

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

**BEYİN BİLGİSAYAR ARAYÜZÜ UYGULAMALARINA YÖNELİK EEG İŞARETLERİ
İÇİN ÖZNİTELİK ÇIKARMA**

YÜKSEK LİSANS TEZİ

Elektrik-Elektronik Mühendisi Önder AYDEMİR

**HAZİRAN 2008
TRABZON**

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

BEYİN BİLGİSAYAR ARAYÜZÜ UYGULAMALARINA YÖNELİK EEG
İŞARETLERİ İÇİN ÖZNİTELİK ÇIKARMA

Elektrik-Elektronik Mühendisi Önder AYDEMİR

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

Tezin Enstitüye Verildiği Tarih : 06.06.2008
Tezin Savunma Tarihi : 26.06.2008

Tez Danışmanı : Doç. Dr. Temel KAYIKÇIOĞLU
Jüri Üyesi : Yrd. Doç. Dr. Ali GANGAL
Jüri Üyesi : Prof. Dr. Vasif V. NABİYEV



Enstitü Müdürü V. : Doç. Dr. Salih TERZİOĞLU

ÖNSÖZ

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

Tüm eğitim-öğretim hayatım boyunca maddi ve manevi desteklerini esirgemeyen aileme teşekkür ederim. Bu tezin, bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Önder AYDEMİR

Trabzon 2008

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	II
İÇİNDEKİLER.....	III
ÖZET	V
SUMMARY	VI
ŞEKİLLER DİZİNİ	VII
TABLolar DİZİNİ.....	IX
SEMBOLLER DİZİNİ	X
1. GENEL BİLGİLER.....	1
1.1. Elektroensefalogram.....	1
1.1.1. Beynin Fizyolojik Yapısı.....	1
1.1.2. İlk EEG.....	2
1.1.3. EEG İşaretlerinin Özellikleri.....	2
1.1.4. EEG Elektrotlarının Bağlanma Şekilleri	4
1.1.5. Uyarılmış Potansiyeller	6
1.2. Beyin Bilgisayar Arayüzü	7
1.2.1. Giriş.....	7
1.2.2. EEG ile Beyin Bilgisayar Arayüzü Arasındaki İlişki.....	8
1.2.3. Beyin Bilgisayar Arayüzü Çeşitleri.....	9
1.2.3.1. Bağımlı Beyin Bilgisayar Arayüzü	10
1.2.3.2. Bağımsız Beyin Bilgisayar Arayüzü	10
1.2.4. Beyin Bilgisayar Arayüzü Sisteminin Temel Bileşenleri.....	10
1.2.4.1. Sinyal Toplama.....	11
1.2.4.2. Sinyal İşleme: Öznitelik Çıkarma	12
1.2.4.3. Sinyal İşleme: Dönüştürme Algoritması	12
1.2.4.4. Cihaz Çıktısı	13
1.2.4.5. İşletim Protokolü	13
1.2.5. Modern Beyin Bilgisayar Arayüzü Örnekleri	13
1.2.5.1. Görsel Olarak Tetiklenen Potansiyeller.....	14

1.2.5.2.	Yavaş Kortikal Potansiyeller	14
1.2.5.3.	P300 Tetiklenen Potansiyeller	14
1.2.5.4.	μ ve β Ritmleri	15
1.2.5.5.	Kortikal Nöronlar	16
1.3.	Literatür Araştırması	16
2.	YAPILAN ÇALIŞMALAR VE BULGULAR	26
2.1.	Materyal	26
2.1.1.	Literatürde Aynı Veri Kümesini Kullanarak Yapılan Çalışmalar	27
2.2.	Yöntem	30
2.2.1.	Temel Bileşen Analizi	30
2.2.2.	Bağımsız Bileşen Analizi	33
2.2.3.	Eğri Uydurma	34
2.2.3.1.	En Küçük Kareler Yöntemi ile Eğri Uydurma	35
2.2.3.2.	En Küçük Kareler Yöntemi ile 2. Dereceden Polinom Uydurma	37
2.2.4.	Destek Vektör Makineleri Yöntemi	39
2.2.4.1.	Doğrusal Destek Vektör Makineleri	41
2.2.4.2.	Sınır (Margin)	45
2.2.4.3.	Doğrusalca Ayrılabilir Veri	46
2.2.4.4.	Doğrusalca Ayrılamayan Veri	48
2.2.4.5.	Doğrusal Olmayan Destek Vektör Makineleri Sınıflandırıcıları	49
2.2.5.	k- En Yakın Komşuluk Yöntemi	50
2.3.	Öznitelik Çıkarma Çalışmaları ve Sınıflandırma	51
2.3.1.	Temel/Bağımsız Bileşen Analizi ile Öznitelik Çıkarma ve Sınıflandırma	51
2.3.2.	EEG Verilerinin Yerel Maksimum ve Minimumlarına 2. Dereceden Polinom Uydurarak Öznitelik Çıkarma	54
2.3.3.	Ham EEG Verilerine 2. Dereceden Polinom Uydurarak Öznitelik Çıkarma	59
2.3.4.	Yerel Maksimum ve Yerel Minimumların Ortaya Çıkış Zamanlarına Bağlı Eğri Uydurma	63
2.3.5.	Yerel Maksimumlardan Yerel Minimumlara ve Yerel Minimumlardan Yerel Maksimumlara Geçiş Zamanlarına Bağlı Öznitelik Çıkarma	68
3.	TARTIŞMA VE SONUÇLAR	72
4.	ÖNERİLER	74
5.	KAYNAKLAR	75

ÖZGEÇMİŞ

ÖZET

Elektroensefalografi (EEG) işaretleri, beyin yüzeyinden elektrotlarla algılanan düşük genlikli biyoelektrik işaretlerdir. Bu işaretlerin genliği tepeden tepeye 1-400 μ V ve frekans bandı ise 0.5-100 Hz aralığında bulunmaktadır. EEG işaretlerinin beyin aktiviteleri ile ilgili çok miktarda bilgi içermesinden dolayı son yıllarda bu alandaki arařtırmalar, tıp ve mühendislik bilimlerinde hız kazanmıştır. Tıbbi alanda, bu işaretler nörolojik hastalıkların teşhis edilmesinde ve seçilen tedavi yöntemlerinin başarımlarının izlenmesinde önemli rol oynamaktadır. Mühendislik alanında, düşünsel ve görsel uygulamalar süresince kaydedilmiş olan EEG işaretlerinden çıkartılan özniteliklere dayalı sınıflandırma beyin bilgisayar arayüzleşmesi için önemli bilgi sağlar. Beyin Bilgisayar Arayüzleri (BBA), kişilerin kas sistemlerini bir başka deyişle motor sinir sistemlerini kullanmadan bir bilgisayarı, elektromekanik bir kolu ya da çeşitli nöroprotezleri kullanmalarını olanaklı hale getirmektedirler. Günümüzde BBA uygulamaları için EEG, tek hücre kayıtlamaları (SCR), fonksiyonel manyetik rezonans görüntüleme (fMRI), bölgesel alan potansiyelleri (LFP), yakın infrared spektroskopisi (NIRS), elektrokortigografi (ECoG), magnetoensefalografi (MEG) gibi teknikler kullanılmaktadır. Bu teknikler içerisinde, pratik olarak elde edilmesi ve uygulanması kolay olduğundan BBA sistemleri için genel olarak EEG seçilmektedir .

BBA tabanlı EEG alanında yapılan arařtırmalardaki amaç, mevcut yöntemlerden daha yüksek sınıflandırma oranına ve beyin-bilgisayar arayüzleşme veri hızına sahip bir yöntem geliřtirmektir.

Bu tez çalışmasında, literatürde kullanılan farklı düşünsel ve görsel uygulamalarda elde edilmiş bir EEG veri kümesi üzerinde çalışıldı. Bu EEG veri kümesinden öznitelik çıkartımı çeşitli matematiksel yöntemlerle analiz edilerek incelendi. Bulunan özniteliklere göre Destek Vektör Makineleri ve KNN sınıflayıcısı kullanılarak sınıflandırma yapılmıştır. Tüm bu çalışmalar daha yüksek sınıflandırma oranı ve yüksek beyin bilgisayar arayüzleşmesi veri hızı elde edebilmek amacı gözetilerek gerçekleştirilmiştir.

Anahtar Kelimeler: EEG, BBA, öznitelik çıkarma, sınıflandırma

SUMMARY

Feature Extraction For EEG Signals Towards Brain Computer Interface Applications

Electroencephalography (EEG) signals are the low amplitude bioelectrical signals which are received from brain surface. Those signals' peak to peak amplitude is 1-400 μ V and frequency band situates between 0.5-100 Hz. Since EEG signals include much information about brain activities, in last years the research in this area has accelerated in the fields of medicine and engineering. In the field of medicine, those signals play an important role in diagnosing neurological diseases and in monitoring success of medical treatments selected. In the engineering field, the features extracted from EEG signals recorded during the mental and visual tasks provide valuable information brain computer interfacing. Brain Computer Interface (BCI) makes possible to people to use a computer, an electromechanical arm or variety of neuroprosthesis without using their muscle systems, in other words without using their motor neurosystems. Nowadays, a couple of techniques, such as EEG, single cell recordings (SCR), functional magnetic resonance imaging (fMRI), local field potential (LFP), Near Infrared Spectroscopy (NIRS), electrocorticography (ECoG) and magnetoencefalography (MEG) are used for BCI implementations. Among these techniques, generally EEG is selected for BCI systems due to the fact that it is easy to apply and practically accessible.

The goal in area of EEG based BCI research is to develop a method which has higher classification rate and brain computer interfacing data rate than existing methods.

In this thesis, it was studied on EEG dataset which was obtained under different mental and visual tasks used in literature. Feature extractions from that EEG dataset were analysed with various mathematical methods. According to discovered features classification was done by using support vector machines (SVM) and KNN classifier. All these studies actualized by considering the goal of to obtain higher classification rate and high brain computer interfacing data rate.

Key Words: EEG, BCI, Feature Extraction, Classification

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1. Nöronun yapısı.....	1
Şekil 1.2. Hans Berger tarafından kaydedilen ilk EEG işareti.....	2
Şekil 1.3. Farklı frekans bandındaki EEG dalgaları	4
Şekil 1.4. 10/20 sistemine göre elektrot yerleşimi	5
Şekil 1.5. Elektriksel sinyalin elektrotta ulaşması	9
Şekil 1.6. BBA sisteminin temel bileşenleri	11
Şekil 2.1. 4. Elektrotun gama band gücü ve 1. elektrotun SCP değeri	28
Şekil 2.2. Deneysel verilerle uydurulmuş bir fonksiyonun(doğrusal) sapmaları.....	35
Şekil 2.3. 3 tane destek vektörlü maksimum sınırlı hiperdüzlem	44
Şekil 2.4a. Hiperdüzlemin tek olmadığı durum.....	45
Şekil 2.4b. Hiperdüzlemin tek olduğu durum.....	46
Şekil 2.5. (a) İki sınıflı veriyi ayıran bir alt düzlem, (b) en iyi alt düzlem ve marjları....	46
Şekil 2.6. Eğitim verilerine ait özdeğerlerin ortalamaları.....	52
Şekil 2.7. PCA, ICA ve korelasyon kullanılarak yapılan sınıflandırma işleminin algoritması	53
Şekil 2.8. YİH'ye ait bir EEG işareti ve bu işaretin YMAK'larına uydurulmuş eğri....	54
Şekil 2.9. AİH'ye ait bir EEG işareti ve bu işaretin YMAK'larına uydurulmuş eğri.....	55
Şekil 2.10. 1. elektrotların YMAK'larına uydurulmuş eğrilerin a değerleri	56
Şekil 2.11. 2. elektrotların YMİN'lerine uydurulmuş eğrilerin a değerleri	56
Şekil 2.12. 1. Elektrotların YMAK'larına uydurulmuş eğrilerden elde edilen tepe noktaları	57
Şekil 2.13. 1. elektrot için a katsayısı ve tepe değerlerinin birlikte gösterimi.....	58
Şekil 2.14. YİH'ye ait ham EEG işareti ve bu işarete uydurulmuş eğri	59
Şekil 2.15. AİH'ye ait ham EEG işareti ve bu işarete uydurulmuş eğri	60
Şekil 2.16. 1. elektrotlara uydurulmuş eğrilerin a değerleri	61
Şekil 2.17. 2. elektrotlara uydurulmuş eğrilerin a değerleri	61
Şekil 2.18. 1. Elektrotlara uydurulmuş eğrilerden elde edilen tepe noktaları.....	62
Şekil 2.19. a katsayısı ve tepe değerlerinin birlikte gösterimi.....	63

Şekil 2.20. YMAK'ların ortaya çıkış zamanlarının birlikte değerlendirilmesi ile elde edilen 2. dereceden polinoma ait öznitelikler	64
Şekil 2.21. YMİN'lerin ortaya çıkış zamanlarının birlikte değerlendirilmesi ile elde edilen 2. dereceden polinoma ait öznitelikler	65
Şekil 2.22. YMAK'lara göre b katsayıları	66
Şekil 2.23. YMİN'lere göre b katsayıları	66
Şekil 2.24. YMAK'lara göre b katsayıları ve TN değerleri.....	67
Şekil 2.25. YMİN'lere göre b katsayıları ve TN değerleri	67
Şekil 2.26. YMAK'tan YMİN'e geçiş zamanlarının gösterimi.....	68
Şekil 2.27. m_i değerleri	69
Şekil 2.28. YMİN'den YMAK'a geçiş zamanlarının gösterimi	70
Şekil 2.29. mn_i değerleri	71

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Brett D. M. ve diğerlerinin yaklaşımları ve elde ettikleri başarımlar	27
Tablo 2. Baojun W. ve diğerlerinin yaklaşımları ve elde ettikleri başarımlar.....	28
Tablo 3. BCI Competition 2003 yarışmasına katılan çalışma gruplarının sonuçları.....	29
Tablo 4. YMAK ve YMİN'e dayalı sınıflandırma sonuçları	58
Tablo5. Ham EEG verilerine yönelik sınıflandırma sonuçları	63
Tablo 6. YMAK+zaman ve YMİN+zaman sınıflandırma sonuçları.....	65
Tablo 7. b değeri ile TN'ye göre yapılan sınıflandırma sonuçları.....	68
Tablo 8. m_i ve mn_i 'ye göre yapılan sınıflandırma sonuçları	71
Tablo 9. Çıkarılan özniteliklere dayalı elde edilen tüm sınıflandırma sonuçları.....	73

SEMBOLLER DİZİNİ

AAR	:	Özbaęlanım parametreleri
AİH	:	Aşğı imleç hareketi
ALS	:	Amiyotrofik lateral sklerozis
ANFIS	:	Adaptive Neuro-Fuzzy Technique
AP	:	Aksiyon potansiyeli
BBA	:	Beyin bilgisayar arayüzü
BCI	:	Brain computer interface
BİUP	:	Beyinsapı İşitsel Uyarılmış Potansiyeller
BSC	:	Bayesian sınıflandırması
C	:	Kovaryans matris
Det	:	Determinant
DSLVO	:	Distinction sensitive learning vector quantization
DV	:	Destek Vektörü
DVM	:	Destek vektör makinaları
ECoG	:	Elektrokortikogram
EEG	:	Elektroensefalogram
ERD	:	Ayırt edilebilir örüntüler
FES	:	Elektrik uyarımı
fMRI	:	Functional magnetic resonance imaging
GTP	:	Görsel tetiklenen totansiyel
GUP	:	Görsel Uyarılmış Potansiyeller
HMM	:	Hidden markov model
Hz	:	Hertz
I	:	Birim matris
ICA	:	Independent component analysis
KNN	:	k-En yakın komşuluk
LDA	:	Linear discriminant analysis
LFP	:	Local field potential
LMD	:	Linear Mahalanobis distance classifier

MEG	:	Magnetoencefalography
m_i	:	Yerel maksimumların yerel minimumlara geçişlerine oranının ortalamaları
MLP	:	Multi-layer perceptron neural network
mn_i	:	Yerel minimumların yerel maksimumlara geçişlerine oranının ortalamaları
MRP	:	Movement Related Signals
NIRS	:	Near Infrared Spectroscopy
P300	:	Beynin yaklaşık 300 ms sonra ürettiği pozitif potansiyeldir
PCA	:	Principal Component Analysis
RESE	:	Random electrode selection ensemble
RP	:	Resting potential
SCP	:	Slow cortical potentials
SCR	:	Single cell recordings
$sign$:	Karar fonksiyonu
SLD	:	Surface Laplacian derivation
SP	:	Sükunet potansiyeli
SSVEP	:	Steady state visual evoked potentials
SUP	:	Somatosensoriyel uyarılmış potansiyeller
SVM	:	Support vector machines
TDA	:	Tekil değer ayrıştırma
TN	:	Tepe noktası
VT1	:	1. veri tabanı
VT2	:	2. veri tabanı
YİH	:	Yukarı imleç hareketi
YKP	:	Yavaş kortikal potansiyel
YMAK	:	Yerel maksimum
YMIN	:	Yerel minimum
Σ	:	Köşegen matris
ε	:	Hata oranı
Φ	:	Özvektör
Λ	:	Özdeğer
σ	:	sigma

μ	:	mü ritmi
α	:	Alfa dalgası
β	:	Beta dalgası
θ	:	Teta dalgası
δ	:	Delta dalgası


1. GENEL BİLGİLER

1.1. Elektroensefalogram

1.1.1. Beynin Fizyolojik Yapısı

Sinir hücresi ya da nöron, sinir sisteminde bilgi iletimini sağlayan en temel parçacıklardır. Sinir hücresi üç bölümden oluşmaktadır; dentritik köprü; giren bilgiyi hücreye iletir, vücut (ya da soma); bilgiyle kaynaşır, akson; diğer nöronlara bilgiyi taşır. Her nöron, akson ve dentritlerinden, diğer nöronlara bağlı haldedirler. Bundan dolayı her bir nöron, sinir sisteminde bağdaştırıcı parça olarak nitelendirilmektedir (Qian ve Chen 1996).

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




Şekil 1.1. Nöronun yapısı

Beynin herhangi iki ucu arasında en uzak mesafe kabaca 17cm'dir ve örneğin önden arkaya doğru gidildiğinde, bölge bölge nöronal fonksiyon birimleri görülmektedir. Bu bölgelerde var olan yoğun nöronlar grubuna, nüklei adı verilmektedir. Beyin herhangi belli bir görevi yaparken, görevle alakalı nüklei aktive olur, bilgiyi işler ve gönderir [1]. Bu

aktivite durağan olmayan işaret olarak gözlenir ve bu bir çok nöronun, aynı anda gösterdiği dentritik potansiyellerin cebirsel toplamına elektroensefologram (EEG) adı verilmektedir.

1.1.2. İlk EEG

İlk defa 1929 yılında, Alman Hans Berger tarafından insan beyninin aktivitesinin varlığı, kafaya yerleştirilen elektrotlar ve bunlara bağlı bir galvanometre yardımıyla ortaya koyuldu. Bu gelişme devrimsel bir buluş olmuştur. Bu sayede tamamen yeni ve çok önemli bir tıbbi bilim dalı keşfedilmiş oldu: Klinik nörofizyoloji. Hans Berger tarafından ilk kaydedilen EEG örneği Şekil 1.2’de gösterilmiştir [2].



Şekil 1.2. Hans Berger tarafından kaydedilen ilk EEG işareti

1.1.3. EEG İşaretlerinin Özellikleri

EEG işaretleri, beyin yüzeyinden elektrotlarla algılanan düşük genlikli biyoelektrik işaretlerdir. Kafa üzerinden algılanan EEG’lerin genliği tepeden tepeye 1-400 μ V ve frekans bandı ise 0.5-100 Hz’dir ve bu işaretlerde çok miktarda bilgi saklandığı yapılan çalışmalarla ortaya çıkmaktadır. Klinik tanılarda, nörolojik rahatsızlıkların çözümünde bu bilgilere çokça başvurulur. Ölçümler beyin üzerinden doğrudan alındığı takdirde, genlik 10 kat daha artar.


EEG, tıpta, başta epilepsi (sara hastalığı) olmak üzere bir çok beyin rahatsızlıklarının teşhisinde ucuz ve hastaya acı vermeyen bir yöntem olduğu için yaygın olarak kullanılır. EEG’yi oluşturan beyin dalgalarının değerlendirilmesi ile bu rahatsızlıkların yeri ve şekli hakkında bilgi edinilir. Ayrıca biyomedikal mühendisliğinde beynin dinamiklerini ortaya koymak için kullanılırlar. Ancak beyin kompleks yapısı ve kontrol ettiği karmaşık işlemlerle birlikte, algılanan işaretlerin düşük genlikli olması bu bilgilere ulaşılmasını zorlaştırmaktadır. Dolayısıyla iyi bir EEG çekimi yapmak için, vücuttan veya dışardan kaynaklanan, gürültü veya istenmedik etkileri azaltacak önlemler alınmalıdır. EEG

işaretleri, ölçüm yaparken oda içerisindeki ışığın açık veya kapalı olması ve çevrede elektromanyetik dalga yayabilecek cihazların bulunması gibi dış etkenlerden ve yine ölçüm yaparken kişinin gözünü kırpması, kalp atışları, kolunu sağa-sola hareket ettirmesi gibi fiziksel aktivitelerden etkilenir.

EEG işareti geniş bir frekans bandına sahip olmakla birlikte, klinik ve fizyolojik ilgi 0.5 ile 30 Hz arasına yoğunlaşmıştır. Bu frekans aralığı 4 frekans bandına ayrılmıştır.

Bunlar:

1. Delta (δ) Dalgaları: Frekansları 0.5-4 Hz, genlikleri 20-400 μ V arasında değişir. Derin uyku, genel anestezi gibi beyin çok düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.
2. Teta (θ) Dalgaları : Frekansları 4-8 Hz, genlikleri 5-100 μ V arasında değişir. Normal bireylerde; rüyalı uyku, orta derinlikte anestezi, stres gibi beyin düşük aktivite gösterdiği durumlarda karşılaşılmaktadır.
3. Alfa(α) Dalgaları : Frekansları 8-13 Hz, genlikleri 2-10 μ V arasında değişir. Uyanık Bireylerin; fiziksel ve zihinsel olarak tam dinlenimde bulunduğu, dış uyarılarının olmadığı, gözlerin kapalı olduğu durumlarda görülürler.
4. Beta (β) Dalgaları : Frekansları 13 Hz fazla olanlar, genlikleri 1-5 μ V arasında değişir. Odaklanmış dikkat, zihinsel iş, duyuşal enformasyon işleme, uykunun hızlı göz hareketleri evrelerinde karşılaşılmaktadır. Beta dalgaları en yüksek aktivite düzeyine karşılık gelir. Şekil 1.3'te tüm dalgalara ait EEG örnekleri gösterilmiştir.



Şekil 1. 3. Farklı frekans bandındaki EEG dalgaları

1.1.4. EEG Elektrotlarının Bağlanma Şekilleri

Elektrotların kafa derisine yerleştirilmesi için kullanılan standart metot Uluslararası EEG Federasyonu Birliği (International Federation of EEG Societies) tarafından belirlenmiş olan 10-20 elektrot sistemidir. Bu yerleşme şeklinde baş dört standart noktayla işaretlenmiştir. “Nasion” , burun; “inion” , kafanın arka kısmı; sağ ve sol preauriküler. “Nasion” ve “inion” arası % 10- 20- 20-20- 20 ve 10 olacak şekilde bölünerek elektrotlar yerleştirilmiştir. Diğer elektrotlar, bu elektrotlarla birlikte bir daire oluşturacak şekilde yerleştirilirler. Böylece 19 elektrot kafa üzerine yerleştirilmiş olur. Kulak memesine yerleştirilen 20. elektrot ise toprak elektrotu olarak kullanılır. Bu sisteme göre elektrot yerleşimleri Şekil 1.4’te gösterilmiştir. Daha çok sayıda elektrot yerleşimi için ise genişletilmiş 10/20 sistemi veya eşuzaklıklı sistemler kullanılır.

