



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



GÖRSEL UYARAN POTANSİYEL TABANLI BEYİN
BİLGİSAYAR ARAYÜZÜ TASARIMI

VOLKAN ÇETİN

DOKTORA TEZİ

Elektronik-Bilgisayar Eğitimi Anabilim Dalı

Elektronik-Haberleşme Programı

DANIŞMAN

Prof. Dr. H. Selçuk VAROL

EŞ-DANIŞMAN

Prof. Dr. Serhat ÖZEKES

İSTANBUL, 2020



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



GÖRSEL UYARAN POTANSİYEL TABANLI BEYİN
BİLGİSAYAR ARAYÜZÜ TASARIMI

VOLKAN ÇETİN
(722210001)

DOKTORA TEZİ

Elektronik-Bilgisayar Eğitimi Anabilim Dalı

Elektronik-Haberleşme Programı

DANIŞMAN

Prof. Dr. H. Selçuk VAROL

EŞ-DANIŞMAN

Prof. Dr. Serhat ÖZEKES

İSTANBUL, 2020

TEŞEKKÜR

Tez çalışmalarım süresince bilgi ve tecrübeleriyle bana destek olan ve yol gösteren tez danışmanlarım Sayın Prof. Dr. H. Selçuk VAROL'a ve Sayın Prof. Dr. Serhat ÖZEKES'e ve maddi desteklerinden dolayı Marmara Üniversitesi Bilimsel Araştırmalar Komisyonu'na teşekkürlerimi sunarım.



İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER.....	ii
ÖZET	v
ABSTRACT	vii
YENİLİK BEYANI	ix
SEMBOLLER.....	x
KISALTMALAR.....	xi
ŞEKİL LİSTESİ	xiii
TABLO LİSTESİ.....	xvi
1. GİRİŞ.....	1
1.1 Tarihçe	4
1.2 Tezin Önemi ve Amacı	10
2. BEYNİN ORGANİZASYONU VE OSİLASYONLARI	13
2.1 Beyin-Bilgisayar Arayüzü Çalışmaları Odağındaki Beyin Bölgeleri.....	13
2.2 Aksiyon Potansiyel	14
2.3 Beyin Osilasyonları.....	17
2.4 Beyin-Bilgisayar Arayüzü Çeşitleri.....	19
2.4.1 Dış Kaynaklı ve İç Kaynaklı Beyin Bilgisayar Arayüzleri.....	19
2.4.2 Senkron ve Asenkron Beyin Bilgisayar Arayüzleri	20
3. SİNYAL İŞLEME	21
3.1 Analog Dijital Çevirici.....	21
3.2 Fourier Dönüşümü	24
3.2.1 Sürekli-Zamanlı Periyodik Sinyallerin Karmaşık Üstel Fourier Serileri.....	24

3.2.2 Sürekli-Zamanlı Aperiodyik Sinyallerin Fourier Dönüşümü	25
3.2.3 Ayrik-Zamanlı Sinyallerin Fourier Dönüşümü	27
3.2.4 Hızlı Fourier Dönüşümü	29
3.3 Doğrusal Zamanda Değişimsiz Sistemler	29
3.4 Dijital Filtreleme	31
3.4.1 Zaman Alanı Parametreleri	32
3.4.2 Frekans Alanı Parametreleri	34
3.5 Dijital Filtre Tasarım Yöntemleri	36
3.5.1 Konvolüsyon Yöntemi ile Filtreleme	36
3.5.2 Özyineleme Yöntemi ile Filtreleme	37
3.6 Beyin Bilgisayar Arayüzü Uygulamalarında Filtreleme	38
4. SINIFLANDIRMA	41
4.1 Sınıflandırıcı Seçimi	42
4.1.1 Özellik Seçimi	44
4.1.2 Bias - Varyans İkilemi	44
4.2 Yapay Sinir Ağları	45
4.2.1 Perceptron	45
4.2.2 Yapay Sinir Ağı Modelleri ve Eğitimi	48
4.2.3 Geri Yayılım Algoritması	49
4.3 Destek Vektör Makineleri	51
4.3.1 Doğrusal Olarak Ayrılabilen Sınıflandırma Durumu	52
4.3.2 Doğrusal Olarak Ayrılamayan Sınıflandırma Durumu	54
4.3.3 Çok Sınıflı Destek Vektör Makineleri	56
4.4 k-Parçalı Çapraz Doğrulama Yöntemi	57
5. DENEYLER VE BULGULAR	59

5.1 Emotiv Nöro-Başlık.....	59
5.2 Elektroensefalogram Kaydı	65
5.3 Görsel Uyarılar.....	68
5.4 Elektroensefalogram Analizi	75
5.4.1 Kanal Seçimi ve Ön İşlemler	76
5.4.2 Dijital Filtre Karakteristikleri.....	77
5.5 Özellik Çıkarma.....	84
5.6 Bulgular	84
5.6.1 Dijital Filtrelemenin Beyin-Bilgisayar Arayüzü Tasarımlarının	
Sınıflandırma Performansına Etkisi	85
5.6.2 Kararlı-Durum Görsel Uyarı Potansiyellerin Sınıflandırılmasında	
Harmoniklerin Sınıflandırmaya Etkisi	88
5.6.3 Sınıflandırmada Yapay Sinir Ağı ve Destek Vektör Makinesi	
Algoritmalarının Performanslarının Karşılaştırılması.....	92
5.6.4 Uyarıların Örtüşen Harmonik Frekanslarının Sınıflandırma	
Performansına Etkisi	94
6. SONUÇLAR VE DEĞERLENDİRME	97
KAYNAKLAR.....	103

ÖZET

GÖRSEL UYARAN POTANSİYEL TABANLI BEYİN BİLGİSAYAR ARAYÜZÜ TASARIMI

Beyin işlevlerinin temelini oluşturan nöronlar, birbirleriyle iyonik akımlar yoluyla haberleşmektedir. Bu haberleşme sonucunda oluşan elektriksel aktivite elektroensefalografi adı verilen yöntemle kaydedilmektedir. Beyinde oluşan elektriksel aktivitenin, bilişsel veya motor faaliyetlerle ilişkisinin bilinmesi durumunda bir beyin-bilgisayar arayüzü tasarımı mümkün olmaktadır. Beyin-Bilgisayar Arayüzü, bir cihazı kontrol etmek veya cihaz ile kullanıcı arasındaki haberleşmeyi sağlamak amacıyla beyin sinyallerini kullanan arayüz olarak tanımlanmaktadır. Beyin-bilgisayar arayüzleri, kullanılan elektrofizyolojik kaynağa göre kategorilendirilmektedir. Bu tez çalışmasında faydalanan elektrofizyolojik kaynak, oksipital lobda görülen ve görsel uyaran potansiyel olarak adlandırılan elektriksel aktivitedir.

Bu tez çalışmasında, beynin oksipital lobundan elde edilen görsel uyaran potansiyeller yoluyla, standart bilgisayar donanımları üzerinde çalışan bilgisayar programlarının kullanımı araştırılmıştır. Bu amaçla deneklerden elde edilen elektroensefalogramlar analiz edilerek, beyin-bilgisayar arayüzü uygulamasının farklı koşullar altındaki sınıflandırma performansları karşılaştırılmıştır. Elektroensefalogram analizi genel olarak dijital sinyal işleme, özellik çıkarma ve sınıflandırma aşamalarından oluşmaktadır. Dijital sinyal işleme aşamasında, sinyallere uygulanan yüksek geçiren ve alçak geçiren filtrelerin, sınıflandırma performansına etkileri araştırılmıştır. Bu araştırma sonucunda, sadece yüksek geçiren filtreleme uygulanan ve yüksek ve alçak geçiren filtrelemenin birlikte uygulandığı tasarımların sınıflandırma performanslarında önemli bir değişim gözlemlenmemiştir. Buna ek olarak, sadece yüksek geçiren filtreleme uygulanan tasarımların daha iyi sınıflandırma performansı gösterdiği durumlar gözlemlenmiştir. Görsel uyaran potansiyel temelli beyin-bilgisayar arayüzü tasarımlarında, sinyallerin spektral özellikleri kullanılmaktadır. Görsel uyaran potansiyeller uyaran frekansın tamsayı katlarındaki harmoniklerinden oluşmaktadır. Bu tez çalışmasında uyaran frekansların ilk dört harmoniğinin çeşitli kombinasyonlarından çıkarılan spektral özelliklerle yapılan sınıflandırma performansları karşılaştırılmıştır.

Sonu olarak grsel uyaran potansiyellerin bir, iki ve drt numaralı harmoniklerinin spektral zellikleri ile gerekleřtirilen sınıflandırmanın, diğerk harmonik kombinasyonlarından ıkarılan zelliklerle gerekleřtirilen sınıflandırmalara gre daha başarılı sonuçlar verdiđi grlmřtr. Bunlara ek olarak, zaman penceresi uzunluğunun, uyaranların rtřen harmonik frekanslarının ve farklı sınıflandırma algoritmalarının beyin-bilgisayar arayz uygulamalarının performansına etkisi arařtırılarak, elde edilen bulgular paylařılmıřtır.



ABSTRACT

A VISUAL EVOKED POTENTIAL BASED BRAIN COMPUTER INTERFACE

The neurons that form the basis of brain functions, communicate with each other through ionic currents. The electrical activity that occurs as a result of this communication is recorded by a method called electroencephalography. A brain-computer interface design is possible if the electrical activity in the brain is known to be related to cognitive or motor activities. Brain-computer interface is defined as the interface that uses brain signals to control a device or to communicate between the device and the user. Brain-computer interfaces are categorized according to the electrophysiological source used. The electrophysiological source used in this study is the electrical activity recorded from the occipital lobe and called visual evoked potentials.

In this study, the usability of computer programs running on standard computer hardware by using visual evoked potentials obtained from the occipital lobe of the brain was investigated. For this purpose, the electroencephalograms obtained from the subjects were analyzed and the classification performances of the brain-computer interface application under different conditions were compared. Electroencephalogram analysis generally consists of digital signal processing, feature extraction and classification stages. In the digital signal processing stage, the effects of the high pass and low pass filters applied to the signals on the classification performance are investigated. As a result of this research, no significant change in the classification performances of designs with only high pass filtering and high and low pass filtering has been observed. In addition, it has been observed that only the designs include a high-pass filtering implementation exhibit better classification performance in many cases. Visual evoked potential based brain-computer interface designs use the spectral properties of the signals for classification. Frequency spectrum of the visual evoked potentials consist of harmonics of integer multiples of the stimulus frequency. In this thesis, the classification performances were compared with the spectral properties extracted from various combinations of the first four harmonics of the stimulus frequencies. As a result, classification performed with features extracted from first,

second and fourth harmonics of the visual stimulus frequencies has been found to be more successful than classifications performed with features extracted from other harmonic combinations. In addition, the effects of time window length, overlapping harmonic frequencies of stimuli and different classification algorithms on the performance of brain-computer interface applications have been investigated.



July, 2020

Volkan ÇETİN

YENİLİK BEYANI

GÖRSEL UYARAN POTANSİYEL TABANLI BEYİN BİLGİSAYAR ARAYÜZÜ TASARIMI

Sinirsel bir aktivite sonucunda beyinde oluşan elektriksel dalgalanmaların, filtreleme nedeniyle elektroensefalogram üzerinde zamana yayılabildiği ve beyin aktivitelerinin dinamiği ve zamanlaması ile ilgili değerlendirmelerde problem yaratabildiği düşünülmektedir. Beyin-bilgisayar arayüzü literatüründe, filtrelemenin tasarımın performansına etkisinin araştırıldığı bir çalışmaya rastlanmamıştır. Bu tez çalışmasında, görsel uyaran potansiyellere filtreleme uygulanmayan, sadece yüksek geçiren filtreleme uygulanan, yüksek ve alçak geçiren filtrelemenin birlikte uygulandığı tasarımların sınıflandırma performansları karşılaştırılmıştır.

Görsel uyaran potansiyeller, beynin doğrusal olmayan doğası gereği, uyaran frekansların temel ve tamsayı katlarındaki harmoniklerinde açığa çıkmaktadır. Beyin-bilgisayar arayüzü tasarımlarında, görsel uyaran potansiyellerin temel frekans ve harmoniklerinden çıkarılan spektral özellikler kullanılmaktadır. Beyin-bilgisayar arayüzü literatüründe, görsel uyaran potansiyellerin harmoniklerinin, tasarımın sınıflandırma performansına etkisinin gösterildiği bir çalışmaya rastlanmamıştır. Bu tez çalışmasında, görsel uyaran potansiyellerin ilk dört harmoniğinin farklı kombinasyonlarından elde edilen spektral özelliklerin çıkarıldığı farklı tasarımların sınıflandırma performansları karşılaştırılmıştır.

Bunlara ek olarak, bu tez çalışmasında görece düşük maliyetli bir nöro-başlık kullanılmıştır. Sonuç olarak, standart bir bilgisayar donanımı üzerinde çalışan bir programının, düşük maliyetli bir beyin-bilgisayar arayüzü tasarımı ile kullanılabileceği gösterilmiştir.

Temmuz, 2020

Prof. Dr. Serhat ÖZEKES

Prof. Dr. H. Selçuk VAROL

Volkan ÇETİN

SEMBOLLER

f_0	Temel frekans (Hertz)
f_c	Kesim frekansı (Hertz)
f_s	Örnekleme frekansı (Hertz)
$\text{Im}[]$	Faz spektrumu
$\text{Re}[]$	Genlik spektrumu
T_0	Temel periyot (1/s)
t_d	Filtreleme kaynaklı zaman gecikmesi
w_c	Kesim frekansı (Radyan)
w_s	Örnekleme frekansı (Radyan)
α	Beyinde 8 Hz - 13 Hz frekans aralığında görülen elektriksel aktivite
β	Beyinde 13 Hz - 30 Hz frekans aralığında görülen elektriksel aktivite
γ	Beyinde 35 Hz ve üzerindeki frekanslarda görülen elektriksel aktivite
δ	Beyinde 0.5 Hz - 4 Hz frekans aralığında görülen elektriksel aktivite
$\delta[]$	Kronecker Delta fonksiyonu
θ	Beyinde 4 Hz - 7 Hz frekans aralığında görülen elektriksel aktivite
μ	Sensorimotor kortekste görülen elektriksel aktivite

KISALTMALAR

ADC	Analog Digital Converter - Analog Dijital Çevirici
AGF	Alçak Geçiren Filtre
AP	Aksiyon Potansiyel
BBA	Beyin Bilgisayar Arayüzü
BDF	Bant Durduran Filtre
BGF	Bant Geçiren Filtre
BMA	Beyin Makine Arayüzü
BSS	Blind Source Separation
CSV	Comma Separated Values
DFT	Discrete Fourier Transform - Ayrık Fourier Dönüşümü
DVM	Destek Vektör Makinesi
ECOG	Electrocorticography - Elektrokortikografi
EDF	European Data Format
EEG	Electroencephalography - Elektroensefalografi
EOG	Electrooculography - Elektrookülografi
FFT	Fast Fourier Transform - Hızlı Fourier Dönüşümü
FIR	Finite Impulse Response - Sonlu Birim Darbe Cevabı
fMRI	Functional Magnetic Resonance Imaging - Fonksiyonel Manyetik Rezonans Görüntüleme
fNIRS	Functional Near Infrared Spectroscopy - Fonksiyonel Yakın Kızılötesi Spektroskopi
GDGUP	Geçici-Durum Görsel Uyarılmış Potansiyel
GUP	Görsel Uyarılmış Potansiyel
ICE	Intracortical Electrode - İntrakortikal Elektrot

IDFT	Inverse Discrete Fourier Transform - Ters Ayrık Fourier Dönüşümü
IFFT	Inverse Fast Fourier Transform - Ters Hızlı Fourier Dönüşümü
IIR	Infinite Impulse Response - Sonsuz Birim Darbe Cevabı
ISCEV	International Society for Clinical Electrophysiology of Vision
KA	Karar Ağacı
KDGUP	Kararlı-Durum Görsel Uyarılmış Potansiyel
kEYK	k En Yakın Komşuluk
KND	Koşullu Negatif Değişim
KTF	Kritik Titreşim Frekansı
LTI	Linear Time Invariant - Doğrusal Zamanda Değişimsiz
MEG	Magnetoencephalography - Manyetoensefalografi
OİP	Olay İlişkili Potansiyel
OKH	Ortalama Karesel Hata
SGY	Spektral Güç Yoğunluğu
SUP	Somatosensöriyel Uyarılmış Potansiyel
UP	Uyarılmış Potansiyel
YGF	Yüksek Geçiren Filtre
YKP	Yavaş Kortikal Potansiyel
YSA	Yapay Sinir Ağı

ŞEKİL LİSTESİ

Şekil 1.1	EEG Tabanlı bir BBA Uygulamasının Blok Diyagramı	4
Şekil 2.1	Beynin Dört Ana Bölümü ve M1, S1 ve V1'in Yeri.....	14
Şekil 2.2	Nöron ve Bağlantıları	15
Şekil 2.3	Aksiyon Potansiyelin Aşamaları	16
Şekil 2.4	BBA Uygulamalarında Beyin Potansiyellerinin Taksonomisi	19
Şekil 3.1	Analog Sinyalden Örnekleme ile Elde Edilen Değerler	22
Şekil 3.2	Analog Sinyalin 3 Bitlik Kuantalama Sonucu Aldığı Ayırık Değerler	23
Şekil 3.3	Aperiodyik $x(t)$ Sinyalinden, T_0 Periyotlu $x_p(t)$ Sinyalinin Elde Edilmesi.....	25
Şekil 3.4	İdeal AGF'nin Frekans Cevabı (a) Genlik Spektrumu (b) Faz Spektrumu..	32
Şekil 3.5	Adım Cevabı Parametreleri (a) Yavaş Yükselme Zamanı (b) Hızlı Yükselme Zamanı	33
Şekil 3.6	Adım Cevabı Parametreleri (a) Salınlımlı Adım Cevabı (b) Salınlımsız Adım Cevabı	33
Şekil 3.7	Adım Cevabı Parametreleri (a) Doğrusal Olmayan Adım Cevabı (b) Doğrusal Adım Cevabı	34
Şekil 3.8	Frekans Spektrumunun Bölgeleri	34
Şekil 3.9	Frekans Alanı Parametrelerinin Frekans Spektrumunda Gözlemlenen Etkileri (a) Salınlımlı Geçirme Bandı, (b) Salınlımsız Geçirme Bandı, (c) Düşük Zayıflatmalı Durdurma Bandı, (d) Yüksek Zayıflatmalı Durdurma Bandı	35
Şekil 3.10	Özyinelemeli Filtre ve Elektronik Filtre Karşılaştırması (a) Dijital Adım Fonksiyonu, (b) Özyinelemeli Filtrenin Adım Cevabı, (c) Analog Adım Fonksiyonu, (d) Elektronik Filtrenin Adım Cevabı	38

Şekil 4.1	Temel Yapay Sinir Ağı Ünitesi Perceptron	46
Şekil 4.2	Doğrusal Sınıflandırılabilen ve (b) Doğrusal Sınıflandırılmayan Veri Setlerinin Geometrik Gösterimi.....	47
Şekil 4.3	İki Katmanlı Perceptron ile Çözülen Bir Sınıflandırma Probleminin Geometrik Gösterimi, (a) Birinci Katman ve (b) İkinci Katman	47
Şekil 4.4	İki Katmanlı Bir Perceptron Ağının Yapısı	48
Şekil 4.5	Giriş Uzayını İkiye Ayıran Optimum Fonksiyon	51
Şekil 4.6	Marjini $2/\ w\ $ Yapan Optimal Hiper-düzlem	53
Şekil 4.7	Doğrusal Olarak Ayrılamayan Veri Seti.....	55
Şekil 4.8	$k=4$ için k -Katlı Çapraz Doğrulama Blok Şeması	57
Şekil 5.1	KDGUP Temelli BBA Çalışmasının Blok Diyagramı	60
Şekil 5.2	Sinyal Kalite Bilgisinin Doğrulanmasında Kullanılan TestBench Arayüzü.....	62
Şekil 5.3	10-20 Elektrot Yerleştirme Sistemi (a) Elektrot Konumları, (b) Nasion'un ve İnion'un Konumları	63
Şekil 5.4	10-20 ve 10-10 Elektrot Yerleştirme Sistemlerinde Yer Alan Elektrot Pozisyonları ile Emotiv Nöro-başlık Üzerindeki Sabit Elektrot Pozisyonları	64
Şekil 5.5	Emotiv TestBench Programının Arayüzü ve Bir Kayıt Sırasında Görülen EEG Sinyalleri	66
Şekil 5.6	Doğru Ayarlanmayan Elektrotlar Nedeniyle EEG Kaydında Gözlemlenen Çevresel Gürültü.....	68
Şekil 5.7	KDGUP Tepkisinin Tetiklenmesi Amacıyla Geliştirilen Programın Arayüzü.....	69

Şekil 5.8	KDGUP Uyarıcı Tipleri (a) Açık-Kapalı Flaş, (b) Desen Flaş, (c) Zıt Desenler.....	69
Şekil 5.9	(a) Uyarıcı Sinyal ve (b) Beyinde Görülen Asimetrik Tepki	70
Şekil 5.10	(a) 11 Hz ve (b) 15 Hz Frekanslarında Titreşen Uyarılardan Oluşan Sekans	73
Şekil 5.11	Frekansı 4.6 Hz Olan Bir Uyarıcının Tetiklediği KDGUP Tepkisinin, Frekans Spektrumunda Görülen Birinci ve İkinci Harmonikleri	74
Şekil 5.12	Göz Kırpma Kaynaklı Gürültünün, Frontal ve Oksipital Kanallara Etkisi	79
Şekil 5.13	Sinyal İşleme Aşamasında Kullanılan Yüksek Geçiren Filtrenin Frekans ve Faz Spektrumu	79
Şekil 5.14	Sinyal İşleme Aşamasında Kullanılan Alçak Geçiren Filtrenin Frekans ve Faz Spektrumu	80
Şekil 5.15	Filtre Uzunluğunun Sinyaller Üzerindeki Kenar Etkisi	83
Şekil 5.16	2-saniye zaman pencereleri ile yapılan ikili sınıflandırmanın doğruluk yüzdeleri	89
Şekil 5.17	2-saniye zaman pencereleri ile yapılan üçlü sınıflandırmanın doğruluk yüzdeleri	90
Şekil 5.18	4-saniye zaman pencereleri ile yapılan ikili sınıflandırmanın doğruluk yüzdeleri	90
Şekil 5.19	4-saniye zaman pencereleri ile yapılan üçlü sınıflandırmanın doğruluk yüzdeleri	91

TABLO LİSTESİ

Tablo 1.1	Nöro-aktivite Kaydında Kullanılan Teknolojiler	3
Tablo 4.1	Sınıflandırıcıların Belirli Kriterlere Göre Performansları	43
Tablo 5.1	Emotiv Nöro-Başlığın Sinyal Kalitesi İçin Kullandığı Renk Kodları.....	61
Tablo 5.2	Uluslararası Elektrot Yerleştirme Sistemlerinde, Elektrotların İsimlendirilmesinde Kullanılan Harfler	63
Tablo 5.3	EEG Kayıtlarının İçeriği	65
Tablo 5.4	Ham EEG verisine karşılık gelen elektrot konumları	67
Tablo 5.5	Beyinden En İyi KDGUP Tepkisinin Elde Edildiği Kanallar	67
Tablo 5.6	KDGUP Tepkisinin Tetiklenmesinde Kullanılan Uyarıların Frekansları	74
Tablo 5.7	EEG Sinyallerinin Filtrelenmesinde Kullanılan YGF ve AGF Karakteristikleri.....	82
Tablo 5.8	Elektronik Filtrelemenin Etkisi: 2 ve 4 Saniyelik Zaman Pencereleri Kullanılan İki Farklı Analizin, 2, 3 ve 4 Görevli Sınıflandırma Doğrulukları	87
Tablo 5.9	YGF ile AGF Uygulanan ve Sadece YGF Uygulanan BBA Sistemlerinde, Sınıflandırma Performansları	88
Tablo 5.10	Deneyde Kullanılan Uyarıların Harmonik Frekansları	89
Tablo 5.11	KDGUP Harmonik Analizi Sonuçlarının Özeti	92
Tablo 5.12	DVM ve YSA Tabanlı KDGUP Sınıflandırma Sonuçları	93
Tablo 5.13	Örtüşen Harmonik Frekanslarının Sınıflandırma Performansına Etkisi ...	95
Tablo 6.1	İki Görevli Sınıflandırma Sonuçlarının Karışıklık Matrisleri	98
Tablo 6.2	Dört Görevli Sınıflandırma Sonuçlarının Karışıklık Matrisleri	99
Tablo 6.3	BBA Literatüründeki, KDGUP Temelli Tasarım Parametreleri.....	100

1. GİRİŞ

İnsan beyni, yaklaşık 1300 gram ağırlığında, süngerimsi yapıda, bilinen evrendeki yaşayan en karmaşık canlı yapıdır. Uzmanlıkları beyin ve sinir sistemi olan sinirbilimciler, geçen yıllar içinde beynin nasıl çalıştığı ve vücudu nasıl kontrol ettiği ile ilgili birçok çalışma yapmışlardır. Günümüzde bu çalışmalar sonucunda büyük aşamalar kaydedilmiştir. Örneğin, insan beyninde nöron adı verilen yaklaşık 100 milyar hücrenin bulunduğu ve beyin işlevlerinin temelini bu hücrelerin birbirleriyle haberleşmesinin oluşturduğu bilinmektedir [1].

Beyin Bilgisayar Arayüzü (BBA) teknolojisi ile ilgili araştırmalar bilim çevrelerinde genellikle ilgi görmemiştir. Beyin aktivitesinden insanların düşüncelerinin veya niyetlerinin anlaşılması fikri garip ve uzak bir fikir olarak düşünülmüştür. BBA tasarımı, beyindeki elektriksel aktivitenin ölçüm tekniklerinin ve elde edilen sinyallerin güvenilirliğinin yetersizliği gibi nedenlerden dolayı çok karmaşık bir problem olarak değerlendirilmiştir. Ancak her geçen yıl BBA tasarımı oldukça ilgi gören bir çalışma alanı haline gelmektedir. Dünya genelinde, yirmi yıl önce BBA çalışmaları yapan üç çalışma grubu ve on yıl önce sekiz çalışma grubu bulunmakta iken günümüzde BBA çalışma gruplarının sayısı yüzü geçmiştir [2]. Son on yılda insan beyni araştırmaları tüm dünyada ilgi gören ve desteklenen araştırmalardan olmuş ve sinirsel arayüz çalışmalarıyla ilgili makalelerin sayısı üstel olarak artmıştır [2]. Tüm bu gelişmelere ek olarak, Avrupa Birliği 2012 yılında İnsan Beyni Projesi adında, insan beynini anlama, beyin hastalıklarıyla mücadele etme ve yeni haberleşme teknolojileri geliştirilmesi amacıyla bir proje yürürlüğe koymuştur [3]. Amerika Birleşik Devletleri'nde, BRAIN (Brain Research through Advancing Innovative Neurotechnologies) adı verilen bir girişim başlatılmıştır [3]. Bu girişim uzun vadeli hedeflerini, beyin hastalıklarının daha iyi anlaşılması, daha iyi tedavi yöntemlerinin geliştirilmesi ve insanlar ile bilgisayarlar arasında daha iyi haberleşme teknolojileri kurulması olarak belirlemiştir.

Bu tezin konusu olan Beyin-Bilgisayar Arayüzü (BBA) teknolojisi, sistemler ile kullanıcıları arasında güçlü bir iletişim ve kontrol imkanı sağlayabilecek bir seçenektir [4]. BBA, tıbbi bakım amaçlı sistemlerin tasarımına odaklanmış durumdadır. Ancak son on yıldaki gelişmeler, BBA uygulamalarının, birçok teknolojik vizyonun parçası olabileceğini de göstermektedir [4]. Örneğin NASA (National Aeronautics and Space

Administration), pilotlarının uçuş sırasında daha atik ve dikkatli olmaları için eğitimlerinde, yıllardır nöro-geribesleme kullanmaktadır. Sony ile birlikte bu teknolojiyi, beyin sinyallerindeki belirli desenlere tepki verebilecek, özel bir Playstation kontrolörü geliştirmek için kullanmışlardır [5].

BBA, bir cihazı kontrol etmek veya cihaz ile kullanıcı arasındaki haberleşmeyi sağlamak amacıyla beyin sinyallerini kullanan arayüz olarak tanımlanır [4]. BBA teknolojisi için daha kapsamlı bir tanım, beyin tarafından üretilen zihinsel aktivitenin, çevresindeki sinir ve kaslara normal çıkış yollarından bağımsız olarak iletildiği bir haberleşme yöntemi olarak verilebilir [5]. Zihinsel aktivitenin ölçülmesi için çeşitli teknolojiler geliştirilmiştir. Bu teknolojiler, elektrokortikografi (Electrocorticogram, ECoG), intrakortikal elektrotlar (Intracortical Electrodes, ICE), fonksiyonel yakın kızılötesi spektroskopi (functional Near Infrared Spectroscopy, fNIRS), fonksiyonel manyetik rezonans görüntüleme (functional Magnetic Resonance Imaging, fMRI), manyetoensefalografi (Magnetoencephalography, MEG) ve elektroensefalografi (EEG) olarak listelenmektedir [4].

BBA araştırmalarında kullanılan teknolojiler iyi bir zamansal ve uzamsal çözünürlüğüne sahip olmalıdır. Zamansal çözünürlük, zihinsel aktivitenin üzerinden çok fazla zaman geçmeden sistem tarafından tespit edilebilmesi anlamına gelmektedir. Uzamsal çözünürlük ise zihinsel aktivitenin yerinin mümkün olan en doğru şekilde belirlenmesi anlamına gelmektedir. fNIRS ve fMRI, dokulardaki oksijenleşmeyi ve beyin damarlarındaki kan akışı gibi metabolik aktiviteleri kullanarak, zihinsel aktiviteyi dolaylı yoldan ölçebilmektedir [4,6]. Bu yöntemler, elektromanyetik aktivite yerine metabolik aktiviteyi temel aldığı için, bir zihinsel aktivitenin sonucu birkaç saniye geçtikten sonra alınabilmektedir. Zamansal çözünürlüğü zayıf olan fNIRS ve fMRI, BBA sistemlerinin geliştirilmesi için uygun değildir [4].

BBA sistemlerinin tasarımında, invaziv ve invaziv olmayan, iki temel yaklaşım bulunmaktadır [7]. İnvaziv yaklaşım, elektrotların doğrudan beyin yüzeyine bağlanmasını gerektirmektedir. Elektrotlar, doğrudan beynin istenen bölgesine bağlanabildiği için invaziv yaklaşımda elektromanyetik aktivite daha kesin bir şekilde ölçülebilmektedir. Ancak, elektrotların ameliyat ile beyne yerleştirilmesi, enfeksiyona veya beyin hasarına neden olabilir. Bu durum, ECoG ve ICE gibi invaziv yöntemlerin


BBA tasarımında kullanımına engel oluşturmaktadır [4]. İnvaziv olmayan yöntemler, zihinsel aktiviteyi, kafatası üzerinden elektrotlar yardımıyla veya tıbbi görüntüleme ile ölçmektedir. EEG ve MEG, invaziv olmayan ve elektromanyetik aktiviteyi ölçtükleri için iyi bir zamansal çözünürlüğe sahip olan yöntemlerdir. MEG, zihinsel aktiviteyi, beyindeki elektrik akımlarının yarattığı zayıf manyetik alanları tespit ederek ölçer. Beynin ürettiği picotesla seviyesindeki manyetik alan, korumalı bir ortamdaki süper iletken kuantum girişim cihazı kullanılarak ölçülür. Bu teknik, mükemmel bir zamansal çözünürlüğe ve iyi bir uzamsal çözünürlüğe sahiptir [6]. Ancak büyük ve pahalı bir cihaz olan MEG, BBA sistemlerinin tasarımı için uygun değildir [4]. Böylece EEG'nin BBA sistemlerinin tasarımında, şu anki teknolojiler içinde en uygun invaziv olmayan ölçüm yöntemi olduğu görülmektedir. Tablo 1.1'de nöro-aktivitenin kaydında kullanılan teknolojiler, avantajları ve dezavantajlarıyla birlikte özetlenmektedir.

