

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK- ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

**BEYİN BİLGİSAYAR ARAYÜZÜ İŞARETLERİNİN FARKLI ZAMAN
DİLİMLERİNDEN ÇIKARILMIŞ ÖZNİTELİKLERLE SINIFLANDIRMA
DOĞRULUĞUNUN ARTTIRILMASI**

YÜKSEK LİSANS TEZİ

Elektrik- Elektronik Müh. Ebru YAVUZ

Haziran 2017
TRABZON



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :

Trabzon

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI
Ebru YAVUZ Tarafından Hazırlanan**

**BEYİN BİLGİSAYAR ARAYÜZÜ İŞARETLERİNİN FARKLI ZAMAN DİLİMLERİNDEN
ÇIKARILMIŞ ÖZNİTELİKLERLE SINIFLANDIRMA DOĞRULUĞUNUN
ARTTIRILMASI**

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 09 / 05 / 2017 gün ve 1701 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Ali GANGAL

Üye : Yrd. Doç. Dr. Önder AYDEMİR

Üye : Yrd. Doç. Dr. Rifat BENVENİSTE



Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Son yıllarda beyin bilgisayar arayüzü sistemleri teknolojisi hızla gelişmektedir. Gelişen bu teknolojiyle bu sistemlerin temelini oluşturan elektroensefalografi ve elektrokortikografi işaretlerine uygulanan ön işlem, öznelik ve sınıflandırma yöntemleri önemlidir. Bu çalışmada bu yöntemlere ek olarak elektroensefalografi ve elektrokortikografi işaretlerinin denemelerinin tüm örneklerini kullanmak yerine etkin zaman dilimleri seçilerek daha hızlı ve yüksek performanslı beyin bilgisayar arayüzü sisteminin oluşturulması amaçlanmıştır.

Bu çalışmanın amacına ulaşması için engin bilgi ve yenilikçi düşünceleriyle bana yol gösteren ve yüksek lisans öğrenimim boyunca gerek bilimsel çalışmalarımda gerekse diğer konularda beni destekleyerek yardımcı olan tez danışmanım Yrd. Doç. Dr. Önder AYDEMİR'e ilgi, destek ve tecrübelerini esirgemediğinden dolayı teşekkürlerimi saygı ve minnetle sunarım.

Çalışmalarım süresince sabır, destek ve sevgileriyle yanımda olup hayatım boyunca bana güç veren anneme ve babama ve Gökhan Galip ERGÜN'e şükranlarımı sunarım.

Ebru YAVUZ

Trabzon 2017

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduđum “Beyin Bilgisayar Arayüzü İşaretlerinin Farklı Zaman Dilimlerinden Çıkarılmış Özniteliklerle Sınıflandırma Doğruluđunun Arttırılması” başlıklı bu çalışmayı baştan sona kadar danışmanım Yrd. Doç. Dr. Önder AYDEMİR’ in sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdıđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 02/06/2017

Ebru YAVUZ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XI
SEMBOLLER DİZİNİ	XII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Beynin Temel Yapısı.....	2
1.3. Sinir Sisteminin Genel Yapısı ve Biyoelektrik Potansiyeller	4
1.4. Beyin Görüntüleme Teknikleri.....	6
1.4.1. Elektroensefalografi	6
1.4.2. Elektrokortikografi	7
1.4.1.1. Elektroensefalografi ve Elektrokortikografi İşaretlerinin Genel Özellikleri.....	8
1.4.1.2. Elektroensefalografi ve Elektrokortikografi Dalga Şekilleri.....	8
1.5. Beyin Bilgisayar Arayüzü	9
1.6. Literatür Araştırması	11
2. YAPILAN ÇALIŞMALAR	18
2.1. Malzeme	18
2.1.1. Veri Kümesi 1	18
2.1.2. Veri Kümesi 2	19
2.1.3. Veri Kümesi 3	19
2.2. Yöntem	21
2.2.1. Hareketli Ortalama Filtresi ile Önişleme	21
2.2.2. Öznitelik Çıkarma Yöntemleri	21
2.2.2.1. Dalgacık Dönüşümü	22
2.2.2.2. Ortalama Türev.....	24
2.2.2.3. Çarpıklık.....	24

2.2.2.4.	Basıklık.....	24
2.2.2.5.	Varyans.....	25
2.2.2.6.	Özbağlanım Metodu	25
2.2.3.	Sınıflandırma Yöntemleri	25
2.2.3.1.	k-En Yakın Komşuluk Yöntemi.....	27
2.2.3.2.	Destek Vektör Makineleri	28
2.2.3.3.	Doğrusal Ayırma Ayırıcı	30
2.2.3.4.	Kısmi En Küçük Kareler Regresyonu	30
2.2.4.	Karar Ağaç Yapısı	31
2.3.	Önerilen Yöntem	32
3.	BULGULAR	34
3.1.	Veri Kümesi 1 ile Elde Edilen Bulgular.....	34
3.2.	Veri Kümesi 2 ile Elde Edilen Bulgular.....	38
3.3.	Veri Kümesi 3 ile Elde Edilen Bulgular.....	43
3.3.	A Kişisi İçin Yapılan Hesaplamalar ve Bulgular	44
3.3.	B Kişisi İçin Yapılan Hesaplamalar ve Bulgular.....	46
3.3.	C Kişisi İçin Yapılan Hesaplamalar ve Bulgular.....	48
4.	SONUÇLAR VE TARTIŞMA.....	51
5.	ÖNERİLER	55
6.	KAYNAKLAR.....	57

ÖZGEÇMİŞ

Yüksek Lisans Tezi

ÖZET

BEYİN BİLGİSAYAR ARAYÜZÜ İŞARETLERİNİN FARKLI ZAMAN DİLİMLERİNDEN ÇIKARILMIŞ ÖZNETELİKLERLE SINIFLANDIRMA DOĞRULUĞUNUN ARTTIRILMASI

Ebru YAVUZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Elektrik- Elektronik Mühendisliği Anabilim Dalı
Danışman: Yrd. Doç. Önder AYDEMİR
2017, 64 Sayfa

Son yıllarda biyomedikal mühendisliği alanında yapılan çalışmalar, sağlıklı bir insan beyninin, kişinin hiç bir kas hareketi yapmadan sadece düşünerek çeşitli elektronik cihazları kontrol edebileceğini ve felçli hastaların hayatlarını kolaylaştıracak olan beyin bilgisayar arayüzü (BBA) sistemlerinin oluşturulabileceğini göstermiştir.

Bu tez çalışmasında, amyotrofik lateral skleroz gibi kas sistemlerini kullanamayan hastaların hayatlarını kolaylaştırmak için BBA sistemlerinin temelini oluşturan elektroensefalografi (EEG) ve elektrokortikografi (ECoG) işaretleriyle çalışılarak, bu işaretlerin farklı zaman dilimlerinden (epok) çıkarılan öznitelikler ile sınıflandırma doğruluğunun artırılması amaçlanmıştır. Daha hızlı ve doğru BBA sistemlerinin oluşturulmasının amaçlandığı bu tez çalışmasında, BCI Competition 2003 Data Set Ia veri kümesi (Veri Kümesi 1), BCI Competition 2005 Dataset I veri kümesi (Veri Kümesi 2) ve Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü bünyesindeki EEG Araştırma Laboratuvarında gerekli etik izinler alınarak 3 sağlıklı bireyden (A, B, C kişileri) kaydedilmiş EEG veri kümesi (Veri Kümesi 3) kullanılmıştır. Elde edilen sonuçlar literatürde yapılan çalışmalar ile karşılaştırılarak tezde kullanılan yöntemin performansı değerlendirilmiştir. Bu sonuçlara göre önerilen yöntem ile Veri Kümesi 1 ve Veri Kümesi 2 ile sırasıyla %99.31 ve %99.00 sınıflandırma doğrulukları (SD) hesaplanarak literatürdeki en iyi sonuçlara ulaşılmıştır. Veri Kümesi 3 ile ise A, B ve C kişisi için sırasıyla %82.24, %62.50, %57.23 SD hesaplanarak literatürdeki çalışmalara göre B ve C kişisi ile %4.6 ve %1.31 oranında SD artırılırken A kişisi için SD oranı değişmemiştir.

Anahtar Kelimeler: Elektroensefalografi, Elektrokortikografi, Beyin-Bilgisayar Arayüzü, Etkin Zaman Dilimi, Öznitelik Çıkarma, Sınıflandırma

Master Thesis

SUMMARY

BRAIN COMPUTER INTERFACE SIGNALS INCREASED ACCURACY WITH
CLASSIFICATION OF DIFFERENT TIME SEGMENTS

Ebru YAVUZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Electrical and Electronics Engineering Graduate Program
Supervisor: Yrd. Doç. Dr. Önder AYDEMİR
2017, 64 Pages

Recent studies in biomedical engineering and neurology showed that a healthy human brain can control a variety of electronic devices only by thinking without making any muscle movements, in this way it can be created brain computer interface (BCI) systems that facilitate the lives of paralyzed patients.

In this thesis, in order to facilitate the lives of patients who can not use muscle systems such as amyotrophic lateral sclerosis, electroencephalography (EEG) and electrocorticography (ECoG) signals were used in BCI systems. Then, It aimed to increase the classification accuracy with features to be extracted from different time periods (epochs) of these signals. In this thesis study, the following three data sets are used for the creation of faster and more accurate BCI systems: BCI Competition 2003 Data Set Ia (Data Set 1), BCI Competition 2005 Data Set I (Data Set 2) and EEG data set recorded from 3 healthy individuals taking necessary ethical permissions in the EEG Research Laboratory of the Electrical and Electronics Engineering Department of the Karadeniz Technical University (Data Set 3). The results obtained are compared with the literature studies, then performance of this method used in the thesis was evaluated. According to these results, 99.31% and 99.00% classification accuracy (SD) were calculated with Data Set 1 and Data Set 2 which the best results in the literature. For Data Set 3, 82.24%, 62.50%, 57.23% SD were calculated for A, B and C respectively. According to the studies in the literature, SD was increased by 4.6% and 1.31% for B and C subjects, whereas SD did not change for A subject.

Key Words: Electroencephalography, Electrocorticography, Brain-Computer Interface, Effective Time Segment, Feature Extraction, Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. İnsan beyninin genel görüntüsü	3
Şekil 1.2. Sinir hücresi	4
Şekil 1.3. Aksiyon potansiyeli evreleri	6
Şekil 1.4. EEG elektrot sistemi	7
Şekil 1.5. ECoG elektrot sistemi	7
Şekil 1.6. EEG ve ECoG verileri için dört ana beyin dalgası	9
Şekil 1.7. Beyin bilgisayar arayüzü	10
Şekil 2.1. Uluslararası 10–20 sistemine göre Veri Kümesi 1 elektrot pozisyonları	18
Şekil 2.2. Uluslararası 10-20 sistemine göre Veri Kümesi 3 elektrot pozisyonları	20
Şekil 2.3. Morlet dalgacığı	23
Şekil 2.4. Daubechies dalgacığı	23
Şekil 2.5. Sarı sınıflı kareler ve yeşil sınıflı dairelerden oluşan öznitelikler	28
Şekil 2.6. k-EYK yöntemi için veri sınıflandırması	28
Şekil 2.7. DVM için iki sınıflı problem örneğı	29
Şekil 2.8. En küçük kareler yöntemi için grafik	31
Şekil 2.9. Karar ağaç yapısı	32
Şekil 2.10. Etkin epokların seçimi için önerilen yöntem	33
Şekil 3.1. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için etkin epoklarla ve tüm epoklarla hesaplanan SD değerleri	35
Şekil 3.2. Veri Kümesi 1’de k-EYK, DVM ve DAA sınıflandırıcıları için seçilen etkin epoklar	35
Şekil 3.3. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için etkin epoklarla ve tüm epoklarla hesaplanan DU değerleri	36
Şekil 3.4. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için etkin epoklarla ve tüm epoklarla hesaplanan ÖZ değerleri	36
Şekil 3.5. Eğitim ve test verileri için hesaplanan öznitelikler	37
Şekil 3.6. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için etkin epoklarla ve tüm epoklarla hesaplanan SD değerleri	39
Şekil 3.7. Veri Kümesi 2’de k-EYK, DVM ve DAA sınıflandırıcıları için seçilen etkin epoklar	40
Şekil 3.8. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için etkin epoklarla ve tüm epoklarla hesaplanan DU değerleri	41

Şekil 3.9. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için etkin epoklarla ve tüm epoklarla hesaplanan ÖZ değerleri	41
Şekil 3.10. Eğitim ve test verileri için hesaplanan öznelilikler.....	42
Şekil 3.11. A kişisi için karar ağaç yapısı	44
Şekil 3.12. A kişisi için seçilen etkin epoklar	45
Şekil 3.13. B kişisi için karar ağaç yapısı	47
Şekil 3.14. B kişisi için seçilen etkin epoklar	47
Şekil 3.15. C kişisi için karar ağaç yapısı	49
Şekil 3.16. C kişisi için seçilen etkin epoklar	49



TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 2.1. Veri Kümesi 3 için eğitim ve test deneme sayıları	20
Tablo 2.2. Hata Matrisi	26
Tablo 3.1. Veri Kümesi 1 için öznitelik çıkarım süreleri.....	38
Tablo 3.2. Sınıflandırıcılar için hata matrisleri, (a) k-EYK, (b) DVM, (c) DAA	38
Tablo 3.3. Veri Kümesi 2 öznitelik çıkarım süreleri.....	42
Tablo 3.4. Sınıflandırıcılar için hata matrisleri, (a) k-EYK, (b) DVM, (c) DAA	43
Tablo 3.5. A kişinin her bir düğümü için etkin epoklarla hesaplanan SD, DU ve ÖZ..	45
Tablo 3.6. A kişisi için hata matrisi	46
Tablo 3.7. B kişinin her bir düğümü için etkin epoklarla hesaplanan SD, DU ve ÖZ..	48
Tablo 3.8. B kişisi için hata matrisi	48
Tablo 3.9. C kişinin her bir düğümü için etkin epoklarla hesaplanan SD, DU ve ÖZ..	50
Tablo 3.10. C kişisi için hata matrisi	50
Tablo 4.1. Veri Kümesi 1 ile yapılmış çalışmalar.....	52
Tablo 4.2. Veri Kümesi 2 ile yapılmış çalışmalar	52
Tablo 4.3. Veri Kümesi 3 ile A,B,C kişisi için hesaplanan sonuçlar.....	54
Tablo 4.4. Aydemir'in doktora tezi sonuçları	54

SEMBOLLER DİZİNİ

ALS	Amyotrofik lateral skleroz
B	Basıklık
BBA	Beyin bilgisayar arayüzü
BT	Bilgisayarlı tomografi
Ç	Çarpıklık
DAA	Doğrusal ayırım ayırıcı
DD	Dalgacık dönüşümü
DU	Duyarlılık
DVM	Destek vektör makinaları
ECoG	Elektrokortikografi
EEG	Elektroensefalografi
fMRI	Fonksiyonel manyetik rezonans görüntüleme
HMM	Hidden markov modeli
Hz	Hertz
HOF	Hareketli ortalama filtresi
K^+	Potasyum iyonu
k-EYK	k-en yakın komşuluk algoritması
MLP	Çok katmanlı algılayıcı
MRI	Manyetik rezonans görüntüleme
msn	Milisaniye
mV	Milivolt
Na^+	Sodyum iyonu
OUÖ	Ortak uzamsal örüntü
OT	Ortak uzamsal örüntü
ÖB	Özbağlanım
ÖÇS	Öznitelik çıkarım süresi
ÖZ	Özgüllük
PB	Pencere boyutu
PET	Pozitron emisyon tomografi
SD	Sınıflandırma doğruluğu

SDD	Sürekli Dalgacık Dönüşümü
SDDK	Sürekli Dalgacık Dönüşümü
$SDDK_0$	Sürekli Dalgacık Dönüşümü katsayılarının ortalaması
$SDDK_s$	Sürekli Dalgacık Dönüşümü katsayılarının standart sapması
SNR	Sinyal/gürültü oranı
SPECT	Tek foton emisyon bilgisayarlı tomografi
TMS	Trankskraniyal manyetik uyarım
V	Varyans
μV	Mikro volt



1. GENEL BİLGİLER

1.1. Giriş

Son yıllarda bilim dünyasında, evrende en karmaşık ve gelişmiş biyolojik organizasyon olarak bilinen beyin ile ilgili yapılan çalışmalar hızlı bir biçimde artmaktadır [1]. Beyin, tüm vücut işlevlerini kontrol eden bir organdır ve insan vücudunun ana kontrol merkezi konumundadır. Bu merkezi organ, duyu organlarından ve vücudun diğer bölgelerinden gelen bilgiyi değerlendirir, işler ve tekrar vücudun ilgili yerlerine geri gönderir. Bilginin iletimi, merkezi sinir sistemi sayesinde gerçekleşmektedir [2], [3]. Merkezi sinir sisteminin ana yapısını nöron olarak adlandırılan sinir hücreleri oluşturmaktadır. Merkezi sinir sistemindeki milyonlarca sinir hücresinin birbiriyle etkileşimi sayesinde elektriksel devrelere benzer yollarla bilgi akışı sağlanır [4]. Bu bilgi akışı sırasında beyin aktivitelerini ölçmek için saç derisinin belirli bölgelerine yerleştirilmiş küçük metal elektrot yardımıyla elektroensefalografi (EEG) verileri, beyin yüzeyine yerleştirilen elektrot ızgarası yardımıyla elektrokortikografi (ECoG) verileri kaydedilir. Belirli frekans ve genlik değerlerine sahip olan bu veriler birçok hastalık teşhisinde kullanılmaktadır. Ayrıca, diğer beyin görüntüleme tekniklerine göre uygulamasının daha hızlı olması ve verilerin yüksek kaliteli olması bakımından bu teknikler beyin bilgisayar arayüzü (BBA) sistemlerinin temelini oluşturmaktadır [5].

Son yıllarda uygulama sistemleri ile oldukça geniş bir araştırma alanı oluşturan farklı bir ifade ile beyin aktivitelerini okumaya çalışan BBA sistemleri hızla gelişmektedir. Bu sistemler, çeşitli nöroprotezleri, elektromekanik bir kolu veya bir bilgisayar tarafından kontrol edilebilecek hemen hemen her şeyi potansiyel olarak kontrol edilebilir [5], [6]. Bilişsel işlevlerinde sıkıntı olmayan sadece motor nöronları bozuk olan hastaların hayatlarını kolaylaştıran bu sistemler sinyal toplama, ön işleme, öznitelik çıkarımı, sınıflandırma ve kontrol çıktısı aşamalarından oluşmaktadır. Hastalara daha hızlı ve yüksek doğrulukta yanıt vermesi bakımından yüksek performanslı BBA sistemleri için EEG ve ECoG verilerine uygulanan ön işleme, öznitelik çıkarma ve sınıflandırma yöntemleri önemlidir. Bu tez çalışmasında ön işleme, öznitelik çıkarma ve sınıflandırma yöntemlerine ek olarak EEG ve ECoG verilerinin denemelerinin tüm örneklerini kullanmanın yerine bu veriler belirlenen zaman dilimlerine (epok) ayrılarak yüksek başarımlı BBA sistemi için bir

yöntem önerilmiştir. Bu yöntem ile sınıflandırma doğruluğu arttırılarak öznelik çıkarım süresinin azaltılması amaçlanmıştır.

Bu tez çalışmasında önerilen yöntem BCI Competition 2003 Dataset Ia Veri Kümesine (Veri Kümesi 1), BCI Competition 2005 Dataset I Veri Kümesine (Veri Kümesi 2) ve Karadeniz Teknik Üniversitesi'nde Önder Aydemir tarafından kaydedilen İmleç Hareketi Hayaline Dayalı Elektroensefalografi Veri Kümesine (Veri Kümesi 3) uygulanmıştır. Önerilen yöntem uygulanırken Veri Kümesi 1 için 14 epok, Veri Kümesi 2 için 12 epok ve Veri Kümesi 3 için 16 epok oluşturulmuştur. Daha sonra Veri Kümesi 1, sinyal işlemede sıklıkla kullanılan hareketli ortalama filtresi [7] ile ön işlemde geçirilip bu veri kümesinin her bir denemesinden ortalama türev tabanlı öznelikler çıkarılmıştır. Çıkarılan öznelikler sırasıyla k-En yakın komşuluk (k-EYK), destek vektör makinaları (DVM) ve doğrusal ayırım ayırıcı (DAA) yöntemi ile sınıflandırılmıştır. Veri Kümesi 2 için de öznelik çıkarma aşaması hariç Veri Kümesi 1 ile aynı prosedür izlenmiştir. ECoG tabanlı olan Veri Kümesi 2'nin her bir denemesinden ise dalgacık dönüşümü tabanlı öznelikler çıkarılmıştır. 3 kişiden kayıt alınan Veri Kümesi 3 için ise Aydemir'in [8] doktora tezinde uyguladığı karar ağaç yapısı, öznelik çıkarma yöntemleri ve sınıflandırma yöntemleri kullanılmıştır. Aydemir'in her bir kişi için ayrı olarak oluşturduğu 3 düğümde kullandığı algoritmalara ek olarak, bu tez çalışmasında etkin epokların tespiti için oluşturulan yöntem tüm kişilerin her bir düğümüne uygulanmıştır. Böylece 3 veri kümesine uygulanarak bu tez çalışmasında önerilen yöntem ile seçilen etkin epoklardan çıkarılan özneliklerin sınıflandırılması sonucu yüksek başarıma sahip, hızlı bir BBA sistemi önerilmiştir. Bu kapsamda önerilen yöntemler Veri Kümesi 1 ve Veri Kümesi 2 için MATLAB 2015'de, Veri Kümesi 3 için ise MATLAB 2010'da programlanmıştır. Elde edilen sonuçlar literatürdeki çalışmalarla karşılaştırılarak tezde kullanılan yöntemlerin başarımlarını değerlendirilmiştir.

1.2. Beynin Temel Yapısı

Ön, orta ve arka beyin olmak üzere üç temel kısımdan oluşan beyin sinir sistemini kontrol eder, çevresel sinir sistemini yönetir ve hemen hemen insanın tüm fonksiyonlarını düzenler [9]. Ön, orta ve arka beyin kendi içlerinde birbirleri ile iletişim halindedir ve her birinin birbirinden bağımsız görevleri vardır. Şekil 1.1'de insan beyninin genel görüntüsü verilmiştir.



Şekil 1.1 İnsan beyninin genel görüntüsü

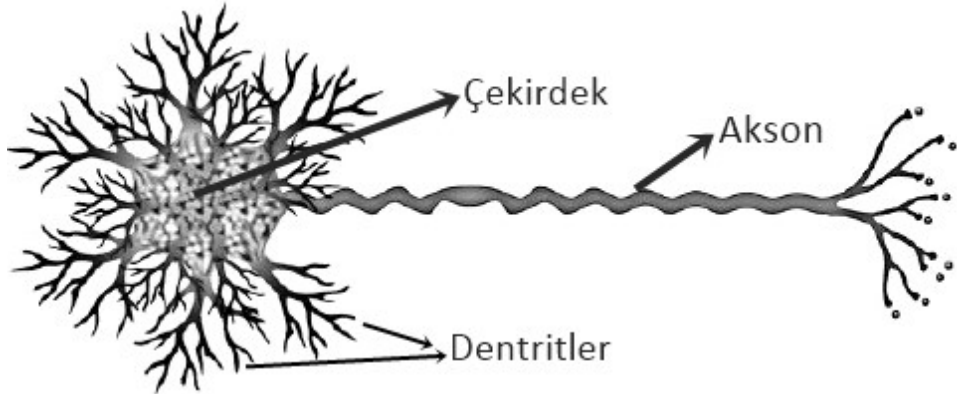
İnsan beynin en büyük kısmı olan ön beyin uç beyin ve ara beyin olmak üzere iki kısımdan oluşur. Önden arkaya doğru uzunlamasına bir çizgiyle birbirinden ayrılan uç beyin beynin diğer kısımlarını üstten kapatır ve iki yarım küreden oluşmaktadır. Bu yarım küreler sinir aksonlarından oluşan alt kısımda beyin üçgeni bağlarıyla, üst kısımda nasırlı cisim bağlarıyla birbirine bağlanmıştır. Bu beyin dış kısımda beyin kabuğu (korteks) adı verilen boz madde, iç kısımda ise miyelinli akson demetlerinden meydana gelmiş ak maddeden oluşur. Ayrıca, beynin bu yarım küresinde beyin kabuğuna giren ve çıkan impulsların iletimi ak madde içerisinde bulunan boz madde kütleleri ile sağlanır. Duyu organların merkezi konumunda olan bu kısım hafıza, öğrenme, değerlendirme, hayal kurma, bilinçli düşünme, konuşma, yazma, çağrışım ve istemli hareket gibi olayları denetler [10]. Ön beyin iki kısmından biri olan ara beyin ise talamus, hipotalamus ve hipofiz bezinin arka bölgesinden oluşur. Beynimizin en önemli bölümü ve en büyük kısmı olan talamus ceviz büyüklüğünde bir sinir dokusudur. Koku duyusu hariç tüm duyu organlarının bağlantı yeri burada yer alır. İnsan hücre haberleşmesi ve denetiminin önemli merkezlerinden biri olan hipotalamus sinir sistemi ile hormon sistemini birbirine bağlar. Yaklaşık 600 miligram ağırlığında olan hipofiz bezi vücuttaki tüm salgı bezlerinin kontrolünü sağlar.

