

**T.C.
BOZOK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

Doktora Tezi

**DÖRT ROTORLU İNSANSIZ HAVA ARACININ
GÖRSEL GERİ BESLEMELİ BİRLEŞTİRİLMİŞ EEG
VE EMG BİYOLOJİK SİNYALLERİ İLE KONTROLÜ**

Cemil ALTIN

**Tez Danışmanı
Yrd. Doç. Dr. Orhan ER**

Yozgat 2017

**T.C.
BOZOK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI**

Doktora Tezi

**DÖRT ROTORLU İNSANSIZ HAVA ARACININ
GÖRSEL GERİ BESLEMELİ BİRLEŞTİRİLMİŞ EEG
VE EMG BİYOLOJİK SİNYALLERİ İLE KONTROLÜ**

Cemil ALTIN

**Tez Danışmanı
Yrd. Doç. Dr. Orhan ER**

**Bu çalışma, Bozok Üniversitesi Bilimsel Araştırma Projeleri Birimi
tarafından 2015 FBE/T166 nolu proje ile desteklenmiştir.**

Yozgat 2017

T.C.
BOZOK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

TEZ ONAYI

Enstitümüzün Mekatronik Mühendisliği Anabilim Dalı Doktora Programı 70111813001 numaralı öğrencisi Cemil ALTIN'nın hazırladığı “**DÖRT ROTORLU İNSANSIZ HAVA ARACININ GÖRSEL GERİ BESLEMELİ BİRLEŞTİRİLMİŞ EEG VE EMG BİYOLOJİK SİNYALLERİ İLE KONTROLÜ**” başlıklı tezi ile ilgili tez savunma sınavı, Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliği'nin ilgili maddeleri gereğince 11/10/2017 Çarşamba günü saat 10:00'da yapılmış, tezin onayına oy birliği ile karar verilmiştir.

Başkan : Prof. Dr. Mehmet Emin YÜKSEL

Jüri Üyesi : Prof. Dr. Feyzullah TEMURTAŞ

Jüri Üyesi : Yrd. Doç. Dr. Orhan ER
(Danışman)

Jüri Üyesi : Yrd. Doç. Dr. Halit ÖZTEKİN

Jüri Üyesi : Yrd. Doç. Dr. Fehim KÖYLÜ

ONAY:

Bu tezin kabulü, Enstitü Yönetim Kurulu'nun .01.../11.../2017 tarih ve .28. sayılı Enstitü Yönetim Kurulu Kararı ile onaylanmıştır.


Doç. Dr. Fuat KÖKSAL
Müdür

İÇİNDEKİLER

Sayfa

ÖZET.....	iii
ABSTRACT	v
TEŞEKKÜR	vii
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	x
KISALTMALAR LİSTESİ.....	xiv
GİRİŞ	1
1. İNSAN MAKİNE ETKİLEŞİMİ.....	7
1.1. EMG Tabanlı İnsan Makine Etkileşimi	7
1.1.1. EMG Sinyalinin Tarihçesi	7
1.1.2. EMG Sinyalinin Oluşumu.....	8
1.1.3. EMG Sinyalinin Algılanması.....	9
1.1.4. EMG Sinyalinde Gürültüler	12
1.1.5. EMG Elektrot Yerleşimi	13
1.2. EEG Tabanlı İnsan Makine Etkileşimi	14
1.2.1. EEG Sinyalinin Tarihçesi.....	14
1.2.2. EEG Sinyalinin Oluşumu.....	15
1.2.3. EEG Sinyalinin Algılanması	17
1.2.4. EEG Sinyalinde Gürültüler	19
1.2.5. EEG Elektrot Yerleşimi	19
2. SİNYAL İŞLEME	22
2.1. DC Sapma Geriliminin Yok Edilmesi	22
2.2. Yüksek Geçiren Filtre	24
2.3. Alçak Geçiren Filtre	25
2.4. 50 Hz Notch Filtre.....	26
3. ÖZELLİK ÇIKARIMI	27
4. SINIFLANDIRMA.....	66
4.1. K-En Yakın Komşu.....	66
4.2. Diskriminant Analizi	69
4.2.1. Lineer Diskriminant Analizi	69