Tablo 1.1 Nöro-aktivite Kaydında Kullanılan Teknolojiler [2]

Yöntem	Ölçülen Aktivite	Zaman Çözünürlüğü (s)	Uzam Çözünürlüğü (mm)	Sağlık Riski	Taşınabilirlik
EEG	Elektrik Alan	0.05	10	İnvaziv Değil	Taşınabilir
MEG	Manyetik Alan	0.05	5	İnvaziv Değil	Taşınabilir Değil
ECoG	Elektrik Alan	0.003	1	İnvaziv	Taşınabilir
ICE	Elektrik Alan	0.003	0.05 ~ 0.5	İnvaziv	Taşınabilir
fMRI	Metabolik Aktivite	1	1	İnvaziv Değil	Taşınabilir Değil
fNIRS	Metabolik Aktivite	1	5	İnvaziv Değil	Taşınabilir

BBA sistemlerinin geliştirilmesi için öncelikle, beyinde oluşan elektriksel aktivitenin yorumlanması ve kaydedilmesi gerekmektedir. Daha sonraki aşama ise kaydedilen elektriksel aktivitelerden, belirli yazılımsal ve/veya donanımsal çözümlerle anlamlı bilgilerin çıkarılmasıdır. Bu aşamada, insan bedeninin bir takım fizyolojik süreçler sonucunda ürettiği sinyallerin analizi ile ilgilenen bir disiplin olan

biyolojik sinyal işleme yöntemleri kullanılır [8]. BBA uygulamaları, tasarlanan sistemin amacına göre belirli değişiklikler göstermekle birlikte genel olarak Şekil 1.1'de görülen aşamalardan oluşmaktadır. BBA sistemlerinin tasarımında, EEG sinyalleri kaydedildikten sonra, sinyal işleme ve yapay öğrenme algoritmaları kullanılarak, kullanıcı ile cihaz arasındaki haberleşme bağlantısı sağlanmaktadır.



Şekil 1.1 EEG tabanlı bir BBA Uygulamasının Blok Diyagramı

1.1 Tarihçe

Carlo Mateucci ve Emil Du Bois-Reymond, kas sinirlerinin yaydığı elektrik sinyallerini bir galvanometre yardımıyla ölçen ilk insanlar olarak nörofizyoloji konseptini kurmuşlardır [1]. Richard Caton, 1875 yılında, bir galvanometre ve iki elektrot kullanarak bir insanın kafatasından beyin aktivitesini elektrik sinyali biçiminde kaydeden ilk insan olmuştur [1]. Bu tarihten itibaren electro, encephalo ve gram konseptleri, beyindeki nöronların elektrikselsel aktivitesini tanımlamak için kullanılmaya başlamıştır. Bununla birlikte, Hans Berger, 1929 yılında, zihinsel aktiviteler ile EEG sinyallerindeki değişimler arasındaki ilişkileri keşfeden ilk insan olmuştur. Beş yıllık bir çalışmanın ardından, beyinden elde edilebilecek en belirgin sinyalin, deneğin gözleri

kapalıyken, occipital lobdan kaydedilebileceği sonucuna varmıştır [9]. Yaptığı çalışmada elde ettiği bulguların, ilk dönemlerde bir çeşit gürültü olduğu düşünülse de, izleyen yıllarda diğer sinirbilimciler Hans Berger'in çalışmalarını doğrulamışlardır [10]. Hans Berger'in ilk yayınından sonraki on yıllar boyunca, EEG sadece tıbbi tanılama ve beyin fonksiyonlarının araştırılması gibi çalışmalarda kullanıldı [11]. İlk BBA uygulaması, 1964 yılında Dr. Grey Walter tarafından gerçekleştirilmiştir [12]. Dr. Walter, bir hastasının beyninin motor bölgelerine elektrotlar bağlayarak, bir slayt projektörünü ilerletmesi için bir butona basmasını istemiş ve bu sırada oluşan zihinsel aktiviteyi kaydetmiştir. Dr. Walter daha sonra hastanın beyninden elde edilen sinyaller butona basmak istediğini gösterdiğinde slayt projektörünü ilerletecek şekilde, sistemi doğrudan slayt projektörüne bağlamıştır. Böylece, hasta butona bastığında değil, butona basmadan çok kısa bir süre önce slayt projektörünün ilerlediğini gözlemlemiştir.

BBA sistemlerinin geliştirilmesi amacıyla kullanılan elektrofizyolojik kaynaklar, sensorimotor temelli, yavaş kortikal potansiyel (YKP) temelli, olay ilişkili potansiyel (OİP) temelli, bir matematiksel işlem yapmak gibi zihinsel görev temelli, nöronların ateşlenme oranları gibi sinir hücresi aktivitesi temelli ve bu listelenen beş kaynağın aynı anda iki veya daha fazlasını kullanan hibrid sistemler olmak üzere altı başlık altında incelenmektedir [13].

Sensorimotor ritimleri, hareket veya harekete hazırlık durumunda azalır veya senkronizasyonlarını kaybeder. Hareket sonrasında veya dinlenme durumunda ise yeniden senkronize olur [14]. Örnek bir sensorimotor tabanlı BBA sistemi, sağ veya sol elin hareketinin hayal edilmesi ve bu sırada sensorimotor korteksten elde edilen EEG sinyallerinin sınıflandırılması biçiminde gerçekleştirilebilir. Bir diğer yaklaşım ise kullanıcının sağ veya sol elin hareketlerinden oluşan motor görüntüleri izleyerek BBA sistemini kontrol etmesiyle sağlanabilir [14]. Motor hareketlerin gözlemlenmesiyle oluşan sensorimotor ritimleri, motor korteksin normal bir fonksiyonu değil, kullanıcıların eğitim ile öğrendikleri bir sürecin sonucudur. Basit hareketlerin hayal edilmesinin, sensorimotor μ ve β bantlarında öngörülebilir geçici ve kararlı değişimler ortaya çıkardığı gösterilmiş olsa da beklenen hayal etme kaynaklı EEG değişimlerini göstermeyen kullanıcılar da bulunmaktadır [14]. *Hwang ve ark.* 2009 yılında yaptıkları çalışmada, motor görüntü eğitimi alan ve almayan katılımcıların, sağ ve sol elin hareketlerinin hayal edilmesi ile kontrol edilen sensorimotor tabanlı BBA

performanslarını karşılaştırmışlardır [15]. Motor görüntü eğitimi almayan kullanıcıların, motor görüntü eğitimi aldıktan sonraki performanslarının arttığını bildirmişlerdir. *Kaiser ve ark.* 2014 yılında yaptıkları sensorimotor tabanlı BBA çalışmasında, kortikal aktivasyon etkinliklerini artıran motor-görüntü tabanlı bir sistem tasarlamışlardır [16]. Bu çalışmada, motor görüntü eğitimi ile özellikle sınıflandırma doğruluğu %70 ve altında olan, düşük performanslı BBA kullanıcılarının kortikal aktivasyonlarında belirgin bir iyileşme olduğunu göstermişlerdir.

Bir uyaran sonucunda oluşan, basmakalıp elektrofizyolojik cevaba OİP denilir. İlk OİP kaydı, Pauline Davis ve Hallowell Davis tarafından 1939 yılında kaydedilmiştir [10]. Ancak, bilgisayarların kullanıldığı ilk modern OİP çalışması, 1964 yılında, Dr. Grey Walter ve çalışma arkadaşları tarafından yapılmıştır. Yaptıkları çalışma sonucunda keşfettikleri OİP sinyaline, koşullu negatif değişim (*Contingent Negative Variation*) adını vermişlerdir [10]. Koşullu negatif değişim (KND) ayrıca bir yavaş kortikal potansiyel (YKP) olarak sınıflandırılmaktadır. YKP, nöronların belirli motor veya bilişsel görevlerin gerçekleşmesine olanak sağlayacak biçimde parlayabilmesi için, kortikal hücre gruplarının depolarizasyonu sonucunda oluşur [14]. Artan dikkat veya bilişsel etkinlik sonucunda negatif YKP değişiminin de arttığı görülür [14]. YKP tabanlı bir BBA sisteminin tasarımı için, önceden belirlenmiş bir eşik değerine göre değişen pozitif ve negatif YKP sinyallerinin ikili sınıflandırılması gerekir.

OİP sinyalleri, sensor, motor veya bilişsel bir olaydan sonra ortaya çıkabilir. OİP sinyali, olayın gerçekleşmesinden 100 ms sonrasına kadar geçen sürede gözlemleniyorsa, dış kaynaklı (*Exogenous*) OİP olarak adlandırılır. Bunun nedeni, dış kaynaklı OİP sinyallerinin, dışarıdan gelen bir sensor uyaran sonucunda üretilen sinyaller olmasıdır. P300 gibi daha uzun bir gecikmeden sonra gözlemlenen sinyaller ise iç kaynaklı (*Endogenous*) OİP olarak adlandırılır. P300 sinyali, karar verme süreci ile ilgili bir sinyaldir. Dolayısıyla, uyarının fiziksel özelliği değil, karar verme süreci daha belirleyicidir. Bu tür OİP sinyalleri, uyarının fiziksel özellikleri daha az belirleyici olduğu için iç kaynaklı OİP olarak adlandırılırlar [17]. BBA çalışmalarında yaygın biçimde kullanılan P300 veya diğer adıyla P3 sinyali, *Sutton ve ark.* tarafından 1965 yılında keşfedilmiştir [10]. P300, seyrek görülen veya işitilen bir olay sonrası, beyin sinyallerinde, tepe biçiminde oluşan bir sinyaldir. Olay gerçekleştikten yaklaşık olarak 300 ms sonra, pozitif bir tepe olarak ortaya çıktığı için P300 adını almıştır [18].

Günümüzde P300 temelli BBA çalışmaları, kelime heceleyici tasarımlarında kullanılmaktadır [18-21]. Ayrıca, yalan detektörü tasarımı gibi çalışmalarda da P300 sinyalinin faydalanıldığı görülmektedir [22].

Görsel bir uyaran sonucunda, beynin occipital ve parietal loblarında görülen, elektriksel sinyallere görsel uyarılmış potansiyel (GUP) veya tepkisel potansiyel adı verilir. Bir OİP türü olan GUP uyarıcıları International Society for Clinical Electrophysiology of Vision (ISCEV) tarafından standartlaştırılmıştır [23]. ISCEV tarafından, özelleşmiş GUP sinyalleri için bir standart getirilmemiştir. *Odom ve ark.* tarafından 2004 yılında yayınlanan bir çalışmada, ISCEV kapsamında değerlendirilmeyen özelleşmiş GUP sinyalleri: Kararlı Durum GUP, Süpürmeli GUP (*Sweep VEP*), Hareketli GUP (*Motion VEP*), LED Gözlüklü GUP (*LED Goggled VEP*) vb. biçimde listelenmiştir [24]. Bu standartlar klinik çalışmalar için geliştirilmiştir. GUP temelli BBA sistemleri ise kendi arasında, zaman modülasyonlu (z-GUP), frekans modülasyonlu (f-GUP) ve kod modülasyonlu (k-GUP) olarak, üç farklı sınıfta incelenebilir [17]. Literatürde en sık kullanılan yöntem, kullanıcı eğitimine gerek olmadığı için f-GUP veya diğer adıyla Kararlı Durum GUP (KDGUP) yöntemidir [17]. 3.5 Hz'den daha düşük frekanslı uyaranlar geçici durum görsel uyarılmış potansiyel (GDGUP) olarak adlandırılırlar. Daha yüksek frekanslı uyaranlar, uyarılmış potansiyellerin örtüşmeleri nedeniyle, uyaranla aynı frekansta bir yarı-sinüzoidal salınım oluşturdıkları için kararlı durum GUP olarak adlandırılırlar [25]. Retina, 3.5 Hz ile 75 Hz arasında herhangi bir frekansta yanıp sönen bir ışık kaynağı ile uyarıldığında, beyinde aynı frekansta bir sinyalin oluştuğu görülür. KDGUP, en iyi, uyaranın yaklaşık olarak 15 Hz olduğu durumda, görsel kortekste (*visual cortex*) gözlemlenir [26]. KDGUP yönteminde, farklı frekanslarda titreşen, farklı ışık kaynaklarına odaklanan kişilerin occipital bölgelerinde oluşan sinyaller kullanılarak bir BBA sistemi tasarlanmaktadır. Günümüzde en güvenilir haberleşme yaklaşımını sağlayan EEG tabanlı BBA olmasına ve kullanıcı eğitimine gerek olmadan bir sınıflandırma olanağı sağlanmasına rağmen, diğer sistemler gibi KDGUP sistemleri de herkesin kullanabileceği evrensel bir BBA sistemi tasarımını sağlayamamaktadır [27]. BBA araştırmaları yapan birçok laboratuvar, geliştirilen BBA sistemlerinin, deneklerin yaklaşık olarak beşte biri tarafından kullanılamadığını bildirmiştir. Bu denekler, literatürde BBA okuyamayanlar (*BCI Illiterates*) olarak adlandırılmaktadır. Son yıllarda yapılan iyileştirmelerle BBA

okuyamayanların oranı düşmüş olsa da, henüz evrensel bir BBA sistemi geliştirilememiştir [27].

Lalor ve ark. 2004 yılında, frekansları 6 Hz ve 25 Hz olan iki uyaran kullandıkları KDGUP tabanlı bir BBA sisteminde, O1 ve O2 elektrotlarından alınan EEG sinyallerinin ikili sınıflandırılması ile bilgisayar oyunlarının kontrolünün, beyin sinyalleri kullanılarak gerçekleştirilebildiğini göstermişlerdir [28]. Spektral güç yoğunluğu (SGY) tabanlı bir sınıflandırma yaptıkları çalışmada, O1 ve O2 elektrotlarından elde ettikleri SGY değerlerinin aritmetik ortalamasını özellik olarak kullanmışlardır. *Kelly ve ark.* 2005 yılında, sağ ve sol uzamsal sınıflandırmayı, KDGUP uyarıları kullanarak gerçekleştirdikleri çalışmada, 10 Hz ve 12 Hz frekanslarında iki uyaran kullanarak, O1 ve O2 elektrotlarından elde ettikleri EEG sinyallerini, SGY tabanlı sınıflandırmışlardır [29]. *Muller-Putz ve Pfurtscheller* 2008 yılında yaptıkları nöro-protez çalışmasında, iki eksenli bir el protezinin, dört görevli sınıflandırmasını, KDGUP tabanlı bir BBA sistemiyle gerçekleştirerek, nöro-protezlerin omurilik yaralanması gibi durumlarda kullanımının mümkün olduğunu göstermişlerdir [30]. *Prueckl ve Guger*, 2009 yılında yaptıkları çalışmada, ileri, geri, sağ ve sol olmak üzere dört görevli bir sınıflandırmayı, 10 Hz, 11 Hz, 12 Hz ve 13 Hz frekanslarında dört uyaran kullandıkları KDGUP tabanlı bir BBA sistemi ile gerçekleştirmişlerdir [25]. Tasarladıkları BBA sisteminde, O1, O2, Oz, PO3, PO4, PO7, PO8 ve POz elektrotlarından elde ettikleri KDGUP sinyallerinin frekans spektrumundan, birinci ve ikinci harmonikleri, SGY tabanlı sınıflandırmışlardır. *Bin ve ark.* 2009 yılında yaptıkları çalışmada, altı görevli, kanonik korelasyon tabanlı bir sınıflandırmayı, oksipital ve temporal bölgelerindeki dokuz kanaldan aldıkları verilerle, KDGUP tabanlı bir BBA sistemi tasarlayarak gerçekleştirmişlerdir [31]. *Luo ve Sullivan* 2010 yılında yaptıkları çalışmada, dört görevli bir sınıflandırmayı, sadece PO2 elektrodunu kullandıkları KDGUP tabanlı bir BBA sistemiyle gerçekleştirmişlerdir [26]. 9 Hz, 10 Hz, 11 Hz ve 12 Hz frekanslarında dört KDGUP uyarını kullandıkları çalışmada, SGY tabanlı bir sınıflandırma yapmışlardır. *Volosyak I.* 2011 yılında, EEG ölçümlerinde problem yaratan yüksek empedansın en aza indirilmesi amacıyla kullanılan elektrolitik elektrot jeli yerine, musluk suyu kullanılabilen EEG elektrotları ile KDGUP tabanlı bir BBA sistemi geliştirmiştir. Yaptığı çalışmada, kelime heceleyici deney düzeneğinin, altı görevden oluşan bir sınıflandırma ile kullanımını gerçekleştirmiştir [27]. 6.67 Hz, 7.5

Hz, 8.57 Hz, 10 Hz ve 12 Hz frekanslarında beş farklı KDGUP uyararı kullanarak, SGY tabanlı bir sınıflandırma yapmıştır. *Long ve ark.* 2012 yılında yaptıkları çalışmada, bir akülü sandalye kontrolünü hibrid bir BBA yaklaşımı kullanarak gerçekleştirmişlerdir. Akülü sandalyenin sağa/sola dönüşleri ve yavaşlaması için sensorimotor temelli EEG sinyallerini kullanırken, hızlanması için O1, O2 ve Oz elektrotlarından elde ettikleri KDGUP sinyallerini kullanmışlardır [32]. *Lee ve ark.* 2012 yılında yaptıkları çalışmada, bir mobil robotun kontrolünü, ileri, sağ ve sol olacak şekilde üç farklı göreve karşılık gelen, 13 Hz, 14 Hz ve 15 Hz frekanslarındaki KDGUP uyararı kullanarak gerçekleştirmişlerdir [33]. *Zhang ve ark.* 2015 yılında, kanonik korelasyon tabanlı sınıflandırma ile 6 Hz, 7 Hz, 8 Hz ve 9 Hz frekanslarında uyarılar kullanarak, KDGUP tabanlı bir BBA sistemi tasarlamışlardır. Bu dört görevli sınıflandırmayı, O1, O2, Oz, P7, P8, P3, P4 ve Pz elektrotlarından elde ettikleri sinyalleri kullanarak gerçekleştirmişlerdir [34].

Genellikle 50 Hz ile 60 Hz aralığında bulunan, kritik titreşim frekansı (KTF) adı verilen belirli bir eşik değerinden daha yüksek frekanslarda titreşen uyarılar, görsel korteks tarafından titreşmiyormuş gibi algılanır. Bu durum deneklerde daha az göz yorgunluğuna neden olur [35]. *Sakurada ve ark.* 2015 yılında, KTF'nin üstündeki frekanslarda uyarıların kullanıldığı bir BBA sistemi tasarlamışlardır [35]. Üç görevli sınıflandırma yaptıkları çalışmada, KTF'nin altındaki uyarılar için 41 Hz, 43 Hz ve 45 Hz frekanslarını, KTF'nin üstündeki uyarılar için 61 Hz, 63 Hz ve 65 Hz frekanslarını kullanmışlardır. Deneklerin görsel olarak algılayabildikleri ve algılayamadıkları frekanslarda uyarıların kullanıldığı bir BBA sisteminin sınıflandırma sonuçlarını karşılaştırmışlardır. KTF'nin üstündeki frekanslarda, BBA'nın sınıflandırma performansında ufak bir düşüş olmasına rağmen, bu frekanslardaki uyarılarda, deneklerin daha az görsel yorgunluk yaşadıklarını bildirmişlerdir. Yaptıkları çalışma ile KTF'nin üstündeki yüksek frekanslı görsel uyarıların KDGUP tabanlı BBA sistemlerinin tasarımında kullanılabileceğini göstermişlerdir.

Uyarılmış Potansiyeller (UP), sadece görsel değil, işitsel ya da somatosensoriyel olabilir. *Müller-Putz ve ark.* 2006 yılında somatosensoriyel uyarı tabanlı (SUP) bir BBA sistemi kullandıkları çalışmada, başarılı sınıflandırma sonuçları elde ederek, SUP'un BBA tasarımında kullanılabileceğini göstermişlerdir [36].

Geçmiş yıllarda yapılan çalışmalarda ayrıca, KDGUP tabanlı EEG sinyallerinin analizinde, müzik seviyesinin odaklanma gerektiren uygulamalara etkisi, yüksek frekanslı uyaranların gözlerde oluşturduğu yorgunluğun BBA kullanıcılarına etkisi ve farklı yaş gruplarının KDGUP tabanlı BBA sistemlerindeki performanslarının analizi gibi BBA sistemlerinin performansını etkileyebilecek çeşitli parametrelerin araştırıldığı çalışmalar bulunmaktadır [35,37-41].

1.2 Tezin Önemi ve Amacı

Çevresel sinir sistemi beynin kullandığı doğal haberleşme yoludur. BBA sistemlerinin amacı bu doğal haberleşme yolu yerine farklı haberleşme yollarını kullanarak kontrol sağlamaktır. BBA araştırmalarının önünde iki önemli zorluk bulunmaktadır. Bu zorluklardan ilki, EEG ölçüm ve kayıt cihazlarının maliyetli ve kullanımı pratik olmayan sistemler olmasıdır. BBA araştırmaları, 2000'li yılların ikinci yarısında Emotiv ve Neurosky gibi nöro-başlıkların üretimine kadar, oldukça maliyetli çalışmalardı. BBA araştırmalarında karşılaşılan diğer bir zorluk ise sinirbilim, psikoloji, fizyoloji, bilgisayar bilimleri, elektronik mühendisliği, yazılım mühendisliği ve benzer bir çok disiplinden oluşan bir çok-disiplinli çalışma alanı olmasından kaynaklanmaktadır [2]. Bu tez çalışmasının amaçlarından biri, BBA araştırmalarında çalışmak isteyen bilim insanlarını, farklı disiplinlerin BBA araştırmaları için gerekli temel konuları üzerine bilgilendirmektir. Özellikle son on yılda BBA çalışmalarına bilim çevrelerinde gösterilen ilginin arttığı görülmektedir. Ancak, son yıllarda kazandığı popüleriteye rağmen BBA çalışmaları henüz emekleme aşamasındadır.

BBA çalışmaları, beyinden elde edilen aktivitenin ölçüm yöntemi, faydalanılan elektrofizyolojik kaynaklar, sinyallerin işleme yöntemleri vb. birçok açıdan farklılıklar göstermektedir. Bu tez çalışmasının bir diğer amacı, bir BBA sisteminin tasarımında karşılaşılabilecek donanımsal veya yazılımsal bir takım problemlerin tanıtımı ve olası çözümlerin tartışılmasıdır. Böylece BBA araştırmalarında çalışmak isteyen bilim insanları için karşılaştıkları problemlerin çözümlerinde bu tez bir başlangıç noktası olabilir.

Bu tez çalışmasında gerçekleştirilen temel araştırmalar: dijital filtreleme uygulanan ve uygulanmayan BBA tasarımlarının sınıflandırma performansları, kararlı-

durum görsel uyaran potansiyellerin (KDGUP) harmonik frekanslarından elde edilen özelliklerin sınıflandırma performansına etkisi, yapay sinir ağları ve destek vektör makineleri sınıflandırıcılarının, KDGUP sınıflandırma performansları, KDGUP uyaranlarının örtüşen ve örtüşmeyen frekanslardaki harmoniklerinin, sınıflandırma performansına etkisi olarak listelenmektedir. Bunlara ek olarak, tüm araştırmalarda zaman penceresi boyutunun ve görev sayısının BBA tasarımının performansına etkisi araştırılmıştır.

Bu tez çalışması sonucunda, standart bilgisayar donanımları üzerinde çalışan bilgisayar programlarının KDGUP temelli BBA yoluyla kullanımının, belirli koşullar altında mümkün olduğu gösterilmiş ve BBA tasarımının sinyal işleme, özellik çıkarımı ve sınıflandırma aşamalarındaki değişkenlerinin, tasarımın performansına olan etkisi araştırılarak elde edilen bulgular ortaya konmuştur.




2. BEYNİN ORGANİZASYONU VE OSİLASYONLARI

Beyin, birbirleriyle farklı biçimlerde bağlantılı ve her biri kendine özgü göreve sahip olan bölgelerden oluşacak şekilde organize edilmiştir. Memeli beynindeki nöronların iki yönlü haberleşmeye izin veren, büyük ölçüde dallı yapısı, beyindeki yerel hesaplamaların, beyin geniş bölgelerine yayınlanmasına ve bu lokal aktiviteden haberdar olmasına olanak verir. Diğer taraftan, yerel hesaplamalar, sürekli devam eden yukarıdan aşağıya kontrol adı verilen bir global beyin aktivitesinin kontrolü altındadır [42]. Bu yerel-global haberleşme ve yukarıdan aşağıya kontrol aktivitesi, beyindeki özel ve dinamik bir organizasyon olan beyin osilasyonlarının sonucudur [42]. Bu bölümde temel olarak, insan beyinin BBA çalışmaları odağında, anatomisi, organizasyonu ve ürettiği osilasyonlardan bahsedilmektedir.

2.1 Beyin-Bilgisayar Arayüzü Çalışmaları Odağındaki Beyin Bölgeleri


İnsan beyni, iki yarı küreden oluşmaktadır. Her bir yarı kürenin üzeri, kalınlığı beyin farklı bölgelerinde değişkenlik göstermekle birlikte, 1.5 mm ile 4 mm arasında olan ve korteks (*kabuk*) adı verilen bir yapıyla kaplıdır. Korteks, gönüllü hareket kontrolü, planlama, algılama ve düşünme gibi faaliyetlerle ilişkili beyin bölgesidir ve korteks-altı beyin bölgelerinin deneysel olarak erişimi zordur. Dolayısıyla korteks, BBA araştırmalarının odağı durumuna gelmiştir [43]. Korteks, Şekil 2.1'de gösterildiği gibi, frontal, parietal, oksipital ve temporal adı verilen dört ana bölümden veya diğer adıyla lobdan meydana gelmektedir. Hareket kontrolüyle yakın ilişkisinden dolayı BBA araştırmaları için önemli bir bölge olan birincil motor korteks (M1), frontal lobda bulunmaktadır. Birincil somatosensor korteks (S1), dokunma, sıcaklık, acı ve uzuv pozisyonu gibi harekete kılavuzluk eden sensor bilgilerin işlendiği bölgedir ve parietal lobda bulunur. Bu tezin konusu olan KDGUP tabanlı BBA sistemlerinin tasarımında, önemli bir bölge olan birincil görsel korteks (V1) ise occipital lobun en arka kısmında bulunmaktadır [43]. Şekil 2.1'de, M1, S1, V1'in yerleri görülmektedir.



Şekil 2.1 Beynin Dört Ana Bölümü ve M1, S1 ve V1'in Yeri

2.2 Aksiyon Potansiyel

Beyindeki en temel fonksiyonel ünite, nörondur. İnsan beyinde yaklaşık 10^{11} adet nöron bulunduğu tahmin edilmektedir [9]. Nöron'un gövdesi soma olarak adlandırılmaktadır. Soma, Şekil 2.2'de görüldüğü gibi, dendritler üzerinden diğer nöronların gönderdiği sinyalleri alır ve akson üzerinden diğer nöronlara sinyal gönderir. Akson, yalıtım sağlayan, miyelin kılıf adı verilen bir katmanla kaplıdır. Akson üzerinde ayrıca, elektriksel sinyalleri yükselten Ranvier boğumları bulunmaktadır. Bir nöronun aksonu ile başka bir nöronun dendriti arasındaki birleşime sinaps adı verilmektedir. Sinaps nöronlar arası bilgi aktarımının gerçekleştiği bölgedir. Somaya gelen sinyallerin toplamı, bir eşik değerinden yüksek olması durumunda aksona gönderilir. Aksonun ucuna ulaşan elektriksel potansiyel, nöro-transmitter adı verilen kimyasalların, sinaptik boşluk boyunca yayılımına neden olur. Sinaptik boşluğa bağlanan diğer nöronun dendritinde, sinaptik boşlukta yayılan nöro-transmitter sayısı ile orantılı olacak şekilde, bir elektriksel potansiyel oluşur [8].




Şekil 2.2 Nöron ve Bağlantıları [8]

Nöronlar birbirlerine, elektriksel potansiyeller yoluyla bilgi göndermektedir. Bir nöron tarafından iletilen bilgiye aksiyon potansiyel (AP) adı verilmektedir [1]. AP'ler, nöron membranı üzerinde gerçekleşen iyon değişimlerinin oluşturduğu, membran potansiyellerindeki geçici değişimlerdir. Bu geçici değişimler genellikle, hücre gövdesinde başlatılır ve akson üzerinde ilerler. Bir AP'nin oluşabilmesi için uyarının belirli bir eşik değerinin üstünde olması gerekmektedir. Eşik değerinin altındaki uyarılar, küçük ve yerel elektriksel bozunumlar oluşturur; ancak akson boyunca ilerleyen AP'ler oluşturmaz. Şekil 2.3'de örnek bir AP görülmektedir.

Bir AP aşağıdaki aşamalardan oluşur [8]:

1. Nöronun dendriti bir uyarı aldığında, membrandaki sodyum (Na^+) kanalları açılır. Hücre dışı ortamda bulunan Na^+ iyonları, açılan kanallardan hücre içi ortama geçer. Açılan Na^+ kanalları hücre içi ortam potansiyelini -70 mV seviyesinden -55 mV seviyesine çıkarabilirse süreç devam eder.
2. Aksiyon eşiğine ulaşıldığında, voltaja duyarlı iyon kapısı adı verilen daha fazla sayıda Na^+ kanalı açılarak, hücre membranının iç potansiyelini yaklaşık 30 mV seviyesine kadar yükseltir. AP sürecinin bu kısmına depolarizasyon adı verilmektedir.

3. Nöron membranındaki Na^+ kanalları kapanır ve kısa bir süre sonra potasyum (K^+) kanalları açılır. Hücre içi ortamda bulunan K^+ iyonları, açılan K^+ kanallarından hücre dışı ortama çıkar.
4. K^+ kanalları açıldıktan sonra membran potansiyeli azalmaya başlar. Bu aşamaya repolarizasyon adı verilir.
5. Repolarizasyon sonucunda membran potansiyeli, durağanlık potansiyelini aşarak -90 mV seviyesine kadar düşer. Bu aşamaya hiperpolarizasyon adı verilmektedir.
6. Son aşamada ise sodyum-potasyum adenosin trifosfat (Na^+/K^+ -ATPase) pompaları, membran potansiyelini yeniden -70 mV olan durağanlık potansiyeli seviyesine getirir.



Şekil 2.3 Aksiyon Potansiyelin Aşamaları [8]

Nöronal aktivitenin oluşturduğu elektrik alan, aktivitenin büyüklüğüne göre dört farklı uzamsal sınıfta incelenebilir. Bunlardan en küçük ölçeklisi, tek bir nöronda oluşan aksiyon potansiyeldir. Diğer üçü ise aşağıdaki gibi sınıflandırılmaktadır [43]:


- Mikro-ölçekli Elektrik Alan: Genellikle doğrudan beyin dokusu içinden kaydedilen, elektrotun 0.1 mm ile 1 mm çevresinde oluşan sinaptik aktiviteden kaynaklanan yerel alan potansiyelleridir.
- Orta-ölçekli Elektrik Alan: Korteksin yüzeyinden kaydedilen, elektriksel aktivitedir. Elektrokortikogram (ECoG) olarak adlandırılmaktadır. Yerel sinaptik aktivite ile birlikte, lokal korteksin daha derin bölgelerindeki (elektrotun 2 mm ile 5 mm altında kalan bölgeler) elektriksel aktiviteden oluştuğu düşünülmektedir.
- Makro-ölçekli Elektrik Alan: Kafa derisi yüzeyinden elde edilen elektroensefalografik sinyalleridir. Hacmi, 10^3 ile 10^4 mm³ aralığında değişen geniş bir kortikal bölgede oluşan ortalama elektriksel aktivitedir.