Ön beyin ile arka beyin arasında bulunan orta beyin, işitme ve görme ile alakalı önemli işlevler yapan nöronlar bulundurur.

Arka beyin beyincik ve omurilik soğanından oluşur. Omurilik soğanı (medulla) omuriliğin beyin ile bağlantı yaptığı yerdeki şişkin bölgedir. Beynin arka alt kısmında bulunan beyincik iki yarım küreden oluşur. Bu kısım omurilik soğanı üzerinde yer alır ve nöron gövdeleri tarafından oluşan boz maddeden yapılmış olan kabuk kısma sahiptir. Ayrıca, beyincik sinir sisteminin önemli organlarından biridir [10]. Beyinciğin altında yer alan omurilik soğanı ise omurilik ile varol köprüsü arasında yer alır. Beyin ile diğer vücut organlarının bağlantısı omurilik soğanı ile sağlanır [11]. Omurilik ve beyin arasında sinirsel iletimi sağlayan omurilik soğanı aynı zamanda sindirim, boşaltım, solunum, kalp atış hızı ve metabolizma gibi birçok hayatsal işlevi kontrol ettiği için buna hayat düğümü de denilmektedir.

1.3. Sinir Sisteminin Genel Yapısı ve Biyoelektrik Potansiyeller

Merkezi sinir sistemi iç organlardan veya kaslardan gelen uyarılara cevap vererek canlı vücudunu yöneten, hücre ile organların uyumlu bir şekilde çalışmasını ve ayrıca istemli hareketlerin gerçekleşmesini sağlayan bir sistemdir [11]. Bu sistem Şekil 1.2'de genel yapısı verilen milyonlarca sinir hücresinden diğer adıyla nörondan oluşur.



Şekil 1.2. Sinir hücresi

Geniş hücre gövdesi ile bu gövdeden çıkan uzantılara sahip olan nöronlar sinir sisteminin ana yapısını oluşturur. Bu uzantılar dentrit ve akson olarak adlandırılır. Çok sayıda kısa uzantıdan oluşan ve hücrenin kökleri konumunda olan dentritler alıcı hücrelerinden uyarıları alır ve hücrenin gövdesine iletilmesini sağlar. Sinir hücresinin


gövdesinden çıkan uzun ve tek parçadan oluşan aksonlar ise uyarıların gönderilmesinde etkindir ve beyne mesajların taşınmasında aktiftirler. Sinir hücrelerinin bu şekilde birbirleri ile ilişki halinde olmasıyla bilgi akışı sağlanır. Hücreler arası bu bilgi akış noktaları sinaps olarak adlandırılır. Kimyasal veya elektriksel olmak üzere iki tür sinaps geçişi bulunmaktadır. Bu iki türden sinir hücreleri arasındaki bağlantının çoğu kimyasal olarak gerçekleşmektedir. Kimyasal iletimde bilginin iletilmesi, akson ile diğer sinir hücresi arasında direk bağlantı olmadan sadece kimyasal sinir ileticileri ile gerçekleşmektedir [11].

Sinapslar ile hücreler arası bilgi akışının sağlanması sinir hücrelerine gelen uyarının oluşturduğu aksiyon potansiyelleri ile sağlanmaktadır. Aksiyon potansiyeli şu şekilde gerçekleşmektedir:

Hücrenin içi ve dışı arasındaki iyon dağılımının dengesiz olması burada elektriksel yük farkının oluşmasına neden olur. Bu dengesiz iyon dağılımı Sodyum (Na^+) iyonlarının hücre içine, Potasyum (K^+) iyonlarının hücre dışına çıkmak istemesinden kaynaklanmaktadır. Bütün canlı hücrelerinin içi her zaman dışarıya göre daha negatif yüklüdür ve bu durum bütün canlı hücrelerin ortak özelliği olan yaklaşık -70 milivolt (mV) değerindeki “dinlenme zar potansiyeli” olarak adlandırılır. Uygun bir uyarı ile zarda bulunan hızlı sodyum kanallarının açılmasıyla hücrelere çok hızlı bir sodyum girişi olur ve normalde dinlenme zar potansiyelinde olan hücre zarının potansiyeli +30mV'a kadar çıkar. Hücredeki bu büyük voltaj değişikliği “eylem (aksiyon) potansiyeli” olarak adlandırılır [12]. Bir sinir hücresinin aksiyon potansiyelinin oluşumunda gerçekleşen evreler Şekil 1.3'te gösterilmiştir.

Şekil 1.3'e göre;

- 1) Dinlenme potansiyelinde olan hücreye gelen bir uyarı ile Na^+ kapıları açılır.
- 2) Depolarizasyon olarak ifade edilen bu kısımda voltaja bağlı açılan Na^+ kapılarından hücre içine büyük miktarda Na^+ girer.
- 3) Na^+ kapıları kapanır ve daha sonra voltaja bağlı K^+ kapıları açılır.
- 4) Repolarizasyon başlangıcı olarak adlandırılan bu kısımda K^+ kapılarından hücre dışına K^+ çıkışı olur.
- 5) Voltajın düşmesi ile birlikte K^+ kapıları kapanır.



Şekil 1.3. Aksiyon potansiyeli evreleri

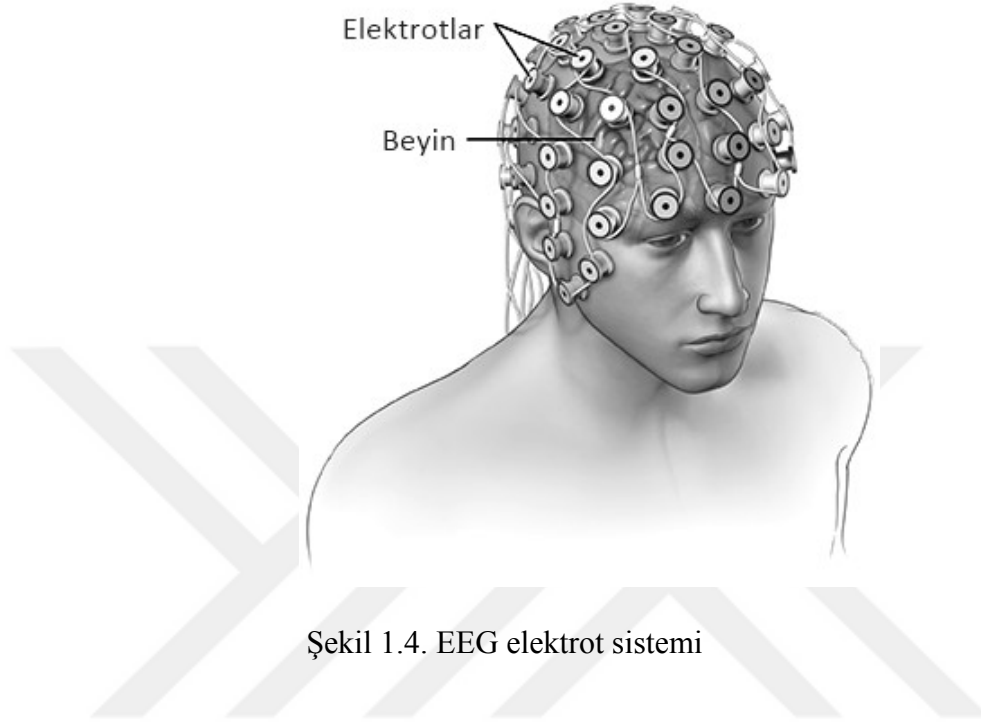
1.4. Beyin Görüntüleme Teknikleri

Bilişsel işlevleri esnasında normal insan beyninin davranışlarını inceleyebilmek için beyin görüntüleme yöntemlerine ihtiyaç vardır. Günümüzde bilimsel çalışmalarda bu yöntemlerden en sık kullanılanları bilgisayarlı tomografi (BT), transkranial manyetik uyarım (TMS), manyetik rezonans görüntüleme (MRI), fonksiyonel manyetik rezonans görüntüleme (fMRI), tek foton emisyon bilgisayarlı tomografi (SPECT), pozitron emisyon tomografi (PET), EEG, ECoG, olay ilişkili potansiyeller (ERP)'dir. Bu tez çalışmasında, bu işaretlerden hastaya acı vermeyen bir yöntem olan ve beyin yüzeyinden elektrotlar yardımıyla işaretin alınmasına olanak sağlayan EEG ile doğrudan beyin yüzeyine yerleştirilen elektrotlar ile kaliteli bilgi ve yüksek SNR oranını içeren ECoG görüntüleme teknikleri ile çalışmıştır.

1.4.1. Elektroensefalografi

Merkezi kontrol organı olarak bilinen beyin diğer tüm organların işlevlerini kontrol eder ve yönetir. Bu yönetim ve kontrol esnasında Şekil 1.4'deki gibi saç derisine yerleştirilmiş elektrotlar yardımıyla sinir hücrelerinin birbiriyle iletişimi esnasında


elektriksel potansiyel deęişimlere baęlı olarak EEG sinyalleri oluşur [13]. Beynin elektriksel faaliyetini incelemek ve yorumlamak amacı ile yapılan EEG, elektriksel bir işarettir.



Şekil 1.4. EEG elektrot sistemi

1.4.2. Elektrokortikografi

Kortikal EEG olarak da isimlendirilen ECoG 1950'lerdeki gelişiminden bu yana, korteks fonksiyonlarının haritalandırılması ve epileptik cerrahi rezeksiyonun başarısını öngörmek için kullanılmıştır [14]. Elektrokortikografi Şekil 1.5'te gösterildięi gibi doğrudan beyin yüzeyine yerleştirilen elektrotlar ile serebral korteksten elektriksel aktiviteyi kaydeden beyin görüntüleme türüdür.



Şekil 1.5. ECoG elektrot sistemi [50]

Elektrot ızgarasını yerleřtirmek iin kafatasına cerrahi bir kesige gerek duyulduėundan, ECoG ameliyat ncesi, sırasında ve sonrasında herhangi bir ařamada ameliyathanede yapılabilir ve acı veren bir yntemdir.

1.4.3. Elektroensefalografi ve Elektrokortikografi İřaretlerinin Elektriksel zellikleri

EEG ve ECoG verileri tam periyodik sinyaller deėildir ancak ritmik olan bu iřaretler beyin aktivitesindeki potansiyel deėişimlere baėlı olarak 0,5 Hz ile 70 Hz frekansları arasında deėişmektedir. Bu iřaretler birok benzer zellik gstermesine raėmen ECoG verileri EEG verilerinden farklı olarak kafatasının altına yerleřtirilen elektrot ile kayıt edildiėi iin farklı genlik deėerlerine sahiptirler. EEG verilerinin genlikleri 5 μ V ile 400 μ V arasında deėişirken, ECoG verilerinin genlikleri ise EEG verilerinden 5-10 kat daha fazladır. Bu iřaretler kaydedilirken evreden ve vcuttan gelen grltler filtrelenmelidir. EEG ve ECoG iřaretlerinin frekansı beynin aktivitesi ykseldike ykselmekte, genlik deėerleri ise dřmektedir. Ayrıca belirgin bazı frekanslar yař arttike ykselmektedir. Bunlara ek olarak, EEG ve ECoG iřaretleri iin en nemli parametre frekans ve daha sonra genliktir.


1.4.4. Elektroensefalografi ve Elektrokortikografi Dalga Őekilleri

EEG ve ECoG verileri iin drt ana beyin dalgası vardır ve bunlar Őekil 1.6'da grldėu gibi Alfa, Beta, Teta ve Delta bantlarıdır.

- Beta dalgaları: Ritmik ve diėer dalgalara gre daha dzensiz olan beta dalgalarının EEG genlik deėeri 1 ile 5 μ V, ECoG genlik deėeri ise 5 ile 30 μ V aralıėındadır. Frekans deėeri 13 Hz'den byk olan bu dalgalarda uykunun hızlı gz hareketleri evrelerinde kaydedilir.
- Alfa dalgaları: EEG genlik deėeri 2 ile 10 μ V, ECoG genlik deėeri 30 ile 50 μ V frekans deėeri ise 8 ile 13 Hz arasında olan dzenli ve ritmik bu dalgalarda sinzoidal

biçime yakın dalgalarıdır. Fiziksel ve zihinsel olarak tam dinlenimde olan gözleri kapalı kişilerin herhangi bir uyaran olmadığı durumlarda kaydedilen dalgalarıdır.

- Teta dalgaları: Alfa dalgalarına göre daha düzensiz olan bu dalgaların EEG genlik değeri 5 ile 100 μV arasında, ECoG genlik değeri ise 200 μV 'un üzerindedir. Bu dalgaların frekans değeri ise 4 ile 8 Hz arasındadır. Bu dalgalar normal bireylerde rüyalı uyku gibi beynin düşük etkinlik gösterdiği durumlarda kaydedilir. Ayrıca yetişkinlerde anormal iken çocuklarda normal dalgalarıdır.
- Delta dalgaları: EEG genlik değeri 20 ile 400 μV arasında, ECoG genlik değeri ise değişken bir genliğe sahip olan dalgalarıdır. Frekans değeri 0,5 ile 4 Hz arasında olan bu dalgalar yüksek genliklidir ve derin uyku gibi beynin çok düşük etkinlik gösterdiği durumlarda oluşur.



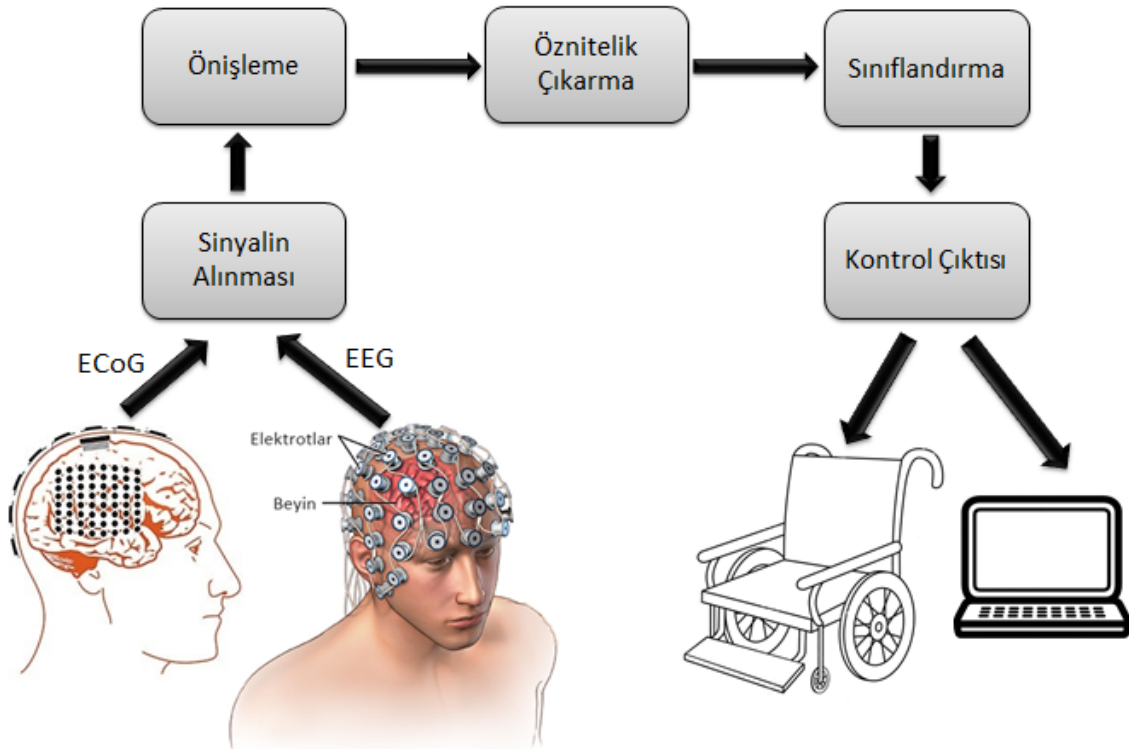
Şekil 1.6. EEG ve ECoG verileri için dört ana beyin dalgası

1.5. Beyin Bilgisayar Arayüzü

Beyin bilgisayar arayüzü, doğrudan tek bir kanal ile insan beyni ve bilgisayar arasında iletişim için tasarlanmış hızla gelişen bir teknolojidir. Bu sistem duyuşal bilgilerin beyne aktarılmasıyla yapay olarak üretilen elektrik sinyallerin beyni uyarması sonucu gerçekleşir.

BBA'lar amyotrofik lateral skleroz (ALS), serebral felç, felç veya omurilik yaralanması gibi nöromüsküler bozukluklara sahip hastaların hayatlarını kolaylaştırır. Bu sistemler bu hasta kişilerin kaslardan ziyade beyin sinyallerini kullanarak hareket eylemini gerçekleştirmelerine olanak sağlarlar [15]. Şekil 1.7'de genel yapısı verilen bir BBA sistemi beyin sinyallerini alır, analiz eder ve bunları istenen eylemleri gerçekleştiren çıktı aygıtlarına ileterek komutlara çevirir. İmleçler, robot kolları, protezler, tekerlekli sandalyeler ve giderek daha karmaşık hale gelen diğer cihazların kontrolü için BBA sistemlerinde elektroensefalografik, elektrokortikografik ve birçok beyin sinyalleri kullanılmaktadır. Bu tez çalışması için bu sinyallerden EEG ve ECoG sinyalleri kullanılmıştır.

Bir BBA sisteminin amacı, kullanıcının niyetini gösteren beyin sinyallerinin özelliklerini tespit ederek bu özellikleri kullanıcının isteğini gerçekleştiren cihaz komutlarına çevirmektir. Bunu başarmak için bir BBA sistemi Şekil 1.7'de gösterildiği gibi beş ayrı bileşenden oluşur. Bunlar: sinyal toplama, önileme, öznitelik çıkarımı, sınıflandırma ve aygıt çıktısı aşamalarıdır. Etkili bir BBA sistemi için bu bileşenlerin yüksek başarımlı olması gerekmektedir.



Şekil 1.7. Beyin bilgisayar arayüzü temel bileşenleri

1) Sinyal toplama: Bu adım BBA sistemindeki ilk aşamadır. Sinyal toplama, belirli bir sensör veya elektrot kullanarak beyin sinyallerinin ölçümü olarak tanımlanabilir. Sinyaller, elektronik işlemeye uygun seviyelere yükseltilerek BBA sistemleri için ideal hale getirilir.

2) Önışleme: Bu adım 60 Hz güç hattı girişimi gibi elektriksel gürültüyü veya diğer istenmeyen sinyal özelliklerini gidermek için uygulanır.

3) Öznitelik çıkarımı: Özellik çıkarımı sinyalleri analiz etme işlemidir. Burada girdi olarak verilen ölçülmüş veriler kullanarak öznitelikler oluşturulur. Bu adım makine öğrenimi, örüntü tanıma gibi birçok alanda kullanılır.

4) Sınıflandırma: Sınıflandırma adımı bir veri kümesinde tanımlı olan çeşitli sınıfları dağıtarak eğitim kümesinden bu dağılım şeklinin öğrenilmesidir. Daha sonra öğrenilen bu şekle göre sınıfı belirli olmayan test verilerinin sınıflandırılması yapılır. Veri kümelerindeki bu sınıflar etiket olarak adlandırılır ve bu etiketler verideki sınıfların belirlenmesi için kullanılır.

5) Kontrol çıktısı: Sınıflandırma sonucu gelen komutları değerlendirir ve bu komutlara göre aygıtı çalıştırır. Örneğin; harf seçimi, imleç kontrolü, robotik kol kullanımı ve benzeri işlevlerin olduğu aygıtların çalıştırılması için uygun komutla sağlanır.

1.6. Literatür Araştırması

Son yıllarda beyin bilgisayar arayüzü sistemleri araştırmalarının artması ile literatürde bu sistemleri geliştirmeye yönelik birçok çalışma yapılmıştır [16-18]. Ancak bu çalışmalarda kullanılan beyin görüntüleme teknikleri farklı olabilmektedir. Beyin bilgisayar arayüzü sistemleri için BT [19], TMS [20], MRI [21], fMRI [22], [23], SPECT [24], PET [25], EEG [26], [27], ECoG [14] ve ERP [28], [29] ile yapılmış birçok çalışma vardır.

Bilgisayarlı tomografi cihazının bulunduğu masada hareketsiz olan hastadan X ışını kullanılarak alınan BT ile beyindeki anormallikler saptanır. Ancak bu teknikte kontrast madde ve iyonizan ışın kullanılması dezavantajlıdır [30]. Beyine yakın tutulan bir bobin

aracılığıyla beyin içinde bir manyetik alan oluşturan TMS tekniği ile beyin işlevlerinin incelenmesine rağmen bu teknik incelediği bölgenin işlevini bozan elektrik akımı oluşturur. Beyin dokusundaki hidrojen atomlarının yoğunlukları ile hareketlerine bağlı olarak beyin görüntüsü oluşturan MRI tekniği ile kalp pili olan, kalıcı dövme sahibi olan ve vücudunda metal proteze sahip olan kişilerden görüntü alınmamaktadır [31]. Bir diğer görüntüleme tekniği ise zaman içerisinde kan oksijenlenmesine dayalı oluşan fMRI beyin görüntüleme tekniğidir. Bu tekniğin uygulandığı ortam kapalı olduğu için kapalı alan fobisi olan hastalara uygulanabilirliği düşüktür ve bunun yanı sıra maliyetli bir tekniktir. Son yıllarda fazlaca kullanılan PET ve SPECT beyindeki kan akımına bağlı olarak oluşan görüntüleme teknikleri olmasına rağmen bu tekniklerin görüntü oluşturma hızı çok yavaştır. Sadece yapısal bilgi taşıyan bu beyin görüntüleme tekniklerine karşın EEG acı vermeyen, ECoG ise sinyal/gürültü oranı (SNR) büyük olması bakımından hastalığı ileri derecede olan kişiler için gerçek zamanlı beyin haritalarını kolaylıkla inceleyebilmektedir. Ayrıca EEG ve ECoG son yıllarda başarılı BBA sistemlerine ulaşabilmek için çok kullanılan beyin görüntüleme teknikleridir [32]. Yüksek başarılı BBA sistemleri elde etmek için özellikle motor hareketi hayaline dayalı kayıt alınan 2 sınıflı ve 4 sınıflı EEG ve 2 sınıflı ECoG veri kümeleriyle yapılmış birçok çalışma literatürde yer almaktadır [33-35]. Bu çalışmalar ise genelde veri kümesine uygulanan çeşitli yöntemler ile SD hesaplama ağırlıklıdır. Bu bağlamda bu veri kümelerine çeşitli önışleme, öznitelik çıkarma ve sınıflandırma yöntemleri uygulanmıştır.

BBA verilerin kalitesini arttırmak ve veriyi gürültüden temizlemek için uygulanan önışlem yöntemleri literatürde birçok yerde çalışılmıştır [36],[37]. Ramoser ve arkadaşları (2000) çok kanallı motor hareketi hayaline dayalı EEG veri kümesi için uzamsal filtre ile ayırt edici bilgiyi elde etmeyi amaçlamışlardır [38]. Blankertz ve arkadaşları (2008) ise yine uzamsal filtre ile BBA verilerindeki SNR'yi optimum seviyeye getirmeyi hedeflemişlerdir [39]. Bunlara ek olarak Kumar ve arkadaşları (2016) motor hayaline dayalı EEG verileri için uzaysal-spektral filtreleme yöntemini kullanmışlardır [40].