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

Fp: frontal kutup (pole)

F: frontal

C: santral (central)

T: temporal

P: pariyetal

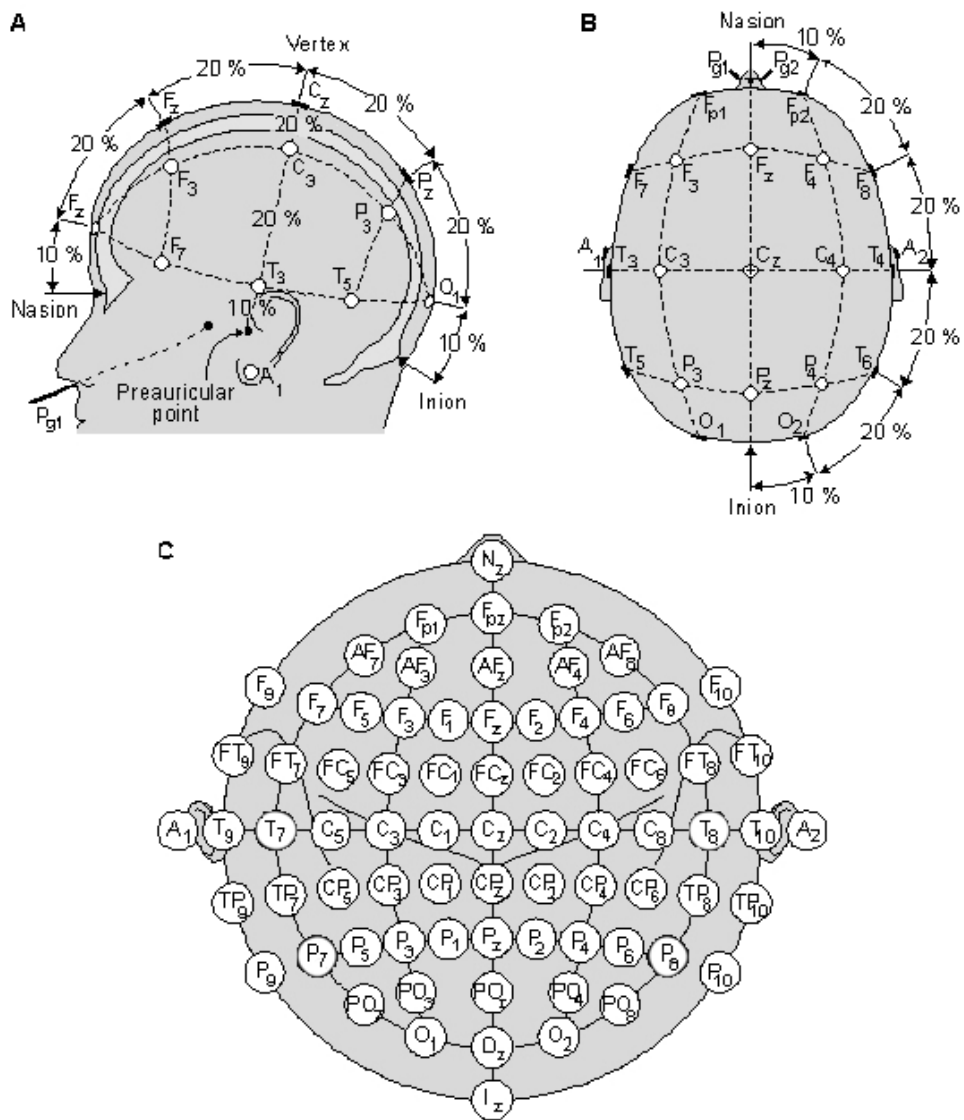
O: oksipital

İki harfin kombinasyonu ise ara elektrot yerleşimlerini gösterir, örneğin:

FC: frontal ve santral elektrot yerleşimlerinin arasında yer alır.

PO: pariyetal ve oksipital elektrot yerleşimlerinin arasında yer alır.

Kafanın sol tarafındaki elektrotlar tek sayılar ile, sağ tarafındaki elektrotlar çift sayılar ile, orta hat elektrotları ise küçük "z" harfi ile gösterilir.



Şekil 1.4. 10/20 sistemine göre elektrot yerleşimi, A: soldan kafaya bakış B: Üstten kafaya bakış C: Genel Gösterim

1.1.5. Uyarılmış Potansiyeller

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

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

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

şekillerine bakılarak normal değerler ve diğer kulaktan elde edilen değerler ile karşılaştırma yapılır. Aynı işlem diğer kulak için de tekrarlanır.

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

1.2. Beyin Bilgisayar Arayüzü

1.2.1. Giriş

İnsanlar makinalarla iletişim kurmak için çeşitli araçlardan faydalanır: Klavyeler, fareler, dokunmatik yüzeyli ekranlar, özel eldivenler, mikrofonlar vs. Tüm bu komut verme araçları kullanıcının vücudunun belli bir kısmını (daha doğrusu kas sistemini) kontrol edebildiğı varsayımına dayanır. Ancak durum her zaman böyle değildir. Söz gelimi motor nöron hastalıklarından biri, amiyotrofik lateral sklerozis (ALS) sadece ABD'de onbinlerce kişiyi etkilemekte ve insanların istemli hareketlerini engellemektedir [3]. ALS, beyin ve omurilikteki motor nöronlara saldırmakta ve kısa sürede hasta hiçbir kasını hareket ettiremez hale gelmektedir. Benzer duruma yol açan motor nöron problemleri arasında beyin kökü travması, beyin ya da omurilik yaralanması, serebral palsi, kas distrofileri ve çoklu skleroz yer almakta, bunların 2.000.000'a yakın hastayı etkilediğı bilinmektedir.

Ancak önemli olan şey ALS hastalığının sadece ve sadece motor nöronları etkilediğı, yani hastanın bilişsel işlevlerine bir zarar vermediğı gerçeğidir. Hafıza, zekâ ve kişilik korunur. Hastalar görebilir, duyabilir, koklayabilir ve dokunsal uyarınları yorumlayabilirler [3]. Bu da demektir ki, eğer hastanın beynindeki sinirsel etkinliğı doğrudan yorumlayabilecek bir teknoloji geliştirilebilirse hastanın çevresindeki araçlarla ve insanlarla iletişim kurması mümkün olabilir.

Beyin Bilgisayar Arayüzü (BBA) , kişilerin kas sistemlerini bir başka deyişle motor sinir sistemlerini kullanmadan bir bilgisayarı, elektromekanik bir kolu ya da çeşitli nöroprotezleri kullanmalarını olanaklı hale getiren sistemlerdir. Günümüzde BBA uygulamaları için EEG, tek hücre kayıtlamaları (SCR), fonksiyonel manyetik rezonans görüntüleme (fMRI), bölgesel alan potansiyelleri (LFP), yakın infrared spektroskopisi (NIRS), elektrokortigografi (ECoG), magnetoensefalografi (MEG) gibi teknikler kullanılmaktadır. EEG bu teknikler içerisinde en hızlı erişilebilir, karar verme süresi daha erken olmasından dolayı ve pratik olduğu için BBA sistemleri genel olarak EEG tabanlı geliştirilmeye çalışılmaktadır.

"Beyin bilgisayar arayüzü" terimini ilk kullanmış olanlardan biri Jacques J. Vidal'dir [4], [5]. Vidal, 1973 yılındaki çalışmasında EEG sinyallerini algılayıp, çözümleyip belli örüntüleri bulup bunları önceden tanımlanmış hareket komutları olarak yorumlayan karmaşık bir bilgisayar sistemi geliştirmiştir. "Bağımlı BBA" olarak tanımlanan bu sistem, ki bu sistem aşağıda daha detaylı incelenecektir, kullanıcının göz hareketlerini kontrol etme kabiliyetine dayanıyordu. Özetle BBA'yı mümkün kılan, beynin ürettiği sinyalleri kaydedip bunları örüntü çözümü ve sınıflandırmasına tabi tutabilme yeteneğidir denebilir.


1.2.2. EEG ile Beyin Bilgisayar Arayüzü Arasındaki İlişki

Daha öncede belirtildiği üzere elektroensefalografi terimi ilk kez Berger tarafından kullanılmıştır [2]. Berger, insan kafatası yüzeyinden beyin dalgalarının tespit edilebileceğini ve okunabileceğini göstermiştir.

Vidal'e göre kafatası yüzeyi elektriksel potansiyellerinin ana kaynağı kafatasının hemen altındaki beynin dış kabuğunu meydana getiren serebral korteksteki elektriksel etkinliktir. Serebral korteks, sinir hücreleri (nöronlar) içeren gri maddeden oluşan ince bir tabakadır. Bu hücrelerin bir kısmı (piramit hücreleri) apik dendritlere sahiptir. Yani beyin yüzeyine doğru uzanır ve yanlamasına genişlerler. Bunun sonucunda ince bir beyaz madde yüzeyi oluşur ve burada da yoğun şekilde iç içe geçmiş ince dendrit uzantıları diğer komşu dendritlerle bağlantı kurarlar. Dendritler elektrik alanı nöron merkezine ileten elektrolitik bağlantı araçlarıdır. Hücre merkezine ulaşan elektrik sinyali hücre zarını depolarize ederek hücre atımını tetikler ve böylece sinyal yeniden diğer bir tür hücrelerarası bağlantı elemanı olan akson üzerinden ilerler. Gözlemlenen yüzey potansiyelleri piramitsel hücrelerin

tepedeki dendritlerinde ve hücre merkezinde üretilir. Bu potansiyeller hücre içindeki polarizasyon ve depolarizasyona karşılık gelir (bu elektrik potansiyel değişimleri sinaps sonrası olarak nitelendirilir çünkü nöronlararası sinaps etkileşiminde gerçekleşir). Hücrelerarası alanda dikey olarak ilerleyen elektrik akımlarının aynı zamanda dendritler ile derinlerdeki hücreler arasında bir tür geribesleme bağlantısı sağladıkları da düşünülmektedir. Yüzeyle pozitif olarak kaydedilen bir değişim derin bölgelerdeki bir depolarizasyona (daha yüksek uyarılabilirlik) karşılık gelir ve bunun terside doğrudur.

Şekil 1.5'te piramitsel hücrelerin beynin üst kısmında nasıl yerleştikleri ve EEG sinyal algılaması ve kaydedilmesi için elektrotlara yakın buldukları şematik olarak gösterilmektedir.



Şekil 1.5. Elektriksel sinyalin elektrotta ulaşması

1.2.3. Beyin Bilgisayar Arayüzü Çeşitleri

BBA çeşitleri, bağımlı BBA ve bağımsız BBA olmak üzere iki adettir [6]. Bu ayırım, beyin çıktısı yollarına olan bağımlılık ile ilgilidir.

1.2.3.1. Bağımlı Beyin Bilgisayar Arayüzü

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

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

1.2.3.2. Bağımsız Beyin Bilgisayar Arayüzü

Bağımsız bir BBA sistemi sağlam bir çevresel sinir sistemi gerektirmez. Böyle bir BBA sadece kullanıcının eğilimlerine dayanır.

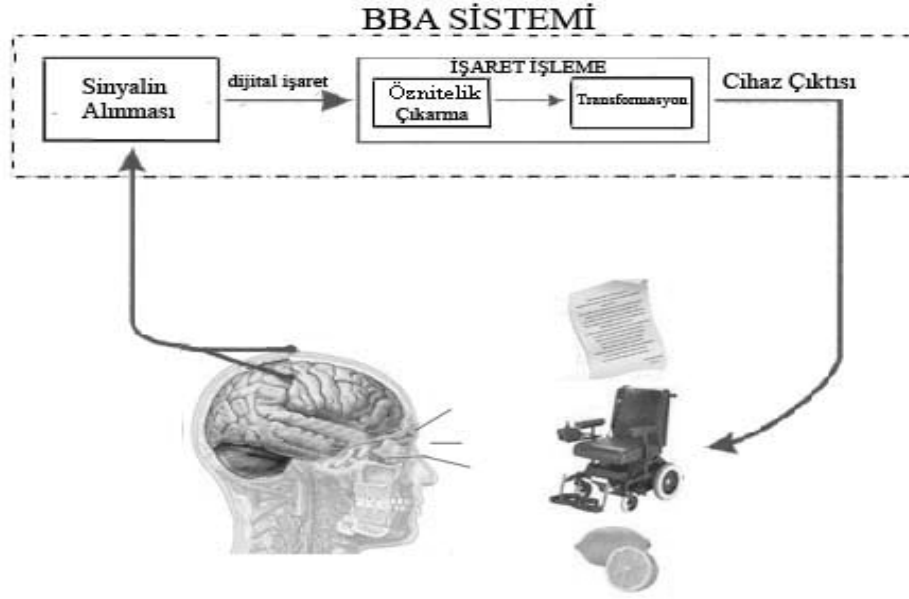
Yine yukarıdaki harf seçme örneğini göz önüne alacak olursak, eğer bağımsız BBA kullanılırsa kullanıcının tek yapması gereken istediği harfi düşündürmektir. Bu mekanizmada gözün hareketi ya da kontrolü ile ilgili hiçbir şey söz konusu değildir. Bu durumda EEG tarafından tespit edilen P300 potansiyelidir. P300 potansiyeli aşağıda açıklanacaktır.

1.2.4. Beyin Bilgisayar Arayüzü Sisteminin Temel Bileşenleri

Modern bir BBA sistemi beş alt sisteme bölünebilir:

1. Sinyal toplama
2. Sinyal işleme: öznitelik çıkarma
3. Sinyal işleme: dönüştürme algoritması
4. Çıktı cihazı
5. İşletme protokolü

Bu sistemlerin işleyişi Şekil 1.6'da gösterilmiştir.



Şekil 1.6. BBA sisteminin temel bileşenleri[6]

1.2.4.1. Sinyal Toplama

Sinyal toplama bir BBA sürecindeki ilk adımdır. Beyinde gelen sinyalleri tespit edip kaydetmek için en yaygın kullanılan yöntem EEG'dir. EEG müdahaleci olmayan bir yöntemdir ancak beyinde elektriksel iletişim haricinde de iletişim gerçekleştiği için fonksiyonel manyetik rezonans görüntüleme(fMRI) gibi yöntemlere de başvurulduğu olur. Weiskopf'un 2004'teki bir çalışmasında beyin sinyallerini algılamak için fMRI kullanımından bahsedilir [7].

Beyin sinyallerini kaydetmek için kullanılan bir başka yöntem de müdahaleci tekniklerdir. Kennedy, 2004 yılındaki bir çalışmasında beyin yüzeyine yerleştirilen bir sinirsel implant ile beyin yüzeyi sinyallerinin algılanıp sonra da bir bilgisayar imlecini kontrol etmek için kullanılan BBA sistemini tarif etmektedir [8].

1.2.4.2. Sinyal İşleme: Öznitelik Çıkarma

Elektrik sinyalleri EEG kullanılarak kaydedildikten sonra bunlardaki özniteliklerin tespit edilmesi, çıkarılması gerekir. Bu süreç, örüntü tanıma ve sınıflandırma öncesindeki bir ön işleme olarak düşünülebilir.

Bu süreçte ham sayısal sinyal verisi alınır ve bazı bakımlardan özetlenir. Uzamsal süzme, spektral çözümleme ve voltaj şiddeti ölçümleri öznitelik çıkarmada kullanılan tekniklerden bazılarıdır.

1.2.4.3. Sinyal İşleme: Dönüştürme Algoritması

Sayısal beyin sinyal verisi özetlenip bazı öznitelikleri çıkarıldıktan sonra bu bilginin içindeki örüntülerin taranması ve tanınması gerekmektedir. BBA sistemi ancak bu şekilde hangi komutların gerçekleştirilmesi gerektiğini anlayabilir.

Toplanan verideki özellikleri çözümlenmek için çeşitli algoritmalar kullanılır. İki yaygın kategori vardır: bunlardan birincisi doğrusal denklem tabanlı istatistiksel çözümlenmeler ve yapay sinir ağları diğeri ise benzeri doğrusal olmayan örüntü sınıflayıcılarıdır.

Bu algoritmalar esnek yani yeniden uyarlanabilir ve hatalara karşı dayanıklı olmalıdır çünkü BBA kullanıcısı her seferinde aynı şeyi düşünüyor olsa da beyin sinyallerinde çeşitli sapmalar, ufak tefek dalgalanmalar mutlaka olacaktır. Algoritmanın esnekliği öğrenme açısından da önemlidir. Bu olay bir konuşma veya görüntü işleme uygulaması gibi de düşünülebilir. Bu uygulamalar işleyecekleri veri için eğitilirler ve genellikle işleyecekleri verinin karakteristikleri de bazı bakımlardan o kullanıcıya özgü olur. Bunların ötesinde algoritmanın esnekliğinin ve öğrenme yeteneğinin önem arz ettiği bir başka durum da vardır: İnsan süreç içinde aynı kalmaz. Ufak tefek metabolizma değişiklikleri, hastalıklar, mevsimsel değişimler ve hatta günün hangi saatinde olduğu kişinin vücudunu ve dolayısı ile beyninin işleyişini bazı bakımlardan değiştirir.

Üçüncü seviye uyarlanabilirlik ise oldukça detaylı bilgi işleme algoritmalarını gerektirmektedir. Bu aşamadaki uyarılama BBA sisteminin, beynin o sisteme uyum sağladığını fark etmesini gerektirir. Diğer bir ifadeyle kullanıcının beyni BBA sistemini nasıl kullanacağını öğrenirken değişmektedir ve BBA kendisine adapte olmaya çalışan beyin ile uyum içinde çalışıp beyne düzgün şekilde geri besleme verir, kullanıcıyı doğru

bir zamanlama ile ödüllendirirse, makina ile kullanıcı arasında güçlü bir bağlantı oluşur. Bu da makinanın çok daha iyi bir başarımla çalışması anlamına gelir.

1.2.4.4. Cihaz Çıktısı

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

1.2.4.5. İşletim Protokolü

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

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

1.2.5. Modern Beyin Bilgisayar Arayüzü Örnekleri

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

1. GTP
2. Yavaş kortikal potansiyeller
3. P300 tetiklenen potansiyeller
4. μ ve β ritimleri
5. Kortikal nöronlar

1.2.5.1. Görsel Olarak Tetiklenen Potansiyeller

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

Daha önce belirtildiği gibi 70'lerde Vidal tarafından BBA araştırmalarında kullanılan ilk sinyal türü GTP idi. Ancak bu BBA sistemi bağımlı BBA olup hastanın az da olsa gözünü bir yere odaklayabilmesini gerektiriyordu. Burada önemli olan nokta dikkat seviyesi ve bakışın yöneldiği yer ile bilginin tamamen EEG ile toplanıyor olmasıdır yani hiçbir şekilde gözün kendisi üzerinden bir ölçüm yapılmamaktadır.

GTP kullanan modern bir BBA sistemine örnek olarak Middendor gösterilebilir. Kullanıcı ekrandaki düğmelerden birini bakışlarını oraya odaklayarak seçebilir [9].

1.2.5.2. Yavaş Kortikal Potansiyeller

Yavaş kortikal potansiyel (YKP) biyoelektriksel beyin sinyalindeki potansiyel kaymadır [10]. Negatif YKP'ler genellikle kortikal etkinliğe yol açan hareket ve benzeri işlevlerle bağlantılı iken pozitif YKP'ler de seviyesi düşen kortikal etkinlikle ilgilidir. Negatif kaymalar genellikle beynin primer görsel korteksinin görsel uyarana karşı verdiği elektriksel tepkidir.

Bu tür sinyaller EEG verisindeki çok yavaş voltaj değişimleri olarak algılanır. Bu değişiklikler 0.5 ile 10 saniye arasında gerçekleşir.

Yavaş kortikal potansiyellerle ilgili en önemli nokta, insanların bunları kullanmak üzere biyogeribesleme aracılığı ile eğitilebilmeleridir. Dolayısı ile YKP'ler BBA operasyonunun temelini oluşturur. YKP'leri kullanan en meşhur BBA'lerden biri Düşünce Tercüme Cihazıdır [11].

1.2.5.3. P300 Tetiklenen Potansiyeller

P300 tetiklenen potansiyeli alakasız bir uyarın dizisi içine gömülmüş dikkat çekici bir uyarın ile karşılaşan beynin yaklaşık 300 ms sonra ürettiği pozitif potansiyeldir [12]. Tipik bir P300 dalga formu Gauss dağılımını andırır, yarı genişliği 150 ms olup şiddeti 100 mikrovolta kadar çıkar. Genellikle temiz bir P300 dalgası elde edebilmek için pek çok

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

P300 potansiyellerini kullanan BBA sistemlerinin kullanımları daha çok yenidir. Yapılan bir çalışmada sistemin kullanıcıları bilgisayar monitöründe yanıp sönen harflere bakarak istedikleri harfi seçebilmektedir. Sistemin performansı dakikada yaklaşık 1 kelime kadardır. P300 tabanlı BBA sistemlerinin avantajlarından biri kullanıcının eğitilmesine pek gerek duyulmamasıdır yani sistem çok kısa sürede kullanılabilir hale gelmektedir. Bu tür çalışmalar çok yeni olduğundan P300 BBA'ların kullanıcı beyninin sisteme alışmasından kötü etkilenip etkilenmeyeceği henüz bilinmemektedir [13].

1.2.5.4. μ ve β Ritimleri

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

β ritimleri ise 18-25 Hz aralığındadır ve bunlar da istemli hareket ve etkin odaklanma ile bağlantılıdır.

Yapılan çalışmalarda insanların 8-12 Hz aralığındaki μ ritimlerini ve 18-25 Hz aralığındaki β ritimlerini kontrol edebildikleri ve böylece ekrandaki bir imleci istedikleri gibi hareket ettirebildikleri görülmüştür [14].

Gerçek ve hayal edilen hareketleri kıyaslayarak ve temel bileşen analizi kullanarak bu ritimler çözümlenmiş ve hem gerçek hareketlerin hem de hayal edilen hareketlerin μ ve β ritim desenkronizasyonları ile bağlantılı olduğu tespit edilmiştir [14].

μ ve β ritimlerinden faydalanan örnek bir çalışma Wolpaw tarafından yapılmıştır. Bu sistemde kullanıcı ekrandaki imleci iki boyutlu olarak kontrol edip sadece düşünerek ve bedeninin başka hiçbir yerindeki hareketlere dair bir şey gerçekleştirilmeksizin bir bilgisayar oyununu oynayabilmektedir [15].

1.2.5.5. Kortikal Nöronlar

BBA için daha ender kullanılan yöntemlerden biri ise müdahaleci bir yöntemdir ve bu yöntemde beyin yüzeyine elektrotlar yerleştirilir. Bu şekilde tek tek nöronların eylem potansiyelleri ve tetiklenme oranları kaydedilebilmektedir [16]. Kortikal nöronlara müdahale ederek oluşturulan BBA sistemleri de vardır [8].

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

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

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

1.3. Literatür Araştırması

Son 15 yılda BBA'ya olan ilgi artmıştır. Bu alanda bir çok yenilikçi çalışmalar yapılmaktadır. EEG'ye dayalı BBA araştırmaları yürütülen başlıca laboratuvar ve araştırmacıların çalışmaları aşağıda özetlenmiştir:

Graz Teknik Üniversitesinden Gert Pfurtscheller ve diğerleri bazı hareketlerin düşünsel ve görsel hayali sırasında sensorimotor bölgeden kayıt edilen EEG işaretlerini gerçek zamanlı sınıflandırılarak örneğin imleç kontrolünde kullanılmıştır. Gerçek zamanlı deneylerde, değişik EEG öznitelik çıkartma ve sınıflandırma yöntemleri değerlendirilmiştir. Öznitelik çıkartılması için kullanılan yöntemler, kişiye has frekans bantlarının bulunması için bant gücünün hesaplanması, uyarlanabilir özbağlaşım parametrelerinin(AAR) yinelemeli en küçük kareler algoritması ile her özyineleme için hesaplanması, genel uzamsal filtrelerin hesaplanması (*Common Spatial Patterns*) şeklindedir. Kişiye has öntanımlı frekans bandının bulunması, başlangıç deneyinin geri

beslemesiz olması demektir. Bunun için distinction sensitive learning vector quantization (DSLVC) algoritması ve dalgacık dönüşümü algoritması kullanılmıştır [17,18].

Christoph Guger ve diğerleri Çok değişik tipte parametre kestirim ve sınıflandırma algoritmalarının gerçek zamanlı kullanımı ve testi arasında hızlı geçişler için, "hızlı prototip" yeni beyin bilgisayar arayüzü sistemini 2001 yılında önermiştir [19].

Yine Gert Pfurtscheller ve diğerleri yüzey elektrotları kullanarak işlevsel elektrik uyarımı(FES) ve EEG kayıtlarını kullanarak, kolları ve bacakları felç olmuş hastalarda, ilk kez cerrahi müdahale olmaksızın el-kavrama işlevinin restore edilebileceğini göstermiştir [20]. Hasta, ayak hareketi hayali ile EEG işaretlerinin *beta* salınımlarında parlamalar yaratabilmektedir. Bu *beta* parlamaları, BBA tarafında analiz edilip sınıflandırılarak çıkış işareti, FES cihazını kontrol etmek için kullanılmıştır. Hasta felçli eli ile bir silindiri kavrayabilmektedir.