2.3 Beyin Osilasyonları

Newton mekaniğinin birinci kanununa göre, üzerine hiç bir kuvvet etki etmiyorsa bir cisim durumunu değiştirmez. Duruyorsa durmaya devam eder; sabit hızla hareket ediyorsa aynı hızla hareketini sürdürür. Burada kuvvet, cismin hareketinden sorumlu olan nedendir. Eğer bir top yuvarlanarak başka bir topa çarpar ve hareket ettirirse, buradaki neden, yuvarlanan topun duran topa uyguladığı kinetik enerji kuvvetidir. Bilgisayar ekranındaki bir topun, başka bir topa doğru hareket ettiği bir deneyde, eğer ikinci top, birinci topun varışından hemen sonra birinci top ile aynı yönde hareket etmeye başlarsa, olayların zamanlamasından dolayı, birinci topun, ikinci topun hareketine neden olduğu düşünülür. Ancak, böyle bir algının oluşabilmesi için ikinci topun, birinci top vardıktan sonraki ilk 140 ms içerisinde harekete geçmesi gerekmektedir. Eğer ikinci top 140 ms'den daha uzun bir süre geçtikten sonra harekete geçerse, beyin iki topun hareketi arasında bir nedensellik ilişkisi kuramaz. Bu deneyden anlaşılacağı üzere, beyin, algıladığı olayları, bilgiyi zamansal olarak paketleme yeteneğine göre ayırt etmektedir ve bu paketleme nöronal osilasyonlar ile gerçekleşmektedir [9]. Memeli beyinde, bu osilasyonlar, yaklaşık olarak 0.5 Hz ile 500 Hz arasında değişen frekanslarda görülmektedir [42]. İnsan beyinde görülen EEG osilasyonları ya da başka bir deyişle EEG sinyalleri genellikle aşağıdaki biçimde sınıflandırılır:

- Delta Sinyalleri (δ): 0.5 Hz ile 3.5 Hz aralığında, uyku halindeyken görülen sinyaldir. Uyanık haldeyken delta sinyallerinin görülmesi, beyindeki fiziksel bir kusura işaret eder [5,44].
- Teta Sinyalleri (θ): 3.5 Hz ile 7.5 Hz aralığında, uykuluyken veya meditasyon yaparken görülen sinyaldir. Teta sinyallerinin bu özelliğinden faydalanılarak, uykulu araç kullanımında, sürücüyü bir alarmı tetikleyerek uyaran bir sistem tasarlanmıştır [45]. Teta sinyalleri ayrıca, hipnagogik halüsinasyonlar, problem çözme, hipnoz, bilinçaltı erişimi ve ilham ile ilişkilendirilmiştir [5,44].
- Alfa Sinyalleri (α): 7.5 Hz ile 12 Hz aralığında, rahatlama ve gevşeme halindeyken, occipital ve frontal loblarda görülen sinyaldir [5,44].
- Beta Sinyalleri (β): 12 Hz ile 30 Hz aralığında, genellikle frontal lobda gözlemlenen, küçük genlikli sinyallerdir. Genellikle odaklanma ve konsantrasyon ile ilişkilendirilir. Matematiksel bir problemi çözmek veya bir plan yapmak gibi görevler gerçekleştirilirken, beyindeki beta aktivitesinde artış görülür [5].
- Gama Sinyalleri (γ): 30 Hz üzerindeki frekanslarda görülen, beta dalgalarıyla birlikte, dikkat, algılama ve kavrama ile ilişkilendirilen sinyallerdir. Gama sinyallerinin, bilinç mekanizmasını yansıttığı düşünülmektedir [5].
- Sensorimotor Sinyalleri: 8 Hz ile 11 Hz aralığında, mü (μ) adı verilen bir bileşen ve bununla birlikte sıklıkla görülen yaklaşık olarak 20 Hz frekansında bir β bileşenden oluşan, somatosensor kortekste görülen bir sinyaldir [14]. Sensorimotor sinyallerin μ bileşeni somatosensor korteks kaynaklıyken, β bileşeni motor korteks kaynaklıdır. Sensorimotor sinyalleri, hareket, hareket imgelemi ve harekete hazırlık durumlarında bloke olur. Dolayısıyla sensorimotor korteksin boşta çalışma sinyali olarak görülmektedir [14].

EEG sinyalleri ayrıca, doğal ritmik potansiyeller ve hareket etmek gibi bir olay sonucunda tetiklenen potansiyeller olmak üzere iki grupta incelenebilir [45]. Şekil 2.4'te BBA çalışmaları için beyin potansiyellerinin taksonomisi görülmektedir.



Şekil 2.4 BBA Uygulamalarında Beyin Potansiyellerinin Taksonomisi [45]

2.4 Beyin Bilgisayar Arayüzü Çeşitleri

BBA tasarımları, kullanılan elektrofizyolojik kaynağa veya beyindeki elektriksel aktivitenin ölçümünde kullanılan tekniğe göre farklı şekillerde sınıflandırılmaktadır. Literatürde bunların dışında, iç kaynaklı/dış kaynaklı ve senkron/asenkron olmak üzere iki farklı BBA tasarım tipi daha bulunmaktadır.

2.4.1 Dış Kaynaklı ve İç Kaynaklı Beyin Bilgisayar Arayüzleri

Bir BBA sistemi, kullanılan giriş sinyalinin yapısına göre dış kaynaklı ya da iç kaynaklı olarak sınıflandırılmaktadır. Dış kaynaklı BBA tasarımları, GUP veya İUP gibi dış kaynaklı bir uyaran sonucunda beyinde oluşan tepki sinyalini kullanmaktadırlar. KDGUP ve P300 gibi beyin aktivitelerini kullanan BBA tasarımları dış kaynaklı tasarımlara örnek gösterilebilir. Dış kaynaklı BBA tasarımlarının avantajları, kullanıcı eğitimine ihtiyaç duyulmaması ya da çok az ihtiyaç duyulması ve iç kaynaklı BBA tasarımlarına göre daha az sayıda elektrot kullanımının yeterli olmasıdır. Diğer taraftan, dış kaynaklı BBA tasarımlarında kullanıcının uyarı sinyaline odaklanması gerekmektedir. Bu durum BBA kullanıcılarında yorgunluğa neden olabilmektedir [2].

YKP ve sensorimotor gibi beyin aktivitelerini kullanan BBA tasarımları iç kaynaklı olarak sınıflandırılmaktadır. İç kaynaklı yaklaşım, kullanıcı için herhangi bir uyaran sinyali gerektirmemektedir; diğer taraftan, BBA sisteminin kullanımı için

haftalar veya aylar süren bir eğitim süreci gerektirmektedir. Ayrıca, iç kaynaklı yaklaşımda tüm kullanıcılar BBA sisteminin kontrolünü sağlayamamaktadır. İç kaynaklı BBA tasarımlarının bir diğer dezavantajı, fazla sayıda elektrot kullanımı gerektirmesidir [2].

2.4.2 Senkron ve Asenkron Beyin Bilgisayar Arayüzleri

BBA sistemleri, girdi sinyalinin işlenme yöntemine göre senkron ya da asenkron olarak sınıflandırılmaktadır [2]. Senkron BBA tasarımında, sadece önceden tanımlanmış zaman aralıklarında kaydedilen EEG sinyalleri analiz edilmekte ve bu zaman aralıklarının dışında kalan kayıtlar dikkate alınmamaktadır. Senkron BBA tasarımının avantajı, kullanıcıların göz kırpması veya göz bebeklerinin hareketleri gibi nedenlerden kaynaklanan gürültülerin giderilmesidir. Kullanıcılardan önceden tanımlanmış kısa zaman aralıklarında göz bebeklerini hareket ettirmemeleri ve göz kırpmamaları istenerek, EEG kaydını etkileyebilecek fizyolojik kaynaklı gürültüler giderilebilir. Dolayısıyla filtreleme aşamasında görece basit yöntemlerin kullanılması ya da hiç filtreleme yöntemi kullanılmaması gibi seçenekler değerlendirilebilir. Diğer taraftan, asenkron BBA tasarımlarında önceden tanımlanmış belirli zaman aralıkları bulunmamaktadır ve kullanıcının hareketlerinden bağımsız olarak tüm EEG kaydı analiz edilmektedir. Dolayısıyla asenkron BBA tasarımları daha doğal bir insan makine etkileşimi sağlamaktadır. Ancak, asenkron BBA tasarımlarında kullanıcıların tüm hareketleri EEG kaydını etkileyeceğinden, senkron BBA yaklaşımına göre daha karmaşık filtreleme yöntemlerinin kullanılması gerekmektedir.

3. SİNYAL İŞLEME

Sinyal, fiziksel değişkenlerle ilgili bilgi taşıyan ve matematiksel olarak, bir veya daha fazla bağımsız değişkenin bir fonksiyonu biçiminde gösterilen kavrama denir [46]. Eşitlik 3.1'de basit bir sinyalin matematiksel ifadesi görülmektedir.

$$s(x, y) = 2x + 3xy + y^2 \quad (3.1)$$

Fonksiyonun bağımsız değişkenlerle ilişkisinin bilinemediği veya basit matematiksel eşitliklerle ifade edilemeyecek karmaşıklıkta olduğu, konuşma sinyalleri, biyolojik sinyaller vb. Eşitlik 3.1'de olduğu gibi kesin olarak tanımlanamazlar; ancak Eşitlik 3.2'de görüldüğü gibi, farklı frekans ve genlikte, birçok sinüzoidal bileşenin toplamı şeklinde, yüksek doğrulukta ifade edilebilirler. Eşitlik 3.2'de $\{A_i(t)\}$, $\{F_i(t)\}$, ve $\{\theta_i(t)\}$ sırasıyla sinyalin genlik, frekans ve faz setlerini ifade etmektedir.

$$s(t) = \sum A_i(t) \sin [2\pi F_i(t)t + \theta_i(t)] \quad (3.2)$$


Analog sinyallerin işlenmesi için elektronik devrelerden oluşan donanımlar kullanılır; ancak dijital sinyaller, belirli dijital sinyal işleme algoritmalarının kullanıldığı yazılımlarla işlenir [47]. Analog olarak kaydedilen EEG sinyallerinin, dijital olarak işlenebilmesi için önce dijital sinyallere dönüştürülmesi gerekmektedir. Bu işlem analog/dijital çevirici (Analog/Digital Converter, ADC) adı verilen elektronik devrelerle gerçekleştirilmektedir. Bu bölümde ADC, sinyal işleme uygulamalarının matematiksel altyapısını oluşturan Fourier dönüşümü ve dijital filtreleme ile ilgili temel bilgiler anlatılmaktadır. Ayrıca, bir dijital filtre, dijital sinyallere belirli matematiksel işlemler uygulayan bir sistem olarak düşünüldüğü için bu bölümde zamanda değişimsiz (Linear Time-Invariant, LTI) sistemler teorisi kısaca anlatılmaktadır.

3.1 Analog Dijital Çevirici

Ayrık zamanlı bir sinyal, Eşitlik 3.3'te görüldüğü gibi bir sekans olarak tanımlanır. Eşitlikte görülen x , sekansı ve $x[n]$, n bir tamsayı olmak üzere, sekanstaki n . sayıyı tanımlamaktadır.

$$x = \{x[n]\}, \quad -\infty < n < \infty \quad (3.3)$$

EEG sinyallerinin matematiksel olarak Eşitlik 3.3'te olduğu gibi ifade edilebilmesi, örnekleme ile mümkündür. Ayrık zamanlı bir $x[n]$ sinyali, sürekli zamanlı bir $x(t)$ sinyalinden eşit zaman aralıklarında değerler alınarak oluşturulur. Her bir $x[n]$ değeri, örnek olarak adlandırılmaktadır ve bir saniyede alınan toplam örnek sayısı, birimi Hertz (Hz) olan örnekleme frekansını vermektedir [8]. Şekil 3.1'de, analog bir sinyal ve bu sinyalden eşit zaman aralıklarında alınan örnekler görülmektedir.




Şekil 3.1 Analog Sinyalden Örnekleme ile Elde Edilen Değerler [8]

Örneklemenin amacı orijinal sinyalin dijital bir kopyasını çıkarmaktır. Dijital sinyalin, analog sinyali mümkün olan en doğru biçimde temsil etmesi gerekmektedir. Bunu sağlamanın yolu örnekleme frekansına bağlıdır [47]. Shannon Örnekleme Teoremine göre, herhangi bir sinüzoidal dalga biçimi örneklenirken bilgi kaybı yaşanmaması için, sinyalin her bir periyodunda en az iki örnek alınmalıdır. EEG sinyalleri, Eşitlik 3.2'de gösterildiği gibi, farklı frekanslardaki ve genliklerdeki birçok sinüzoidal bileşenin toplamı biçiminde ifade edilebilmektedir. Dolayısıyla, EEG gibi analog bir sinyal, sinyalin içeriğindeki en yüksek frekanslı sinüzoidal bileşenin frekansının en az iki katı büyüklüğünde bir frekansla örneklenirse, herhangi bir bilgi kaybı gerçekleşmez. Shannon Örnekleme Teoremi matematiksel olarak, örnekleme frekansı f_s ve analog sinyalin en yüksek frekanslı sinüzoidal bileşeninin frekansı f_{max} olmak üzere; $f_s > 2f_{max}$ biçiminde ifade edilir. Örneğin bir BBA çalışmasında, beta sinyallerinin veri kaybı olmadan örneklenmesi istenirse, Shannon Örnekleme Teoremine göre, örnekleme frekansı en az 60 Hz olarak seçilmelidir. Bununla birlikte ticari veya araştırma amaçlı üretilen EEG kayıt cihazlarının örnekleme frekansı 1 KHz ile 20 KHz arasında değişmektedir.

Bir sinyalin dijital olması için ayrık-zamanlı olmasının yanı sıra zamanda aldığı değerlerin de ayrık-değerli olması gerekmektedir. Bir sinyalin, zamanda aldığı değerlerin ayrık-değerli biçime veya diğer bir deyişle sonlu bir değer kümesine dönüştürülmesine kuantalama adı verilmektedir [46]. Kuanta aslında bir fizik terimidir ve Max Plank tarafından 1900 yılında kara cisim ışınlığının yayılımını araştırdığı çalışmasında yayımladığı gibi, elektromanyetik enerjiyi oluşturan çok küçük ve ayrışık enerji paketlerine denilir. Dijital sinyal işlemede kuantalama, bir sekanstaki her örneğin sadece belirli bir kümeden değer alabilmesini ifade eder. Eğer bu küme tam sayılar kümesi ise sekanstaki tamsayı olmayan örnekler en yakın tamsayıya yuvarlanarak kuantalanır [48]. Kuantalamada kullanılan ayrık değerler genellikle, 8 bit ($2^8 = 256$ seviye), 16 bit ($2^{16} = 65536$ seviye), vb. ikinin kuvvetleri olacak şekilde seçilmektedir. Örneğin, Şekil 3.2'de görüldüğü gibi 3 bitlik bir kuantalayıcı seçilirse, örneklerin alabileceği sekiz farklı değer oluşmaktadır.

Eğer örnekleme frekansı, Shannon Örnekleme Teoremine uygunsa, analog/dijital çevirme işleminde hataya neden olan tek aşama kuantalamadır [46]. Şekil 3.2'de görüldüğü gibi kuantalama sonucunda hata oluşması kaçınılmazdır. Örneğin, analog sinyalin 2.5V ile 3.5V aralığında aldığı tüm değerler, dijital sinyalde 3V değerine kuantalanmıştır. Dolayısıyla $\pm 0.5V$ değerinde bir kuantalama hatası oluşmuştur. Kuantalama hatasını azaltmanın yolu, daha fazla kuantalama seviyesi kullanmaktır. Eğer 3 bitlik yerine 4 bitlik bir kuantalayıcı kullanılırsa, Şekil 3.2'de görülen analog sinyalin kuantalama hatası $\pm 0.5V$ değerinden, $\pm 0.25V$ değerine düşer.



Şekil 3.2 Analog Sinyalin 3 Bitlik Kuantalama Sonucunda Aldığı Ayrık Değerler

Şekil 3.2'de dijital sinyalin aldığı değerler, ikili (binary) biçimde görülmektedir. Bu, analog/dijital çevirme işleminin son aşaması olan kodlamanın bir sonucudur ve kodlama genellikle, kuantalama seviyelerinin ikili gösterimi biçimindedir [48].

3.2 Fourier Dönüşümü

Fourier dönüşümü, frekans bilgisi içeren döngülerin analizi için kullanılan bir matematiksel araçtır. Leonhard Euler, Daniel Bernoulli, ve Jean Le Rond d'Alembert gibi 18. yy. matematikçileri titreşen bir yayın matematiksel analizi üzerinde çalışmalar yapmıştır. 1753 yılında Bernoulli, titreşen bir yayın farklı genliklerdeki birçok sinüzoidal bileşenin toplamı biçiminde ifade edilebileceğini varsaymış; ancak bu sinüzoidlerin katsayılarını bulamamıştır. Jean-Baptiste-Joseph Fourier 1822 yılında yayımlanan Isının Analitik Kuramı başlıklı ünlü çalışmasında, periyodik bir $x(t)$ fonksiyonunun, frekansları $x(t)$ fonksiyonunun frekansının tamsayı katları olan sinüzoidlerin toplamı biçiminde ifade edilebileceğini ispat etmiştir [48].

3.2.1 Sürekli-Zamanlı Periyodik Sinyallerin Karmaşık Üstel Fourier Serileri

Periyodu T_0 olan sürekli-zamanlı bir $x(t)$ sinyalinin karmaşık üstel Fourier seri açılımı, n bir tamsayı olmak üzere,

$$x(t) = \sum_{n=-\infty}^{\infty} c_n e^{j2\pi n f_0 t} \quad (3.4)$$

olarak ifade edilir [49]. Burada c_n ile gösterilen karmaşık Fourier serisi katsayıları Eşitlik 3.5; f_0 ile gösterilen temel frekans ise Eşitlik 3.6 ile tanımlanmaktadır.

$$c_n = \frac{1}{T_0} \int_{-\frac{T_0}{2}}^{\frac{T_0}{2}} x(t) e^{-j2\pi n f_0 t} dt \quad (3.5)$$

$$f_0 = \frac{1}{T_0} \quad (3.6)$$

3.2.2 Sürekli-Zamanlı Aperiyodik Sinyallerin Fourier Dönüşümü


Aperiyodik bir sürekli-zamanlı sinyal belirli aralıklarla tekrarlanırsa Şekil 3.3'de görüldüğü gibi bir periyodik sinyal elde edilebilir. Şekil 3.3 (a) ve (b) de görülen sinyaller için

$$x(t) = \lim_{T_0 \rightarrow \infty} x_p(t) \quad (3.7)$$

olduğu görülmektedir [46]. $x_p(t)$ sinyalinin Fourier seri açılımı eşitlik 3.8'de, c_n katsayıları ise Eşitlik 3.9'da gösterilmektedir.

$$x_p(t) = \sum_{n=-\infty}^{\infty} c_n e^{j2\pi n f_0 t} \quad f_0 = \frac{1}{T_0} \quad (3.8)$$

$$c_n = \frac{1}{T_0} \int_{-\frac{T_0}{2}}^{\frac{T_0}{2}} x_p(t) e^{-j2\pi n f_0 t} dt \quad (3.9)$$



Şekil 3.3 Aperiyodik $x(t)$ Sinyalinden, T_0 Periyotlu $x_p(t)$ Sinyalinin Elde Edilmesi

$-\frac{T_0}{2} \leq t \leq \frac{T_0}{2}$ aralığında $x_p(t) = x(t)$ olduğundan, Eşitlik 3.9 aşağıdaki biçimde yazılabilir.

$$c_n = \frac{1}{T_0} \int_{-\frac{T_0}{2}}^{\frac{T_0}{2}} x(t) e^{-j2\pi n f_0 t} dt \quad (3.10)$$

Ayrıca $|t| > \frac{T_0}{2}$ için $x(t) = 0$ olduğundan, integralin limiti Eşitlik 3.11'de görüldüğü gibi değiştirilebilir.

$$c_n = \frac{1}{T_0} \int_{-\infty}^{\infty} x(t) e^{-j2\pi n f_0 t} dt \quad (3.11)$$

$x(t)$ fonksiyonunun Fourier Transformu adı verilen bir $X(f)$ fonksiyonu, Eşitlik 3.12'de görüldüğü gibi tanımlanırsa,

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi f t} dt \quad (3.12)$$

c_n Fourier katsayılarının $X(f)$ cinsinden Eşitlik 3.13'deki gibi tanımlanabileceği görülür.

$$c_n = \frac{1}{T_0} X(n f_0) \quad (3.13)$$

Dolayısıyla, Fourier katsayılarının, f_0 'ın katlarında alınan $X(f)$ örneklerinin, f_0 ile ölçeklenmiş biçimi olduğu görülmektedir [46]. Eşitlik 3.13 ile verilen ifade, Eşitlik 3.8'de c_n yerine yazılırsa,

$$x_p(t) = \frac{1}{T_0} \sum_{n=-\infty}^{\infty} X(n f_0) e^{j2\pi n f_0 t} \quad (3.14)$$

elde edilir.

$f_0 = \frac{1}{T_p}$ olduğundan, Eşitlik 3.14 aşağıdaki gibi yazılabilir.

$$x_p(t) = \frac{1}{T_0} \sum_{n=-\infty}^{\infty} X\left(\frac{n}{T_0}\right) e^{j2\pi n f_0 t} \quad (3.15)$$

$\Delta f = \frac{1}{T_0}$ olarak tanımlanır ve T_0 sonsuza yaklaşırken Eşitlik 3.15'in limiti alınır,

$$\lim_{T_0 \rightarrow \infty} x_p(t) = x(t) = \lim_{\Delta f \rightarrow 0} \sum_{n=-\infty}^{\infty} X(n\Delta f) e^{j2\pi n\Delta f t} \Delta f = \int_{-\infty}^{\infty} X(f) e^{j2\pi f t} df \quad (3.16)$$

elde edilir. T_0 sonsuza yaklařırken Δf , df integraline; $n\Delta f$ ise sürekli frekans deęiřkeni f 'ye dönüşmektedir. Bu durumda Eřitlik 3.15 ile verilen toplam, Eřitlik 3.16 ile verilen integrale dönüşmektedir. $X(f)$ bilinirken $x(t)$ fonksiyonunu veren bu integral iliřkisine ters Fourier dönüşümü adı verilmektedir [46].

Eřitlik 3.12 ve Eřitlik 3.16 sırasıyla Fourier dönüşümü ve ters Fourier dönüşümünden oluşan Fourier dönüşüm çifti olarak adlandırılmaktadır. Fourier dönüşüm çifti aynı zamanda radyan frekans deęiřkeni $\omega = 2\pi f$ cinsinden Eřitlik 3.17 ve Eřitlik 3.18'de verildięi biçimde ifade edilebilir.

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(\omega) e^{j\omega t} d\omega \quad (3.17)$$

$$X(\omega) = \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt \quad (3.18)$$

3.2.3 Ayırık-Zamanlı Sinyallerin Fourier Dönüşümü

Üzerinde bir frekans analizi yapılabilmesi için, ayırık-zamanlı bir $\{x[n]\}$ sinyali, sinyalin Fourier transformu ile tanımlanan frekans alanındaki gösterimine dönüřtürölür. Ancak $\{x[n]\}$ sinyalinin Fourier dönüşümü, Eřitlik 3.12'de de görüldüęü üzere frekansın sürekli bir fonksiyonudur ve dijital olarak ifade edilebilmesi mümkün deęildir. Dolayısıyla, ayırık-zamanlı sinyallerin frekans alanındaki gösterimi için ayırık Fourier dönüşümü (Discrete Fourier Transform, DFT) tanımlanmıřtır.

Ayırık-zamanlı bir sinyalin Fourier dönüşümü,

$$X(\omega) = \sum_{n=-\infty}^{\infty} x(n) e^{-j\omega n} \quad (3.19)$$

olarak tanımlanmaktadır. Ayırık-zamanlı aperiyojik bir sinyalin Fourier dönüşümü, Eřitlik 3.20'de görüldüęü gibi periyodiktir ve periyodu 2π 'dir [46].

$$\begin{aligned}
X(\omega + 2\pi k) &= \sum_{n=-\infty}^{\infty} x(n)e^{-j(\omega+2\pi k)n} = \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n}e^{-j2\pi kn} \\
&= \sum_{n=-\infty}^{\infty} x(n)e^{-j\omega n}
\end{aligned} \tag{3.20}$$

Ayrık Fourier dönüşümünün bir diğer özelliği ise, sinyallerin ayrık-zamanlı olmasının doğal bir sonucu olarak, integrasyon yerine terimlerin toplamı biçiminde ifade edilmesidir [46]. Ayrık-zamanlı bir sinyalin frekans alanındaki gösteriminde, frekansın sürekli bir fonksiyonu yerine, ayrık bir frekans değişkeni vardır. Saniyede N adet değer alınarak örneklenen bir sinyalde, ayrık frekans değişkeni 0 ile N-1 arasında değerler alabilir. Dolayısıyla ayrık-zamanlı bir sinyalin Fourier dönüşümü sonucunda, sinyalin frekans bilgisini içeren bir $\{x[m]\}$ sekansı elde edilir.

f_s örnekleme frekansı, $\omega = \frac{2\pi f}{f_s}$ ve $f = \frac{mf_s}{N}$ olmak üzere, DFT Eşitlik 3.21'de, ters ayrık Fourier dönüşümü (Inverse Discrete Fourier Transform, IDFT) ise Eşitlik 3.22'de gösterilmektedir [8].

$$X[m] = \sum_{n=0}^{N-1} x[n]e^{-j\frac{2\pi mn}{N}} \tag{3.21}$$

$$x[n] = \frac{1}{N} \sum_{m=0}^{N-1} X[m]e^{j\frac{2\pi mn}{N}} \tag{3.22}$$

Eşitlik 3.23 ile verilen Euler denklemi kullanılarak, DFT Eşitlik 3.24 ile gösterildiği biçimde tanımlanabilir.

$$e^{jx} = \cos(x) + j\sin(x) \tag{3.23}$$

$$X[m] = \sum_{n=0}^{N-1} x[n]\cos\left(\frac{2\pi mn}{N}\right) - j \sum_{n=0}^{N-1} x[n]\sin\left(\frac{2\pi mn}{N}\right) \tag{3.24}$$

Eşitlik 3.24'de görüldüğü gibi, DFT her bir m frekans değeri için bir gerçel kısımdan ve bir sanal kısımdan oluşmaktadır. DFT ile elde edilen gerçel kısım ve sanal kısım kullanılarak, sinyallerin genlik ve faz spektrumları çıkarılabilir. $Re[m]$ ve $Im[m]$

$$Re[m] = \sum_{n=0}^{N-1} x[n] \cos\left(\frac{2\pi mn}{N}\right) \quad (3.25)$$

$$Im[m] = \sum_{n=0}^{N-1} x[n] \sin\left(\frac{2\pi mn}{N}\right) \quad (3.26)$$

olmak üzere, Eşitlik 3.27'de, $X[m]$ ile gösterilen genlik spektrumu; Eşitlik 3.28'da ise $\theta(m)$ ile gösterilen faz spektrumu tanımlanmaktadır [8].

$$|X[m]| = \sqrt{Re(X[m])^2 + Im(X[m])^2} \quad (3.27)$$

$$\theta(m) = \tan^{-1} \frac{Im(x[m])}{Re(x[m])} \quad (3.28)$$

3.2.4 Hızlı Fourier Dönüşümü

N örnek sayısı olmak üzere, Eşitlik 3.24 ile tanımlanan ayrık Fourier dönüşümünün doğrudan hesaplanması,

- $2N^2$ adet trigonometrik fonksiyon,
- $4N^2$ adet çarpma,
- $4N(N - 1)$ adet toplama ve
- birçok indeksleme ve adresleme işleminden oluşmaktadır [46].

DFT algoritmasının algoritmik karmaşıklığını indirmek için, bir takım iyileştirmelerle daha etkin hale getirildiği belirli hızlı Fourier dönüşümü (Fast Fourier Transform, FFT) algoritmaları geliştirilmiştir. Bu tez kapsamında yapılan çalışmalarda, Matlab program geliştirme ortamının sunduğu FFT algoritmalarından faydalanılmıştır.

3.3 Doğrusal Zamanda Değişimsiz Sistemler

Sinyal işleme uygulamalarının önemli bir aşaması olan filtre tasarımı, matematik mühendisliğinin bir konusu olan doğrusal zamanda değişimsiz (Linear Time-Invariant, LTI) sistemler teorisi ile incelenmektedir. Bir sistem, fiziksel bir sürecin giriş sinyalini

çıkış sinyaline bağlayan matematiksel bir modeldir [46]. Bir sistemin doğrusal olabilmesi için $x_1(t)$ ve $x_2(t)$ giriş sinyalleri, $y_1(t)$ ve $y_2(t)$ çıkış sinyalleri olmak üzere, sırasıyla Eşitlik 3.29 ve Eşitlik 3.30 ile verilen, toplamsallık ve homojenlik şartlarının sağlanması gerekmektedir.

$$F[x_1(t) + x_2(t)] = F[x_1(t)] + F[x_2(t)] = y_1(t) + y_2(t) \quad (3.29)$$

$$F[ax(t)] = aF[x(t)] = ay(t) \quad (3.30)$$

Bir sistemin zamanda değişimsiz olması için $x(t)$ giriş sinyali, $y(t)$ çıkış sinyali ve t_0 herhangi bir gerçel sabit olmak üzere, Eşitlik 3.31 ile verilen şart sağlanmalıdır.

$$F[x(t - t_0)] = y(t - t_0) \quad (3.31)$$

Sistemlerin farklı koşullarda nasıl çalıştığını tanımlayan, birim darbe cevabı, frekans cevabı ve adım cevabı adı verilen nitelikleri bulunmaktadır. Bir dijital sistemde birim darbe fonksiyonu, Kronecker delta fonksiyonu adı verilen ve $\delta[n]$ ile gösterilen, Eşitlik 3.32 ile tanımlanır.

$$\delta[n] = \begin{cases} 0, & n = 0 \\ 1, & n \neq 0 \end{cases} \quad (3.32)$$

Bir sistemin birim darbe cevabı $h[n]$, sistemin girişine $\delta[n]$ sinyali uygulandığında, çıkışından alınan sinyaldir. Eğer bir sistemin birim darbe cevabı ve giriş sinyali biliniyorsa, çıkış sinyali Eşitlik 3.33'de görüldüğü gibi bu iki sinyalin konvolüsyonu ile bulunabilir [48].

$$y[n] = x[n] * h[n] \quad (3.33)$$

Eşitlik 3.33'e konvolüsyon teoremi uygulanırsa Eşitlik 3.34 elde edilir. Burada $H[\omega]$, birim darbe cevabının Fourier dönüşümüdür ve sistemin frekans cevabı olarak adlandırılır.

$$Y[\omega] = X[\omega]H[\omega] \quad (3.34)$$

Bir sistemin adım cevabı, sistemin girişine Heaviside adım fonksiyonu uygulandığında, filtrenin çıkışından elde edilen sinyaldir. Adım fonksiyonu birim darbe

fonksiyonunun integralidir. Dolayısıyla, adım cevabını bulmanın ikinci bir yolu, birim darbe cevabının integralinin alınmasıdır [50].

Dijital sinyal işleme uygulamalarında kullanılan filtreler, genellikle LTI sistemler olarak modellenmektedir. Dolayısıyla, bir dijital filtrenin karakteristiği, birim darbe cevabı, frekans cevabı ve adım cevabı niteliklerinden en az birinin tanımlanmasıyla belirlenmektedir.

3.4 Dijital Filtreleme

Bir filtre, frekans cevabı $H(\omega)$, yalnızca belirli frekans bantlarında anlamlı değerler alan bir sistemdir [46]. Filtreler frekans seçiciliklerine göre genellikle alçak geçiren, yüksek geçiren, bant geçiren ve bant durduran filtreler olarak sınıflandırılır.


İdeal bir alçak geçiren filtre (AGF), Eşitlik 3.35 ile tanımlanır. Burada t_d , zaman gecikmesini ifade etmektedir.

$$H_{AGF}(\omega) = \begin{cases} e^{-j\omega t_d} & |\omega| \leq \omega_c \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.35)$$

Bir sistemin frekans cevabı, genlik spektrumu ve faz spektrumu adı verilen iki diyagram ile gösterilmektedir. Genlik spektrumu, sinyalin içerdiği farklı frekans bileşenlerinin genliklerini gösterir. Faz spektrumu ise sinyalin içerdiği farklı frekans bileşenlerinin faz kaymalarını gösterir. İdeal bir AGF için genlik ve faz spektrumları sırasıyla Şekil 3.4a ve Şekil 3.4b'de gösterilmektedir. İdeal AGF, giriş sinyalinin ω_c değerinden daha küçük frekanslı bütün bileşenlerini bozulmasız olarak geçirir. Burada ω_c kesim frekansını ifade etmektedir.