Literatürde 2 sınıflı EEG tabanlı BBA verilerine uygulan öznitelik, sınıflandırma ve diğer yöntemleri içeren çalışmalar ise şöyle sıralanabilir; Pfurtscheller ve arkadaşları (1996) bir görsel ekranla 6 kişiden sağ ve sol imleç hareketi hayaline dayalı EEG verileri kaydetmişlerdir. Hareketin gerçekleştirilmesi sırasında EEG verilerini analiz ederek iki elektrot ve iki zaman penceresi kullanarak vektör nicemlemesi öğrenmesi şeklinde bir sinir ağı ile bu verileri eğitmişlerdir. 1 saniyelik zaman penceresiyle işledikleri iki farklı

oturumda ve iki seansta kaydedilen EEG veri kümesi ile 6 kişiden %47 ile %77 arasında sınıflandırma doğruluğu (SD) hesaplayarak motor nöronları bozuk olan hastalar için bir BBA sistemi önermişlerdir [41]. Zhong ve Ghosh (2002) EEG tabanlı BBA uygulamalarında [42]'de yaptıkları çalışmada ise birleşmiş hidden markov modelini (HMM) önermişlerdir. Çok kanallı EEG sınıflandırma problemi için önerdikleri bu model ile iki veri kümesi için de HMM'nin performansını incelemişlerdir. Önerdikleri model ile birinci veri kümesiyle %87.0±6.9, ikinci veri kümesiyle ise %77.0±8.3 SD hesaplayarak düşük hesaplama karmaşıklığına sahip BBA sistemi oluşturmayı hedeflemişlerdir. Garcia ve arkadaşları (2003) ise motor hareketi hayaline dayalı EEG verileri üzerinde DVM sınıflandırıcısını kullanarak teorik hata sınırını en aza indirmek için gerekli DVM parametrelerini optimize etmeye çalışmışlardır. Daha sonra EEG verilerinden Fourier ve korelasyonlu zaman-frekans tabanlı öznitelikler çıkartarak BBA sistemi için ayırt edici güce sahip öznitelikleri seçmeye çalışmışlardır. İki kişi üzerinden hesapladıkları sınıflandırma sonuçlarına göre en iyi hata oranını %18 ile Fourier tabanlı öznitelikler ile birinci kişiden elde etmişlerdir [43]. Li (2008) ve arkadaşları EEG tabanlı BBA sistemlerinin geliştirebilmek için ise yeni bir tensör tabanlı şema önermişlerdir. Bu şemada, EEG verilerinden dalgacık dönüşümü tabanlı öznitelikler çıkartarak DVM yöntemi ile çıkarılan öznitelikleri sınıflandırmışlardır. Üç veri kümesi üzerinde uyguladıkları tensör tabanlı şema ile en iyi sonuçları birinci veri kümesi için 8-30 Hertz (Hz) arasında ortalama %76.3, 4-45 Hz arasında ise ortalama %70.0 SD hesaplamışlardır. Hesapladıkları sonuçlar güç spektrum yoğunluğu ve ortak uzamsal örüntü (OUÖ) algoritmalarıyla elde ettikleri sonuçlara göre yüksek çıkmasına rağmen sonuçlar yüksek başarılı bir BBA sistemi için yetersizdir [44]. Hsu (2012) [45]'de yaptığı çalışmada ise motor hareketi hayaline dayalı EEG verilerinin sınıflandırılması için gelişmiş aktif segment seçimi yöntemini önermiştir. Bu yönteminin uygulanmasından sonra verilerden öznitelik çıkartarak daha sonra sınıflandırma yapmaktadır. 6 kişiden kaydedilen EEG verilerinden çok çözünürlüklü fraktal öznitelik vektörü ile çıkarılan özniteliklerle DAA için %78.7, DVM için %82.5 sınıflandırma doğruluğu hesaplamıştır. EEG tabanlı BBA sistemleri üzerine yapılan başka bir çalışma ise Daliri'nin (2013) EEG verilerinin sınıflandırılması için yer değiştiricinin uzaklığına dayalı yeni bir çekirdek yaklaşımı önermesidir. Burada EEG zaman serileri önce bu yaklaşımdaki histogramlara dönüştürülür. Daha sonra EEG verilerini DVM ile sınıflandırarak önerdiği yeni çekirdek yöntemiyle iyi bir BBA sistemi oluşturmaya çalışmıştır [46]. Amin ve arkadaşları (2015) ise EEG verilerinin

sınıflandırılması için ayrık dalgacık dönüşümü tabanlı öznitelik çıkarma şemasını önermişlerdir. Bu şemada, ayrık dalgacık dönüşümü EEG sinyallerine uygulanarak dalgacık enerjisini hesaplamışlardır. Daha sonra dalgacık enerjisinden hesaplanan öznitelikler DVM, çok katmanlı algılayıcı (MLP) ve k-EYK yöntemleri ile sınıflandırılarak iyi bir BBA sistemi için çalışmışlardır [47]. Son yıllarda hızla artan 2 sınıflı EEG tabanlı BBA sistemleri için yapılan diğer bir çalışma da Singh ve arkadaşlarının (2016) sinyallerin durağan olmayan niteliğini yakalayan EEG ritimlerini kullanarak EEG verilerini analiz etmesidir [48]. Kuremoto ve arkadaşları (2017) hızlı fourier dönüşümü ve işlem karakteristiği eğrisi tekniklerini kullanılarak yeni bir EEG sinyal öznitelik çıkarma yöntemi sunmuşlardır. Çıkarılan öznitelikleri DVM ile sınıflandırarak önerilen öznitelik çıkarma yönteminin etkililiğini araştırmışlardır [49]. Bunlara ek olarak Abdalsalam ve arkadaşları (2017) [50]'deki çalışmalarında MLP ve k-EYK gibi farklı sınıflandırma yöntemlerini ayrık dalgacık dönüşümü tabanlı özniteliklerine uygulayarak EEG veri kümeleri için etkin sınıflandırıcı araştırması yapmışlardır.

Bu tez çalışmasında kullanılan 2 sınıflı EEG tabanlı Veri Kümesi 1 ile çalışmalar literatürde yer almaktadır. Aydemir ve Kayıkçıoğlu [51] Veri Kümesi 1'in sadece tek kanalını kullanarak sinyalin ikinci dereceden polinom katsayılarını hesaplamışlardır. Daha sonra hesapladıkları iki boyutlu bu öznitelik vektörünü k-EYK ile sınıflandırarak %92 sınıflandırma doğruluğu hesaplamışlardır. Veri Kümesi 1 ile yapılan diğer çalışma ise Mensh ve arkadaşlarının [52] basit bir doğrusal sınıflandırıcı ile yaptıkları çalışmadır. Burada önerdikleri yöntem ile %88.7 sınıflandırma doğruluğu hesaplamışlardır. Bunlara ek olarak Guo ve arkadaşları dalgacık dönüşümü tabanlı öznitelikleri doğrusal olmayan sınıflandırma algoritması olan randomize sinir ağı ile %92.5 olarak sınıflandırmışlardır [53]. Ancak hesaplanan bu sonuçlar bu tez çalışmasında ulaşılan sınıflandırma doğruluğuyla geçilmiştir.

İki sınıflı ECoG tabanlı BBA verilerine uygulan öznitelik, sınıflandırma ve diğer yöntemleri içeren çalışmalar ise şöyle sıralanabilir; Won ve arkadaşları (2014) düşük çözünürlüklü ayrık kosinüs dönüşümüne dayanan bir öznitelik çıkarma yöntemi önererek bu öznitelikleri DAA ve DVM yöntemleriyle sınıflandırmışlardır. En iyi sınıflandırma doğruluğunu %82.9 olarak hesaplayarak ECoG tabanlı BBA sistemi oluşturmayı hedeflemişlerdir [54]. Kapeller (2014) ve arkadaşları ise ECoG verilerine BCI sistemlerinde öznitelik çıkarımı ve boyut azaltmada yaygın olarak kullanılan OUÖ algoritmasını uygulamışlardır ve burada yüksek gamma frekans aralıklarındaki sinyalleri

100 ve 500 Hz arasında filtrelemişlerdir. Daha sonra çıkarılan öznitelikleri DAA yöntemi ile sınıflandırarak 35 yaşındaki kadın denekten kaydedilen verilerden %13.89 ile %7.22, 22 yaşındaki erkek denekten %18.42 ile %1.17 arasında hata oranı hesaplayarak iyi bir BBA sistemleri oluşturabilmek için çalışmışlardır [55]. ECoG tabanlı BBA sistemi için Kapeller ve arkadaşlarının (2015) [56]'da yapılan başka bir çalışmaları ise yine OUÖ algoritmasını kullanarak öznitelik hesaplamalarıdır. Tek kişiden alınan ve 40 denemeden oluşan ECoG verisinin 6 koşum sonucunu ortalama % 95.4 SD olarak hesaplamışlardır. Aswineshadri ve Thulasi Bai (2016) motor nöron bozukluğu olan hastaların beyni ile bilgisayar arasındaki etkileşimi sağlayan BBA sistemleri için ECoG verilerinden bilgi kazancı (IG) ve karşılıklı bilgi (MI) algoritmaları ile öznitelikler çıkartarak bir yöntem önermişlerdir. Bu algoritmaları kullanmadan Bayes sınıflandırıcı ile %88.49, IG algoritması ile %91.37, MI algoritmasıyla ise %89.93 sınıflandırma doğruluğu hesaplamışlardır [57]. Islam ve arkadaşları (2016) ise BCI competition III Data Set I verilerinden sürekli dalgacık dönüşümü tabanlı öznitelikler (SDD) çıkartmışlardır. SDD katsayılarının L_2 normları ile iki sınıflı motor verilerini ayrılabilir olarak ifade etmişlerdir. Daha sonra L_2 normuna dayalı öznitelikleri DAA yöntemi ile sınıflandırarak %92 sınıflandırma doğruluğu hesaplamışlardır. [58]. Erkan ve Kurnaz (2017) ise BCI Competition III dataset I veri kümesi ile çalışmışlardır ve kanal seçimi için ark algılama algoritmasını (ADA) önererek ECoG veri kümesinden dalgacık dönüşümü tabanlı öznitelikler çıkarmışlardır. Çıkarılan öznitelikler daha sonra k-EYK, DVM ve DAA yöntemleriyle sınıflandırılarak performans karşılaştırması yapmışlardır [59].

Bu tez çalışmasında çalışılan 2 sınıflı ECoG tabanlı olan Veri Kümesi 2 ile ise Qingguo ve arkadaşları [60] olay ilgili potansiyeller, olayla ilişkili desenkronizasyon ve ortak uzamsal altuzay ayırma ile çıkardıkları üç özniteliği sınıflandırarak %91.00 sınıflandırma doğruluğu hesaplamışlardır. Dat ve arkadaşları ise [61] aynı ECoG verilerini Gabor filtreleri kullanarak alt bantlara ayırtmışlardır. Daha sonra alt bant sinyallerini, parametrik olmayan istatistiksel modelleme kullanılarak kodlayıp ortaya çıkan deneysel dağılımlar arasındaki mesafeyi sınıflandırma kriteri olarak kullanmışlardır. Önerdikleri yöntemle %92 sınıflandırma doğruluğu hesaplamışlardır. Veri Kümesi 2 ile yapılan başka bir çalışma ise Li ve arkadaşlarının [62]'de dalgacık dönüşümü yöntemi ve fisher doğrusal ayırım analizini kullanarak önerdikleri algoritmadır. Burada hesaplanan sınıflandırma doğruluğu ise %92'dir.

İki sınıflı EEG ve ECoG sınıflandırılmasının yanında literatürde dört sınıflı EEG veri sınıflandırılması üzerine yapılmış çalışmalar da bulunmaktadır. Schlögl ve arkadaşları (2005) beş denekten 60 elektrot ile kaydedilen 4 sınıflı motor hayaline dayalı EEG verileri ile çalışmışlardır. Kalman filtrelemesini kullanarak özbağlanım yöntemi için parametre hesaplamışlar ve daha sonra özbağlanım tabanlı öznitelik hesaplayarak verileri k-EYK, DVM, DAA, minimum mesafe analizi yöntemleriyle sınıflandırmışlardır. En iyi sınıflandırma doğruluğunu DVM ile beş kişi için %52.4 ile %77.2 arasında hesaplamışlardır [63]. 9 denekten 4 sınıflı olarak kaydedilen BCI Competition IV veri seti IIA'ya Chin ve arkadaşları (2009) ise ortak uzamsal örüntü yaklaşımının çok sınıflı uzantısının üç yaklaşımını uygulamışlardır. Bunlar Bir-iki dinlenme, Çift-Bilge ve Böl ve Fethet yaklaşımlarıdır. Bu üç yaklaşımla sırasıyla %57.00, %57.00 ve %55.000 test sınıflandırma doğruluklarını hesaplamışlardır [64]. Dört sınıflı motor hareketi hayaline dayalı BCI Competition IV veri seti ile yapılan başka bir çalışma ise Bai ve arkadaşlarının (2014) bağımsız bileşenler analizi, dalgacık dönüşümü ve ortak uzamsal örüntü yaklaşımlarını beraber kullanarak önerdikleri çalışmadır. Burada önerdikleri yöntemle çıkardıkları öznitelikleri DVM ile sınıflandırarak 9 kişi için ortalama %68.00 sınıflandırma doğruluğu hesaplamışlardır [65].

Bu tez çalışmasında çalışılan 4 sınıflı motor hareketi hayaline dayalı EEG tabanlı Veri Kümesi 3 ile Aydemir [8]'de daha önce de bahsedildiği gibi doktora tezinde çalışmıştır. Burada A, B ve C olarak adlandırılan kişilere karar ağaç yapısını uygulayarak her bir kişi için SD hesaplamıştır. Karar ağacı sonunda A, B ve C kişisi için sırasıyla %82.24, %57.90 ve %55.92 SD hesaplamıştır. Aynı veri kümesiyle yapılan başka bir çalışma Aydemir'in [66]'de OUÖ öznitelikleriyle en iyi zaman dilimini aramasıdır. Aydemir bu çalışmasında 4 sınıflı EEG veri kümesini birbiriyle kombinasyonlu olacak şekilde ikili gruplara ayırarak SD hesaplamıştır. Bu çalışmasında kişinin imleci yukarı ve sağa hareketini hayali sırasında kaydedilmiş EEG verilerini kullanarak DVM yöntemiyle ortalama %54.82 SD hesaplarken, önerdiği yöntem ile ortalama %77.19 SD hesaplamıştır.

Literatür de incelendiği gibi motor hayaline dayalı 2 sınıflı ve 4 sınıflı EEG ve 2 sınıflı ECoG tabanlı BBA işaretlerinin sınıflandırma doğruluğunu artırıcı yapılan birçok çalışma vardır. Ancak, bu işaretlerin zaman dilimlerine ayrılarak (epoklar) bir denemesine ait tüm epoklar yerine belirlenen öznitelik ve sınıflandırma yöntemlerine göre seçilen etkin epoklar ile sınıflandırma doğruluğunu artırıcı çalışmalar kısıtlıdır. Han ve Wei (2015) [67]'deki çalışmalarında pencereleme yöntemiyle uygun zaman ve frekans band aralığını

aramışlardır. İşaretten OUÖ tabanlı öznitelikleri çıkartarak çıkarılan öznitelikleri k-EYK algoritmasıyla sınıflandırmışlardır. En iyi zaman ve frekans aralıklarını seçerek 9 ayrı kişi için sırasıyla %72.02, %74.13 ortalama SD hesaplamışlardır. Asensio ve arkadaşları (2013) ise SD artırmak ve ÖÇS'yi azaltmak için yerel diskriminant temelleri yöntemi ile EEG işaretini 0.5 saniye (sn), 0.6 sn, 0.8 sn ve 1 sn'lik pencerele bölmüşürler. Daha sonra işaretin bu bölümleri OUÖ tabanlı çıkarılan özniteliklerle DAA ile sınıflandırılmıştır [68]. Wei-Yen Hsu (2011) ise EEG işaretlerini sınıflandırmak için işarete önerdiği geliştirilmiş aktif bölüm seçimi yöntemini uygulayarak işareti zamansal olarak ayırmıştır. Tüm işaret ile %66.70, orijinal aktif bölüm seçimi ile %76.50 hesaplarken, geliştirilmiş aktif bölüm seçimi ile %80.20'ye yükseltmiştir [69]. Bu tez çalışmasında ise diğer çalışmalardan farklı olarak hesaplama süresini azaltmak için veri kümelerinin tüm denemeleri bu tez çalışmasında önerilen yöntem ile belirlenen epoklara ayrılarak seçilen etkin epoklardan çıkarılan özniteliklerle yüksek sınıflandırma doğruluğu hesaplanmıştır.


2. YAPILAN ÇALIŞMALAR

2.1. Malzeme

Bu tez çalışmasında, BCI Competition 2003 Dataset Ia, BCI Competition 2005 Dataset I ve İmleç Hareketi Hayaline Dayalı 3 ayrı veri kümesi kullanılmıştır. Her bir veri kümesinin tanıtımı aşağıdaki alt başlıklarda ayrıntılı olarak verilmiştir.

2.1.1. Veri Kümesi 1

Veri Kümesi 1 olarak isimlendirilen BCI Competition 2003 Dataset Ia, Tübingen Üniversitesi tarafından sağlanan veri kümesidir. Veri kümesi, imleci bir bilgisayar ekranında yukarı (sınıf 0) ve aşağı (sınıf 1) hareket ettirmesini hayal etmesi esnasında sağlıklı bir kişiden alınmıştır. Her bir deneme 6 saniye sürmüştür. Görsel geri bildirim ilk 2. saniyeden 5.5. saniyeye kadar sürmüştür. Eğitim ve test kümeleri, bu görsel bildirim olduğu her denemenin yalnızca 3.5 saniyelik aralığını oluşturmaktadır. 256 Hz'lik örnekleme frekansına sahip verilerin herbir toplam 896 örnekten oluşmaktadır.



Şekil 2.1. Uluslararası 10–20 sistemine göre Veri Kümesi 1 elektrotlarının pozisyonları

Bu veri kümesinin 268 denemesi eğitim, 293 denemesi test kümesini oluşturmaktadır. Eğitim kümesinin 135 denemesi sınıf 0, 133 denemesi sınıf 1 ve test kümesinin 147 denemesi sınıf 0, 146 denemesi sınıf 1'den oluşmaktadır. Veri kümesi 6 elektrot ile alınmıştır ve uluslararası 10-20 Sistemi'ne göre elektrotların pozisyonları Şekil 2.1'deki gibi konumlandırılmıştır. Burada 1. elektrot A1, 2. elektrot A2, 3. elektrot FC3, 4. elektrot CP3, 5. elektrot FC4, 6. elektrot CP4 noktasıdır. Bu elektrotlar Şekil 2.1'de siyah dolgulu daireler ile belirtilirken, gri dolgulu daire referans elektrot Cz pozisyonunu göstermektedir.

2.1.2. Veri Kümesi 2

Veri Kümesi 2 olarak isimlendirilen BCI Competition 2005 Data Set I, elektrokortigogram işaretlerinden oluşmaktadır. Bu veri kümesi bir epilepsi hastasından iki farklı aşamada eğitim ve test kümesi olarak yaklaşık bir hafta ara ile alınmıştır. 64 elektrot ile alınan bu veri kümesi 1 kHz'lik örnekleme frekansına sahiptir. Veriler kişinin sol elinin küçük parmağını (sınıf a) ve dilini (sınıf b) hareket ettirdiğini hayal etmesi esnasında kaydedilmiştir. Eğitim verileri için 278 deneme kaydı yapılmışken, test kümesi için 100 denemeden oluşan kayıt yapılmıştır. Eğitim ve test kümelerinin her birinin yarısı sınıf a, diğer yarısı ise sınıf b verilerinden oluşmaktadır. Ayrıca, veri kümesinin her bir denemesi 3 saniye uzunluğundadır.

2.1.3. Veri Kümesi 3

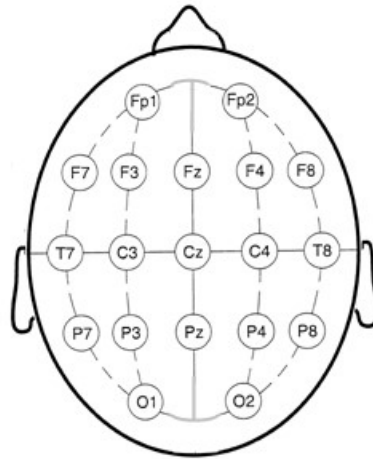
Veri Kümesi 3 olarak isimlendirilen imleç hareketi hayaline dayalı EEG veri kümesi, Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünde ilgili araştırmacı Dr. Önder AYDEMİR tarafından sağlanıp [8] açık kullanıma sunulmuştur. EEG verileri üç sağlıklı erkek yetişkinden (24-29 yaşları arasındaki A, B ve C olarak adlandırılan) yaklaşık iki haftalık ara ile iki farklı oturumdan kayıt alınmıştır. Trabzon Klinik Araştırmalar Etik Kurulu tarafından onaylanmış olan EEG veri kaydı için tüm kişiler bilgilendirilerek onayları alınmıştır. Her oturum dört bölümden, her bölüm 40 denemeden, 40 deneme de imleç hareketi hayaline dayalı 10'ar yukarı, sola, sağa ve aşağı

sınıflarından oluşmaktadır. Her oturumda toplam 160 deneme yapılmıştır. Ancak, kötü motive olunmuş bazı denemeler veri kümesinden çıkarılmıştır.

Tablo 2.1. Veri Kümesi 3 için eğitim ve test deneme sayıları

Kişiler	Eğitim verileri deneme sayısı	Test verileri deneme sayısı
A	140	152
B	148	152
C	148	152

Veri kaydı esnasında her bir kişi 19x19'luk siyah arka planlı ızgaralı bir ekranına bakan bir koltuğa oturmuştur ve kayıt sırasında herkesten hareketsiz kalması istenmiştir. Her bir deneme 2 saniyelik bir gecikmenin ardından 10 saniye uzunluğundan oluşmaktadır. Ardından, hedef (yukarı, sol, aşağı ve sağ) ekranın orta noktasında görüntülenmiştir. Hedef ekranda görününce, monitörün ortasında bir imleç ortaya çıkar ve daha sonra hedefe karşılık 8 saniyelik gelen zihinsel bir faaliyet gerçekleştirilir. Her deneme bip sesi ile sona erer. İlk oturum kaydı eğitim kümesi olarak kullanılmışken ikinci oturum denemeleri ise test kümesi olarak kullanılmıştır. Tablo 2.1, her bir kişi için eğitim ve test verilerinin deneme sayısını göstermektedir. Hem eğitim hem de test kümesi, her sınıf için eşit denemelerinden oluşmaktadır. Hem eğitim hem de test verilerindeki denemeler bu tez çalışması için şu şekilde tanımlanır: S1= imleç yukarı, S2= imleç sağ, S3= imleç aşağı ve S4= imleç sol. Amaç, test verilerindeki denemeleri S1, S2, S3 ve S4 olarak sınıflandırmaktır.



Şekil 2.2. Uluslararası 10-20 sistemine göre Veri Kümesi 3 elektrotlarının pozisyonları

EEG verilerinin elde edilmesi için Brain Quick EEG System (Micromed, İtalya) kullanılmıştır. Veriler 256 Hz ile örneklenmiştir ve 0,1 Hz ile 120 Hz arasında filtrelenmiştir. Ayrıca, hat gürültüsünü gidermek için 50 Hz'lik çentik filtresi kullanılmıştır. Tüm EEG elektrot empedansları 5 k Ω 'un altında tutularak Şekil 2.2'de gösterildiği gibi Cz referans noktası alınarak uluslararası 10-20 sistemine göre yerleştirilmiştir.

