düğüm öznitelikleri: Değişmemiştir (F1 ve F2 (K=5, S=5, B=13-20))

3. düğüm sınıflandırıcısı: Değişmemiştir (k-NN, k=25), SD %80.26 olarak aynı kalmıştır.

EKLER bölümünde Tablo 7.3'te HK için 1. düğüm öznitelik değerlerine örnekler verilmiştir. Bu tabloda ilk 4 sütun F3'e ait AR katsayılarını ve son 2 sütun F1 ve F2 öznitelik değerlerini göstermektedir. Tablo 7.4'te ise HK için 2. düğüm öznitelik değerlerini göstermektedir. Bu tabloda tüm değerler F3'e ait AR katsayılarını göstermektedir. Bu sonuçlara göre HK için elde edilen sınıflandırma doğruluğu %57.90'dan %62.50'ye ve BTO ise 0.35'ten 0.46'ya çıkarılmıştır. Elde edilen yeni SD'ye göre HK hata matrisi aşağıdaki gibi hesaplanmıştır.

Tablo 3.17. HK ağaç yapısında yeni HK hata matrisi

Görev	G1	G2	G3	G4
G1	25	18	7	5
G2	0	13	0	0
G3	8	4	24	0
G4	5	3	7	33

OA kişisine ait düğüm parametreleri ise şöyledir:

1. düğüm öznitelikleri: F1 ve F2 (K=7, S=3.5, B= 8-13) + F3 (K=10, S=5.5, N=6)

1. düğüm sınıflandırıcısı: k-NN (k=1), SD %81.58 olmuştur.

2. düğüm öznitelikleri: Değişmemiştir (F1 ve F2 (K=14, S=4, B= 4-13))

2. düğüm sınıflandırıcısı: Değişmemiştir (DVM, $\sigma=1.3$), SD %78.07 olarak aynı kalmıştır.

3. düğüm öznitelikleri: F3 (K=5, S=3.25, N=5) + **F4, F5 (K=12, S=2.5)**

3. düğüm sınıflandırıcısı: DAA, SD %88.16 olmuştur.

EKLER bölümünde Tablo 7.5'te OA için 1. düğüm öznitelik değerlerine örnekler verilmiştir. Bu tabloda ilk 2 sütun F1 ve F2 özniteliklerini, ve son 6 sütun F3'e ait AR katsayılarını göstermektedir. Tablo 7.6'de ise OA için 3. düğüm ilk 5 sütun F3'e ait AR katsayılarını ve son 2 sütun F4 ve F5 özniteliklerini göstermektedir. Bu sonuçlara göre OA için elde edilen sınıflandırma doğruluğu %55.92'den %60.53'ye ve BTO ise 0.31'den 0.42'ye çıkarılmıştır. Elde edilen yeni SD'ye göre OA hata matrisi aşağıdaki gibi hesaplanmıştır.

Tablo 3.18. OA ağaç yapısında yeni OA hata matrisi

Görev	G1	G2	G3	G4
G1	17	1	5	1
G2	8	29	1	10
G3	10	6	31	12
G4	3	2	1	15

Tüm kişiler için elde edilen bu SD'ler bu tez çalışmasında 4 görev için hesaplanan en iyi sonuçları temsil etmektedir.

3.11. Kararlılık Analizi

Elde edilen SD'lerin kararlı sonuçlar olduğunu göstermek için eğitim verileri ile test verileri karıştırılmış ve rastgele bir miktar eğitim verisi seçilip SD'ler tekrar hesaplanmıştır. Bu durum her seçim miktarı için 30 kez tekrar edilmiş ve ortalama SD ile standart sapma hesaplanmıştır. Bu sonuçlar Tablo 3.19'da verilmiştir. Bu tablodan da anlaşılacağı gibi eğitim verisi sayısı arttıkça hesaplanan SD artmakta ve standart sapma düşmektedir. MM için ortalama SD %70.39 ile %83.55 arasında, HK için %34.86 ile %59.92 ve OA için ise %39.54 ile %58.67 arasında değişmektedir.

Tablo 3.19. Kararlılık analizi

Eğitim Sayısı	MM için Ortalama SD	HK için Ortalama SD	OA için Ortalama SD
52	70.39±5.25	34.86±5.35	39.54±5.67
80	71.95±4.27	37.97±4.66	44.19±3.77
100	73.85±3.48	41.75±5.05	46.21±3.72
120	76.45±3.21	51.72±4.30	49.87±3.52
148	83.55±2.56	59.92±4.11	58.67±3.21

3.12. Görevlerin İkili Sınıflandırma Doğrulukları

Görevlerin birbiri ile ayrı ayrı sınıflandırılması ile hesaplanan SD'ler MM, HK ve OA kişiler için sırasıyla Tablo 3.20, Tablo 3.21 ve Tablo 3.22'de verilmiştir.

Tablo 3.20. MM kişisi için ikili sınıflandırma doğrulukları

Görev	MM			
	Sınıflandırıcı	Öznitelikler	SD (%)	BTO
G1-G2	DVM ($\sigma=1.1$)	F1, F2	93.42	1.52
G1-G3	DAA	F3, F4, F5	80.26	0.96
G1-G4	DVM ($\sigma=1.0$)	F1, F2	93.42	1.52
G2-G3	DVM ($\sigma=0.6$)	F1, F2	90.79	1.42
G2-G4	k-NN (k=6)	F3, F4, F5	97.37	1.76
G3-G4	DAA	F1, F2	90.79	1.42

MM kişisi için ikili sınıflandırma doğrulukları %80.26 ile 97.37 arasında değişiklik göstermektedir. Tüm ikili görevlerin SD ortalaması % 91.00 ve BTO ortalaması ise 1.43'tür.

Tablo 3.21. HK kişisi için ikili sınıflandırma doğrulukları

Görev	HK			
	Sınıflandırıcı	Öznitelikler	SD (%)	BTO
G1-G2	DVM ($\sigma=2.0$)	F1, F2, F3	75.00	0.79
G1-G3	DAA	F3	71.05	0.67
G1-G4	k-NN (k=25)	F1, F2	80.26	0.96
G2-G3	DVM ($\sigma=2.0$)	F1, F2, F3	71.05	0.67
G2-G4	DVM ($\sigma=2.0$)	F1, F2, F3	80.26	0.96
G3-G4	k-NN (k=3)	F3	75.00	0.79

HK kişisi için ikili sınıflandırma doğrulukları %71.05 ile 80.26 arasında değişiklik göstermektedir. Tüm ikili görevlerin SD ortalaması % 75.44 ve BTO ortalaması ise 0.81'dir.

Tablo 3.22. OA kişisi için ikili sınıflandırma doğrulukları

Görev	OA			
	Sınıflandırıcı	Öznitelikler	SD (%)	BTO
G1-G2	k-NN (k=3)	F1, F2, F3	64.47	0.51
G1-G3	k-NN (k=3)	F1, F2, F3	64.47	0.51
G1-G4	DVM ($\sigma=1.5$)	F1, F2, F3	65.79	0.54
G2-G3	DAA	F3, F4, F5	88.16	1.28
G2-G4	k-NN (k=12)	F1, F2	64.47	0.51
G3-G4	DVM ($\sigma=0.8$)	F1, F2	65.79	0.54

OA kişisi için ise ikili sınıflandırma doğrulukları %64.47 ile 88.16 arasında değişiklik göstermektedir. Tüm ikili görevlerin SD ortalaması % 68.86 ve BTO ortalaması ise 0.65'tir.

3.13. Hesaplama Karmaşıklığı

Kişiler için önerilen ağaç yapılarında öznitelik hesaplama süresi (ÖHS) ve sınıflandırma süresi (SS) Intel ® Core™ i7 CPU 1.73 GHz, 4 GB RAM özelliklerine sahip bir dizüstü bilgisayar kullanılarak hesaplanmıştır. Hesaplama sırasında bilgisayarda başka bir program çalıştırılmamıştır. Hesaplama süreleri saniye cinsinden Tablo 3.23'te verilmiştir. Bu tabloda;

Eğitim Seti ÖHS: Eğitim setindeki bütün denemelere ait öznitelik çıkarma süresini,

Sınıflandırıcı Eğitim Süresi: Ağaç yapısındaki 3 sınıflandırıcının eğitimi için geçen süreyi

Test setinin SS: Test setindeki bütün denemelerin sınıflandırılması için geçen süreyi (bu süreye öznitelik çıkarma süresi dahildir)

KVS/deneme: deneme başına düşen ortalama karar verme süresini ifade etmektedir.

Tablo 3.23. Hesaplama süreleri

Ağaç Yapısı	Eğitim seti ÖHS	Sınıflandırıcı eğitim süresi	Test setinin SS	KVS/D
MM	7.64	38	14.34	0.09
HK	7.55	72	11.64	0.08
OA	7.20	22	9.20	0.06

Sınıflandırma algoritmaları birini dışarıda bırak çapraz onaylama yöntemi ile eğitildiklerinden dolayı sınıflandırıcı eğitim süresi 22 ile 72 sn arasında değişmektedir. KVS/D ise ortalama 0.075 sn civarındadır. Test setlerinin SS'leri ise MM, HK ve OA için sırasıyla 14.34 sn, 11.64 sn ve 9.20 sn'dir. Bir test setinde 152 denemenin olduğunu burada tekrar belirtmek gerekir.

3.14. Performans Karşılaştırması

Daha önce de ifade edildiği gibi literatürde, EEG tabanlı BBA konusu ilk olarak ikili problemlerin çözümü ile başlamıştır. İkili problemlerin çözümlerinde elde edilen başarılı sonuçlardan sonra bu alanda çalışan bilim adamları dört görevli problemleri çözmeye yönelmiştir. Problemlerin çözümünde özellikle eğitim ve test verilerinin farklı günlerde hatta haftalarda kaydedilmiş olup olmadıkları etkin rol oynamaktadır. Aşağıda verilen tabloda bilim adamlarının motor hayaline dayalı çeşitli dört görevli problemlerin çözümünde elde ettikleri en iyi sonuçlar verilmiştir. Bu çalışmalarda elde edilen sonuçları görevlerin birbirinden farklı olması ve verilerin farklı veya aynı günlerde kaydedilmiş olmasından dolayı bu tez çalışmasının sonuçları ile direkt karşılaştırmak mümkün değildir. Performans karşılaştırması için dört sınıflı bir problem için deneye katılan kişi sayıları, kaydedilen deneme sayısı, eğitim ve test verilerinin kaydedilme periyotlarına bakarak bu tez çalışmasında elde edilen sonuçlar hakkında bir değerlendirme yapılabilir. Verilerin 1 hafta ara ile kaydedilmesi ve farklı bir dört sınıflı problem çözümü ile bu tez çalışması orijinal bir çalışma özelliğindedir.