İdeal bir yüksek geçiren filtre (YGF), Eşitlik 3.36 ile tanımlanır. İdeal bir YGF, ω_c değerinden küçük frekanslı tüm giriş sinyali bileşenlerini filtreler ve ω_c değerinden büyük frekanslı olanlarını bozulmasız olarak geçirir.

$$H_{YGF}(\omega) = \begin{cases} e^{-j\omega t_d} & |\omega| \geq \omega_c \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.36)$$



Şekil 3.4 İdeal AGF'nin Frekans Cevabı, (a) Genlik Spektrumu, (b) Faz Spektrumu

İdeal bant geçiren filtre (BGF) ve ideal bant durduran filtre (BDF) için frekans cevapları sırasıyla Eşitlik 3.37 ve Eşitlik 3.38 ile verilmektedir.


$$H_{BGF}(\omega) = \begin{cases} e^{-j\omega t_d} & \omega_{c1} \leq |\omega| \leq \omega_{c2} \\ 0 & \text{diğer durumlarda} \end{cases} \quad (3.37)$$

$$H_{BDF}(\omega) = \begin{cases} 0 & \omega_{c1} \leq |\omega| \leq \omega_{c2} \\ e^{-j\omega t_d} & \text{diğer durumlarda} \end{cases} \quad (3.38)$$

Dijital filtreleme, bir sinyalin istenmeyen frekans bileşenlerinin, belirli algoritmalar kullanılarak ortadan kaldırılmasıdır. Bir dijital filtrenin tasarımı aşamasında belirlenmesi gereken parametreler genel olarak, zaman alanı ve frekans alanı parametreleri olarak ikiye ayrılır [50].


3.4.1 Zaman Alanı Parametreleri

Zaman alanı parametreleri, bir filtrenin girişinden verilen adım fonksiyonu sinyali sonucunda ürettiği çıkış sinyalinde görülmek istenen niteliklerdir. Bir filtrenin zaman alanında sahip olması istenen nitelikler genellikle salınımsız, hızlı bir yükselme zamanı ve doğrusal fazdır. Şekil 3.5a'da yavaş bir adım cevabı görülürken, Şekil 3.5b'de hızlı bir adım cevabı görülmektedir. Bir filtrenin adım cevabının, başka bir deyişle yükselme zamanının, Şekil 3.5b'de gösterildiği gibi hızlı olması beklenir. İdeal olarak bir filtrenin yükselme zamanının 0 olması istenir; ancak sinyal kayıt sisteminin dahili kısıtlamaları vb. nedenlerden dolayı çok hızlı bir yükselme zamanı elde etmek oldukça zordur [50].




Şekil 3.5 Adım Cevabı Parametreleri (a) Yavaş Yükselme Zamanı (b) Hızlı Yükselme Zamanı [50]

Adım cevabının salınımsız olması istenmektedir. Şekil 3.6a'da salınımlı bir adım cevabı görülmektedir. Bu salınım neticesinde sinyalin genliğinde, başka bir deyişle zaman domeninde taşıdığı bilgide bozulma meydana geldiği görülmektedir. Bir filtrenin adım cevabında salınım olması durumunda, bu salınımların kaynağının bilinmesi imkansız olacağından, filtrenin Şekil 3.6b'de görüldüğü gibi salınımsız bir adım cevabına sahip olması beklenir [50].



Şekil 3.6 Adım Cevabı Parametreleri (a) Salınımlı Adım Cevabı (b) Salınımsız Adım Cevabı [50]


Bir filtrenin adım cevabının alt yarısı ile üst yarısının genellikle Şekil 3.7b'de gösterildiği gibi simetrik olması istenmektedir. Bu simetri, doğrusal faz olarak adlandırılmaktadır ve sinyal biçiminin bozulmaması için gerekli bir özelliktir [50].



Şekil 3.7 Adım Cevabı Parametreleri (a) Doğrusal Olmayan Adım Cevabı (b) Doğrusal Adım Cevabı [50]


3.4.2 Frekans Alanı Parametreleri

Bir filtrenin frekans spektrumu, Şekil 3.8'de görüldüğü gibi, geçirme bandı, geçiş bandı ve durdurma bandı olarak adlandırılan üç bölgeden oluşmaktadır. Bir filtrenin frekans cevabının, adım cevabında olduğu gibi birtakım niteliklere sahip olması beklenmektedir. Bu nitelikler genellikle dar bir geçiş bölgesi, salınımsız bir geçirme bandı ve durdurma bandında iyi bir zayıflatmadır. Geçirme bandı ve durdurma bandını ayıran frekans değerine kesim frekansı adı verilir.



Şekil 3.8 Frekans Spektrumunun Bölgeleri

Şekil 3.9a'da salınımlı bir geçirme bandı görülmektedir. Böyle bir filtre kullanılması durumunda, geçirme bandındaki frekans bileşenleri sabit bir değer yerine farklı değerlerle çarpılacağından, genliklerinde bozulmalar olacaktır. Şekil 3.9b'de salınımsız bir geçirme bandı görülmektedir. Geçirme bandındaki tüm frekans bileşenleri aynı sabit ile çarpılacağından, sinyalin içerdiği frekans alanı bilgisinde filtre kaynaklı bir bozulma olmayacaktır. Şekil 3.9c düşük bir zayıflatmaya sahip bir durdurma bandını gösterirken; Şekil 3.9d yüksek bir zayıflatmaya sahip bir durdurma bandını göstermektedir. Durdurma bandındaki zayıflatmanın yüksek olması, istenmeyen frekans bileşenlerinin genliklerinin sıfıra yakın değerlerle çarpılarak ihmal edilebilir duruma getirilmesini sağlamaktadır.



Şekil 3.9 Frekans Alanı Parametrelerinin Frekans Spektrumunda Gözlemlenen Etkileri

(a) Salınlı Geçirme Bandı, (b) Salınımsız Geçirme Bandı, (c) Düşük Zayıflatmalı Durdurma Bandı, (d) Yüksek Zayıflatmalı Durdurma Bandı [50]

3.5 Dijital Filtre Tasarım Yöntemleri

Dijital bir filtrenin gerçekleştirilebilmesi için iki yöntem kullanılmaktadır. Daha kolay olan yöntem, filtrenin birim darbe cevabı ile giriş sinyalinin konvolüsyonu sonucunda çıkış sinyalinin elde edilmesidir. Diğer yöntem ise özyineleme kullanarak filtrenin gerçekleştirilmesidir. Konvolüsyon yönteminde filtrenin çıkışı, filtrenin önceki giriş sinyallerine bağlıken; özyineleme yönteminde filtrenin çıkışı, filtrenin önceki giriş ve çıkış değerlerine bağlıdır [50].

Bir özyinelemeli filtrenin birim darbe cevabı, genliği üstel olarak azalan sinüzoid biçimindedir. Dolayısıyla özyinelemeli bir filtrenin itki cevabı hiçbir zaman sıfır olmamaktadır. Bu özelliklerinden dolayı özyinelemeli filtreler sonsuz birim darbe cevablı, (Infinite Impulse Response, IIR) filtreler adı verilmektedir. Konvolüsyon yöntemiyle uygulanan filtrelerin birim darbe cevapları ise sonlu bir zaman içerisinde sıfır olduğundan, bu tür filtreler sonlu birim darbe cevablı (Finite Impulse Response, FIR) filtreler denilmektedir. Genel olarak, FIR filtreler, IIR filtreler göre çok daha iyi performans göstermekle birlikte, daha uzun hesaplama zamanı ve bellek alanı gerektirmektedir [50].

3.5.1 Konvolüsyon Yöntemi ile Filtreleme

Dijital bir sinyal, $\{x[0], x[3], x[1], \dots\}$ biçiminde bir sekans olarak gösterilebileceği gibi $\{x[0]\delta[n], x[3]\delta[n-1], x[1]\delta[n-2], \dots\}$ biçiminde birim darbe fonksiyonları sekansı olarak da gösterilebilmektedir. Giriş sinyalinin birim darbe fonksiyonları biçiminde gösterimi sigma notasyonu ile,

$$x(n) = \sum_{k=0}^{\infty} x(k)\delta(n-k) \quad (3.39)$$

olarak ifade edilir. Doğrusal bir sistemde, $x(0)\delta(n)$ girişine karşılık elde edilen çıkış $x(0)h(n)$ olmalıdır. Ayrıca, zamanda değişimsiz bir sistemde, $x(1)\delta(n-1)$ girişine karşılık elde edilen çıkış $x(1)h(n-1)$ olmalıdır. Dolayısıyla, doğrusal zamanda değişimsiz bir sistemde genel olarak, $x(k)\delta(n-k)$ girişine karşılık elde edilen çıkış

$x(k)h(n-k)$ olarak gösterilir. Bu durumda, Eşitlik 3.39 ile ifade edilen giriş sinyalindeki tüm birim darbelerin, birim darbe cevapları toplamı,

$$y(n) = \sum_{k=0}^{\infty} x(k)h(n-k) \quad (3.40)$$

ile gösterilir. Eşitlik 3.40 konvolüsyon toplamı olarak adlandırılmaktadır ve daha öz bir biçimde, Eşitlik 3.33'de görüldüğü gibi ifade edilmektedir. Bir sistemin birim darbe cevabının bilinmesi durumunda, herhangi bir $x(n)$ sinyali için $y(n)$, konvolüsyon toplamı kullanılarak elde edilebilir [51].

3.5.2 Özyineleme Yöntemi ile Filtreleme


Tasarımında özyineleme algoritması kullanan filtreler, sistemin önceki giriş değerlerine ek olarak, çıkış sinyalinin önceki değerlerinden oluşan bilgiyi de kullanır. Dolayısıyla çıkış sinyali, Eşitlik 3.41 ile verilen özyineleme formülü ile hesaplanır.

$$y[n] = a_0x[n] + a_1x[n-1] + a_2x[n-2] + a_3x[n-3] + \dots \\ + b_1y[n-1] + b_2y[n-2] + b_3y[n-3] + \dots \quad (3.41)$$

Özyineleme formülünde görülen "a" ve "b" değerleri, filtrenin özelliklerini tanımlar ve özyineleme katsayıları olarak adlandırılır. Özyineleme katsayıları ile filtre karakteristiği arasındaki ilişkinin tanımlanmasında, matematiksel olarak z dönüşümü adı verilen yöntem kullanılabileceği gibi temel filtreler için tanımlanan belirli tasarım formülleri de kullanılabilir [51].

Özyineleme yöntemi ile analog filtreler taklit edilebilir. Örneğin Şekil 3.10(a)'da verilen adım sinyaline karşılık, a_0 ve b_1 katsayıları sırasıyla 0.15 ve 0.85 olan bir özyinelemeli filtre tasarımının adım cevabı Şekil 3.10(b)'de görülmektedir. Özyinelemeli filtrenin adım cevabının, 3.10(d) ile gösterilen, birinci derecen bir RC filtrenin adım cevabı ile aynı olduğu görülmektedir.

Özyinelemeli filtrelerin bir diğer özelliği çok fazla matematiksel çarpım ve toplam işlemi gerektiren uzun bir konvolüsyon işlemi yerine daha az matematiksel işlem gerektirmesidir. Şekil 3.10'da da görüldüğü gibi, özyinelemeli filtre sadece iki adet katsayı içermektedir.



Şekil 3.10 Özyinelemeli Filtre ve Elektronik Filtre Karşılaştırması (a) Dijital adım fonksiyonu, (b) Özyinelemeli Filtrenin Adım Cevabı, (c) Analog Adım Fonksiyonu, (d) Elektronik Filtrenin Adım Cevabı [50]

3.6 Beyin Bilgisayar Arayüzü Uygulamalarında Filtreleme

EEG sinyallerini etkileyen gürültü kaynakları iki sınıfta incelenmektedir. EEG sinyalleri, alternatif akım güç kaynakları, sinyallerin kaydında ve görüntülenmesinde kullanılan elektronik cihazlar, ortamda bulunan kablosuz modemler, cep telefonları vb. birçok çevresel faktörden etkilenmektedir. Çevresel gürültünün giderilmesi için, kayıt ortamındaki gerekli olmayan tüm elektromanyetik kaynakların kapatılması ve alternatif akım yerine doğru akım güç kaynaklarının kullanılması gibi önlemler alınabilir. Daha iyi; fakat maliyetli başka bir yöntem ise kayıt ortamının Faraday kafesi ile yalıtılmasıdır.

[52]. EEG sinyallerini etkileyen diğer gürültü kaynakları, kas hareketleri, göz küresi hareketleri, göz kırpması, deri potansiyeli vb. fizyolojik kaynaklardır. Deneklerden, EEG kaydı yapılırken rahat bir pozisyonda oturmaları ve kayıt sırasında hareket etmemeye özen göstermeleri istenerek, kas hareketlerinden kaynaklanan gürültüler azaltılabilmektedir. Göz küresinin hareketi, göz çevresinde elektrookülogram (Electrooculogram, EOG) adı verilen, yüksek genlikli elektriksel potansiyellerin oluşmasına neden olmaktadır. Bu potansiyeller kafatası boyunca yayılarak EEG sinyallerini etkilemektedir [53]. Deneklerden, göz küresinin hareket ettirilmemesi ve kayıt sırasında sadece belirli bir noktaya bakılması istenerek, göz küresi kaynaklı gürültüler de azaltılabilmektedir. Göz kırpması kaynaklı gürültülerin giderilmesi ise oldukça zordur. Çok kısa süreli EEG kayıtlarında, deneklerden göz kırpmamaları istenebilir. Ancak, uzun süreli EEG kayıtlarında göz kırpması kaynaklı gürültü EEG kaydında mutlaka görülmektedir [52].

Ter bezlerinden kaynaklanan iyonik potansiyel, deri potansiyeli adı verilen fizyolojik bir gürültü kaynağıdır. Derinin dış katmanı, elektrotlar ve ter bezleri arasında yalıtkan bir katman olarak kaldığından deri potansiyeli oluşmaktadır. EEG sinyallerinin deri potansiyelinden etkilenmemesi için aşındırıcı jel ve deri altı iğneler kullanılarak, derinin yalıtım özellikli dış katmanının etkisi en aza indirilmektedir [52].

EEG sinyallerini etkileyen gürültüler, ne kadar önlem alınsa da tamamen giderilememektedir. Gürültülü verinin temizlenmesi için en düz yöntem, sinyalin gürültülü kısımlarının çıkarılmasıdır. Bu işlem, gözle inceleme yoluyla veya gürültülü bölgeleri tespit edebilen bir sınıflandırma algoritmasıyla yapılabilmektedir. Göz kırpması ve göz küresi hareketleri, EEG sinyallerinde belirgin olarak görülebilmektedir. Bu durumda, EEG kaydının bir kısmı atılarak, gürültüsüz kısmı incelenmektedir. Ancak, gözle inceleme her zaman güvenilir bir yöntem değildir ve uzun EEG kayıtlarının incelenmesi uzun zaman alabilmektedir. Bir sınıflandırma algoritması da gürültülü EEG bölgelerini, BBA uygulamaları için kabul edilebilir bir zamanda tespit edememektedir. Ayrıca, atılan EEG sinyalleri önemli zaman veya frekans alanı bilgileri içeriyor olabilir ve bu bölgelerin atılması, BBA sisteminin performansını olumsuz yönde etkileyebilir. Bu durumda belirli dijital filtreleme algoritmaları kullanılarak, EEG sinyalleri gürültüden temizlenebilmektedir.



4. SINIFLANDIRMA

Sınıflandırma, istatistikte ve makine öğrenmesinde kullanılan denetimli bir öğrenme biçimidir. Basit bir sınıflandırma örneği, bir grup verinin iki sınıfa ayrılacağı durumdur. Bu durumda, veri ile ilgili bilgiler, bir sınıflandırıcıya girdi olarak verilir ve sınıflandırıcı da bu bilgilerden faydalanarak verinin hangi sınıfa ait olduğunu belirler [54]. Sınıf öğrenme, bir sınıfa ait olan tüm örnekler için geçerli olan ve bu sınıfa ait olmayan örneklerin hiçbiri için geçerli olmayan bir tanımlama bulma işlemidir [54]. BBA uygulamalarında, beyinden elde edilen ve belirli sinyal işleme algoritmaları ile işlenen sinyallerin bir takım özellikleri kullanılarak sınıflandırma yapılmaktadır. Sınıflandırma amacıyla geliştirilen yüzlerce algoritma bulunmaktadır [55]. Bu algoritmaların bazıları doğrusal diskriminant analiz gibi istatistik temelli, bazıları karar ağaçları ve kural tabanlı sınıflandırıcılar gibi veri madenciliği temelli ve bazıları da yapay sinir ağları gibi bağlantısal yaklaşım temelli olabilmektedir [55].

Sınıflandırmanın ilk adımı, sınıflandırılacak veri setinin elde edilmesidir. Örneğin, bu tez çalışmasında kullanılan veri seti beyinden elde edilen elektriksel aktivitedir. Bu veri, bir Emotiv nöro-başlık kullanılarak ölçülmüş ve Bölüm 3.1'de anlatılan temel prensiplere göre dijital olarak bilgisayar ortamına aktarılmıştır.

Bir veri setindeki her bir verinin sahip olduğu özelliklere göre hangi sınıfa ait olması gerektiğini bulan yöntemle sınıflandırıcı denilmektedir [56]. Örneğin mamografik görüntülerden oluşan bir veri setinde, anormal kitle içeren görüntüler pozitif; diğerleri negatif olarak etiketlenmiş olsun. Bir sınıflandırıcının etiketlenmiş görüntülerden elde ettiği bilgiyi kullanarak, etiketlenmemiş bir görüntüyü pozitif ya da negatif olarak sınıflandırması beklenir. Dolayısıyla sınıflandırıcının veri setindeki örneklerin ayırt edici özelliklerini bilmesi gerekmektedir. Eğer bir radyolojist uzmanına danışılırsa, mamografik görüntülerin sınıflandırılmasında en bilgilendirici veya ayırt edici özellikler öğrenilebilir. Ancak her sınıflandırma uygulamasında bir uzmana danışma imkanı bulunmayabilir. Böyle bir durumda brute-force yöntemi kullanılarak sınıflandırmada kullanılması gereken özellikler belirlenmeye çalışılır [56]. Bu tez çalışmasında beyinden elde edilen sinyallerin özelliklerinin belirlenmesinde, geçmiş yıllarda yapılan GUP tabanlı BBA çalışmaları temel alınmıştır [25-27,30-38].

Sınıflandırmanın önemli bir aşaması da sınıflandırıcının seçimidir. Günümüze kadar yüzlerce sınıflandırma yöntemi geliştirilmiştir ve içlerinde hepsinden iyi performans gösteren bir yöntem bulunmamaktadır. Sınıflandırıcının seçimi, geçmiş yıllarda yapılan benzer çalışmalardan faydalanılarak yapılabileceği gibi sezgisel bir şekilde de yapılabilir. Örneğin beyin sinyallerinin sınıflandırılmasında, sezgisel bir yaklaşımla Yapay Sinir Ağları yöntemi kullanılabilir.

Sınıflandırma sürecinin son aşaması, sınıflandırıcının performansının değerlendirilmesidir. En sık kullanılan değerlendirme kriteri, doğru tahmin sayısının toplam tahmin sayısına oranından elde edilen doğruluk kriteridir. Bir sınıflandırıcının doğruluğunu ölçmek için kullanılan üç teknik bulunmaktadır [56]. Bu tekniklerden biri, veri setindeki örneklerin %70'inin sınıflandırıcının eğitiminde, %30'unun performans değerlendirmesinde kullanılmasıdır. Sınıflandırıcı doğruluğunun ölçülmesinde kullanılan diğer bir teknik çapraz doğrulama olarak adlandırılmaktadır. Çapraz doğrulama tekniğinde öncelikle veri seti eşit boyutta alt setlere ayrılır ve her bir alt set için diğer tüm alt setler sınıflandırıcının eğitiminde kullanılır. Dolayısıyla tüm alt setlerin hata oranlarının ortalaması sınıflandırıcının hata oranını vermektedir. Üçüncü bir teknik ise çapraz doğrulamanın özel bir durumu olan, tüm alt setlerin veri setindeki tek bir örnekten oluştuğu Leave-One-Out tekniğidir [56]. Bu tez çalışmasında, sınıflandırıcı performansının değerlendirilmesinde, aşırı uygunluktan kaçınmak için de kullanılmasından dolayı çapraz doğrulama tekniği kullanılmıştır.

Bu bölümde sınıflandırma problemlerinde sınıflandırıcıların seçimine etki eden etmenler, bu tez çalışmasında kullanılan sınıflandırıcılar, özellik seçimi ve çapraz doğrulama tekniği ile ilgili temel bilgiler verilmektedir.

4.1 Sınıflandırıcı Seçimi

Sınıflandırma yöntemlerinin seçimi ile ilgili geçmiş yıllarda yapılan bir takım çalışmalar bulunmaktadır [55,56]. *Delgado ve ark.* 17 sınıflandırıcı ailesine ait 179 farklı yöntemi, UCI (University of California, Irvine) Makine Öğrenmesi Arşivinden elde ettikleri 121 veri seti üzerinde uygulamışlardır [55]. Yaptıkları çalışmada tüm veri setleri üzerinde en iyi doğruluk oranlarına sahip olan sınıflandırıcı ailelerinin sırasıyla, Random Forest (RF), Destek Vektör Makinesi (DVM) ve Yapay Sinir Ağı (YSA)

olduğu sonucuna varmışlardır. Başka bir çalışmada *Kotsiantis* farklı sınıflandırıcıların performanslarını doğruluk ve belirli başka kriterlere göre de değerlendirdiği bir çalışma yapmıştır [56]. Her bir kriter için sınıflandırıcılara 4 üzerinden puan vermiştir. Yaptığı çalışmada kullandığı kriterlere göre en iyi üç sınıflandırıcının, Tablo 4.1'de görüldüğü üzere sırasıyla, DVM, YSA ve Karar Ağacı (KA) olduğu görülmektedir.

Tablo 4.1 Sınıflandırıcıların Belirli Kriterlere Göre Performansları [56]

	KA	YSA	Naive Bayes	kEYK*	SVM	Kural Tabanlı
Genel Doğruluk	2	3	1	2	4	2
Sınıflandırma Hızı	4	4	4	1	4	4
İlgisiz Özelliklere Tolerans	3	1	2	2	4	2
Gereksiz Özelliklere Tolerans	2	2	1	2	3	2
Birbirlerine Bağlı Özelliklere Tolerans	2	3	1	1	3	2
Gürültüye Tolerans	2	2	3	1	2	1
Aşırı Uygunluktan Kaçınma	2	1	3	3	2	2
Toplam	17	16	15	12	22	15

*kEYK (k En Yakın Komşu)

Farklı özelliklerdeki veri setleri üzerinde yapılan, genel sınıflandırıcı performans analizi çalışmalarına ek olarak BBA verileri üzerinde sınıflandırıcı performanslarının incelendiği çalışmalar da bulunmaktadır. Genel olarak, BBA çalışmaları için ortak kabul gören yüksek üstünlüklü bir sınıflandırıcı olmamakla birlikte literatürde en çok kullanılan yöntemlerin, YSA, DVM, Naive Bayes ve kEYK olduğu gözlemlenmektedir [2,57,58].

4.1.1 Özellik Seçimi

Doğru sınıflandırıcının seçilmesi için dikkate alınması gereken önemli bir konu da özellik seçimidir. Sınıflandırıcılar, sinyallerin belirli özelliklerinden oluşan bir özellik vektörü kullanarak işlem yapar. Dolayısıyla bir EEG sinyalinin hangi özelliklerinin ne amaçla kullanıldığını bilmek, sınıflandırıcının seçiminde önemli rol oynamaktadır. BBA uygulamalarında özellik seçiminde karşılaşılan en önemli problemlerden biri çok boyutluluktur. Bir uygulamada sınıf sayısı arttıkça, her bir sınıfı tanımlamak için kullanılan ayırt edici özelliklerin sayısı da artacağından, sınıflandırıcı performansı zayıflamaktadır. Diğer bir deyişle özellik sayısı arttıkça sınıflandırıcı performansı düşmektedir. Özellikle, örnek sayısının, özellik vektörünün boyutuna oranla küçük olduğu durumlarda çok boyutluluk problemi artmaktadır ki genellikle BBA uygulamalarında örnek sayısı azken, özellik vektörünün boyutu büyük olmaktadır [57].

4.1.2 Bias - Varyans İkilemi

Sınıflandırma algoritmaları, kararlı ve kararsız olmak üzere iki farklı grupta incelenmektedir. KEYK benzeri kararlı sınıflandırıcılar basit yapıdadır ve eğitim setindeki ufak değişiklikler, sınıflandırıcının performansında büyük değişikliklere neden olmamaktadır. Diğer taraftan YSA gibi kararsız algoritmalar karmaşık yapıdadır ve eğitim setindeki ufak değişiklikler, sınıflandırıcının performansında önemli değişimlere yol açabilmektedir [57].

Sınıflandırma, özellik vektörleri kullanılarak yapılan bir ölçme işlemidir. Sınıflandırıcı, eğitim seti ile öğrendiği bir eşleştirme fonksiyonu kullanarak, özellik vektörleri için en iyi eşleşmeyi bulan yöntemdir; ancak en iyi eşleştirmeyi yapan fonksiyon bilinmemektedir. f eşleştirme fonksiyonu ve x özellik vektörü olmak üzere, sınıflandırma işleminin ortalama karesel hatası (OKH), Eşitlik 4.1'de görüldüğü gibi üç kısım içermektedir [57].

$$OKH = Gürültü^2 + Bias(f(x))^2 + Varyans(f(x)) \quad (4.1)$$

Gürültü sistemden kaynaklanan, giderilemez hatadır. Bias, tahmin edilen eşleştirme ile en iyi eşleştirme arasındaki farkı ifade etmektedir. Varyans ise kullanılan


eđitim setine olan hassasiyeti gsteren ifadedir. En iyi sınıflandırma performansı iin bias ve varyans mmkn olan en dřk deęerlerde tutulmalıdır. Ancak her iki hatayı da en az yapan bir yntem bulunmamaktadır. Kararlı sınıflandırıcılar yksek bias ve dřk varyans deęerlerine sahipken, kararsız sınıflandırıcılar dřk bias ve yksek varyans deęerlerine sahiptir. *Lotte ve ark.* farklı oturumlarda kaydedilen EEG sinyalleri olduka byk farklar gsterdięinden, daha iyi bir sınıflandırma performansı iin dřk varyanslı sınıflandırıcıların kullanılmasını nermiřlerdir [57].

4.2 Yapay Sinir Aęları

Hodgkin ve Huxley 1952 yılında, nronlarda aksiyon potansiyelin tetiklenmesinin ve yayılmasının altında yatan iyonik deęiřimleri aıklayan, kondktans temelli bir matematiksel model geliřtirmiřlerdir [59]. Bu tarihten itibaren yapılan, nronların matematiksel modellerine dayanan alıřmalar ve bilgisayar teknolojisindeki geliřmeler sonucunda, insan beyninin ęrenme, iliřkilendirme ve sınıflandırma yeteneklerini taklit eden algoritmalar geliřtirilmiřtir [60]. Bu tr algoritmalar Yapay Sinir Aęları (YSA) olarak adlandırılmaktadır. Geliřtirilen ilk YSA yntemine, Trkeye algılayıcı olarak evrilebilecek, perceptron adı verilmiřtir. Perceptron, 1958 yılında Frank Rosenblatt tarafından geliřtirilmiřtir [61]. Bu tarihten itibaren, LVQ (Learning Vector Quantization), SOM (Self-Organizing Maps), RBFN (Radial Basis Function Networks), PNN (Probabilistic Neural Networks) vb. birok YSA modeli geliřtirilmiřtir [60].

4.2.1 Perceptron

Perceptron yapay sinir aęlarında kullanılan temel iřlem nitesidir. Bir perceptron nitesinin yapısı řekil 4.1'de grlmektedir. Giriřler, aęın dıřından ya da aędaki dięer perceptron nitelerinden gelen sayısal bilgileri ifade etmektedir. Aęrılıklar, gelen giriř bilgisinin nemini gstermektedir. Bir perceptron nitesinin net giriři, her bir giriřin kendi aęrılık deęeriyle arpımı ve tm giriř deęerleri iin elde edilen bu arpım deęerlerinin toplamından elde edilmektedir. Aktivasyon fonksiyonu, hesaplanan net giriřin belirli bir deęerin zerinde olduęu durumlarda ıkıř retir.



Şekil 4.1 Temel Yapay Sinir Ağı Ünitesi Perceptron

Şekil 4.1'de görülen perceptron matematiksel olarak,

$$y = \sum_{i=1}^n w_i x_i + b \quad (4.2)$$

biçiminde ifade edilir [54]. Bu eşitlikte y çıkış değerini, " w " ağırlık değerlerini, " x " giriş değerlerini ve " b " eşik değeri ya da diğer adıyla bias değerini ifade etmektedir. Eşitlik 4.2'nin aslında, doğrusal bir fonksiyonun ifadesi olan $ax+b$ biçiminde olduğu görülmektedir. Dolayısıyla perceptron, doğrusal bir sınıflandırma işleminde kullanılabilir.

Perceptron ayrıca matris formunda,


$$y = \mathbf{w}^T \mathbf{x} \quad (4.3)$$

biçiminde ifade edilir [54]. Bu eşitlikte $\mathbf{w}=[w_0, w_1, \dots, w_n]^T$ ve $\mathbf{x}=[x_0, x_1, \dots, x_n]^T$ sırasıyla ağırlık ve giriş vektörlerini ifade etmektedir. Matris formunda w_0 girişi, bias olarak kullanılır. Eşitlik 4.3 giriş uzayını iki parçaya ayıran bir düzlem oluşturur. Eğer Eşitlik 4.4 ile gösterildiği gibi bir $s(\cdot)$ eşik fonksiyonu tanımlanırsa, giriş uzayını ikiye bölen düzlemin oluşturduğu sınıflar Eşitlik 4.5'de gösterildiği gibi seçilebilir [54].

$$s(a) = \begin{cases} 1 & a > 0 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (4.4)$$


$$Se\check{c} \begin{cases} C_1 & s(\mathbf{w}^T \mathbf{x}) > 0 \\ C_2 & \text{diğer durumlarda} \end{cases} \quad (4.5)$$

Şekil 4.1'de görüldüğü üzere en sade aktivasyon fonksiyonu, adım fonksiyonudur. Adım fonksiyonu, Şekil 4.2(a) ve benzeri doğrusal olarak sınıflandırılabilen veri setlerinde başarılı sonuçlar vermektedir. Ancak Şekil 4.2(b)'de görüldüğü gibi doğrusal olarak sınıflandırılmayan veri setlerinde başarılı olamamaktadır. Şekil 4.2'de görülen siyah ve beyaz noktalar, bir veri setindeki iki ayrı sınıfa ait örnekler olarak düşünüldüğünde, Şekil 4.2(a)'da görülen verileri ayırt edebilen doğrusal bir fonksiyon bulunurken; Şekil 4.2(b)'de görülen verileri doğrusal olarak ayırt edebilecek bir fonksiyon bulunmamaktadır.




Şekil 4.2 (a) Doğrusal Sınıflandırılabilen ve (b) Doğrusal Sınıflandırılmayan Veri Setlerinin Geometrik Gösterimi

Doğrusal olarak ayırt edilemeyen problemler, iki katmanlı perceptron ağı ya da diğer adıyla iki katmanlı ileri beslemeli yapay sinir ağı kullanılarak çözülebilmektedir [62]. Birinci katman, Şekil 4.3(a)'da görüldüğü gibi verileri doğrusal olarak ayırt edilebildikleri farklı bir düzleme geçirir. İkinci katman ise Şekil 4.3(b)'de görüldüğü gibi bu yeni düzlem üzerindeki verileri doğrusal bir fonksiyonla sınıflandırır.