Acı vermeyen (*non-invasive*) EEG kayıtları işlevsel FES işlemine kontrol sinyali üretmek için kullanılabilir. Bu gibi, nakil edilebilen nöro-protezlerin EEG temelli kontrolü Lauer ve diğerleri [21] tarafından rapor edilmiştir. Bu çalışmada ilk kez rapor edilen kol-bacak felçlide yüzey elektrotları kullanılarak "düşünce" temelli FES kontrolüdür.

Başka bir çalışmada Andreas Spiegler ve diğerleri ilk kez faz kilitleme değeri, dil hareketi hayali sırasında, farklı motor bölgelerdeki sensorimotor ritimlerin faz bağlaşımını araştırmış ve iki yenilikçi sonuç çıkarmışlardır. Bunlardan ilki dil çıkartma hareketinin hayali sırasında, sol ve sağ el bölgesinde mu ritminde (8-12Hz) genlik artması tespit edilmiştir. İkincisi Primary sensorimotor ele karşılık gelen bölge (C3-C4 elektrotları) ile premotor bölge (Cz elektrodu) arasında 10 Hz salınımlarında faz bağlaşımı meydana gelmektedir. Motor hayal sırasındaki bağlaşım sonuçlarının bütünleyici motor bölgedeki nöron ağları ve her iki hemisferdeki primary sensorimotor bölgelerdeki ağlar arasında ayrı bir etkileşime işaret etmekte olduğu ileri sürülmektedir [22].

Yine Graz'da yapılan çalışmalarda bir vaka çalışması EEG temelli BBA ile kola nakledilmiş nöro-protezin (Freehand sistemi) birleşimi incelenmiştir. Hastanın sadece üç günü vardır ve kısa eğitim süresinde motor hareket hayaline dayalı GRAZ BBA sistemi üzerinde kontrol kazanmalıdır. Hasta organize ve koordine edilmiş eğitimi uygulayarak felçli sol elinin motor hareket hayali ile ayırt edilebilir örüntüler (ERD) yaratmayı başardı. BBA'nın çıktı işareti genellikle omuz koşumunun kontrolü için kullanıldı ve ardışık motor hayaller kullanarak Freehand sisteminin izin verdiği değişik kavrama hareketleri arasında geçişler yapıldı. Bazı kavrama-bırakma testlerinin yapılmasından sonra hasta basit bir

nesneyi bir yerden başka bir yere taşımayı başardı. Bu kısa sürede hastanın BBA'yı kontrol etmesi gerçeği, bu yöntemin klinik uygulamalara alternatif bir yaklaşımdır [23].

Wadsworth Merkezindeki Araştırmalarda Jonathan R. Wolpaw ve diğerleri birincil olarak sensimotor korteks bölgesinde kafa derisi üzerinden alınan EEG ritimleri ile bir veya iki boyutta imleç kontrolüne odaklanmıştır. Çalışmalar, kullanıcı ve sistem arasındaki uyarlanabilir etkileşimi optimize ederek, işaret özelliklerinin seçimini iyileştirerek ve ek işaret özellikleri ekleyerek kontrol işaretinin oluşturulmasını iyileştirmektedir. İlerlemelerin karşılaştırılabileceği ve diğer araştırma gruplarının da kullanabileceği, BCI-2000 adında genel amaçlı beyin bilgisayar arayüzü sistemi, alternatif BBA yöntemlerini birleştirerek geliştirilmiştir. Sonuç olarak diğer gruplarla iş birliği içinde basit BBA uygulamaları geliştirilmektedir ve motor engelliler için pratikliği ve değeri test edilmektedir [24, 25].

Wadsworth merkezindeki gerçekleştirilen EEG tabanlı BBA, imleci hareket ettirmek için sensimotor bölgedeki *mu* veya *beta* frekans bandını kullanır. Eğitilmiş denekler imleci bir veya iki boyutta hareket ettirebilir. Bu araştırmanın birincil amacı, çeşitli nedenlerden motor engelli insanlara yeni iletişim ve kontrol seçeneği sağlamaktır. Şu anda her bir yöndeki imleç hareketi, EEG'nin bir veya iki özelliğinin (farklı elektrot yerlerindeki spektral bantlar) doğrusal fonksiyonundan deneysel olarak saniyede 10 kez türetilir. Bu çalışmada, imleç hareketinin doğruluğunu iyileştirmek için araştırılan yöntemlerin verileri offline analiz için sistem çalışırken toplandı. Kullanıcılar, düşey imleç hareketini (bir boyut) kontrol ederek olası üç hedefi seçerken EEG işaretleri kaydedildi. Üç yöntem, imleç hareketinin boyutsallığındaki farka göre (bir boyuta karşılık iki boyut) ve fonksiyon tipine göre (doğrusala karşılık doğrusal olmayan) analiz edildi. EEG özellikleri sayısı, her bir yöntemin başarısını nasıl etkiliyor? Bütün yöntemler 10-20 özellikle optimum performanslarına ulaşmıştır. Offline simülasyonda, 1 boyutlu doğrusal yöntem ile karşılaştırıldığında; 2 boyutlu doğrusal yöntem ve 1 boyut doğrusal olmayan yöntem başarımları önemli derecede iyileştirilmiştir. 1 boyutlu doğrusal yöntemde aynı başarı elde edilememiştir. Bu offline sonuçlar, 1 boyutlu doğrusal olmayan veya 2 boyutlu doğrusal yöntem, BBA sistemi online çalışmasını iyileştireceği sonucunu doğrulamıştır [26,27].

Berlin Üniversitesinde Klaus-Robert Müller ve diğerleri, çalışmalarında "Sanal Klavye:Virtual Keyboard" EEG ile çalışan harf heceleyen cihaz tasarlamışlardır. EEG düşünsel el ve ayak motor hayali ile modüle edilir. Sanal Klavyeyi kullanan üç engelsiz kişi ile çalışılmıştır. Sanal Klavyeyi hatasız yazarak kullanma becerileri 0.85 ve 0.5

harf/dakika arasında değişmektedir. Çalışmada Whitening dönüşümü ve HMM sınıflandırıcısı kullanılmıştır [28].

Başka bir çalışmada Klaus-Robert Müller ve diğerleri çok kanal EEG'de sağ el, sol el hareket hayali sırasında, tek süpürümlü EEG'den iki grubu ayırt edecek bilgiyi etkin şekilde çıkartmışlardır. Üç denekte en iyi sınıflama sonuçları %90.8 , %92.7 ve %99.7'dir. Genel Uzaysal Örüntüler (*Common Spatial Patterns CSP*) yöntemi ile veri kümesinden uzaysal filtreler kestirilmiştir ve kortikal bölgelerdeki aktiviteyi göstermiştir. Yöntem, sınıflandırmadaki önemine göre elektrotlara bir ağırlık verir. Bu yöntemin yüksek tanıma oranı ve hesaplama kolaylığı, EEG temelli BBA lar için umut vericidir [29].

[30,31,32] numaralı yapılan çalışmalarda bulunan özneliklere göre yapılacak sınıflandırma işlemlerinin öneminden bahsedilmekte ve bu konuda kıyaslamalar yapılmaktadır.

Beyinin durumu ile ilgili daha fazla bilgi toplamak için çok kanal EEG kullanılabilir. Son zamanlarda çok kanallı EEG analizleri, her bir EEG kanalı için bir yapay sinir ağını eğitmenin ve bütün ağları birleştirmenin, sınıflama doğruluğunu arttırdığını göstermiştir [40]. Başka bir yaklaşım, varyansları en ayırt edici bilgiyi içeren, çok az sayıda zaman serisi yapılandırılan, genel uzamsal örüntüler(*common spatial patterns CSP*) yöntemi ile tasarlanan uzaysal filtrelerdir. Doğrusal ayırt ediciler ile sınıflandırılırlar [33].

EEG temelli beyin-bilgisayar arayüzü genellikle ayırt etme/sınıflandırma yöntemlerini bozacak şekilde çok gürültülü, durağan olmayan ve yapay olgular ile kirletilmiş durumdadır. Bu çalışmada, bu bozucu etkileri hafifletmek amacıyla Genel uzamsal örüntüler (*CSP*) algoritması geliştirmişlerdir. Özellikle CSP'nin durum uzayına bir genişlemesi olarak zaman gecikmeli gömme yöntemi kullanılmıştır. Orijinal CSP yöntemi üzerinden ileri sürülen yöntemin avantajları, hayal edilen kol-bacak hareketi deneyinden alınan EEG kayıt kümesi üzerinde iyileştirilmiş bilgi aktarım hızı (süpürüm başına bit) terimi üzerinden sağlaması yapılmıştır [34].

Bin He ve diğerleri kafa derisi üzerinden alınan EEG kayıtlarında kaynak analizini kullanarak beyin-bilgisayar arayüzü uygulamalarında motor hayal sınıflaması sağlayan çalışmaları kılavuz bir çalışmadır. Sağ veya sol motor hayali ile ilgili işaret bileşenlerini çıkartmak için bağımsız bileşen analizi (*independent component analysis-ICA*) uzamsal-zaman filtresi olarak kullanılmıştır. Motor hayale karşılık denk nöronal kaynakları oluşturmak için kaynak analiz yöntemleri; denk dipol analizi ve kortikal akım yoğunluğu görüntülemesi uygulanmıştır ve ters-çözümü temel alan sınıflandırma uygulanmıştır. Eğer

motor korteksin karşılık gelen yarı küresinde denk-kaynak bulunursa sınıflandırma doğru olarak ele alınabilir. Hem denk-dipol analizinde hem de kortikal akım yoğunlu analizlerinde, insan deneklerde sınıflandırma ölçüsü %80 civarında elde edilmiştir. Bu sonuçlar, kortikal aktivitenin temiz bir resmini ortaya koyar ve böylelikle hareket hayalinin sınıflandırılmasına yardımcı olur [35].

Bin He ve diğerlerinin başka bir çalışmada motor hareket hayalini sınıflandırmak için EEG ters çözümünü kullanarak yeni bir yaklaşım geliştirmişleridir. Beyin-bilgisayar arayüzünde motor hareket hayalinin sınıflandırılmasını desteklemek için iki-denk-dipol analizi önerilmiştir. Tek süpürümde alınan veri için EEG ters problem çözülerek, kaynak analizi yaklaşımının sağ, sol el motor hayalinin sınıflandırılmasına eğitim olmaksızın yardımcı olacağı bulunmuştur [36].

Gideon Inbar ve diğerleri bu çalışmada geçici, kayıttan kayıta değişen uyarılmış potansiyellerden özellikle serabral aktivite içerisine gömülmüş, çok düşük işaret-gürültü oranına sahip; hareketle ilişkili potansiyellerin (*Movement Related Signals MRP*), çok kanallı EEG kayıtlarından tek süpürümde kestirimi için yeni bir “uyarlanabilir nöro-bulanık yöntem (*Adaptive Neuro-Fuzzy Technique:ANFIS*)” önermektedir. ANFIS, sinir-ağları yada uyarlanabilir özbağlanım parametrelerini (AAR) temel alan diğer algoritmalar ile karşılaştırıldığında (Jang 1993), ayarlanması gereken az parametre sayısı ve daha iyi sonuçlar vermesi ile öne çıkar [37].

Christoph Guger ve diğerleri 3 ayrı kişiden sağ veya sol el düşünceleri sırasında EEG işaretlerini kayıt ederek, bu iki farklı düşünceyi uyarlamalı özbağlanım (AAR) modeli ve doğrusal ayırtaç (*Linear discriminant analysis-LDA*) yöntemleri ile sınıflandırma yoluna gitmişler ve %70 ile %95 arasında başarımler elde etmişlerdir. Bu başarımler sonucunda önerdikleri modelin uzaktan kontrol için kullanabileceğini savunmuşlardır [38].

Michael Zibulevsky ve diğerleri çok kanallı (kendileri 122 kanal kullanmıştır) EEG kayıtlarından elde edilmiş işaretlere bağımsız bileşenler analizi (ICA) yöntemini kullanarak belirli düşünsel kayıtlara ait örüntü oluşturma işlemi üzerine çalışmışlardır [39].

Silvia Chiappa ve diğerleri de “BCI competition III” [38] yarışmasındaki verilerden V numaralı EEG verileri ile çalışmışlardır. Bu veriler 32 kanallı EEG cihazı ile kayıt edilmiş ve 3 ayrı düşünceye ait verilerdir. Bu 3 ayrı sınıfı bağımsız bileşenler analizi yöntemini kullanarak modellemişlerdir ve sınıflandırma işlemi Bayes kuralına göre yapmışlardır. Bağımsız bileşenler analizi yöntemini kullanırken kişinin düşünme esnasında

konu dışı başka şeylerde düşünmüş olabileceğini öne sürmüşlerdir ve bu yüzden modellemede bağımsız bileşenler analizi yönteminin konu dışı düşünceleri ortaya çıkarmada etkili olduğunu belirtmişlerdir [40].

Kouhyar Tavakolian ve diğerleri yaptıkları çalışmada EEG işaretleri toplanırken bir çok elektrot kullanıldığı için, bunlardan hangileri hangi düşünsel durumda seçilirse daha iyi olur sorusuna cevap aramışlar. EEG verileri üzerinden 0.1 saniye uzunluğunda bir pencere gezdirerek kendilerine özgü bir filtreleme yöntemi ile EEG işaretlerini inceledikten sonra farklı düşünsel durumlarda kaydedilmiş EEG verilerini sınıflandırma için hangi EEG kanallarını kullanmanın daha iyi sonuç vereceğini ortaya koymuşlardır. Bu çalışma çok kanallı EEG cihazı ile çalışan araştırmacıların sınıflandırma için karar verme zamanında tasarruf sağlayan önemli bir önışlemdir [41].

Allan Kardec Barros ve diğerleri çok sayıda elektrot kullanılarak alınmış EEG işaretlerinden anlamlı işareti çıkarma konusu üzerinde çalışmışlar. EEG işaretlerinin lineer olarak kaydedildiği varsayımını yaparak ön işlem wiener filtresini kullanarak kullanmışlar, daha sonra ICA yöntemini kullanarak anlamlı işareti bulma yoluna gitmişlerdir. Uyarılmış potansiyeller sonucu kaydedilen EEG işaretlerinde iyi sonuçlar verdiğini bulmuşlardır [42].

Pari Jahankhani ve diğerleri gönüllü ve sağlıklı kişilerden ve bir de epilepsi hastalarından EEG kayıtları almışlardır. Zamana bağlı olarak frekanstaki değişimi zamanla gözleyebilmek için ayrık dalgacık dönüşümü kullanarak EEG işaretlerinden zamansal bilgi çıkartma yoluna gitmişlerdir. Arka planı gürültülü EEG işaretlerine gömülmüş, sabit olmayan anlamlı EEG işaretlerini elde etmek için etkili bir yöntem olduğunu söylemişlerdir. Ayrıca karar verme zamanını arttırmak için çok kanallı EEG cihazından elde ettikleri işaretlerin boyutlarını temel bileşenler analizi (PCA) yöntemini kullanarak azaltmışlardır [43].

Tubingen Üniversitesi'nden Niels Birbaumer ve arkadaşları bilgisayarda imlecin yukarı ve aşağı hareket ettirilmesi durumunda deneğin EEG işaretlerini kaydederek bu işaretleri sınıflandırma yoluna gitmişlerdir [44]. Bu tez çalışmasında Tubingen Üniversitesi'nden Niels Birbaumer ve arkadaşlarının kaydettikleri imleç hareketine ait EEG işaretlerinden öznitelik çıkarma ve bu işaretlerin sınıflandırılması üzerine çalışılmış ve "BCI Competition 2003 [45]" yarışmasında kullanılan bu verilerden elde edilen başarımdan daha üst seviyede bir başarı elde edilmiştir. Bu yarışmada test verilerinde en yüksek başarı % 88.7 iken [46], yüksek lisans çalışmasında bu başarımdan test verilerinde en iyi % 93.52 seviyesinde elde edilmiştir. Ayrıca 2003 yılındaki bu yarışmadan sonra bu

veriler literatürde de kullanılmış ve değişik başarımlar elde edilmiştir. Brett D. Mensh ve diğerleri bu verilerle elde ettikleri en iyi sınıflandırma başarımları yavaş kortikal potansiyelleri ile elde edilmiş olup %88.7'dir [47]. Baojun Wang ve diğerleri ise beta bandını kullanarak kortikal potansiyelerine dayalı öznitelik çıkartımı ile en iyi sınıflandırma başarımları %91.13 seviyesindedir [48].

Yine aynı yarışmada (BCI Competition 2003) Berlin üniversitesinden Klaus-Robert Müller ve Benjamin Blankertz, iki elini klavyenin üzerine tuşlara basma pozisyonunda koyan ve gelen komutla birlikte sağ veya sol serçe parmağı ile tuşlara basan denekten alınan EEG işaretlerini sunmuşlardır [49].

Deon Garrett ve diğerleri büyük boyutlu ve doğası gereği gürültülü olan EEG işaretlerini sınıflandırmada doğrusal olmayan sınıflandırma yöntemlerinin, doğrusal olan sınıflandırma yöntemlerine göre çok fazla üstün olmadığını gösteren bir çalışma yapmışlardır. Çalışmalarında yapay sinir ağı, destek vektör makineleri gibi doğrusal olmayan sınıflandırma yöntemi ile doğrusal sınıflandırma biçimi olan lineer ayırtaç analizi (linear discriminant analysis) yöntemini karşılaştırmıştır. Bunu yaparken 5 ayrı düşünsel durumda kaydedilmiş EEG verilerini kullanmışlardır. Buldukları sonuçlarda destek vektör makinaları ile sınıflandırma ortalama %72, yapay sinir ağına göre %69.4, lineer ayrışım analizine göre %66 oranında başarımlar elde etmişler ve doğrusal yöntemin daha hızlı çalıştığını ve doğrusal olmayan yöntemlere göre de çok az hata yaptığını belirtmişlerdir [50].

Wenjie Xu ve diğerleri "BCI competition 2003" yarışmasında sunulan verilerden sağ ve sol parmağın hareketine ait olan EEG verileri üzerine çalışmış ve yarışmada elde edilen %84'lük başarıya karşılık yavaş kortikal potansiyeller ile temel bileşenler analizi yöntemlerini birlikte kullanarak bu başarımları destek vektör makineleri sınıflandırma yöntemi ile %90 oranında bir başarımla sağlamıştır [51].

Jakub Stastny ve Pavel Sovka yaptıkları çalışmalarında el hareketi yapılan ve yapılmayan durumlardaki EEG işaretlerini inceleyerek bu iki durumu ayırtırmaya çalışmışlardır. Zamansal bir filtre ile öznitelik çıkarma yoluna gitmişlerdir. Daha sonra Hidden Markov Modelini kullanarak %94-%100 arasında başarımlar elde ederek kişi elini hareket ettiriyor mu ettirmiyor mu sorusunu cevaplamışlardır. Ancak hangi elin hareket ettiğine karar veremediklerini belirtmişlerdir. Bu durumun üstesinden etkili bir sınıflandırma yöntemi ile gelinebileceğini de ifade etmişlerdir [52].

Yong Li ve diğeri Hidden Markov Model tabanlı bir algoritma ile sağ ve sol el hareketi yapılarak kaydedilmiş EEG işaretlerinden öznitelik çıkarma yoluna gitmişler ve %93.2 oranında bir başarımla bunu gerçekleştirmişlerdir. Yaptıkları çalışmanın gerçek zamanlı çalışabilmeğe uygun olduğunu belirtmişlerdir [53].

L. G. Doroshenkov ve diğeri Hidden Markov Model ile uyku durumlarının sınıflandırılması konusunu incelemiştir. Kimi insanlar geç uykuya dalarken kimileri çok kısa sürede uykuya dalabilirler. Bazıları da uzun süreler boyunca uykuya dalmama sorunları yaşarlar. Bu çalışmada Hidden Markov Model tabanlı filtreleme yöntemi öznitelik çıkartırlarken, iyi %88 oranında sınıflandırma başarımla elde edilmiştir [54].

Shiliang Sun ve diğeri doğrusal ayırtaç (Fisher Discriminant) yönteminin BBA uygulamaları için EEG işaretlerinden öznitelik çıkartımındaki hataları önlemek amacı ile rasgele seçilen elektrotlarla uygulama yapma yoluna gitmişlerdir. Bu yöntemle rasgele seçilmiş elektrot takımı (*random electrode selection ensemble*- RESE) adı vermişlerdir. Rasgele seçilen elektrotlar düşünsel beyin aktivitesinin psikolojik geri planın cevabını vermektedir. Ayrıca çalışmalarında boyut azaltımı için temel bileşenler analizi de kullanılmıştır ve Fisher diskriminant yöntemi öznitelik çıkartımı için başarılı bir şekilde kullanılmış ve sınıflandırma içinde Bayesian Sınıflandırma metodunu Gauss katışım modeli (Gaussian Mixture Model) ile kullanmışlardır. Teorik analizler ve sınıflandırma sonuçları bu yöntemin (RESE) gerçek EEG işaretleri için etkin ve verimli bir yöntem olduğunu göstermiştir [55].

Shang-Ming Zhou ve diğeri “BCI competition 2003” [45] yarışmasında Graz Üniversitesi tarafından sunulan sağ ve sol el motor hareketlerine bağlı kaydedilmiş EEG işaretlerinden ikili tayfa bağlı öznitelik çıkartımı ve bu özniteliklere göre sınıflandırma yapma yoluna gitmişlerdir. Sınıflandırmayı Lineer Diskriminant Analizi, Destek vektör makineleri ve yapay sinir ağı kullanarak denemişlerdir. Elde ettikleri sonuç söz konusu yarışmada elde edilen en iyi sonuçtan daha iyi olmuştur. En iyi %90 başarımla elde etmişlerdir [56].

Luca Citi ve diğeri EEG işaretlerindeki P300 dalgalarını kullanarak bilgisayar ekranında fare kullanımına olanak sağlayan çalışma yapmışlardır. Yaşları 25 ile 40 arasında değişen 6 ayrı denek kullanılarak çalışmalarını yürütmüşlerdir. Sistem analog olarak çalışmaktadır yani hangi yön için P300 dalgası saptanırsa o yöne doğru fare sürüklenmektedir. Çalışma sonucu tatmin edici düzeydedir ancak çalışanlar sistemin daha iyi olabileceğini de belirtmişlerdir [57].

EEG işaretlerinden öznitelikler çıkartıp bunların sınıflandırılması çalışmaları genel olarak gerçel zamanlı değildir. Lehtonen ve diğerleri yaptıkları çalışmada sağ ve sol el hareketleri esnasındaki düşüncelerle bilgisayar ekranında görülen bir daireyi söylenen hedefe gerçel zamanlı olarak hareket ettirmeye çalışmışlardır. Her 2 sn'de bir, sistem kendini güncelleyerek alınan işaretleri belirlenen özniteliklere göre analiz edip bilgisayara ilgili komutu göndermektedir. Yapılan deneylerde 10 kişiden 7'si %84 ile %100 arasındaki başarımları dakikada 3.5 ile 7.7 defa arasında değişen miktarlarda hedefi bulmuşlardır. Tüm hepsinin doğruluk ortalaması %80'dir ve hızı 10 bit/dk'dır [58].

Allison ve diğerleri yaptıkları çalışmada kişilere ekranda bulunan iki cisimden birine odaklanmalarını isteyerek (dakikada 12 defa tekrarlayarak) alınan EEG işaretlerini kaydederek kişinin hangi nesneye odaklandığını sabit durum görsel uyarılmış potansiyellerini (steady state visual evoked potentials- SSVEP) göz önüne alarak incelemişlerdir. EEG işaretleri incelenenlerden ancak yarısının SSVEP'leri ile doğru sonuca ulaşılabilmiştir. Bu verimli bir kontrol için yeterince güçlü bir metot olmadığını da çalışmalarında belirtmişlerdir [59].

G. Schalk ve diğerleri yaptıkları çalışmalarında EEG işaretlerini klinik amaçlı değerlendirme yoluna gitmişlerdir. EEG işaretlerinden öznitelik çıkartıp sınıflandırma yapma yerine, konuşacak durumda olmayan hastaların beyinsel aktivitelerini dedekte edecek bir model üzerine yoğunlaşmışlardır. Çalışmalarında Gauss katışım modeli (*Gaussian Mixture Model*) kullanarak kişinin hiçbir şey düşünmediği durumdan beyin aktif duruma geçtiğinde bunun farkına varacak bir model üzerine çalışmışlardır. Bu sayede hastanın beyinsel fonksiyonları hakkında bilgi sahibi olarak, konuşacak durumda olan kişilerin durumu hakkında doktorlar bilgi sahibi olabilmektedir. Çalışmalarında 2 sağlık problemi bulunmayan bir de spinal hasarı bulunan olmak üzere 3 kişi ile deneyler yapılmıştır [60].