Tablo 3.24. Performans karşılaştırması

Çalışma Özellikleri	Çalışma						
	[81]	[39]	[40]	[82]	[49]	[83]	Bu çalışma
Deneye katılan kişi sayısı	8	4	3	3	1	3	3
Kaydedilen deneme sayısı	4608	1600	1080	840	59	432	1024
Örnekleme frekansı (Hz)	250	250	250	250	250	250	256
Bir denemenin süresi (sn)	3	7	7	7	2	2.5	8
Görevler	Sol el Sağ el Ayak Dil	Sol el Sağ el Ayak Dil	Sol el Sağ el Ayak Dil	Sol el Sağ el Ayak Dil	İmlecin Yukarı/sağ a/aşağı/sol a hareketi	İmlecin Yukarı/sağ a/aşağı/sol a hareketi	İmlecin Yukarı/sağ a/aşağı/sol a hareketi
Eğitim ve Test verilerinin kaydedilme periyodu	Farklı günler	Aynı gün	Aynı gün	Aynı gün	Aynı gün	Aynı gün	1 hafta ara ile
Ortalama SD (%)	63.6	65.00	63.00	77.96	53.1	56.8	69.08

Tablo 3.24'te [39], [40], [81] ve [82] çalışmalarında sol el, sağ el, ayak ve dil hareketlerinin yapıldığının düşünülmesi sırasında kaydedilen motor hayaline dayalı EEG işaretleri sınıflandırılmıştır. Bu çalışmalarda verilerin hepsi aynı prosedürle kaydedilmiştir. Yine aynı prosedürle kaydedilmiş BCI Competition III Data Set IIIa isimli veri kümesi üzerinde bu tez çalışmasında önerilen öznetelik çıkarma yöntemleri ile öznetelikler çıkarılmış ve sınıflandırılmıştır. Bu veri kümesinin önemli özellikleri yukarıda Tablo 3.24'te [82] referans numaralı çalışma ile beşinci sütununda verilmiştir. Bu veri kümesinde bulunan 3 kişiye ait ortalama sınıflandırma doğruluğu %52 olarak hesaplanmıştır.

Literatürde BBA alanında çok sıklıkla kullanılan birkaç yöntem ile veri kümesi ayrıca test edilmiştir. Elde edilen SD'ler Tablo 3.25'te verilmektedir. Bu yöntemlerin sonuçları %26.44 ile % 43.23 ile değişirken, en yüksek SD Fourier dönüşümü ile % 43.23 olarak elde edilmiştir.

Tablo 3.25. Sık kullanılan yöntemlerin SD sonuçları

Yöntem	Ortalama SD (%)
Bağımsız bileşenler analizi [14], [81]	40.34
Fourier dönüşümü [84]	43.23
Güç spektrum analizi [23], [24], [39]	38.94
Genlik analizi [85]	28.48
Ortak uzamsal örüntü [40]	32.21
Yavaş kortikal potansiyeller [21], [22], [27]	37.62
Zaman domeni parametreleri (Varyans, Sıfır nokta tespiti, Minimum ve maksimum değerler) [86]	26.44

4. SONUÇLAR

EEG işaretleri yapısı gereği sürekli değişim gösteren oldukça karmaşık işaretler olduğundan sağlıklı yorumlanmaları matematiksel yöntemlerle analizlerine bağlıdır. Çok miktarda bilgi içerdikleri gün geçtikçe yapılan çalışmalarla ortaya çıkmakta olan EEG işaretleri, özellikle tıpta teşhis ve uygulanan tedavilerin başarımlarının izlenmesinde kullanıldığı gibi, insanoğlunun hayatına farklı teknolojilerle de gireceği kesindir. EEG uygulamalı teknolojiye atılan adımlardan biri de BBA uygulamalarıdır. BBA’da kaydedilen EEG işaretlerinin yüksek doğrulukta ve hızda yorumlanması esastır. Bu tez çalışmasında BBA uygulamaları için farklı oturumlarda bilgisayar imlecinin dört yönde, yukarı, aşağı, sağa ve sola, hayali sırasında kaydedilmiş EEG işaretleri üzerinde matematiksel analizler yapılmıştır. Yapılan analizler sonucunda bu dört tür işaret başarılı bir şekilde sınıflandırılmıştır.

Öznitelik çıkarma, işaret sınıflandırmada çok önem arz eden bir aşamadır. Öznitelikler mevcut sınıflandırma problemi için uygun olmadığında, elde edilen performans tatmin edici olmayacaktır. Bu durumda, sınıflandırma yöntemi problem için en uygun şekilde belirlense dahi zayıf öznitelikler nedeniyle yöntem yüksek performans sergileyemeyecektir. Dolayısıyla, tatmin edici sınıflandırma sonuçları elde etmek için işaretlerden uygun öznitelikler çıkarmak mecburidir. Dalgacık dönüşümü, özbağlanım parametreleri, ortalama türev ve çarpıklık yöntemleri ile çıkarılan özniteliklerle ağaç yapısı modeline dayalı böl-ve-fethet yaklaşımı ile dört sınıflı BBA problemi bu tez çalışmasında çözümlenmiştir.

Tablo 4.1. Ortalama sınıflandırma doğrulukları

Ağaç Yapısı	Ortalama SD
Kişiyeye özel (ilave özniteliklerle)	69.08
Kişiyeye özel	65.35
MM	58.55
HK	48.91
OA	46.27

Motor (hareket) hayaline dayalı mevcut BBA sistemlerinin önemli bir kısıtlaması her bir yeni kullanıcı için eğitim verisi kaydının yapılması ve sistem eğitimi gerektirmesi

zorunluluğundan dolayı kişiye özel olmasıdır. Bu süreç özellikle sınırlı hesaplama kaynaklarıyla sıradan kullanıcılar veya taşınabilir BBA sistemleri için zaman alıcı ve zahmetlidir. Yukarıda Tablo 4.1’de verilen sonuçlara göre de kişiye özel olması BBA’lar için daha yüksek performans sağlayacağını kanıtlamaktadır. Kişiye özel parametrelerle elde edilen sınıflandırma doğruluğu ile her bir ağaç yapısı ile elde edilen ortalama sınıflandırma doğrulukları Tablo 4.1’de verilmiştir. Kişiye özel ağaç yapısı oluşturulduğunda ortalama %65.35 oranında SD elde edilmektedir. Eğer bir kişi için oluşturulan ağaç yapısı diğer kişilere de aynı yöntemle uygulanırsa MM, HK ve OA ağaç yapılarında sırasıyla %58.55, %48.91 ve % 46.27 oranında SD’ler elde edilmektedir. En yüksek SD, MM kişisi ile %82.24 olarak elde edilirken, en düşük SD yine MM kişisi için OA ağaç modeli aynı yöntemle uygulandığında %40.79 olarak elde edilmiştir. Kişiye özel ağaç yapılarının bir avantajı da mevcut çıkarılan özneliklere rahatlıkla ilave yapılabilmesidir. Yukarıda 3.10 başlığı altında kişiye özgü oluşturulan ağaç yapılarında sınıflandırma doğruluğunu arttırmak için çıkarılan özneliklere farklı anlar ve farklı kanallardan çıkarılan ilave öznelikler eklenmiştir. Bu sayede MM kişisine ait SD %84.21’e HK için %62.50’ye, OA için ise %60.53’e yükseltilmiştir. Böylece %65.35 olan genel SD ortalaması da %69.08’e yükseltilmiştir. Genlik normalizasyonu, standart sapma normalizasyonu gibi normalizasyon teknikleri ile sınıflandırma doğrulukları arttırılmaya çalışılmıştır. Ancak tatmin edici sonuçlar elde edilememiştir.

Bu tez çalışmasında önerilen ağaç yapısı yaklaşımı yerine çıkarılan öznelikler hep birlikte k-EYK sınıflandırıcısı ile sınıflandırıldıklarında ortalama %47.37 SD elde edilmektedir. Bu değer ağaç yapısı yaklaşımı ile elde edilen değerden %17.98 oranında daha düşüktür. Ayrıca ağaç yapısı yaklaşımında hangi görevin sınıflandırılmasında düşük performans var ise o göreve spesifik öznelik çıkarılarak bu görevinde daha yüksek oranda sınıflandırılmasına imkan tanınabilirken, özneliklerin hep birlikte kullanımında böyle bir imkan bulunmamaktadır.

Validasyon kümesinin SD’leri genelde test kümesi SD’lerine göre daha düşük kalmıştır. Bu sonuçlara göre, iki seansta kaydedilen veriler için, deneyde yer alan kişilerin ikinci seansta motivasyonlarının birinci seansa göre arttığını söylemek mümkündür.

Bu çalışmanın başarılı ve uygulanabilir olduğunu gösteren bir taraf da kullanılan öznelik vektörlerinin kolay çıkarılabilir ve düşük boyutlu olmasıdır. Elde edilen en iyi SD şartlarında MM kişisi için 24, HK kişisi için 13 ve OA kişisi için 17 boyutlu öznelik vektörleri kullanılarak ağaç yapısı sonuçları elde edilmiştir. Elde edilen sonuçlar sürekli

dalgacık dönüşümü katsayıları, özbağlanım parametreleri, ortalama türev ve çarpıklık değerinin bilgisayar imleci hayaline dayalı EEG işaretlerinin sınıflandırılması için kullanılabilceğini göstermiştir.

Daha önce de değinildiği gibi BBA uygulamalarının pratikte uygulanabilirliğinin kolay olması açısından kullanılan elektrot sayılarının da mümkün olduğunca az sayıda olması önem arz etmektedir. Ağaç yapısı yaklaşımında MM için referans elektrotu hariç 4 (K: 8, 10, 11, 12), HK için 2 (K: 5, 6) ve OA için ise sadece 5 elektrot (K: 5, 7, 10, 12, 14) kullanılmıştır. 8 saniyelik verilerin MM için ilk 5.75 sn, HK için ilk 6.75 sn ve OA için ilk 4 saniyelik kısmı kullanılmıştır.

Oluşturulan üç ağaç yapısı dikkate alındığında kullanılan sınıflandırıcılardan DVM 4, k-EYK 3 ve DAA ise 2 düğümde en başarılı sonuçları vermiştir. Ortaya çıkan bu duruma göre DVM'nin bu sınıflandırıcılar içerisinde daha başarılı olduğu söylenebilir.

Çoklu sınıflandırma yöntemleri arasından böl-ve-fethet yöntemi kullanılarak daha az sayıda sınıflandırıcı kullanılmıştır. Daha az sayıda sınıflandırıcı kullanmak hem eğitim aşamasında hem de test aşamasında zaman kaybını önlemiştir. Bu tez çalışmasında olduğu gibi 4 sınıflı bir problemde bire-karşı-hepsi 4 sınıflandırıcı, bire-karşı-bir 6 sınıflandırıcı ve böl-ve-fethet en fazla 3 sınıflandırıcıya ihtiyaç duymaktadır. Örneğin, HK ve OA ağaç yapılarında ilk düğümde tek sınıflandırıcı ile bir test örneğine karar verilebilirken 2 veya en fazla 3 sınıflandırıcı ile de karar verilebilir. MM ağaç yapısında ise bir test örneğine sadece iki sınıflandırıcı kullanılarak karar verilmektedir. Ayrıca, böl-ve-fethet yönteminde eşitlik durumunun ortaya çıkma ihtimali yoktur. Bu özelliği ile de ekstra bir eşitlik çözücü yöntemi kullanılmak zorunda kalınmamış ve zaman kaybı oluşturulmamıştır. Böl-ve-fethet yönteminde karar ağacının her bir düğümünde aynı öznitelik çıkarma ve sınıflandırıcı yöntemi kullanılmak zorunda değildir. Hibrit bir yaklaşımla her düğümde en başarılı öznitelik çıkarma ve sınıflandırıcı yöntemleri kullanılabilir.