Şekil 4.3 İki Katmanlı Perceptron ile Çözülen Bir Sınıflandırma Probleminin Geometrik Gösterimi, (a) Birinci Katman ve (b) İkinci Katman

Şekil 4.4'de, Şekil 4.3 ile geometrik gösterimi verilen iki katmanlı perceptron ağının yapısı görülmektedir. İlk katmanda bulunan iki perceptron ünitesi, x_1 ve x_2 girişlerinden elde edilen değerleri kullanarak, $g_1(x)$ ve $g_2(x)$ fonksiyonlarını hesaplar ve gizli katman olarak adlandırılır. İkinci katmanda bulunan perceptron ise ilk katmandan elde edilen değerleri kullanarak, giriş uzayındaki verileri doğrusal olarak ayıran $f(g_1(x), g_2(x))$ fonksiyonunu hesaplar ve çıkış katmanı olarak adlandırılır [62].



Şekil 4.4 İki Katmanlı Bir Perceptron Ağının Yapısı

4.2.2 Yapay Sinir Ağı Modelleri ve Eğitimi

Günümüzde onlarca farklı YSA modeli bulunmakta ve bu sayı her geçen gün artmaktadır. Bütün YSA modelleri, bir araya getirilmiş perceptron ünitelerinden oluşmaktadır. Bir YSA modelini diğer modellerden farklı kılan ise modelin sahip olduğu ağ mimarisi ve modelin eğitim aşamasında kullanılan öğrenme stratejisidir. Ağ mimarisi, ağı oluşturan hücrelerin diziliş düzeni ve hücrelerin birbiriyle olan bağlantı şeklidir. Ağ içindeki bilgi akışı bu bağlantılar üzerinden tek yönlü veya iki yönlü yapılabilmektedir. Tek yönlü bilgi akışına izin veren ağ yapıları ileri beslemeli; iki yönlü bilgi akışına izin veren ağ yapıları ise geri beslemeli ağlar olarak adlandırılmaktadır [60].

Öğrenen bir sistem, değişen çevresel şartlara uyum sağlayabilecek biçimde kendini değiştirme yeteneğine sahiptir. Teorik olarak, bir YSA sistemi aşağıda listelenen yöntemleri kullanarak öğrenebilir [63].

- Yeni bağlantılar geliştirmek,
- Var olan bağlantıları silmek,
- Bağlantı ağırlıklarını değiştirmek,
- Eşik (bias) değerlerini değiştirmek,
- Farklı aktivasyon fonksiyonları kullanmak,
- Yeni nöronlar (perceptron üniteleri) geliştirmek ve
- Var olan nöronları silmek.

YSA eğitiminde en sık kullanılan yöntem ağırlık değerlerinin değiştirilmesidir. Bir yapay sinir ağında, yeni bağlantı geliştirmek ya da var olan bağlantıları silmek, bağlantı ağırlıklarının değiştirilmesiyle kolaylıkla gerçekleştirilebilir. Örneğin, bir nöronun ağırlık değeri 0 olan bağlantıları, silinen bağlantılar olarak düşünülebilir. Benzer şekilde, başlangıçta ağırlık değeri 0 olan bağlantılara yeni ağırlık değerleri atanarak, yeni bağlantılar geliştirilebilir. Bir nöronun eşik değerinin değiştirilmesi ise nöronun giriş değerlerinden birinin eşik değeri olarak kullanılması ve bu girişin ağırlığının değiştirilmesi ile sağlanabilir [63]. Görüldüğü üzere bir YSA eğitiminde, yukarıda listelenen maddelerden ilk dördünün uygulamada kolaylıkla gerçekleştirilebildiği anlaşılmaktadır. Diğer taraftan, aktivasyon fonksiyonlarının değiştirilmesi, uygulamada problem yaratabileceğinden dolayı tercih edilmeyen bir eğitim yöntemidir [63]. Dolayısıyla YSA modelinin eğitiminde, başlangıçta belirlenen aktivasyon fonksiyonu değiştirilmemektedir. Bir ağın eğitiminin büyük bir kısmı, sadece ağırlık değerlerinin değiştirilmesiyle sağlanabildiğinden dolayı, ağ topolojisini değiştiren, yeni nöronların eklenmesi veya var olan nöronların silinmesi, YSA eğitiminde öncelikle tercih edilen yöntemlerden değildir [63].

4.2.3 Geri Yayılım Algoritması

Geri yayılım, yapay sinir ağlarının denetimli eğitiminde en sık kullanılan yöntemdir [64]. Eğitim aşamasında, bir ağın çıkışından elde edilen değerler ile istenen değerler arasındaki fark ağ boyunca geriye yayılarak, nöronların ağırlık değerlerinin değiştirilmesinde kullanılır. Oluşan fark, bir maliyet fonksiyonunu minimize edecek şekilde ağın ağırlık değerlerini değiştirmektedir. Yapay sinir ağlarının eğitiminde en sık

kullanılan maliyet fonksiyonu, eşitlik 4.6'da tanımlanan toplam karesel hata fonksiyonudur.

$$J(\mathbf{w}) = \frac{1}{2}(\mathbf{t} - \mathbf{z})^2 \quad (4.6)$$

Burada " $\mathbf{t}$ " istenen sonuç vektörünü, " $\mathbf{z}$ " çıkış vektörünü ve " $\mathbf{w}$ " ağırlık vektörünü ifade etmektedir. Genel olarak, geri yayılım algoritmasının maliyet fonksiyonunun optimizasyonunda, azalan gradyan algoritması kullanılmaktadır. Gadyan, iki veya daha fazla değişkene göre tanımlanmış fonksiyonların türevi olarak tanımlanır. Çok katmanlı perceptron mimarisi, McCulloch-Pitts nöron modeli temel alınarak geliştirilmiştir ve aktivasyon fonksiyonu olarak adım fonksiyonunu kullanmaktadır [62]. Adım fonksiyonu süreksizlik içerdiği için türevlenemez bir fonksiyondur. Dolayısıyla, çok katmanlı YSA mimarilerinde aktivasyon fonksiyonu olarak türevlenebilir fonksiyonlar kullanılmaktadır. Yapay sinir ağlarında en sık kullanılan aktivasyon fonksiyonları, hiperbolik tanjant, ters tanjant ve lojistik fonksiyon gibi sigmoid fonksiyonlardır.

Geri yayılım algoritması tüm ağırlıklara rastgele başlangıç değerleri verir ve eğitim süresince istenen ve elde edilen değerler arasındaki farktan kaynaklanan hatayı ağ boyunca tüm nöronlara yayarak, Eşitlik 4.7'de gösterildiği gibi ağırlık değerlerini günceller [64].

$$w(\text{yeni}) = w(\text{eski}) + \Delta w(\text{eski}) \quad (4.7)$$


Burada Δw , azalan gradyan yöntemiyle hesaplanan ağırlık düzeltme değerleridir ve Eşitlik 4.8 ile ifade edilmektedir [64].

$$\Delta w = -\eta \frac{\partial J}{\partial w} \quad (4.8)$$

Eşitlik 4.8'de görülen η , öğrenme oranını ifade etmektedir. Öğrenme oranı çok küçük seçildiğinde, karesel hata fonksiyonunun minimumuna yakınsamak uzun zaman almaktadır. Diğer taraftan büyük bir öğrenme oranı seçilirse, hata fonksiyonunun minimumunun bulunması mümkün olmamaktadır.

4.3 Destek Vektör Makineleri

Destek vektör makineleri, Vladimir Vapnik ve Alexey Chervonenkis tarafından geliştirilen, sınıflandırma ve regresyon analizinde kullanılan bir denetimli öğrenme modelidir. Perceptron algoritmasında olduğu gibi doğrusal ya da doğrusal olmayan bir fonksiyon yardımıyla sınıflandırma yapmaktadır. Ancak, perceptron algoritmasından farklı olarak, veri setini ayıran sonsuz sayıda fonksiyon içerisinde, optimum fonksiyonun tahmin edilmesi esasına dayanmaktadır [65]. Şekil 4.5'de veri setini iki sınıfa ayıran üç fonksiyon görülmektedir. Perceptron, bu üç fonksiyondan herhangi birine yakınsayabilir. Ancak, Şekil 4.5'te görüldüğü üzere veri setini en iyi biçimde ikiye bölen fonksiyon düz çizgi ile gösterilen fonksiyondur.



Şekil 4.5 Giriş Uzayını İkiye Ayıran Optimum Fonksiyon

Şekil 4.5'de görüldüğü gibi veri setini en uygun biçimde ayıran fonksiyon ya da geometri terminolojisi ile hiper-düzlem, her iki sınıfa da maksimum uzaklıkta olmalıdır. Marjin olarak adlandırılan bu maksimum uzaklık, hiper-düzleme en yakın olan veri örneklerinden belirlenir. Belirlenen örnekler destek vektörler olarak adlandırılır. Destek vektör makinelerinde karşılaşılabilecek iki durum, verilerin doğrusal olarak ayrılabilen bir yapıda olması veya doğrusal olarak ayrılamayan bir yapıda olmasıdır. Doğrusal olarak ayrılabilen veriler arasında maksimum sınır doğrudan bulunabilirken; doğrusal olarak ayrılamayan veriler öncelikle doğrusal olarak ayrılacakları farklı bir uzaya aktarılmalıdır [65].

4.3.1 Doğrusal Olarak Ayrılabilen Sınıflandırma Durumu

$X = \{\mathbf{x}^t r^t\}$, bir veri setindeki, $\mathbf{x}^t \in C_1$ ise $r^t = +1$ ve $\mathbf{x}^t \in C_2$ ise $r^t = -1$ olarak etiketlenmiş bir örneği ifade etmek üzere, pozitif ve negatif örnekleri ayıran bir hiper-düzlem bulunduğu durumda, doğrusal sınıflandırıcı, hiper-düzlemin normal vektörü $\mathbf{w}$ ve bias değeri w_0 ile tanımlanır. Bu durumda $\mathbf{w}$ ve w_0 değerleri Eşitlik 4.9 ve 4.10 ile hesaplanabilir [54].

$$r^t = +1 \text{ için } \mathbf{w}^T \mathbf{x}^t + w_0 \geq +1 \quad (4.9)$$

$$r^t = -1 \text{ için } \mathbf{w}^T \mathbf{x}^t + w_0 \leq -1 \quad (4.10)$$

Eşitlik 4.9 ve Eşitlik 4.10

$$r^t(\mathbf{w}^T \mathbf{x}^t + w_0) \geq +1 \quad (4.11)$$

biçiminde yazılabilir. Diskriminant ile $\mathbf{x}^t$ arasındaki uzaklık,

$$\frac{|\mathbf{w}^T \mathbf{x}^t + w_0|}{\|\mathbf{w}\|} \quad (4.12)$$

olduğundan, $r^t \in \{-1, +1\}$ için uzaklık,

$$\frac{r^t(\mathbf{w}^T \mathbf{x}^t + w_0)}{\|\mathbf{w}\|} \quad (4.13)$$

olarak tanımlanır. Burada uzaklık değerinin, Eşitlik 4.14'de ifade edildiği gibi en az ρ gibi bir değer alması istenmektedir.


$$\frac{r^t(\mathbf{w}^T \mathbf{x}^t + w_0)}{\|\mathbf{w}\|} > \rho, \forall t \quad (4.14)$$

ρ değerini maksimum yapan, $\mathbf{w}$ değerlerinin değiştirilmesiyle elde edilebilecek sonsuz sayıda çözüm bulunmaktadır. Eşsiz bir çözüm için $\rho\|\mathbf{w}\| = 1$ olarak sabitlenirse, $\|\mathbf{w}\|$ değerini minimum yapan değer, uzaklığı maksimum yapar. Bu durumda sınıflandırma problemi Eşitlik 4.15'de görüldüğü biçimde ifade edilebilir [54].

$$r^t(\mathbf{w}^T \mathbf{x}^t + w_0) \geq +1, \forall t \text{ olmak üzere,}$$

$$\text{minimum } \frac{1}{2} \|\mathbf{w}\|^2 \quad (4.15)$$

Eşitlik 4.15 çözüldüğünde, toplam marjın $2/\|\mathbf{w}\|$ olacak şekilde veri setini iki sınıfa ayıran doğrusal fonksiyon, Şekil 4.6'da görüldüğü gibi elde edilmektedir [54].



Şekil 4.6 Toplam Marjini $2/\|\mathbf{w}\|$ Yapan Optimal Hiper-düzlem [54]

Eşitlik 4.15'de görüldüğü üzere, $\|\mathbf{w}\|$ değerini minimum yapmak aynı zamanda marjini maksimum yapmak anlamına gelmektedir. Eşitlik 4.15'i minimum yapan değer, Eşitlik 4.16 ve Eşitlik 4.17 ile tanımlanan Karush-Kuhn-Tucker şartlarını sağlamalıdır [54].

$$\frac{\partial L(\mathbf{w}, w_0, \alpha)}{\partial \mathbf{w}} = 0 \quad \rightarrow \quad \mathbf{w} = \sum_t \alpha^t r^t \mathbf{x}^t \quad (4.16)$$

$$\frac{\partial L(\mathbf{w}, w_0, \alpha)}{\partial w_0} = 0 \quad \rightarrow \quad \sum_t \alpha^t r^t = 0 \quad (4.17)$$

Burada α , Lagrange çarpanlarını, $L(\mathbf{w}, w_0, \alpha)$ ise Eşitlik 4.18'de tanımlanan Lagrangian fonksiyonunu ifade etmektedir [62].

$$L(\mathbf{w}, w_0, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_t \alpha^t [r^t (\mathbf{w}^T \mathbf{x}^t + w_0) - 1] \quad (4.18)$$

Eşitlik 4.16 ve Eşitlik 4.17, Eşitlik 4.18'de yerlerine yazılarak düzenlendiğinde, optimizasyon problemi,

$$\sum_t \alpha^t r^t = 0 \text{ ve } \alpha^t \geq 0, \forall t \text{ olmak üzere,}$$

$$\max_{\alpha} \left(\sum_t \alpha^t - \frac{1}{2} \sum_t \sum_s \alpha^t \alpha^s r^t r^s (\mathbf{x}^t)^T \mathbf{x}^s \right) \quad (4.19)$$

biçimine dönüşmektedir [62]. Eşitlik 4.19 ile tanımlanan maksimizasyon problemi ile optimum Lagrangian çarpanları hesaplandıktan sonra, optimum hiper-düzlemin sabitleri $\mathbf{w}$ ve w_0 sırasıyla, Eşitlik 4.16 ve Eşitlik 4.20 kullanılarak hesaplanabilir.

$$w_0 = r^t - \mathbf{w}^T \mathbf{x}^t \quad (4.20)$$

4.3.2 Doğrusal Olarak Ayrılamayan Sınıflandırma Durumu


Şekil 4.7'de görüldüğü gibi iki sınıfa ayrılamayan bir veri setinde, iki sınıfı en az hatayla ayıran hiper-düzlem bulunmaya çalışılır. Bunu sağlamak için Eşitlik 4.21'de görülen, Eşitlik 4.15'in, ξ ile ifade edilen yapay bir değişken ile değiştirilmiş biçimi kullanılır.

$$r^t(\mathbf{w}^T \mathbf{x}^t + w_0) \geq 1 - \xi^t, \forall t \text{ olmak üzere,}$$

$$\text{minimum } \frac{1}{2} \|\mathbf{w}\|^2 + c \sum_t \xi^t \quad (4.21)$$

Burada $\sum_t \xi^t$, geçici hatayı ve "c", marjinin büyüklüğü ile ξ arasında belirlenmiş, ceza faktörünü ifade etmektedir. Geçici hatalı hiper-düzlem ile yapılan bir sınıflandırma sonucunda, Şekil 4.7'de gösterildiği gibi üç farklı durum oluşmaktadır. Birinci durumda (1), $\xi = 0$ olduğu için örnek, hiper-düzlemin doğru tarafında ve hiper-düzlemden gerekli uzaklıktadır. İkinci durumda (2), $\xi > 1$ olduğu için örnek, hiper-düzlemin yanlış tarafındadır. Son olarak üçüncü durumda (3), $0 < \xi < 1$ olduğu için

örnek, hiper-düzlemin doğru tarafındadır; ancak hiper-düzlemden gerekli uzaklıkta değildir [66].



Şekil 4.7 Doğrusal Olarak Ayrılamayan Veri Seti [66]

Doğrusal olarak ayrılamayan verilerin sınıflandırılmasında kullanılan ikinci bir yöntem daha bulunmaktadır. Veriler doğrusal olmayan bir fonksiyon kullanılarak, doğrusal olarak ayrılabilirler başka bir uzaya geçirilir. Bu işleme özellik eşleştirme adı verilmektedir. Özellik eşleştirme yönteminde, giriş uzayı, eşleştirme fonksiyonu adı verilen ve $\phi(\cdot)$ ile gösterilen bir fonksiyon kullanılarak, daha yüksek boyutlu bir özellik uzayına dönüştürülür [66]. Dolayısıyla özellik uzayında, giriş uzayına ek olarak fazladan boyut veya boyutlar bulunur.

d-boyutlu bir x uzayı, k-boyutlu bir z uzayına dönüştürüldüğünde diskriminant,

$$g(x) = \mathbf{w}^T \mathbf{z} = \mathbf{w}^T \boldsymbol{\phi}(x) = \sum_{j=1}^k w_j \phi_j(x) \quad (4.22)$$

eşitliği ile ifade edilir [54]. $\boldsymbol{\phi}(x)$ eşleştirme fonksiyonlarının değerleri çekirdek fonksiyonları ile hesaplanır. En sık kullanılan çekirdek fonksiyonlar; radyal, polinomial ve sigmoid fonksiyonlarıdır [54].

4.3.3 Çok Sınıflı Destek Vektör Makineleri


Destek vektör makineleri yöntemi, maksimum marjin kriterine göre ikili sınıflandırma yapmak üzere tasarlanmıştır. Ancak uygulamada çoğu zaman ikiden fazla sınıf için diskriminant hesaplanması gerekmektedir. Bu durumda, orijinal DVM yönteminin çok sınıflı durumları da kapsayacak şekilde genelleştirilmesi ihtiyacı doğmuştur. Üç veya daha fazla sınıf içeren durumlarda, sınıflandırma problemi bir dizi ikili sınıflandırma problemine ayrıştırılarak, her bir ikili probleme DVM yöntemi uygulanmaktadır. Bu yöntemde, bire-bir ve bire-çok olarak adlandırılan iki farklı yaklaşım kullanılmaktadır. Bu iki yaklaşım dışında, sınıflandırma problemini ayrıştırma yapmadan çözmek için geliştirilen yöntemler de bulunmaktadır. Ancak çoklu sınıflandırma probleminin doğrudan çözümü için geliştirilen DVM modelleri, bire-bir ve bire-çok yöntemlerine göre oldukça yüksek işlemsel karmaşıklığa sahip oldukları için genellikle tercih edilmemektedir [67].

Bire-çok yönteminin eğitim aşamasında, sırasıyla her bir sınıf pozitif, diğer tüm sınıflar negatif olarak belirlenir ve k sınıflı bir problem için k adet diskriminant oluşturulur. Bir örneğin ait olduğu sınıf ise en yüksek çıkış değerini veren diskriminant ile belirlenir. Diğer taraftan bire-bir yönteminde, k adet sınıftan, olası tüm ikili sınıflar ayrıştırılarak, $k(k - 1)/2$ adet diskriminant bulunur. Bir örneğin ait olduğu sınıf ise oylama işlemi ile belirlenir. Her sınıflandırıcı bir örneğe uygulanarak, kazanan sınıfa bir oy verilir. Bir test örneği en çok oy aldığı sınıfa etiketlenir [67].

Bire-çok yönteminde diskriminant sayısı, bire-bir yöntemine göre oldukça fazladır. Diğer taraftan bire-bir yöntemi daha düşük bir işlemsel karmaşıklığa sahiptir. Bununla birlikte, *Platt ve ark.* Yönlü-Düz-Graf DVM (Directed Acyclic Graph SVM, DAGSVM) adını verdikleri bir çok sınıflı DVM modeli geliştirmişlerdir [64]. Bu model, bir örneğin ait olduğu sınıfın bulunması için sadece $k - 1$ adet hesaplama gerektirmektedir. *Hsu ve ark.* çok sınıflı DVM modellerinin performanslarını karşılaştırdıkları çalışmalarında, bire-bir DVM ve Yönlü-Düz-Graf DVM yöntemlerinin en iyi sonuçları verdiğini bildirmişlerdir [68].

4.5 k-Parçalı Çapraz Doğrulama Yöntemi

Yeterince büyük bir veri seti, verilerin %70'i ya da daha fazlası eğitim amaçlı, geri kalan kısmı ise test amaçlı kullanılacak şekilde iki parçaya ayrılarak, sınıflandırıcının performansı değerlendirilebilir. Ancak, genellikle veri setleri bu işlemi gerçekleştirebilmek için yeterince büyük değildir. K-Parçalı çapraz doğrulama adı verilen yöntemle, bir veri seti rastgele k eşit parçaya bölünür. Bu parçalardan bir tanesi test seti; diğer k-1 adet parça eğitim seti olarak kullanılır. Bu işlemin Şekil 4.8'de görüldüğü gibi k defa tekrarlanması ile k adet eğitim/test seti elde edilir [54]. Çapraz doğrulama yoluyla elde edilen k adet test verisinin ortalamasından sınıflandırıcının performans göstergeleri elde edilmektedir.



Şekil 4.8 k=4 için k-Katlı Çapraz Doğrulama Blok Şeması




5. DENEYLER VE BULGULAR

Bu tez kapsamında yapılan çalışmaların genel çerçevesi Şekil 5.1'de görülmektedir. BBA, görsel uyaran için geliştirilen program, EEG sinyallerinin ölçümü için kullanılan cihaz ve elde edilen ham verinin analizi için geliştirilen yazılımdan oluşan üç ana kısım içermektedir. GUP temelli bir çalışma için öncelikle beynin oksipital lobunda gerekli elektriksel aktiviteyi tetikleyecek şekilde farklı frekanslarda titreşen uyarlardan oluşan bir program yazma ihtiyacı oluşmuştur. İkinci aşamada, GUP uyaran programıyla paralel olarak çalışan ve denek ile uyaran programın etkileşimi sonucunda beyinde oluşan aktivite, sinyal işleme ve yapay öğrenme yöntemleriyle analiz edilmiş ve sınıflandırıcı performansları kaydedilmiştir. Bu bölümde Şekil 5.1'de gösterilen aşamalar açıklanmakta ve deneylerde elde edilen bulgular paylaşılmaktadır.

5.1 Emotiv Nöro-Başlık

Emotiv nöro-başlık, EEG tabanlı BBA uygulamalarında kullanılmak üzere tasarlanmış bir kayıt cihazıdır. Bu tez çalışmasında tercih edilmesinin iki nedeni bulunmaktadır. Öncelikle, bir BBA sisteminin tasarımı için taşınabilir, kurulumu ve kullanımı kolay bir kayıt cihazı gerekmektedir. Emotiv nöro-başlık bir giyilebilir teknoloji ürünüdür. Tasarımı sayesinde, elektrotlar küçük bir hata payıyla doğru bir şekilde konumlandırılabilir. Bu özelliği, cihazın bir elektronörofizyolojist rehberliğine ihtiyaç duyulmadan kullanımını mümkün kılmaktadır. Nöro-başlığın tercihindeki ikinci neden, görece düşük maliyetidir.

Nöro-başlığın bir takım dezavantajları da bulunmaktadır. Önemli bir dezavantajı aynı zamanda avantajı da olan kablosuz iletim özelliğidir. Kablosuz iletim, elektromanyetik girişime neden olmaktadır ve bu durum cihazın performansını etkileyebilmektedir. Cihazın başka bir dezavantajı, örnekleme frekansının görece düşük olmasıdır. Klinik uygulamalarda kullanılan EEG ölçüm cihazları genellikle 512 Hz. ya da daha yüksek örnekleme frekansına sahiptir. Beyin araştırmalarında kullanılan EEG ölçüm cihazlarının örnekleme frekansları 20 KHz. seviyesine kadar çıkabilmektedir.




Şekil 5.1 GUP Temelli BBA Çalışmasının Blok Diyagramı

Emotiv 2048 Hz. frekanslı örnekleme yapmaktadır. Ancak, cihazın üzerinde bulunan gömülü yazılım saniyedeki örnek sayısını 128'e düşürmektedir. Bu durum dijital filtreleme aşamasında sorun yaratabilmektedir. Son olarak, nöro-başlık ile ilgili teknik dokümanlarda, elektrot empedans değerleri ile ilgili kesin bir bilgi verilmemektedir. Klinik çalışmalarda elektrot empedans değerlerinin 5 K Ω olması bir standart haline gelmiştir [69,70]. Bu standart sadece klinik çalışmalar için geçerli olup, BBA çalışmaları için benzer bir gerekliliği içeren standart bulunmamaktadır. Bununla birlikte, yüksek elektrot empedans değerleri, EEG ölçümünün sinyal/gürültü oranını arttırmaktadır. Dolayısıyla, kayıt sırasında görülen yüksek empedans değerlerinin, BBA uygulamaları için de istenen bir durum olmadığı açıktır. Emotiv kayıt sırasında elektrotların empedanslarıyla ilgili kesin değerler vermemektedir; ancak sinyal kalitesini renk kodlarıyla göstermektedir. Kullanılan beş renk kodu ve anlamları Tablo 5.1'de gösterilmektedir.

Tablo 5.1 Emotiv Nöro-Başlığın Sinyal Kalitesi İçin Kullandığı Renk Kodları

Renk Kodu	Anlamı
Siyah	Sinyal Yok
Kırmızı	Kötü Sinyal Kalitesi
Turuncu	Zayıf Sinyal Kalitesi
Sarı	Kabul Edilebilir Sinyal Kalitesi
Yeşil	İdeal Sinyal Kalitesi (< 20 K Ω)

Emotiv kaydedilen sinyallerin kalitesini, Şekil 5.2'de görüldüğü gibi göstermektedir. Nöro-başlığın tüm elektrotları, sinyal kalitelerine göre farklı renklerle ifade edilmektedir. Bu tez çalışmasında yapılan tüm EEG kayıtlarında, elektrot empedans değerleri Emotiv TestBench programının sunduğu Şekil 5.2'de gösterilen arayüz ile kontrol edilmiştir.




Şekil 5.2 Sinyal Kalite Bilgisinin Doğrulanması için Emotiv TestBench Arayüzü

Uluslararası Elektroensefalografi ve Klinik Nörofizyoloji Federasyonu 1958 yılında, elektrotların kafatası üzerindeki konumlarını belirleyen bir standart geliştirmiştir [70]. Bu standart, uluslararası 10-20 elektrot yerleştirme sistemi olarak adlandırılmaktadır. 10-20 sisteminde, Şekil 5.3(a)'da görüldüğü gibi 21 adet elektrot bulunmaktadır. Bu elektrotlardan 19 tanesi aktif elektrot; 2 tanesi ise referans elektrodu olarak kullanılmaktadır. Referans olarak genellikle, kulak elektrotları (A1 ve A2) kullanılmaktadır.

Elektrot yerleştirme standardının, 10-20 sistemi olarak adlandırılmasının nedeni: elektrotların birbirlerine olan uzaklıklarının, kafatasının önden arkaya veya sağdan sola toplam uzunluğunun %10'u ya da %20'si olacak şekilde belirlenmesidir. Elektrotların yerlerinin belirlenebilmesi için iki referans noktaya ihtiyaç vardır. Kafatası üzerindeki, nasion ve inion adı verilen referans noktaları Şekil 5.3(b)'de görülmektedir. Nasion, burun kemikleri ile alın kemiğinin kesişim noktasıdır. İnion ise artkafa kemiğinin alt arka kısmındaki en belirgin çıkıntıdır [22].

EEG ölçümünün uzamsal çözünürlüğünü arttırmak amacıyla 1985 yılında, 10-20 elektrot yerleştirme sistemine eklenen yeni elektrot konumları ile 10-10 sistemi tanımlanmıştır. 2001 yılında ise uzamsal çözünürlüğü daha fazla arttırmak amacıyla 320 elektrot konumundan oluşan 10-5 sistemi tanımlanmıştır [71].



Şekil 5.3 10-20 Elektrot Yerleştirme Sistemi (a) Elektrot Konumları, (b) Nasion'un ve İnion'un Konumları


Elektrot yerleştirme sistemlerinde, Şekil 5.3(a)'da görüldüğü gibi tüm elektrotlar belirli kurallara göre isimlendirilmiştir. Tablo 5.2'de elektrotların isimlendirilmesinde kullanılan harflerin anlamları verilmektedir. Elektrot isimlendirmesinde her harfe ayrıca bir sayı da eklenmektedir. Beynin sağ yarı küresindeki elektrotlar çift sayılarla; sol yarı küresindeki elektrotlar ise tek sayılarla etiketlenmiştir.

Tablo 5.2 Uluslararası Elektrot Yerleştirme Sistemlerinde, Elektrotların İsimlendirilmesinde Kullanılan Harfler [72]

Harf	Açılımı	Sistem
F	Frontal	10-20
Fp	Frontal pole	10-20
C	Central	10-20
P	Parietal	10-20
O	Occipital	10-20
T	Temporal	10-20
AF	Anterio-frontal	10-10
FC	Fronto-central	10-10

Emotiv üzerinde, 2 tanesi referans elektrodu olmak üzere toplam 16 elektrot bulunmaktadır. Nöro-başlıkta bulunan aktif elektrotlar: AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 olarak sabit konumda bulunmaktadır. P3 ve P4 ise referans elektrotları olarak kullanılmaktadır. Ayrıca, nöro-başlığın iç bağlantıları mastoid elektrotlarının da referans elektrotları olarak kullanabileceği biçimde tasarlanmıştır. Dolayısıyla P3, P4 elektrotları ya da mastoid elektrotları referans olarak tercih edilebilmektedir. Şekil 5.4'de 10-20 sistemi elektrot konumları siyah; 10-10 sistemi elektrot konumları gri renkle gösterilmektedir. Emotiv nöro-başlık üzerindeki sabit elektrot konumları ise yeşil çerçeve içerisinde alınmıştır.

Şekil 5.3(a) ve Şekil 5.4 karşılaştırıldığında, elektrotların adlandırılmalarında önemli bir değişiklik fark edilmektedir. 10-20 sisteminde, T3, T4, T5 ve T6 olarak tanımlanan elektrotlar, 10-10 sisteminde sırasıyla T7, T8, P7 ve P8 olarak yeniden tanımlanmıştır.



Şekil 5.4 10-20 ve 10-10 Elektrot Yerleştirme Sistemlerinde Yer Alan Elektrot Pozisyonları ile Emotiv Nöro-başlık Üzerindeki Sabit Elektrot Pozisyonları

5.2 Elektroensefalogram Kaydı


EEG sinyallerinin kaydında, Emotiv firmasının nöro-başlık kullanımı için geliştirdiği TestBench programı kullanılmıştır. Şekil 5.5'de programın arayüzü gösterilmektedir. TestBench programı, EEG sinyallerini EDF (European Data Format) veya CSV (Comma Separated Values) dosya formatlarında kaydedebilmektedir. Kaydedilen dosya sadece EEG verisinden oluşmamaktadır ve 36 kanal içermektedir. Dosyanın içerdiği veri sırasıyla, Tablo 5.3'de görüldüğü şekilde etiketlenmiştir.

Tablo 5.3 EEG Kayıtlarının İçeriği

Kanal Adı	Kanal Sırası	Açıklama
COUNTER	1	Veri paketi sayacı
INTERPOLATED	2	Veri iletimi doğrulama
AF3 ... AF4	3-16	Ham EEG verisi
RAW_CQ	17	Genel sinyal kalitesi
CQ_AF3 ... CQ_AF4	18-31	Her bir elektrot için sinyal kaliteleri
CQ_CMS ve CQ_DRL	32 ve 33	Referans elektrotlarının sinyal kaliteleri
GYROX ve GYROZ	34 ve 35	Yatay ve dikey jiroskop değerleri
MARKER	36	Zamanlayıcı işareti

Tablo 5.3'de kısa açıklamaları verilen bilgiler, bu tezde yer alan Emotiv nöro-başlık ile ilgili diğer tüm teknik bilgilerle birlikte firmanın resmi internet sitesinde yayımladığı teknik dökümanlardan elde edilmiştir [73].