4.2.2. İkinci Dereceden (Kuadratik) Diskriminant Analizi.....	72
4.3. Yapay Sinir Ağları	73
4.4. Naive Bayes Sınıflandırıcı	76
4.5. Destek Vektör Makineleri	77
5. UYGULAMA ARAÇLARI Ve UYGULAMA ADIMLARI	81
5.1. Dört Rotorlu İnsansız Hava Aracı.....	81
5.2. 3 Boyutlu Sanal Gerçeklik Oyun Ortamı	84
5.3. Sinyal İşleme Grafik Arayüzü.....	90
5.4. Gerçek Oyun Kumandası	94
5.5. İHA'ya Komut Gönderimi İçin Kumanda Tadilatı.....	95
5.6. Uygulamanın Gerçekleştirilmesi.....	99
SONUÇLAR	109
TARTIŞMA VE ÖNERİLER	138
KAYNAKLAR	141
EKLER.....	149
EK-1 Etik Kurul Raporu	149
ÖZGEÇMİŞ.....	150

DÖRT ROTORLU İNSANSIZ HAVA ARACININ GÖRSEL GERİ BESLEMELİ BİRLEŞTİRİLMİŞ EEG VE EMG BİYOLOJİK SİNYALLERİ İLE KONTROLÜ

Cemil ALTIN

**Bozok Üniversitesi
Fen Bilimleri Enstitüsü
Mekatronik Mühendisliği Anabilim Dalı
Doktora Tezi**

2017; Sayfa:150

Tez Danışmanı: Yrd. Doç. Dr. Orhan ER

ÖZET

Bu tez çalışmasında, EEG (Elektroensefalogram) ve EMG (Elektromyogram) biyolojik sinyalleri kullanılarak 4 rotorlu bir insansız hava aracının (İHA) hem gerçek ortamda hem de performans testlerinin de yapılabildiği bir sanal gerçeklik ortamında uçuş kontrolü gerçekleştirilmiştir. Sanal gerçeklik oyunu içerisinde ve gerçek İHA kontrolü uygulamasında yörünge planlama ile kontrol performansı çıkarılmıştır. Bu amaç için oluşturulan sanal gerçeklik oyunu içerisinde uçuş kontrollerinin simüle edilmesi, farklı gerçeklik ortamlarında yörünge planlaması ve uçuş kontrol performansının test edilmesi amaçlanmıştır.

EEG sinyali İHA'nın kalkış ve inişi için, EMG sinyali ise İHA'yı yönlendirmek (sağa, sola, ileri, geri hareket işlemi) için kullanılmıştır. Yönlendirme komutlarının oluşturulması için EEG ve EMG sinyalleri ile filtreleme, özellik çıkarma, boyut azaltma ve sınıflandırma işlemleri yapılmıştır. Özellik çıkarımı yapılırken hem zaman hem de frekans domenli özelliklerden faydalanılmıştır. Sınıflandırıcı olarak da EYK, LDA, KDA, YSA, DVM ve Naive Bayes sınıflandırıcı algoritmaları kullanılmıştır. Bu çalışma ve yapılan performans testleri neticesinde, biyolojik sinyaller kullanılarak bir İHA'nın uçuş kontrolleri başarıyla gerçekleştirilmiştir. Ayrıca engelli insanların kas ve düşünce gücü ile yönlendirme yapabilecekleri bir sanal gerçeklik uygulaması oluşturulmuştur. Tasarlanan farklı sahnelere

sahip oyun ortamında, uçuş keyfini tamamen düşünerek ve kaslarını oynatarak yapabilmeleri sağlanmıştır.

Böylelikle birçok aleti, oyuncacı veya makineyi kontrol etmekte kullanılan pahalı eldivenlere, joystiklere veya kumandalara alternatif sunulmuştur. Kısmi ortopedik engelli bireyler için fizik tedaviye alternatif bir uygulama oluşturulmuştur. Birçok alanda veya sektörde oldukça sık kullanılan dört rotorlu İHA kontrolüne, hibrit biyolojik sinyalleri ile kontrol edilerek yeni bir boyut kazandırılmıştır. Gelecek çalışmalara ilham oluşturacak bu özellikler, bu tez çalışmasının özgün tarafını da oluşturmaktadır.