5. ÖNERİLER VE TARTIŞMA

EEG işaretleri yapısı gereği sürekli değişim gösteren oldukça karmaşık işaretler olduğundan sağlıklı yorumlanmaları matematiksel yöntemlerle analizlerine bağlıdır. EEG uygulamalı teknolojiye atılan adımlardan biri olan BBA sistemleri halen geliştirilme aşamasındaki sistemlerdir. BBA konusu ülkemizdeki üniversiteler de dahil olmak üzere dünyada bir çok üniversite tarafından çeşitli seviyelerde incelenen oldukça popüler bir araştırma konusudur. Araştırmalar sonucunda dünya nüfusunda göz ardı edilemeyecek kadar yüksek sayıdaki felçli ve ALS hastaları için hayatlarını daha kaliteli yaşayabilme olanağı sunulabilecektir.

Bu çalışmada BBA uygulamaları için farklı düşünsel ve görsel durumlarda kaydedilmiş EEG işaretlerinin sınıflandırılması üzerine çalışılmıştır. Ele alınan işaretin hangi sınıfa ait olduğuna karar verebilmek için öncelikle eğitim verileri üzerinde incelemeler yapılarak farklı sınıflara ait EEG işaretlerinden öznitelikler çıkartılmalıdır. Öznitelik çıkarma işlemi BBA uygulamalarının en temel ve en zor konusunu oluşturur. Çünkü kaydedilen EEG işaretleri düşünsel durumda oluşan nörolojik bilgileri içermesinin yanında EMG ve EOG gibi EEG için potansiyel artifakt kaynaklarını, şebeke etkisi, ortam etkisi ve biyolojik etkiler gibi gürültü olarak isimlendirebileceğimiz kaynakları da içerebilir. Bunlar gibi birçok gürültü içeren bir veri üzerinde matematiksel incelemeler yapmak oldukça zordur. Dolayısıyla bu artifaktları EEG işaretlerinden arındırmak, düşünsel durumda oluşan nörolojik veriyi elde etme veya işaretlerden öznitelik çıkarma açısından oldukça önemlidir. Bu arındırma işlemi bir önışleme aşaması ile giderilmeye çalışırken, bu durum ek işlem yükünü sisteme getirecektir ki, bu ek işlem BBA'nın hızlı çalışmasına engel teşkil edecektir. Bu durumu aşmak için yapılabilecek en doğru yaklaşımlardan biri EEG kayıtları sırasında bu tür gürültü kaynaklarından etkilenmemek için önlemler alınmalıdır. Bu tez çalışmasında EEG kayıt sisteminin yazılımında 50 Hz'lik çentik süzgeç şebeke gürültüsünü filtrelemek için aktif edilmiştir. Bundan başka EEG işaretleri 0-100 Hz arasında kaydedilmesi için bant geçiren süzgeç yazılımda aktif edilmiştir.

Çoklu elektrot kullanılarak kaydedilen EEG verileri incelenirken, hangi elektrot öznitelik çıkarma için daha uygundur konusu da önemlidir. Beynin farklı bölgeleri farklı görevler için daha duyarlıdır. Örneğin dokunma duyuları beynin yankafa lobunda beden

duyumu bölgesi adı verilen bölgeyle algılanıp yorumlanır. Bunun gibi koklama, işitme, hayal kurma, matematiksel işlemler yapma gibi farklı görevler beynin farklı bölgelerinde daha fazla etki yaratır. Dolayısıyla, çoklu elektrotlu EEG verilerinde tüm elektrotlardan (kanallardan) elde edilen verileri kullanmak yerine, yapılan uygulamaya göre beyinsel aktivitenin yoğun olduğu bölgelerden alınan verileri kullanmak hem sınıflandırma için çıkartılacak en iyi özneliğin bulunmasını, hem de sınıflandırma aşamasında karar verme süresinin kısılmasını sağlayabilir. Birçok sınıflandırma yöntemi, öznelik vektörü çok büyük ve sınıflandırma işlemi için sınırlı süre olduğunda ve öznelik vektörlerinin dağılımı hakkında hiçbir bilgi yok ise verimli çalışmazlar.

Yukarıda da değinildiği gibi farklı düşünsel ve görsel uygulamalarda kaydedilmiş EEG işaretlerinden öznelik çıkarma işlemi çok önemlidir. Öznelik çıkartımı için literatürde birçok matematiksel yöntem mevcuttur. Her yöntem her uygulamada iyi sonuç vermeyebilir. Yapılan uygulamaya has matematiksel analizlerle, o uygulamaya ait öznelik(ler) aranmalıdır. Diğer taraftan farklı insanlardan aynı uygulamaya ait EEG işaretleri de insan fizyolojisi gereği aynı olmayacağından, bulunacak öznelik(ler) kişiden kişiye de farklı sonuçlar verecektir. Yapılacak çalışmalarda tüm bunların dikkate alınması çalışmanın sağlıklı temellere dayandırılması açısından önemlidir.

EEG işaretleri kaydedilirken yüksek örnekleme frekanslarında kaydetmek daha sonraki adımlar için zaman kaybına ve işlem karmaşıklığına neden olmaktadır. Bundan dolayı kayıt aşamasında literatürde de sıklıkla tercih edilen 256 Hz örnekleme frekansı olarak seçilebilir.

Önerilen çalışmanın en önemli dezavantajı en uygun ağaç yapısı oluşturmanın çok zaman alıcı olmasıdır. Ancak, bir kişi için ağaç yapısı oluşturulduktan sonra bir test verisini değerlendirmek hızlı ve doğruluğu yüksek olmaktadır.

Deney süresinin zaman alması, farklı seanslarda kayıt işlemlerinin yapılması, elektrot şapkasının yerleştirilmesinde elektrot ile saç derisi arasındaki iletkenliğin artması için sürülmesi zorunlu olan jelin kullanılması BBA çalışmalarında deneye katılacak gönüllü kişilerin bulunmasını zorlaştırmaktadır. Deneye katılacak bireylerin tüm bu zorlukları bilip ondan sonra deneye katılmak için istekli olması kaydedilecek EEG işaretlerin kalitesini arttıracaktır. Deney için isteksiz bir kişiden EEG kaydı yapmak ve sonra bu işaretlerin analiz edilmesi için harcanacak zaman anlamsız olabilir. Dünyada bu alanda çalışan grupların gönüllü birey bulmakta zorlanmadıkları yaptıkları çalışmalardan anlaşılmaktadır.

BBA konusu halen geliştirilmekte olan bir konudur. Literatüre sunulan veri kümesi sayısı ve sınıflandırılmaya çalışılan göre sayısı çok sınırlıdır. Her ne kadar BBA'nın her aşamasında bir takım zorluklara neden olacaksa da görevler içerisinde *diğer* ya da *hiç biri* sınıfı da olmalıdır. Aksi durumda, BBA'lar gündelik kullanımda kişiler için tatminkar olmayacaktır.

6. KAYNAKLAR

1. Wolpaw, J.R., Birbaumer, N., McFarland, D.J., Pfurtscheller, G. ve Vaughan, T.M., Brain-Computer Interfaces for Communication and Control, Clin. Neurophysiol., 113 (2002) 767-779.
2. Aydemir, Ö. ve Kayıkçıoğlu, T., EEG Tabanlı Beyin Bilgisayar Arayüzleri, *Akademik Bilişim 2009*, Şubat 2009, Şanlıurfa, Bildiriler Kitabı, 7-13.
3. Vaughan, T.M., Brain-computer interface technology: A Review of the Second International Meeting, IEEE Trans. Neural Syst. Rehabil. Eng., 11 (2003) 94-109.
4. Kayıkcioglu, T. ve Aydemir, O., A Polynomial Fitting and k-NN Based Approach for Improving Classification of Motor Imagery BCI Data, Pattern Recognition Letters, 31,11 (2010) 1207-1215.
5. Niedermeyer, E. ve Da Silva, F.H.L., Electroencephalography: Basic Principles, Clinical Applications and Related Fields, 5th edition, Lippincott Williams and Wilkins, ABD, 2004.
6. Ersop, M. E., EEG İşaret Analiz Metotlarının Karşılaştırmalı Bir Çalışması, Yüksek Lisans Tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü, 2003.
7. Weiskopf, N., Mathiak, K., Bock S.W., Scharnowski F., Veit R., Grodd W., Goebel, R. ve Birbaumer, N., Principles of a Brain-Computer Interface (BCI) Based on Real-Time Functional Magnetic Resonance Imaging (fMRI), IEEE Trans Biomedical Engineering , 51,6 (2004), 966-970.
8. Aydemir, O. ve Kayıkcioglu, T., Comparing Common Machine Learning Classifiers in Low-Dimensional Feature Vectors for Brain Computer Interface Applications, International Journal of Innovative Computing Information and Control, 9,3 (2013) 1145-1157.
9. Duda, R. O., Hart, P. E. ve Stork, D. G., Pattern Classification, 2nd edition, Wiley, NY, 2001.
10. Middendorf, M., McMillan, G., Calhoun, G. ve Jones, K.S., Brain Computer Interfaces Based on Steady-State Visual Evoked Response, IEEE Trans. Rehabil. Eng., 8 (2000) 211-213.
11. Lebedev, M. A. ve Nicolelis, M. A. L., Brain-Machine Interfaces: Past, Present and Future, Trends in Neuroscience, 29,9 (2006).

12. Xue, Z., Li, J. ve Li, S., Using ICA to Remove Eye Blink and Power Line Artifacts in EEG, Proceedings of the First International Conference on Innovative Computing, Information and Control, 3 (2006) 107-110.
13. Nezhadarya, E. ve Shamsollahi, M. B., EOG Artifact Removal from EEG Using ICA and ARMAX Modeling, ICBME 2005, Singapore, 2005.
14. Barbati G., Porcaro C., Zappasodi F., Rossini, P.M. ve Tecchio F., Optimization of an Independent Component Analysis Approach for Artifact Identification and Removal in Magnetoencephalographic Signals, Clinical Neurophysiology, 115 (2004) 1220-1232.
15. He, P., Wilson, G. ve Russell, C., Removal of Ocular Artifacts from Electroencephalogram by Adaptive Filtering, Medical and Biological Engineering and Computing, 42 (2004) 407-412.
16. Shooshtari, P., Mohamadi, G., Ardekani, B. M. ve Shamsollahi, M. B., Removing Ocular Artifacts from EEG Signals Using Adaptive Filtering and ARMAX Modeling, Proceedings of World Academy of Science, Engineering and Technology, 11(2006) 277-280.
17. Kumar, P. S., Arumuganathan, R., Sivakumar, K. ve Vimal, C., A Wavelet Based Statistical Method for De-Noising of Ocular Artifacts in EEG Signals, IJCSNS International Journal of Computer Science and Network Security, 8,9 (2008) 87-92.
18. Browne, M. ve Cutmore, T. R., Low-Probability Event-Detection and Separation Via Statistical Wavelet Thresholding: An Application to Psychophysiological Denoising, Clin. Neurophysiol., 113,9(2002) 1403-1411.
19. Lagerlund, T. D., Sharbrough, F. W. ve Busacker, N. E., Spatial Filtering of Multichannel Electroencephalographic Recordings Through Principal Component Analysis by Singular Value Decomposition, J. Clin. Neurophysiol., 14,1(1997) 73-82.
20. Berg, P. ve Scherg, M., A Multiple Source Approach to the Correction of Eye Artifacts, Electroencephalogr. Clin. Neurophysiol., 90,3 (1994) 229-241.
21. Wolpaw, J. R., McFarland, D. J., Neat, G. W. ve Forneris, C. A., An EEG-Based Brain-Computer Interface for Cursor Control, Electroencephalogr. Clin. Neurophysiol., 78(1991) 252-259.
22. Guger, C., Ramoser, H. ve Pfurtscheller, G., Real-Time EEG Analysis with Subject-Specific Spatial Patterns for a Brain-Computer Interface (BCI), IEEE Trans. Rehab. Eng., 8 (2009) 447-456.
23. Chiappa, S. ve Bengio, S., HMM and IOHMM Modeling of EEG Rhythms for Asynchronous BCI Systems, European Symposium on Artificial Neural Networks (ESANN), (2004) 199-204.