2.2. Yöntem

2.2.1. Hareketli Ortalama Filtresi ile Önişleme

Hareketli ortalama filtresi (HOF), örneklenen veri dizisini yumuşatmak için yaygın olarak kullanılan basit bir alçak geçiren filtredir [7]. Anlaşılması ve kullanımı kolay olan bu filtre veride istenmeyen gürültülü bileşenleri filtrelemek için kullanışlıdır. Ayrıca, veri kümesinin farklı alt gruplarının ortalamasını alarak bir dizi oluşturarak veri noktalarını analiz eden bir hesaplamadır. Bu filtre, veri boyunca PB (pencere boyutu) uzunluğunda bir pencere kaydırarak her bir penceredeki verilerin ortalamalarını hesaplayarak tek bir $m(n)$ çıkış sinyali üretir. Denklem 2.1'deki fark denklemi bir t vektörünün hareketli ortalama filtresini tanımlar. Bu tez çalışmasında 5 olarak seçilen *WindowSize* pencere boyutu, rasyonel aktarım fonksiyonu için pay ve payda katsayılarını oluşturur.

$$m(n) = \frac{1}{PB} [t(n) + t(n-1) + \dots + t(n-(PB-1))] \quad (2.1)$$

2.2.2. Öznitelik Çıkarma Yöntemleri

EEG işaretlerinin tek başına belirleyici olmamasından dolayı bu işaretlerin analizi esnasında istatistiksel ve matematiksel analiz yöntemlerine başvurulur. Bu tez çalışmasında Veri Kümesi 1, Veri Kümesi 2 ve Veri Kümesi 3'e aşağıda alt başlıklarda açıklanan Dalgacık Dönüşümü (DD), Ortalama Türev (OT), Çarpıklık (Ç), Basıklık (B), Varyans (V) ve Özbağlanım (ÖB) yöntemlerinden etkin olanları uygulanmıştır.

2.2.2.1. Dalgacık Dönüşümü

Sinyali alt frekans bantlarına ayırıştıran DD, 1984’de ilk olarak Grossman ve Morlet tarafından kullanılmıştır. Bu dönüşüm zaman ölçekli olup durağan olmayan ve karakteristiği zamanla değişen sinyaller için geliştirilmiş bir inceleme yöntemidir [66]. Bir diğer ifade ile genel olarak DD, $m(n)$ giriş sinyalinin ana dalgacık olarak tanımlanan $\psi_{a,b}(x)$ dalgacığı ile çarpımıdır. Düzenli bir sinyal olan $\psi_{a,b}(x)$ dalgacıklarının $x \rightarrow \infty$ iken merkez noktası ve dalgacığın ortalaması sıfırdadır. Bu dönüşüm ile sinyale ait zaman ve frekans tanımlı bilgiler eşzamanlı ifade edilebilir. Ayrıca, bu yöntem ile sinyal herhangi bir bozulma olmadan gürültüden arındırılabilir. Dalgacık dönüşümünün sürekli ve ayrık olmak üzere iki çeşidi vardır. Bu tez çalışmasında Sürekli Dalgacık Dönüşümü kullanılmıştır. Sürekli Dalgacık Dönüşümü, $\psi_{a,b}(x)$ ana dalgacığı ile sinyal arasındaki benzerliği ölçmek için iki sinyalin iç çarpımı ile gerçekleşmektedir. Böylece sinyal ve dalgacığın değişik ölçeklerde karşılaştırılmasıyla iki boyutlu fonksiyon oluşturulur. Bir $m(n)$ işaretinin Sürekli Dalgacık Dönüşümü Denklem 2.2’de verildiği gibi hesaplanır. Bu denklemde; r ölçek (frekans) ve p zaman (konum) parametresini ifade etmektedir.

$$SDD(r, p) = p^{-1/2} \int_{-\infty}^{+\infty} m(n) \psi\left(\frac{n-r}{p}\right) dt \quad (2.2)$$

Bu çalışmada Sürekli Dalgacık Dönüşümü tabanlı öznelilikler Denklem 2.3 ve Denklem 2.4’te verildiği gibi Sürekli Dalgacık Dönüşümü katsayılarının ($SDDK$) ortalaması ($SDDK_o$) ve standart sapmaları ($SDDK_s$) hesaplanarak çıkarılmıştır. Bu denklemlerde L_{SDDK} dalgacık dönüşümü katsayılarının uzunluğunu ifade etmektedir.


$$SDDK_o = \frac{\sum |SDDK|}{L_{SDDK}} \quad (2.3)$$

$$SDDK_s = \sqrt{\frac{\sum (|SDDK| - SDDK_o)^2}{L_{SDDK}}} \quad (2.4)$$

Sürekli Dalgacık Dönüşümü için birçok dalgacık türü vardır. Bunlardan bazıları; Haar, Daubechies, Coiflets, Biorthogonal, Morlet ve Mexican dalgacıklarıdır. Bu dalgacık


türlerinden sinyalin özelliğine göre seçilen dalgacık önemlidir. Bu tez çalışmasında Morlet ve Daubechies dalgacıkları kullanıldığı için bu dalgacıkların açıklamaları aşağıda verilmiştir.

Ölçeklendirme fonksiyonuna sahip olmayan Morlet dalgacığı ani değişimleri olan sinyaller için iyi sonuç vermektedir. Şekil 2.3’de Morlet dalgacık grafiği verilmiştir.



Şekil 2.3. Morlet dalgacığı

Ingrid Daubechies tarafından keşfedilen ve Daubechies dalgacığının birçok çeşidi vardır. Bu tez çalışmasında geçici olayları analiz etmede iyi olan ve Şekil 2.4’de verilen Daubechies 2 dalgacığı kullanılmıştır.



Şekil 2.4. Daubechies dalgacığı

2.2.2.2. Ortalama Türev

Analog ve dijital sinyal işleme ile ilgili birçok alanda kullanılan türev bir fonksiyonun grafiğine çizilen teğet doğrusunun eğiminin hesaplanmasıyla elde edilir [67]. Bir veri dizisinde iki veya ikiden çok örneğin toplamının veri dizisinin uzunluğuna bölümüne ise ortalama denir. Bir $m(n)$ sinyalinin $n = 1$ 'den $(c - 1)$ 'e kadar ki ortalaması Denklem 2.5'te verilmiştir. Burada OT işaretin ortalama türevini, c ise $m(n)$ fonksiyonun uzunluğunu ifade etmektedir.

$$OT = \frac{1}{(c - 1)} \sum_{n=1}^{c-1} m(n) - m(n - 1) \quad (2.5)$$

2.2.2.3. Çarpıklık

Çarpıklık, istatistiksel veri kümesindeki normal dağılımdan simetri olmayanları tanımlamak için kullanılan bir terimdir [72]. Veri noktalarının soldan çarpılarak negatif veya sağdan çarpılarak pozitif olup olmadığına bağlı olarak çarpıklık, negatif veya pozitif çarpıklık olarak tanımlanabilir. Bir $m(n)$ işareti için Denklem 2.6'da çarpıklık verilmiştir. Burada \bar{m} , 1'den c ' ye kadarki m değerlerinin aritmetik ortalamasıdır.

$$\zeta = \frac{\frac{1}{c} \sum_{n=1}^c (m(n) - \bar{m})^3}{\left(\frac{1}{c} \sum_{n=1}^c (m(n) - \bar{m})^2\right)^{\frac{3}{2}}} \quad (2.6)$$

2.2.2.4. Basıklık

K. Pearson tarafından ilk defa açıklanmış olan Basıklık veri dağılımını inceleyerek verilerin tepe noktalarının durumu hakkında bilgi veren istatistiksel bir ölçüttür. Ayrıca veri dağılımının “dikliğini” veya “düzgünlüğünü” de inceleyen yöntem olarak ifade edilebilir [72]. Basıklığın sıfıra yakın olması dağılımın normal olduğunu, basıklığın pozitif değerlere sahip olması ise normalden dik bir dağılımın olduğunu gösterir. Bir $m(n)$ işareti için Denklem 2.7'de basıklık ifadesi verilmiştir. Burada \bar{m} , 1'den c ' ye kadarki m değerlerinin aritmetik ortalamasıdır.

$$B = \frac{\frac{1}{c} \sum_{n=1}^c (m(n) - \bar{m})^4}{\left(\frac{1}{c} \sum_{n=1}^c (m(n) - \bar{m})^2\right)^2} \quad (2.7)$$

2.2.2.5. Varyans

Dağılım ölçümü olan varyans, bir veri kümesindeki değerlerin ortalamaya göre dağılımını gösterir. Bir $m(n)$ işareti için 1'den c ' ye kadarki varyans ifadesi Denklem 2.8'de verilmiştir.

$$V = \frac{1}{c} \sum_{n=1}^c (m(n) - \bar{m})^2 \quad (2.8)$$

2.2.2.6. Özbağlanım Yöntemi

Özbağlanım, gelecek değerlerin geçmiş değerlerin ağırlıklı toplamına bağlı olarak tahmin edildiği bir yöntemdir ve istatistiksel hesaplamalarda kullanılır [73]. Bu yöntem geçmiş değerlerin mevcut değerler üzerinde bir etkiye sahip olduğu önermesine göre çalışır. Denklem 2.9'da verildiği gibi bir $H(n)$ sinyali için A_{k1} birinci derece geçerli işlemdir, A_{k2} işlemi ise önceki iki değere dayanan geçerli değeri taşır.

$$H(n) = A_{k1}H(n-1) + A_{k2}H(n-2) + \dots + A_{kp}H(n-p) + e(n) \quad (2.9)$$

Burada p modelin düzenini, $A_{k1}, A_{k2}, \dots, A_{kp}$ özbağlanım katsayılarını, $e(n)$ tahmin hatasını ifade etmektedir. Tahmin hata değerlerinin zaman dizisi beyaz bir gürültü çıkarsa, analiz edilen süreç gerçek bir özbağlanım sinyalidir.

2.2.3. Sınıflandırma Yöntemleri

Benzer özelliğe sahip nesnelerin bilinen alt gruplara ayrılması işlemine sınıflandırma denir. Böylece bir veri kümesinde bulunan çeşitli sınıflar arasında veri dağıtılır.

Sınıflandırma için dağılım öncelikle eğitim kümesinde gerçekleştirilerek veriler eğitilir. Daha sonra eğitilen bu dağılım şeklini öğrenerek sınıfı belirli olmayan test kümesi sınıflandırılmaya çalışılır. Bir sınıflandırma işlemi sonunda hesaplanan gerçek ve tahmini sınıflandırmalar hakkındaki bilgi Tablo 2.2’de verilen hata matrisi ile gösterilir.

Tablo 2.2. Hata matrisi

Hata Matrisi		Gerçek Sınıf	
		1.Sınıf	2.Sınıf
Tahmini Sınıf	1.Sınıf	D1	H2
	2.Sınıf	H1	D2

D1: 1. Sınıf olarak bilinen sınıfların 1. Sınıf olarak sınıflandırılma sayısı

D2: 2. Sınıf olarak bilinen sınıfların 2. Sınıf olarak sınıflandırılma sayısı

H1: 1. Sınıf olarak bilinen sınıfların 2. Sınıf olarak sınıflandırılma sayısı

H2: 2. Sınıf olarak bilinen sınıfların 1. Sınıf olarak sınıflandırılma sayısı

Hata matrisinden faydalarak hesaplanan sınıflandırma doğruluğunun eşitliği Denklem 2.10’da verilmiştir.

$$\text{Sınıflandırma Doğruluğu} = \frac{D1 + D2}{D1 + H1 + D2 + H2} \times 100 \quad (2.10)$$

Duyarlılık bir test kümesindeki 1. sınıflar içersinden gerçek sınıfların ayırabilme yeteneği olarak tanımlanırken, Özgüllük test kümesindeki 2. sınıflar içersinden gerçek sınıfların ayırabilme yeteneği olarak tanımlanır. Burada Duyarlılık ve Özgüllük Denklem 2.11 ve 2.12’de verilmiştir. Test sınıflandırılması sonucunda duyarlılığın %100 hesaplanması, o testin tüm 1. sınıflarının Özgüllüğün %100 hesaplanması ise o testin tüm 2. sınıflarının doğru olarak sınıflandırıldığını gösterir.

$$\text{Duyarlılık} = \frac{D1}{D1 + H1} \times 100 \quad (2.11)$$

$$\text{Özgüllük} = \frac{D2}{D2 + H2} \times 100 \quad (2.12)$$

Bu tez çalışmasında iki sınıflı ve dört sınıflı veriler ile çalışılmıştır. Dört sınıflı veriler için karar ağaç yapısı uygulandığı için Veri Kümesi 3 için de ikili sınıflandırma gerçekleştirilmiştir. Bu veri kümeleri k-EYK, DVM, DAA ve kısmi en küçük kareler regresyonu (KEKK) yöntemleriyle sınıflandırılmıştır. Bu yöntemler aşağıda açıklanmıştır.

2.2.3.1. k-En Yakın Komşuluk Yöntemi

Sınıflandırma ve regresyon için kullanılan bir yöntem olan k-en yakın komşuluk yöntemi, ilk olarak 1970'lerin başında parametrik olmayan bir teknik olarak istatistiksel tahmin ve örüntü tanımada kullanılmıştır [51]. Bu yöntem tüm mevcut durumları saklar ve benzerlik ölçüsüne dayalı olarak yeni durumları sınıflandırır. Böylece test verileri için tüm eğitim verilerinin birbirine uzaklıklarını hesaplar. Bu hesaplama öklid, manhattan, minkosvki ve şehir bloğu gibi birçok uzaklık ölçütü ile yapılabilir. Bu çalışmada literatürde de sık tercih edilen öklid ve şehir bloğu uzaklık ölçütleri kullanılarak sınıflandırma hesabı yapılmıştır. Denklem 2.13 ile öklid uzaklık ölçütü, Denklem 2.14 ile şehir bloğu uzaklık ölçütü verilmiştir. c tane r ve t noktaları için verilen bu eşitlikte, $d_{\bar{o}}$ bu noktalar arasındaki öklid uzaklığını, d_{sb} ise bu noktalar arasındaki şehir bloğu uzaklığını ifade etmektedir.


$$d_{\bar{o}}(r, t) = \sqrt{\sum_{i=1}^c (m_{ri} - m_{ti})^2} \quad (2.13)$$

$$d_{sb}(r, t) = \sum_{i=1}^c |a_{ri} - b_{ti}| \quad (2.14)$$

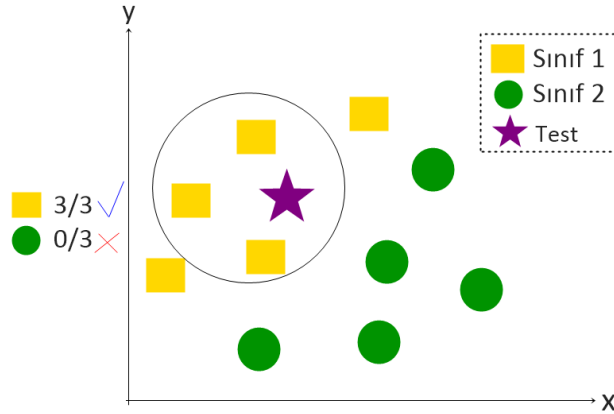
k- EYK yöntemi için basit bir uygulama Şekil 2.5'de verilmiştir. Burada öznitelikler sarı sınıflı kareler ve yeşil sınıflı daireler olarak dağılmıştır.

Şekil 2.5'te mor yıldızın sınıfı öğrenilmek istenmektedir. Burada mor yıldız sarı renkli kare veya yeşil renkli daire sınıflarından biridir. " k " ise k-EYK yöntemi için en yakın komşu değeridir. Eğer $k = 3$ ise Şekil 2.6'da verildiği gibi mor yıldız ile birlikte, daire yalnızca üç veri noktasını içine alacak büyüklükte olacaktır. Burada mor yıldızın en yakın üç nokta, sarı kare sınıflardır. Bu nedenle, büyük olasılık mor yıldızın sarı kare sınıfa

ait olması gerektiğini göstermektedir. Böylece en yakın komşudaki üç sınıf da sarı kare sınıfa gittiğinden mor yıldızın sınıfı açık bir şekilde sarı kare sınıf olarak belirlenir.



Şekil 2.5. Sarı sınıflı kareler ve yeşil sınıflı dairelerden oluşan öznitelikler



Şekil 2.6. k-EYK yöntemi için veri sınıflandırması

k-EYK yönteminde önemli noktalardan biri de en iyi k parametresinin belirlenmesidir. Bu tez çalışmada rastgele alt örnekleme (random subsampling) yöntemi ile en ideal k parametresi her bir veri kümesi için belirlenmiştir.

2.2.3.2. Destek Vektör Makineleri Yöntemi

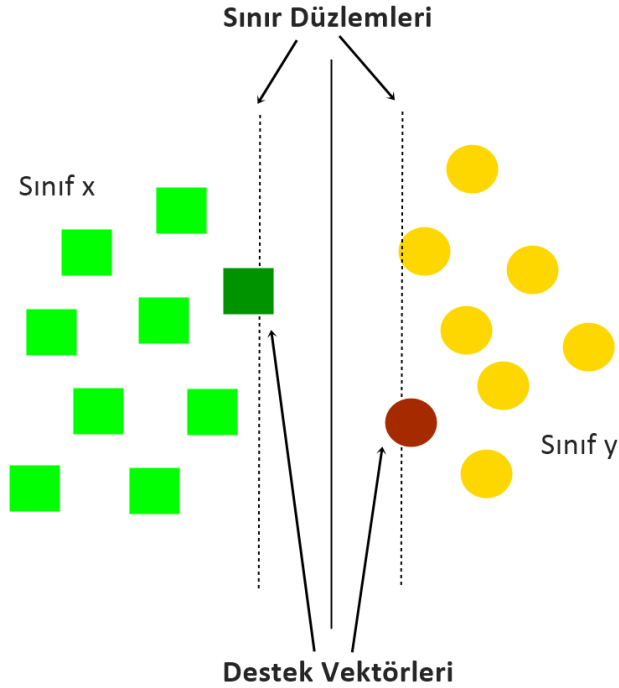
Destek Vektör Makineleri, sınıflandırma ve regresyon analizi için kullanılan veriyi analiz eden etkili ve basit sınıflandırma yöntemlerinden birisidir. Bir dizi eğitim örneği göz

önüne alındığında, her iki sınıftan her biri bir sınıfa ait olmalıdır. Bir düzlem üzerinde bu sınıflar arasına çizilen sınır çizgisi yardımıyla sınıflar birbirinden ayrılabilir [44]. İki sınıfın da üyelerine en uzak mesafede olan bu çizgi DVM yöntemi ile belirlenir. Sınır çizgisi olarak adlandırılan bu çizgi, iki gruba yakın ve birbirine paralel olarak çizilen iki çizginin orta sınır çizgisidir. İki grup arası çizilecek olan bu sınır çizgisi Denklem 2.15’de verilmiştir. Burada girişler i olarak ifade edilirken p ve m sırasıyla ağırlık ve eğim olarak ifade edilmiştir.

$$D(x) = pi + m \quad (2.15)$$

Şekil 2.7’de iki sınıflı bir veri kümesi için örnek bir destek vektörleri ile hiper düzlemin gösterimi yapılmıştır. Burada her iki sınıfa yakın olan kesikli çizgiler sınır düzlemlerini belirtirken tam ortalarından geçen doğru, sınır çizgisini ifade etmektedir. Burada sınır düzlemlerinin sınır çizgisine olan uzaklıkları eşittir ve sınır düzlemleri üzerinde bulunan sınıflar destek vektörleri olarak tanımlanmaktadır.

Bu tez çalışmasında DVM yöntemi için sigma parametresi rastgele alt örnekleme yöntemi ile her bir veri kümesi için ideal olarak seçilmiştir.



Şekil 2.7. DVM için iki sınıflı problem örneği

2.2.3.3. Doğrusal Ayırma Analizi Yöntemi

Doğrusal Ayırma Analizi iki veya daha fazla örnek sınıfı en iyi şekilde ayırarak doğrusal özellikli bir birleşim bulmaya çalışır. Elde edilen birleşim daha sonra lineer bir sınıflandırıcı olarak kullanılır. Bu yöntem ile hangi iki veya daha fazla sınıflı gruplar arasında ayırım yapılacağı belirlenebilmektedir [45]. Ayrıca DAA, diğer ölçümlerin doğrusal bir birleşimi olarak bağımlı değişkeni ifade etmeye çalışan varyans analizi ve regresyon analizi ile yakından ilişkilidir. İki sınıflı bir veri kümesindeki iki sınıfın ayrı ayrı ortalaması h_1 ve h_2 olarak, kovaryans matrisi ise C_1 ve C_2 olarak tanımlanırsa bunların toplanmış kovaryans matrisi C_{12} Denklem 2.16'daki gibi tanımlanır.

$$C_{12} = \frac{1}{k_1 + k_2} (k_1 C_1 + k_2 C_2) \quad (2.16)$$

Burada k_1 ve k_2 sırasıyla veri kümesindeki iki sınıfın boyutunu belirtmektedir. Burada doğrusal model katsayıları ise Denklem 2.17'deki gibi gösterilmiştir.

$$LMK = C_{12}^{-1} (h_1 - h_2) \quad (2.17)$$

DDA analizi için Denklem 2.16 ve 2.17'den elde edilen sonuçlara göre eğer Denklem 2.18'deki şart sağlanırsa yeni gelen bir özellik sınıflandırılır. Burada m veri vektörünü ifade etmektedir.


$$LMK^T \left(m - \left(\frac{h_1 + h_2}{2} \right) \right) > \log \frac{(1. Sınıf Olasılığı)}{(2. Sınıf Olasılığı)} \quad (2.18)$$

2.2.3.4. Kısmi En Küçük Kareler Regresyonu

Herman Wold tarafından 1966'da ortaya atılan kısmi en küçük kareler regresyonu istatistiksel bir yöntemdir. Bu yöntem iki veya daha fazla değişken arasındaki bağlantıyı ölçmek için kullanılır ve bu tez çalışmasında sınıflandırıcı olarak kullanılmıştır [74]. Bu yöntem A açıklayıcı ve B bağımlı olmak üzere iki değişken matrisi ile ilgilenmektedir. Bu matrisler arasındaki ilişki Denklem 2.19'da verilmiştir.

$$A = Bx + y \quad (2.19)$$

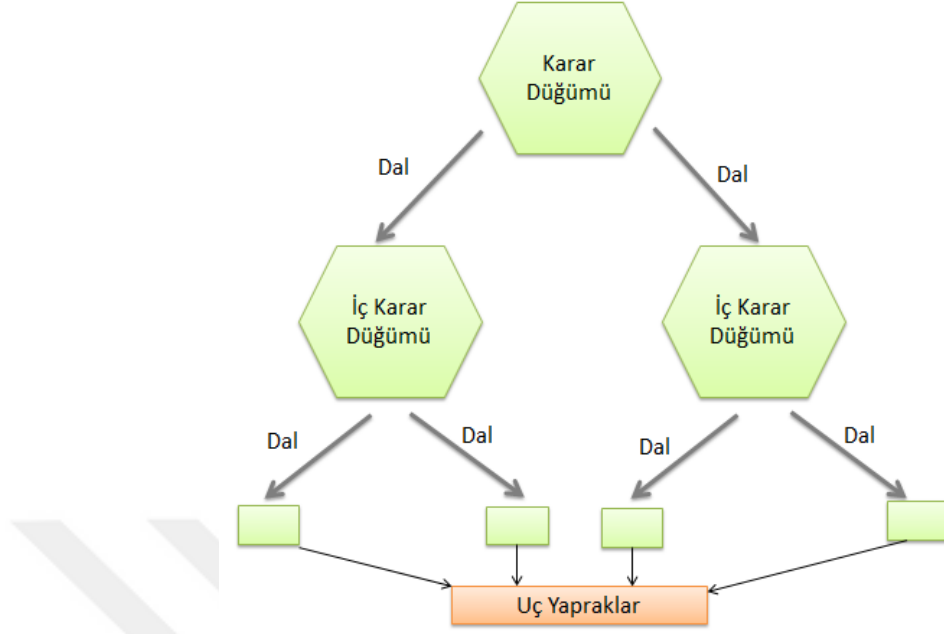
Denklem 2.19'da x ve y sayıları hesaplanan sonuç için en doğru değerleri temsil etmektedir. Burada amaç A ve B matrisleri için oluşturulan veri noktalarına en yakın geçecek olan tek bir doğru denklemi elde etmektir. En küçük kareler regresyonu için oluşturulan grafik Şekil 2.8'de verilmiştir. Burada ölçüm ile hesaplanan veri noktaları, mor kare şekiller ile en küçük kareler yöntemi için bulunan teorik bağlantı (doğru) ise yeşil doğrusal çizgi ile belirtilmektedir.