Anahtar Kelimeler: Elektroensefalogram, Elektromiyogram, İnsansız hava aracı otomatik kontrolü, 3D sanal oyun, Sinyal işleme.

CONTROL OF FOUR ROTOR UNMANNED AERIAL VEHICLE WITH VISUAL FEEDBACK VIA COMBINED EEG AND EMG BIOLOGICAL SIGNALS

Cemil ALTIN

**Bozok University
The Institute of Science and Technology
Department of Mechatronics Engineering
Doctor of Philosophy Thesis**

2017; Pages:150

Supervisor: Assist. Prof. Dr. Orhan ER

ABSTRACT

In this thesis study, flight control was carried out using a 4-rotor unmanned aerial vehicle using EEG (Electroencephalogram) and EMG (Electromyogram) biological signals, in the real-world and virtual reality environment where performance tests can be performed. Control performance is achieved by trajectory planning in virtual reality game and real unmanned aerial control application. For this purpose, it is aimed to simulate flight controls in virtual reality game, to plan orbit in different reality environments and to test flight control performance.

The EEG signal is used for take-off and landing of the UAV (Unmanned Aerial Vehicle), and the EMG signal is used to move the UAV to the right, left, forward, and backward. Filtering, feature extraction, size reduction and classification were performed with EEG and EMG signals for the creation of direction commands. When the feature extraction is performed, both time and frequency domain features are utilized. EYK, LDA, KDA, YSA, DVM and Naive Bayes classification algorithms are used as classifier. As a result of these studies and performance tests, flight control of an unmanned aerial vehicle using biological signals have been successfully performed. In addition, a virtual reality application was created to enable people with disabilities to control with muscle and mind power. In the game environment with different designed scenes, it is possible to think about flight pleasure completely and to play by playing the muscles. Thus, a system is offered as an alternative to expensive gloves joysticks or remote controllers used to control many tools, toys or machines. An alternative

application for physical treatment for partial orthopedically impaired individuals has been established. A new dimension has been added to the four-rotor unmanned aerial vehicle control, which is often used in many areas or industries. These characteristics, which will inspire future work, also constitute the original side of our work.



Keywords: Electroencephalogram, Electromyogram, UAV control, 3D virtual game, Signal processing.

TEŞEKKÜR

Çalışmalarında emeğini, bilgilerini ve yardımlarını esirgemeyen danışmanım Yrd. Doç. Dr. Orhan ER'e ve maddi, manevi destekleriyle bana yardımcı olan ailem ve eşime teşekkür ederim.



TABLÖLAR LİSTESİ

Sayfa

Tablo 2.1: EEG ve EMG sinyallerinin frekans aralıkları	22
Tablo 2.2: EEG sinyalinin alt bantları	24
Tablo 3.1: Kullanılan özellik çıkarma yöntemleri	27
Tablo 3.2: EEG sinyalinin alt bantları ve dalgacık dönüşümünde karşılıkları.....	59
Tablo 3.3: EEG sinyalinin alt bantları ve oluşum durumları	60
Tablo 3.4: 8 özellikli örnek veri setinin korelasyon matrisi.....	63
Tablo 3.5: 8 özelliğin özdeğerleri	64
Tablo 5.1: Olimex EMG cihazının özellikleri.....	86
Tablo 5.2: Emotiv Epoc+ EEG cihazının özellikleri.....	87
Tablo S.1: EMG sınıflandırması için diskriminant analizinin tipleri ve sonuçları..	110
Tablo S.2: EMG sınıflandırması için en yakın komşu sınıflandırıcısının tipleri ve sonuçları	110
Tablo S.3: EMG sınıflandırması için Naive Bayes sınıflandırıcısının tipleri ve sonuçları	111
Tablo S.4: EMG sınıflandırması için destek vektör makinesi sınıflandırıcısının tipleri ve sonuçları.....	111
Tablo S.5: EMG sınıflandırması için yapay sinir ağı sınıflandırıcısının sonuçları..	112
Tablo S.6: EEG sınıflandırması için diskriminant analizinin tipleri ve sonuçları...	116
Tablo S.7: EEG sınıflandırması için k - en yakın komşu sınıflandırıcısının tipleri ve sonuçları.....	116
Tablo S.8: EEG sınıflandırması için Naive Bayes sınıflandırıcısının tipleri ve sonuçları	117
Tablo S.9: EEG sınıflandırması için destek vektör makinesi sınıflandırıcısının tipleri ve sonuçları.....	117
Tablo S.10: EEG sınıflandırması için yapay sinir ağı sınıflandırıcısının Sonuçları.....	117
Tablo S.11: Gerçek kumanda ile birinci rota planlamasının takip performansları....	121
Tablo S.12: EEG ve EMG sinyalleri ile birinci rota planlamasının takip performansları.....	122