24. Millan, J. R. ve Mourino, J., Asynchronous BCI and Local Neural Classifiers: An Over View of the Adaptive Brain Interface Project, IEEE Trans. Neural Syst. Rehabil. Eng., 11 (2003) 159–161.
25. Penny, W. D., Roberts, S. J., Curran, E. A. ve Stokes, M. J., EEG-Based Communication: a Pattern Recognition Approach, IEEE Trans. Rehabil. Eng., 8 (2000) 214–215.
26. Pfurtscheller, G., Neuper, C., Schlogl, A. ve Lugger, K., Separability of EEG Signals Recorded During Right and Left Motor Imagery Using Adaptive Autoregressive Parameters, IEEE Trans. Rehabil. Eng., 6(1998) 316–325.
27. Mensh, B. D., Werfel, J. ve Seung, H. S., BCI Competition 2003—Data Set Ia: Combining Gamma-Band Power With Slow Cortical Potentials to Improve Single-Trial Classification of Electroencephalographic Signals, IEEE Trans. Biomed. Eng., 51,6 (2004) 1052-1056.
28. Lotte, F., Congedo, M., Lecuyer, A., Lamarche, F. ve Arnaldi, B., A Review of Classification Algorithms for EEG-Based Brain–Computer Interfaces, Journal of Neural Engineering, (2007) R1-R13.
29. Blankertz, B., Curio, G. ve Muller, K. R., Classifying Single Trial EEG: Towards Brain Computer Interfacing, Adv. Neural Inf. Process. Syst. (NIPS 01) 14 (2002)157–164.
30. Muller, K. R., Krauledat, M., Dornhege, G., Curio, G. ve Blankertz, B., Machine Learning Techniques for Brain–Computer Interfaces, Biomed. Technol. 49(2004) 11–22.
31. Schlogl, A., Lee, F., Bischof, H. ve Pfurtscheller, G., Characterization of four-class motor imagery EEG data for the BCI-competition 2005, J. Neural Eng. 2 (2005) L14–22.
32. Borisoff, J. F., Mason, S. G., Bashashati, A. ve Birch, G. E., Brain–Computer Interface Design for Asynchronous Control Applications: Improvements to the LF-ASD Asynchronous Brain Switch, IEEE Trans. Biomed. Eng., 51(2004) 985–992.
33. Vapnik, V., Statistical Learning Theory, Wiley, 1998.
34. BCI Competition 2003,
http://ida.first.fraunhofer.de/projects/bci/competition_ii. 13.08.2012.
35. Xu, W., Guan, C., Siong, C. E., Ranganatha, S., Thulasidas, M. ve Wu, J., High Accuracy Classification of EEG Signal, Pattern Recognition, 2 (2004) 391-394.

36. Zhou, S. M., Gan, J. Q. ve Sepulveda, F., Classifying Mental Tasks Based on Features of Higher-Order Statistics from EEG Signals in Brain-Computer Interface, Information Sciences, 178(2008) 1629-1640.
37. Aydemir, O. ve Kayikcioglu, T., Wavelet Transform Based Classification of Invasive Brain Computer Interface Data, Radioengineering, 20,1 (2011) 31-38.
38. Aydemir, O. ve Kayikcioglu, T., Classifying ECoG Based Mental Tasks Using Wavelet Transform Features, 33rd International Conference on Telecommunications and Signal Processing (TSP-2010), Ağustos 2010, Viyana, Bildiriler Kitabı: 17-20.
39. Townsend, G., Graimann, B. ve Pfurtscheller, G., A Comparison of Common Spatial Patterns With Complex Band Power Features in a Four-Class BCI Experiment, IEEE Transactions On Biomedical Engineering, 53,4 (2006) 642-651.
40. Lei X., Yang, P. ve Yao, D., An Empirical Bayesian Framework for Brain-Computer Interfaces, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 17,6 (2009) 521-529.
41. Ting, W., Guo-Zheng, Y., Bang-Hua, Y. and Hong, S., EEG Feature Extraction Based on Wavelet Packet Decomposition for Brain Computer Interface, Measurement, 41,6 (2008) 618-625.
42. Aydemir, Ö. ve Kayıkçıoğlu, T., İkinci Dereceden Polinom Uydurma Algoritması Kullanarak Ham EEG İşaretlerinden Öznitelik Çıkarma, 17. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 2009, Antalya, Bildiriler Kitabı: 189-192.
43. McFarland, D.J., Sarnacki, W.A. ve Wolpaw, J.R., Should the Parameters of a BCI Translation Algorithm Be Continually Adapted?, Journal of Neuroscience Methods, 199 (2011) 103– 107.
44. Lederman, D., Tabrikian, J., Classification of Multichannel EEG Patterns Using Parallel Hidden Markov Models, Med Biol Eng Comput., 50 (2012)319–328.
45. Wang, T. ve He, B., An Efficient Rhythmic Component Expression and Weighting Synthesis Strategy for Classifying Motor Imagery EEG in a Brain-Computer Interface, J. Neural Eng., 1 (2004) 1–17.
46. Qin, L. ve He, B., A Wavelet-Based Time-Frequency Analysis Approach for Classification of Motor Imagery for Brain-Computer Interface Applications, J. Neural Eng., 2 (2005) 65–72.
47. Pfurtscheller, G., Brunner, C., Schloegl, A. ve Lopes da Silva, F.H., Mu Rhythm (De)Synchronization and EEG Single-Trial Classification of Different Motor Imagery Tasks, NeuroImage, 33 (2006) 153–159.

48. Kamousi, B., Amini, A.N. ve He, B., Classification of Motor Imagery by Means of Cortical Current Density Estimation and Von Neumann Entropy for Brain-Computer Interface Applications, J. Neural Eng., 4 (2007) 17-25.
49. Kayagil T.A., Bai, O., Henriquez, C.S. ve Lin, P., A Binary Method for Simple and Accurate Two-Dimensional Cursor Control from EEG with Minimal Subject Training, Journal of Neuro Eng. and Rehabilitation, 6,14 (2009) 1-16.
50. Huang, D., Lin, P., Fei, D.Y., Chen, X. ve Bai, O., Decoding Human Motor Activity from EEG Single Trials for a Discrete Two-Dimensional Cursor Control, Journal of Neural Engineering, 6,4 (2009) 1-12.
51. Bai, O., Lin, P. ve Vorbach, S., et. al., A High Performance Sensorimotor Beta Rhythm-Based Brain-Computer Interface Associated with Human Natural Motor Behavior, Journal of Neural Engineering, 5 (2008) 24-35.
52. Li, Y., Long, J., Yu, T., Yu, Z., Wang, C., Zhang, H. ve Guan, C., An EEG-Based BCI System for 2-D Cursor Control by Combining Mu/Beta Rhythm and P300 Potential, IEEE Trans. on Biomedical Eng., 57,10 (2010) 2495-2505.
53. Long, J., Li, Y., Yu, T. ve Gu, Z., Target Selection with Hybrid Feature for BCI-Based 2-D Cursor Control, IEEE T Bio-Med Eng., 59,1 (2012) 132-140.
54. <http://www.bbc.de/competition/ii>, BCI Competition II. 13.08.2012.
55. <http://www.bbc.de/competition/iii>, BCI Competition III.13.08.2012.
56. <http://www.bbc.de/competition/iv>, BCI Competition IV. 13.08.2012.
57. Birbaumer, N., Flor, H. ve diğerleri, A Brain-Controlled Spelling Device for the Completely Paralyzed, Nature, 398, 297-298.
58. Pfurtscheller, G., Müller, G. R., Pfurtscheller, J., Gerner, H. J. ve Rupp, R., 'Thought' – Control of Functional Electrical Stimulation to Restore Hand Grasp in a Patient with Tetraplegia, Neuroscience Letters, 351 (2003) 33-36.
59. Müller-Putz, G. R., Scherer, R., Pfurtscheller, G. ve Rupp, R., EEG-Based Neuroprosthesis Control: A Step Towards Clinical Practice, Neuroscience Letters, 382 (2005) 169-174.
60. Aydemir, O. ve Kayikcioglu, T., Comparative Performance Assessment of Classifiers in Low-Dimensional Feature Space Which are Commonly Used in BCI Applications, Elektrorevue, 2,4 (2011) 58-63.
61. Wang, B., Jun, L. ve diğerleri, EEG Recognition Based on Multiple Types of Information by Using Wavelet Packet Transform and Neural Networks, 27. IEEE Engineering in Medicine and Biology, Ocak 2006, Shanghai, Bildiriler Kitabı: 5377-5380.

62. Doroshenkov, L. G., Konyshov, V. A. ve Selishchev, S. V., Classification of Human Sleep Stages Based on EEG Processing Using Hidden Markov Models, Biomedical Engineering, 41,1 (2007) 25-28.
63. Roberts, R. A. ve Mull, C. T. 1987. Digital Signal Processing. Addison-Wesley Publishing Company, USA, 85-86.
64. Papoulis, A., The Fourier Integral and Its Applications, Mc Graw Hill, New York, 1962.
65. Goswami, J. C. ve Chan A. K., Fundamentals of Wavelets Theory, Algorithm and Applications, John Wiley & Sons, USA, 1999.
66. Adeli, H., Zhou, Z. ve Dadmehr, N., Analysis of EEG Records in an Epileptic Patient Using Wavelet Transform, Journal of Neuroscience Methods, 123 (2003) 69–87.
67. Burrus, C.S., Gopinath, R.A. ve Guc, H., Introduction to Wavelets and Wavelet Transforms, Texas, Prentice Hall, 1998.
68. Vetterli, M. ve Herley, C., Wavelets and Filter Banks: Theory and Design, IEEE Transactions on Signal Processing, 40,9 (1992) 2207 - 2232.
69. Subasi, A., EEG Signal Classification Using Wavelet Feature Extraction and a Mixture of Expert Model, Expert Systems with Applications, 32 (2007) 1084-1093.
70. Bostanov, V., BCI Competition 2003-Data Sets Ib and Iib Feature Extraction from Event-Related Brain Potentials with the Continuous Wavelet Transform and the t-Value Scalogram, IEEE Trans BME, 51,6 (2004) 1057-1061.
71. Fatourechi, M., Birch, G. E. and Ward, R. K., Application of a Hybrid Wavelet Feature Selection Method in the Design of a Self-Paced Brain Interface System, J Neuroeng Rehabil., 4,11 (2007).
72. Semmlow, J. L., Biosignal and Biomedical Image Processing Matlab-Based Applications, Marcel Dekker, ABD, 2004.
73. Yıldırım, S., Destek Arıza Teşhisinde Destek Vektör Makinelerinin Kullanımı, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 2006.
74. Aydemir, O., Beyin Bilgisayar Arayüzü Uygulamalarına Yönelik EEG İşaretleri İçin Öznitelik Çıkarma, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, 2008.
75. Xu Q., Zhou, H., Wang, Y. ve Huang, J., Fuzzy Support Vector Machine for Classification of EEG Signals Using Wavelet-Based Features, Medical Engineering & Physics, 31 (2009) 858–865.