Femke Nijboer ve diğerleri çalışmalarında, kişilerin her zaman görsel olarak uyarı alamayacaklarını bazı insanların görme yetilerini kaybetmiş olabileceklerini belirtmişlerdir. Buradan yola çıkarak hem görsel hem de sesli geri beslemeler ile 16 gönüllü ile çalışarak 3 seansta beyin aktivitelerini inceleyerek BBA sistemi için uygun modelleme yapma yoluna gitmişlerdir. 2-3 dakikada 30 deneme yaparak sensorimotor ritimlerdeki genliklerin artış ve azalışına göre öğrenmeye tabi tutulmuşlardır. 8 kişi görsel, 8 kişide sesli geri beslemeler ile öğrenmeye tabi tutulmuşlardır. 3 seansın sonunda elde edilen bulgulara göre; sesli uyarı alanlar daha yavaş öğrenme gerçekleştirmektedir

ancak sonuç itibari ile 3. seansın sonunda görsel ve sesli geri beslemelerle öğrenenler hemen hemen aynı doğrulukta öğrenme gerçekleştirmişlerdir. Ruh hali ve motivasyonda bu öğrenmede oldukça etkilidir [61].

Ou Bai ve diğerleri 12 gönüllü denekten sağ ve sol el hareketine dayalı EEG işaretlerini 128 kanallı bir EEG cihazı ile kaydederek zamansal filtreleme ve frekans domeninde filtrelemelerle öznelik çıkarımına giderek örüntü tanıma üzerine çalışmışlardır. Öznelik çıkartımı için PCA, ICA, zamansal ve uzaysal filtreleme, ortak uzaysal örüntü analizi (*common spatial patterns analysis* -CSP), yüzeysel Laplasyan türetimi (*surface Laplacian derivation* -SLD), güç tayfi tahmini ile zamansal filtreleme, ayırık dalgacık dönüşümü yöntemlerinin kombinasyonlarını; örüntü sınıflandırma için doğrusal Mahalanobis uzaklık sınıflandırması (linear Mahalanobis distance classifier -LMD), kuadratik Mahalanobis uzaklık sınıflandırması (quadratic Mahalanobis distance classifier -QMD), Bayesian sınıflandırması (BSC), çok katman nöronlu yapay sinir ağı (*multi-layer perceptron neural network* -MLP), destek vektör makineleri (DVM, *support vector machine* -SVM)'nin kombinasyonlarını kullanmışlardır. En iyi başarımı ICA, güç tayfi tahmini ile zamansal filtreleme ve SVM ile elde ederek %75 oranında sağlamışlardır. Bu çalışmada ayrıca beta bandının bu uygulamayı sınıflandırmadaki başarısında öne çıktığını belirtmişlerdir [62].

Yapılan çalışmalarda sınıflandırma başarımlarının beyin bilgisayar arayüzü uygulamaları için yeterli düzeyde olmadığı ve geliştirmeye ihtiyaç duyulduğu görülmektedir. Ayrıca gerçel zamanlı çalışmaların genelde yapılmadığı ve BBA veri hızının iyileştirilmesi yönünde çalışmaların yaygın olmadığı görülmektedir.

2. YAPILAN ÇALIŞMALAR VE BULGULAR

2.1. Materyal

Çalışmada kullanılan veri kümesi Almanya'nın Tübingen Üniversitesi'nde sağlıklı bir kişiden elde edilmiş işaretlerden oluşmaktadır [63]. Bu veriler “*BCI Competition 2003*” yarışması için sunulmuştur [45].

Kişiden, bir bilgisayar ekranında imleci yukarı ve aşağı yönde hareket ettirmesi istenmiştir. Bu deney esnasında 10-20 sistemine göre Cz noktası referans seçilerek 6 elektrot ile EEG kayıtları alınmıştır. Her bir deneme 6 saniye sürmüştür.

Her bir denemede kişiden, imleci sürüklemesi istenen hareket yönü bilgisayar ekranında 0.5'inci saniyeden denemenin sonuna kadar gösterilmiştir. Görsel geri besleme her bir denemede 2. ve 5.5'inci saniyelerde yapıldığı için sunulan veriler bu saniye aralığına düşen 3.5 saniyelik işaretlerdir. Örneklem frekansı 256 Hz ve 3.5 saniyede alınan örnek sayısı 896'dır.

Elektrotların yerleşimi ve verilerin elde edildiği sistem özellikleri aşağıdaki gibidir:

Sistem özellikleri:

Yükselteç: PsyLab EEG8

A/D-dönüştürücü: Computer Boards PCIM-DAS1602/16 bit

Genlik aralığı: +/-1000 μ V

Örneklem oranı: 256 S/s

10/20 Sistemine Göre Elektrot Pozisyonları:

Elektrot 1: A1

Elektrot 2: A2

Elektrot 3: FC3

Elektrot 4: CP3

Elektrot 5: FC4

Elektrot 6: CP4

Tüm değerler μ Volt'lar mertebesindedir.

Eđitim verileri 268 ayrı denemeden oluřmaktadır. Bunların 135 tanesi yukarı ynl harekete ait iřaretler olup, 133 tanesi ise ařađı ynl harekete ait iřaretlerdir. Bu 268 denemenin 168 tanesi bir gnde alınmıř, kalan 100 denemede ikinci bir gnde alınmıřtır. Daha sonra bu iki gne ait veriler rasgele karıřtırılmıřtır. Test veri kmesi ise 293 denemeden oluřmaktadır. Yukarı ve ařađı ynl denemelere ait veriler, test veri kmesinde rasgele dađıtılmıřtır.

2.1.1. Literatrde Aynı Veri Kmesini Kullanarak Yapılan alıřmalar

Brett D. Mensh ve diđerleri EEG iřaretlerinin yksek frekans blgesi olan gama bandını kullanarak iřaretleri sınıflandırma yoluna gitmiř ve bu yaklařımla eđitim veri kmesi iin %62.3 test veri kmesi iin %72.4 dođrulukla sınıflandırmayı gerekleřtirmiřlerdir. Ayrıca yavař kortikal potansiyelleri (*slow cortical potentials- SCPs*) kullanarak bařka bir yaklařımda bulunarak sınıflandırma oranını arttırmıřlardır [47]. Elde ettikleri sonular ařađıda tablo halinde verilmiřtir. Ayrıca Őekil 2.1'de 4. elektrottan elde edilmiř normalize g tayfı ve 1. elektrottan elde edilmiř SCP'ler birlikte verilmiřtir. Bu yaklařıma ait sınıflandırma bařarımı %88.7 olarak hesaplanmıřtır.

Tablo 1. Brett D. M. ve diđerlerinin yaklařımları ve elde ettikleri bařarımlar

zellik(ler)	Eđitim verileri (% dođruluk)	Test verileri (% dođruluk)
SCP	70.9	82.6
Gama(Welch metodu)	62.3	72.4
Gama (Thomson metodu)	64.9	73.4
SCP+Welch	80.2	85.3
SCP+Thomson	81.3	88.7

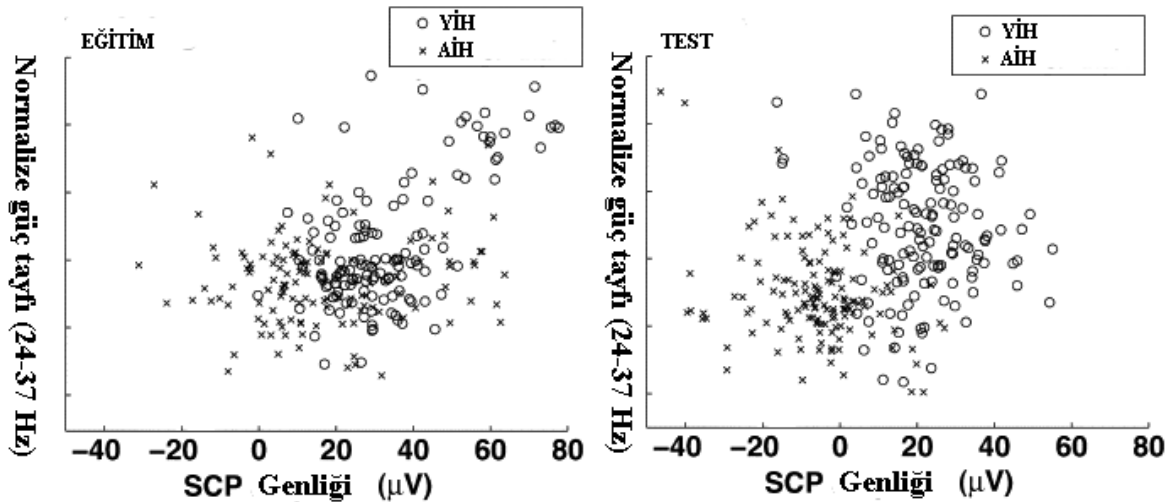
Baojun Wang ve diđerleri EEG iřaretlerinin beta frekans blgesini kullanarak iřaretleri sınıflandırma yoluna gitmiřler ve buradan elde ettikleri bařarımı yavař kortikal

potansiyelleri ile birleştirerek sınıflandırma doğruluk oranını arttırmışlardır [48]. Baojun Wang ve diğerlerinin elde ettikleri sonuçlar aşağıda tablo halinde verilmiştir.

Tablo 2. Baojun W. ve diğerlerinin yaklaşımları ve elde ettikleri başarımlar

	SCPs+ β bandı enerjisi	SCP	β bandı enerjisi
C ve σ	C= 3640.7 σ=215.27	C=3640.7 σ=215.27	C=274.37 σ=117.78
Eğitim verileri (% doğruluk)	83.9	71.27	70.15
Test verileri (% doğruluk)	91.13	87.71	77.13

Bu verileri kullanarak BCI Competition 2003 yarışmasına katılan çalışma gruplarının sonuçları aşağıda tablo halinde verilmiştir [46]. Bu yarışmada en iyi sınıflandırma başarımları %88.7 dir. Bu başarımların 1. ve 2. elektrotların yüksek beta güç bandının spektrum analizinden elde edilen öznelilikler kullanılarak elde edilmiştir.



Şekil 2.1. 4. Elektrotun gama band gücü ve 1. elektrotun SCP değeri

Tablo 3. BCI Competition 2003 yarışmasına katılan çalışma gruplarının sonuçları

Sıra No	Katılımcı	Doğruluk (%)	Üniversite	Yardımcı Araştırmacı
1.	Brett Mensh	88.7	MIT	Justin Werfel, Sebastian Seung
2.	Guido Dornhege	88.4	Fraunhofer FIRST (IDA), Berlin	BenjaminBlankertz,Klaus-Robert Müller
3.	Kai-Min Chung	88.1	National Taiwan University, Taipei	Tzu-Kuo Huang, Chih-Jen Lin
4.	Tzu-Kuo Huang	85	National Taiwan University, Taipei	Kai-Min Chung, Chih-Jen Lin
5.	David Pinto	84.3	University of Florida	-
6.	Juma Mbwana	82.9	Yale University	Mark Laubach
7.	Vladimir Bostanov	82.6	University of Tübingen	-
8.	Ulrich Hoffmann	82.8	-	-
9.	Deniz Erdogmus	80.9	University of Florida	Yadu Rao, David Pinto, Kenneth Hild, Tue Lehn-
10.	Justin Sanchez	80.2	University of Florida	Deniz Erdogmus, Tue Lehn-Schioeler, Yadu
11.	Amir Saffari	76.5	Sahand University of Technology,	T. Emami, S. Ashkboos
12.	Michael Grabner	75.4	Technical University of Graz	Alois Schlögl
13.	Yadu Rao	65.5	University of Florida	David Pinto
14.	Kenneth Hild	53.2	University of Florida	Tue Lehn-Schioeler
15.	Fabien Torre	50.9	-	-

2.2. Yöntem

2.2.1. Temel Bileşen Analizi

Temel bileşen analizi (Principal Components Analysis -PCA), aralarında yüksek korelasyon bulunan çok değişkenli verileri, aralarında korelasyon olmayan yeni bir koordinat sistemine dönüştüren istatistiksel bir veri dönüşümü yöntemidir. Bu dönüşüm, farklı disiplinlerce çok değişkenli (çok boyutlu) verilerin analizinde (*multivariate analysis*) kullanılmaktadır. Özellikle sinyallerin iletiminde sıkça kullanılan bu dönüşüm, sayısal görüntülerin de sinyal olarak yorumlanabilmesi sayesinde, görüntü işleme ve işaret işleme uygulamalarında da sıkça kullanılmaktadır. Beyin bilgisayar arayüzü uygulamalarında, çok sayıda elektrot ile elde edilmiş EEG kayıtlarının boyutlarını azaltmada da oldukça sık kullanılmaktadır.

Çok değişkenli analiz konusu, iki veya daha çok boyutlu rasgele değişkenleri bir bütün olarak ele alan ve değişkenler arasındaki ilişkileri göz önünde tutarak bütünsel bir sonuç üreten istatistiksel tekniklerden meydana gelmektedir. Bu istatistiksel tekniklere örnek olarak; korelasyon ve regresyon analizi verilebilir. Bununla birlikte, çok değişkenli verilerin analizinde, bütüncül istatistiksel sonuçlar üretmenin ötesinde, çok değişkenli veri kümesinin yapısını tanımlamaya yönelik veri-çözümleme teknikleri de vardır. PCA böyle bir tekniktir. PCA, bazı kesin koşulları yerine getirerek, bir grup korelasyonlu değişkenlere doğrusal dönüşüm uygulayan bir veri-çözümleme tekniğidir. Bu koşullardan en önemlisi, dönüşümden sonra değişkenler arasında korelasyon bulunmamasıdır [64].

PCA'nın temel ilkesi; multispektral vektör uzayında, verileri korelasyonsuz olarak ifade edebilen diğer bir deyişle yeni sistemde kovaryans matrisi köşegen olan, yeni bir koordinat sisteminin araştırılmasıdır [65].

PCA'da temel bilinmeyen olan dönüşüm matrisinin hesabı, aslında bir lineer cebir problemidir. Konunun daha iyi anlaşılabilmesi için, “özdeğerler” (eigenvalues) ve “özvektörler” (eigenvectors) kavramlarının kısaca açıklanmasında yarar vardır.

$$A \cdot \vec{x}_i = \lambda_i \cdot \vec{x}_i, \quad i = 1, \dots, n \quad (1)$$

A matrisi $n \times n$ boyutlu ve x vektörü $n \times 1$ boyutlu olmak üzere; (1) eşitliğini sağlayan sıfırdan farklı x vektörlerine, A matrisinin özvektörleri ve λ skalar değerlerine de A matrisinin özdeğerleri denir. (1) eşitliği aşağıdaki gibi de yazılabilir;

$$(A - \lambda_i \cdot I) \cdot \vec{x}_i = \vec{0} \quad , \quad I: \text{birim matris} \quad (2)$$

x_i bilinmeyenler vektörü olarak ele alınırsa, (2) eşitliğinin homojen bir denklem sistemi olduğu anlaşılacaktır. Bu durumda x vektörleri sıfır olamayacağından, homojen denklem sistemlerinin sıfırdan farklı bir çözümünün bulunabilmesi için katsayılar matrisinin determinantı sıfır olmalıdır.

$$\det|A - \lambda_i \cdot I| = 0 \quad (3)$$

(3) eşitliğine “karakteristik denklem” (*characteristic equation*) adı verilir. Verilen A matrisinin özdeğerleri, (3) eşitliğinden çıkarılan n dereceli polinomun kökleridir. Özdeğerler bulunduktan sonra, (2) eşitliği kullanılarak özvektörler de bulunabilir. Eğer A matrisi simetrik ve elemanları gerçekte sayılar ise; özdeğerleri ve özvektörleri de gerçekte sayılar olup, özvektörleri de ortogonal olur.

Yukarıda da değinildiği gibi PCA’daki esas fikir, doğrusal olarak dönüştürülmüş bileşenlerle maksimum değişim miktarını ifade eden bileşenleri bulmaktır. Danışmansız bir metod olan PCA yüksek boyutlu verileri daha düşük boyutlu verilere indirgemeye yarayan güçlü bir veri analiz tekniğidir. PCA şu şekilde özetlenebilir:

X , n adet d boyutlu i x verisi içeren bir matris olsun,

$$X = [x_1, x_2, \dots, x_n] \quad (4)$$

İlk olarak n adet verinin ortalama değeri \bar{x} bulunur, ortalama değerle herbir x_i verisinin farkı alınarak \hat{X} fark matrisi bulunur.

$$\hat{X} = [x_1 - \bar{x}, x_2 - \bar{x}, \dots, x_n - \bar{x}] \quad (5)$$

Elde edilen fark matrisi aşağıdaki ifadede kullanılarak C kovaryans matrisi elde edilir.

$$C = \frac{1}{n} \hat{X}\hat{X}^T \quad (6)$$

Aşağıdaki ifade doğrulanacak şekilde C kovaryans matrisinin $\Phi_{\hat{X}}$ özvektörleri ve $\Lambda_{\hat{X}}$ özdeğerleri bulunur.

$$C\Phi_{\hat{X}} = \Phi_{\hat{X}}\Lambda_{\hat{X}} \quad (7)$$

Bu aşamayla elde edilen d adet d boyutlu özvektör ve köşegen matris biçiminde d adet özdeğer aşağıdaki gibidir.

$$\Lambda_{\hat{X}} = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \lambda_d \end{bmatrix} \quad (8)$$

$$\Phi_{\hat{X}} = [\phi_1, \phi_2, \dots, \phi_d] \quad (9)$$

m adet, yüksek özdeğere karşılık gelen özvektörler seçilerek $d \times m$ boyutlu izdüşüm matrisi W elde edilir.

$$x'_i = W^T(x_n - \bar{x}) \quad (10)$$

ifadesiyle d boyutlu x_i verisiyle daha düşük boyutlu x'_i elde edilir. Bununla birlikte, büyük boyutlu veriler için kovaryans matrisinin hesaplanması hesapsal maliyetlidir ve özdeğer ayrıştırması sadece kare matrislere uygulanabilir. Bu çalışmada, bu sebeple izdüşüm matrisinin bulunması için tekil değer ayrıştırma (TDA) işlemi tercih edilmiştir.

X geliş güzel pxq 'lik bir matris olsun. X 'in tekil değer ayrıştırması aşağıdaki gibidir.

$$X = U\Sigma V^{-1} \quad (11)$$

U ve V birimboy lu matrislerdir. U matrisi pxq ve V matrisi qxq boyutlarındadır. Σ , pxq boyutlarında köşegen bir matristir. Burda U sol tekil vektörleri, V sağ tekil vektörleri, Σ ise tekil değerleri temsil etmektedir. PCA'da izdüşüm matrisinin daha kolay bulunabilmesi için, fark matrisi tekil değer ayrıştırması yöntemiyle ayrıştırılır ve böylece U, V ve Σ matrisleri elde edilir. Burada U özvektörlere, Σ ise özdeğerlere karşılık gelmektedir.

2.2.2. Bağımsız Bileşen Analizi

Bağımsız bileşen analizi (Independent Component Analysis -ICA), çok boyutlu istatistiksel verilerde saklı faktörlerin bulunması için geliştirilmiş olan oldukça yeni istatistiksel bir yöntemdir. Bağımsız bileşen analizi modelinde saklı faktörler ya da bağımsız bileşenler doğrusal veya doğrusal olmayan şekilde bilinmeyen bir karıştırma mekanizması ile karıştırılarak gözlem verilerini oluştururlar. Temel doğrusal karışım modeli matematiksel olarak şu şekilde ifade edilebilir:

$$X = As \quad (12)$$

Burada x gözlem verileri x_j 'lerden oluşan gözlem vektörü, s ise s_i olarak adlandırılan bağımsız bileşenlerden oluşan kaynak vektörü; A da karıştırma matrisidir. Amaç bilinmeyen A ve s değerlerinin gözlem vektörü x kullanılarak kestirilmesidir. Temel Bağımsız bileşen analizi modelinde A matrisi kare olarak yani kaynak ve bağımsız bileşen sayısı eşit olarak kabul edilir [66]. Modeldeki varsayımlar kullanılarak; A matrisi kestirilir daha sonra da kaynaklar aşağıdaki gibi hesaplanır:

$$s = WX \quad (13)$$

burada W matrisi A matrisinin tersidir [67,68].

Bu yöntemde en maliyetli kısım A matrisinin elde edilmesi kısmıdır. Bundan dolayı A matrisinin kestiriminde genel olarak daha hızlı olduğu için hızlıICA (fastICA)

kullanılması tavsiye edilir. hızlıICA'nın algoritması aşağıda adım adım verilmiştir (Hyvarinen and Oja, 1997).

1. X verisi standartlaştırılır.
2. Z asal bileşenleri X verisinden 2. derece istatistikten (kovaryans matrisi) bulunur.
3. m sayıda bağımsız bileşen seçilir.
4. A operatörünün her bir dönüşüm vektörü $w_i, i=1,2,\dots,m$ başlangıçta rasgele seçilir ve birim norma dönüştürülür. Tüm vektörlerden oluşan W matrisi 6. adımdaki yöntem ile ortogonal hale dönüştürülür.
5. Her bir $i=1,2,\dots,m$ için, $w_i \leftarrow E\{zg(w_i^T z)\} - E\{g'(w_i^T z)\}w$, uygulanır. Burada g' , g 'nin türevi ve

$$g = \log \cosh(y) \quad (14)$$

şeklinde tanımlıdır.

6. $W = (w_1, w_2, \dots, w_m)^T$ matrisi bakışık ortogonal hale getirilir.

$$W = (WW^T)^{-1/2} W \quad (15)$$

7. Eğer yakınsaklık sağlanılamazsa 5. adıma dönülür.


2.2.3. Eğri Uydurma

Bir çok mühendislik problemlerinde deneysel çalışma sonucu elde edilen veya incelenen veriler noktasal değerlerdir veya analog olarak ölçülerek daha sonra sayısal değerlere dönüştürülmüş değerlerdir. Eğer $y = f(x)$ tanımında her bir (x) değeri için (y) değeri biliniyor ise bilindiği gibi bu fonksiyona sürekli fonksiyon denilmektedir. Yani (x) değerinin bütün değerleri için (y) karşılıkları bulunabilir. Bir fonksiyonun nokta nokta verilen değerlerinden, fonksiyonun kendisine en uygun başka bir fonksiyonun belirlenmesi veya uygulamada kullanılan zor karmaşık fonksiyonların yerine geçebilecek veya sayısal hesaplamalarda kolaylık sağlayabilecek yeni fonksiyonların araştırılması problemi eğri uydurma olarak bilinir. Mühendislikte bu konunun uygulanması yukarıda söylendiği gibi deneysel veriler arasındaki ilişkinin araştırılmasında yaygın olarak kullanılmaktadır.

Eđri uydurma problemlerine çeřitli řekillerde yaklařımlar mevcuttur. Bu tez alıřmasında en kk kareler yntemi yaklařımı kullanılmıřtır. Bu yntemin uygulanıřı ařađıda aıklanmıřtır.

2.2.3.1. En Kk Kareler Yntemi ile Eđri Uydurma

Deneysel verilerde, verilerdeki sapmalar kaınılmazdır. ođu zaman ařırı farklı noktalar lmlerden ıkarılır. nk bu ařırı byk ve kk deđerler genel ortalamayı ve verilerin sapmasını bozacaktır. Bunun iin elde bulunan verilere uygun bir eđri semeden bunları bir programla basit bir grafik zerinde grmek ve noktaların diziliřine bakarak uygun bir eđri veya fonksiyon semek ođu zaman iyi bir yol olacaktır. Deđilse en uygun fonksiyonu bulmak iin daha fazla zaman harcanacaktır. Ařađıda řekil 2.2' de grldđ gibi verilen noktalara bakıldıđında iliřkinin dođrusal olduđu grlmektedir. Ancak birbirine yakın ok farklı dođru bu noktalar iin izilebileceđi gz ardı edilmemelidir. En kk kareler yntemi bu farklılıklara bir temel yaklařım getirmektedir. Uydurulan eđri ile veri noktaları arasındaki farkları bir bařka deyiřle sapmaları minimum yapan bir eđri retmek iin geliřtirilen bir tekniktir.