Tablo 5.3'de görüldüğü üzere, 3. kanal ve 16. kanal arasındaki veriler ham EEG bilgisini içermektedir. Dolayısıyla EEG sinyallerinin kaydından sonraki ilk işlem, analiz edilecek olan kanalların seçilmesidir. Ham EEG verisine karşılık gelen elektrot konumları, Tablo 5.4'de verilmektedir.



Şekil 5.5 Emotiv TestBench Programının Arayüzü ve Bir Kayıt Sırasında Görülen EEG Sinyalleri

Tablo 5.4 Ham EEG verisine karşılık gelen elektrot konumları

Kanal No	3	4	5	6	7	8	9	10	11	12	13	14	15	16
Elektrot	AF3	F7	F3	FC5	T7	P7	O1	O2	P8	T8	FC6	F4	F8	AF4


Marx ve ark. SSVEP sinyallerinin kaydedilebileceği en iyi elektrot pozisyonlarını araştırdıkları çalışmalarında, 17 deneğin her biri için farklı elektrot kombinasyonlarının en iyi sonuçları verdiğini gözlemlemişlerdir. Bununla birlikte tüm deneklerde en sık görülen elektrotların O1, O2, PO1 ve PO2 elektrotları olduğunu tespit etmişlerdir [73]. *Prueckl ve Guger* beyinden en iyi KDGUP tepkisinin elde edildiği kanalları belirlemek için yaptıkları çalışmada, beş farklı denek üzerinde 30 farklı kanal kombinasyonu deneyerek, Tablo 5.5 ile verilen sonuçları elde etmişlerdir [25]. Sinyal işleme aşamasında, Oz merkez elektrot olacak biçimde, eşit ağırlıklı yüzey Laplacian dönüşümü kullandıkları için tabloda verilen tüm kombinasyonlarda Oz görülmektedir. *Prueckl ve Guger* yüzey Laplacian dönüşümü kullanmış olsalar da elde ettikleri sonuçlar, O1 ve O2 kanallarından elde edilen verinin, beyinden elde edilen KDGUP tepkisinin en iyi görülebildiği kanal kombinasyonlarından olduğunu göstermektedir.

Tablo 5.5 Beyinden En İyi KDGUP Tepkisinin Elde Edildiği Kanallar [25]

Kanal Kombinasyonu
Oz, O1, O2, PO7, PO8
Oz, O1, O2
Oz, O1, O2, PO3, PO4
Oz, PO7, PO8

Kayıt aşamasında, kayıt cihazının gerekli ayarlamalarının ve kontrollerinin yapılması, deneğin yapılacak olan kayıt ile ilgili bilgilendirilmesi ve kayıt ortamı için gerekli çevresel koşulların hazırlanması, geçerli bir EEG kaydı için gerekli; ancak yeterli koşullar değildir. Bunlara ek olarak, elektrotların konumlarının ve kafa derisine temaslarının titizlikle ayarlanması gerekmektedir. Özellikle, referans elektrotlarının kafa derisi üzerine iyi temas etmeleri gerekmektedir. *Hvaring ve Ulltveit-Moe* doğru ayarlanmayan elektrotlar nedeniyle EEG kaydında oluşan bozulmaları gözlemlemek

üzere bir deney yapmışlardır [17]. İki denek ile yaptıkları çekimlerde, birinci deneğin kaydı düzgün, ikinci deneğin kaydı ise kasten düzgün olmayan bir şekilde ayarlanmış elektrotlarla gerçekleştirilmiştir. Her iki deneğin kaydı sırasında, arkalarında yürümekte olan bir kişi nedeniyle oluşan çevresel gürültünün etkisi Şekil 5.6'da görülmektedir. İkinci deneğin kaydında, arkasında yürüyen kişi nedeniyle oluşan çevresel gürültü, elektrotların düzgün bir şekilde ayarlanmaması nedeniyle EEG kaydını kirletmektedir.




Şekil 5.6 Doğru Ayarlanmayan Elektrotlar Nedeniyle EEG Kaydında Gözlemlenen Çevresel Gürültü [17]

5.3 Görsel Uyarılar


Deneylerde kullanılmak üzere, beyinde bir KDGUP tepkisi oluşturacak bir bilgisayar programı, C# programlama dili ile geliştirilmiştir. Şekil 5.7'de görüldüğü gibi 6 adet buton, istenen frekanslarda yanıp sönerek, beyinde bir GUP oluşturmaktadır. Her bir butonun kendine ait titreşim periyodu ayarlanabilmektedir. Ayrıca, her bir uyarın için kayıt süreleri ve uyarınlar arasında geçirilecek dinlenme süreleri de ayarlanabilmektedir. Butonların birbirlerine ve monitörün kenarlarına olan uzaklıkları

Şekil 5.7'de gösterilmektedir. Bu uzaklıklar, 21.5" boyutunda bir monitörde, program tam ekran kullanıldığında ölçülen değerlerdir. Tez çalışması süresince yapılan EEG kayıtlarında, deneklerin monitöre olan uzaklığı yaklaşık 60 cm olacak şekilde ayarlanmıştır.




Şekil 5.7 GUP Tepkisinin Tetiklenmesi Amacıyla Geliştirilen Programın Arayüzü

Görsel korteksten GUP elde etmek için Şekil 5.8'de görüldüğü gibi üç farklı temel uyaran kullanılmaktadır. Bu tez çalışmasında kullanılan uyaran, Şekil 5.8(a)'da görülen, belirli bir frekansta parlayan bir yüzey biçimindedir. Uyaran sinyalinin bir periyodu, yüzeyin parladığı açık konum ve parlamadığı kapalı konumdan oluşmaktadır.



Şekil 5.8 Uyarıcı Tipleri (a) Açık-Kapalı Flaş, (b) Desen Flaş, (c) Zıt Desenler

Periyodu 250 ms olan bir uyaran sinyal, saniyede dört kere parlayan bir ışık kaynağıdır. Ancak beyin, uyaran sinyalin periyoduna veya frekansına değil, yüzeyin parlaklığındaki değişime tepki vermektedir. Diğer bir deyişle, Şekil 5.9'da görüldüğü gibi yüzeyin sadece kapalı konumdan açık konuma geçtiği durumlarda değil, açık konumdan kapalı konuma geçtiği durumlarda da beyinde bir sinyal tetiklenmektedir [75]. Bununla birlikte, beynin uyaran sinyale cevabında, Şekil 5.9(b)'da görüldüğü gibi bir asimetri söz konusudur. Kapalı konumdan açık konuma geçme anında elde edilen tepkinin genliği ile açık konumdan kapalı konuma geçme anında elde edilen tepkinin genliği arasında önemli bir fark gözlemlenmektedir. Uyaran sinyaldeki asimetri, tepki sinyalinde de bir asimetri yaratmaktadır. Dolayısıyla tepki sinyali sadece uyaran sinyalin temel frekansını değil, daha yüksek harmoniklerini de içermektedir [75].



Şekil 5.9 (a) Uyaran Sinyal ve (b) Beyinde Görülen Asimetrik Tepki [75]

Şekil 5.8(a) ve Şekil 5.8(b)'de görülen uyaranlar asimetrik bir GUP üretmektedir. Diğer taraftan Şekil 5.8(c)'de görülen uyaranın açık ve kapalı konumlarındaki ortalama parlaklık değerleri değişmediğinden, beyinden elde edilen GUP simetrik olmaktadır. Asimetrik ve simetrik GUP tepkileri frekans analizi açısından önemli bir fark yaratmaktadır. Asimetrik GUP tepkisinde, temel frekans ve temel frekansın tek ve çift katlı harmonikleri gözlemlenmektedir. Simetrik GUP ise sadece temel frekans ve temel frekansın çift katlı harmoniklerini içermektedir [75].

Bu tez çalışmasında, uzun süren KDGUP kayıtlarının neden olduğu yorgunluk hesaba katıldığında daha provokatif bir uyarının daha çabuk yorgunluğa neden olacağı göz önünde bulundurularak, provokatif bir desen yerine [26] tekdüze bir yüzey, uyarın olarak kullanılmıştır. Uyarın yüzeyin rengi ile KDGUP tepkisi arasındaki ilişkiyi inceleyen bir çalışma, *Cao ve ark.* tarafından gerçekleştirilmiştir. Yaptıkları çalışmada, en güçlü KDGUP tepkisini sırasıyla beyaz, gri, kırmızı, yeşil ve mavi renkli uyarınlar ile elde etmişlerdir [76]. Diğer taraftan, *Hvaring ve Ulltveit-Moe* yaptıkları çalışmalarda, önce her denek için en kuvvetli KDGUP tepkisinin elde edildiği renkleri tespit etmişler, daha sonra deneylerine bu renklerle devam etmişlerdir [17]. Yaptıkları çalışmadan, her deneğin, farklı renkli uyarınlara kuvvetli tepki gösterdiği anlaşılmaktadır. Dolayısıyla bu tez çalışmasında, uyarınların rengi ile ilgili herhangi bir çalışma yapılmamış ve uyarın rengi olarak kırmızı belirlenmiştir.


3.5 Hz ve altındaki frekanslarda görsel korteksten elde edilen GUP, geçici GUP (*transient GUP*) olarak adlandırılmaktadır [25, 75]. Bunun nedeni, uyarın sinyalin görsel kortekste sürekli bir sinüzoidal benzeri tepki sinyali oluşturmamasıdır. 3.5 Hz ile 75 Hz arasındaki frekanslarda, görsel korteksten elde edilen tepki sinyallerinin üst üste örtüşmeleri nedeniyle sinüzoidal benzeri bir dalga biçimi oluşmaktadır [26]. Uyarın sinyalin devam ettiği süre boyunca, görsel kortekste oluşan tepki sinyali yarı-sinüzoidal biçimini korumaktadır. Bu nedenle 3.5 Hz ve üzerindeki uyarınlar sonucunda elde edilen GUP, kalıcı durum GUP (*steady-state GUP*) olarak adlandırılmaktadır [75]. GUP temelli bir BBA tasarımında, sinyallerin spektral özelliklerinin kullanıldığı bir sınıflandırma yapılabilmesi için uyarınların 3.5 Hz ile 75 Hz arasında olması gerekmektedir. Diğer taraftan, uyarınların frekansları, BBA sisteminin tasarımında kullanılan donanım ve yazılımlar nedeniyle özgürce ayarlanamamaktadır.

Şekil 5.7'de görülen flaş uyarınlar, belirli frekanslarda arka plan rengi değişen buton kontrolleriyle gerçekleştirilmiştir. Butonların titreşim frekanslarının ayarlanması, bir bilgisayar programının KDGUP temelli bir BBA ile kullanımında karşılaşılan en önemli zorluklardan biridir. Bir uyarının titreşim frekansının belirlenmesinde, işletim sisteminin, programlama dilinin ve monitörün zaman çözünürlükleri göz önünde bulundurulmalıdır.

- Programlama Dilinin Zaman Çözünürlüğü: Bu tez çalışması kapsamında geliştirilen uyaran programın yazıldığı C# programlama dili 1 ms zaman çözünürlüğüne sahiptir. Dolayısıyla bir butonun titreşim frekansı en fazla 500 Hz olarak ayarlanabilir. KDGUP sinyallerinin frekans aralığı göz önünde bulundurulduğunda, programlama dilinin zaman çözünürlüğünün BBA sistemi için yeterli olduğu görülmektedir.
- İşletim Sisteminin Zaman Çözünürlüğü: Bu tez çalışmasında yapılan deneylerde Windows 10 işletim sistemi yüklü bir bilgisayar kullanılmıştır. Windows 10 işletim sisteminde zaman çözünürlüğü 15.6 ms olarak belirlenmiştir. İşletim sisteminin zaman çözünürlüğü nedeniyle butonların titreşim frekansları en fazla 32 Hz olarak ayarlanabilmektedir.
- Monitörün Zaman Çözünürlüğü: Bir monitörün zaman çözünürlüğü veya diğer adıyla hareket çözünürlüğü, ekrandaki görüntünün saniyedeki yenilenme sayısı ile tanımlanır. Monitörlerin yenileme oranları 50 Hz ya da 60 Hz olarak ayarlanabilmektedir. Bu tez çalışmasında yapılan deneylerde kullanılan monitörün yenileme hızı 60 Hz olarak ayarlanmıştır. Dolayısıyla butonların titreşim frekansı en fazla 30 Hz olarak ayarlanabilmektedir.

Aynı anda iki veya daha fazla uyaranın kullanıldığı deneylerde, işletim sisteminin zaman çözünürlüğünün önemli bir kısıtlayıcı etkisinin olduğu anlaşılmaktadır. Örneğin birinci uyaranın frekansı 9 Hz olarak ayarlanırsa, ikinci uyaranın frekansı 10 Hz olarak ayarlanamaz. Bunun nedeni, birinci uyaranın periyodu $T_1 = 1/9 = 111 \text{ ms}$ ve ikinci uyaranın periyodu $T_2 = 1/10 = 100 \text{ ms}$ arasındaki farkın $111 - 100 = 11 \text{ ms}$ işletim sisteminin zaman çözünürlüğünden daha düşük bir değer olmasıdır. Dolayısıyla, her iki uyaran da aynı zaman dilimi içerisinde kalacak ve aynı frekansta titreşecektir. Buna ek olarak, monitör kaynaklı zaman çözünürlüğü kısıtlamaları daha büyük problemlere neden olmaktadır. Standart bilgisayar donanımları ile 3.5 Hz ve 75 Hz aralığındaki KDGUP tepkisinin, 3.5 Hz ile 30 Hz aralığındaki kısmı ölçülebilir durumdadır. Bant genişliği açısından değerlendirildiğinde, monitörün zaman çözünürlüğünün önemli bir kısıtlayıcı etkisi olmadığı gözlemlenmektedir. Ancak monitörün zaman çözünürlüğü nedeniyle, sadece belirli frekanslardaki uyaranlar düzgün bir kare dalga formunda elde edilebilmektedir. Örneğin, 60 Hz yenileme frekanslı bir monitörde, bir uyaranın frekansının tam 9 Hz olması mümkün değildir. Bir uyaranın


frekansının, tam olarak ayarlandığı değerde görülebilmesi için frekansının 60'a tam bölünebilen bir değerde olması gerekmektedir. Diğer bir deyişle, yenileme frekansı 60 Hz olan bir monitörde, düzgün bir kare dalga formunda görülebilecek uyaran frekansları, 1 Hz, 2 Hz, 3 Hz, 4 Hz, 5 Hz, 6 Hz, 6.67 Hz, 7.5 Hz, 8.57 Hz, 10 Hz, 12 Hz, 15 Hz, 20 Hz ve 30 Hz olabilir [17]. Şekil 5.10'da yenileme frekansı 60 Hz olan bir monitörde, 11 Hz ve 15 Hz frekanslarında titreşen iki uyaranın oluşturduğu bir saniyelik sekans görülmektedir. Kırmızı kareler uyaranın açık olduğu durumu, siyah kareler ise kapalı olduğu durumu ifade etmektedir. Frekansı 15 Hz olarak ayarlanan uyaran, kusursuz bir kare dalga biçiminde görülürken, frekansı 11 Hz olarak ayarlanan uyaranın dalga biçiminde bozulma gözlemlenmektedir. Diğer taraftan, gerçekleştirilen spektral analizler sonucunda, 9 Hz ve 11 Hz gibi kusursuz bir kare dalga formunda olmayan uyaranların, frekansları yaklaşık olarak 9 Hz ve 11 Hz olan KDGUP sinyallerini tetiklediği görülmektedir. Örneğin, frekansı 4.6 Hz olan bir uyaranın tetiklediği 20 saniyelik bir kayıttan elde edilen KDGUP tepkisinin birinci ve ikinci harmonikleri, Şekil 5.11'de verilen frekans spektrumunda görüldüğü gibi sırasıyla 4.56 Hz ve 9.16 Hz olarak gözlemlenmektedir.



Şekil 5.10 (a) 11 Hz ve (b) 15 Hz Frekanslarında Titreşen Uyarılardan Oluşan Sekans

Bir bilgisayar programının KDGUP temelli bir BBA yoluyla kullanımında, monitörün yenileme frekansı, uyaran frekanslarının belirlenmesinde önemli bir faktördür. Bu tez çalışmasında iki farklı uyaran seti kullanılmıştır. Her iki uyaran seti,

her biri farklı görevlere atanabilecek altı farklı uyaran sinyal içermektedir. Her iki uyaran set ve uyaranların frekansları Tablo 5.6'da görülmektedir.



Şekil 5.11 Frekansı 4.6 Hz Olan Bir Uyaranın Tetiklediği KDGUP Tepkisinin, Frekans Spektrumunda Görülen Birinci ve İkinci Harmonikleri

Tablo 5.6 KDGUP Tepkisinin Tetiklenmesinde Kullanılan Uyaranların Frekansları

1. Set				
Uyaranlar	1. Harmonik	2. Harmonik	3. Harmonik	4. Harmonik
1. Uyaran	4	8	12	16
2. Uyaran	4.6	9.1	13.7	18.2
3. Uyaran	5.3	10.6	15.9	21.2
4. Uyaran	6.4	12.7	19.1	25.5
5. Uyaran	8	16	23.9	31.9
6. Uyaran	10.6	21.2	31.9	42.6
2. Set				
Uyaranlar	1. Harmonik	2. Harmonik	3. Harmonik	4. Harmonik
1. Uyaran	3.6	7.1	10.6	14.2
2. Uyaran	4	8	12	16
3. Uyaran	4.6	9.1	13.7	18.2
4. Uyaran	5.4	10.6	16	21.4
5. Uyaran	6.4	12.8	19.2	25.6
6. Uyaran	16	32	48	64

Tez çalışması boyunca yapılan tüm EEG kayıtlarında, Tablo 5.6'da görülen, 1 ya da 2 numaralı uyaran seti kullanılmıştır. Tabloda vurgulandığı gibi, ikinci set daha az örtüşen harmonik içermektedir. Sınıflandırma aşamasında, sadece 1 ve 2 numaralı harmoniklerin kullanılması durumunda, 2. setin örtüşen harmonikler içermediği görülmektedir. Ancak ilk iki harmonik göz önüne alındığında, 1. setin 1 ve 5 numaralı uyaranlarının frekansları ile 3 ve 6 numaralı uyaranlarının frekansları örtüşmektedir. KDGUP sinyallerinin sadece temel frekans bileşenleri göz önünde bulundurularak yapılan sınıflandırılmalarında, uyaran sinyallerin örtüşen harmonikleri bir problem yaratmamaktadır. Diğer taraftan, ikinci, üçüncü ve/veya daha yüksek harmoniklerin özellik çıkarımında kullanılması durumunda titreşim frekanslarının örtüşen harmoniklerinin sınıflandırmanın performansına etkisi ayrıca incelenmiştir.

Görsel uyaranlar ile ilgili göz önünde bulundurulması gereken başka bir değişken, görsel korteksin frekans çözünürlüğüdür. *Gao ve ark.* aralarında 0.2 Hz fark olan iki farklı uyaranın, görsel korteks tarafından ayırt edilebildiğini göstermişlerdir [27]. Ancak, monitör ve işletim sistemi kaynaklı frekans çözünürlüğü değerleri bu değerin çok üzerindedir. Dolayısıyla standart bilgisayar ekipmanlarının kullanıldığı KDGUP temelli BBA sistemlerinde görsel korteksin frekans çözünürlüğü önemli bir değişken olmaktan çıkmaktadır.

5.4 Elektroensefalogram Analizi

Tez çalışmasının Şekil 5.1'de görülen analiz kısmı, Matlab programı yardımıyla gerçekleştirilmiştir. EEG sinyallerinin analizi genel olarak, dijital filtreleme, spektral analiz ve sınıflandırma olarak üç aşamaya ayrılabilir. Her aşamada, hesaplanması gereken onlarca değişken bulunmaktadır. Bu tez çalışmasındaki en temel zorluk: deney ve analiz aşamalarındaki hesaplanması gereken onlarca değişkenin varlığıdır. Esasen temel zorluk bu değişkenlerin çokluğu değil, değişkenlerin sisteme etkisinin ancak son aşamada gözlemlenebilmesidir. Örneğin, EEG kaydı sırasında, referans elektrodunun sistemin performansına etkisi; ancak kayıt yapıldıktan ve tüm analiz aşamaları gerçekleştirilip, sınıflandırma sonuçları elde edildikten sonra anlaşılabilir. Dolayısıyla değişkenlerin hesabı ve sisteme etkisinin ölçülmesi oldukça zaman almaktadır. Bu değişkenlerin büyük bir bölümü literatürdeki çalışmalar göz önünde

bulundurularak belirlenmiştir. Bununla birlikte belirli bir takım değişkenin BBA sisteminin performansına etkisi, yapılan deneylerle ortaya konmuştur.

5.4.1 Kanal Seçimi ve Ön İşlemler

BBA uygulamalarında, kullanılan elektrofizyolojik kaynaklara bağlı olarak sadece belirli bir grup elektrot veya sadece tek elektrot kullanılabilir. Örneğin sensorimotor temelli bir BBA sisteminin tasarımında C1, C2, C3, C4, C5 ve C6 elektrotları veya bu elektrotların alt kümeleri kullanılmaktadır. GUP temelli bir BBA sisteminin tasarımında ise O1, O2 ve PO1'den PO10'a kadar tüm elektrotlar veya bu elektrotların alt kümeleri kullanılmaktadır. Tablo 5.4'de görüldüğü gibi Emotiv nöro-başlık üzerinde, GUP temelli BBA çalışmasında kullanılabilecek sadece O1 ve O2 elektrotları bulunmaktadır. Bu durum ilk bakışta kısıtlayıcı bir etken olarak görülebilir. Ancak, O1 ve O2 elektrotlarının, beyinden en iyi GUP tepkisinin elde edildiği kanallardan olduğu, Tablo 5.5 incelendiğinde görülmektedir. Dolayısıyla analiz işleminde ilk aşama O1 ve O2 kanallarından elde edilen verinin diğer verilerden ayıklanmasıdır. Bu işlem basit olarak, EEG kaydının 9 ve 10 numaralı kanallarından elde edilen verinin diğer verilerden ayıklanmasıyla gerçekleştirilmiştir.

Bu tez çalışmasında gerçekleştirilen, sinyal ön-işleme olarak kabul edilebilecek tek işlem, EEG kayıtlarının 4-5 mV değerleri arasında değişen DC ofset değerlerinin temizlenmesidir. İlk bakışta bir YGF ile DC ofset değerinin temizlenebileceği düşünülebilir. DC ofset vb. yüksek genlikli ve düşük frekanslı gürültülerin temizlenebilmesi için 100 dB veya daha yüksek durdurma bandı zayıflatması gerekmektedir [77]. Ancak dijital filtreleme aşamasında karşılaşılan bir takım kısıtlardan dolayı, durdurma bandı zayıflatması 100 dB olacak şekilde bir YGF uygulanarak DC ofset tam olarak temizlenememektedir. Bu nedenle DC ofset, sinyalin ve aritmetik ortalamasının farkı alınarak temizlenmiştir.

BBA uygulamalarında genel olarak gerçekleştirilen başka bir sinyal ön-işleme, aktif kanallardan ve referans kanallarından elde edilen verilerin bir takım matematiksel operasyonlardan geçirilmesidir. Bu tür matematiksel operasyonlar genellikle EEG ölçümlerindeki farklı referans stratejilerinin uygulanması amacıyla kullanılmaktadır. EEG ölçümünde genel olarak üç farklı strateji izlenmektedir. Bunlar, referanssal (kulak,

mastoid vb.), ortalama referanssal ve Laplacian olarak adlandırılmaktadır. Ortalama referanssal ölçümde, tüm elektrotlardan alınan verilerin ortalaması ortak referans olarak kabul edilmektedir. Laplacian ölçümde ise her kanal, bir elektrot ile bu elektrodu çevreleyen komşu elektrotların ağırlıklı veya ağırlıksız ortalamalarının farkını içermektedir [43]. Ortalama referanssal ve Laplacian ölçüm stratejileri donanımsal veya yazılımsal olarak gerçekleştirilebilir. Eğer yazılımsal olarak gerçekleştirilmek istenirse, gerekli matematiksel operasyonlar sinyal ön-işleme aşamasında yapılmalıdır. Bu tez çalışmasında referanssal ölçüm stratejisi izlenmiştir ve referans olarak P3 ve P4 elektrotları kullanılmıştır. Dolayısıyla herhangi bir referans stratejisinin uygulanması amacıyla bir sinyal ön-işleme gerçekleştirilmemiştir.

5.4.2 Dijital Filtre Karakteristikleri

Bir BBA uygulaması söz konusu olduğunda, EEG sinyallerinin filtrelenmesi ile ilgili cevap bekleyen sorular aşağıda listelenmektedir.


❖ Dijital Filtreleme Gerekli mi?

Her ne kadar tüm EEG kayıt cihazları en azından temel seviyede donanımsal filtreler içerse de dijital filtreleme, EEG kayıtlarını çevresel, biyolojik ve elektronik gürültüden temizleyerek özellik çıkarımı ve sınıflandırma aşamalarında daha geçerli bir veri ile çalışma imkanı sağlamaktadır. Diğer taraftan, *Widmann ve ark.* dijital filtrelemenin, mutlaka gerçekleştirilmesi gereken bir aşama olarak değerlendirilmemesi gerektiği sonucuna varmışlardır [77]. *Van Rullen* bir sinirsel aktiviteyle ilişkili EEG verisinin, filtreleme nedeniyle zamanda yüzlerce milisaniye boyunca yayılabildiğini ve beyin aktivitelerinin dinamiği ve zamanlaması ile ilgili değerlendirmelerde problem yaratabildiğini bildirmiştir [78]. Bir uyarının 150 ile 180 ms sonrasında oluşan OİP'nin, dijital filtreleme nedeniyle olaydan 100 ms sonra gerçekleşmiş biçimde gözlemlenebileceği örneğini vermiştir [78]. Bu ve benzeri durumlardan kaçınmak için gerekmediği takdirde, hiç AGF uygulanmamasını dahi önermiştir. Buna ek olarak, bir BBA sisteminin verilen girdilere mümkün olan en kısa sürede cevap vermesi beklenir. Rehabilitasyon mühendisliği açısından değerlendirildiğinde, bir BBA kullanıcısının istediği bir görevi en fazla bir kaç saniye içerisinde gerçekleştirmesi beklenmektedir. Bir görevin gerçekleştirilmesi için geçen sürenin uzaması, kullanıcı konforunu da

olumsuz yönde etkileyecektir. Dolayısıyla, analiz aşamasının hesaplama zamanının az olması, sistem tepki süresine olumlu yönde katkı yapacaktır. Bu durumda asıl soru: dijital filtreleme yapılmadığı için filtreleme algoritmalarının hesaplama zamanından kazanılan süreye karşılık, azalan sınıflandırma performansının kabul edilebilirliği. Bu soru aslında ikinci bir soruyu da beraberinde getirmektedir. EEG kayıt cihazlarının elektronik filtreleri, bir BBA sisteminin tasarımında herhangi bir dijital filtrelemeye gerek bırakmaksızın yeterli performansı sağlayabilecek midir? Diğer bir deyişle, dijital filtreleme aşaması atlanırsa, sınıflandırma performansı düşecek midir? Bu sorular, geleneksel dijital filtreleme yöntemlerinin kullanıldığı ve kullanılmadığı iki ayrı durumun sınıflandırma performanslarının karşılaştırılmasıyla cevaplanmıştır.


❖ Geleneksel Dijital Filtreleme Yöntemleri Yeterli mi?

Geleneksel filtreleme yöntemleri, gözbebeklerinin hareketi ve göz kırpmaya nedeniyle oluşan EOG kaynaklı gürültülerin giderilmesinde yetersiz kalmaktadır. Göz kaynaklı gürültülerin giderilmesinde en hızlı ve basit çözüm gürültü bulunan kısmın analize dahil edilmemesidir. Ancak bu durumda EEG kaydının göz kırpmaya anında ve/veya göz bebeği hareketleri sırasında içerdiği önemli zaman ve frekans bilgisi de silinecektir [52]. Göz kaynaklı gürültünün temizlenmesi için diğer bir yaklaşım ise BSS (Blind Source Separation) algoritmaları kullanmaktır [52]. Bu tez çalışmasında göz kaynaklı gürültülerin temizlenmesi amacıyla geleneksel filtreleme yöntemlerine ek herhangi bir işlem yapılmamıştır. Bunun birinci nedeni: göz kaynaklı gürültünün Şekil 5.12'de görüldüğü üzere frontal lobda belirgin; ancak oksipital lobda ihmal edilebilecek düzeyde olmasıdır. Göz kırpmaya kaynaklı gürültünün oksipital lobdaki ihmal edilebilirliği, Şekil 5.12'de yeşil çember içine alınarak vurgulanan oksipital lob ve kırmızı çember içine alınarak vurgulanan frontal lob elektrotlarındaki etkiler gözlemlendiğinde daha iyi anlaşılacaktır. BSS algoritmalarının kullanılmamasındaki ikinci neden: deneylerde sadece O1 ve O2 elektrotlarının kullanılmasıdır. Sadece iki kanal içeren bir EEG kaydında, ihmal edilebilir düzeydeki gürültülerin temizlenmesi için bir BSS algoritması kullanmak, gerekli fazladan algoritmik hesaplama zamanı ve kanal sayısının az olması göz önünde bulundurularak, tercih edilmemiştir.




Şekil 5.12 Göz Kırpma Kaynaklı Gürültünün, Frontal ve Oksipital Kanallara Etkisi

Sinyal işleme aşamasında, EEG sinyallerine YGF ve AGF uygulanmıştır. Şekil 5.13'de YGF'nin, Şekil 5.14'de AGF'nin frekans ve faz spektrumları görülmektedir.



Şekil 5.13 Sinyal İşleme Aşamasında Kullanılan Yüksek Geçiren Filtrenin Frekans ve Faz Spektrumu



Şekil 5.14 Sinyal İşleme Aşamasında Kullanılan Alçak Geçiren Filtrenin Frekans ve Faz Spektrumu

Bir dijital filtrenin tasarımında, dar bir geçiş bandı, yüksek durdurma bandı zayıflatması ve düşük geçiş bandı salınımı istenmektedir. Aynı zamanda bu üç parametrenin mümkün olan en kısa uzunluktaki filtre ile gerçekleştirilmesi istenmektedir. Tüm şartları sağlayan bir filtrenin tasarımı mümkün değildir; ancak herhangi bir sinyal işleme uygulamasında ihtiyaçları optimum seviyede karşılayacak bir filtre tasarlanabilir.

Bu tez çalışmasında, filtre tasarım yöntemi olarak FIR tercih edilmiştir. Elektrofizyolojide genellikle Butterworth IIR ya da FIR filtreler uygulanmaktadır [77]. Bu tez çalışmasında, IIR ya da FIR filtre tasarım tercihinde göz önünde bulundurulacak iki parametre söz konusudur. Bu parametreler, sistem kararlılığı ve doğrusal fazdır. IIR filtreler geri beslemeli olduklarından, her zaman kararlı çalışmamaktadır. Diğer taraftan FIR filtreler geri beslemesiz olduklarından her zaman kararlı bir yapıdadır. Buna ek olarak, simetrik FIR filtreler her zaman doğrusal faza sahiptir. Sistem kararlılığı ve doğrusal faz açısından değerlendirildiğinde FIR filtrelerin IIR filtrelere üstünlüğü açıkça görülmektedir. IIR filtrelerin FIR filtrelere üstünlüğü ise istenen filtre karakteristiklerinin düşük dereceli filtrelerle uygulanabilmesidir. Bu tez çalışmasında, iki tasarım yöntemi arasında öne çıkan en önemli etken filtre uzunluğu olmuştur. İstenen filtre özellikleri ikinci ya da üçüncü derecen bir IIR filtre ile tasarlanabilirken,

aynı özelliklerdeki bir FIR filtrenin derecesi 50 veya üstünde değer alabilmektedir. Bu tez çalışmasında, özellikle doğrusal olmayan faz kaynaklı sinyal bozulmalarından kaçınmak amacıyla FIR filtre tasarımı uygulanmıştır.