76. Güler, İ. ve Übeyli, E. D., Multiclass Support Vector Machines for EEG-Signals Classification, IEEE Transactions on Information Technology in Biomedicine, 11,2 (2007) 117-126.
77. Coyle, D., Prasa, G. ve McGinnity, T. M., A Time-Series Prediction Approach For Feature Extraction in a Brain-Computer Interface, IEEE Trans. Neural Syst. Rehabil. Eng., 13,4 (2005) 461-467.
78. İnce, N. F., Göksu, F. ve Tewfik, A. H., ECoG Based Brain Computer Interface with Subset Selection, Communications in Computer and Information Science, 25 (2008) 357-374.
79. Poli, R., Salvaris, M. ve Cinel, C., A Genetic Programming Approach to the Evolution of Brain-Computer Interfaces for 2-D Mouse-Pointer Control, Genet. Program. Evolvable Mach., 13 (2012) 377-405.
80. Bradberry, T. J., Gentili, R.J. ve Contreras-Vidal, J. L., Fast Attainment of Computer Cursor Control with Noninvasively Acquired Brain Signals, Journal of Neural Engineering, 8,3 (2011), 1-9.
81. Naeem, M., Brunner, C., Leeb, R., Graimann, B. ve Pfurtscheller, G., Seperability of Four-Class Motor Imagery Data Using Independent Components Analysis, Journal of Neural Engineering, 3 (2006) 208-216.
82. AlZoubi, O., Koprinska, I. ve Calvo, R. A., Classification of Brain-Computer Interface Data, 7. The Australasian Data Mining Conference, Kasım 2008, Stamford Grand, Bildiriler Kitabı: 27-28.
83. Huang, D., Qian, K., Oxenham, S., Fei, D.Y. ve Bai, O., Event-Related Desynchronization/ Synchronization-Based Brain-Computer Interface Towards Volitional Cursor Control in a 2D Center-Out Paradigm, IEEE Symp. Series on Computational Intelligence, Nisan 2011, Paris, Bildiriler Kitabı: 11-15.
84. Khushaba, R. N., Greenacre, L., Kodagoda, S. ve diğerleri, Choice Modeling and the Brain: A Study on the Electroencephalogram (EEG) of Preferences, Expert Systems With Applications, 39,16 (2012) 12378-12388.
85. Krusienski, D. J., McFarland, D. J. ve Wolpaw, J. R., Value of Amplitude, Phase and Coherence Features for a Sensorimotor Rhythm-Based Brain-Computer Interface, Brain Research Bulletin, 87,1 (2012) 130-134.
86. Geethanjali, P., Mohan, Y. K. ve Sen J., Time Domain Feature Extraction and Classification of EEG Data for Brain Computer Interface, 9th International Conference on Fuzzy Systems and Knowledge Discovery, Mayıs 2012, Sichuan, Bildiriler Kitabı: 1136 – 1139.

7. EKLER

Bu bölümde ağaç yapılarındaki düğümlerde boyutları 2'den büyük olan öznitelik değerlerinden bir kısmı örnek olarak tablolar halinde verilmiştir. Ayrıca, Matlab yazılımının R2010b versiyonunda hazırlanan program kodları da sunulmuştur.

Tablo 7.1. MM için 2. düğüm öznitelik değerleri

Görevler	Öznitelik Değerleri									
1	-0.7865	0.4426	-0.7540	0.6082	-0.4972	0.4583	-0.4700	0.1399	-0.0212	0.2640
1	-0.9913	0.5625	-0.9284	0.8458	-0.6021	0.4909	-0.4705	0.1636	0.1419	1.1590
1	-0.7685	0.4141	-0.7727	0.5747	-0.5181	0.4337	-0.4331	0.1487	0.0147	1.3693
1	-1.1038	0.5841	-0.9117	0.8951	-0.5695	0.4972	-0.5356	0.1921	-0.0538	0.9520
1	-1.0692	0.5107	-0.8591	0.8505	-0.5664	0.5601	-0.5469	0.1902	-0.0025	2.4841
1	-1.0583	0.5621	-0.9235	0.8704	-0.6215	0.5479	-0.5547	0.2187	0.0013	0.8775
1	-1.0147	0.5567	-0.9392	0.8820	-0.6131	0.5242	-0.5419	0.2171	-0.0134	0.6931
1	-0.8373	0.4342	-0.8342	0.6993	-0.5231	0.4606	-0.4932	0.1671	0.0094	0.7721
1	-0.9039	0.4586	-0.8260	0.7252	-0.5032	0.4361	-0.4776	0.2049	-0.0275	0.1513
1	-0.8114	0.4266	-0.7958	0.6609	-0.4888	0.4401	-0.4480	0.1561	0.0200	0.0590
3	-0.8490	0.4244	-0.8010	0.6632	-0.4709	0.3795	-0.4421	0.1011	0.2698	0.4385
3	-0.9832	0.5402	-0.8834	0.8591	-0.5765	0.4806	-0.5316	0.1780	0.0190	0.1704
3	-0.9327	0.4396	-0.8515	0.7820	-0.5252	0.4500	-0.5597	0.2022	-0.0674	0.1935
3	-0.9412	0.4316	-0.7817	0.7521	-0.5684	0.4503	-0.4932	0.1968	-0.0390	2.0157
3	-1.0611	0.5453	-0.8515	0.8015	-0.5324	0.4861	-0.5093	0.1587	0.0106	1.5844
3	-1.0486	0.5504	-0.8686	0.8499	-0.6078	0.5175	-0.5323	0.1992	-0.0034	1.6734
3	-1.1604	0.6757	-0.9917	0.9862	-0.6950	0.5715	-0.5758	0.2171	0.0232	1.3719
3	-1.1212	0.6802	-0.9782	0.8874	-0.6210	0.5040	-0.5230	0.1825	-0.1562	-0.7349
3	-1.1245	0.6763	-0.9476	0.8380	-0.6227	0.5658	-0.5709	0.2449	0.1530	-1.0172
3	-1.1266	0.6264	-0.9055	0.8759	-0.6393	0.5650	-0.6222	0.2296	-0.0071	2.3187

Tablo 7.2. MM için 3. düğüm öznitelik değerleri

Görevler	Öznitelik Değerleri											
2	0.0024	-0.7220	-1.0319	0.6255	-1.1346	1.0343	-0.9303	0.8667	-0.7894	0.4933	-0.4007	0.3064
2	0.0072	-0.7644	-0.9909	0.5790	-1.0534	0.8830	-0.7918	0.7825	-0.7700	0.4472	-0.3666	0.3158
2	0.0054	-0.2879	-0.7963	0.5562	-0.9878	0.8163	-0.7790	0.7322	-0.7394	0.4059	-0.4135	0.2668
2	-0.0308	-0.0294	-1.1844	0.7942	-1.1160	1.1564	-0.9402	0.8912	-0.9211	0.5424	-0.3758	0.2099
2	0.0138	-0.8966	-1.2239	0.7747	-1.2140	1.1918	-0.9437	0.9525	-0.9301	0.5675	-0.4467	0.2984
2	0.0677	-0.8083	-1.0620	0.5992	-1.0755	1.0227	-0.8079	0.8254	-0.8335	0.4776	-0.3525	0.2492
2	0.0184	-0.5351	-0.7367	0.5492	-0.9254	0.7933	-0.6952	0.6993	-0.7226	0.3817	-0.3641	0.2280
2	0.0160	-0.6375	-1.0707	0.6209	-1.0689	0.9955	-0.8288	0.8174	-0.8094	0.4962	-0.3521	0.2325
2	0.0121	-1.0272	-1.0388	0.6373	-1.1139	0.9928	-0.8584	0.8263	-0.8629	0.5249	-0.4063	0.3297
2	0.0125	-1.2551	-0.9943	0.6110	-1.0972	0.9996	-0.8561	0.8083	-0.8603	0.4909	-0.3997	0.3346
4	-0.0244	1.2265	-0.9793	0.6471	-1.0837	0.9872	-0.8532	0.7802	-0.8320	0.4556	-0.3683	0.2483
4	-0.0808	-0.7607	-0.9817	0.6240	-1.1111	0.9680	-0.8611	0.7874	-0.7959	0.4502	-0.3474	0.2762
4	-0.0823	0.2588	-1.0501	0.7018	-1.0930	1.0407	-0.9027	0.8105	-0.8341	0.4753	-0.3894	0.2414
4	-0.0674	0.1682	-1.1385	0.7623	-1.1166	1.1184	-0.9370	0.8253	-0.8647	0.5261	-0.3783	0.2238
4	0.0040	0.0965	-1.1328	0.6955	-1.1069	1.0710	-0.8622	0.8346	-0.8734	0.5253	-0.4330	0.3060
4	-0.0133	0.6918	-1.4711	1.0231	-1.1944	1.3292	-1.1115	0.9769	-0.9857	0.6502	-0.3900	0.1955
4	-0.0344	0.1304	-1.3994	0.9421	-1.1998	1.3189	-1.1002	0.9395	-0.9414	0.6298	-0.4472	0.2787
4	-0.0385	0.2088	-1.2488	0.7967	-1.1397	1.1472	-0.9685	0.9163	-0.9281	0.5915	-0.4438	0.2892
4	-0.0066	1.0163	-1.3352	0.9646	-1.2417	1.2686	-1.0356	0.9818	-0.9124	0.5426	-0.4306	0.2096
4	0.0128	0.0585	-1.4055	0.9103	-1.1902	1.2849	-1.0405	0.9798	-0.9749	0.6345	-0.3817	0.1842