řekil 2.2. Deneysel verilerle uydurulmuş bir fonksiyonun (dođrusal) sapmaları

En kk kareler ynteminde veri noktalarına dođrusal veya istenilen dereceden polinom uydurmak mmkndr. Dođru uydurmak bu iřlemin en basit ve pratik yoludur. Veri noktalarına uydurulan yeni fonksiyon $g(x)$ olduđunda veri noktaları da

$[(x_i, y_i), (i = 1, 2, 3, \dots, n)]$ şeklinde olduğu düşünülürse veri ile yeni fonksiyonda bulunan nokta arasındaki fark aşağıdaki eşitlikler şeklinde yazılabilir.

$$\varepsilon = y_i - g(x_i) \quad (16)$$

Burada temel amaç (y) ile $g(x)$ arasındaki farkı gösteren ε sapmasının minimum yapmaktır. Çünkü bu değer bütün noktalar için sıfır olması demek uydurulan eğri ile veri noktalarının üst üste düşmesi anlamına gelmektedir. Bu hatalar toplamlar şeklinde bütün noktalar için ifade edilecek olursa;

$$\sum_{i=1}^n \varepsilon_i = \sum_{i=1}^n (y_i - g(x_i)) \quad (17)$$

$$\sum_{i=1}^n \varepsilon_i = \sum_{i=1}^n (y_i - (a_0 - a_1 x_i)) \quad (18)$$

şeklinde olur. Burada $g(x)$ 'in yerine kullanılan ve ifadesi içinde kullanılan belirsiz katsayılar a_0 ve a_1 uydurulacak eğrinin derecesine göre sayısı artmaktadır. Burada iki katsayı olmasının nedeni en basit şekli ile bir doğru denklemi şeklinde düşünülürse içindir. Bu hata değerlerini en aza indiren bir çok kriter geliştirilmiştir. Bunlardan birisi uydurulan değerle veri noktaları arasındaki farkların veya bir başka deyişle hataların karelerin toplamının minimum yapılmasıdır. Bu durum aşağıdaki eşitlikle ifade edilebilir.

$$E = \sum_{i=1}^n (\varepsilon_i)^2 = \sum_{i=1}^n (y_i - (a_0 - a_1 x_i))^2 \quad (19)$$

Bu ifade şeklinin doğru veya yüksek dereceden eğri uydurmada bu ifadenin kısmi türevinin sıfır olması E değerinin minimum olması anlamına gelmektedir. Böylece yukarıdaki eşitlik (19) istenilen sayıda belirsiz katsayı veya istenilen derecede bir eğri için bütün katsayılar için türevin sıfıra eşitlenmesini gerektirir.

$$E = \sum_{i=1}^n (\varepsilon_i)^2 = \sum_{i=1}^n (y_i - (a_0 + a_1 x_i + a_2 x_i^2 + \dots + a_n x_i^n))^2 \quad (20)$$

$$\frac{\partial E}{\partial a_0} = 0 = -2 \sum_{i=1}^n (y_i - (a_0 + a_1 x_i + a_2 x_i^2 + \dots + a_n x_i^n)) \quad (21a)$$

$$\frac{\partial E}{\partial a_1} = 0 = -2 \sum_{i=1}^n (y_i - (a_0 + a_1 x_i + a_2 x_i^2 + \dots + a_n x_i^n)) \cdot x_i \quad (22b)$$

...

$$\frac{\partial E}{\partial a_n} = 0 = -2 \sum_{i=1}^n (y_i - (a_0 + a_1 x_i + a_2 x_i^2 + \dots + a_n x_i^n)) \cdot x_i^n \quad (23c)$$

Yukarıda eşitlikler n. Dereceden bir eğri için düzenlendiğinde $(n+1)$ adet eşitlik ve $(n+1)$ adet belirsiz katsayı bulunacaktır. Bu eşitlikler genel bir tanım şeklinde aşağıdaki eşitlikle yazılabilir. Bu durumda uydurulacak eğri ve bulunması gereken belirsiz katsayı sayısına göre elde edilecek denklem takımı çözümlenerek aranan belirsiz katsayılar bulunabilir.

$$\sum_{i=1}^n g(x_i) \cdot \frac{\partial g(x_i)}{\partial a_k} = \sum_{i=1}^n y_i \cdot \frac{\partial g(x_i)}{\partial a_k} \quad (24)$$

2.2.3.2. En Küçük Kareler Yöntemi ile 2. Dereceden Polinom Uydurma

Uydurulacak eşitlik bir ikinci dereceden eğri denklemi olduğundan aşağıdaki eşitlik (25) biçiminde üç belirsiz katsayı içeren bir ifadedir. Böylece eşitlik (24) ile verilen genel ifadeden gidilerek belirsiz katsayılara göre (a_0, a_1, a_2) ayrı ayrı kısmi türevleri alınarak üç tane eşitlik türetilir.

$$g(x) = a_0 + a_1 x + a_2 x^2 \quad (25)$$

Birinci katsayıya göre işlemler:

$$\sum_{i=1}^n g(x_i) \cdot \frac{\partial g(x_i)}{\partial a_0} = \sum_{i=1}^n y_i \cdot \frac{\partial g(x_i)}{\partial a_0} \quad (26)$$

$$\frac{\partial g(x_i)}{\partial a_0} = 1 \quad (27)$$

$$\sum_{i=1}^n [a_0 + a_1 x_i + a_2 x_i^2] \cdot 1 = \sum y_i \quad (28a)$$

$$(n) \cdot a_0 + \left(\sum_{i=1}^n x_i \right) \cdot a_1 + \left(\sum_{i=1}^n x_i^2 \right) \cdot a_2 = \left(\sum_{i=1}^n y_i \right) \quad (28b)$$

İkinci katsayıya göre işlemler:

$$\sum_{i=1}^n g(x_i) \cdot \frac{\partial g(x_i)}{\partial a_1} = \sum_{i=1}^n y_i \frac{\partial g(x_i)}{\partial a_1} \quad (29)$$

$$\frac{\partial g(x_i)}{\partial a_1} = x_i \quad (30)$$

$$\sum_{i=1}^n [a_0 + a_1 x_i + a_2 x_i^2] \cdot x_i = \sum y_i x_i \quad (31a)$$

$$\left(\sum_{i=1}^n x_i \right) a_0 + \left(\sum_{i=1}^n x_i^2 \right) \cdot a_1 + \left(\sum_{i=1}^n x_i^3 \right) \cdot a_2 = \left(\sum_{i=1}^n y_i x_i \right) \quad (31b)$$

Üçüncü katsayıya göre işlemler:

$$\sum_{i=1}^n g(x_i) \cdot \frac{\partial g(x_i)}{\partial a_2} = \sum_{i=1}^n y_i \frac{\partial g(x_i)}{\partial a_2} \quad (32)$$

$$\frac{\partial g(x_i)}{\partial a_2} = x_i^2 \quad (33)$$

$$\sum_{i=1}^n [a_0 + a_1 x_i + a_2 x_i^2] \cdot x_i^2 = \sum y_i x_i^2 \quad (34a)$$

$$\left(\sum_{i=1}^n x_i^2 \right) a_0 + \left(\sum_{i=1}^n x_i^3 \right) a_1 + \left(\sum_{i=1}^n x_i^4 \right) a_2 = \left(\sum_{i=1}^n y_i x_i^2 \right) \quad (34b)$$

Eşitlikler (28b), (31b), (34b) bir denklem takımı şeklinde getirilerek matris formunda düzenlenirse aşağıdaki eşitlik şeklinde düzenlenebilirler.

$$\begin{aligned} 1. \text{Eşitlik } (a_0) &\rightarrow (n) \cdot a_0 + \left(\sum_{i=1}^n x_i \right) \cdot a_1 + \left(\sum_{i=1}^n x_i^2 \right) \cdot a_2 = \left(\sum_{i=1}^n y_i \right) \\ 2. \text{Eşitlik } (a_1) &\rightarrow \left(\sum_{i=1}^n x_i \right) \cdot a_0 + \left(\sum_{i=1}^n x_i^2 \right) \cdot a_1 + \left(\sum_{i=1}^n x_i^3 \right) \cdot a_2 = \left(\sum_{i=1}^n y_i x_i \right) \\ 3. \text{Eşitlik } (a_2) &\rightarrow \left(\sum_{i=1}^n x_i^2 \right) \cdot a_0 + \left(\sum_{i=1}^n x_i^3 \right) \cdot a_1 + \left(\sum_{i=1}^n x_i^4 \right) \cdot a_2 = \left(\sum_{i=1}^n y_i x_i^2 \right) \end{aligned}$$

$$\begin{bmatrix} n & \sum x_i & \sum x_i^2 \\ \sum x_i & \sum x_i^2 & \sum x_i^3 \\ \sum x_i^2 & \sum x_i^3 & \sum x_i^4 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} \sum f_i \\ \sum f_i x_i \\ \sum f_i x_i^2 \end{bmatrix} \quad (35)$$

Bu matris formundaki eşitlikler doğrusal denklem takımı çözüm yöntemlerinden birisi kullanılarak çözülür. Çözüm sonunda bilinmeyenler (a_0, a_1, a_2) bulunarak eşitlik (25) olan $g(x) = a_0 + a_1 x + a_2 x^2$ deki eşitliğinde yerlerine konulduğunda aranılan 2. dereceden polinom olan $g(x)$ eşitliği belirlenmiş olur [69].

2.2.4. Destek Vektör Makineleri Yöntemi

DVM'ler 1960'ların sonlarında V.Vapnik tarafından bulunan istatistiksel bir metottur [70]. DVM'ler yapısal risk minimizasyonu prensibi etrafında formülleştirilmiştir. Beklenen riskin üst sınırını küçükmeye çalışır.

DVM uygulamaları diğer geleneksel metotlardan daha iyi sonuçlar vermektedir. DVM'ler el yazısı tanıma, ses tanıma, nesne tanıma ve uzaysal veri analizi gibi alanlarda ve çoğu sınıflandırma probleminde kullanılmıştır [71].

Destek Vektörü öğrenme iki bakımdan çok kullanışlıdır. Birincisi Destek Vektörü (DV) öğrenme basit fikirler üzerine kurulmuştur. ikincisi yüksek performanslı pratik uygulamalarda kullanılabilir.

DV algoritması öğrenme teorisinin ve pratiğinin kesiştiği bir uygulamadır; bazı belirli algoritma tipleri için istatistiksel öğrenme teorisinde hesaplamaların başarılı olması için faktörler tam olarak istenir. Gerçek-dünya uygulamaları, sık sık teorik olarak çözülmesi zor ve kompleks olan uygulamalardır. DV algoritması iki zorluğu da basitçe kaldırabilir. Yeterince kompleks olan modellere çözüm getirebilir.

Nöral ağların, radyal tabanlı fonksiyon ağlarının ve polinomal sınıflandırıcıların geniş bir kısmını içerir. Aynı zamanda matematiksel olarak analizi basittir, çünkü doğrusal olmayan giriş uzayındaki verileri dönüşümler yaparak özellik uzayına düşürür ve çözüm kolaylaşır.

DVM istatistiksel öğrenme teorisinde iyi şekilde kurulmuş bir teoriye sahiptir ve sınıflandırma ile regresyon problemlerine çözüm için uygundur. Vapnik'in teorisi eğitim kümesindeki arıza ile VC-boyutuna göre ifade edilen hipotez uzayının karmaşıklığının her ikisini de küçükleyen çözümün bulunduğunu göstermektedir. Bu bakımdan, DVM ile bulunan fonksiyon, veriye yakınlık ve çözümün karmaşıklığı arasındaki geçiştir. Özellikle iki sınıflı sınıflandırma probleminde DVM iki sınıf arasındaki sınırı büyüleyen optimal ayırt etme yüzeyini belirlemekte, yani eğitim kümesi ile ayırt etme yüzeyine en yakın noktaların arasındaki mesafeyi en büyülemektedir. Ayrıca, optimal ayırt etme yüzeyi, destek vektörleri olarak adlandırılan veri noktalarının küçük bir kümesinde merkezlenmiş Kernel fonksiyonların doğrusal bir kombinasyonu olarak ifade edilmektedir. Genelde destek vektörleri çok az miktarda olduğu için optimal ayırt etme yüzeyinin gösterimi seyrek, bir anlamda veri noktalarının sadece bir bölümü sınıflandırma görevi ile ilgilidir. Buna ilaveten, doğrusal kombinasyon katsayıları doğrusal eşitsizlik ve eşitlik kısıtları dahilinde bir konveks ikinci dereceli (*quadratic*) programlama probleminin çözümü ile belirlenmektedir. Çok katmanlı perseptron ve radyal tabanlı ağlar, uygun çekirdek fonksiyonları ile elde edilen DVM ağların özel durumları olarak gösterilebilir.

DVM eğitimindeki dizayn adımlarını şu şekilde verebiliriz :

Adım 1: Sınıflandırma probleminde karar fonksiyonunun, regresyon probleminde regresyon fonksiyonunun biçimini belirleyen Kernel fonksiyonunun belirlenmesi

Adım 2: Seçilen Kernel fonksiyonunun parametre seçimi

Adım 3: C yaptırım faktörünün seçimi

Adım 4: ikinci dereceden problemin çözümü

2.2.4.1. Doğrusal Destek Vektör Makineleri

DVM'lerin en basit modeli en büyük sınırlı sınıflandırma olarak bilinmektedir. DVM'lerin bu kısmı sadece doğrusal olarak ayrılabilen özellik uzayı için geçerlidir. Bu nedenle, çoğu gerçek dünya uygulamalarında kullanılması oldukça zor bir yöntemdir. Ama anlaşılması en kolay algoritmadır ve daha karmaşık DVM için temel kısmı inşa etmektedir. DVM için geçerli olan çoğu anahtar özellikleri içinde bulundurur. Giriş verilerinin Kernel fonksiyonlarından geçirilip özellik uzayına düşürülmesine gerek yoktur. Sadece verileri birbirinden en iyi şekilde ayıran ve en büyük sınırlı sınıflandırmayı yapan hiperdüzlemi bulmak yeterli olacaktır.

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

$$\langle w \cdot x^+ \rangle + b = +1 \quad (36)$$

$$\langle w \cdot x^- \rangle + b = -1 \text{ 'dir.} \quad (37)$$

Sınıflandırıcının sınırını γ ile gösterecek olursak;

$$\gamma = \frac{1}{2} \left(\left\langle \frac{w}{\|w\|_2} \cdot x^+ \right\rangle - \left\langle \frac{w}{\|w\|_2} \cdot x^- \right\rangle \right) \quad (38)$$

$$= \frac{1}{2\|w\|_2} \left(\langle w \cdot x^+ \rangle - \langle w \cdot x^- \rangle \right) \quad (39)$$

$$= \frac{1}{\|w\|_2} \quad (40)$$

ifadesi geometrik sınırı verecektir.

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

$$\gamma = \frac{1}{\|w\|_2} \quad (41)$$

olarak hesaplanır.

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

$$L(w, b, \alpha) = \frac{1}{2} \langle w, w \rangle - \sum_{i=1}^n \alpha_i [y_i (\langle w, x_i \rangle + b) - 1] \quad (42)$$

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

$$\frac{\partial L(w, b, \alpha)}{\partial w} = w - \sum_{i=1}^n y_i \alpha_i x_i = 0, \quad (43)$$

$$\frac{\partial L(w, b, \alpha)}{\partial b} = \sum_{i=1}^n y_i \alpha_i = 0, \quad (44)$$

Bu iki ifadeyi birleştirirsek;

$$w = \sum_{i=1}^n y_i \alpha_i x_i, \quad (45)$$

$$0 = \sum_{i=1}^n y_i \alpha_i \quad (46)$$

ifadeleri bulunur.

Hesaplanan bütün bu değerler birleştirilirse;

$$L(w, b, \alpha) = \frac{1}{2} \langle w, w \rangle - \sum_{i=1}^n \alpha_i [y_i (\langle w, x_i \rangle + b) - 1] \quad (47)$$

$$= \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle - \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle + \sum_{i=1}^n \alpha_i \quad (48)$$

$$= \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \quad (49)$$

ifadesi elde edilir.

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

$$W(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j \alpha_i \alpha_j \langle x_i, x_j \rangle \quad (50)$$

$$\sum_{i=1}^n y_i \alpha_i = 0, \quad \alpha_i \geq 0, \quad i = 1, \dots, n \quad (51)$$

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

$\gamma = \frac{1}{\|w^*\|_2}$ olarak hesaplanır.


b değeri ikili problemde bulunmamaktadır. Bu nedenle birincil sabitler kullanılarak b^* değeri bulunmalıdır.

$$b^* = - \frac{\max_{y_i=-1} (\langle w^*, x_i \rangle) + \min_{y_i=1} (\langle w^*, x_i \rangle)}{2} \quad (52)$$

Karush-Kuhn-Tucker şartları kullanılarak,

$$\alpha_i^* [y_i (\langle w^*, x_i \rangle + b^*) - 1] = 0, \quad i = 1, \dots, n \quad (53)$$

ifadesi bulunur.



Şekil 2.3. 3 tane destek vektörlü maksimum sınırlı hiperdüzlem

Hiperdüzleme en yakın noktalar yani Destek Vektörleri için α_i^* değerleri 0 değildir. Diğer noktalar için bütün α_i^* değerleri 0'a eşittir. Bu nedenle ağırlık vektörü w için sadece Destek Vektörlerinin (DV) α_i^* değerleri geçerlidir. Bu açıklamalardan sonra optimal hiperdüzlem şu şekilde verilir:

$$f(x, \alpha, b^*) = \sum_{i=1}^n y_i \alpha_i^* \langle x_i, x \rangle + b^* \quad (54)$$

$$= \sum_{i \in DV}^n y_i \alpha_i^* \langle x_i, x \rangle + b^* \quad (55)$$

$j \in DV$ için,

$$y_j f(x_j, \alpha^*, b^*) = y_j \left(\sum_{i \in DV}^n y_i \alpha_i^* \langle x_i, x_j \rangle + b^* \right) = 1 \quad (56)$$

$$\langle w^*, w^* \rangle = \sum_{i,j=1}^n y_i y_j \alpha_i^* \alpha_j^* \langle x_i, x_j \rangle \quad (57)$$


$$= \sum_{j \in DV} \alpha_j^* y_j \sum_{i \in DV} y_i \alpha_i^* \langle x_i, x_j \rangle \quad (58)$$

$$= \sum_{j \in DV} \alpha_j^* (1 - y_j b^*) \quad (59)$$


$$= \sum_{i \in DV} \alpha_i^* \quad (60)$$

2.2.4.2. Sınır (Margin)

Regresyon için nöral ağların içeriğindeki iyi genellemeyi elde etmek için ağırlık yenilemesi ne kadar önemliyse, sınıflandırma problemlerinde sınır aynı rolü oynar. Sınır içeriği DVM'lerin formülasyonunu anlamak için en önemli adımdır. Şekil 2.4 (a) ve Şekil 2.4 (b) iki boyutlu bir giriş uzayında verilmiş ayrılabilir probleme bir örnektir. Şekil 2.4(a)'da iki sınıf verisini ayıran birkaç tane hiperdüzlem görülür.




Şekil 2.4. (a) Hiperdüzlemin tek olmadığı durum



Şekil 2.4. (b) Hiperdüzlemin tek olduğu durum

2.2.4.3. Doğrusalca Ayrılabilir Veri

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



Şekil 2.5. (a) İki sınıflı veriyi ayıran bir alt düzlem, (b) en iyi alt düzlem ve marjları

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

$$y_i(w \cdot x_i + b) \geq 1 \quad (61)$$

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

$$w \cdot x + b = 0 \quad (62)$$

ve ayıran alt düzlem olarak adlandırılır ve denklem (61)'deki çarpım, veri noktası ile etiketinin alt düzlemin aynı tarafında olmasını belirler. Şekil 2.5'de iki sınıfı ayıran böyle alt düzlemlerden biri gösterilmiştir. Tabiki, iki sınıfı ayırabilen sonsuz sayıda alt düzlem vardır. Şimdi alt düzlemden bir veri noktası x_i 'ye olan bir d_i uzaklık ölçüsü tanımlayalım:

$$d_i = \frac{w \cdot x_i + b}{\|w\|} \quad (63)$$

Eğer denklem (61) ve (63) birleştirilirse aşağıdaki denklemi elde ederiz:

$$y_i d_i \geq \frac{1}{\|w\|} \quad (64)$$

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

$$w \cdot x_i + b \quad (65)$$

yukarıdaki denklemin işaretini bulmaya indirgenir. Böylelikle, karar fonksiyonumuz;

$$f(x) = \text{sign}(w \cdot x + b) = \text{sign}(\langle w, x \rangle + b) \quad (66)$$

olur.

2.2.4.4. Doğrusalca Ayrılamayan Veri

Gerçek hayatta karşılaşılan çoğu problemler ya doğrusal ya da doğrusal olmayan durumlarda ayırt edilemezler. Genellikle mümkün olduğu kadar sınıfları ayırabilen giriş kümeleri bulmaya çalışılır, fakat çoğunlukla ilgili girişler kayıptır, veri tam değildir, güvenilir değildir veya gürültülüdür. Doğrusal DVM'lerin ayırt edilemez durumuna genişletilmesi Cortes ve Vapnik tarafından yapılmıştır. Temel olarak, problem formülasyonlarında ek serbestlik değişkenleri olarak yapılmıştır. Doğrusal olarak ayırt edilebilen sınıflar hipotezi pratik uygulamalar için oldukça sınırlıdır. Bu nedenle önceki sonuçları düzenlemeye gerek vardır. Bu durum, $y_i(w \cdot x_i + b) + \xi_i < 1$ ifadesini sağlayacak şekilde bir takım $(x_i, y_i) \in S$ noktalarının var olduğu anlama gelir. Negatif olmayan bir ξ_i serbestlik değişkeninin girilmesi $y_i(w \cdot x_i + b) \geq 1$ ile aynı formda doğru şekilde sınıflandırılmamış bir nokta için kısıt belirtmeye ve doğrusal olarak ayırt edilemeyen eğitim kümesi durumunda önceki analizleri genişletmeye izin verir. Bu amaçla, aşağıdaki ifadeyi sağlayacak şekilde N adet negatif olmayan serbestlik değişkeni (S'teki her nokta için) $\xi = (\xi_1, \xi_2, \dots, \xi_N)$ verilirse;

$$y_i(w \cdot x_i + b) + \xi_i \geq 1, \quad i = 1, 2, \dots, N \quad (67)$$

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

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

2.2.4.5. Doğrusal Olmayan Destek Vektör Makineleri Sınıflandırıcıları

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

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

$$x \in R^n \rightarrow z(x) = [a_1\phi_1(x), a_2\phi_2(x), \dots, a_n\phi_n(x)]^T \in R^f \quad (68)$$

Yukarıdaki gösterimde $n \times f \times R \otimes R$ 'e bir dönüşüm gösterilmiştir. Bir $f(x)$ eşleştirmesi önceden seçilen, sabit bir fonksiyondur. Bir x -giriş uzayı, x giriş vektörünün x_i bileşenlerinden oluşur ve bir f -özellik uzayı (z -uzayı) z vektörünün $\phi_i(x)$ bileşenlerinden oluşur. Bu dönüşüm yapıldıktan sonra z -uzayında doğrusal algoritma uygulanarak çözüme ulaşılması beklenilir.

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

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

En çok kullanılan kernel fonksiyonları şunlardır:

$$K(x, y) = (x.y)^d \quad (\text{polinomal Kernel}) \quad (69)$$

$$K(x, y) = \tanh(K(x, y) + \Phi) \quad (\text{sigmoidal Kernel}) \quad (70)$$

$$K(x, y) = \exp\left(-\|x - y\|^2 / (2\sigma^2)\right) \quad (\text{RBF Kernel}) \quad (71)$$

Bu tez çalışmasında DVM'ye dayalı bulunan sonuçlar genelde RBF Kernel fonksiyonu kullanılarak hesaplanmıştır.