Şekil 2.8. En küçük kareler yöntemi için grafik

2.2.4. Karar Ağaç Yapısı

Veri madenciliğinde makine öğrenmesi yaklaşımlarından biri olan karar ağaç yapısı sınıflandırma ve tahmin için sıkça kullanılır. Bu yapı kolay yorumlanması ve anlaşılabilirliği açısından avantajlıdır. Karar ağaç yapısı iç karar düğümleri, dal ve uç yapraklar olmak üzere üç kısımdan oluşur [8]. Bu kısımları belirten karar ağaç modeli Şekil 2.9'da verilmiştir. Burada iç karar düğümleri ile giriş verileri test edilerek hangi yöne yöneleceğine dair sorular sorulur, dallar ile bu soruların cevapları ifade edilir ve uç yapraklar ile sınıf etiketleri belirtilir. Bu yöntem direk kullanılmamış, bundan esinlenerek ağaç yapısının düğümleri için en iyi sınıflandırıcı ve öznitelikler ile 4 sınıflı problem çözülmüştür.

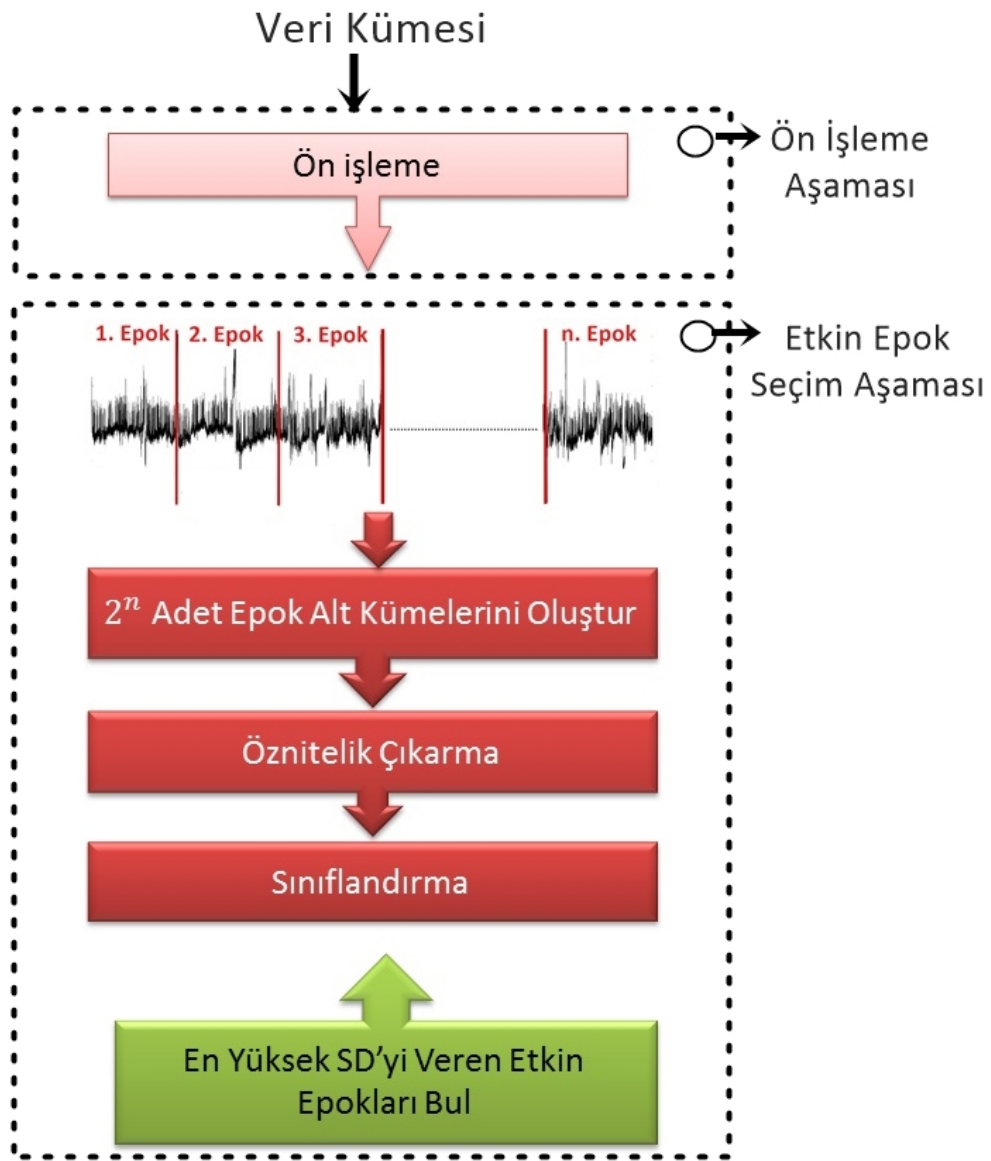


Şekil 2.9. Karar ağaç yapısı

2.3. Önerilen Yöntem

Bu tez çalışmasında genel yöntem olarak 3 EEG veri kümesine Şekil 2.10’da verilen algoritma uygulanmıştır. Burada Veri Kümesi 1 ve Veri Kümesi 2 öncelikle HOF ile ön işlem aşamasından geçirilip etkin epok seçimi aşamasına geçerken, Veri Kümesi 3’e ön işlem aşaması uygulanmadan etkin epok seçimi aşamasına geçilmiştir. Aydemir doktora tezinde Veri Kümesi 3’e herhangi bir ön işlem uygulamadığı için burada Aydemir’in tezinde uyguladığı aynı şartlar ile yarışmak amaçlanmıştır. Etkin epok seçimi aşamasında Veri Kümesi 1 ve Veri Kümesi 2 0.25 saniyelik epoklara, Veri Kümesi 3 ise 0.5 saniyelik epoklara bölünmüştür. 3.5 saniye (896 örnek) uzunluğunda olan Veri Kümesi 1’in 0.25 saniyelik epoklara bölünmesiyle 14 epok, 3 saniye (3000 örnek) uzunluğunda olan Veri Kümesi 2’nin 0.25 saniyelik epoklara bölünmesiyle 12 epok ve 8 saniye (2048 örnek) uzunluğunda olan Veri Kümesi 3’ün 0.50 saniyelik epoklara bölünmesiyle 16 epok elde edilmiştir. Bu aşamada epok uzunlukları her bir veri kümesinin veri uzunluklarına bağlı olarak en uygun şekilde seçilmiştir. Şekil 2.10’da verildiği gibi veri kümelerinin epokları sırasıyla 1., 2., 3.....n. olarak isimlendirilmiştir. Burada n her bir veri kümesinin son epogunu temsil etmektedir. Veri kümeleri epoklara bölündükten sonra her bir veri

kümesinin n sayıda elemanı için altküme (2^n sayıda altküme) oluşturulur. Daha sonra veri kümelerinin alt kümeleri sırasıyla her bir veri kümesi için bu tez çalışmasında belirlenen öznitelik ve sınıflandırma yöntemlerine uygulanarak SD hesaplanır. Bu sınıflandırma sonucu sırasıyla Veri Kümesi 1, Veri Kümesi 2 ve Veri Kümesi 3 için en yüksek SD'yi veren alt kümeyi oluşturan epoklar etkin olarak seçilerek algoritma sonlanır. Burada tüm veri kümeleri Şekil 2.10'da verilen algoritmaya başarılı bir şekilde ayrı zamanlı olarak uygulanmıştır ve yapılan hesaplamalar ile sonuçlar *Bulgular* başlığı altında her bir veri kümesi için ayrıntılı olarak verilmiştir.



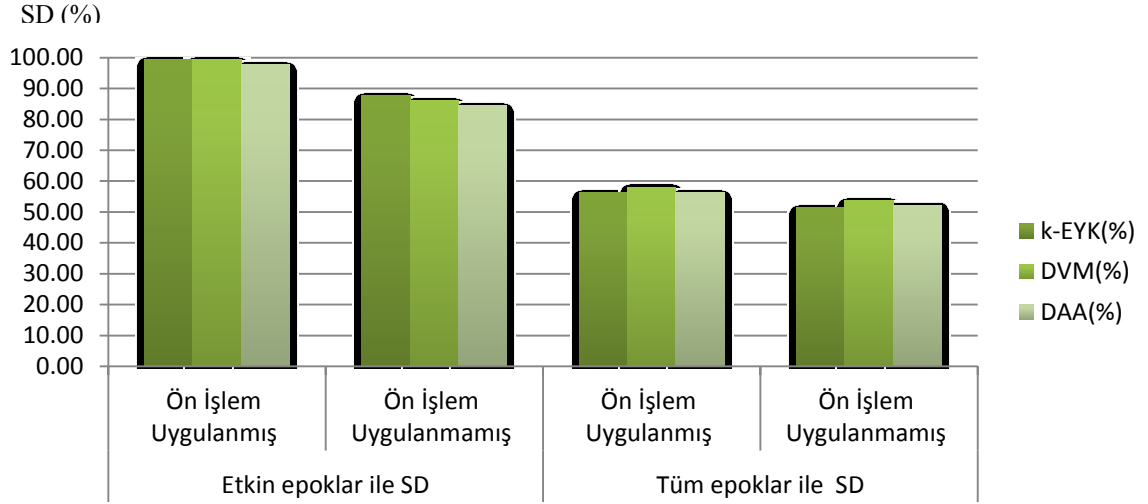
Şekil 2.10. Etkin epokların seçimi için önerilen yöntemin blok şeması

3. BULGULAR

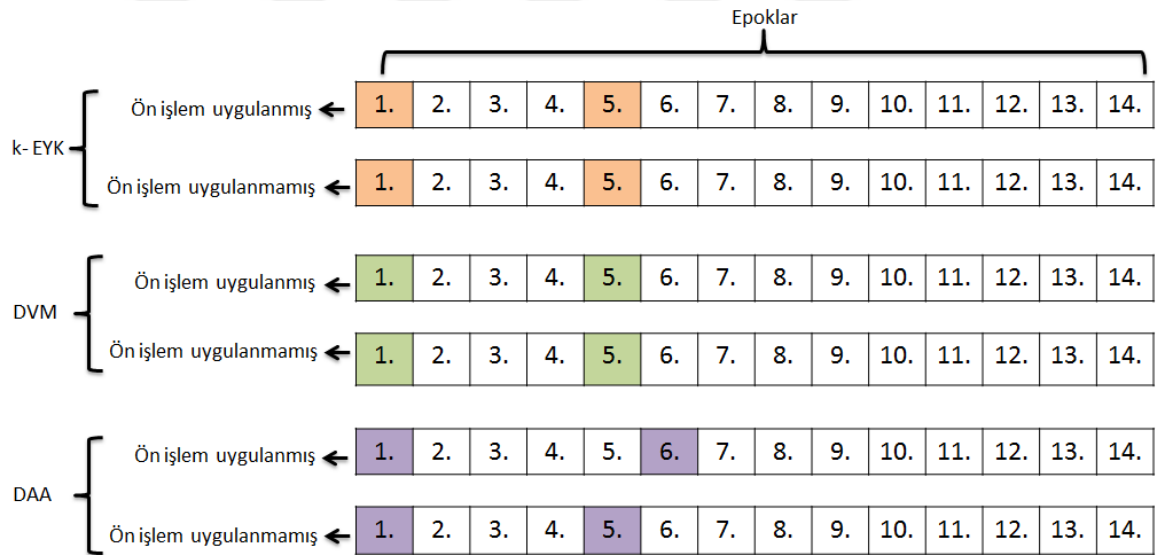
3.1. Veri Kümesi 1 ile Elde Edilen Bulgular

Bu tez çalışması için Şekil 2.10'da verilen algoritma genel yöntem olarak Veri Kümesi 1'e uygulanmıştır. Etkin zaman dilimlerinin tespiti için oluşturulan algoritmada EEG veri kümesinin her bir denemesinden Denklem 2.5'de verilen ortalama türev tabanlı öznelikler çıkartılmıştır. Veri Kümesi 1 için etkin olan 1. ve 3. elektrotlar ile toplamda iki öznelik hesaplanarak daha sonra çıkarılan öznelikler sırasıyla k-EYK, DVM ve DAA yöntemleriyle sınıflandırılarak bu sınıflandırıcılar için performans karşılaştırması yapılmıştır.

Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1'e Şekil 2.10'daki algoritma ortalama türev tabanlı öznelik yöntemi ile birlikte ve sırasıyla k-EYK, DVM ve DAA sınıflandırıcıları için uygulanmıştır. Bu işlemin sonunda seçilen etkin zaman dilimleri ile hesaplanan SD'ler ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için Şekil 3.1'de verilmiştir. Ayrıca ön işlem uygulanmış ve ön işlem uygulanmamış EEG veri kümesi için seçilen etkin zaman dilimleri Şekil 3.2'de verilmiştir. Şekil 3.2'de verilen etkin zaman dilimleri ile Şekil 3.1'de verildiği gibi ön işlem uygulanmış Veri Kümesi 1 ile k-EYK, DVM ve DAA sınıflandırıcıları için sırasıyla %99.31, %99.31 ve %97.61 SD hesaplanırken, ön işlem uygulanmamış Veri Kümesi 1 ile sırasıyla %87.73, %86.00 ve %84.30 SD hesaplanmıştır. Ön işlem uygulanmış veri kümesiyle hesaplanan SD'lerin ön işlem uygulanmamış SD'lerden sırasıyla %11.58, %13.31 ve %13.31 daha fazla olması ön işlem aşamasının bu veri kümesi için etkin olduğunu göstermektedir. Ayrıca, bu tez çalışması için etkin zaman dilimi seçiminin yüksek başarılı olduğunu göstermek için ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1'in her bir denemesinin tüm örnekleri ile de belirlenen öznelik ve sınıflandırıcı yöntemleriyle SD'ler hesaplanarak Şekil 3.1'de verilmiştir. Burada ön işlem uygulanmış Veri Kümesi 1'den k-EYK, DVM ve DAA sınıflandırıcıları için sırasıyla %56.31, %58.05 ve %56.31 SD hesaplanırken, ön işlem uygulanmamış Veri Kümesi 1 için sırasıyla %51.53, %53.58 ve %52.21 SD hesaplanmıştır.




Şekil 3.1. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için etkin epoklarla ve tüm epoklarla hesaplanan SD değerleri




Şekil 3.2. Veri Kümesi 1’de k-EYK, DVM ve DAA sınıflandırıcıları için seçilen etkin epoklar

Şekil 3.3 ve Şekil 3.4’te verildiği gibi ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için etkin zaman dilimleriyle ve tüm zaman dilimleriyle ayrıca Duyarlılık (DU) ve Özgüllük (ÖZ) değerleri hesaplanmıştır. Ön işlem uygulanmış Veri Kümesi 1 ile etkin zaman dilimleriyle k-EYK, DVM ve DAA sınıflandırıcıları için %100 DU ve k-EYK ile DVM sınıflandırıcıları için %97.94, DAA sınıflandırıcısı için %95.20 ÖZ değerleri hesaplanmıştır. Ancak tüm zaman dilimleriyle sırasıyla k-EYK, DVM ve DAA sınıflandırıcıları için %56.46, %59.86, %59.86 DU ve %52.05, %51.36,

%52.73 ÖZ değerlerine ulaşılmıştır. Ayrıca, Ön işlem uygulanmamış Veri Kümesi 1 ile etkin zaman dilimleriyle k-EYK, DVM ve DAA sınıflandırıcıları için sırasıyla %91.83, %91.15, %89.79 DU ve %80.13, %81.50, %73.97 ÖZ değerleri hesaplanırken, tüm zaman dilimleriyle aynı sınıflandırıcılar ile sırasıyla %56.46, %59.86, %59.86 DU ve %47.26, %51.70, %52.05 ÖZ değerlerine ulaşılmıştır.



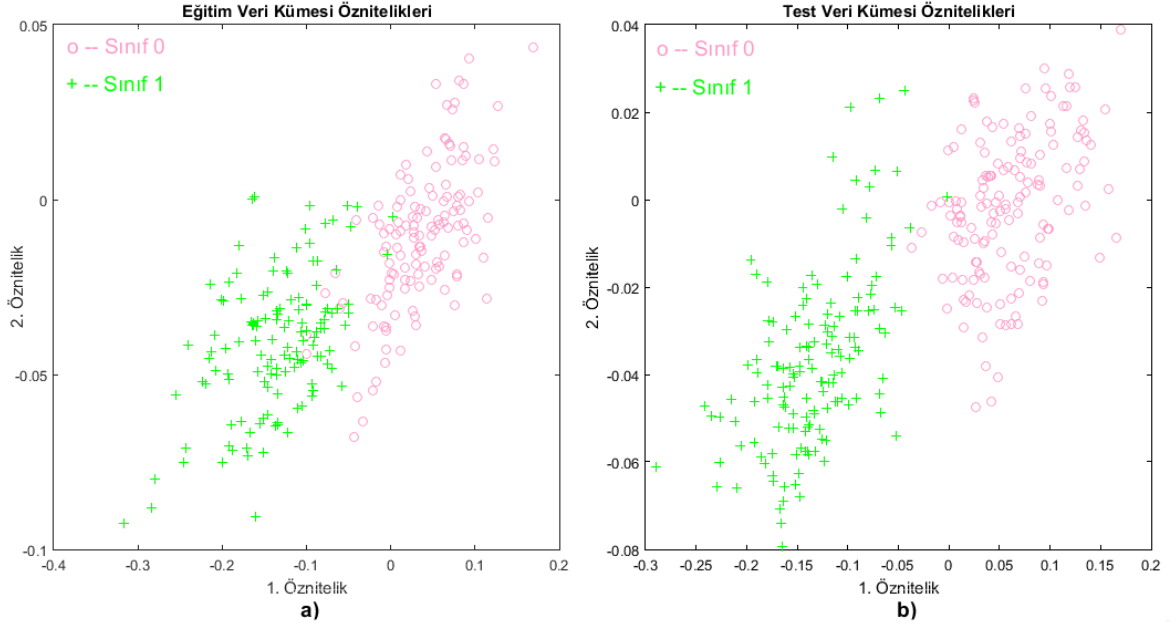
Şekil 3.3. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için etkin epoklarla ve tüm epoklarla hesaplanan DU değerleri



Şekil 3.4. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 1 için etkin epoklarla ve tüm epoklarla hesaplanan ÖZ değerleri

Şekil 3.1 ve Şekil 3.2’de verilenlere göre en yüksek SD ön işlem uygulanmış Veri Kümesi 1 için k-EYK ve DVM sınıflandırıcıları ile 1. ve 5. epokları için %99.31 olarak hesaplandığından, sadece bu zaman dilimleri ile sınıf 0 ve sınıf 1’i ayırmak için hesaplanan

öznitelikler Şekil 3.5'te verilmiştir. Şekil 3.5 a)'da verilen grafik eğitim verileriyle hesaplanan öznitelikleri gösterirken, Şekil 3.5 b)'de verilen grafik test verileriyle hesaplanan öznitelikleri göstermektedir. Şekil 3.5'deki grafiklerden anlaşılacağı gibi ortalama türev tabanlı öznitelikler ve seçilen 1. ve 5. epoklar Veri Kümesi 1 için etkin özelliklerdir.



Şekil 3.5. Eğitim ve test verileri için hesaplanan öznitelikler

Bu tez çalışmasında önerilen yöntem ile sadece SD artırılmamış, aynı zamanda Tablo 3.1'de verildiği gibi öznitelik çıkarma aşamasındaki hesaplama süresi (ÖÇS) de azaltılmıştır. Şekil 3.2'de gösterildiği gibi k-EYK, DVM ve DAA sınıflandırıcıları için 2 tane etkin epok seçildiğinden bu sınıflandırıcıların hepsi için etkin epoklar ile birlikte 18.82 milisaniye (msn) ÖÇS hesaplanırken, tüm zaman dilimleriyle 33.90 msn ÖÇS hesaplanmıştır. Intel i5 işlemcili, 4 GB RAM bilgisayar ile Matlab R2015a ortamında gerçekleştirilen hesaplamalara göre ÖÇS tüm sınıflandırıcılar için %44.7 oranında azaltılmıştır.

Seçilen etkin epoklar ile DVM, k-EYK ve DAA sınıflandırıcı için test verileri üzerindeki hata matrisleri sırasıyla Tablo 3.2'de a), b) ve c)'de verilmiştir. Burada k-EYK, DVM ve DAA sınıflandırıcı için %100.00 sınıf 0 doğru sınıflandırılmıştır. Ayrıca k-EYK ve DVM sınıflandırıcıları için %97.94, DAA sınıflandırıcısı için %92.46 sınıf 1 doğru

sınıflandırılırken, k-EYK ve DVM sınıflandırıcıları için %2.05, DAA sınıflandırıcısı için %7.53 sınıf 1 bilgisi sınıf 0 olarak sınıflandırılmıştır.

Tablo 3.1. Veri Kümesi 1 için öznitelik çıkarım süreleri

k-NN-DVM-DAA	ÖÇS (msn)
Etkin Zaman Dilimleriyle	18.82
Tüm Zaman Dilimleriyle	33.90
Hesaplama Süresi Azaltım Oranı	%44.7

Tablo 3.2. Sınıflandırıcılar için hata matrisleri, (a) k-EYK, (b) DVM, (c) DAA

k-EYK		Gerçek Sınıf		DVM		Gerçek Sınıf	
		Sınıf 0	Sınıf 1			Sınıf 0	Sınıf 1
Tahmini Sınıf	Sınıf 0	%100.00	%2.05	Tahmini Sınıf	Sınıf 0	%100.00	%2.05
	Sınıf 1	%0.00	%97.94		Sınıf 1	%0.00	%97.94

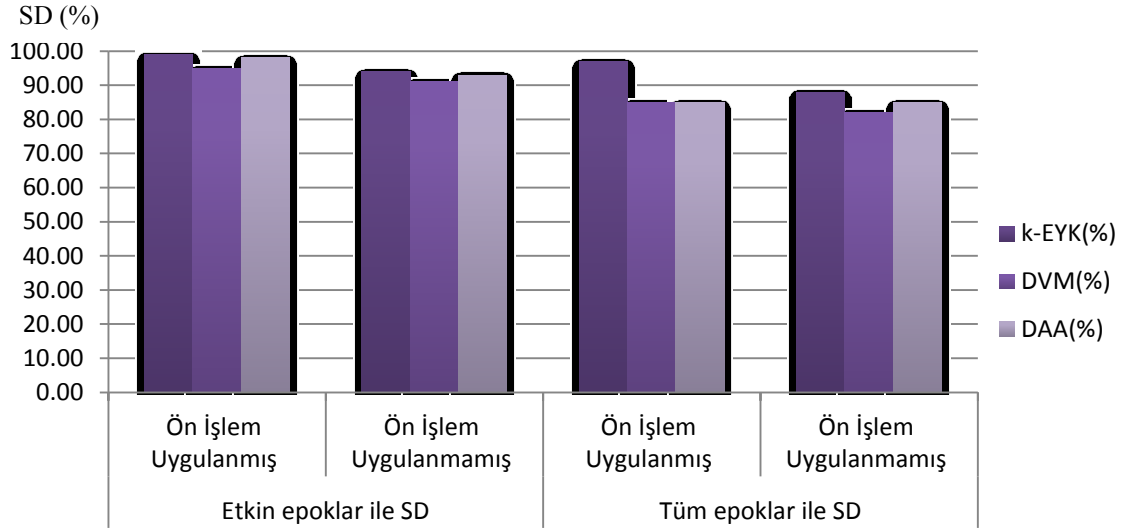
DAA		Gerçek Sınıf	
		Sınıf 0	Sınıf 1
Tahmini Sınıf	Sınıf 0	%100.00	%7.53
	Sınıf 1	%0.00	%92.46

3.2. Veri Kümesi 2 ile Elde Edilen Bulgular

Bu tez çalışması için Şekil 2.10'da verilen algoritma genel yöntem olarak Veri Kümesi 2'ye uygulanmıştır. Etkin zaman dilimlerinin tespiti için oluşturulan algorithmada ECoG veri kümesinin her bir denemesinden Dalgacık Dönüşümü tabanlı öznitelikler çıkartılmıştır. Dalgacık dönüşümü katsayılarının Denklem 2.3 ve Denklem 2.4'de verildiği gibi sırasıyla ortalaması ve standart sapması alınmış ve Veri Kümesi 2 için etkin olan 12. ve 38. elektrotlar ile birlikte toplamda dört öznitelik hesaplanmıştır. Bu öznitelikler Morlet dalgacığında alfa+beta bant aralığından hesaplanmıştır. Daha sonra çıkarılan öznitelikler sırasıyla k-EYK, DVM ve DAA yöntemleriyle sınıflandırılmıştır.