Tablo 7.3. HK için 1. düğüm öznitelik değerleri

Görevler	Öznitelik Değerleri					
2	-0.4179	0.0938	-0.5270	0.1284	7.3189	5.8504
2	-0.4364	0.0727	-0.5353	0.1335	7.3785	5.5022
2	-0.4181	0.1098	-0.4789	0.1439	8.8268	6.7722
2	-0.4312	0.1330	-0.5004	0.1379	8.5613	6.3548
2	-0.4720	0.0835	-0.5252	0.1606	8.2392	6.5570
2	-0.8163	0.1969	-0.5638	0.2779	5.8769	4.8185
2	-0.8359	0.2215	-0.6210	0.3132	6.0458	4.9184
2	-0.3401	0.1035	-0.4852	0.0742	8.4384	6.6522
2	-0.4521	0.0856	-0.5492	0.1364	8.9224	7.0800
2	-0.9752	0.3495	-0.6479	0.3354	4.9693	3.7958
1	-0.4486	0.1618	-0.5296	0.1039	8.4434	6.3203
1	-0.4327	0.1542	-0.5277	0.1192	7.5229	5.9994
1	-0.7361	0.2293	-0.5790	0.2212	5.7262	4.4007
1	-0.7751	0.1900	-0.5553	0.2508	6.5463	5.3590
1	-0.8977	0.2681	-0.5995	0.2606	5.8196	4.9786
1	-0.8404	0.3026	-0.6104	0.2466	5.8112	4.6249
1	-0.2986	0.1514	-0.4754	0.1248	8.8232	6.6695
1	-0.8717	0.2971	-0.5726	0.2281	5.6287	4.2806
1	-0.8804	0.3121	-0.5803	0.2723	5.6217	4.5044
1	-0.8867	0.3091	-0.5981	0.2546	5.8541	4.6224
3	-0.8244	0.2169	-0.5339	0.2320	5.8769	4.4351
3	-0.3933	0.0852	-0.4992	0.0968	8.3703	6.0572
3	-0.3738	0.0407	-0.5106	0.1235	9.4657	7.3107
3	-1.0549	0.4778	-0.6727	0.3017	4.4954	3.6185
3	-0.8946	0.2385	-0.5365	0.3107	6.3892	5.1743
3	-0.9543	0.3498	-0.5911	0.2869	5.8252	4.5432
3	-1.0335	0.3756	-0.6147	0.3431	5.9950	4.9891
3	-0.4333	0.0486	-0.5834	0.0980	6.7165	5.0033
3	-0.3549	0.1193	-0.4819	0.0889	8.3334	6.5021
3	-0.4278	0.1442	-0.5265	0.1660	8.4180	6.2125
4	-0.5556	0.1601	-0.5137	0.1251	8.1831	5.8888
4	-0.4378	0.1269	-0.5352	0.1065	7.2453	5.4309
4	-0.5196	0.0801	-0.5976	0.1041	8.2181	6.4070
4	-0.4914	0.0478	-0.5792	0.0929	6.7852	5.1274
4	-0.6203	0.1747	-0.5804	0.1279	7.2682	5.5052
4	-0.5497	0.0851	-0.5800	0.1083	6.9253	5.2930
4	-0.5845	0.1025	-0.5847	0.1662	7.0882	5.7874
4	-0.5067	0.0858	-0.5321	0.1571	7.0126	5.8571
4	-0.5305	0.1050	-0.4889	0.1539	6.3909	4.9341
4	-0.6219	0.1461	-0.5420	0.1408	6.8059	5.2027

Tablo 7.4. HK için 2. düğüm öznelik değerleri

Görevler	Öznelik Değerleri									
3	-0.6259	0.5239	-0.9274	0.7632	-0.7227	0.6009	-0.7596	0.3321	-0.3297	0.2475
3	-0.6215	0.5122	-0.9703	0.7383	-0.6787	0.6845	-0.7311	0.3241	-0.3517	0.2677
3	-0.6392	0.5494	-0.9294	0.7184	-0.6962	0.6409	-0.6707	0.3298	-0.3494	0.2659
3	-0.7259	0.6181	-1.0164	0.8462	-0.8122	0.7244	-0.7888	0.3975	-0.3981	0.2659
3	-0.7564	0.7039	-1.0060	0.8275	-0.8235	0.7035	-0.7351	0.3963	-0.3409	0.2393
3	-0.9545	0.6277	-1.0857	0.9658	-0.8412	0.8235	-0.8137	0.4565	-0.3517	0.2513
3	-1.0870	0.7417	-1.0856	1.0309	-0.9264	0.8159	-0.7838	0.5273	-0.3653	0.2102
3	-0.5935	0.5211	-0.9026	0.7158	-0.7181	0.6279	-0.6990	0.2822	-0.3433	0.2595
3	-0.6299	0.5043	-0.9432	0.7467	-0.7574	0.6464	-0.7025	0.3712	-0.3575	0.2823
3	-1.3073	1.0286	-1.3804	1.2980	-1.0986	1.0733	-1.0151	0.6488	-0.4767	0.2698
1	-0.6654	0.5691	-0.9539	0.7312	-0.6879	0.6815	-0.7161	0.3688	-0.3643	0.2369
1	-0.6365	0.5868	-1.0110	0.8027	-0.7437	0.7195	-0.7399	0.3217	-0.3607	0.2762
1	-0.9573	0.7245	-1.1380	1.0394	-0.9062	0.8489	-0.8061	0.4447	-0.3877	0.2398
1	-1.0278	0.7196	-1.1389	1.0416	-0.9167	0.9029	-0.8376	0.5412	-0.4468	0.2667
1	-1.1502	0.8274	-1.2493	1.1629	-0.9670	0.9609	-0.8704	0.4766	-0.3920	0.2263
1	-1.0921	0.8112	-1.2404	1.0790	-0.9298	0.9502	-0.8903	0.5569	-0.4082	0.2459
1	-0.4929	0.5099	-0.8600	0.6470	-0.6516	0.5856	-0.6005	0.2394	-0.3074	0.2793
1	-1.0918	0.7728	-1.1631	1.0445	-0.8802	0.8674	-0.8423	0.4702	-0.3497	0.2390
1	-1.1174	0.8367	-1.2367	1.1383	-0.9609	0.9266	-0.8467	0.4967	-0.3927	0.2675
1	-1.1284	0.8002	-1.2090	1.0829	-0.9152	0.9593	-0.9038	0.5724	-0.4388	0.2497
4	-1.1516	0.7591	-1.1156	1.0274	-0.9017	0.8679	-0.8379	0.5280	-0.3788	0.2636
4	-0.5053	0.4597	-0.8486	0.6254	-0.6446	0.5714	-0.6581	0.2697	-0.3614	0.2474
4	-0.6277	0.4802	-0.8766	0.6947	-0.7025	0.5901	-0.6625	0.2776	-0.3017	0.2626
4	-1.2895	1.0406	-1.4108	1.3232	-1.1078	1.1357	-1.0531	0.6359	-0.4595	0.2590
4	-1.1044	0.8652	-1.2820	1.1675	-1.0435	1.0060	-0.8959	0.5286	-0.4401	0.2833
4	-1.1661	0.8660	-1.2709	1.2034	-0.9998	0.9244	-0.8598	0.5113	-0.3482	0.2018
4	-1.2046	0.9285	-1.2822	1.1973	-1.0575	1.0002	-0.9354	0.5828	-0.4335	0.2722
4	-1.2533	1.0042	-1.4029	1.3515	-1.1947	1.0714	-0.9685	0.6130	-0.3852	0.2361
4	-0.6318	0.5317	-0.9580	0.7477	-0.7309	0.6901	-0.7253	0.3606	-0.3703	0.3036
4	-0.6764	0.6159	-0.9488	0.7549	-0.7760	0.6954	-0.7267	0.3402	-0.3866	0.2757

Tablo 7.5. OA için 1. düğüm öznitelik değerleri

Görevler	Öznitelik Değerleri							
1	6.3515	5.6034	-0.5958	-0.3975	-0.1392	0.2131	0.1435	-0.1599
1	5.8322	5.0643	-0.5906	-0.3674	-0.1858	0.1048	0.2810	-0.0919
1	6.6353	5.7216	-1.0115	-0.0196	-0.0586	0.1786	0.0305	-0.0590
1	6.2149	5.0141	-1.1302	0.0249	0.0381	0.1050	0.1178	-0.0992
1	6.6238	5.3455	-1.0794	-0.0042	-0.0529	0.2664	0.0260	-0.0916
1	5.5903	4.3235	-1.0959	0.0044	-0.0025	0.1776	0.0146	-0.0535
1	6.7092	5.2034	-1.1260	-0.0055	0.0348	0.2221	-0.0005	-0.0735
1	6.3277	5.3993	-1.2169	0.0807	0.0697	0.1882	0.0180	-0.1149
1	6.0540	5.4612	-0.6919	-0.4437	-0.0515	0.2435	0.2126	-0.1935
1	5.7097	4.1438	-0.5124	-0.5198	-0.2442	0.3149	0.1980	-0.1208
2	6.3600	5.4159	-1.1059	0.0333	0.0078	0.1076	0.0926	-0.0747
2	7.4163	5.6223	-1.0982	-0.0312	0.0202	0.2530	-0.0156	-0.0929
2	7.1881	5.3152	-1.1506	0.0588	-0.0111	0.2143	0.0209	-0.0801
2	6.3647	5.5498	-0.9070	-0.1672	-0.0609	0.2451	0.0175	-0.0748
2	6.3937	5.8974	-0.5808	-0.4564	-0.2413	0.3588	0.2205	-0.2101
2	8.3661	7.6680	-0.6668	-0.3958	-0.2006	0.2637	0.2117	-0.1461
2	6.8898	6.0127	-0.6629	-0.3500	-0.1511	0.2670	0.0233	-0.0371
2	5.9210	4.7707	-0.3160	-0.3165	-0.4894	0.1224	0.1774	0.0213
2	9.8982	8.0027	-0.2506	-0.4458	-0.5302	0.0067	0.3668	-0.0125
2	5.8836	4.3898	-0.1500	-0.4008	-0.6162	-0.1775	0.1799	0.2268
3	6.4795	5.1623	-0.6751	-0.4015	-0.1705	0.3068	0.1355	-0.0798
3	7.8413	6.7806	-0.7281	-0.3915	-0.0548	0.2337	0.0457	-0.0127
3	8.1939	8.6588	-0.5898	-0.4900	-0.1889	0.2296	0.2094	-0.0881
3	6.1049	5.1014	-0.5656	-0.3570	-0.2383	0.2209	0.1099	-0.0792
3	6.6472	4.8891	-0.3008	-0.4265	-0.3621	0.0468	0.3279	-0.1391
3	6.8119	5.2775	-0.1526	-0.5052	-0.4738	0.0820	0.2766	-0.1234
3	7.2315	5.8563	-0.4880	-0.4501	-0.3438	0.1954	0.2472	-0.1139
3	6.3897	5.0956	-0.4624	-0.4139	-0.3272	0.2496	0.2631	-0.2284
3	7.9339	7.2929	-0.2209	-0.3997	-0.4097	-0.0351	0.2474	0.0456
3	6.4265	5.1029	-0.3851	-0.4246	-0.3901	0.0115	0.2194	-0.0262
4	8.7407	7.0915	-0.3605	-0.5283	-0.3951	0.1999	0.3062	-0.0877
4	5.3547	4.3585	-0.4606	-0.4442	-0.2512	0.0274	0.4122	-0.1832
4	7.5451	5.9422	-0.4270	-0.3885	-0.3778	0.0814	0.3535	-0.1226
4	7.2469	6.7192	-0.5016	-0.4912	-0.3329	0.3593	0.3487	-0.2955
4	7.2475	5.7867	-0.2124	-0.7809	-0.4026	0.4845	0.1098	-0.0587
4	8.5492	6.4481	-0.2064	-0.6843	-0.2549	0.2571	-0.0193	0.1180
4	6.4625	5.2899	-0.3884	-0.5720	-0.1037	0.2117	-0.0422	0.0539
4	7.8216	6.6112	-0.4577	-0.5260	-0.1366	0.1840	0.0363	0.0677
4	6.5896	4.6723	-0.5531	-0.5277	-0.0107	0.2927	-0.1730	0.0855
4	6.0177	5.5541	-0.4960	-0.6922	-0.1144	0.5049	-0.0832	-0.0075