2.2.5. k- En Yakın Komşuluk Yöntemi

k-en yakın komşuluk algoritması sorgu vektörünün en yakın k komşuluktaki vektör ile sınıflandırılmasının bir sonucu olan denetlemeli öğrenme algoritmasıdır. Bu algoritma ile yeni bir vektörü sınıflandırabilmek için doküman vektörü ve eğitim dokümanları vektörleri kullanılır. Bir sorgu örneği verilir, bu sorgu noktasına en yakın k tane eğitim noktası bulunur. Sınıflandırma ise bu k tane nesnenin en fazla olanı ile yapılır. k en yakın komşuluk uygulaması yeni sorgu örneğinin sınıflandırmak için kullanılan bir komşuluk sınıflandırma algoritmasıdır.

k- en yakın komşuluk algoritması çok kolaydır. K en yakın komşulukları bulmak için sorgu örneği ile eğitim dokümanları arasındaki en küçük uzaklıklar dikkate alınır. En yakın komşuları bulduktan sonra bu komşulardan kategorisi en çok olanın kategorisi dokümanın kategorisini tahmin etmekte kullanılır. Uygulanabilirliği basit bir algoritmadır. Gürültülü eğitim dokümanlarına karşı dirençlidir. Eğitim dokümanları sayısı fazla ise etkilidir. Bunlara karşılık k parametreye ihtiyaç duyar. Uzaklık bazlı öğrenme algoritması, en iyi sonuçları elde etmek için, hangi uzaklık tipinin ve hangi niteliğin kullanılacağı konusunda açık değildir. Hesaplama maliyeti gerçekten çok yüksektir çünkü her bir sorgu örneğinin tüm eğitim örneklerine olan uzaklığını hesaplamak gerekmektedir. Bazı indeksleme metotları ile (örneğin K-D ağacı), bu maliyet azaltılabilir. En yakın komşuluk prensibine dayanır. Tüm dokümanlar vektörel olarak temsil edilir. Bu çalışmada Kosinüs uzaklığına dayalı en yakın komşuluk yöntemi uygulanmıştır. Genel formülü denklem 72'de verilmiştir.

$$\cos(q, r) = d_i = \frac{\sum_y q(y).r(y)}{\sqrt{\sum_y q(y)^2.r(y)^2}} \quad (72)$$

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


2.3. Öznitelik Çıkarma Çalışmaları ve Sınıflandırma

2.3.1. Temel/Bağımsız Bileşen Analizi ile Öznitelik Çıkarma ve Sınıflandırma

Çoklu elektrot kullanılarak yapılan EEG kayıtlarında PCA ile özdeğer incelemesi yapılarak boyut azaltımı bazı varsayımlar dikkate alınarak sıklıkla yapılmaktadır. Dataset Ia verilerinin özdeğerlerinin incelenmesi sonucu S_0 arkaplan işareti ve S_1 düşünce durumunda beyin faaliyetlerinin aktif olduğu durumda oluşan kaynak işareti olarak varsayım yapılmıştır. Denklem 73'te bu varsayım göre 6 elektrottan kayıt edilen verilerin (X) belirsiz bir A matrisi ile karıştırılmış hali gösterilmiştir.

$$X_{6 \times 896} = A_{6 \times 2} \cdot \begin{bmatrix} S_0 \\ S_1 \end{bmatrix}_{2 \times 896} \quad (73)$$

YİH ve AİH'nin eğitim verilerine ait tüm denemelerinden elde edilen özdeğerlerin ortalaması Şekil 2.6'da gösterilmiştir. Burada görüleceği üzere 2. özdeğerden sonraki özdeğerlerin ortalaması 1 ve 2. ye göre oldukça küçüktür. Bu sonuç kayıt edilen EEG verilerinin S_0 ve S_1 gibi 2 kaynaktan elde edildiği varsayımının yapılabilmesi konusunda bir bilgi vermektedir.



Şekil 2.6. Eğitim verilerine ait özdeğerlerin ortalamaları

Yapılan varsayım ve özdeğerlerin ortalamalarından çıkan sonuç ile birlikte değerlendirilerek PCA ile 6 boyutlu $X_{6 \times 896}$ matrisi, konu 2.2.1’de anlatıldığı gibi 2 boyutlu $Y_{2 \times 896}$ matrisine indirgenmiştir. Bu durumda ;

$$Y_{2 \times 896} = B_{2 \times 2} \cdot \begin{bmatrix} S_0 \\ S_1 \end{bmatrix}_{2 \times 896} \quad (74)$$

şekline dönmüş olur.

S_0 ve S_1 kaynaklarını bulabilmek için karıştırma matrisi B’yi veya B matrisinin tersi olan W dönüşüm matrisini bulmak gerekir. Konu 2.2.2’ de anlatılan ICA algoritması ile önce dönüşüm matrisi W, daha sonra matrisel çarpma işlemleri ile her bir deneme için S_0 ve S_1 kaynakları bulunur.

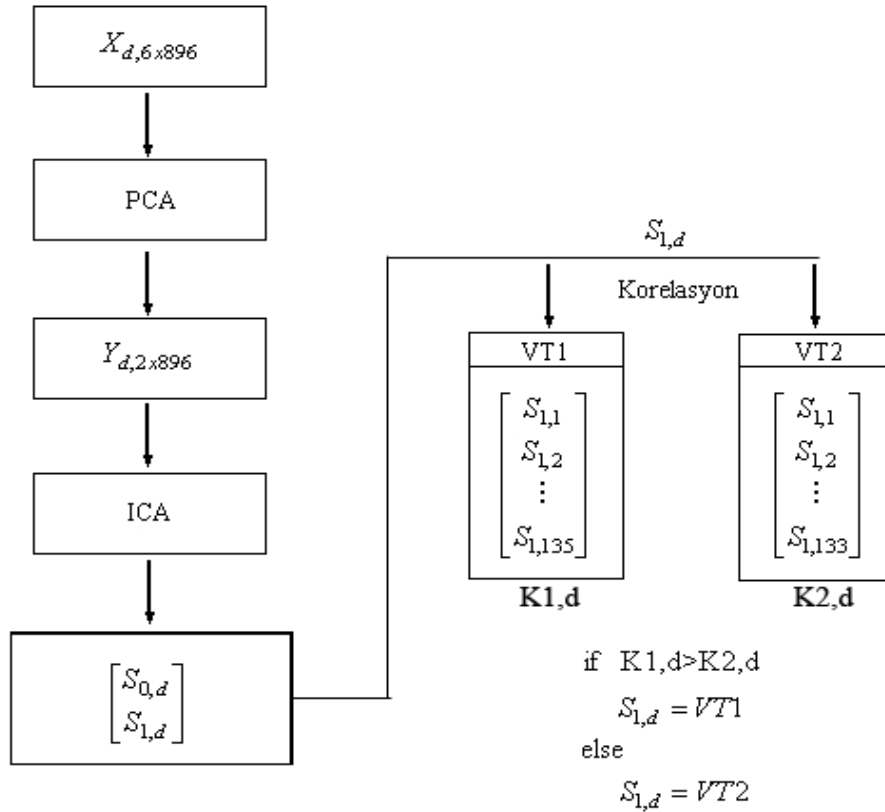
$$\begin{bmatrix} S_0 \\ S_1 \end{bmatrix} = W \cdot Y \quad (75)$$

Tüm eğitim verileri için bu işlemler yapılarak YİH için 135 denemeye ait 135 S_0 ve S_1 , AİH için 133 denemeye ait S_0 ve S_1 'ler hesaplanarak veri tabanı oluşturulur. Daha sonra test verilerine ait her bir deneme için $S_{0,d}$ ve $S_{1,d}$ hesaplanır. Hesaplanan $S_{1,d}$, veri tabanına ait 268 adet S_1 ile korelasyona tabi tutulur. Sonuçta $S_{1,d}$, hangi veri tabanında en yüksek korelasyon değerine sahip olursa o sınıfa gönderilir. Bu şekilde 293 test verisi sınıflandırılır.

PCA, ICA ve korelasyon kullanılarak yapılan bu sınıflandırma işlemi bu veriler için %68 oranında bir sınıflandırma başarımı sağlamıştır. Yapılan bu sınıflandırma işlemleri Şekil 2.7'de gösterilmiştir.

Korelasyon denklem 76 ile hesaplanmıştır. C kovaryans matrisini göstermektedir.

$$R(S_{VT1,VT2}, S_{1,d}) = \frac{C(S_{VT1,VT2}, S_{1,d})}{\sqrt{C(S_{VT1,VT2}, S_{VT1,VT2}) \cdot C(S_{1,d}, S_{1,d})}} \quad (76)$$




Şekil 2.7. PCA, ICA ve korelasyon kullanılarak yapılan sınıflandırma işleminin algoritması

Burada $d, (d = 1, 2, \dots, 293)$ deneme sayısını, VT1 YİH'ye ait veri tabanı, VT2 ise AİH'ye ait veri tabanını, $K1, d$ $S_{1,d}$ nin VT1 kümesi ile elde edilen en yüksek korelasyon değerini, $K2, d$ $S_{1,d}$ nin VT2 kümesi ile elde edilen en yüksek korelasyon değerini göstermektedir.

2.3.2. EEG Verilerinin Yerel Maksimum ve Minimumlarına 2. Dereceden Polinom Uydurarak Öznitelik Çıkarma


Sinir sistemi, vücut bilgilerinin toplandığı, depo edildiği ve kontrol edildiği bir sistemdir. Sinir sistemi nöron adını da alan sinir hücrelerinden meydana gelir. Nöronlar bilginin kodlanması, dekodlanması, ve iletilmesinde temel elemandır. Nöronlar arası iletişim aksiyon potansiyeli(AP) yada spike adı verilen sinyallerin sinaps bölgelerine ulaşarak bu bölgelerde oluşturdukları kimyasal yapı değişiklikleri ile gerçekleşir. Bunlar EEG verileri içerisinde yerel maksimumların (YMAK) ve yerel minimumların (YMİN) oluşmasını sağlar. Bir nevi AP'ler beynin faaliyette olduğunun göstergesidir. Çalışmanın bu kısmında YMAK'lar göz önüne alınarak EEG verilerine 2. dereceden polinom uydurarak YİH ve AİH durumlarında ortaya çıkan farklılıklar incelenmiştir. Sonuçta 1. ve 2. elektrotlara uydurulan eğrilerde YİH ve AİH durumlarında $f(x) = ax^2 + bx + c$ denklemine göre a katsayısının farklılık gösterdiği gözlenmiştir. Eğitim verilerinden alınan birer örnekle bu durum Şekil 2.8 'de ve 2.9'da gösterilmiştir.



Şekil 2.8. YİH'ye ait bir EEG işareti ve bu işaretin YMAK'larına uydurulmuş eğri

Uydurulan eğri sonucu elde edilen polinom eşitlik 77'deki gibidir. Burada a katsayısının işaretinin eksi olduğu (-1.8930) görülmektedir.

$$f(x) = -1.8930x^2 - 5.9798x + 40.9842 \quad (77)$$

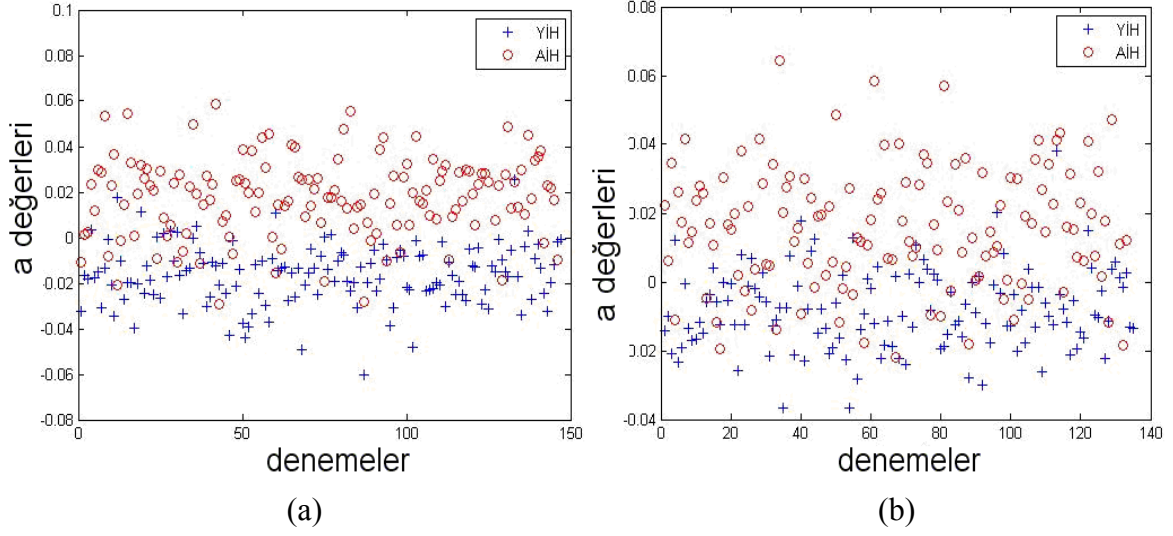


Şekil 2.9. AİH'ye ait bir EEG işareti ve bu işaretin YMAK'larına uydurulmuş eğri

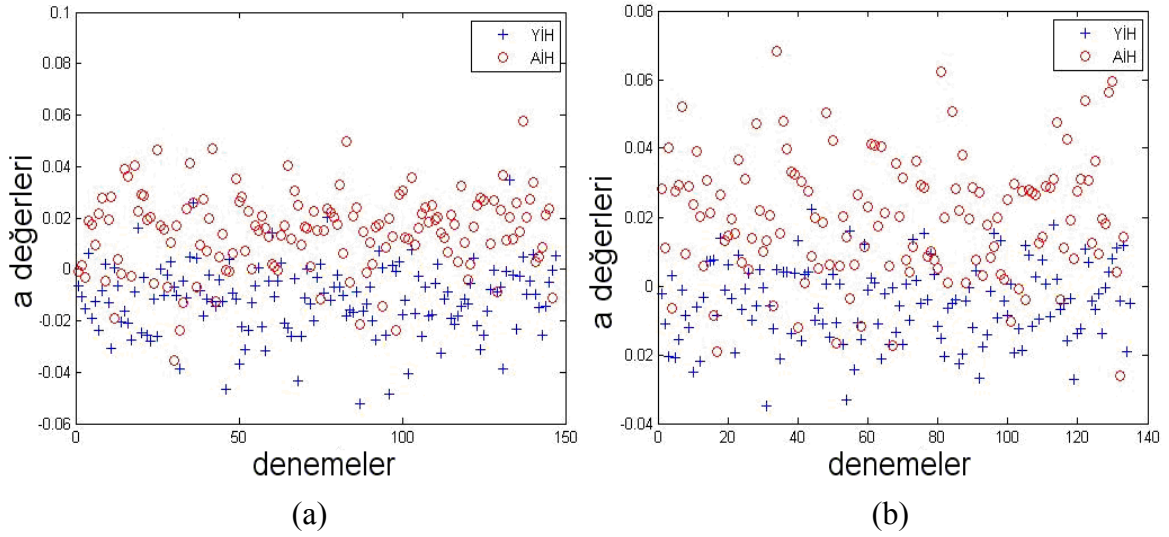
Uydurulan eğri sonucu elde edilen polinom eşitlik 78'deki gibidir. Burada a katsayısının işaretinin artı olduğu (+6.0494) görülmektedir.

$$f(x) = 6.04946x^2 - 22.6832x + 12.9167 \quad (78)$$

Şekil 2.10'da tüm verilerin 1. elektrotlarına ve Şekil 2.11'de tüm verilerin 2. elektrotlarına eğri uydurma sonucu elde edilen a katsayılarının gösterimi verilmiştir. Burada YİH'de a katsayılarının çoğunun sıfırdan küçük, AİH' de ise a katsayılarının çoğunun sıfırdan büyük olduğu açıkça görülmektedir. Bu durum çok iyi bir öznelilik olup test verilerine de uygulandığında yüksek başarımlı bir yöntemdir.




Şekil 2.10. 1. elektrotların YMAK'larına uydurulmuş eğrilerin a değerleri, (a)eğitim verileri, (b) test verileri



Şekil 2.11. 2. elektrotların YMIN'lerine uydurulmuş eğrilerin a değerleri, (a)eğitim verileri, (b) test verileri


a katsayısından başka, uydurulan eğriden çıkartılan bir başka öznelik de eğrilerin tepe noktalarının kullanılmasıdır. Dikkat edilirse YIH'de uydurulan eğrinin tepe noktası, AIH'ne göre büyük değerdedir. Eğrilerin tepe noktası denklem 79'de verildiği şekilde hesaplanabilir. Eğitim verilerinin 1. Elektrolarına uydurulmuş eğrilerden elde edilen tepe noktalarının grafiksel gösterimi Şekil 2.12'de verilmiştir. Bu şekilden de görüldüğü gibi tepe noktalarına göre sınıflandırma da iyi bir öznelik olup, test verilerine uygulandığında başarıyı oldukça yükseltecek bir yöntem olduğu görülmektedir.

$$TepeNoktası = \frac{-b^2}{4a} + c \quad (79)$$



Şekil 2.12. 1. Elektroların YMAK'larına uydurulmuş eğrilerden elde edilen tepe noktaları, (a)eğitim verileri,(b) test verileri

Bu sonuçlardan elde edilen önemli bir sonuç da a katsayılarına göre sınıflandırma yapıldığında YİH'de noktalar AİH'nin noktalarına göre x - y ekseninde aşağıda kalmaktadır. Diğer taraftan, tepe noktalarına göre sınıflandırma yapıldığında ise bunun tam tersi olarak YİH'de noktalar, AİH'ye göre x - y ekseninde yukarıda kalmaktadır. Dolayısıyla sınıflandırma kriteri olarak bu iki özelliği birlikte kullanmak çok daha büyük bir avantaj sağlayacak olup x - y ekseninde iki yönlü bir ayrışma olduğu görülecektir. Bu durum Şekil 2.13'te açıkça görülmektedir.



Şekil 2.13 1. elektrot için a katsayısı ve tepe değerlerinin birlikte gösterimi, (a) eğitim verileri, (b) test verileri

Yerel maksimumlara göre bulunan bu öznitelikler yerel minimumlar göz önüne alınarak da ayrıca elde edilmiş olup 1. elektrota göre elde edilen bu özniteliklere dayalı sınıflandırma sonuçları Tablo 4'de gösterilmiştir. Burada a uydurulan polinomun a katsayısını, TN eğrinin tepe noktasını belirtir.


Tablo 4. YMAK ve YMİN'e dayalı sınıflandırma sonuçları

Sınıflandırma	YMAK	YMİN
	% Doğruluk	% Doğruluk
	Öznitelik: $a+TN$	Öznitelik: $a+TN$
DVM	90,78	89,42
KNN	90,44	92,15

2.3.3 Ham EEG Verilerine 2. Dereceden Polinom Uydurarak Öznitelik Çıkarma

EEG verilerinin YMAK'larına eğri uydurmak yerine direkt olarak ham EEG verilerine eğri uydurmak da, YMAK'lara göre yakın sonuçlar vermektedir. Bu işlem hızı bakımından avantaj sağlamaktadır.


Eğitim verilerinin birinci ve ikinci elektrotlarına 2. dereceden eğri uydurmak sureti ile yukarı ve aşağı yönlü imleç hareketlerinde nasıl bir eğri ortaya çıktığı incelenmiş ve bunun sonucunda YİH'de 2.dereceden polinomda $f(x) = ax^2 + bx + c$ denklemi göz önüne alınırsa a katsayısının genelde eksi işaretli (sıfırdan küçük) olduğu gözlenmiştir. Diğer taraftan AİH'de ise a katsayısının artı işaretli (sıfırdan büyük) olduğu gözlenmiştir. Eğitim verilerinden alınan birer örnekle bu durum şekil 2.14 'te ve 2.15'te gösterilmiştir.



Şekil 2.14. YİH'ye ait ham EEG işareti ve bu işarete uydurulmuş eğri

Uydurulan eğri sonucu elde edilen polinom eşitlik 80'deki gibidir. Burada a katsayısının işaretinin eksi olduğu (-3.5643) görülmektedir.

$$f(x) = -3.5643x^2 + 13.0702x + 25.7619 \quad (80)$$




Şekil 2.15. AİH'ye ait ham EEG işareti ve bu işarete uydurulmuş eğri

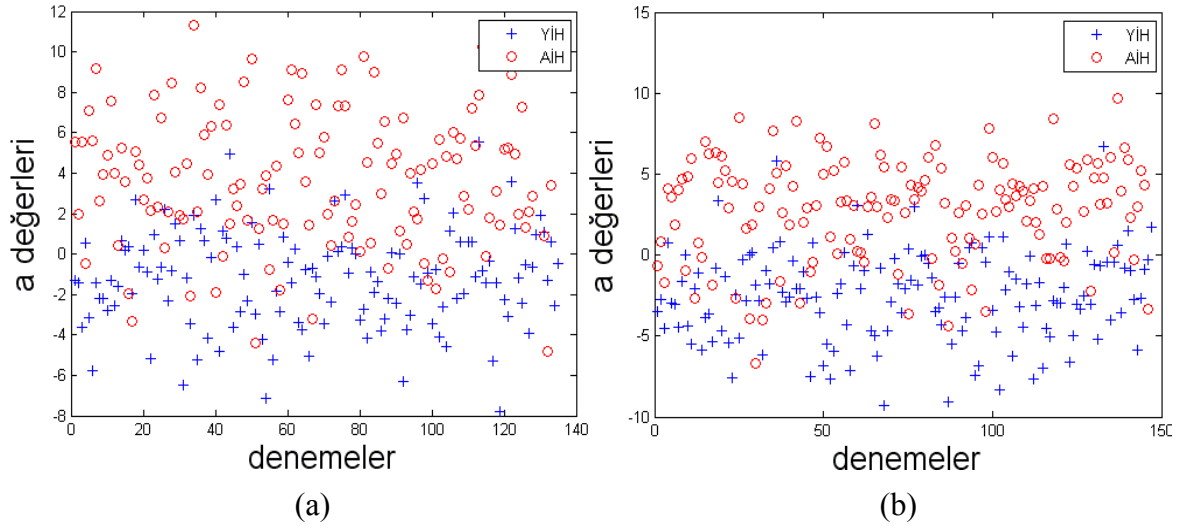
Uydurulan eğri sonucu elde edilen polinom eşitlik 81'deki gibidir. Burada a katsayısının işaretinin artı olduğu (+4.9076) görülmektedir.

$$f(x) = 4.9076x^2 - 16.1334x + 59.4993 \quad (81)$$

Şekil 2.16'de tüm verilerin 1. elektrotlarına ve Şekil 2.17'de tüm verilerin 2. elektrotlarına eğri uydurma sonucu elde edilen a katsayılarının grafiksel gösterimi yapılmıştır. Burada YİH'de a katsayılarının çoğunun sıfırdan küçük, AİH' de ise a katsayılarının çoğunun sıfırdan büyük olduğu açıkça görülmektedir. Bu durum çok iyi bir öznelik olup test verilerine de uygulandığında yüksek başarımlı bir yöntemdir.