Tablo S.13: EEG ve EMG sinyalleri ile takibin kumanda ile takibe benzerlik oranı.....	123
Tablo S.14: Gerçek kumanda ile ikinci rota planlamasının takip performansları..	124
Tablo S.15: EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları	125
Tablo S.16: EEG ve EMG sinyalleri ile takibin kumanda takibine benzerlik oranları	126
Tablo S.17: Kumanda ile birinci rota planlamasının takip performansları	129
Tablo S.18: EEG ve EMG sinyalleri ile birinci rota planlamasının takip performansları	130
Tablo S.19: Kumanda ile EEG ve EMG sinyalleri ile yapılan rota takibinin benzerlik oranları	131
Tablo S.20: Kumanda ile ikinci rota planlamasının takip performansları	132
Tablo S.21: EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları..	133
Tablo S.22: EEG ve EMG sinyalleri ile ikinci rota planlaması takibinin kumanda ile takibe benzerlik oranları.....	134
Tablo S.23: Uygulama ortamlarında elde edilen sonuçlar.	135

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.1: Kaslardaki iyon değişimleri.....	8
Şekil 1.2: Kaslardaki iyon değişimlerinin ardından EMG'nin oluşumu.	9
Şekil 1.3: EMG sinyalinin elektrot devre modeli.	10
Şekil 1.4: Yüzey ve iğne elektrotları	11
Şekil 1.5: a)Extensor Pollicis Longus b)Extensor Pollicis Brevis c)Abductor Pollicis Longus Kasları	14
Şekil 1.6: EEG sinyalinin oluşumu.....	16
Şekil 1.7: Farklı elektrot materyallerinin kare dalgaya verdikleri tepkiler.....	18
Şekil 1.8: Beyin lobları ve isimleri	19
Şekil 1.9: 10/20 sistemi ve beyin görev haritası.	20
Şekil 1.10: 10/10 Sistemi.....	21
Şekil 1.11: 10/5 Sistemi.....	21
Şekil 2.1: a) Ham EEG sinyali, b) DC sapma gerilimi yok edilmiş EEG sinyali.....	23
Şekil 2.2: Ham EEG sinyalinin fourier dönüşümü, a) DC sapma yok edilmeden, ...	23
Şekil 2.3: EEG sinyalinin fourier dönüşümü a) DC sapma yok edildikten sonra,	24
Şekil 2.4: 4 saniyelik ham EEG ve filtrelenmiş EEG.....	25
Şekil 2.5: EMG sinyalini kirlüten 50 Hz şebeke gürültüsü	26
Şekil 3.1: Özbağlanım katsayılarını belirlemek için çizdirilen Akaike kriteri	30
Şekil 3.2: a) Analog sinyal b) Örnekleme c) Ayrık zamanlı sinyal.....	34
Şekil 3.3: Kısa süreli fourier dönüşümünün gerçekleşmesi	37
Şekil 3.4: Pencereleme fonksiyonları	39
Şekil 3.5: Spektral sızıntı oluşumu	40
Şekil 3.6: 50 % çakışan Hanning pencereleri	42
Şekil 3.7: Hızlı fourier dönüşümü ile elde edilmiş GSY	44
Şekil 3.8: Periodogram yöntemi ile elde edilmiş GSY	45
Şekil 3.9: Welch yöntemi ile elde edilmiş GSY	46
Şekil 3.10: Pencere genişliği azaltılarak Welch yöntemi ile elde edilmiş GSY	47
Şekil 3.11: Özbağlanım model seviyesini belirlemek için çizdirilmiş Akaike bilgi kriteri	48