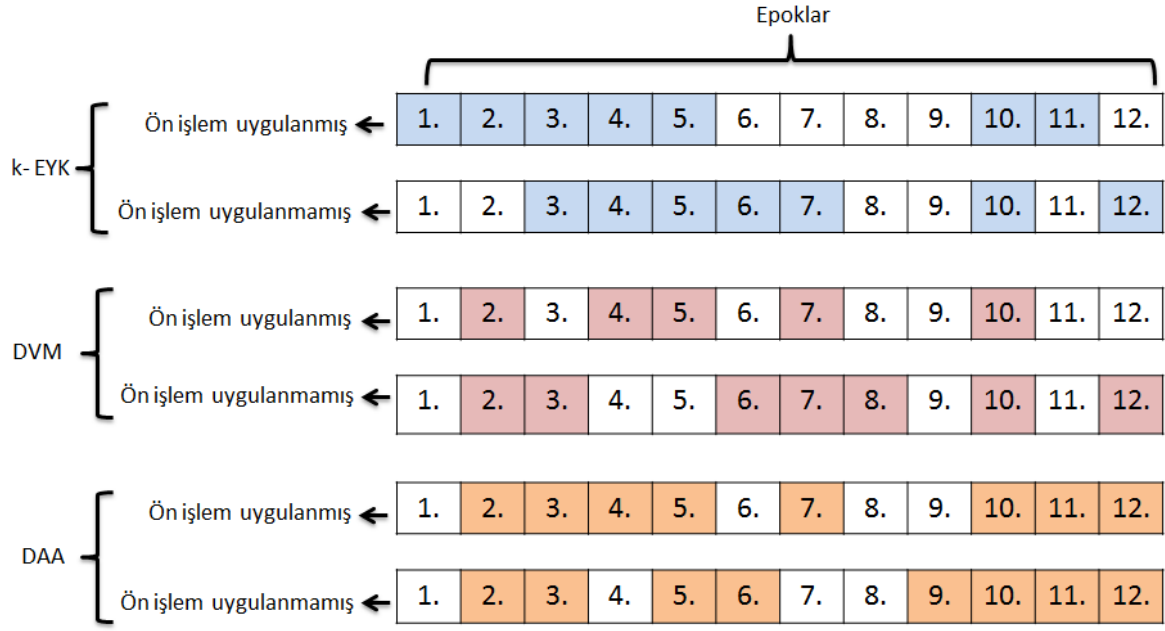
Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2'ye Şekil 2.10'daki algoritmanın uygulanmasıyla etkin zaman dilimleri seçilmiş ve bu zaman dilimlerinden çıkarılan özniteliklerle k-EYK, DVM ve DAA sınıflandırıcıları için Şekil 3.6'da verilen

SD'ler hesaplanmıştır. Burada ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için seçilen etkin zaman dilimleri Şekil 3.7'de verilmiştir.




Şekil 3.6. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için etkin epoklarla ve tüm epoklarla hesaplanan SD değerleri

Şekil 3.7'de verilen etkin zaman dilimleri ile Şekil 3.6'da verildiği gibi ön işlem uygulanmış Veri Kümesi 2 ile k-EYK, DVM ve DAA sınıflandırıcıları için sırasıyla %99.00, %95.00 ve %98.00 SD hesaplanırken, ön işlem uygulanmamış Veri Kümesi 2 ile sırasıyla %94.00, %91.00 ve %93.00 SD hesaplanmıştır. Ön işlem uygulanmış veri kümesiyle hesaplanan SD'ler ön işlem uygulanmamış SD'lerden sırasıyla %5.00, %4.00 ve %5.00 daha fazladır. Böylece ön işlem aşaması Veri Kümesi 2 için de etkin olduğu söylenebilir. Ayrıca, bu veri kümesi için de etkin zaman dilimi seçiminin yüksek başarılı olduğunu göstermek için ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2'nin her bir denemesinin tüm örnekleri kullanılarak, bu veri kümesi için belirlenen öznelik ve sınıflandırıcı yöntemleriyle SD'ler hesaplanarak Şekil 3.6'da verilmiştir. Burada ön işlem uygulanmış Veri Kümesi 2'den k-EYK, DVM ve DAA sınıflandırıcıları için sırasıyla %97.00, %85.00 ve %85.00 SD hesaplanırken, ön işlem uygulanmamış Veri Kümesi 2 için sırasıyla %88.00, %82.00 ve %85.00 SD hesaplanmıştır. Şekil 3.6'daki grafikten de görüldüğü gibi en yüksek SD'ler ön işlem uygulanmış Veri Kümesi 2'nin etkin zaman dilimlerinden hesaplanmıştır.




Şekil 3.7. Veri Kümesi 2’de k-EYK, DVM ve DAA sınıflandırıcıları için seçilen etkin epoklar

Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için de etkin zaman dilimleriyle ve tüm zaman dilimleriyle Şekil 3.8 ve Şekil 3.9’da verildiği gibi ayrıca DU ve ÖZ değerleri hesaplanmıştır. Ön işlem uygulanmış Veri Kümesi 2 ile etkin zaman dilimleriyle k-EYK ve DAA sınıflandırıcıları için %100 DU ve %96.00 ÖZ, DVM sınıflandırıcısı için %96.00 DU ve %92.00 ÖZ değerlerine ulaşılmıştır. Ancak, tüm zaman dilimleriyle sırasıyla k-EYK, DVM ve DAA sınıflandırıcıları için %98.00, %76.00, %100.00 DU ve k-EYK ile DVM sınıflandırıcıları için %94.00, DAA sınıflandırıcısı için %70.00 ÖZ değerleri hesaplanmıştır. Ayrıca, ön işlem uygulanmamış Veri Kümesi 2 ile etkin zaman dilimleriyle k-EYK, DVM ve DAA sınıflandırıcıları sırasıyla için %94.00, %90.00, %92.00 DU ve k-EYK ile DVM sınıflandırıcıları için %90.00, DAA sınıflandırıcısı için %94.00 ÖZ değerleri hesaplanmıştır. Daha sonra tüm zaman dilimleriyle k-EYK ile DAA sınıflandırıcıları için %90.00, DVM sınıflandırıcısı için %88.00 DU ve k-EYK, DVM ve DAA sınıflandırıcıları için sırasıyla %82.00, %76.00, %80.00 ÖZ değerleri hesaplanmıştır.




Şekil 3.8. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için etkin epoklarla ve tüm epoklarla hesaplanan DU değerleri



Şekil 3.9. Ön işlem uygulanmış ve ön işlem uygulanmamış Veri Kümesi 2 için etkin epoklarla ve tüm epoklarla hesaplanan ÖZ değerleri

Şekil 3.6 ve Şekil 3.7’de verilenlere göre en yüksek SD, ön işlem uygulanmış Veri Kümesi 2 için k-EYK sınıflandırıcısı ile 1. 2. 3. 4. 5. 10. ve 11. epoklar için %99.00 olarak hesaplandığından, sadece bu zaman dilimleri ile sınıf a ve sınıf b’yi ayırmak için hesaplanan öznelilikler Şekil 28’de verilmiştir. Şekil 3.10 a)’da verilen grafik eğitim verileri üzerindeki öznelilikleri gösterirken, Şekil 3.10 b)’de verilen grafik test verileri

üzerinde hesaplanan öz nitelikleri göstermektedir. Ayrıca burada hesaplanan 4 öz nitelikten sırasıyla x, y ve z ekseninde ilk üç öz nitelik gösterilmiştir. Şekil 3.10'daki grafikten de anlaşılacağı gibi dalgacık dönüşümü tabanlı öz nitelikler ve 1. 2. 3. 4. 5. 10. ve 11. epoklar Veri Kümesi 2 için etkin özelliktedir.



Şekil 3.10. Eğitim ve test verileri için hesaplanan öz nitelikler

Veri Kümesi 2 için ÖÇS hesaplanarak Tablo 3.3'de verilmiştir. Şekil 3.7'de verilen etkin zaman dilimlerine göre k-EYK sınıflandırıcısı için 2.95 sn, DVM sınıflandırıcısı için 2.58 sn ve DAA sınıflandırıcısı için 2.98 sn ÖÇS hesaplanırken, tüm zaman dilimleriyle 3.63 sn ÖÇS hesaplanmıştır. İntel i5 işlemcili, 4 GB RAM bilgisayar ile Matlab R2015a ortamında gerçekleştirilen hesaplamalara göre ÖÇS, k-EYK, DVM ve DAA sınıflandırıcıları için sırasıyla %18.73, %28.92 ve %17.90 oranında azaltılmıştır. Elde edilen bu sonuçlara göre sadece SD artırılmamış, aynı zamanda ÖÇS de azaltılmıştır.

Tablo 3.3. Öz nitelik çıkarım süreleri

Sınıflandırıcılar	k-NN	DVM	DAA
Etkin Zaman Dilimleriyle ÖÇS	2.95 sn	2.58 sn	2.98 sn
Tüm Zaman Dilimleriyle ÖÇS	3.63 sn	3.63 sn	3.63 sn
Hesaplama Süresi Azaltım Oranı	%18.73	%28.92	%17.90

Seçilen etkin epoklar ile DVM, k-EYK ve DAA sınıflandırıcı için test verileri üzerindeki hata matrisleri sırasıyla Tablo 3.4'te a, b ve c'de verilmiştir. Burada sınıf a bilgisi, k-EYK ve DAA sınıflandırıcıları için %100.00, DVM sınıflandırıcısı için %96.00 oranında doğru sınıflandırılmıştır. Ancak, DVM sınıflandırıcısı için sınıf a bilgisi %4.00 oranında sınıf b olarak sınıflandırılmıştır. Sınıf b bilgisi ise, k-EYK ve DAA sınıflandırıcıları için %96.00, DVM sınıflandırıcısı için %92.00 oranında doğru sınıflandırılmıştır. Ancak sınıf b bilgisi, k-EYK ve DAA sınıflandırıcıları için %4.00, DVM sınıflandırıcısı için %8.00 oranında sınıf a olarak sınıflandırılmıştır.

Tablo 3.4. Sınıflandırıcılar için hata matrisleri, (a) k-EYK, (b) DVM, (c) DAA

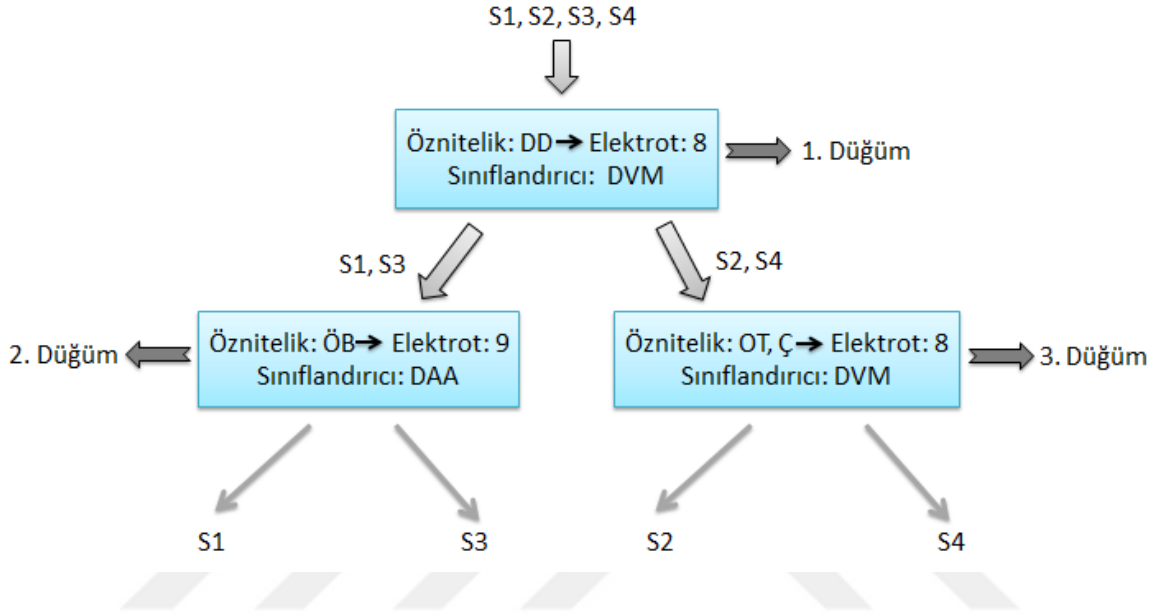
		k-EYK		DVM		DAA	
		Gerçek Sınıf		Gerçek Sınıf		Gerçek Sınıf	
		Sınıf 0	Sınıf 1	Sınıf 0	Sınıf 1	Sınıf 0	Sınıf 1
Tahmini Sınıf	Sınıf 0	%100.00	%4.00	%96.00	%8.00	%100.00	%4.00
	Sınıf 1	%0.00	%96.00	%4.00	%92.00	%0.00	%96.00

3.3. Veri Kümesi 3 ile Elde Edilen Bulgular

Bu veri kümesi Aydemir'in [8] referanslı doktora tezinde kayıt aldığı ve çalıştığı imleç hareketi hayaline dayalı elektroensefalografi işaretlerinden oluşmaktadır. Aydemir doktora çalışmasında 3 kişiden kayıt aldığı bu veri kümesine karar ağaç yapısını uygulayarak her bir kişi için 3 ağaç yapısı oluşturmuştur. Her bir kişi ve ağaç yapısı için Veri Kümesi 3'e çeşitli öznitelik ve sınıflandırıcı yöntemleri uygulayarak sınıflandırma doğruluğu hesaplamıştır. Bu tez çalışmasında Aydemir'in önerdiği öznitelik ve sınıflandırıcı yöntemlerine ek olarak sınıflandırma doğruluğu artırmak için bu veri kümesine Şekil 2.10'da verilen algoritma uygulanmıştır. Aynı öznitelik ve sınıflandırma yöntemlerine bağlı kalarak Şekil 2.10'da verilen algoritma ile yapılan hesaplamalar bu üç kişi (A, B ve C kişileri) için ayrıntılı olarak alt başlıklarda verilmiştir.

3.3.1. A Kişisi İçin Yapılan Hesaplamalar ve Bulgular

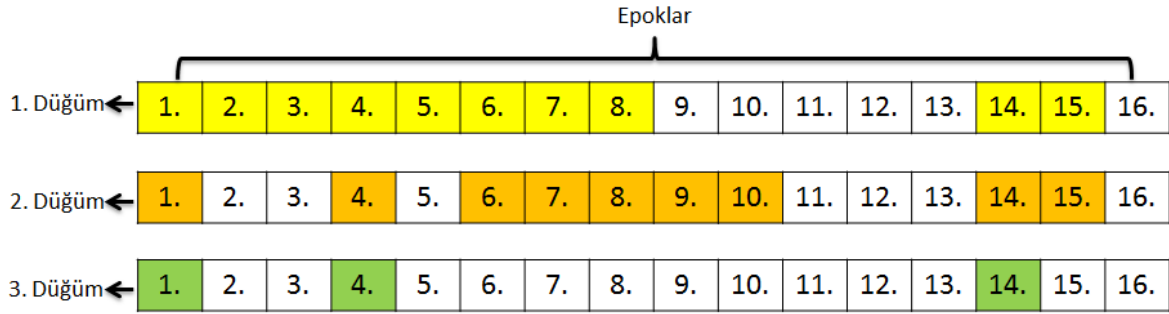
A kişi için uygulanan karar ağacı yapısı Şekil 3.11’de verilmiştir. Burada A kişisi için 3 düğüm vardır ve her bir düğüm için kullanılan öznitelik ile sınıflandırıcı yöntemleri düğüm içerisinde belirtilmiştir.



Şekil 3.11. A kişisi için karar ağacı yapısı

Burada 1. düğümde S1, S3 ile S2, S4 sınıfları dalgacık dönüşümü tabanlı özniteliklerle 8. elektrot kullanılarak DVM ile sınıflandırılmıştır. Dalgacık dönüşümü için daubechies dalgacığı 6-9 Hz bandında kullanılmış ve DVM için $\sigma = 0.6$ olarak seçilmiştir. 2. düğümde S1 ile S3 Özbağlanım tabanlı özniteliklerle 9. elektrot kullanılarak DAA ile sınıflandırılmıştır. Burada özbağlanım parametresi 8 olarak seçilmiştir. 3. düğümde ise S2 ile S4 ortalama türev ve çarpıklık tabanlı özniteliklerle 8. elektrot kullanılarak DVM ile sınıflandırılmıştır. Burada Özbağlanım parametresi 5 olarak ve DVM için $\sigma = 0.7$ olarak seçilmiştir. A kişisi için oluşturulan karar ağacı yapısında 1. düğüm için toplam 2 öznitelik, 2. düğüm için toplam 8 öznitelik ve 3. düğüm için ise toplam 2 öznitelik hesaplanmıştır.

Şekil 3.11’da verilen tüm düğümler birbirinden bağımsız bir şekilde Şekil 2.10’daki algoritmaya uygulanarak her bir düğüm için etkin epok(lar) seçilmiştir. Her bir düğüm için seçilen etkin epoklar Şekil 3.12’de verilmiştir. Burada sarı, turuncu ve yeşil işaretli epoklar sırasıyla 1. 2. ve 3. düğüm için seçilen etkin epokları belirtmektedir.



Şekil 3.12. A kişisi için seçilen etkin epoklar

Şekil 3.12’de verilen etkin epoklar ile her bir düğüm için hesaplanan test SD sonuçları Tablo 3.5’de verilmiştir. Burada Dügüm 1, 2, 3 için sırasıyla %94.73, %75.00 ve %97.36 SD hesaplanmıştır ve tüm düğümler ile karar ağacı sonunda %82.24 SD hesaplanmıştır. Tüm epoklar hesaplamaya katıldığında ise SD %16.46 oranında azalarak %65.78 SD hesaplanmıştır. Ayrıca düğüm 1 için %93.42 DU, %96.05 ÖZ, düğüm 2 için %78.94 DU, %71.05 ÖZ ve düğüm 3 için %100.00 DU, %94.73 ÖZ değerleri hesaplanmıştır.

Tablo 3.5. A kişinin her bir düğümü için etkin epoklarla hesaplanan SD, DUve ÖZ

Karar Ağacı Düğümleri	SD(%)	DU(%)	ÖZ(%)
Dügüm 1	94.73	93.42	96.05
Dügüm 2	75.00	78.94	71.05
Dügüm 3	97.36	100.00	94.73
Karar Ağacı Sonucu	82.24	76.31	90.35

Şekil 2.10’daki algoritma ile SD’yi artırmanın yanında A kişisi için ÖÇS de artırılmıştır. Her bir düğüm için hesaplanan etkin epolar ile karar ağacı sonunda 3.13 sn ÖÇS hesaplarken tüm epoklar ile 3.59 sn ÖÇS hesaplanmıştır. A kişisi için ÖÇS %12.81 azaltılmıştır. Ayrıca A kişisi için karar ağacı sonucu hesaplanan %82.84 SD için elde edilen hata matrisi Tablo 3.6’de verilmiştir.

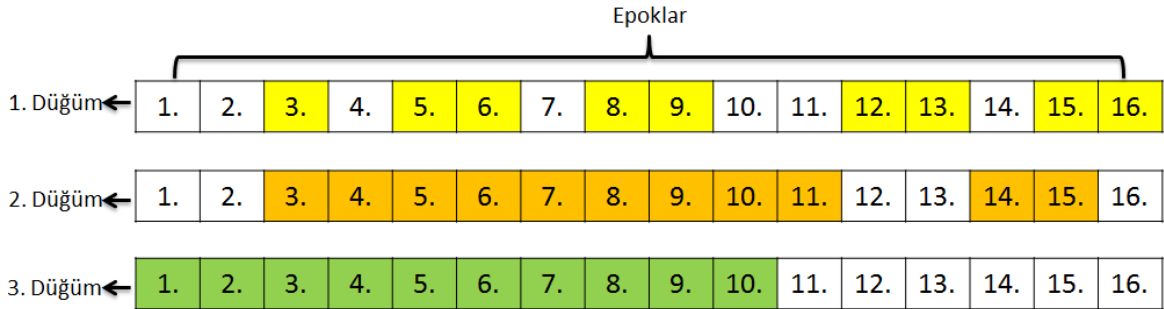
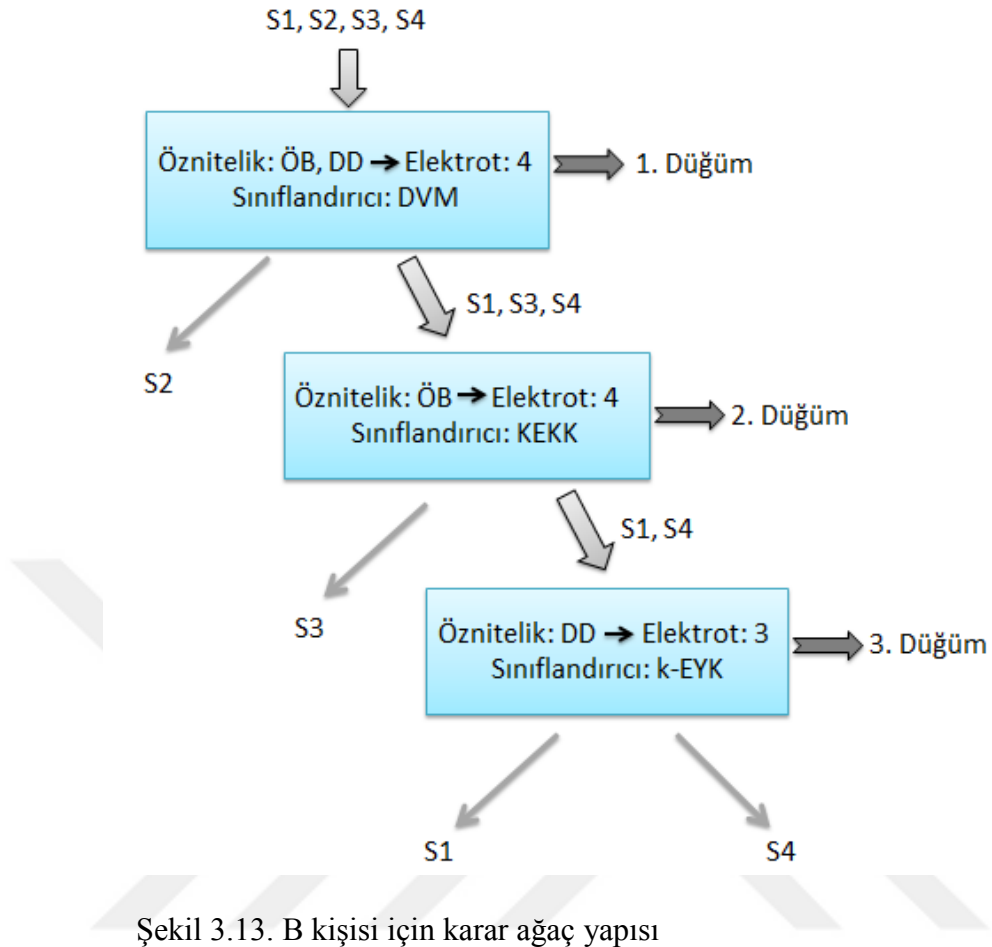
Tablo 3.6. A kişisi için hata matrisi

A Kişisi		Gerçek Sınıf			
		S1	S2	S3	S4
Hesaplanan Sınıf	S1	29	0	10	1
	S2	0	37	0	2
	S3	7	1	25	1
	S4	2	0	3	34

3.3.2. B Kişisi İçin Yapılan Hesaplamalar ve Bulgular

B kişi için uygulanan karar ağacı yapısı Şekil 3.13’de verilmiştir. Burada B kişisi için 3 düğüm vardır ve her bir düğüm için kullanılan öznitelik ile sınıflandırma yöntemleri düğüm içerisinde belirtilmiştir. Burada 1. düğümde S2 ile S1, S3, S4 özbağlanım ve dalgacık dönüşümü tabanlı özniteliklerle 4. elektrot kullanılarak DVM ile sınıflandırılmıştır. Burada dalgacık dönüşümü için morlet dalgacığı 13-40 Hz bandında kullanılmış, DVM için $\sigma = 1.9$ ve özbağlanım parametresi 4 olarak seçilmiştir. 2. düğümde S3 ile S1, S4 özbağlanım tabanlı özniteliklerle 4. elektrot kullanılarak KEKK regresyonu ile sınıflandırılmıştır. Burada özbağlanım parametresi 10 olarak seçilmiştir. 3. düğümde ise S1 ile S4 dalgacık dönüşümü tabanlı özniteliklerle 3. elektrot kullanılarak k-EYK ile sınıflandırılmıştır. Burada dalgacık dönüşümü için Morlet dalgacığı 13-40 Hz bandında kullanılmış ve k-EYK için k parametresi 25 olarak seçilmiştir. B kişisi için oluşturulan karar ağaç yapısında 1. düğüm için toplam 6 öznitelik, 2. düğüm için toplam 10 öznitelik, 3. düğüm için toplam 2 öznitelik hesaplanmıştır.