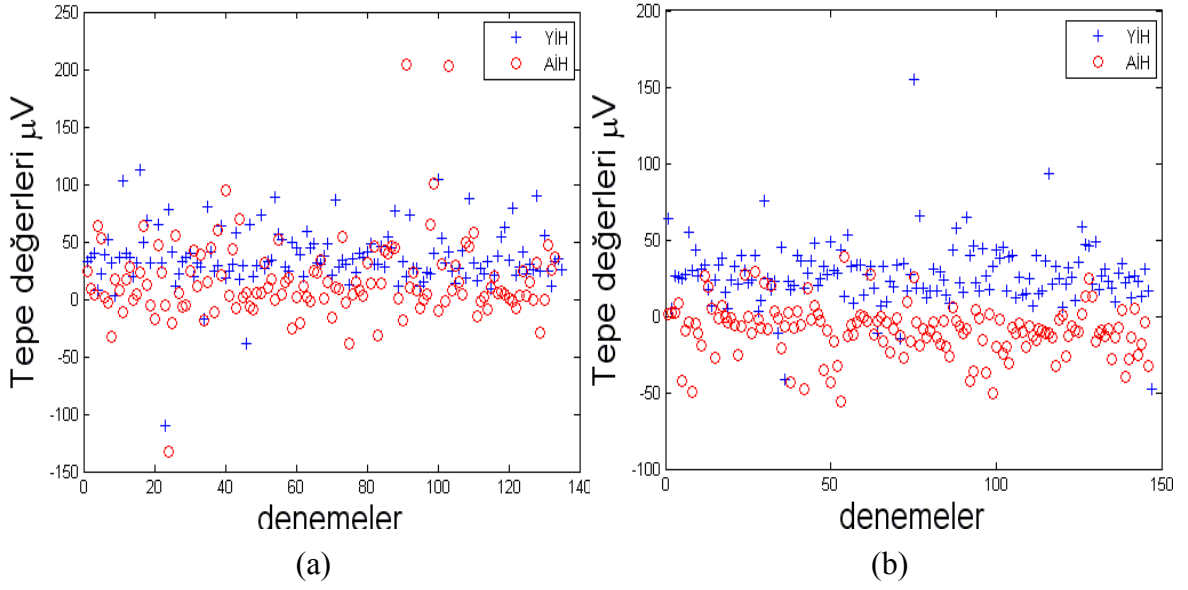


Şekil 2.16. 1. elektrotlara uydurulmuş eğrilerin a değerleri, (a)eğitim verileri,(b) test verileri



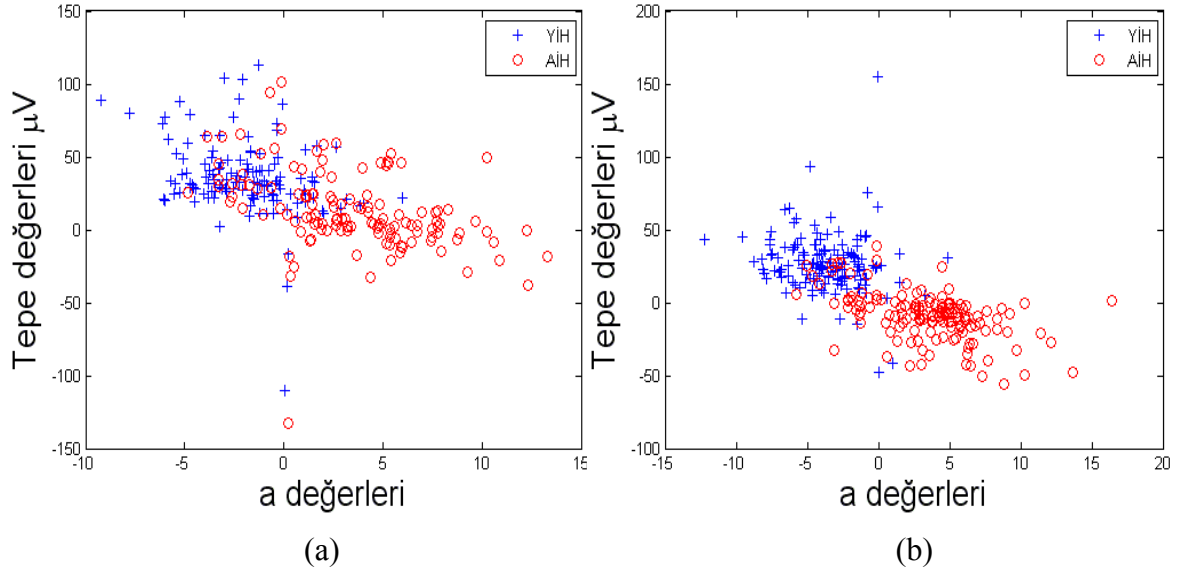
Şekil 2.17. 2. elektrotlara uydurulmuş eğrilerin a değerleri, (a)eğitim verileri,(b) test verileri

Eğitim verilerininin 1. Elektrolarına uydurulmuş eğrilerden elde edilen tepe noktalarının grafiksel gösterimi Şekil 2.18’de verilmiştir. Bu şekilden de görüldüğü gibi tepe noktalarına göre sınıflandırma da iyi bir öznelilik olup, test verilerine uygulandığında başarıyı oldukça yükseltecek bir yöntem olduğu görülmektedir.



Şekil 2.18. 1. Elektrolara uydurulmuş eğrilerden elde edilen tepe noktaları, (a)eğitim verileri,(b) test verileri

Bu sonuçlardan elde edilen önemli bir sonuç da a katsayılarına göre sınıflandırma yapıldığında YİH'de noktalar AIH'nin noktalarına göre x - y ekseninde aşağıda kalmaktadır. Diğer taraftan, tepe noktalarına göre sınıflandırma yapıldığında ise bunun tam tersi olarak YİH'de noktalar, AIH'ne göre x - y ekseninde yukarıda kalmaktadır. Dolayısıyla sınıflandırma kriteri olarak bu iki özelliği birlikte kullanmak çok daha büyük bir avantaj sağlayacak olup x - y ekseninde iki yönlü bir ayrışma olduğu görülecektir. Bu durum Şekil 2.19'da açıkça görülmektedir. Burada a değerleri ve Tepe değerleri 1. elektrotlara aittir.



Şekil 2.19. a katsayısı ve tepe değerlerinin birlikte gösterimi, (a) eğitim verileri, (b) test verileri

1. elektrota göre elde edilen özniteliklere dayalı sınıflandırma sonuçları Tablo 5'te gösterilmiştir.

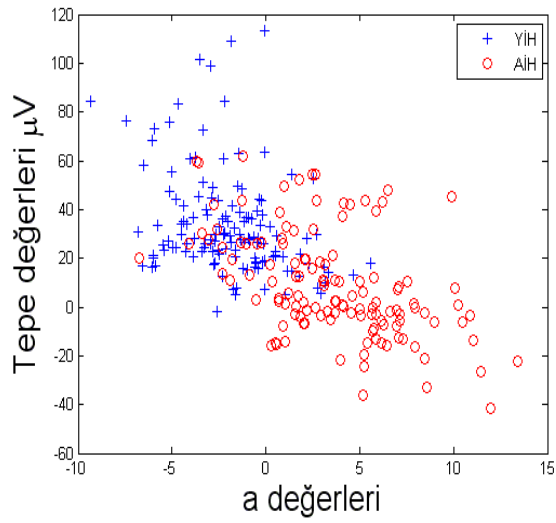
Tablo5. Ham EEG verilerine yönelik sınıflandırma sonuçları

Sınıflandırma	Ham EEG verileri % Doğruluk
	Öznitelik: a+TN
DVM	90,44
KNN	89,76


2.3.4. Yerel Maksimum ve Yerel Minimumların Ortaya Çıkış Zamanlarına Bağlı Eğri Uydurma

YMAK'ların ortaya çıkış zamanları da beyin aktivitesi konusunda yorum yapılabilmesi anlamında önemli bilgi vermektedir. Daha önceki çalışmada sadece YMAK'ların genliklerini dikkate alarak eğri uydurma ile öznitelik çıkarma yoluna gidilmişti. Bu kısımda ise, YMAK'ların oluşum zamanları ile o zamandaki genlik değerleri göz önüne alınarak eğri uydurma yöntemi ile öznitelik çıkarma denenmiş ve daha iyi sonuç

alınmıştır. Bundan başka yerel minimumların (YMİN)'nin genlik değerleri ve ortaya çıkış zamanları birlikte göz önüne alınarak eğri uydurma ile öznelik çıkartma denenmiştir. Bu denemede gayet iyi sonuçlar vermiştir. Şekil 2.20'de Eğitim ve Test verilerinde YMAK'ların ortaya çıkış zamanlarının birlikte değerlendirilmesi ile elde edilen 2. dereceden a katsayısı ve polinomun tepe değeri birlikte gösterilmiştir. Şekil 2.21'de ise Eğitim ve Test verilerinde YMİN'lerin ortaya çıkış zamanları ile birlikte değerlendirilmesi ile elde edilen 2. dereceden polinoma ait a katsayısı ve polinomun tepe değeri birlikte gösterilmiştir.

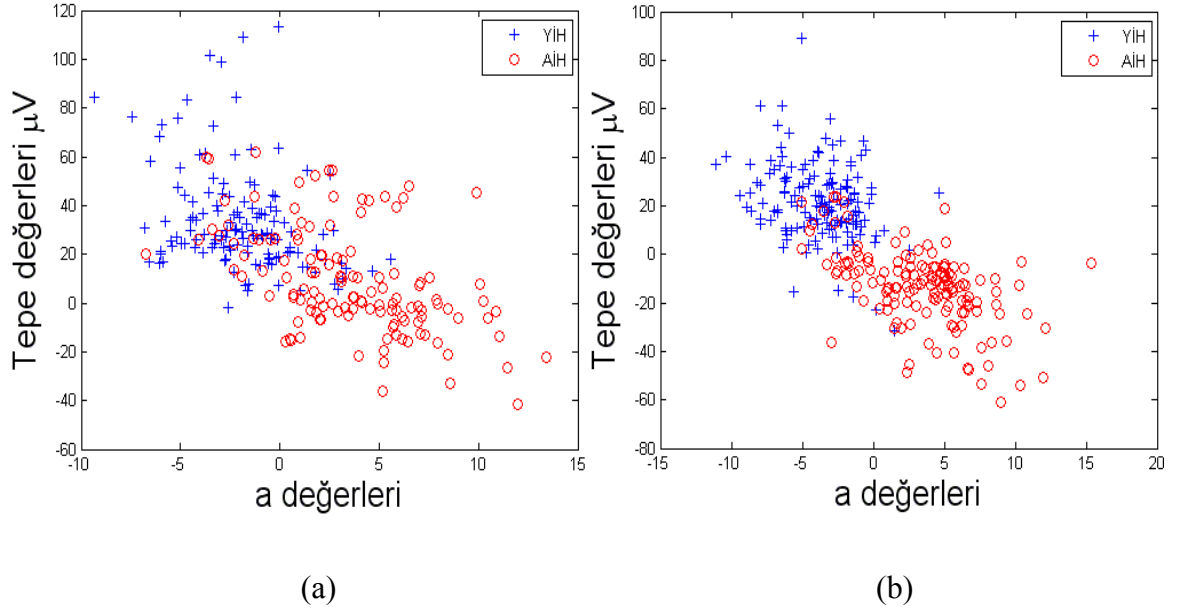


(a)



(b)

Şekil 2.20. YMAK'ların ortaya çıkış zamanlarının birlikte değerlendirilmesi ile elde edilen 2. dereceden polinoma ait öznelikler, (a) Eğitim verileri, (b) Test verileri




Şekil 2.21. YMİN'lerin ortaya çıkış zamanlarının birlikte değerlendirilmesi ile elde edilen 2. dereceden polinoma ait öznitelikler, (a) Eğitim verileri, (b) Test verileri

1. elektrota göre elde edilen özniteliklere dayalı sınıflandırma sonuçları Tablo 6'da gösterilmiştir.

Tablo 6. YMAK+zaman ve YMİN+zaman sınıflandırma sonuçları


Sınıflandırma	YMAK+Zaman	YMİN+Zaman
	% Doğruluk	% doğruluk
	Öznitelik:a+TN	Öznitelik:a+TN
DVM	91,47	92,15
KNN	90,44	93,52

YMAK ve YMİN'lerin ortaya çıkış zamanlarına göre eğri uydurma işleminde,uydurulan polinomdan çıkarılan bir başka öznitelikte eğrilerin eğimlerinin YIH ve AIH için farklılık göstermesidir. $f(x) = ax^2 + bx + c$ denkleminde b katsayıları denklemin eğimini belirtmektedir. Şekil 2.22'de 1. Elektrotlarda YMAK'lar dikkate alınarak uydurulmuş eğrilerin tüm denemelere ait b katsayıları gösterilmiştir.



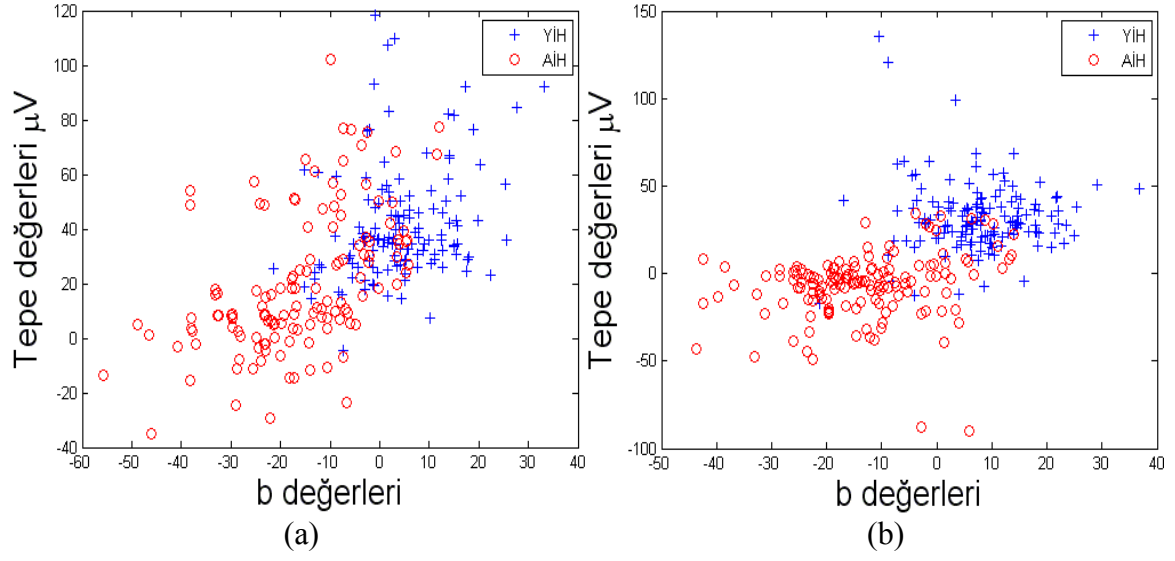
Şekil 2.22. YMAK'lara göre b katsayıları, (a) Eğitim verileri, (b) Test verileri

Şekil 2.23'de 1. Elektrotlarda YMİN'ler dikkate alınarak uydurulmuş eğrilerin, tüm denemelere ait b katsayıları gösterilmiştir.



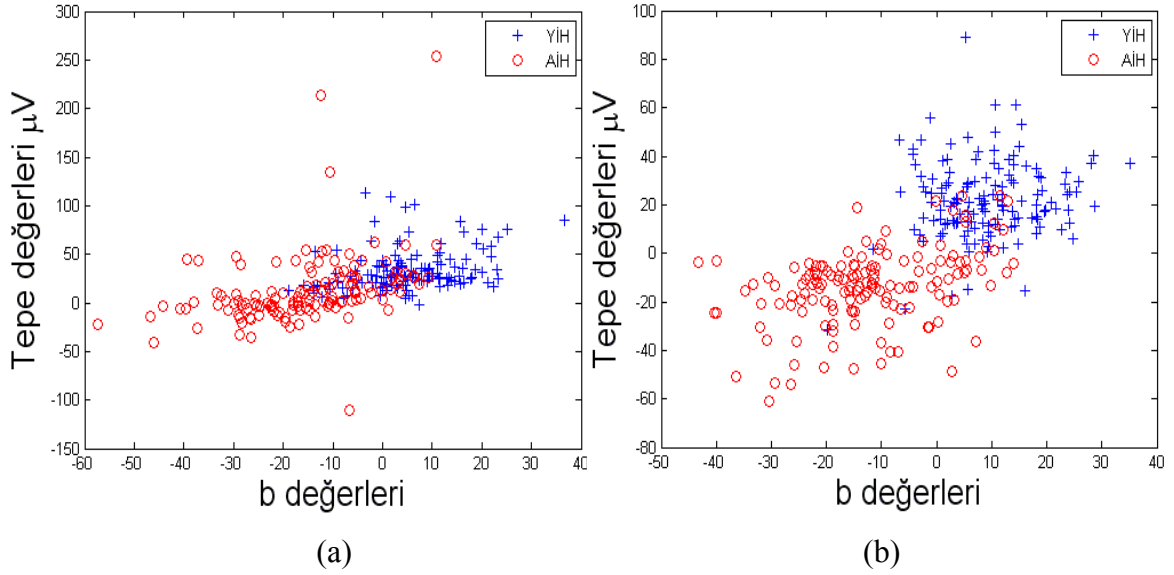
Şekil 2.23. YMİN'lere göre b katsayıları, (a) Eğitim verileri, (b) Test verileri

YMAK'lar dikkate alınarak uydurulan eğriye ait b katsayısı ile uydurulan eğrinin TN'leri Şekil 2.24'te verilmiştir. Çıkarılan bu özneteliğe dayalı sınıflandırma işlemi de oldukça iyi sonuç vermektedir. Burada kümelenmenin x-y ekseninin merkezine göre simetrik olması kullanılan iki özneteliğinde etkinliğini göstermektedir.



Şekil 2.24 YMAK'lara göre b katsayıları ve TN deęerleri, (a) Eęitim verileri, (b) Test verileri

YMİN'ler dikkate alınarak uydurulan eğriye ait b katsayısı ile uydurulan eğrinin TN'leri Şekil 2.25'te verilmiştir.



Şekil 2.25. YMİN'lere göre b katsayıları ve TN deęerleri, (a) Eęitim verileri, (b) Test verileri

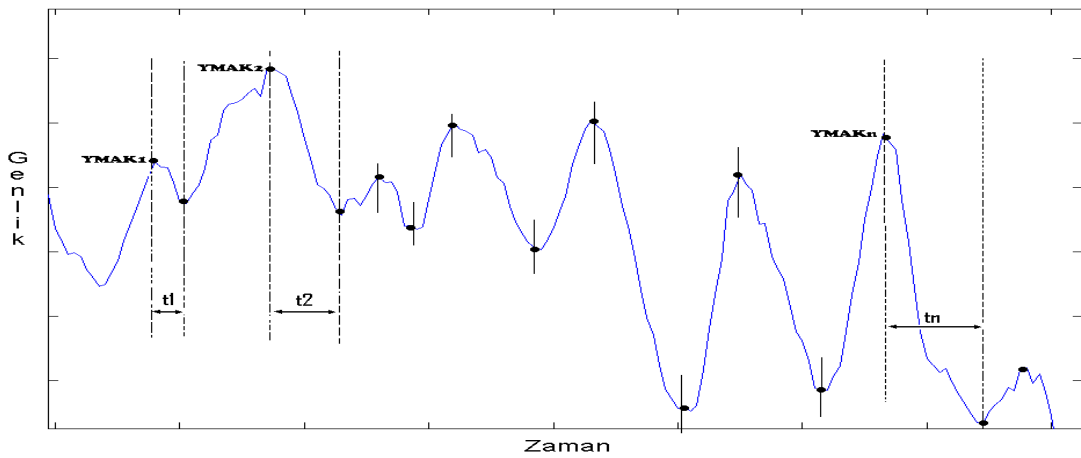
Göz önüne alınan öznelikler için elde edilen sonuçlar Tablo 7’de gösterilmiştir.

Tablo 7. b değeri ile TN’ye göre yapılan sınıflandırma sonuçları

Sınıflandırma	YMAK % Doğruluk	YMİN % Doğruluk
	Öznitelik: $b+TN$	Öznitelik: $b+TN$
DVM	90,78	91,47
KNN	90,10	93,52

2.3.5 Yerel Maksimumlardan Yerel Minimumlara ve Yerel Minimumlardan Yerel Maksimumlara Geçiş Zamanlarına Bağlı Öznelik Çıkarma

Yapılan her bir denemeye ait işaretlerin 1. Elektrotlarında YMAK’ların ne kadar süre içerisinde YMİN’e geçiş yaptığı göz önüne alınarak öznelik çıkarma incelenmiştir. Şekil 2.26’da örnek işaretteki YMAK’tan YMİN’e geçiş zamanları gösterilmiştir. Bir denemede YMAK’ın YMİN’e geçiş süresine bölünmesi ile elde edilen dizinin ortalaması alınarak YİH ve AİH’den öznelikler hesaplanmış ve sınıflandırmada bu öznelikler dikkate alınmıştır.



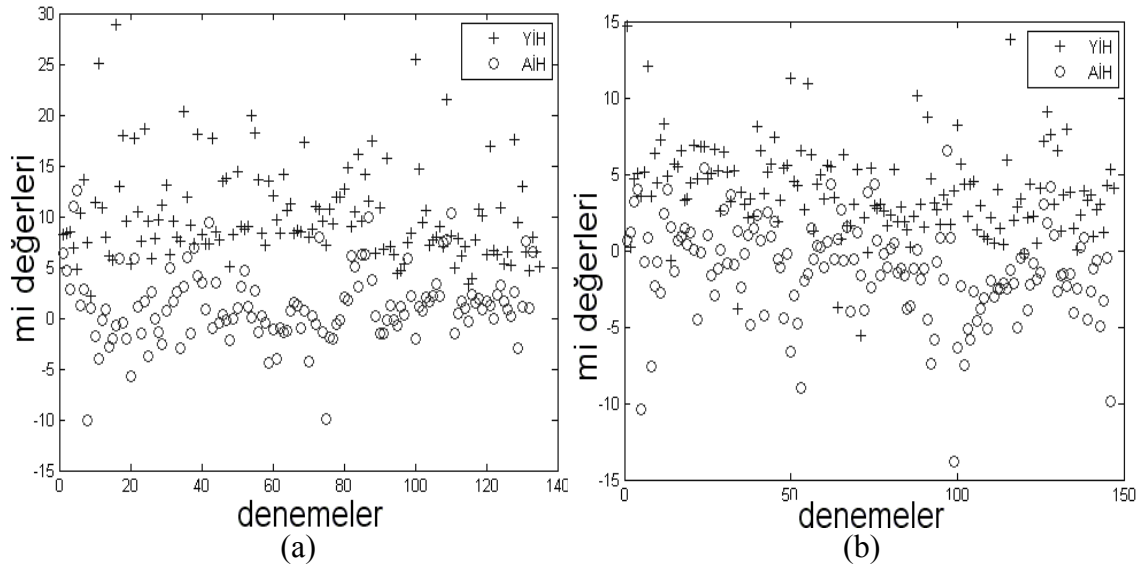
Şekil 2.26. YMAK’tan YMİN’e geçiş zamanlarının gösterimi

Denklem 82’de her bir deneme için YMAK’tan YMİN’e geçiş zamanlarına oranlarının ortalamasının nasıl hesaplandığı belirtilmiştir.

$$m_i = \frac{\sum_{k=1}^n \frac{YMAK_k}{t_k}}{n} \quad (82)$$

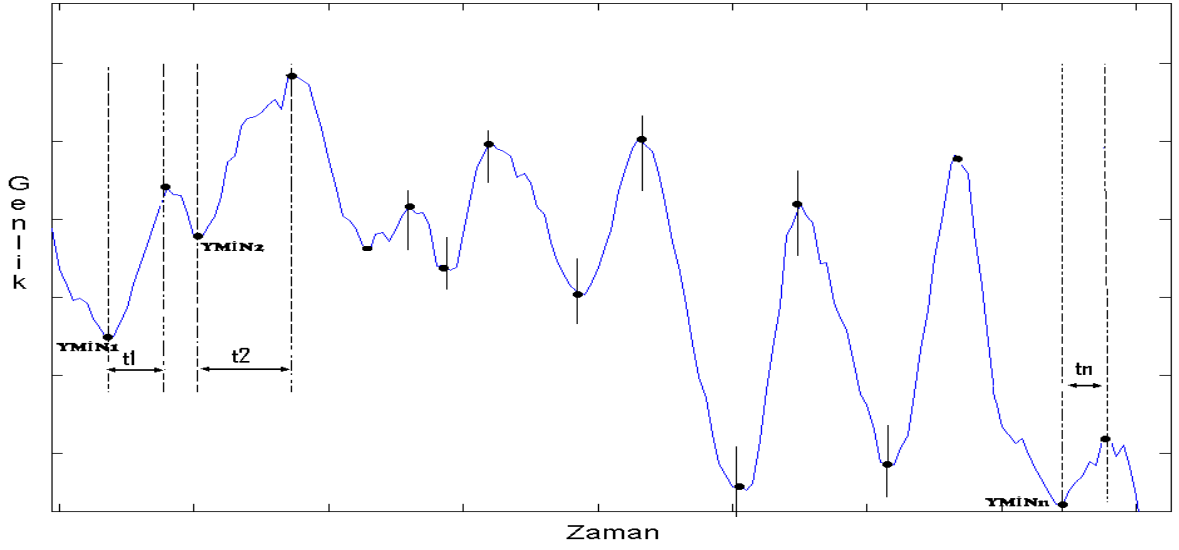
Burada n ; denemeye ait toplam YMAK sayısını, $YMAK_k$; k. YMAK değerini, t_k ; $YMAK_k$ ’tan sonra gelen YMİN’e geçiş süresini, m_i ; i. denemeye ait ortalama değeri belirtmektedir.

Şekil 2.27’de eğitim ve test verilerinin 1. elektrotları için YİH ve AİH’nin her bir denemesinden hesaplanan m_i değerleri gösterilmiştir.



Şekil 2.27 m_i değerleri (a) Eğitim verileri, (b) Test verileri

Yapılan her bir denemeye ait işaretlerin 1. Elektrotlarında YMİN’lerin ne kadar süre içerisinde YMAK’a geçiş yaptığı göz önüne alınarak öznelik çıkarma incelenmiştir. Şekil 2.28’de örnek işarettaki YMİN’den YMAK’a geçiş zamanları gösterilmiştir. Bir denemede YMİN’in YMAK’a geçiş süresine bölünmesi ile elde edilen dizinin ortalaması alınarak YİH ve AİH’nin sınıflandırılması yapılmıştır.