Tablo 7.6. OA için 3. düğüm öznitelik değerleri

Görevler	Öznitelik Değerleri						
2	-0.7665	-0.1652	-0.1788	0.1484	0.0171	0.0140	2.4549
2	-0.8557	-0.0202	-0.2008	0.0798	0.0611	-0.0047	2.1859
2	-1.0623	0.0706	-0.1486	0.1172	0.0763	0.0325	2.7469
2	-0.9545	0.1131	-0.2580	0.1106	0.0705	0.0198	3.3677
2	-0.9760	-0.0180	-0.1532	0.1754	0.0223	0.0179	3.1344
2	-0.8859	-0.1064	-0.2004	0.2216	0.0195	-0.0106	2.8888
2	-0.8474	-0.1327	-0.1492	0.1690	-0.0055	0.0044	2.8443
2	-0.8098	-0.0604	-0.1911	0.1385	-0.0365	0.0091	2.8848
2	-0.9018	-0.0628	-0.1627	0.1206	0.0511	0.0163	2.5138
2	-0.8225	-0.1116	-0.1737	0.0862	0.0657	0.0160	2.9782
3	-1.0246	0.1007	-0.1047	0.1368	-0.0394	-0.0041	2.8466
3	-1.0421	0.0607	-0.1150	0.1967	-0.0388	-0.0332	3.2495
3	-0.9410	0.0093	-0.1651	0.1199	0.0667	0.0149	2.8763
3	-0.8754	-0.1493	-0.1324	0.2483	-0.0628	0.0138	2.8933
3	-0.9775	-0.0284	-0.1134	0.1466	0.0354	-0.0233	3.0183
3	-0.9540	-0.0583	-0.1218	0.1594	0.0243	0.0066	3.0035
3	-0.8342	-0.0209	-0.2171	0.1378	-0.0248	-0.0020	2.7331
3	-0.6567	-0.2294	-0.1829	0.1341	0.0181	-0.0360	3.8910
3	-0.7182	-0.2556	-0.3193	0.3995	-0.0516	0.0188	3.3402
3	-0.9007	-0.0998	-0.1649	0.2460	-0.0288	-0.0105	2.5098

Program kodları 1: k-EYK için k parametresinin belirlenmesine ait birini dışarıda bırak yöntemi kodları

```
function [AccTr Best_k]=kNNloocv(TrainingSet,TrainingLabel)
%%Açıklama:Bu fonksiyon öklidyan uzaklığına bağlı birini dışarıda bırak
%%(leave-one-out cross validation)
%% için hazırlanmıştır.
%% k parametresi 1-25 arasında aramaktadır. Giriş matrislerinin boyutları
%%aşağıdaki gibi olmalıdır
%% TrainingSet MxN, where M is the number of features and N is the number
%%of training trials
%% TrainingLabel Nx1
%% TestSet MxH, where H is the number of test trials
%% TestLabel Hx1
TrSet=TrainingSet;
TrLbl=TrainingLabel;

TrLngt=max(size(TrSet));
R=randomsayi(1,TrLngt,TrLngt)'; %sınıf 0'dan alınan random veriler
TrSet=TrSet(:,R);
trainlabel=TrLbl(R,1);

for k=1:25
    for i=1:TrLngt
        val(:,1)=TrSet(:,i);
        subtrain=TrSet;
        subtrain(:,i)=[];
        subtrlabel=trainlabel;
        subtrlabel(i)=[];

class_tr(i)=knnclassify(val',subtrain',subtrlabel,k,'euclidean','nearest'
);
        end
        cp_tr=classperf(trainlabel,class_tr);
        ca(k)=100*cp_tr.CorrectRate;
    end

[AccTr Best_k]=max(ca);
```

Program kodları 2: Program 1'in çağırdığı randomsayi fonksiyonu kodları

```
function r=randomsayi(a,b,c)
%Random tam sayı üretici
%axb boyutlu 1'den c ye kadar b tane random tam sayılar üretir
c=c-1;
N=b;
r=round(c*(rand(a,1)))+1;
while length(r)<N
    % r=unique([r round(c*(rand(a,1)))+1]); %küçükten büyüğe çıkış verir
    r=myunique([r round(c*(rand(a,1)))+1]); %karışık çıkış verir
end
r=r';
```

Program kodları 3: randomsayi fonksiyonunun çağırdığı myunique fonksiyonu kodları

```

function [a ndx h]=myunique(a,mode)
% bu fonksiyon bir dizi içerisinde bir ya da birkaç kez tekrar etmiş
% sayılardan sadece birini dizide tutar ve sıralama yapmadan verir.
% Örnek:
% >> a=[9 3 6 2 7 1 2 1 1 1 9 9 3 3];
% >> myunique(a)
% ans =
%
%      9      3      6      2      7      1
% >> myunique(a,'last')
% ans =
%
%      6      7      2      1      9      3

if nargin==1
    mode='first';
end

[r c]=size(a); u=max(r,c);
[s si]=sort(a);
ds = false(r,c);
v=1:(u+1);
esit=diff(s)==0;

if strcmpi(mode,'last')
    ds(1:end-1) = esit;
    v=v(not([false;ds(:)]));
    h=diff(v);
else
    ds(2:end) = esit;
    v=v(not([ds(:);false]));
    h=diff(v);
end

si(ds)=[];
[ndx ndxi]=sort(si);
h=h(ndxi);
a=a(ndx);

```

Program Kodları 4: DVM için sigma parametresinin belirlenmesine ait birini dışarıda bırak yöntemi kodları

```

function [AccTr Best_si]=SVMloocv(TrainingSet,TrainingLabel)
%%Açıklama:Bu fonksiyon RBF kerneline bağlı DVM için en iyi sigma
%%parametresini aramak için kullanılır.
%% TrainingSet MxN, where M is the number of features and N is the number
%% of training trials
%% TrainingLabel Nx1
%% TestSet MxH, where H is the number of test trials
%% TestLabel Hx1
TrSet=TrainingSet;
TrLbl=TrainingLabel;

TrLngt=max(size(TrSet));
R=randomsayi(1,TrLngt,TrLngt)'; %sınıf 0'dan alınan random veriler
TrSet=TrSet(:,R);

```

```

trainlabel=TrLbl(R,1);

k=1;
siVal=0.1:0.2:1.5;
for si=0.1:0.2:1.5
    for i=1:TrLngt
        val(:,1)=TrSet(:,i);
        subtrain=TrSet;
        subtrain(:,i)=[];
        subtrlabel=trainlabel;
        subtrlabel(i)=[];

        svmStruct = svmtrain(subtrain',subtrlabel','Kernel_Function','rbf',
'RBF_Sigma', si);
        class_tr(i)= svmclassify(svmStruct,val','showplot',false);
        end
%     cp_tr=classperf(class_tr,trainlabel);
%     ca(k)=100*cp_tr.CorrectRate;
%Hata verirse
        cp_tr=myclassperf(class_tr,trainlabel);
        ca(k)=100*cp_tr;
        k=k+1;
    end
    [AccTr_Best_k]=max(ca);
    Best_si=siVal(Best_k);

```

Program Kodları 5: Dalgacık dönüşümü katsayılarının hesaplanması için kullanılan kod

```

function [FE szT1 szT2 szT3
szT4]=wcoefs(K,tm,DSR,scale,wname,Data,Datalabel)

Training=Data;
TrainingLabel=Datalabel;

fs=256; %OA için 256, MM ve HK için 2048 olarak girilmeli

data_tm=1:tm*fs; %data uzunluğu
T1=Training(TrainingLabel==1,data_tm,:);
T2=Training(TrainingLabel==2,data_tm,:);
T3=Training(TrainingLabel==3,data_tm,:);
T4=Training(TrainingLabel==4,data_tm,:);

szT1=size(T1,1);
szT2=size(T2,1);
szT3=size(T3,1);
szT4=size(T4,1);

aa=[1 2 4 8];
SSR=aa(DSR);
for i=1:size(T1,1)
    S1=T1(i,:,K);
    S1=decimate(S1,SSR);
    Wcoef1=cwt(S1,scale,wname);
    T1f1(i)=mean(abs(Wcoef1(:)));
    T1f2(i)=std(abs(Wcoef1(:)));

```

```

S2=T2(i, :, K);
S2=decimate(S2, SSR);
Wcoef2=cwt(S2, scale, wname);
T2f1(i)=mean(abs(Wcoef2(:)));
T2f2(i)=std(abs(Wcoef2(:)));

S3=T3(i, :, K);
S3=decimate(S3, SSR);
Wcoef3=cwt(S3, scale, wname);
T3f1(i)=mean(abs(Wcoef3(:)));
T3f2(i)=std(abs(Wcoef3(:)));

S4=T4(i, :, K);
S4=decimate(S4, SSR);
Wcoef4=cwt(S4, scale, wname);
T4f1(i)=mean(abs(Wcoef4(:)));
T4f2(i)=std(abs(Wcoef4(:)));
end

T1Fs=[T1f1;T1f2];
T2Fs=[T2f1;T2f2];
T3Fs=[T3f1;T3f2];
T4Fs=[T4f1;T4f2];

FE=[ T1Fs T2Fs T3Fs T4Fs];

```

Program kodları 6: AR katsayılarını hesaplamak için kullanılan kod

```

function [FE szT1 szT2 szT3 szT4]=ARcoefs(K, tm, DSR, NmC, Data, Datalabel)

Training=Data;
TrainingLabel=Datalabel;

fs=256; %OA için 256, MM ve HK için 2048 olarak girilmeli

data_tm=1:tm*fs; %data uzunluğu
T1=Training(TrainingLabel==1, data_tm, :);
T2=Training(TrainingLabel==2, data_tm, :);
T3=Training(TrainingLabel==3, data_tm, :);
T4=Training(TrainingLabel==4, data_tm, :);

szT1=size(T1, 1);
szT2=size(T2, 1);
szT3=size(T3, 1);
szT4=size(T4, 1);

aa=[1 2 4 8];
SSR=aa(DSR);
for i=1:size(T1, 1)
    S1=T1(i, :, K);
    S1=decimate(S1, SSR);
    eq1=ar(S1, NmC);
    getCoefs1=get(eq1);
    ARcoefs1(:, i)=getCoefs1.a(2:end);

```

```

S2=T2(i, :, K);
S2=decimate(S2, SSR);
eq2=ar(S2, NmC);
getCoefs2=get(eq2);
ARcoefs2(:, i)=getCoefs2.a(2:end);

S3=T3(i, :, K);
S3=decimate(S3, SSR);
eq3=ar(S3, NmC);
getCoefs3=get(eq3);
ARcoefs3(:, i)=getCoefs3.a(2:end);

S4=T4(i, :, K);
S4=decimate(S4, SSR);
eq4=ar(S4, NmC);
getCoefs4=get(eq4);
ARcoefs4(:, i)=getCoefs4.a(2:end);
end

FE=[ ARcoefs1 ARcoefs2 ARcoefs3 ARcoefs4];

```

Program kodları 7: Çarpıklık ve ortalama türev özniteliklerinin hesaplandığı kod

```

function [FE szT1 szT2 szT3 szT4]=features(K, tm, DSR, Data, Datalabel)

Training=Data;
TrainingLabel=Datalabel;

fs=256; %OA için 256, MM ve HK için 2048 olarak girilmeli

data_tm=1:tm*fs; %data uzunluğu
T1=Training(TrainingLabel==1, data_tm, :);
T2=Training(TrainingLabel==2, data_tm, :);
T3=Training(TrainingLabel==3, data_tm, :);
T4=Training(TrainingLabel==4, data_tm, :);
T=[T1;T2;T3;T4];
szT1=size(T1, 1);
szT2=size(T2, 1);
szT3=size(T3, 1);
szT4=size(T4, 1);

aa=[1 2 4 8];
SSR=aa(DSR);
for i=1:size(T, 1)
    S1=T(i, :, K);
    y=decimate(S1, SSR);
    %features
    yTR1(i)=var(diff(y));
    yTR2(i)=mean(diff(y));
    nozero=0;
    yy=diff(y);
    for j=1:length(yy)-1