Şekil 3.13’de verilen tüm düğümler birbirinden bağımsız bir şekilde Şekil 2.10’daki algoritmaya uygulanarak her bir düğüm için etkin epok(lar) seçilmiştir. Her bir düğüm için seçilen etkin epoklar Şekil 3.14’de verilmiştir. Burada sarı, turuncu ve yeşil işaretli epoklar sırasıyla 1. 2. ve 3. düğüm için seçilen etkin epokları belirtmektedir.



Şekil 3.14. B kişisi için seçilen etkin epoklar

Şekil 3.14’de verilen etkin epoklar ile her bir düğüm için hesaplanan test SD sonuçları Tablo 3.7’de verilmiştir. Burada Düğüm 1, 2, 3 için sırasıyla %82.89, %82.45 ve %80.26 SD hesaplanmıştır ve tüm düğümler ile karar ağacı sonunda %62.50 SD hesaplanmıştır. Tüm epoklar hesaplamaya katıldığında ise SD %17.77 oranında azalarak %44.73 SD hesaplanmıştır. Ayrıca düğüm 1 için %52.63 DU, %92.98 ÖZ, düğüm 2 için

%57.89 DU, %94.73 ÖZ ve düğüm 3 için %73.68 DU, %86.84 ÖZ değerleri hesaplanmıştır.

Tablo 3.7. B kişinin her bir düğümü için etkin epoklarla hesaplanan SD, DU ve ÖZ

Karar Ağacı Düğümleri	SD(%)	DU(%)	ÖZ(%)
Düğüm 1	82.89	52.63	92.98
Düğüm 2	82.45	57.89	94.73
Düğüm 3	80.26	73.68	86.84
Karar Ağacı Sonucu	62.50	60.52	79.82

B kişisi için de SD'yi artırmanın yanında ÖÇS de arttırılmıştır. Her bir düğümü için hesaplanan etkin epolar ile 13.18 sn ÖÇS hesaplarırken tüm epoklar ile 14.48 sn ÖÇS hesaplanmıştır. B kişisi için ÖÇS %8.97 azaltılmıştır. Ayrıca B kişisi için karar ağacı sonucu hesaplanan %62.50 SD ile elde edilen hata matrisi Tablo 3.8'da verilmiştir.

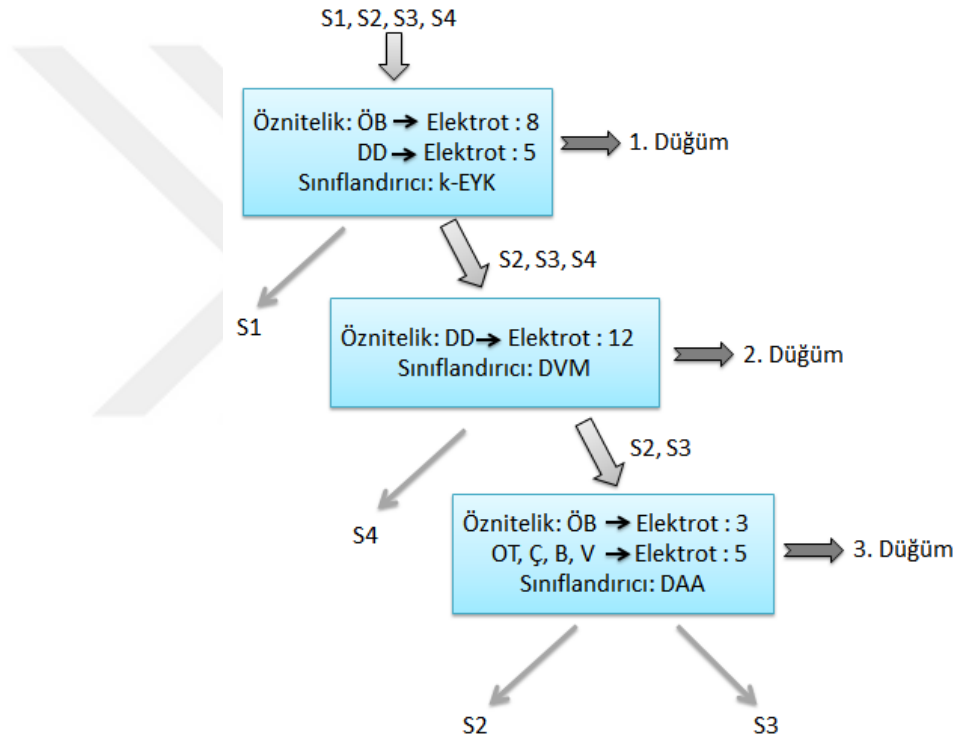
Tablo 3.8. B kişisi için hata matrisi

B Kişisi		Gerçek Sınıf			
		S1	S2	S3	S4
Hesaplanan Sınıf	S1	23	10	8	5
	S2	2	20	5	1
	S3	3	6	20	0
	S4	10	2	25	32

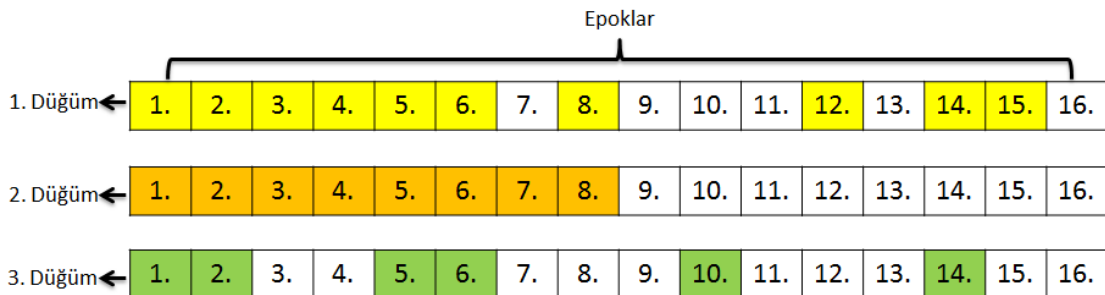
3.3.3. C Kişisi İçin Yapılan Hesaplamalar ve Bulgular

C kişi için uygulanan karar ağacı yapısı Şekil 3.15'te verilmiştir. Burada C kişisi için 3 düğüm vardır ve her bir düğüm için kullanılan öznitelik ile sınıflandırıcı yöntemleri düğüm içerisinde belirtilmiştir. 1. düğümde S1 ile S2, S3, S4 sınıfları özbağlanım ve dalgacık dönüşümü tabanlı özniteliklerle k-EYK ile sınıflandırılmıştır. Burada özbağlanım tabanlı öznitelikler çıkarılırken 8. elektrot kullanılırken dalgacık dönüşümü tabanlı öznitelikler için 5. elektrot kullanılmıştır. Ayrıca dalgacık dönüşümü için morlet dalgacığı 13-40 Hz bandında kullanılmış, özbağlanım parametresi 6 olarak ve k-EYK için $k = 1$ olarak seçilmiştir. 2. düğümde S4 ile S2, S3 sınıfları dalgacık dönüşümü tabanlı özniteliklerle 8. elektrot kullanılarak DVM ile sınıflandırılmıştır. Burada dalgacık

dönüşümü için morlet dalgacığı 13-40 Hz bandında kullanılmış, DVM için $\sigma = 1.3$ olarak seçilmiştir. 3. düğümde ise S2 ile S3 özbağlanım, ortalama türev, basıklık, çarpıklık ve varyans tabanlı özniteliklerle DAA ile sınıflandırılmıştır. Burada özbağlanım tabanlı öznitelikler çıkarılırken 3. elektrot kullanılırken ortalama türev, basıklık, çarpıklık ve varyans tabanlı öznitelikler için 10. elektrot kullanılmıştır ve özbağlanım parametresi 5 olarak seçilmiştir. C kişisi için oluşturulan karar ağaç yapısında 1. düğüm için toplam 8 öznitelik, 2. düğüm için toplam 2 öznitelik, 3. düğüm için toplam 9 öznitelik hesaplanmıştır.



Şekil 3.15. C kişisi için karar ağaç yapısı



Şekil 3.16. C kişisi için seçilen etkin epoklar

Şekil 3.15’te verilen tüm düğümler birbirinden bağımsız bir şekilde Şekil 2.10’daki algoritmaya uygulanarak her bir düğüm için etkin epok(lar) seçilmiştir. Her bir düğüm için seçilen etkin epoklar Şekil 3.16’de verilmiştir. Burada sarı, turuncu ve yeşil işaretli epoklar sırasıyla 1. 2. ve 3. düğüm için seçilen etkin epokları belirtmektedir.

Şekil 3.16’ de verilen etkin epoklar ile her bir düğüm için hesaplanan test SD sonuçları Tablo 3.9’da verilmiştir. Burada Düğüm 1, 2, 3 için sırasıyla %81.57, %78.07 ve %84.21 SD hesaplanmıştır ve tüm düğümler ile karar ağacı sonunda %57.23 SD hesaplanmıştır. Tüm epoklar hesaplamaya katıldığında ise SD, %23.02 oranında azalarak %34.21 SD hesaplanmıştır. Ayrıca düğüm 1 için %39.47 DU, %95.61 ÖZ, Düğüm 2 için %42.10 DU, %96.05 ÖZ ve düğüm 3 için %76.31 DU, %92.10 ÖZ değerleri hesaplanmıştır.

Tablo 3.9. C kişinin her bir düğümü için etkin epoklarla hesaplanan SD, DU ve ÖZ

Karar Ağacı Düğümleri	SD(%)	DU(%)	ÖZ(%)
Düğüm 1	81.57	39.47	95.61
Düğüm 2	78.07	42.10	96.05
Düğüm 3	84.21	76.31	92.10
Karar Ağacı Sonucu	57.23	39.47	95.61

Şekil 2.10’daki algoritma ile SD’yi artırmanın yanında C kişisi için de ÖÇS de arttırılmıştır. Her bir düğümü için hesaplanan etkin epoklar ile 9.21 sn ÖÇS hesaplarken tüm epoklar ile 13.95 sn ÖÇS hesaplanmıştır. C kişisi için ÖÇS %33.95 azaltılmıştır. Ayrıca C kişisi için karar ağacı sonucu hesaplanan %57.23 SD için elde edilen hata matrisi Tablo 3.10’de verilmiştir.

Tablo 3.10. C kişisi için hata matrisi

C Kişisi		Gerçek Sınıf			
		S1	S2	S3	S4
Hesaplanan Sınıf	S1	15	2	2	1
	S2	11	25	3	11
	S3	8	9	32	11
	S4	4	2	1	15

4. SONUÇLAR VE TARTIŞMA

Beynin elektriksel aktiviteleri ile oluşan EEG ve ECoG verilerinin yorumlanması belirli matematiksel algoritmalarla sağlanmaktadır. Bu veriler son zamanlarda çok fazla çalışılan BBA sisteminin ana bileşenlerinden biridir. BBA ise kişinin herhangi bir uzvunu kullanmadan sadece beyin sinyalleriyle imleçleri, robot kolları, protezleri, tekerlekli sandalyeleri, bilgisayarı veya elektromekanik bir kolu kontrol eden sistemdir. Sinyal analiz etme metotlarının gelişmesi, motor nöronları bozuk hastaların sayısının artması ile birlikte teknolojide bu sistemlerin gelişme hızı artmaktadır. Ancak bu gelişimle birlikte BBA sistemlerinin hasta için uygulanabilirliği, sistemin çalışma hızı, sistemin doğruluğu gibi sorunlarla karşılaşılmaktadır. Bu sorunların cevapları hastanın isteğini yansıtacak olan komutların yüksek hassasiyette olmasıyla doğru orantılıdır. Bu bağlamda BBA işaretlerine uygulanan önışleme, öznitelik çıkartma ve sınıflandırma ile birlikte işarete uygulanan diğer yöntemler önemlidir. Bunlara ek olarak BBA sistemlerinin uygulanabilirliğinin iyi olması için kullanılan veri uzunluğu da mümkün olduğunca ideal olması sistem için önemlidir. Çünkü farklı zihinsel aktiviteler sırasında hangi hareketin hangi zaman diliminde yoğunlaştığının tespit edilmesi buna uygun zaman dilimi seçimi yapılmasını sağlar. Böylece veri kümesinin analizi esnasında veri uzunluğunun azalması BBA sisteminin daha hızlı olmasını sağlayacaktır.

Bu tez çalışmasında Veri Kümesi 1, Veri Kümesi 2 ve Veri Kümesi 3 olarak tanımlanmış üç ayrı EEG veya ECoG tabanlı sinyaller ile çalışılmıştır. Sınıflandırma doğruluğunu arttırmak ve öznitelik çıkarım süresini azaltmak için Şekil 2.10'da verilen yöntem, çeşitli ön işlem, öznitelik çıkarımı ve sınıflandırıcı algoritmalarıyla bu veri kümelerine uygulanmıştır. Bu yöntem ile birlikte üç veri kümesi de epoklara ayrılarak bu epoklar arasından etkin olanların seçilmesiyle yüksek başarılı sonuçlar elde edilmiştir.

Bulgular kısmında da bahsedildiği gibi etkin zaman dilimlerinin tespiti için oluşturulan Şekil 2.10'daki algoritma öncelikle Veri Kümesi 1'e uygulanmıştır. Veri Kümesi 1'e hareketli ortalama filtresi uygulandıktan sonra işareten ortalama türev tabanlı öznitelikler çıkartılmıştır. Daha sonra Veri Kümesi 1 için etkin olan 1. ve 3. elektrotlar ile toplamda iki öznitelik hesaplanarak çıkarılan öznitelikler sırasıyla k-EYK, DVM ve DAA yöntemleriyle sınıflandırılarak bu sınıflandırıcılar için performans karşılaştırması yapılmıştır. Bu sınıflandırıcılar için hesaplanan etkin zaman dilimleri Şekil 3.2'de

verilmiştir. Veri Kümesi 1 için en yüksek SD k-EYK sınıflandırıcı için 1. ve 5. epoklar ile birlikte %99.31 olarak hesaplanmıştır. Ayrıca ÖÇS bu sınıflandırıcı için %44.70 oranında azaltılmıştır. Bunlara ek olarak literatürde bu veri kümesiyle yapılmış çalışmalar Tablo 4.1’de verilmiştir. Hesaplanan sonuçlar incelendiğinde bu tez çalışmasında bu veri kümesine uygulanmış yöntem ve algoritmalarla ulaşılan sonuçların yüksek başarımı olduğu görülmektedir.

Tablo 4.1. Veri Kümesi 1 ile yapılmış çalışmalar

Çalışma	SD (%)
Aydemir ve Kayıkçioğlu [51]	92.2
BCI competition [75]	88.7
Mensh vd. [52]	88.7
Sun vd. [76]	90.4
Ting vd. [77]	90.8
Wang vd. [78]	91.1
Duan vd. [79]	93.5
Guo vd. [53]	92.5
Önerilen yöntem	99.31

Veri Kümesi 2’ye Şekil 2.10’daki algoritmanın uygulanmasıyla ise etkin epoklar Şekil 3.7’deki gibi seçilmiştir. Bu algoritma uygulanırken veri kümesi hareketli ortalama filtresinden geçirilmiştir. Ön işlemde geçirilmiş veri kümesinin her bir denemesinden dalgacık dönüşümü tabanlı öznelilikler çıkartılmış ve daha sonra çıkarılan öznelilikler sırasıyla k-EYK, DVM ve DAA yöntemleriyle sınıflandırılmıştır.

Tablo 4.2. Veri Kümesi 2 ile yapılmış çalışmalar

Çalışma	SD (%)
Qingguo vd.[60]	91.00
Dat vd.[61]	92.00
Qin vd.[80]	90.00
Demirer vd.[81]	73.00
Yan Li vd.[62]	92.00
Ince vd.[82]	93.00
Hu vd.[83]	92.00
Aydemir ve Kayıkçioğlu [71]	94.00
Önerilen yöntem	99.00

Veri kümesi 2 için hesaplanan en yüksek SD 1. 2. 3. 4. 5. 10. ve 11.epoklarla k-EYK sınıflandırıcı için %99.00 olarak hesaplanmıştır. Sınıflandırma doğruluğunun yüksek hesaplanmasının yanı sıra seçilen etkin epoklar ile ÖÇS %18.73 oranında azaltılmıştır. Veri Kümesi 2 ile literatürde yapılan çalışmalar Tablo 4.2’de verilmiştir. Bu tez çalışmasında önerilen yöntemle Veri Kümesi 2 ile %99.00 SD ile en iyi sonuca ulaşılmıştır. Bu da bu veri kümesi için önerilen yöntemin etkin olduğunu göstermektedir.

Bu çalışmada önerilen yöntem Veri Kümesi 1 ve 2’nin yanı sıra daha önce bahsedildiği gibi Aydemir’in doktora tezinde kullanılan ve Aydemir tarafından kaydedilen Veri Kümesi 3’e de uygulanmıştır. Üç kişiden oluşan veri kümesinden etkin epoklar seçilirken öznitelik ve sınıflandırma yöntemleri için Aydemir’in doktora tezinde uyguladığı yöntemler uygulanmıştır. Veri kümesine ağaç karar yapısı uygulanarak her bir kişi için üç düğüm oluşturulmuştur.

A kişinin 1. düğümünde S1, S3 ile S2, S4 sınıfları dalgacık dönüşümü tabanlı özniteliklerle 8. elektrot kullanılarak DVM ile sınıflandırılmıştır. 2. düğümde S1 ile S3 özbağlanım tabanlı özniteliklerle 9. elektrot kullanılarak DAA ile sınıflandırılmıştır. 3. Düğümde ise S2 ile S4 ortalama türev ve çarpıklık tabanlı özniteliklerle 8. elektrot kullanılarak DVM ile sınıflandırılmıştır. Şekil 3.12’de gösterildiği gibi burada toplam 16 epokdan 1. düğüm için 11 etkin epok, 2. düğüm için 9 etkin epok ve 3. düğüm için 3 etkin epok seçilmiştir.

B kişinin 1. düğümünde S2 ile S1, S3, S4 özbağlanım ve dalgacık dönüşümü tabanlı özniteliklerle 4. elektrot kullanılarak DVM ile sınıflandırılmıştır. 2. düğümde S3 ile S1, S4 özbağlanım tabanlı özniteliklerle 4. elektrot kullanılarak KEKK regresyonu ile sınıflandırılmıştır. 3. düğümde ise S1 ile S4 dalgacık dönüşümü tabanlı özniteliklerle 3. elektrot kullanılarak k-EYK ile sınıflandırılmıştır. Şekil 3.14’de verildiği gibi B kişisi için toplam 16 epokdan 1. düğüm için 9 etkin epok, 2. düğüm için 11 etkin epok ve 3. Düğüm için 10 etkin epok seçilmiştir.

C kişinin 1. düğümde S1 ile S2, S3, S4 sınıfları özbağlanım ve dalgacık dönüşümü tabanlı özniteliklerle k-EYK ile sınıflandırılmıştır. Burada özbağlanım tabanlı öznitelikleri çıkarma aşamasında 8. elektrot kullanılırken dalgacık dönüşümü tabanlı öznitelikler için 5. elektrot kullanılmıştır. 2. düğümde S4 ile S2, S3 sınıfları dalgacık dönüşümü tabanlı özniteliklerle 8. elektrot kullanılarak DVM ile sınıflandırılmıştır. 3. düğümde ise S2 ile S3 özbağlanım, ortalama türev, basıklık, çarpıklık ve varyans tabanlı özniteliklerle DAA ile sınıflandırılmıştır. Burada özbağlanım tabanlı öznitelikler çıkarılırken 3. elektrot, ortalama

türev, basıklık, çarpıklık ve varyans tabanlı öznitelikler için 10. elektrot kullanılmıştır. Ayrıca Şekil 3.16'de gösterildiği gibi toplam 16 epokdan 1. düğüm için 10 etkin epok, 2. düğüm için 8 etkin epok ve 3. düğüm için 6 etkin epok seçilmiştir.

Her bir ağaç yapısının tüm düğümlerinde kişiye özel parametrelerle hesaplanan sınıflandırma doğrulukları Tablo 4.3'de verilmiştir. Aydemir'in doktora tezinde tüm kişilerin her bir düğümü için hesapladığı sınıflandırma doğrulukları ise Tablo 4.4'de gösterilmiştir. Tablolarda görüldüğü gibi karar ağacı sonucu önerilen yöntem ile birlikte B kişi için SD %4.6, C kişisi için SD %1.31 artırılmıştır. Ancak A kişisi için SD değişmemiştir. Bu da A kişisi için hesaplanan %82.24 SD değerinin ulaşılacak en üst seviye olduğunu göstermektedir.

Tablo 4.3. Veri Kümesi 3 ile A,B,C kişisi için hesaplanan sonuçlar

Kişiler	Sınıflandırma Doğruluğu (%)			
	1. Düğüm	2. Düğüm	3. Düğüm	Karar Ağacı Sonucu
A	94.73	75.00	97.36	82.24
B	82.89	82.45	80.26	62.50
C	81.57	78.07	84.21	57.23

Tablo 4.4. Aydemir'in doktora tezi sonuçları

Kişiler	Sınıflandırma Doğruluğu (%)			
	1. Düğüm	2. Düğüm	3. Düğüm	Karar Ağacı Sonucu
A	92.76	77.63	96.05	82.24
B	82.89	79.82	80.26	57.90
C	80.92	78.07	80.26	55.92

Bu tez çalışmasında ulaşılan önemli sonuçlardan biri olan ÖÇS azaltımı Veri Kümesi 3 içinde gerçekleştirilmiştir. Veri Kümesi 3'de A kişisi için %12.81, B kişisi için %8.97, C kişisi için ise %33.95 oranında ÖÇS azaltılmıştır. Bu sonuçlar hedeflenen BBA sisteminin daha hızlı ve etkin olacağını göstermektedir.

Önerilen yöntem BCI Competition 2003 Data Set Ia veri kümesine, BCI Competition 2005 Dataset I veri kümesine ve Karadeniz Teknik Üniversitesi'nde Aydemir tarafından kaydedilen İmleç Hareketi Hayaline Dayalı Elektroensefalografi veri kümesine uygulanmıştır. Bu sonuçlara göre EEG veya ECoG tabanlı BBA verilerinin tüm uzunluğu

kullanılmadan etkin bilgiyi içeren kısım ile daha yüksek SD ve hesaplama karmaşıklığı az sistemin oluşturulmasının literatüre büyük katkı sağlayacağı düşünülmektedir.



5. ÖNERİLER

Zihinsel faaliyetler esnasında beyinden alınan EEG ve ECoG sürekli değişim gösteren karmaşık verilerdir. Bu veriler matematiksel işlemler uygulanarak beyin-bilgisayar arayüzleri için giriş işareti olarak kullanılırlar. BBA sistemleri ise çevresel sinir sistemlerini kullanarak dış dünya ile iletişim kuramayan insanlara bunu olanaklı hale getirmelerini sağlar. Bu sistemlerin uzun vadeli hedefi ALS hastaları ve üst düzey omurilik yaralanmaları gibi kas kontrolünün kaybedilmesine neden olan hastalık ve yaralanma mağdurları için yeni bir iletişim modeli oluşturmaktır. Bu yüzden BBA sistemleri için kullanılan EEG veya ECoG işaretlerine uygulanan ön işlem, öznitelik ve sınıflandırma yöntemleri önemlidir.