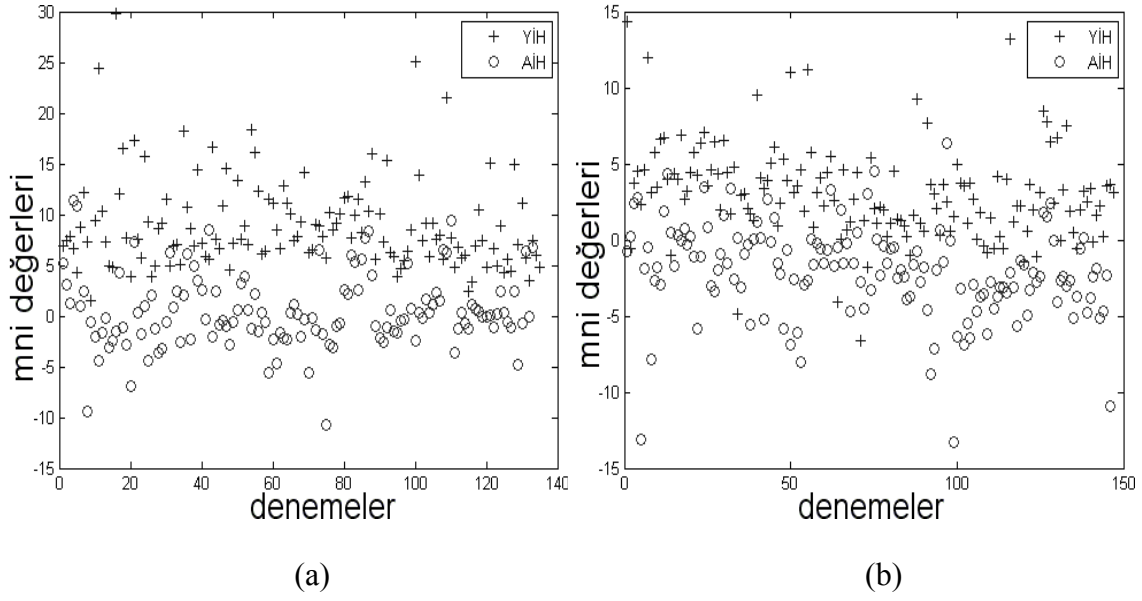
Şekil 2.28. YMİN'den YMAK'a geçiş zamanlarının gösterimi

Denklem 83'te her bir deneme için YMİN'den YMAK'a geçiş zamanlarına oranlarının ortalamasının nasıl hesaplandığı belirtilmiştir.

$$mn_i = \frac{\sum_{k=1}^n \frac{YMIN_k}{t_k}}{n} \quad (83)$$

Burada n ; denemeye ait toplam YMİN sayısını, $YMIN_k$; k. YMİN değerini, t_k ; $YMIN_k$ dan sonra gelen YMİN'e geçiş süresini, mn_i ; i. denemeye ait ortalama değeri belirtmektedir.

Şekil 2.29'da eğitim ve test verilerinin 1. elektrotları için YİH ve AİH'nin her bir denemesinden hesaplanan mn_i değerleri gösterilmiştir.



Şekil 2.29 mn_i değerleri (a) Eğitim verileri, (b) Test verileri

Çıkarılan bu öznitelikler dikkate alınarak yapılan sınıflandırma sonuçları Tablo 8’de verilmiştir.

Tablo 8. m_i ve mn_i ’ye göre yapılan sınıflandırma sonuçları

Sınıflandırma	Öznitelik: $m_i + mn_i$ % Doğruluk
DVM	87,58
KNN	84,30

3. TARTIŞMA VE SONUÇLAR

EEG işaretleri yapısı gereği sürekli deęişim gösteren oldukça kompleks işaretler olduğundan sağlıklı yorumlanmaları matematiksel yöntemlerle analizlerine baęlıdır. Çok miktarda bilgi içerdikleri gün geçtikçe yapılan çalışmalarla ortaya çıkmakta olan EEG işaretleri, özellikle tıpta teşhis ve uygulanan tedavilerin başarımlarının izlenmesinde kullanıldığı gibi, insanoęlunun hayatına farklı teknolojilerle de gireceęi kesindir. EEG uygulamalı teknolojiye atılan adımlardan biri de BBA uygulamalarıdır. BBA’da kaydedilen EEG işaretlerinin yüksek doğrulukta ve hızda yorumlanması esastır. Bu tez çalışmasında BBA uygulamaları için kaydedilmiş EEG işaretleri üzerinde matematiksel analizler yapılmıştır.

EEG işaretlerinin YMAK’ları, YMİN’leri ile birlikte ham EEG işaretleri göz önüne alınarak 2. dereceden polinom uydurmak sureti öznelik çıkarma yoluna gidilmiştir. Bulunacak farklı öznelik sayısı arttıkça sınıflandırmadaki başarımda artacağı kaçınılmazdır. Bu bakımdan mümkün olduğunca farklı öznelikler çıkartılarak sınıflandırma yapılmaya çalışılmıştır. Elde edilen özneliklere dayalı yapılan %91.13’ten büyük sınıflandırma sonuçları, literatürde aynı verileri kullanarak elde edilen sonuçlardan daha iyidir [46,47,48]. BBA uygulamalarında sınıflandırma başarımının yanı sıra, BBA veri hızı da oldukça önemli bir parametredir. Önerilen yöntem hem sınıflandırma açısından hem de işaretin ait olduğu sınıfı belirlemek için geçen süre bakımından oldukça iyi sonuçlar vermektedir.

Önerilen yöntemler farklı BBA uygulamaları için kaydedilen EEG işaretleri için de uygulanabilir olduğundan faydalı olabilecek niteliktedir.

Çıkarılan özneliklere dayalı elde edilen tüm sınıflandırma sonuçları Tablo 9’da birlikte verilmiştir.

Tablo 9. Çıkarılan özniteliklere dayalı elde edilen tüm sınıflandırma sonuçları

Öznitelik	Sınıflandırma Sonucu (% Doğruluk)	
	DVM	KNN
PCA+ICA+Korelasyon	68	
YMAK için a+TN	90,78	90,44
YMİN için a+TN	89,42	92,15
Ham EEG için a+TN	90,44	89,76
Zamana bağlı YMAK için a+TN	91,47	90,44
Zamana bağlı YMİN için a+TN	92,15	93,52
Zamana bağlı YMAK için b+TN	90,78	90,10
Zamana bağlı YMİN için b+TN	91,47	93,52
$m_i + mn_i$	87,58	84,30

4. ÖNERİLER

Bu çalışmada BBA uygulamaları için farklı düşünsel ve görsel durumlarda kaydedilmiş EEG işaretlerinin sınıflandırılması üzerine çalışılmıştır. Ele alınan işaretin hangi sınıfa ait olduğuna karar verebilmek için öncelikle eğitim verileri üzerinde incelemeler yapılarak farklı sınıflara ait EEG işaretlerinden öznitelikler çıkartılmalıdır. Öznitelik çıkarma işlemi BBA uygulamalarının en temel ve en zor konusunu oluşturur. Çünkü kaydedilen EEG işaretleri düşünsel durumda oluşan nörolojik bilgileri içermesinin yanında göz kırpması etkisi, şebeke etkisi, ortam etkisi, biyolojik etkiler gibi gürültü olarak isimlendirebileceğimiz kaynakları (artifakt) da içerir. Bunlar gibi birçok artifakt içeren bir veri üzerinde matematiksel incelemeler yapmak oldukça zordur. Dolayısıyla bu artifaktları EEG işaretlerinden arındırmak, düşünsel durumda oluşan nörolojik veriyi elde etme veya işaretlerden öznitelik çıkarma açısından oldukça önemlidir.

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

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

5. KAYNAKLAR

1. Ersop, M. E., EEG İşaret Analiz Metodlarının Karşılaştırmalı Bir Çalışması, Yüksek lisans tezi, Uludağ Üniversitesi Fen Bilimleri Enstitüsü, 2003.
2. Berger H., Über das Elektrenkephalogramm des Menschen, Archives für Psychiatrie und Nervenkrankheiten, 87 (1929) 527-570.
3. Amyotrophic Lateral Sclerosis Fact Sheet, http://www.ninds.nih.gov/disorders/amyotrophiclateralsclerosis/detail_amyotrophiclateralsclerosis.htm, 19 Kasım 2007
4. Vidal, J. J., Toward Direct Brain-Computer Communication, Annual Review of Biophysics and Bioengineering, 2 (1973) 157-180.
5. Vidal, J.J., Real-time Detection of Brain Events in EEG, Special Issue on Biological Signal Processing and Analysis, 65, 5 (1977) 633-664.
6. Wolpaw, R. J., Birbaumer, N., McFarland, D.J., Pfurtscheller, G. ve Vaughan, T.M., Brain-Computer Interfaces for Communication and Control, Clinical Neurophysiology, 113 (2002) 767-791.
7. Weiskopf, N., Mathiak, K., Bock S.W., Scharnowski F., Veit R., Grodd W., Goebel, R. ve Birbaumer, N., Principles of a Brain-Computer Interface (BCI) Based on Real-Time Functional Magnetic Resonance Imaging (fMRI), IEEE Trans Biomedical Engineering , 51, 6 (2004) 966-970.
8. Kennedy, P.R., Kirby, M.T., Moore, M. M., King, B. ve Mallory A., Computer Control Using Human Intracortical Local Field Potentials, IEEE Trans Neural Syst. Rehabil. Eng., 12, 3 (2004) 339-344.
9. Middendorf, M., McMillan, G., Calhoun, G. ve Jones, K.S., Brain Computer Interfaces Based on Steady-State Visual Evoked Response, IEEE Trans. Rehabil. Eng., 8 (2000) 211-213.
10. BCI-Info Portal for Brain-Computer Interfaces, <http://www.bci-info.tugraz.at/Members/graimann/definitions/scp>, 24 Kasım 2007
11. Birbaumer, N., Kübler, A., Ghanayim, N., Hinterberger, T., Perelmouter, J., Kaiser, J., Iversen, I., Kotchoubey, B., Neumann, N. ve Flor, H., The Thought Translation Device (TTD) for Completely Paralyzed Patients, IEEE Trans. Rehabil. Eng., 8 (2000) 190-192 .
12. BCI-Info Portal for Brain-Computer Interfaces, <http://www.bci-info.tugraz.at/Members/graimann/definitions/P300>, 24 Kasım 2007

13. Donchin, E., Spencer, K.M. ve Wijesinghe, R., The Mental Prosthesis: Assessing The Speed of a P300-Based Brain Computer Interface, IEEE Trans. Rehabil. Eng., 8 (2000) 174-179.
14. McFarland, D.J., Miner, L.A., Vaughan, T.M. ve Wolpaw, J.R., Mu And Beta Rhythm Topographies During Motor Imagery and Actual Movement, Brain Topogr., 12, 3 (2000) 177-186.
15. Wolpaw, J.R. ve McFarland, D.J., Control of a Two-Dimensional Movement Signal by a Noninvasive Brain-Computer Interface in Humans, Proceedings of National Academy of Sciences, 101, 51 (2004) 17849-17854.
16. Kennedy, P.R., The Cone Electrode: a Long-Term Electrode That Records from Neurites Grown onto Its Recording Surface, J. Neurosci. Methods, 29, 3 (1989) 181-193.
17. Pfurtscheller, G. ve Lopes da Silva, F.H., Event-Related EEG/MEG Synchronization and Desynchronization: Basic Principles, Clinical Neurophysiology, 110 (1999) 1842-1857.
18. Pfurtscheller, G., Neuper, C., Guger, C., Harkam, W., Ramoser, H., Schlögl, A., Obermaier B. ve Pgegenzer, M., Current Trends in Graz Brain-Computer Interface (BCI) Research, IEEE Transactions On Rehabilitation Engineering, 8, 2 (2000) 216-219.
19. Guger, C., Schlögl, A., Neuper, C., Walterspacher, D., Strein, T. ve Pfurtscheller, G., Rapid Prototyping of an EEG-Based Brain-Computer Interface (BCI), IEEE Transactions On Neural Systems And Rehabilitation Engineering, 9, 1 (2001) 49-58.
20. Pfurtscheller, G., Müller, G. R., Pfurtscheller, J., Gerner, H. J. ve Rupp, R., 'Thought' – Control of Functional Electrical Stimulation to Restore Hand Grasp in a Patient with Tetraplegia, Neuroscience Letters, 351 (2003) 33–36.
21. Lauer, R.T., Peckham, P.G. ve Kilgore, K.L., EEG-Based Control of a Hand Grasp Neuroprosthesis, NeuroReport, 10 (1999) 1767–1771.
22. Spiegler, A., Graimann B. ve Pfurtscheller, G., Phase Coupling Between Different Motor Areas During Tongue-Movement Imagery, Neuroscience Letters, 369 (2004) 50–54.
23. Gernot R., Müller-Putz, Scherer, R., Pfurtscheller, G. ve Rupp, R., EEG-Based Neuroprosthesis Control: A Step Towards Clinical Practice, Neuroscience Letters, 382 (2005) 169–174.

24. Wolpaw, J. R., McFarland, D. J., Vaughan, T.M. ve Schalk, G., The Wadsworth Center Brain-Computer Interface (BCI) Research and Development Program, IEEE Transactions On Neural Systems And Rehabilitation Engineering, 11, 2 (2003) 204-207.
25. Schalk, G., McFarland, D. J., Hinterberger, T., Birbaumer, N. ve Wolpaw, J. R., BCI2000: A General-Purpose Brain-Computer Interface (BCI) System, IEEE Transactions On Biomedical Engineering, 51, 6 (2004) 1034-1043.
26. McFarland, D. J. ve Wolpaw, J. R, Sensorimotor Rhythm-Based Brain-Computer Interface (BCI): Feature Selection by Regression Improves Performance, IEEE Transactions On Neural Systems And Rehabilitation Engineering, 13, 3 (2005) 372-379.
27. Guger, C., Schlögl, A., Neuper, C., Walterspacher, D., Strein, T. ve Pfurtscheller, G., Rapid Prototyping of an EEG-Based Brain-Computer Interface (BCI), IEEE Transactions On Neural Systems And Rehabilitation Engineering, 9, 1 (2001) 49-58.
28. Obermaier, B., Müller, G. R. ve Pfurtschelle, G., Virtual Keyboard Controlled by Spontaneous EEG Activity IEEE Transactions On Neural Systems And Rehabilitation, 11, 4 (2003) 422-426.
29. Ramoser, H., Müller-Gerking, J. ve Pfurtscheller, Gert., Optimal Spatial Filtering of Single Trial EEG During Imagined Hand Movement, IEEE Transactions On Rehabilitation Engineering, 8, 4 (2000) 441-446.
30. Pfurtscheller, G., Neuper, C., Schloegl, A. ve Lugger, K., Separability of EEG Signals Recorded During Right and Left Motor Imagery Using Adaptive autoregressive Parameters, IEEE Trans. Rehab. Eng., 6 (1998) 316-325.
31. Haselsteiner, E. ve Pfurtscheller, G., Using Time Dependent Neural Networks for EEG Classification, IEEE Trans. Rehab. Eng., 6 (2000) 457-463.
32. Haykin, S., NewYork: Macmillan, Neural Networks: A Comprehensive Foundation, 1994.
33. Müller-Gerking, J., Pfurtscheller, G. ve Flyvbjerg, H., Designing Optimal Spatial Filters for Single-Trial EEG Classification in a Movement Task, Electroenc. Clin. Neurophys., 110, 5 (1999) 787-798.
34. Lemm, S., Blankertz, B., Curio G. ve Müller, K. R., Spatio-Spectral Filters for Improving the Classification of Single Trial EEG, IEEE Transactions On Biomedical Engineering, 52, 9 (2005) 1541-1548.
35. Qin, L., Ding L. ve He, B., Motor Imagery Classification by Means of Source Analysis for Brain-Computer Interface Applications, Journal Of Neural Engineering, 1 (2004) 135-141.

36. Kamousi, B., Liu, Z. ve He, B., An EEG Inverse Solution Based Brain-Computer Interface, IEEE Transactions On Rehabilitation Engineering, 7, 2 (2005) 1-3.
37. Ben Dayan Rubin, D. D., Baselli, G., Inbar, G. F. Cerutti, ve S., An Adaptive Neuro-Fuzzy Method (*ANFIS*) for Estimating Single-Trial Movement-Related Potentials, Biol. Cybern., 91 (2004) 63–75.
38. Zibulevsky, M. ve Zeevi, Y. Y., Extraction of a Source from Multichannel Data Using Sparse Decomposition, Neurocomputing, 49, 1 (2002) 163-173.
39. BCICompetition2005, http://ida.first.fraunhofer.de/projects/bci/competition_iii, 10 Aralık Kasım 2007
40. Chiappa, S. ve Barber, D., EEG Classification Using Generative Independent Component Analysis, Neurocomputing, 69, 7-9 (2006) 769-777.
41. Tavakolian, K., Nasrabadi, A.M. ve Rezaei, S., Selecting Better EEG Channels for Classification of Mental Tasks, Circuits and Systems,. ISCAS '04. Proceedings of the 2004 International Symposium, 3 (2004) 537-540.
42. Barros, A. K., Vigário, R., Jousmäki, V. ve Ohnishi, N., Extraction of Event-Related Signals from Multichannel Bioelectrical Measurements, IEEE Transactions On Biomedical Engineering, 47, 5 (2000) 583-588.
43. Jahankhani, P., Revett K. ve Kodogiannis, V., Data Mining an EEG Dataset With an Emphasis on Dimensionality Reduction, Proceedings of the 2007 IEEE Symposium on Computational Intelligence and Data Mining, (2007) 405-412.
44. Birbaumer, N., Flor, H., Ghanayim, N., Hinterberger, T., Iverson, I., Taub, E., Kotchoubey, B., Kübler, A. ve Perelmouter, J, A Brain-Controlled Spelling Device for the Completely Paralyzed, *Nature*, 398 (1999) 297-298.
45. BCI Competition2003, http://ida.first.fraunhofer.de/projects/bci/competition_ii, 10 Aralık 2007
46. BCICompetitionResults, http://ida.first.fraunhofer.de/projects/bci/competition_ii/results/index.html#tuebingen1, 12 Aralık 2007
47. Mensh, B. D., Werfel, J. ve Seung, H. S., BCI Competition 2003—Data Set Ia: Combining Gamma-Band Power With Slow Cortical Potentials to Improve Single-Trial Classification of Electroencephalographic Signals , IEEE Trans. Biomed. Eng., 51, 6 (2004) 1052-1056.
48. Wang, B., Jun, L., Bai, J., Peng, L., Li, Y. ve Li, G., EEG Recognition Based on Multiple Types of Information by Using Wavelet Packet Transform and Neural Networks, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference Shanghai, China, 2005, 5377-5380.

49. Blankertz, B., Curio G. ve Müller, K. R., Classifying Single Trial EEG: Towards Brain Computer Interfacing, Advances in Neural Inf. Proc. Systems, 14 (2002) 157-164.
50. Garrett, D., Peterson, D. A., Anderson, C. W. ve Thaut, M. H., Comparison of Linear, Nonlinear, and Feature Selection Methods for EEG Signal Classification, IEEE Transactions On Neural Systems And Rehabilitation Engineering, 11, 2 (2003) 141-144.
51. Xu, W., Guan, C., Siong, C.E., Ranganatha, S., Thulasidas, M. ve Wu, J., High Accuracy Classification of EEG Signal, Pattern Recognition, 2 (2004) 391-394.
52. Stastny, J. ve Sovka, P., High-Resolution Movement EEG Classification, Computational Intelligence and Neuroscience, 54925 (2007) 1155-1166.
53. Li, Y., Dong, G., Gao, X., Gao, S., Ge, M. ve Yan, W., Single Trial EEG Classification During Finger Movement Task by Using Hidden Markov Models, proceedings of the 2nd International IEEE EMBS Conference on Neural Engineering Arlington, Virginia, March 16 - 19, 2005.
54. Doroshenkov, L. G., Konyshchev, V. A. ve Selishchev, S. V., Classification of Human Sleep Stages Based on EEG Processing Using Hidden Markov Models, Biomedical Engineering, 41, 1 (2007) 25-28.
55. Sun, S., Zhang, C. ve Lu, Y., The Random Electrode Selection Ensemble for EEG Signal Classification, Pattern Recognition , 41, 5 (2008) 1663-1675.
56. Zhou, S. M., Gan, J. Q. ve Sepulveda, F., Classifying Mental Tasks Based on Features of Higher-Order Statistics from EEG Signals in Brain-Computer Interface, Information Sciences, 178 (2008) 1629-1640.
57. Citi, L., Poli, R. ve Cinel, C., P300-Based BCI Mouse With Genetically-Optimized Analogue Control, IEEE Transactions On Neural Systems And Rehabilitation Engineering, 16, 1 (2008) 51-61.
58. Lehtonen, J., Jylanki, P., Kauhanen, L. ve Sams, M., Online Classification of Single EEG Trials During Finger Movements, IEEE Transactions on Biomedical Engineering, 55, 2 (2008) 713– 720.
59. Allison, B. Z., McFarland, D. J. ve Schalk, G., Towards an Independent Brain-Computer Interface Using Steady State Visual Evoked Potentials, Clinical Neurophysiology, 119 (2008) 399-408.
60. Schalk, G., Brunner, P. ve Gerhardt, L. A., Brain-Computer Interfaces (BCIs): Detection Instead of Classification, Journal Of Neuroscience Methods, 167 (2008) 51-62.

61. Nijboer, F., Furdea, A. ve Gunst, I., An Auditory Brain-Computer Interface (BCI), Journal Of Neuroscience Methods, 167 (2008) 43-50.
62. Bai, O., Lin, P. ve Vorbach, S., Exploration of Computational Methods for Classification of Movement Intention During Human Voluntary Movement from Single Trial EEG, Clinical Neurophysiology, 118 (2007) 2637-2655.
63. Blankertz, B., Mueller, K. R., Curio, G., Vaughan, T. M., Schalk, G., Wolpaw, J. R., Schloegl, A., Neuper, C., Pfurtscheller, G., Hinterberger, T., Schroeder, M. ve Birbaumer, N., The BCI Competition 2003, IEEE Trans. Biomed. Eng., 51 (2004) 1044–1051.
64. Jackson, J.,E. : A User's Guide To Principal Components, John Wiley&Sons Inc., Canada, 1991.
65. Richards, J.,A. : Remote Sensing Digital Image Analysis, Springer-Verlag, Germany, 1993.
66. Hyvarinen, A., Karhunen J. ve Oja, E., Independent Component Analysis, John Wiley and Sons. Inc., 2001.
67. Hyvarinen, A., Survey on Independent Component Analysis, Neural Comp. Surveys, (1999).
68. Hyvarinen, A. ve Oja, E., Independent Component Analysis: Algorithms and Applications, Neural Networks, (2000).
69. Uzun, İ. Mühendislikte Nümerik Çözüm Yöntemleri: Nümerik Analiz, 2000.
70. Vapnik , V., Statistical Learning Theory, Wiley, 1998.
71. Burges, J.C., A Tutorial on Support Vector Machines for Pattern Recognition, Data Mining and Knowledge Discovery, 2 (1998) 121-167.
72. Pontil, M. ve Verri, A., Support Vector Machines for 3D Object Recognition, IEEE Trans. on Pattern Analysis and Machine Intelligence, 20, 6 (1998) 637-646.
73. Cristianini, N., Taylor, J. S., An Introduction to Support Vector Machines and Other Kernel-based Learning Methods, Cambridge Univ. Press 2000.
74. Yıldırım, S., Destek Arıza Teşhisinde Destek Vektör Makinelerinin Kullanımı, Yüksek Lisans Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, 2006.

ÖZGEÇMİŞ

13.04.1982 tarihinde Trabzon'da doğdu. Liseyi Trabzon Affan Kitapçiođlu Lisesi'nde tamamladı. 2000 yılında Karadeniz Teknik Üniversitesi, Mühendislik Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliđi Bölümü'nü kazandı. Bu öğrenimi sırasında KTÜ İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü'nde Yandal eğitimini ayrıca tamamladı ve yine öğrenimi süresince, 2002/2005 yılları arasında, KTÜ Bilimsel Araştırma Projeleri Biriminde (BAP) kısmi zamanlı öğrenci statüsünde çalıştı. 2005 yılı güz döneminde Elektrik Elektronik Mühendisliđi Anabilim Dalı'nda yüksek lisans eğitimine başladı. Kasım 2005'te Elektrik-Elektronik Mühendisliđi Bölümü'nde Araştırma Görevlisi olarak göreve başladı. 2006-2007 Eğitim Öğretim Dönemi'nde Erasmus programı ile Viyana Teknik Üniversitesi'ne yüksek lisans çalışması yapmak üzere gitti (*Vienna University of Technology, Institut für Computergraphik und Algorithmen Vienna-Austria*). Yabancı dil olarak İngilizce ve Almanca bilmektedir.