Tablo 5.7'de, tasarlanan filtrelerin özellikleri görülmektedir. YGF tasarımını zorlaştıran en büyük etken, dar geçiş bandı zorunluluğudur. KDGUP sinyallerinin tetiklenmesinde kullanılan en düşük frekanslı uyaran, Tablo 5.6'da görüldüğü üzere 3.6 Hz değerindedir. Diğer bir deyişle, 3.6 Hz ve daha yüksek frekanslı sinyal bileşenleri filtrelenecek şekilde bir YGF tasarlanmalıdır. Dolayısıyla YGF'nin çok dar bir geçiş bandına sahip olması gerekmektedir. Bu gereksinim, özellikle FIR filtre tasarımında oldukça yüksek dereceli bir filtre anlamına gelmektedir. Bu tez çalışmasında kullanılan YGF'nin geçiş bandı 0.2 Hz ile 4.8 Hz aralığındadır. Örnek olarak, daha ideal bir filtre için geçiş bandının 0.2 Hz ile 3.2 Hz aralığına daraltılması, filtre uzunluğunu 111 yapmaktadır. Bunun sonucunda, filtrelemeden kaynaklanan zaman gecikmesi artacaktır. N filtre uzunluğu ve T örnekleme periyodu olmak üzere, bir filtrenin zaman gecikmesi:

$$\Delta t = \frac{N - 1}{2} T \quad (5.1)$$

eşitliğiyle hesaplanmaktadır. Bu tez çalışmasında uygulanan YGF ve AGF sırasıyla, 172 ms ve 160 ms zaman gecikmesine sahiptir. Uzunluğu 111 olan bir filtrenin zaman gecikmesi ise 430 ms olmaktadır. Görüldüğü üzere, filtre uzunluğu arttıkça, filtreleme kaynaklı zaman gecikmesi de artmaktadır. Bu nedenle mümkün olan en kısa filtre uygulanmalıdır.




Filtre uzunluğunu arttıran diğer iki faktör, durdurma bandı zayıflatması ve geçirme bandı salınımıdır. Durdurma bandının zayıflatma değeri arttıkça ve/veya geçirme bandının salınımı azaldıkça, filtre uzunluğu da artmaktadır. Bu tez çalışmasında uygulanan YGF, durdurma bandı zayıflatma değeri 37 dB, geçirme bandı maksimum salınım değeri 0.33 dB olacak şekilde tasarlanmıştır. Durdurma bandı zayıflatmasının daha fazla arttırılması ve/veya geçirme bandı salınımının daha fazla azaltılması, filtre uzunluğunu gerçek zamanlı uygulamalarda kabul edilemeyecek değerlere yükseltmektedir.

Tablo 5.7 EEG Sinyallerinin Filtrelenmesinde Kullanılan YGF ve AGF Karakteristikleri

Filtre Özellikleri	YGF	AGF
Tasarım	Tip 1 FIR	Tip 2 FIR
Kararlılık	Kararlı	Kararlı
Doğrusal Faz	Doğrusal Faz	Doğrusal Faz
Durdurma Bandı Zayıflatması	37 dB	60.5 dB
Geçirme Bandı Salınımı	0.33 dB	0.1 dB
Geçiş Bandı Genişliği	4.6 Hz	12 Hz
6 dB Noktası	2.48 Hz	38 Hz
3 dB Noktası	3.22 Hz	36.7 Hz
Filtre Uzunluğu	45	42

YGF için geçerli olan dar geçiş bandı kısıtlaması AGF tasarımında söz konusu değildir. Dolayısıyla AGF tasarımında, geçiş bandı genişliği artırılarak, durdurma bandı zayıflatması ve geçirme bandı salınımı daha etkili hale getirilmiştir.

Özellikle 2 saniye ve daha kısa zaman pencerelerinin söz konusu olduğu çalışmalarda filtre uzunluğu sistem performansı açısından önemli bir parametre haline gelmektedir. Bu tez çalışmasında olduğu gibi, kısa zaman penceresi ve düşük bir frekansla örneklenmiş bir sinyal söz konusuysa, filtre tasarımının önemi daha da artmaktadır. 128 Hz örnekleme frekanslı bir sinyal, 2 saniyelik pencereler halinde analiz edildiğinde, her bir veri parçası 256 örnekten oluşmaktadır. Dolayısıyla uzunluğu 45 olan YGF, EEG sinyallerinin ilk 22 örneğini Şekil 5.15(a)'da görüldüğü gibi geçersiz hale getirmektedir. Filtre uzunluğunun, verinin kenarlarında yarattığı bu duruma kenar etkisi adı verilmektedir. Uzunlukları 79 ve 171 olan iki filtrenin neden olduğu kenar etkisi sırasıyla Şekil 5.15(b) ve Şekil 5.15(c)'de gözlemlenmektedir. Şekil 5.15(b)'de görülen, uzunluğu 79 olan filtre, verinin ilk 39 örneğini geçersiz kılmaktadır. Böyle bir filtre zaman pencereleri 0.5s olarak belirlenen bir BBA sisteminde kullanılırsa, verilerin ilk 39 örneğini ya da başka bir deyişle %61'ini silecektir. İdeal filtre karakteristiklerine yaklaştıkça, Şekil 5.15'de görüldüğü gibi filtre uzunluğunun artmasından kaynaklanan zaman gecikmesi ve kenar etkisi, özellikle gerçek zamanlı uygulamalarda kabul edilemeyecek ölçüde bozulmalara neden olmaktadır. Bu tez çalışmasında, kenar etkisi özellikle YGF tasarımında önemli bir sınırlayıcı etken olmuştur.



Şekil 5.15 Filtre Uzunluğunun Sinyaller Üzerindeki Kenar Etkisi

5.5 Özellik Çıkarma ve Sınıflandırma

EEG sinyallerinin sınıflandırılmasında kullanılan özellikler genel olarak zaman alanı ve frekans alanı parametreleri olarak ikiye ayrılmaktadır. BBA çalışmalarında kullanılan zaman alanı özellikleri, tepe değerleri gibi sinyal biçimi tabanlı veya sinyalin zaman penceresi boyunca integrali veya ortalaması gibi zaman bloğu tabanlı olabilmektedir [43]. Ayrıca, şablon eşleştirme tabanlı özellik çıkarımı yöntemleri içeren BBA çalışmaları da bulunmaktadır. Bu çalışmalarda, önceden tanımlanmış bir şablon ile EEG sinyalinin benzerliği bir özellik olarak kullanılmıştır [43].

BBA kullanıcıları KDGUP sinyallerinin en iyi spektral özelliklerini modüle edebilmektedir. Dolayısıyla KDGUP temelli BBA çalışmalarında, en çok EEG sinyallerinin spektral özellikleri kullanılmaktadır [25,27,28,33,43,79,80]. Bununla birlikte, korelasyon tabanlı özelliklerin kullanıldığı KDGUP temelli BBA çalışmaları da bulunmaktadır [26,34].

Spektral özellikler, doğrudan frekans spektrumundan, güç spektrumu kestirimi yoluyla veya otoregresif modelleme yollarıyla elde edilmektedir [43]. Bu tez çalışmasında frekans spektrumundan ve güç spektrumundan elde edilen özellikler kullanılmış ve sınıflandırma performansına etkileri araştırılmıştır.

Sınıflandırma yöntemlerinin seçimi ile ilgili geçmiş yıllarda yapılan çalışmalar incelendiğinde, öne çıkan algoritmaların YSA, DVM ve karar ağaçları olduğu görülmektedir [55,56]. Bununla birlikte son yıllarda yapılan SSVEP tabanlı BBA çalışmalarında sınıflandırıcı olarak, çok az ya da neredeyse hiç eğitim gerektirmeyen Canonical Correlation Analysis (CCA) yönteminin tercih edildiği görülmektedir [81-85]. Bunlara ek olarak, son yıllarda yapılan nöral ağ tabanlı sınıflandırmalarda, Convolutional Neural Network (CNN) tercih edilen çalışmalar bulunmaktadır [86].

5.6 Bulgular

Bu tez çalışmasında yapılan deneyler, deneylerden elde edilen sonuçlar ve çıkarımlar bu başlık altında incelenmektedir. Tez çalışması süresince araştırılan olgular aşağıda özetlenmektedir.

- Dijital filtreleme uygulanan ve uygulanmayan BBA tasarımlarının sınıflandırma performanslarının karşılaştırılması
- KDGUP tepkisinden elde edilen sinyallerin harmonik frekanslarından elde edilen özelliklerin sınıflandırma performansına etkisinin araştırılması
- YSA ve DVM sınıflandırıcılarının, KDGUP sınıflandırma performanslarının karşılaştırılması
- Uyanların örtüşen ve örtüşmeyen frekanslardaki harmoniklerinin, KDGUP sinyallerinin sınıflandırma performansına etkisinin incelenmesi
- Zaman penceresi uzunluğunun, BBA tasarımlarının sınıflandırma performansına etkisinin incelenmesi
- Sınıf (görev) sayısının, BBA tasarımlarının performansına etkisinin araştırılması

5.6.1 Dijital Filtrelemenin Beyin-Bilgisayar Arayüzü Tasarımlarının Sınıflandırma Performansına Etkisi

Widmann ve ark. yaptıkları çalışmalar sonucunda dijital filtrelemenin, EEG çalışmalarında mutlaka gerçekleştirilmesi gereken bir aşama olarak değerlendirilmemesi gerektiği sonucuna varmışlardır [77]. Vardıkları sonuç, bu tez çalışmasında kullanılan nöro-başığın içerdiği filtrelerle birlikte düşünüldüğünde, dijital filtreleme yapılan ve yapılmayan BBA sistemlerinin performanslarının karşılaştırılması ihtiyacı ortaya çıkmıştır.

Bu çalışmada, üç farklı denekten elde edilen EEG kayıtları kullanılmıştır. Tablo 5.6'da verilen birinci setin ilk dört frekansı, uyan olarak kullanılmıştır. Tabloda görülen 5 ve 6 numaralı uyanlar; birinci ve ikinci harmonikleri sırasıyla 1 ve 3 numaralı uyanlarla örtüştüğü için kullanılmamıştır. Uyanların her biri için 4 dakikalık EEG kaydı yapılmıştır. Denekler, kayıtlar arasında üçer dakika dinlenmiştir.

Özellik vektörü, KDGUP sinyallerinin frekans spektrumlarından elde edilen, birinci ve ikinci harmoniklerin toplam ve bağıl bant gücü değerlerinden oluşmaktadır. Bu çalışmada ikili, üçlü ve dörtlü sınıflandırma gerçekleştirilmiştir. Örneğin, ikili sınıflandırma işlemi için kullanılan özellik vektörü x^T , f uyan frekanslarını, h

KDGUP tepkisinde görülen harmonikleri ve T [0, 64] Hz aralığındaki toplam bant gücünü ifade etmek üzere,

$$\begin{aligned} O_1^T &= [f_1 h_1 \ f_1 h_2 \ f_2 h_1 \ f_2 h_2 \ f_1 h_1 : T \ f_1 h_2 : T \ f_2 h_1 : T \ f_2 h_2 : T] \\ O_2^T &= [f_1 h_1 \ f_1 h_2 \ f_2 h_1 \ f_2 h_2 \ f_1 h_1 : T \ f_1 h_2 : T \ f_2 h_1 : T \ f_2 h_2 : T] \\ x^T &= [O_1^T \ O_2^T] \end{aligned}$$

biçiminde tanımlanmıştır. O_1^T ve O_2^T sırasıyla O1 ve O2 kanallarından elde edilen EEG sinyallerine ait özellik vektörlerini ifade etmektedir. Özellik vektörlerine sırasıyla, üçlü sınıflandırma işleminde üçüncü; dördümlü sınıflandırma işleminde dördüncü frekans bandının bir ve iki numaralı harmoniklerinden elde edilen toplam ve bağıl güç değerleri eklenmiştir.

EEG sinyallerinin sınıflandırılmasında, geri yayılım algoritmasıyla eğitilen, üç katmanlı perceptron ağı kullanılmıştır. Ağı öğrenme oranı 0.3 ve eğitim iterasyonu 40 olarak belirlenmiştir. Sınıflandırma sonuçlarının değerlendirilmesinde k-parçalı çapraz doğrulama modeli kullanılmıştır ve veri seti 10 parçaya ayrılmıştır. Veri setinin her parçası, sınıf dağılımı eşit olacak şekilde rastgele örneklerden oluşturulmuştur.

Bu araştırmada, dijital filtreleme yapılmayan, sadece YGF uygulanan, sadece AGF uygulanan ve YGF sonrasında AGF uygulanan EEG sinyallerinin sınıflandırma sonuçları karşılaştırılmıştır. Uygulanan YGF ve AGF karakteristikleri Tablo 5.7'de verilmektedir.

2 ve 4 saniyelik zaman pencereleri kullanılan iki farklı analizin, 2, 3 ve 4 görevli sınıflandırma doğrulukları, Tablo 5.8'de verilmektedir. İkili sınıflandırmada, Tablo 5.6'da görülen birinci setin 1 ve 3 numaralı uyarıları; üçlü sınıflandırmada, 1, 2 ve 3 numaralı uyarıları; dördümlü sınıflandırmada, 1, 2, 3 ve 4 numaralı uyarıları kullanılmıştır.

Tablo 5.8'den iki önemli sonuç çıkmaktadır. Birincisi; tüm deneklerin tüm sınıflandırma işlemlerinde, dijital YGF sınıflandırma performansını ortalama %9.38 yükseltmektedir. Dijital YGF'nin, zaman penceresi, denek ve sınıf sayısından bağımsız

olarak tüm analizlerde sınıflandırma performanslarını yükseltmesi, BBA uygulamasında nöro-başlık üzerindeki YGF'nin tek başına yeterli bir filtreleme performansı göstermediğini ortaya koymaktadır. Diğer taraftan dijital AGF'nin, sınıflandırma performansına önemli bir etki yapmadığı gibi çoğu durumda olumsuz etki yaptığı gözlemlenmektedir. Bu durum, nöro-başlık içinde bulunan AGF'nin yeterli bir sınıflandırma performansı sağlayacak nitelikte olmasıyla açıklanabilir. Bir başka açıklama, yüksek frekanslı gürültülerin sahip olduğu düşük enerjinin, sınıflandırma performansına olumsuz etkisinin çok az; ancak dijital AGF sonucunda oluşan zaman ve hesaplama gecikmelerinin çok fazla etki yapması olabilir.

Tablo 5.8 Elektronik Filtrelemenin Etkisi: 2 ve 4 Saniyelik Zaman Pencereleri
Kullanılan İki Farklı Analizin, 2, 3 ve 4 Görevli Sınıflandırma Doğrulukları

		2s			4s		
		2 Sınıf	3 Sınıf	4 Sınıf	2 Sınıf	3 Sınıf	4 Sınıf
Denek 1	Filtreleme Yok	68.75	55.28	46.04	75.83	59.44	46.67
	Sadece AGF	66.25	56.94	45.00	69.17	58.33	51.25
	Sadece YGF	78.75	62.22	52.71	82.50	64.44	59.58
	AGF + YGF	78.75	57.78	49.17	78.33	67.22	60.83
Denek 2	Filtreleme Yok	92.08	70.83	53.54	90.00	71.11	57.92
	Sadece AGF	90.00	67.78	51.67	85.00	61.67	61.67
	Sadece YGF	96.67	85.83	66.46	94.17	82.22	55.42
	AGF + YGF	97.50	85.00	65.00	93.33	85.56	59.58
Denek 3	Filtreleme Yok	71.25	56.11	51.25	81.67	64.44	57.08
	Sadece AGF	73.33	54.17	51.46	79.17	59.44	55.83
	Sadece YGF	82.92	69.22	67.92	87.50	75.00	74.58
	AGF + YGF	80.83	70.56	67.29	87.50	73.89	70.83
Ortalama	Filtreleme Yok	77.36	60.74	50.28	82.50	65.00	53.89
	Sadece AGF	76.53	59.63	49.38	77.78	59.81	56.25
	Sadece YGF	86.11	72.42	62.36	88.06	73.89	63.19
	AGF + YGF	85.69	71.11	60.49	86.39	75.56	63.75

Araştırmadan elde edilen ikinci önemli sonuç, sinyal işleme aşamasında, sırasıyla YGF ile AGF uygulanan ve sadece YGF uygulanan analizler karşılaştırıldığında ortaya çıkmaktadır. Tablo 5.9'da iki farklı analiz sonucunda elde edilen ortalama sınıflandırma performansları verilmektedir. YGF ardından uygulanan

AGF'nin, sınıflandırma performansını 1.67 ile -1.87 arasında değişen oranlarda etkilediği görülmektedir. Gerçek zamanlı bir BBA sisteminin, beyin aktivitesine en kısa sürede cevap vermesi istenmektedir. Sistemin cevap süresini etkileyen faktörler, zaman penceresi ve analiz algoritmalarından kaynaklanan hesaplama gecikmeleridir. Ayrıca, filtre uzunluğu kaynaklı zaman gecikmesi de hesaba katılması gereken önemli bir etkidir. AGF kaynaklı zaman ve hesaplama gecikmesine karşılık, sınıflandırma performansı en fazla %1.67 oranında artmaktadır. Buna ek olarak, YGF ardından uygulanan AGF sonucunda sınıflandırma performansının %0.42 ile %1.87 arasında değişen oranlarda düştüğü durumlar gözlemlenmektedir. Sonuç olarak, deneyden elde edilen veriler, *Widmann ve ark.* tarafından yapılan, dijital filtrelemenin EEG analizinde mutlak bir aşama olmadığı çıkarımını ve *Van Rullen* tarafından önerilen EEG sinyallerinin analizinde AGF'nin mümkün olan durumlarda uygulanmaması gerektiği savını doğrulamaktadır.

Tablo 5.9 YGF ile AGF Uygulanan ve Sadece YGF Uygulanan BBA Sistemlerinde, Sınıflandırma Performansları

	2s			4s		
	2 Sınıf	3 Sınıf	4 Sınıf	2 Sınıf	3 Sınıf	4 Sınıf
Sadece YGF	86.11	72.42	62.36	88.06	73.89	63.19
AGF + YGF	85.69	71.11	60.49	86.39	75.56	63.75
Değişim	-0.42	-1.31	-1.87	-1.67	1.67	0.56


5.6.2 Kararlı-Durum Görsel Uyaran Potansiyellerin Sınıflandırılmasında Harmoniklerin Sınıflandırmaya Etkisi

Bu çalışmada kullanılan EEG kayıtları yedi farklı kişiden elde edilmiştir. Her denek için toplam 12 dakikalık EEG kaydedilmiştir. Farklı frekanslarda yanıp sönen üç butonlu bir arayüz tasarlanmış ve deneklerden her butona dört dakika bakmaları istenmiştir. Her biri ayrı bir sözde-göreve karşılık gelen uyaran frekansları Tablo 5.10'da verilmektedir. Her uyaran için dört dakikalık EEG kaydedilmiş ve denekler kayıtlar arasında üç dakika dinlendirilmiştir.


Tablo 5.10 Deneyde kullanılan uyaranların harmonik frekansları

Uyaran	1. Harmonik	2. Harmonik	3. Harmonik	4. Harmonik
1	4	8	12	16
2	4.6	9.2	13.8	18.4
3	5.3	10.6	15.9	21.2

Bu çalışma en belirgin KDGUP özelliklerinin, KDGUP cevabının ikinci harmoniğinden elde edilebileceğini göstermiştir. Birinci ve ikinci harmoniklerin birlikte diğer ikili harmonik kombinasyonlarından daha ayırt edici olduğu gözlenmiştir. Tüm denekler için 2 saniyelik pencere uzunluğu kullanılarak ikili ve üçlü sınıflandırmaların doğruluk yüzdeleri sırasıyla Şekil 5.16 ve Şekil 5.17'de verilmektedir. İlk harmoniğin sınıflandırma performansı üzerindeki etkisinin ikinci harmoniğe göre yetersiz olduğu görülmektedir. Diğer yandan, ikinci, üçüncü ve/veya dördüncü harmoniklerden herhangi birinin, birinci harmonik ile birlikte kullanıldığı sınıflandırmalarda, sınıflandırma doğruluğunun büyük ölçüde arttığı görülmektedir.




Şekil 5.16 2-saniye zaman pencereleri ile yapılan ikili sınıflandırmanın doğruluk yüzdeleri




Şekil 5.17 2-saniye zaman pencereleri ile yapılan üçlü sınıflandırmanın doğruluk yüzdeleri

Bu çalışmada ayrıca 4 saniyelik pencere uzunluğu ile ikili ve üçlü sınıflandırmalar gerçekleştirilmiştir. Tüm denekler için 4 saniyelik pencere uzunluğu kullanılarak ikili ve üçlü sınıflandırmaların doğruluk yüzdeleri sırasıyla Şekil 5.18 ve Şekil 5.19'da verilmektedir. 4 saniyelik pencere uzunluğu ile yapılan sınıflandırmalarda, 2 saniyelik pencere uzunluğuyla yapılan çalışma ile paralel sonuçlar elde edilmiştir.



Şekil 5.18 4-saniye zaman pencereleri ile yapılan ikili sınıflandırmanın doğruluk yüzdeleri



Şekil 5.19 4-saniye zaman pencereleri ile yapılan üçlü sınıflandırmanın doğruluk yüzdeleri

Sonuçlar ikinci harmonik tabanlı özelliklerin birinci harmonik tabanlı özelliklerden daha ayırt edici olduğunu göstermektedir. Bu nedenle, sınıflandırma için sadece tek harmonik yeterliyse, ikinci harmonik tabanlı özellikler tercih edilmelidir. Beklendiği gibi, ilk iki harmonik tabanlı sınıflandırmalar, denekten ve zaman penceresi uzunluğundan bağımsız olarak, yalnızca birinci ve yalnızca ikinci harmonik tabanlı sınıflandırmalardan daha iyi sonuç vermektedir. Üçüncü harmoniğin dördüncü harmonikten daha ayırt edici olması beklenmekte olmasına rağmen dördüncü harmonik tabanlı özelliklerin üçüncü harmonik tabanlı özelliklerden daha ayırt edici olduğu gözlenmiştir. Bu sonucun, görsel korteksin uyarılara asimetrik tepkisi nedeniyle oluştuğuna inanılmaktadır.

Tablo 5.11'de, sınıflandırma sonuçları görülmektedir. 1, 2, ve 4 numaralı harmonik tabanlı özelliklerin KDGUP sınıflandırma doğruluğu açısından en iyi doğruluk yüzdelerini verdiği görülmektedir.

Tablo 5.11 KDGUP Harmonik Analizi Sonuçlarının Özeti

Harmonik Seti	Ortalama Doğruluk			
	2 s		4 s	
	2 Sınıf	3 Sınıf	2 Sınıf	3 Sınıf
1	73,6	53,6	78,1	56,0
1,2	85,5	68,9	88,7	74,5
1,2,3	86,1	71,6	88,9	76,1
1,2,4	86,5	71,6	89,8	75,4
1,2,3,4	85,6	70,6	88,1	74,4
2	82,4	66,3	87,3	71,8

5.6.3 Sınıflandırmada Yapay Sinir Ağı ve Destek Vektör Makinesi Algoritmalarının Performanslarının Karşılaştırılması

Sınıflandırıcıların belirli kriterlere göre performanslarının özetlendiği Tablo 4.1, geçmiş yıllarda yapılan BBA tasarımlarında en çok kullanılan yapay öğrenme yöntemleriyle birlikte değerlendirildiğinde, KDGUP sinyallerinin sınıflandırılmasında YSA ve DVM performanslarının araştırılması ihtiyacı oluşmuştur. Bu amaçla, üç denekten elde edilen EEG kayıtları, YSA ve DVM yöntemleriyle sınıflandırılmıştır. EEG kayıtları, birinci araştırmada açıklanan şartlarda gerçekleştirilmiştir. Uyaran olarak, Tablo 5.6'da verilen birinci setin ilk üç frekansı seçilmiştir.

Bu araştırmada, KDGUP sinyallerinin frekans spektrumlarından elde edilen, birinci ve ikinci harmoniklerin bağıl bant gücü değerleri özellik vektörü olarak kullanılmıştır.

Sınıflandırma aşamasında uygulanan YSA, geri yayılım algoritmasıyla eğitilen, üç katmanlı bir perceptron ağıdır. Çok sınıflı DVM olarak, *Chang ve Lin* tarafından geliştirilen LibSVM'den faydalanılmıştır [87]. YSA ve DVM algoritmalarının hiperparametre optimizasyonu için ağ arama (*grid search*) ve çapraz doğrulama kullanılmıştır. KDGUP sinyallerinin sınıflandırma sonuçları Tablo 5.12'de özetlenmektedir. YSA ve DVM sınıflandırıcılarının performansları arasında büyük bir fark gözlemlenmemiştir. Bu durum, her iki algoritmanın merkezlerindeki matematiksel teorilerin aynı olması ile açıklanabilir.

Tablo 5.12 DVM ve YSA Tabanlı KDGUP Sınıflandırma Sonuçları

Denek	Yöntem	Çek. / Akt. Fonksiyonu *	Performans (%)	
			2s	4s
1	DVM	Doğrusal	60.28 (c = 890)	63.89 (c = 280)
	DVM	Sigmoid	60.83 (c = 716, $\gamma = 1.2$)	64.44 (c = 304, $\gamma = 1.6$)
	DVM	Radyal Taban	61.39 (c = 484, $\gamma = 2$)	64.44 (c = 304, $\gamma = 0.8$)
	YSA	Sigmoid	60.56 (ö = 0.1, i = 168) **	64.44 (ö = 0.17, i = 268)
2	DVM	Doğrusal	59.44 (c = 370)	62.22 (c = 316)
	DVM	Sigmoid	58.89 (c = 668, $\gamma = 1.6$)	62.22 (c = 236, $\gamma = 0.8$)
	DVM	Radyal Taban	60.00 (c = 660, $\gamma = 2$)	62.78 (c = 64, $\gamma = 1.6$)
	YSA	Sigmoid	60.83 (ö = 0.45, i = 108)	67.22 (ö = 0.66, i = 72)
3	DVM	Doğrusal	59.17 (c = 60)	71.11 (c = 642)
	DVM	Sigmoid	60.00 (c = 476, $\gamma = 0.4$)	71.11 (c = 652, $\gamma = 1.6$)
	DVM	Radyal Taban	59.72 (c = 476, $\gamma = 0.2$)	71.11 (c = 652, $\gamma = 0.8$)
	YSA	Sigmoid	58.89 (ö = 0.38, i = 64)	71.67 (ö = 0.52, i = 124)
Ort.	DVM	Doğrusal	59.63	65.74
	DVM	Sigmoid	59.9	65.92
	DVM	Radyal Taban	60.37	66.11
	YSA	Sigmoid	60.09	67.77

* Çekirdek / Aktivasyon Fonksiyonu

** ö: öğrenme oranı, i: iterasyon sayısı

İki saniyelik zaman pencerelerinin kullanıldığı sınıflandırma işleminde, bir ve üç numaralı deneklerin DVM, iki numaralı denegin YSA ile en iyi performansı gösterdiği anlaşılmaktadır. Dört saniyelik zaman pencerelerinin kullanıldığı sınıflandırmada ise her üç denek en iyi performansı YSA ile göstermişlerdir. Buna ek olarak, iki saniyelik zaman pencerelerinin kullanıldığı sınıflandırmada, DVM ile YSA sınıflandırıcılarının ortalama performansları arasındaki fark sadece %0.28 olarak ortaya çıkmıştır. Bu fark dört saniyelik zaman pencerelerinin kullanıldığı sınıflandırmada, %1.66 olarak görülmektedir. Sonuçlar her denek için tek başına değerlendirildiğinde ve ortalama sınıflandırma performansları karşılaştırıldığında, zaman penceresi boyutu arttıkça YSA'nın DVM'den daha iyi bir performans gösterdiği çıkarımı yapılabilir.

Tablo 5.12'de özetlenen sonuçların, KDGUP sinyallerinin sınıflandırılmasında tercih edilecek yöntem ile ilgili net bir karar vermek için yeterli olmadığı görülmektedir. YSA ve SVM karşılaştırmasında, sınıflandırıcı tercihini etkileyebilecek başka bir etken, parametrik ve parametrik olmayan iki yöntemin avantajlarının ve dezavantajlarının göz

önünde bulundurulmasıdır. Parametrik bir yöntem olmayan DVM, sınıflandırıcının eğitimi aşamasında, veri setine bağlı olarak çok sayıda destek vektörünün seçimi ve buna bağlı olarak eğitimin zaman alması gibi bir sonuca neden olabilir. Sonuç olarak, KDGUP sinyallerinin sınıflandırılmasında, parametrik bir yöntem olarak YSA önerilmektedir.

5.6.4 Uyarıların Örtüşen Harmonik Frekanslarının Sınıflandırma Performansına Etkisi

KDGUP temelli BBA tasarımlarında, uyarıların temel frekans dışındaki harmoniklerinin özelliklerinin kullanıldığı sınıflandırmalarda, örtüşen frekans değerlerinin tasarımın performansını olumsuz etkilemesi gerektiği öngörülmüştür. Bu durum Tablo 5.6'da 1 ve 2 numaralı setlerde gösterilen uyarı frekansları kullanılarak kaydedilen EEG sinyallerinin sınıflandırma performansları karşılaştırılarak araştırılmıştır. Öncelikle her iki setin 1, 3, 5 ve 6 numaralı uyarıları kullanılarak EEG kaydı gerçekleştirilmiştir. Bu uyarılar, harmonik frekanslardaki örtüşmeleri en çok yapmak için seçilmiştir. İkinci çalışmada elde edilen sonuçlardan dolayı, özellik vektörü, KDGUP sinyallerinin frekans spektrumlarından elde edilen 1, 2 ve 4 numaralı harmoniklerden oluşturulmuştur. Bu durumda, uyarı frekanslarının harmoniklerinin dördünde örtüşme görülen ve hiçbirinde örtüşme görülmeyen iki farklı durumda sınıflandırma performansları karşılaştırılmış olmaktadır. Bu çalışmada ayrıca Tablo 5.6'da verilen her iki setin tüm uyarılarının kullanıldığı kayıtlar sınıflandırılmıştır. Diğer bir deyişle 6 görevli bir sınıflandırma işlemi gerçekleştirilmiştir. Tüm uyarıların kullanıldığı sınıflandırmada, birinci set dört, ikinci set bir örtüşen harmonik içermektedir.

Sınıflandırma aşamasında uygulanan YSA, geri yayılım algoritmasıyla eğitilen, üç katmanlı bir perceptron ağıdır. YSA'nın hiperparametre optimizasyonu, ağ arama ve çapraz doğrulama yöntemiyle gerçekleştirilmiştir. Tablo 5.13'de, elde edilen sonuçlar görülmektedir.

Tablo 5.13 Örtüşen Harmonik Frekanslarının Sınıflandırma Performansına Etkisi

Set	Uyaranlar	
	1, 3, 5, 6	1, 2, 3, 4, 5, 6
1	70.00% (ö = 0.15, i = 94)	59.72% (ö = 0.24, i = 67)
2	74.17% (ö = 0.1, i = 58)	62.22% (ö = 0.24, i = 65)

Dört ve altı görevli sınıflandırma sonuçları, uyaranların harmonik frekanslarındaki örtüşmelerin, BBA tasarımının performansına olumsuz bir etki yaptığını ortaya koymaktadır. Bu etki dört görevli BBA için %4.17, altı görevli BBA için %2.5 olarak görülmektedir. Sonuçlar başlangıçtaki öngörüyü doğrular niteliktedir.