Beyin aktiviteleri esnasında kayıt alınan EEG ve ECoG verilerine bu esnada göz kırpması, ortam ve çeşitli biyolojik etkiler olarak adlandırılan gürültüler eklenebilir. Bu gürültüler verilerin işlenmesini zorlaştırabilir. Öncelikle gerekli ön işleme yöntemiyle bu gürültüler verilerden temizlenmelidir. Daha sonra gerekli bilgiyi veri kümesinden çıkartacak olan öznitelik çıkarma kısmına geçilir. Bu kısım için literatürde çeşitli matematiksel yöntem vardır. Her yöntemin her uygulamada iyi sonuç vermemesi ve aynı uygulama için farklı kişilerden kayıt alınan EEG veya ECoG verilerinin beynin fizyolojik yapısından dolayı aynı olmaması uygulanacak öznitelik yöntemlerinde ve hesaplanan özniteliklerde farklılık oluşturur. Ayrıca hastanın hangi hareketinin hangi veriyi kısmında yoğunlaştığının tespitiyle veri kümesinden uygun zaman diliminin seçilmesi sağlanmalıdır. Buna ek olarak kayıt alınan verinin hangi beyin bölgesinde etkin olduğu belirlenerek analiz için uygun elektrotlar seçilmelidir. Bu durum BBA sisteminin daha hızlı olmasını sağlayacaktır. Bu bağlamda bu tez çalışmasında Şekil 2.10'daki algoritma ile birlikte yeni bir yöntem önerilmiştir. Veri kümelerinin epoklara bölünerek bu epoklar arasından etkin epokların seçilmesi temeline dayanan bu yöntem ile EEG veya ECoG verilerindeki sadece BBA sistemine uygun kısım kullanılır. Böylece BBA sistemleri için daha hızlı ve yüksek başarılı sonuçlara ulaşılabilir.

Bu tez çalışmasında kullanılan sınıflandırıcılara ek olarak literatürde yer alan Yapay Sinir Ağları, Gömülü Markov Modeli ve Bayes gibi farklı türden sınıflandırıcılar da kullanılarak sonuçlar değerlendirilebilir. Ayrıca BBA sistem için tüm elektrotlardan elde edilen verileri kullanmak yerine, yapılan uygulamaya göre beyinsel aktivitenin yoğun

olduđu bölgelerde yer alan elektrotların kullanılması önemlidir. Bu çalışmada bu elektrotların seçiminin otomatik olmayışı dezavantajlıdır. Bu yüzden elektrot sayısını hızlı ve otomatik bir şekilde belirleyen algoritma oluşturulabilir. Bunlara ek olarak farklı kişilerden farklı koşullarda kaydedilmiş EEG veya ECoG işaretlerinden öznelik çıkarma işlemi çok önemlidir. Literatürde yer alan birçok öznelik çıkarımı yöntemi vardır ve bu yöntemler tüm veri kümelerinde iyi sonuç vermeyebilir. Bu yüzden bu tez çalışmasında önerilen yöntemin farklı veri kümelerine uygulanabilmesi için farklı öznelik yöntemlerinin uygulanması gerekebilir. Bunun için önerilen yöntem çeşitli öznelik çıkartma yöntemi seçenekleri eklenerek veri kümesi için etkin olanı otomatik olarak seçilebilir.



6. KAYNAKLAR

1. Aydemir, O. ve Kayikcioglu, 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.
2. McCane, L. M., Sellers, E. W., McFarland, D. J., Mak, J. N., Carmack, C. S., Zeitlin, D., ve Vaughan, T. M., Brain-computer interface (BCI) evaluation in people with amyotrophic lateral sclerosis, Amyotrophic lateral sclerosis and frontotemporal degeneration, 15, 3 (2014) 207-215.
3. Louveau, A., Smirnov, I., Keyes, T. J., Eccles, J. D., Rouhani, S. J., Peske, J. D., ve Harris, T. H., Structural and functional features of central nervous system lymphatic vessels, Nature, 523, 7560 (2015) 337-341.
4. Ang, K. K., ve Guan, C., Brain-computer interface in stroke rehabilitation, Journal of Computing Science and Engineering, 7, 2 (2013) 139-146.
5. Salisbury, D. B., Parsons, T. D., Monden, K. R., Trost, Z., ve Driver, S. J., Brain-computer interface for individuals after spinal cord injury, Rehabilitation psychology, 61, 4 (2016) 435-441.
6. Kübler, A., Kotchoubey, B., Kaiser, J., Wolpaw, J. R., ve Birbaumer, N., Brain-computer communication: Unlocking the locked in, Psychological bulletin, 127, 3 (2001) 358-375.
7. Azami, H., Bozorgtabar, B., ve Shiroie, M., Automatic signal segmentation using the fractal dimension and weighted moving average filter, Journal of Electrical & Computer science, 11, 6 (2011) 8-15.
8. Aydemir Ö., İmlecin İki Boyutlu Hareketinin Hayali Sırasında Kaydedilmiş EEG İşaretlerinin Karar Ağaç Yapısı Esaslı Sınıflandırılması, Doktora Tezi, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon, 2013.
9. Bularka, S. ve Gontean, A., Brain-Computer Interface review, In Electronics and Telecommunications (ISETC), June 2016, Timisoara, Bildiriler Kitabı: 219-222.
10. Ivry, R. B. ve Keele, S. W., Timing functions of the cerebellum, Journal of Cognitive Neuroscience, 1, 2 (1989) 136-152.
11. Uchida, N., Buck, D. W., He, D., Reitsma, M. J., Masek, M., Phan, T. V. ve Weissman, I. L., Direct isolation of human central nervous system stem cells, Proceedings of the national academy of sciences, 97, 26 (2000) 14720-14725.
12. Bean, B. P., The action potential in mammalian central neurons, Nature Reviews Neuroscience, 8, 6 (2007) 451-465.

13. Curran, E. A., ve Stokes, M. J., Learning to control brain activity: a review of the production and control of EEG components for driving brain-computer interface (BCI) systems, Brain and cognition, 51, 3 (2003) 326-336.
14. Wilson, J. A., Felton, E. A., Garell, P. C., Schalk, G., ve Williams, J. C., ECoG factors underlying multimodal control of a brain-computer interface, IEEE transactions on neural systems and rehabilitation engineering, 14, 2 (2006) 246-250.
15. Aydemir Ö., Beyin Bilgisayar Arayüzü Uygulamalarına Yönelik EEG İşaretleri için Öznitelik Çıkarma, Yüksek Lisans Tezi, K.T.Ü., Fen Bilimleri Enstitüsü, Trabzon, 2008.
16. Leuthardt, E. C., Schalk, G., Wolpaw, J. R., Ojemann, J. G., ve Moran, D. W., A brain-computer interface using electrocorticographic signals in humans, Journal of neural engineering, 1, 2 (2004) 63.
17. Wolpaw, J. R., Birbaumer, N., McFarland, D. J., Pfurtscheller, G., ve Vaughan, T. M., Brain-computer interfaces for communication and control, Clinical neurophysiology, 113, 6 (2002) 767-791.
18. Wolpaw, J. R., McFarland, D. J., ve Vaughan, T. M., Brain-computer interface research at the Wadsworth Center, IEEE Transactions on Rehabilitation Engineering, 8, 2 (2000) 222-226.
19. Kwoh, Y. S., Hou, J., Jonckheere, E. A., ve Hayati, S., A robot with improved absolute positioning accuracy for CT guided stereotactic brain surgery, IEEE Transactions on Biomedical Engineering, 35, 2 (1988) 153-160.
20. Paus, T., Jech, R., Thompson, C. J., Comeau, R., Peters, T., ve Evans, A. C., Transcranial magnetic stimulation during positron emission tomography: a new method for studying connectivity of the human cerebral cortex, Journal of Neuroscience, 17, 9 (1997) 3178-3184.
21. Filipek, P. A., Kennedy, D. N., Caviness, V. S., Rosnick, S. L., Spraggins, T. A., ve Starewicz, P. M., Magnetic resonance imaging-based brain morphometry: development and application to normal subjects, Annals of neurology, 25, 1 (1989) 61-67.
22. 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 transactions on biomedical engineering, 51, 6 (2004) 966-970.
23. Yoo, S. S., Fairney, T., Chen, N. K., Choo, S. E., Panych, L. P., Park, H. ve Jolesz, F., A Brain-computer interface using fMRI: spatial navigation by thoughts, Neuroreport, 15, 10 (2004) 1591-1595.

24. Malison, R. T., Miller, E. G., Greene, R., McCarthy, G., Charney, D. S., ve Innis, R. B., Computer-assisted coregistration of multislice SPECT and MR brain images by fixed external fiducials, Journal of computer assisted tomography, 17, 6 (1993) 952-960.
25. Ciernik, I. F., Dizendorf, E., Baumert, B. G., Reiner, B., Burger, C., Davis, J. B., ve Von Schulthess, G. K., Radiation treatment planning with an integrated positron emission and computer tomography (PET/CT): a feasibility study, International Journal of Radiation Oncology* Biology* Physics, 57, 3 (2003) 853-863.
26. Blankertz, B., Curio, G., ve Müller, K. R., Classifying single trial EEG: Towards brain computer interfacing, Advances in neural information processing systems, 1 (2002) 157-164.
27. Neuper, C., Müller, G. R., Kübler, A., Birbaumer, N., ve Pfurtscheller, G., Clinical application of an EEG-based brain-computer interface: a case study in a patient with severe motor impairment, Clinical neurophysiology, 114, 3 (2003) 399-409.
28. Treder, M. S., ve Blankertz, B., (C) overt attention and visual speller design in an ERP-based brain-computer interface, Behavioral and brain functions, 6, 1 (2010) 28.
29. Levine, S. P., Huggins, J. E., BeMent, S. L., Kushwaha, R. K., Schuh, L. A., Rohde, M. M. ve Smith, B. J., A direct brain interface based on event-related potentials, IEEE Transactions on Rehabilitation Engineering, 8, 2 (2000) 180-185.
30. Chan, T., Computer aided detection of small acute intracranial hemorrhage on computer tomography of brain, Computerized Medical Imaging and Graphics, 31, 4 (2007) 285-298.
31. Sack, A. T., Kadosh, R. C., Schuhmann, T., Moerel, M., Walsh, V., ve Goebel, R., Optimizing functional accuracy of TMS in cognitive studies: a comparison of methods, Journal of Cognitive Neuroscience, 21, 2 (2009) 207-221.
32. Shih, J. J., Krusienski, D. J., ve Wolpaw, J. R., Brain-computer interfaces in medicine, In Mayo Clinic Proceedings, 87, 3 (2012) 268-279.
33. Schalk, G., ve Leuthardt, E. C., Brain-computer interfaces using electrocorticographic signals, IEEE reviews in biomedical engineering, 4 (2011) 140-154.
34. Nicolas-Alonso, L. F., ve Gomez-Gil, J., Brain computer interfaces, a review, Sensors, 12, 2 (2012) 1211-1279.
35. Hill, N. J., Lal, T. N., Schröder, M., Hinterberger, T., Widman, G., Elger, C. E., ve Birbaumer, N., Classifying event-related desynchronization in EEG, ECoG and MEG signals, In Joint Pattern Recognition Symposium, Eylül 2006, Berlin, Bildiriler Kitabı: 404-413.

36. Hammon, P. S., ve de Sa, V. R., Preprocessing and meta-classification for brain-computer interfaces, IEEE Transactions on Biomedical Engineering, 54, 3 (2007) 518-525.
37. Gupta, S., ve Singh, H., Preprocessing EEG signals for direct human-system interface, In Intelligence and Systems, Kasım 1966, Rockville, Bildiriler Kitabı: 32-37.
38. Ramoser, H., Muller-Gerking, J., ve Pfurtscheller, G., Optimal spatial filtering of single trial EEG during imagined hand movement, IEEE transactions on rehabilitation engineering, 8, 4 (2000) 441-446.
39. Blankertz, B., Tomioka, R., Lemm, S., Kawanabe, M., ve Muller, K. R., Optimizing spatial filters for robust EEG single-trial analysis, IEEE Signal processing magazine, 25, 1 (2008) 41-56.
40. Kumar, Se., Sharma, R., Sharma, A., ve Tsunoda, T., Decimation filter with Common Spatial Pattern and Fishers Discriminant Analysis for motor imagery classification, In Neural Networks (IJCNN), Haziran 2016, Vancouver, Bildiriler Kitabı: 2090-2095.
41. Pfurtscheller, G., Kalcher, J., Neuper, C., Flotzinger, D., ve Pregenzer, M., On-line EEG classification during externally-paced hand movements using a neural network-based classifier, Electroencephalography and clinical Neurophysiology, 99, 5 (1996) 416-425.
42. Zhong, S., ve Ghosh, J., HMMs and coupled HMMs for multi-channel EEG classification, In Neural Networks, Ağustos 2002, Honolulu, Bildiriler Kitabı: 1154-1159.
43. Garcia, G. N., Ebrahimi, T., ve Vesin, J. M., Support vector EEG classification in the Fourier and time-frequency correlation domains, In Neural Engineering, Mart 2003, Capri Island, Bildiriler Kitabı: 591-594.
44. Li, J., Zhang, L., Tao, D., Sun, H., ve Zhao, Q., A prior neurophysiologic knowledge free tensor-based scheme for single trial EEG classification, IEEE Transactions on Neural Systems and Rehabilitation Engineering, 17, 2 (2009) 107-115.
45. Hsu, W. Y., Enhanced active segment selection for single-trial EEG classification, Clinical EEG and neuroscience, 43, 2 (2012) 87-96.
46. Daliri, M. R., Kernel earth mover's distance for EEG classification, Clinical EEG and neuroscience, 44, 3 (2013) 182-187.
47. Amin, H. U., Malik, A. S., Ahmad, R. F., Badruddin, N., Kamel, N., Hussain, M., ve Chooi, W. T., Feature extraction and classification for EEG signals using wavelet transform and machine learning techniques, Australasian Physical & Engineering Sciences in Medicine, 38, 1 (2015) 139-149.

48. Singh, P., Joshi, S. D., Patney, R. K., ve Saha, K., Fourier-Based Feature Extraction for Classification of EEG Signals Using EEG Rhythms, Circuits, Systems, and Signal Processing, 35, 10 (2016) 3700-3715.
49. Kuremoto, T., Baba, Y., Obayashi, M., Mabu, S., ve Kobayashi, K., A Method of Feature Extraction for EEG Signals Recognition Using ROC Curve, The International Conference on Artificial Life and Robotics, Ocak 2017, Miyazaki, Bildiriler Kitabı: 654-657.
50. Abdalsalam, E., Yusoff, M. Z., Kamel, N., Malik, A. S., ve Mahmoud, D., Classification of Four Class Motor Imagery for Brain Computer Interface, In 9th International Conference on Robotic, Vision, Signal Processing and Power Applications, Eylül 2017, Singapore, Bildiriler Kitabı: 297-305.
51. Kayikcioglu, T., 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.
52. Mensh, B. D., Werfel, J., 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 Transactions on Biomedical Engineering, 51, 6 (2004) 1052-1056.
53. Guo, X., Zhao, H., Li, X., Li, T., Dai, M., EEG signal analysis based on fixed-value shift compression algorithm, In Natural Computation (ICNC), Ağustos 2015, Zhangjiajie, Bildiriler Kitabı: 959-963.
54. Won, M., Albalawi, H., Li, X., ve Thomas, D. E., Low-power hardware implementation of movement decoding for brain computer interface with reduced-resolution discrete cosine transform, In Engineering in Medicine and Biology Society (EMBC), Ağustos 2014, Chicago, Bildiriler Kitabı: 1626-1629.
55. Kapeller, C., Schneider, C., Kamada, K., Ogawa, H., Kunii, N., Ortner, R., ve Guger, C., Single trial detection of hand poses in human ECoG using CSP based feature extraction, In Engineering in Medicine and Biology Society (EMBC), Ağustos 2014, Chicago, Bildiriler Kitabı: 4599-4602.
56. Kapeller, C., Gergondet, P., Kamada, K., Ogawa, H., Takeuchi, F., Ortner, R. ve Guger, C., Online control of a humanoid robot through hand movement imagination using CSP and ECoG based features, In Engineering in Medicine and Biology Society (EMBC), Ağustos 2015, Milan, Bildiriler Kitabı: 1765-1768.
57. Aswineshadri, K., Evaluation of feature selection in Brain Computer Interface, In Advances in Electrical, Electronics, Information, Communication and Bio-Informatics (AEEICB), Şubat 2016, Chennai, Bildiriler Kitabı: 93-97.
58. Islam, M. R., Fatema, U., Bhuiyan, M. I. H., ve Bashar, S. K., Classification of electrocorticography based motor imagery movements using continuous wavelet

- transform, In Technology Symposium (TechSym), Mart 2016, Kharagpur, Bildiriler Kitabı: 13-17.
59. Erkan, E., ve Kurnaz, I., A study on the effect of psychophysiological signal features on classification methods, Measurement, 101 (2017) 45-52.
 60. Quigguo, W., Fei, M., Yijun, W., Xiaorong, G., ve Shangkai, G., Feature combination for classifying single-trial ECoG during motor imagery of different sessions, Progress in natural science, 17, 7 (2007) 851-858.
 61. Dat, T. H., Shue, L., ve Guan, C., Electrographic signal classification based on time-frequency decomposition and nonparametric statistical modeling, 28th Annual International Conference In Engineering in Medicine and Biology Society, Ağustos 2006, New York, Bildiriler Kitabı: 2292-2295.
 62. Li, Y., Koike, Y., ve Sugiyama, M., A framework of adaptive brain computer interfaces, In Biomedical Engineering and Informatics (BMEI), Ekim 2009, Tianjin, Bildiriler Kitabı: 1-5.
 63. Tong, S., ve Chang, E., Support vector machine active learning for image retrieval, In Proceedings of the ninth ACM international conference on Multimedia, Ekim 2011, Ottawa, Bildiriler Kitabı: 107-118.
 64. Chin, Z. Y., Ang, K. K., Wang, C., Guan, C., ve Zhang, H., Multi-class filter bank common spatial pattern for four-class motor imagery BCI, Annual International Conference of In Engineering in Medicine and Biology Society, Eylül 2009, Minneapolis, Bildiriler Kitabı: 571-574.
 65. Bai, X., Wang, X., Zheng, S., ve Yu, M., The offline feature extraction of four-class motor imagery EEG based on ICA and Wavelet-CSP, In Control Conference, Haziran 2014, Chinese, Bildiriler Kitabı: 7189-7194.
 66. Aydemir, Ö., Common spatial pattern-based feature extraction from the best time segment of BCI data, Turkish Journal of Electrical Engineering & Computer Sciences, 24, 5 (2016) 3976-3986.
 67. Han, R., ve Wei, Q., Joint selection of time and frequency segments for classifying multiclass EEG data in motor imagery based BCIs, In Fuzzy Systems and Knowledge Discovery (FSKD), Ağustos 2015, Zhangjiajie, Bildiriler Kitabı: 1571-1576.
 68. Asensio-Cubero, J., Gan, J. Q., ve Palaniappan, R., Extracting optimal tempo-spatial features using local discriminant bases and common spatial patterns for brain computer interfacing, Biomedical Signal Processing and Control, 8, 6 (2013) 772-778.
 69. Hsu, W. Y., EEG-based motor imagery classification using enhanced active segment selection and adaptive classifier, Computers in biology and medicine, 41, 8 (2011) 633-639.

70. Yavuz, E. ve Aydemir, Ö., Olfaction recognition by EEG analysis using wavelet transform features. In INnovations in Intelligent SysTems and Applications (INISTA), Ağustos 2016, Sinaia, Bildiriler Kitabı: 1-4.
71. Aydemir, O. ve Kayikcioglu, T., Wavelet transform based classification of invasive brain computer interface data. Radioengineering, 20, 1 (2011) 31-38.
72. Mardia, K. V. Measures of multivariate skewness and kurtosis with applications. Biometrika, 1970, 519-530.
73. Aydemir, O. ve Kayikcioglu, T., Decision tree structure based classification of EEG signals recorded during two dimensional cursor movement imagery, Journal of neuroscience methods, 229 (2014) 68-75.
74. Boulesteix, A. L. ve Strimmer, K., Partial least squares: a versatile tool for the analysis of high-dimensional genomic data, Briefings in bioinformatics, 8, 1 (2007) 32-44.
75. <http://www.bbc.de/competition/iii>, BCI Competition III.13.08.2012.
76. Sun, S. ve Zhang, C., Assessing features for electroencephalographic signal categorization. In Acoustics, Speech, and Signal Processing, Proceedings, (ICASSP'05), Mart 2005, Philadelphia, Bildiriler Kitabı: 5-417.
77. Ting, W., Guo-zheng, Y., Bang-hua, Y., ve Hong, S., EEG feature extraction based on wavelet packet decomposition for brain computer interface, Measurement, 41, 6 (2008) 618-625.
78. Wang, B., Jun, L., Bai, J., Peng, L., Li, G., ve Li, Y., EEG recognition based on multiple types of information by using wavelet packet transform and neural networks, In Engineering in Medicine and Biology Society, Ocak 2005, Shanghai, Bildiriler Kitabı: 5377-5380.
79. Duan, L., Zhong, H., Miao, J., Yang, Z., Ma, W. ve Zhang, X., A voting optimized strategy based on ELM for improving classification of motor imagery BCI data, Cognitive Computation, 6, 3 (2014) 477-483.
80. Qin, J., Li, Y., ve Sun, W., A semisupervised support vector machines algorithm for BCI systems, Computational intelligence and neuroscience, 17, 7 (2007) 851-858.
81. Demirer, R. M., Ozerdem, M. S., ve Bayrak, C., Classification of imaginary movements in ECoG with a hybrid approach based on multi-dimensional Hilbert-SVM solution, Journal of neuroscience methods, 178, 1 (2009) 214-218.
82. Ince, N. F., Goksu, F. ve Tewfik, A. H., ECoG based brain computer interface with subset selection, Biomedical Engineering Systems and Technologies, 25 (2008) 357-374.

83. Hu, R., Li, G., Hu, M., Fu, J. ve Freeman, W., Recognition of ECoG in BCI systems based on a chaotic neural model, Advances in Neural Networks–ISNN, 4491 (2007) 685-693.



ÖZGEÇMİŞ

Ebru YAVUZ, 1991 yılında Trabzon'un Yomra ilçesinde doğdu. İlköğretim ve ortaöğretimi Trabzon Merkez'de tamamlamış olup, 2009 yılında Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği Bölümünü kazandı. Bu öğrenimini 2014 yılında tamamlayarak aynı sene yüksek lisans eğitimine başladı. 2015 yılında Recep Tayyip Erdoğan Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. İyi derecede İngilizce bilen Yavuz, biyomedikal alanındaki çalışmalarını sürdürmektedir.

SCI/SCI-E indekslerine giren dergilere gönderilen makaleler

1. Yavuz, E. ve Aydemir Ö., Improving class separability of BCI signals using effective epochs of EEG trials. Electronics Letters, **inceleme altında**.

Diğer dergilerde yayınlanacak makaleler

2. Yavuz, E., ve Aydemir, Ö., Nilüfer Çiçeği ve Kediotu Kokularını Koklama Anında Kaydedilmiş EEG İşaretlerinin Sınıflandırılması, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2017, **basım hazırlığında**.
3. Yavuz, E., ve Aydemir, Ö., Etkin Epoklar ile Motor Hayaline Dayalı EEG İşaretlerinin Sınıflandırma Doğruluğunun Artırılması, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2017, **kabul edildi**.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan yayınlar

4. Yavuz, E. ve Aydemir, Ö., Olfaction recognition by EEG analysis using wavelet transform features. In INnovations in Intelligent SysTems and Applications (INISTA), Ağustos 2016, Sinaia, Bildiriler Kitabı: 1-4.
5. Yavuz, E., ve Aydemir, Ö., EEG Tabanlı Beyin Bilgisayar Arayüzü İşaretlerinin Etkin Zaman Dilimlerinden Çıkarılmış Özniteliklerle Sınıflandırma Doğruluklarının Artırılması. XX. Biyomedikal Mühendisliği Ulusal Toplantısı (BİYOMUT), Kasım 2016, İzmir, Bildiriler Kitabı: 1-5.

6. Yavuz, E. ve Aydemir, Ö., Beyin-Bilgisayar Arayüzü Uygulamalarında Etkin Kanalların Belirlenmesi, 25. Sinyal İşleme ve İletişim Uygulamaları Kurultayı (SIU), Mayıs 2017, Antalya.
7. Yavuz, E., ve Aydemir, Ö., Classification of EEG Based BCI Signals Imagined Hand Closing and Opening, In Telecommunications and Signal Processing (TSP), Temmuz 2017, Barselona, **kabul edildi.**