Şekil 3.12: Özbağlanım parametreleri ile elde edilmiş GSY.....	49
Şekil 3.13: Bütün GSY yöntemleri ile elde edilen sonuçların üst üste çizimi.....	50
Şekil 3.14: KOF uygulanmış HFD ile elde edilmiş GSY ve Welch yöntemi ile elde edilmiş GSY	51
Şekil 3.15: Ana dalgacık sinyalleri.....	54
Şekil 3.16: Sinüzoidal sinyalde oluşmuş küçük süreksizlik	55
Şekil 3.17: Süreksizlik içeren sinüs sinyalinin a) fourier b) dalgacık dönüşümü.....	56
Şekil 3.18: Ölçekleme ve öteleme işlemleri	56
Şekil 3.19: Dalgacık dönüşümünde detay ve yaklaşım sinyallerinin oluşumu	58
Şekil 3.20: 3/1 oranında aşağı örnekleme-seyreltme	59
Şekil 3.21: Orijinal EEG ve alt bantları.....	60
Şekil 3.22: Tablo 3.4.'teki korelasyon matrisinin çizimi.....	64
Şekil 3.23: Yamaç-birikinti çizimi	65
Şekil 4.1: K-en yakın komşu mesafeleri.....	66
Şekil 4.2: K parametresinin seçimi.....	68
Şekil 4.3: KDA ve LDA karar sınırları.....	73
Şekil 4.4: Yapay sinir ağlarının blok diyagramı	73
Şekil 4.5: YSA transfer fonksiyonları	74
Şekil 4.6: Farklı ayırıcı düzlemler	77
Şekil 4.7: Destek vektörleri	78
Şekil 5.1: İHA'nın dönme açıları yuvarlanma, yunuslama ve yönelme.....	81
Şekil 5.2: Kullanılan oyuncak İHA	84
Şekil 5.3: EMG hareketleri ve elektrot yerleşimleri a) sağ b) sol c) ileri d) geri	85
Şekil 5.4: a)Kullanılan EMG cihazı b) Tahribatsız elektrotlar.....	86
Şekil 5.5: a) Kullanılan elektrotlar b) EEG cihazı (Emotiv EPOC+).....	86
Şekil 5.6: Oyunun ana menüsü	87
Şekil 5.7: Oyunun birinci bölümü	88
Şekil 5.8: Oyunun ikinci bölümü.....	88
Şekil 5.9: Oyunun üçüncü bölümü	89
Şekil 5.10: Oyunun dördüncü bölümü.....	89
Şekil 5.11: Bilgisayar ortamındaki akış şeması.....	90
Şekil 5.12: Grafik arayüzünün ilk açıldığındaki görüntüsü.....	91

Şekil 5.13: Veri alınması ve etiketlenmesi	92
Şekil 5.14: Filtreleme adımı ve parametreleri	92
Şekil 5.15: Dalgacık dönüşümü adımı ve parametreleri.....	92
Şekil 5.16: Özellik seçme adımı ve parametreleri	93
Şekil 5.17: Sınıflandırıcı seçme adımı.....	93
Şekil 5.18: Tasarlanan gerçek oyun kumandası	94
Şekil 5.19: DAC elektronik devresi.....	96
Şekil 5.20: DAC tasarımı.....	96
Şekil 5.21: Audacity programında oluşturulmuş 50 Hz PWM ses dalgası.....	97
Şekil 5.22: Tasarlanan İHA kumandası	98
Şekil 5.23: Baştan sona uygulama	99
Şekil 5.24: Sinyal alma aşaması	100
Şekil 5.25: Sinyal işleme aşaması (sinyal filtreleme).....	101
Şekil 5.26: Sinyal işleme aşaması (özellik çıkarma)	102
Şekil 5.27: Sinyal işleme aşaması (sınıflandırma).....	103
Şekil 5.28: Oyun için komut çıkarımı	104
Şekil 5.29: İHA için komut çıkarımı	105
Şekil 5.30: Kumanda joysticklerinin konumlarına göre ürettiği gerilimler	106
Şekil 5.31: Bilgisayardan İHA'ya komut gönderimi	107
Şekil S.1: Aynı kişilerle EMG sınıflandırma algoritmalarının kıyaslanması	113
Şekil S.2: Farklı kişilerle EMG sınıflandırma algoritmalarının kıyaslanması	114
Şekil S.3: EEG sınıflandırma algoritmalarının kıyaslanması	118
Şekil S.4: a) Oyun ortamındaki birinci yol b) MATLAB'a aktarılmış çizimi.....	119
Şekil S.5: a) Oyun ortamındaki ikinci yol b)MATLAB'a aktarılmış çizimi.....	120
Şekil S.6: Gerçek kumanda ile birinci rota planlamasının takibi	121
Şekil S.7: EEG ve EMG sinyalleri ile birinci rota planlamasının takibi	122
Şekil S.8: EEG ve EMG sinyalleri ile takibin ortalaması ile kumanda ile takibin ortalaması	123
Şekil S.9: Gerçek kumanda ile ikinci rota planlamasının takibi.....	124
Şekil S.10: EEG ve EMG sinyalleri ile ikinci rota planlamasının takibi.....	125
Şekil S.11: İkinci rota planlamasında EEG ve EMG sinyalleri ile takibin ortalaması ile kumanda ile takibin ortalaması	126