```

```

        sgn(j)=sign(yy(j)/yy(j+1));
        if sgn(j)<0
            nozero=nozero+1;
        end
    end
    yTR3(i)=nozero;
    yTR4(i)=kurtosis(y);
    yTR5(i)=skewness(y);
    yTR6(i)=svd(y);
    yTR7(i)=var(y);
    yTR8(i)=var(diff(diff(y)));
end
FE=[yTR2;yTR5];

```

Program kodları 8: MM için oluşturulan ağaç yapısının kodu

```

clear
clc
close all
load MM_Training.mat
load MM_Traininglabel.mat
load MM_Test2.mat
load MM_Testlabel2.mat
TestData=MM_Test2;

DSR=4;
aa=[1 2 4 8];
SSR=aa(DSR);
fs=2048; %OA için 256, MM ve HK için 2048 olarak girilmeli

scale1=16:52;
K1=10;
tm1=1.75;
wname='mor1';

[Train1 szT1_TR szT2_TR szT3_TR
szT4_TR]=wcoefs_MM(K1,tm1,DSR,scale1,wname,MM_Training,MM_Traininglabel);

TR_label1=[13*ones(1,szT1_TR) 13*ones(1,szT1_TR) 24*ones(1,szT4_TR)
24*ones(1,szT4_TR)];

K2=11;
tm2=5.75;
K22=8;
tm22=1.75;
NmC=8;
[Train21 szT1_TR szT2_TR szT3_TR
szT4_TR]=ARcoefs_MM(K2,tm2,DSR,NmC,MM_Training,MM_Traininglabel);
[Train22 szT1_TR szT2_TR szT3_TR
szT4_TR]=features_MM2(K22,tm22,DSR,MM_Training,MM_Traininglabel);
Train2=[Train21;Train22];
TR_label2=[1*ones(1,szT1_TR) 3*ones(1,szT3_TR)];

K3=10;
tm3=1.75;
K32=12;
tm32=5.75;
NmC32=10;

```

```

[Train31 szT1_TR szT2_TR szT3_TR
szT4_TR]=features_MM(K3,tm3,DSR,MM_Training,MM_Traininglabel);
[Train32 szT1_TR szT2_TR szT3_TR
szT4_TR]=ARcoefs_MM2(K32,tm32,DSR,NmC32,MM_Training,MM_Traininglabel);
Train3=[Train31;Train32];
TR_label3=[2*ones(1,szT1_TR) 4*ones(1,szT4_TR)];

%%%%%%%%%%%%%%
%Test aşaması
%%%%%%%%%%%%%%
for i=1:size(TestData,1)

    %Step1

    %FE1
    Sa=TestData(i,1:tm1*fs,K1);
    S1=decimate(nrmlztn(Sa),SSR);
    Wcoef1=cwt(S1,scale1,wname);
    Test1=[mean(abs(Wcoef1(:))) std(abs(Wcoef1(:)))];

    %Classification1
    svmStruct =
    svmtrain(Train1',TR_label1,'Kernel_Function','rbf','RBF_Sigma',.6,'showplot',false);
    CalculatedLabel(i) = svmclassify(svmStruct,Test1,'showplot',false);

    %FE2
    if CalculatedLabel(i)==13
        Sb=TestData(i,1:tm2*fs,K2);
        S2=decimate(nrmlztn(Sb),SSR);

        Sb2=TestData(i,1:tm22*fs,K22);
        S22=decimate(nrmlztn(Sb2),SSR);

        eq1=ar(S2,NmC);
        getCoefs1=get(eq1);
        Test2(:,1)=[getCoefs1.a(2:end) mean(diff(S22)) skewness(S22)];

    %Classification2
    classLDA1=classify(Test2',Train2',TR_label2,'linear');
    CalculatedLabel(i)=classLDA1;
    else
        %FE3
        Sc=TestData(i,1:tm3*fs,K3);
        S3=decimate(nrmlztn(Sc),SSR);

        Sc2=TestData(i,1:tm32*fs,K32);
        S32=decimate(nrmlztn(Sc2),SSR);
        eq3=ar(S32,NmC32);
        getCoefs3=get(eq3);

        Test3=[mean(diff(S3)) skewness(S3) getCoefs3.a(2:end)];
    %Classification3

    classkNN3 = knnclassify(Test3,Train3',TR_label3,6,'euclidean','nearest');
    CalculatedLabel(i)=classkNN3;

end

```

```
end
CR=classperf(MM_Testlabel2,CalculatedLabel);
CA=CR.CorrectRate*100

m=0;
for i=1:size(TestData,1)
    if CalculatedLabel(i)~=MM_Testlabel2(i)
        m=m+1;
        Error_ndx(m)=i;
    end
    CCA(i)=100*(i-m)/i;
end
plot(1:size(TestData,1),CCA)
AAA=CR.CountingMatrix
```


ÖZGEÇMİŞ

13.04.1982 tarihinde Trabzon'da doğdu. Liseyi, Trabzon Affan Kitapçioğlu Lisesi'nde tamamladı. 2000 yılında Karadeniz Teknik Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü'nü kazandı. Bu öğrenimi sırasında KTÜ İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü'nde Yandal eğitimini ayrıca tamamladı ve yine öğrenimi süresince, 2002-2005 yılları arasında, KTÜ Bilimsel Araştırma Projeleri Birimi'nde kısmi zamanlı öğrenci statüsünde çalıştı. 2005 yılı güz döneminde Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. Aynı yıl, Elektrik-Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. 2006-2007 Eğitim Öğretim Dönemi'nde Erasmus programı ile yüksek lisans çalışması yapmak üzere Viyana Teknik Üniversitesi'ne gitti. Yabancı dil olarak İngilizce ve Almanca bilmektedir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

1. Aydemir, O. ve Kayikcioglu, T., Comparing Common Machine Learning Classifiers in Low-Dimensional Feature Vectors for Brain Computer Interface Applications, Inter. Journal of Innovative Computing Information and Control, 9, 3 (2013) 1145-1157.
2. Aydemir, O., Pourzare, S. ve Kayikcioglu, T., Classifying Various EMG and EOG Artifacts in EEG Signals, Electrical Review (Przeład Elektrotechniczny), 88, 11a (2012) 218-222.
3. Aydemir, O., Letter to the Editor: regarding "Performance evaluation of multiple classifications of the ultrasonic supraspinatus images by using ML, RBFNN and SVM classifiers", Expert Systems with Applications, 39,12 (2012) 11321.
4. Aydemir, O. ve Kayikcioglu, T., Wavelet Transform Based Classification of Invasive Brain Computer Interface Data, Radioengineering, 20,1 (2011) sy: 31-38.
5. Kayikcioglu, T. ve Aydemir, O., A Polynomial Fitting and k -NN Based Approach for Improving Classification of Motor Imagery BCI Data, Pattern Recognition Letters, 31,11 (2010) 1207-1215.

Diğer dergilerde yayınlanan makaleler

6. Aydemir, O. ve Kayıkcıoğlu, T., Comparative Performance Assessment of Classifiers in Low-Dimensional Feature Space Which are Commonly Used in BCI Applications, Elektrorevue, 2,4 (2011) 58-63.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

7. Aydemir, O. ve Kayıkcıoğlu, T., Electroencephalogram Based Human-Computer Interfaces, 6th International Computer & Instructional Technologies Symposium, Ekim 2012, Gaziantep.
8. Aydemir, O. ve Kayıkcıoğlu, T., Classification of Various Face Movement Artifacts in EEG Signals, 35th International Conference on Telecommunications and Signal Processing (TSP-2012), Temmuz 2012, Prag.
9. Şahin Pourzare, Aydemir, Ö. ve Kayıkcıoğlu, T., İnsan-Makina Etkileşimi için Yüz Hareketleri Yapıldığı Sırada Kaydedilen EEG İşaretlerinin Sınıflandırılması, 20. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 2012, Muğla.
10. Aydemir, O., Öztürk, M., Kayıkcıoğlu, T., Performance Evaluation Of Five Classification Algorithms In Low-Dimensional Feature Vectors Extracted From EEG Signals, 34th International Conference on Telecommunications and Signal Processing (TSP-2011), Ağustos 2011, Budapeşte.
11. Aydemir, Ö. ve Kayıkcıoğlu, T., Sağ/Sol El Hareketi Düşünülerek Kaydedilmiş EEG İşaretlerinin Fourier Dönüşümü Esaslı Öznitelikler Kullanarak Sınıflandırılması, 19. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 2011, Antalya.
12. Aydemir, O. ve Kayıkcıoğlu, T., Classifying ECoG Based Mental Tasks Using Wavelet Transform Features, 33rd International Conference on Telecommunications and Signal Processing (TSP-2010), Ağustos 2010, Viyana.
13. Aydemir, Ö. ve Kayıkcıoğlu, T., Dalgacık Dönüşümü Öznitelikleri Kullanarak Motor İmgeleme ECoG İşaretlerinin Sınıflandırılması,, 18. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 2010, Diyarbakır.
14. Aydemir, O., Öztürk, M., Okumuş, H.İ., EEG Based Robotic Arm Position Control, International Symposium on INnovations in Intelligent SysTems and Applications, , June 29-July 1 2009, Trabzon.

15. Aydemir, Ö. ve Kayıkçıođlu, T., İkinci Dereceden Polinom Uydurma Algoritması Kullanarak Ham EEG İşaretlerinden Öznitelik Çıkarma,, 17. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, Nisan 2009, Antalya.
16. Yazgan, A., Tuđcu, E., Aydemir, O., Şimşek, C., OFDM Sisteminin AWGN Kanallardaki Performansının İncelenmesi, Akademik Bilişim 2009, Şubat 2009, Şanlıurfa.
17. Aydemir, Ö. ve Kayıkçıođlu, T., EEG Tabanlı Beyin Bilgisayar Arayüzleri, Akademik Bilişim 2009, Şubat 2009, Şanlıurfa.
18. Aydemir, Ö. ve Kayıkçıođlu, T., Beyin Bilgisayar Arayüzü Uygulamalarına Yönelik EEG İşaretlerinin Sınıflandırılması için Öznitelik Çıkarma,, 30. Yıl Sempozyumu, Ekim 2008, Adana.
19. Hacıođlu, G., Aydemir, O., Öztürk, M., Sayısal Modülasyon Yöntemlerinin Spektral Etkinlikleri Bakımından İncelenmesi, URSI-Türkiye 2006, 3. Bilimsel kongresi ve 4. Ulusal genel kurul toplantısı, Eylül 2006, Ankara..
20. Aydemir, O., Öztürk, M., Hacıođlu, G., İşlevsel Manyetik Rezonans Görüntüleme ile Beyin Görüntülerinin İncelenmesi, URSI-Türkiye 2006, 3. Bilimsel kongresi ve 4. Ulusal genel kurul toplantısı, Eylül 2006, Ankara.

Ödüller

- En iyi makale ödülü: 33rd International Conference of TSP 2010, Viyana, 2010.
- TUBİTAK yayın teşvik ödülü, 2010.
- KTÜ yayın teşvik ödülü, 2011 ve 2012.
- Teknoloji Liderleri Lisansüstü Bursu, 2011.