6. SONUÇLAR VE DEĞERLENDİRME

Gerçekleştirilen deneylerden elde edilen bulgular, bilgisayar programlarının KDGUP temelli BBA yoluyla kullanımının belirli koşullarda mümkün olduğunu göstermiştir. Buna ek olarak, tasarımın sinyal işleme, özellik çıkarma ve sınıflandırma aşamalarındaki belirli parametrelerinin, sistem performansına etkisi araştırılmıştır. Sinyal işleme aşamasında, sadece YGF uygulanan EEG, YGF arkasından AGF uygulanan EEG kayıtlarına göre daha iyi ya da aynı sonucu vermektedir. KDGUP uyaran frekanslarının 1, 2 ve 4 numaralı harmoniklerden elde edilen özellikler, en iyi sınıflandırma performansını vermektedir. Son olarak YSA ve DVM sınıflandırıcıları arasında belirgin bir performans farkı gözlemlenmemekle birlikte, zaman penceresi uzunluğu arttıkça YSA sınıflandırıcısının daha iyi bir performans gösterdiği düşünülmektedir. Elde edilen tüm bu veriler sonucunda, en iyi sınıflandırma performansını verecek biçimde, üç denekten elde edilen EEG kayıtları 2 ve 4 görevli olarak sınıflandırılmıştır. İki görevli sınıflandırma işleminde uyaran frekansları, 4 Hz ve 5.3 Hz olarak ayarlanmıştır. Dört görevli sınıflandırma işleminde, 4.6 Hz ve 6.4 Hz frekanslı iki uyaran daha eklenmiştir. Her bir uyaran için dört dakikalık kayıt yapılmış ve denekler her kayıt arasında üç dakika dinlenmiştir. Sinyal işleme aşamasında, EEG sinyallerine sadece YGF uygulanmıştır. Özellik çıkarımı aşamasında, en iyi sınıflandırma sonuçlarını veren 1, 2 ve 4 numaralı harmoniklerden elde edilen bağıl ve toplam bant gücü değerleri kullanılmıştır. Sınıflandırma aşamasında üç katmanlı perceptron ağı kullanılmıştır. Ağın hiperparametre optimizasyonu ağ arama yöntemiyle gerçekleştirilmiştir. Sınıflandırma sonuçlarının değerlendirilmesinde k-parçalı çapraz doğrulama modeli kullanılmıştır ve veri seti 10 parçaya ayrılmıştır. Veri setinin her parçası, sınıf dağılımı eşit olacak şekilde rastgele örneklerden oluşturulmuştur. Tablo 6.1'de 2 görevli, Tablo 6.2'de 4 görevli sınıflandırma sonuçlarının karışıklık matrisleri (*confusion matrix*) verilmektedir.

İki görevli sınıflandırmanın oldukça başarılı sonuçlar verdiği gözlemlenmiştir. İki saniyelik zaman pencerelerinin kullanıldığı tasarımda, deneklerden elde edilen ortalama sınıflandırma doğruluğu %92.22 olarak gerçekleşmiştir. Dört saniyelik zaman pencerelerinin kullanıldığı tasarımda ortalama sınıflandırma performansı %92.5'e yükselmiştir. İkili sınıflandırmada, zaman penceresi uzunluğunun, sınıflandırma performansına oldukça küçük bir etki yaptığı görülmektedir. Dolayısıyla, 1 ve 0.5

saniyelik zaman pencerelerinin, iki görevli BBA tasarımında başarılı performans göstermesi beklenebilir.

Tablo 6.1 İki Görevli Sınıflandırma Sonuçlarının Karışıklık Matrisleri

Denek I						
	2s			4s		
	Gerçek 1	Gerçek 2	Kesinlik	Gerçek 1	Gerçek 2	Kesinlik
Tahmin 1	103	8	92.79%	50	5	90.91%
Tahmin 2	17	112	86.82%	10	55	84.62%
Duyarlılık	85.83%	93.33%		83.33%	91.67%	
Denek II						
	2s			4s		
	Gerçek 1	Gerçek 2	Kesinlik	Gerçek 1	Gerçek 2	Kesinlik
Tahmin 1	120	5	96.00%	58	2	96.67%
Tahmin 2	0	115	100.00%	2	58	96.67%
Duyarlılık	100.00%	95.83%		96.67%	96.67%	
Denek III						
	2s			4s		
	Gerçek 1	Gerçek 2	Kesinlik	Gerçek 1	Gerçek 2	Kesinlik
Tahmin 1	106	12	89.83%	56	4	93.33%
Tahmin 2	14	108	88.52%	4	56	93.33%
Duyarlılık	88.33%	90.00%		93.33%	93.33%	

Dört görevli BBA tasarımında, deneklerden elde edilen ortalama sınıflandırma, iki saniyelik zaman pencereleriyle %65.83, dört saniyelik zaman pencereleriyle %72.92 olarak gerçekleşmiştir. Görev sayısı arttıkça, zaman penceresi uzunluğunun sınıflandırma performansını önemli ölçüde etkilediği gözlemlenmiştir.

Tablo 6.3'de, bu tez çalışmasında faydalanan belirli KDGUP temelli BBA çalışmalarının performansları farklı değişkenlere göre karşılaştırılabilecek biçimde listelenmiştir. KDGUP temelli bir BBA tasarımında, sistemin performansını etkileyebilecek, göz, optik sinir veya görsel korteks gibi görme sistemlerinde görülebilecek hasar veya bozukluklardan, EEG kaydında kullanılan cihazın, örnekleme frekansı, kuvvetlendirici kazancı veya EEG sinyallerinin ölçüm stratejisine kadar

onlarca değişken bulunmaktadır. Tablo 6.3'de, BBA tasarımının bu tez çalışmasında odaklanılan sınırlı sayıdaki değişkenlerine yer verilmiştir.

Tablo 6.2 Dört Görevli Sınıflandırma Sonuçlarının Karışıklık Matrisleri

Denek I										
	2s					4s				
	G1	G2	G3	G4	K*	G1	G2	G3	G4	K*
T1	104	7	9	19	74.82%	50	4	6	7	74.63%
T2	5	63	38	36	44.37%	4	37	11	12	57.81%
T3	3	26	59	23	53.15%	3	9	33	5	66.00%
T4	8	24	14	42	47.73%	3	10	10	36	61.02%
D**	86.67%	52.50%	49.17%	35.00%		83.33%	61.67%	55.00%	60.00%	
Denek II										
	2s					4s				
	G1	G2	G3	G4	K*	G1	G2	G3	G4	K*
T1	107	6	4	8	85.60%	56	3	0	0	94.92%
T2	5	72	7	36	60.00%	4	40	6	25	53.33%
T3	0	6	99	14	83.19%	0	0	48	7	87.27%
T4	8	36	10	62	53.45%	0	17	6	28	54.90%
D**	89.17%	60.00%	82.50%	51.67%		93.33%	66.67%	80.00%	46.67%	
Denek III										
	2s					4s				
	G1	G2	G3	G4	K*	G1	G2	G3	G4	K*
T1	82	16	7	21	65.08%	49	3	2	9	77.78%
T2	13	92	13	8	73.02%	4	51	1	1	89.47%
T3	6	7	95	20	74.22%	4	3	51	4	82.26%
T4	19	5	5	71	71.00%	3	3	6	46	79.31%
D**	68.33%	76.67%	79.17%	59.17%		81.67%	85.00%	85.00%	76.67%	

* Kesinlik

** Duyarlılık

Tablo 6.3 BBA Literatüründeki, KDGUP Temelli Tasarım Parametreleri

Çalışma	Görev Sayısı	Örnekleme Frekansı (Hz)	Zaman Penceresi (s)	Kanallar	Harmonikler	Ortalama Performans (%)
[25]	4	256	2	8 adet [a]	1, 2	82.7
[33]	3	1000	1	Oz	EEMD [b]	94.73
[26]	4	256	4 [c]	PO2	1, 2	75.8
[80]	4	128	2	7 adet [d]	1, 2	90
[27]	5	128	[e]	8 adet [f]	1, 2	89.48 [g]
[28]	2	256	1	O1, O2	1, 2	79.9
[28]	2	256	2	O1, O2	1, 2	89.5
[34]	4	250	2	8 adet [h]	1, 2	79.5 [i]
[34]	4	250	4	8 adet [h]	1, 2	86.5 [j]
Bu Tez	4	128	2	O1, O2	1, 2, 4	65.83
Bu Tez	4	128	4	O1, O2	1, 2, 4	72.92
Bu Tez	2	128	2	O1, O2	1, 2, 4	92.22
Bu Tez	2	128	4	O1, O2	1, 2, 4	92.5

[a] Kanallar: POz, PO3, PO4, PO7, PO8, O1, O2, Oz

[b] EEMD: Ensemble Empirical Mode Decomposition

[c] *Luo ve Sullivan* yaptıkları çalışmada, 2 ile 6 saniye aralığındaki zaman pencerelerinden bahsetmişlerdir. Tabloya, bu değerlerin aritmetik ortalaması olarak 4 saniye yazılmıştır.

[d] Kanallar: PO3, PO4, POz, O1, O2, Oz

[e] *Volosyak* yaptığı çalışmada, uzunlukları 813, 2031 ve 4063 ms olan üç farklı zaman penceresi kullanmıştır.

[f] Kanallar: Pz, PO3, PO4, O1, O2, O9, O10, Oz

[g] *Volosyak*, geliştirdiği BBA uygulamasının yedi denekten elde edilen sınıflandırma başarılarını, en kötü %78.96, en iyi %100 olarak vermiştir. Tabloya bu değerlerin aritmetik ortalaması olarak % 89.48 yazılmıştır.

[h] Kanallar: P7, P3, Pz, P4, P8, O1, O2, Oz

[i] *Zhang ve ark.* 2 saniyelik zaman pencereleriyle yaptıkları çalışmada, sınıflandırma performansının %75 ile %84 olduğunu belirtmişlerdir. Tabloya bu değerlerin aritmetik ortalaması %79.5 yazılmıştır.

[j] *Zhang ve ark.* 4 saniyelik zaman pencereleriyle yaptıkları çalışmada, sınıflandırma performansının %81 ile %92 olduğunu belirtmişlerdir. Tabloya bu değerlerin aritmetik ortalaması %86.5 yazılmıştır.

Tablo 6.3'de görüldüğü üzere, BBA tasarımlarında kullanılan zaman penceresi uzunluğu 1 ile 4 saniye aralığında değişmektedir. Bununla birlikte zaman penceresi uzunluğunun 0.5 ile 8 saniye aralığında değiştiği çalışmalar bulunmaktadır [34]. Zaman penceresi uzunluğu arttıkça, özellikle çok görevli BBA tasarımlarının performansları artmaktadır. Diğer taraftan zaman penceresi uzunluğu sistemin karar verme süresini uzatan bir etkidir. Tablo 6.3 incelendiğinde, BBA tasarımında optimum sistem

performansının 2 saniyelik zaman pencereleriyle elde edildiği çıkarımı yapılabilir. Ancak, 1 saniye veya daha kısa zaman pencerelerinin kullanılması, daha doğal bir insan-makine etkileşimi gerçekleştirmek için daha uygun bir tercih olacaktır.

BBA tasarımlarında karşılaşılan zaman penceresi ikilemi, örnekleme frekansı için de geçerlidir. Yüksek frekanslı bir örneklemenin daha iyi bir sistem performansı göstermesi beklenebilir. Diğer taraftan saniyedeki örnek sayısının artması, algoritmik hesaplamalardan kaynaklanan zaman gecikmesi anlamına gelmektedir. Yüksek frekanslı bir örnekleme yaptıktan sonra, aşağı örnekleme yöntemiyle saniyedeki örnek sayısının azaltılması olası bir çözümdür.

KDGUP temelli bir BBA tasarımında temel değişkenlerden biri, EEG kaydının yapıldığı kanallardır. Literatürde tek kanallı tasarımlar bulunduğu gibi [33], kanal sayısının 13'e kadar çıktığı görülmektedir [79]. Kanal sayısı, örnekleme frekansı ve zaman penceresi uzunluğu gibi, ikilem yaratan bir değişkendir. Kanal sayısındaki artış, analiz aşamasında saniyedeki veri sayısındaki artış anlamına gelmektedir. Bu durumda hesaplama zamanının artış göstermesi beklenir. Diğer taraftan, literatürdeki diğer çalışmalar incelendiğinde, çok kanallı BBA tasarımlarının daha iyi sınıflandırma performansı gösterdiği anlaşılmaktadır.

Tablo 5.16'da yer verilememekle birlikte, tüm çalışmalarda EEG sinyallerine YGF ve AGF uygulanmıştır. Bu tez çalışması ile literatürdeki diğer çalışmalar arasındaki farklardan biri, EEG sinyallerine sadece YGF uygulanmasıdır. Bu durum, bu tez çalışmasını literatürdeki diğer çalışmalardan ayıran önemli unsurlardan biridir.

Tablo 5.16'da verilen çalışmalar ile bu tez çalışması arasındaki en belirgin fark, sınıflandırmada kullanılan özelliklerin, 1, 2 ve 4 numaralı harmoniklerden elde edilmesidir. Literatürde en çok karşılaşılan özellikler, sadece birinci ya da ilk iki harmoniğin bağıl ve toplam bant güçlerinden çıkarılmaktadır. Literatürde 1, 2 ve 4 numaralı harmoniklerden elde edilen özelliklerin kullanıldığı bir BBA tasarımına rastlanmamıştır. Saniyedeki örnek sayısının görece azlığı ve sadece iki kanalın kullanıldığı göz önünde bulundurulursa, 1, 2 ve 4 numaralı harmoniklerden elde edilen özelliklerle yapılan sınıflandırmanın literatürdeki diğer çalışmalara göre daha iyi performans gösterdiği anlaşılmaktadır. Diğer taraftan, BBA tasarımlarını etkileyen değişkenlerin çokluğu, herhangi bir çalışmanın literatürdeki diğer çalışmalarla bire bir

karşılaştırılmasını oldukça güç hale getirmektedir. EEG kaydında kullanılan cihazın özellikleri (örnekleme frekansı, kuvvetlendirici kazancı, vb.), uyaran programın özellikleri (uyaranların frekansları, boyutları, renkleri, biçimleri, vb.), denekler (deneğin görme bozuklukları, motivasyonu, vb.), çevre (ortam aydınlatması, elektromanyetik girişim, vb.) gibi birçok etken, BBA tasarımının performansını doğrudan etkilemektedir. Bu tez ve literatürdeki diğer tüm BBA çalışmalarında, ortam aydınlatması, denek motivasyonu, uyaranlar ile denek arasındaki uzaklık, uzun süren EEG kaydı sırasındaki hareketsizlikten kaynaklanan rahatsızlık, uyaran frekansları ile görsel kortekste görülen alfa ritmi frekansındaki örtüşmeler, sürekli yanıp sönen uyaranların gözlerde oluşturduğu yorgunluk vb. kontrol dışı birçok etken, tasarımın performansını düşürmektedir.

KAYNAKLAR

- [1] Sanei, S., Chambers, J.A. (2007) EEG Signal Processing, John Wiley and Sons Ltd., West Sussex, İngiltere
- [2] Nicolas-Alonso, L.F., Gomez-Gil, J. (2012) Brain Computer Interfaces, a Review. Sensors, 12(2), 1211-1279
- [3] Öner, M., Hu, G. (2013) Analyzing One-Channel EEG Signals for Detection of Close and Open Eyes Activities. 2nd IIAI International Conference on Advanced Applied Informatics, 31 Ağustos - 4 Eylül, Los Alamitos, CA, ABD
- [4] VanErp, J., Lotte, F., Tangermann, M. (2012) Brain-Computer Interfaces: Beyond Medical Applications. Computer, 45(4), 26-34
- [5] Larsen E.A. (2011) Classification of EEG Signals in a Brain-Computer Interface System. Yüksek Lisans Tezi, Norwegian University of Science and Technology, Department of Computer and Information Science, Trondheim, Norveç
- [6] Nijholt A., Tan D. (2008) Brain-Computer Interfacing for Intelligent Systems. IEEE Intelligent Systems, 23(3), 72-79
- [7] Ortiz, S. (2007) Brain-Computer Interfaces: Where Human and Machine Meet. Computer, 40(1), 17-21
- [8] Palaniappan, R. (2010) Biological Signal Analysis, Ventus Publishing ApS, Kopenhag, Danimarka
- [9] Buzsáki, G. (2006) Rhythms of the Brain, Oxford University Press, Inc., New York, ABD
- [10] Luck S.J. (2014) An Introduction to the Event-Related Potential Technique, 2nd Edition, MIT Press, Cambridge, MA, ABD
- [11] Wolpaw, J.R., Birbaumer, N., McFarland, D.J., Pfurtscheller, G., Vaughan, T.M. (2002) Brain-Computer Interfaces for Communication and Control. Clinical Neurophysiology 113, 767-791

- [12] Bernhard, G., Allison, B.Z., Pfurtscheller, G. (2010) Brain-Computer Interfaces Revolutionizing Human-Computer Interaction, Springer-Verlag GmbH, Berlin, Almanya
- [13] Bashashati, A., Fatourehchi, M., Ward, R.K., Birch, G.E. (2007) A Survey of Signal Processing Algorithms in Brain-Computer Interfaces Based on Electrical Brain Signals. *Journal of Neural Engineering* 4, 32-57
- [14] Dornhege, G., Millan, J., Hinterberger, T., McFarland, D.J., Müller, K.R. (2007) *Toward Brain-Computer Interfacing*, MIT Press, Cambridge, MA, ABD
- [15] Hwang, H., Kwon, K., Im, C. (2009) Neurofeedback-Based Motor Imagery Training for Brain-Computer Interface (BCI). *Journal of Neuroscience Methods*, 179(1), 150-156
- [16] Kaiser, V., Bauerfeind, G., Kreilinger, A., Kaufmann, T., Kübler, A., Neuper, C., Müller-Putz, G.R. (2014) Cortical Effects of User Training in a Motor Imagery Based Brain-Computer Interface Measured by fNIRS and EEG. *NeuroImage*, 85(1), 432-444
- [17] Hvaring, F.T., Ulltveit-Moe, A.H. (2014) A Comparison of Visual Evoked Potential (VEP)-Based Methods for the Low-Cost Emotiv EPOC Neuroheadset. Yüksek Lisans Tezi, Norwegian University of Science and Technology, Department of Computer and Information Science, Trondheim, Norveç
- [18] Erdoğan, H.B. (2009) A Design and Implementation of P300 Based Brain-Computer Interface. Yüksek Lisans Tezi, Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, Türkiye
- [19] Li, Y. (2009) A P300 Based Brain-Computer Interface (BCI): Effects of Luminosity Contrast, Stimulus Duration, Interface Type and Screen Size. Yüksek Lisans Tezi, University of Arkansas, Department of Industrial Engineering, Fayetteville, ABD

- [20] Panicker, R.C., Puthusserypady, S., Sun, Y. (2010) Adaptation in P300 Brain-Computer Interfaces: A Two-Classifer Cotraining Approach. IEEE Transactions on Biomedical Engineering, 57(12), 2927-2935
- [21] Ryan, D.B. (2011) Improving Brain-Computer Interface Performance: Giving the P300 Speller Some Color. Yüksek Lisans Tezi, East Tennessee State University, Department of Psychology, Johnson City, TN, ABD
- [22] Abhari, K. (2008) Design, Implementation and Evaluation of P300 Based Brain-Computer Interface Speller and Lie Detector. Yüksek Lisans Tezi, University of Manitoba, Faculty of Graduate Studies, Winnipeg, Kanada
- [23] Odom, J.V., Bach, M., Brigell, M., Holder, G.E., McCulloch, D.L., Mizota, A., Tormene, A.P. (2016) ISCEV Standard for Clinical Visual Evoked Potentials: (2016 update). Documenta Ophthalmologica, 133(1), 1-9
- [24] Odom, J.V., Bach, M., Barber, C., Brigell, M., Marmor, M.F., Tormene, A.P., Holder, G.E. (2004) Visual Evoked Potentials Standard. Documenta Ophthalmologica, 108(2), 115-123
- [25] Robert Prueckl, R., Guger, C. (2009) A Brain-Computer Interface Based on Steady State Visual Evoked Potentials for Controlling a Robot. 10th International Work-Conference on Artificial Neural Networks, 10-12 Haziran, Salamanca, İspanya
- [26] Luo, A., Sullivan, T.J. (2010) A User-Friendly SSVEP-Based Brain-Computer Interface using a Time-Domain Classifier. Journal of Neural Engineering, 7(2), 026010
- [27] Volosyak, I. (2011) SSVEP-Based Bremen-BCI Interface - Boosting Information Transfer Rates. Journal of Neural Engineering, 8(3), 036020
- [28] Lalor, E.C., Kelly, S.P., Finucane, C., Burke, R., Smith, R., Reilly, R.B., McDarby, G. (2005) Steady-State VEP-Based Brain-Computer Interface Control in an Immersive 3D Gaming Environment. EURASIP Journal on Applied Signal Processing, 2005(19), 3156-3164

- [29] Kelly, S.P., Lalor, E.C., Finucane, C., McDarby, G., Reilly, R.B. (2005) Visual Spatial Attention Control in an Independent Brain-Computer Interface. *IEEE Transactions on Biomedical Engineering*, 52(9), 1588-1596
- [30] Muller-Putz, G.R., Pfurtscheller, G. (2008) Control of an Electrical Prosthesis with an SSVEP-Based BCI. *IEEE Transactions on Biomedical Engineering*, 55(1), 361-364
- [31] Bin, G., Gao, X., Yan, Z., Hong, B., Gao, S. (2009) An Online Multi-Channel SSVEP-Based Brain-Computer Interface using a Canonical Correlation Analysis Method. *Journal of Neural Engineering*, 6(4), 046002
- [32] Long, J., Li, Y., Wang, H., Yu., T., Pan, J., Li, F. (2012) A Hybrid Brain Computer Interface to Control the Direction and Speed of a Simulated or Real Wheelchair. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 20(5), 720-729
- [33] Lee, P., Chang, H., Hsieh, T., Deng, H., Sun, C. (2012) A Brain-Wave-Actuated Small Robot Car using Ensemble Empirical Mode Decomposition-Based Approach. *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems And Humans*, 42(5), 1053-1064
- [34] Zhang, Y., Zhou, G., Jin, J., Wang, X., Cichocki, A. (2015) SSVEP Recognition using Common Feature Analysis in Brain-Computer Interface. *Journal of Neuroscience Methods*, 244, 8-15
- [35] Sakurada, T., Kawase, T., Komatsu, T., Kansaku, K. (2015) Use of High-Frequency Visual Stimuli Above the Critical Flicker Frequency in a SSVEP-Based BMI. *Clinical Neurophysiology*, 126(10), 1972-1978
- [36] Müller-Putz, G.R., Scherer, R., Neuper, C., Pfurtscheller, G. (2006) Steady-State Somatosensory Evoked Potentials: Suitable Brain Signals for Brain-Computer Interfaces?. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(1), 30-37
- [37] Hasan, K., Hossain, S., Ghosh, T.K., Ahmad, M. (2015) A SSVEP Based EEG Signal Analysis to Discriminate the Effects of Music Levels on Executional Attention. *American Journal of Bioscience and Bioengineering*, 3(3-1), 27-33

- [38] Gembler, F., Stawicki, P., Volosyak, I. (2015) A Comparison of SSVEP-Based BCI-Performance Between Different Age Groups. 13th International Work-Conference on Artificial Neural Networks, 10-12 Haziran, Palma de Mallorca, İspanya
- [39] Chen, X., Zhao, B., Wang, Y., Gao, X. (2019) Combination of High-Frequency SSVEP-based BCI and Computer Vision for Controlling a Robotic Arm, *Journal of Neural Engineering*, 16, 026012.
- [40] Park, S., Cha, H., Im, C. (2019) Development of an Online Home Appliance Control System using Augmented Reality and an SSVEP-Based Brain-Computer Interface, *IEEE Access* 7 163604–163614.
- [41] Choi, K., Park, S., Im, C. (2019) Comparison of Visual Stimuli for Steady-State Visual Evoked Potential-Based Brain-Computer Interfaces in Virtual Reality Environment in terms of Classification Accuracy and Visual Comfort, *Computational Intelligence and Neuroscience*, 9680697.
- [42] Buzsáki, G., Watson, B.O. (2012) Brain Rhythms and Neural Syntax: Implications for Efficient Coding of Cognitive Content and Neuropsychiatric Disease. *Dialogues in Clinical Neuroscience*, 14(4), 345-367
- [43] Wolpaw, J.R., Wolpaw, E.W. (2012) *Brain-Computer Interfaces Principles and Practice*, Oxford University Press, Inc., New York, ABD
- [44] Moazzami, M. (2012) *EEG Signal Processing in Brain-Computer Interface*. Yüksek Lisans Tezi, Michigan State University, Department of Computer Science, East Lansing, MI, ABD
- [45] Hinic, V. (2009) *Brain Computer Interface System for Communication Robot Control Based on Auditory Evoked Event-Related Potentials*. Yüksek Lisans Tezi, University of Ottawa, Faculty of Graduate and Postdoctoral Studies, Ottawa, Kanada
- [46] Proakis, J.G., Manolakis, D.G. (2006) *Digital Signal Processing*, 4th Edition, Pearson, Upper Saddle River, NJ, ABD
- [47] Semmlow, J.L. (2004) *Biosignal and Biomedical Image Processing Matlab-Based Applications*, Marcel Dekker Inc., New York, NY, ABD

- [48] Bose, T. (2003) Digital Signal and Image Processing, John Wiley and Sons Inc., Hoboken, NJ, ABD
- [49] Haykin, S., Moher, M. (2013), Communication Systems, 5th Edition International Student Version, John Wiley and Sons (Asia) Pte. Ltd.
- [50] Smith, W. (1997) The Scientist and Engineer's Guide to Digital Signal Processing, <http://www.dspguide.com/pdfbook.htm> (02.02.2016)
- [51] Shenoi, B.A. (2006) Introduction to Digital Signal Processing and Filter Design, John Wiley and Sons Inc., Hoboken, NJ, ABD
- [52] Repovš, G. (2010) Dealing with Noise in EEG Recording and Data Analysis. Informatica Medica Slovenica, 15, 18-25
- [53] Kofronov, M., Biolek, D. (1996) Artefact Filtering from Human EEG. 39th Midwest Symposium on Circuits and Systems, 21 Ağustos, Ames, IA, ABD
- [54] Alpaydm, E. (2004) Introduction to Machine Learning, MIT Press, Cambridge MA, ABD
- [55] Fernandez-Delgado, M., Cernadas, E., Barro, S., Amorim, D. (2014) Do we Need Hundreds of Classifiers to Solve Real World Classification Problems?. Journal of Machine Learning Research, 15, 3133-3181
- [56] Kotsiantis, S.B. (2007) Supervised Machine Learning: A Review of Classification Techniques. Informatica, 31, 249-268
- [57] Lotte, F., Congedo, M., Lecuyer, A., Lamarche, F., Arnaldi, B. (2007) A Review of Classification Algorithms for EEG-Based Brain-Computer Interfaces. Journal of Neural Engineering, 4(2), R1
- [58] Zhou, J. (2011) EEG Data Analysis, Feature Extraction and Classifiers. Yüksek Lisans Tezi, Clemson University, Graduate School of Clemson University, Clemson, SC, ABD
- [59] Lytton, W.W. (2002) From Computer to Brain Foundations of Computational Neuroscience, Springer-Verlag Inc., New York, NY, ABD

- [60] Yıldız, A. (2011) EEG ve EKG İşaretlerinden Örüntü Tanıma Uygulamaları ve Karşılaştırılması. Doktora Tezi, Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ, Türkiye
- [61] Rosenblatt, F. (1958) The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65(6), 386-408
- [62] Theodoridis, S., Koutroumbas, K. (2003) *Pattern Recognition*, 2nd Edition, Elsevier Academic Press, San Diego, CA, ABD
- [63] Kriesel, D. (2007) *A Brief Introduction to Neural Networks*, <http://www.dkriesel.com> (19.03.2016)
- [64] Duda, R.O., Hart, P.E., Stork, D.G. (2000) *Pattern Classification*, 2nd Edition, John Wiley and Sons Inc., Hoboken, NJ, ABD
- [65] Yakut, E. (2012) Veri Madenciliği Tekniklerinden C5.0 Algoritması ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama. Doktora Tezi, Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Erzurum, Türkiye
- [66] Bhuvaneswari, P., Kumar, J.S. (2013) Support Vector Machine Technique for EEG Signals. *International Journal of Computer Applications*, 63(13), 1-5
- [67] Ma, Y., Guo, G. (2014) *Support Vector Machines Applications*, Springer International Publishing AG, Cham, İsviçre
- [68] Hsu, C.W., Lin, C.J. (2002) A Comparison of Methods for Multiclass Support Vector Machines. *IEEE Transactions on Neural Networks*, 13(2), 415-425
- [69] Ferree, T.C., Luu, P., Russell, G.S., Tucker, D.M. (2001) Scalp Electrode Impedance, Infection Risk, and EEG Data Quality. *Clinical Neurophysiology*, 112(3), 536-544
- [70] Teplan, M. (2002) Fundamentals of EEG Measurement. *Measurement Science Review*, 2(2), 1-11
- [71] Jurcak, V., Tsuzuki, D., Dan, I. (2007) 10/20, 10/10, and 10/5 Systems Revisited: Their Validity as Relative Head-Surface-Based Positioning Systems. *NeuroImage*, 34(4), 1600-1611

- [72] Chatrian, G.E., Lettich, E., Nelson, P.L. (1985) Ten Percent Electrode System for Topographic Studies of Spontaneous and Evoked EEG Activities. *American Journal of EEG Technology*, 25(2), 83-92
- [73] Marx, E., Benda, M., Volosyak, I. (2019) Optimal Electrode Positions for an SSVEP-based BCI. 2019 IEEE International Conference on Systems, Man and Cybernetics, Bari, Italy
- [74] <https://www.emotiv.com/epoc/> (18/02/2017)
- [75] Norcia, A.M., Appelbaum, L.G., Ales, J.M., Cottareau, B.R., Rossion, B. (2015) The Steady-State Visual Evoked Potential in Vision Research: A Review. *Journal of Vision*, 15(6), 1-46
- [76] Cao, T., Wan, F., Mak, P.U., Mak, P.I., Vai, M.I., Hu, Y. (2012) Flashing Color on the Performance of SSVEP-Based Brain-Computer Interfaces. 34th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 28 August-1 Eylül, San Diego, CA, ABD
- [77] Widmann, A., Schröger, E., Maess, B. (2014) Digital Filter Design for Electrophysiological Data - A Practical Approach. *Journal of Neuroscience Methods*, 250, 34-46
- [78] VanRullen, R. (2011) Four Common Conceptual Fallacies in Mapping the Time Course of Recognition. *Frontiers in Psychology*, 2, Article 365
- [79] Wang, Y., Wang, R., Gao, X., Hong, B., Gao, S. (2006) A Practical VEP-Based Brain-Computer Interface. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 14(2), 234-239
- [80] Gollee, H., Volosyak, I., McLachlan, A.J., Hunt, K.J., Graser, A. (2010) An SSVEP-Based Brain-Computer Interface for the Control of Functional Electrical Stimulation. *IEEE Transactions on Biomedical Engineering*, 57(8), 1847-1855
- [81] Xing, X., Wang, Y., Pei, W., Guo, X., Liu, Z., Wang, F., Ming, G., Zhao, H., Gui Q., Chen, H. (2108) A High-Speed SSVEP-Based BCI using Dry EEG Electrodes. *Scientific Reports*, 8:14708

- [82] Gao, Z., Zhang, K., Dang, W., Yang, Y., Wang, Z., Duan, H., Chen, G. (2018) An Adaptive Optimal-Kernel Time-Frequency Representation-based Complex Network Method for Characterizing Fatigued Behavior Using the SSVEP-based BCI System. *Knowledge Based Systems*, 152, 163-171
- [83] Sadeghi, S., Maleki, A. (2020) Character Encoding Based on Occurrence Probability Enhances Theperformance of Ssvep-Based BCI Spellers. *Biomedical Signal Processing and Control*, 58, 101888
- [84] Chen, X., Zhao, B., Wang, Y., Gao, X. (2019) Combination of High-Frequency SSVEP-Based BCI and Computer Vision for Controlling a Robotic Arm. *Journal of Neural Engineering*, 16, 026012
- [85] Shao, L., Zhang, L., Belkacem, A.N., Zhang, Y., Chen, X., Li, J., Liu, H. (2020) EEG-Controlled Wall-Crawling Cleaning Robot Using SSVEP-Based Brain-Computer Interface. *Journal of Healthcare Engineering*, 2020, 6968713
- [86] Nguyen, T., Chung, W. (2018) A Single-Channel SSVEP-Based BCI Speller using Deep Learning. *IEEE Access*, 7, 1752-1763
- [87] Chang, C.C., Lin, C.J. (2011) LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3), Article 27