Şekil S.12: Gerçek İHA’da deneyler için oluşturulan platform	127
Şekil S.13: İHA’nın uçuşu sırasında lazer işaretleyici (yuvarlak içine alınmış)	128
Şekil S.14: İki farklı oturumda gerçek kumanda ile elde edilen birinci rota planlamasının takibi	129
Şekil S.15: İki farklı oturumda EEG ve EMG sinyalleri ile birinci rota planlamasının takibi.....	130
Şekil S.16: Kumanda ile EEG ve EMG sinyalleri ile yapılan rota takibinin benzerlikleri.....	131
Şekil S.17: İki farklı oturumda gerçek kumanda ile elde edilen ikinci rota planlamasının takibi	132
Şekil S.18: İki farklı oturumda EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları	133
Şekil S.19: EEG ve EMG sinyalleri ile ikinci rota planlaması takibinin kumanda ile takibe benzerliği	134

KISALTMALAR LİSTESİ

EMG	: Elektromyogram
EEG	: Elektroensefalogram
ECG	: Elektrokardiyogram
EOG	: Elektrookülogram
Ag	: Gümüş
Ag/Cl	: Gümüş Klorid
DC	: Doğru Akım
AC	: Alternatif Akım
AGF	: Alçak Geçiren Filtre
YGF	: Yüksek Geçiren Filtre
AIC	: Akaike Bilgi Kriteri
AR	: Özbağlanım
ADC	: Analog Dijital Çevirici
DAC	: Dijital Analog Çevirici
AFD	: Ayrık Fourier Dönüşümü
HFD	: Hızlı Fourier Dönüşümü
FFT	: Fast Fourier Transform
KZFD	: Kısa Zamanlı Fourier Dönüşümü
GSY	: Güç Spektral Yoğunluğu
KOF	: Kayan Ortalama Filtre
AO	: Asimetri Oranı
DD	: Dalgacık Dönüşümü
SDD	: Sürekli Dalgacık Dönüşümü
ADD	: Ayrık Dalgacık Dönüşümü
TBA	: Temel Bileşenler Analizi
PCA	: Principal Component Analysis
KNN	: K Nearest Neighbor (K-en yakın komşu)
LDA	: Lineer Diskriminant Analizi
KDA	: Kuadratik Diskriminant Analizi
YSA	: Yapay Sinir Ağları

DVM	:	Destek Vektör Makineleri
KKT	:	Karush Kuhn Tucker
İHA	:	İnsansız Hava Aracı
3D	:	3 Boyutlu
PWM	:	Darbe Genişlik Modülasyonu
RF	:	Radyo Frekansı
CPU	:	Merkezi İşlem Birimi
GPU	:	Grafik İşlemci Ünitesi



GİRİŞ

Günümüzde, dört rotorlu insansız hava araçları birçok alanda kullanılmaktadır. Bu alanlar eğlence, askeri, enerji, meteoroloji, inşaat, tarım, teslimat, trafik ve güvenlik alanlarıdır. Ayrıca uçağa veya helikoptere göre dört rotorlu İHA'nın üstün manevra kabiliyeti vardır. İHA'lar 2 joystickli uzaktan kumandalarla kontrol edilirler. Uzaktan kumandalar ile İHA'yı yönetmek için iki elde meşgul olur. Bir İHA'nın geleneksel bir uzaktan kumanda tarafından kontrol edilmesi için, tutma ve kontrol için hem sol hem de sağ el kullanılmalıdır. Böylesine yararlı ve uygulama alanı geniş bir aletin kumandası ise bu aletin yeri geldiğinde kullanımını zorlaştırmaktadır. Bir yük olan uzaktan kumandayla İHA kontrolü sorunu, eller serbest uzaktan kumanda tasarlanmasına öncülük etmiştir. Önerilen sistem hem İHA kullanımını kolaylaştıracak hem de kısmi felçli ya da özürlü bireylerin yaşam kalitesini arttırmaya yardımcı olacaktır. Böyle sistemleri gerçekleştirmek için insan makine etkileşimi sistemleri kullanılmaktadır.

İnsan makine etkileşimi yapıları özellikle son 10 yıldır gelişmekte olup engelli veya sağlıklı insanların yaşam kalitesinin iyileştirilmesine öncülük etmektedir. İnsan makine etkileşimi yapılarında insan vücudundan alınan biyolojik sinyaller sıklıkla kullanılır. İnsan vücudu mekanik bir yapı tarafından desteklenen elektriksel ve kimyasal sistemlerin birleşimidir [1]. Biyoelektrik hayati fonksiyonların elektriksel olgusudur. Biyolojik sinyallerin varlığı 1789 yılında İtalyan fizikçi Luigi Galvani tarafından bulunmuştur [2]. Biyolojik sinyallerin insan vücudundan alınıp değerlendirilip yorumlanması başta tıp bilimi olmak üzere disiplinler arası birçok alanda önemlidir. Başlıca biyolojik sinyaller beyin tarafından üretilen elektroensefalogram (EEG) kalp tarafından üretilen elektrokardiyogram (ECG), kaslar tarafından üretilen elektromiyogram (EMG) ve göz kasları tarafından oluşturulan elektrookülogram (EOG) dır. Bu biyolojik sinyallerin elde edilip bilgisayarda işlenmesi ile insan makine etkileşimi diye adlandırılan yapılar oluşturulmaktadır. İnsan makine etkileşimi ile genellikle felçli veya engellilerin yaşam kalitesinin artırılması amaçlanır. Bunun yanında tedavi amaçlı olanlar da mevcuttur. Günümüzde eğlence ve oyun amaçlı insan-bilgisayar ara yüzleri de gelişmektedir.

İnsanoğlu sahip olduđu bütün organlarını eş zamanlı veya ayrı ayrı kullanarak günlük hayattaki zorlukların üstesinden gelmektedir. Karşı karşıya kaldığı durumun zorluğu ile bu durumun üstesinden gelmek için kullandığı organların çokluğu orantılıdır. Çok fonksiyonlu bir işlem için sahip olunan organlar yetersiz kalabilir ya da bir takım uzuvlar kaybedilmiş olunabilir. Böyle durumlarda vücudumuzda oluşan biyolojik sinyaller bir takım ekipmanlar ile birleştirilmek suretiyle tıpkı organlar gibi kullanılabilir.

İnsan makine etkileşimi yapıları genellikle insan hareketini biyolojik sinyallerin algılanıp değerlendirilmesiyle veya vücuda yerleştirilen birtakım sensörler vasıtasıyla hareketlerin algılanması üzerinedir. Bu anlamda atılmış olan ilk adım ise farklı teknolojiler kullanılarak el ve parmak hareketlerini tanıyan giyilebilir elektronik eldivenlerdir. Son yıllarda bu tarz eldivenler sanal gerçeklik oyunlarında da kullanılır hale gelmiştir [3].

Eldiven tabanlı el hareketi tanıma sistemlerinden ilki Massachusetts Institute of Technology (MIT) üniversitesinde 1977 yılında Thomas de Fanti ve Daniel Sandin tarafından yapılmıştır (Sayre Glove) [4]. Işık tabanlı sensörlerin kullanıldığı bu eldiven, parmak hareketlerini fotoseller üzerine düşen ışık miktarına göre hesaplamaktadır. 1980 yılına gelindiğinde MIT medya laboratuvarında MIT-LED eldiveni geliştirilerek, kamera tabanlı LED sistemi ile gerçek zamanlı bilgisayar animasyonu için vücut ve uzuv izlemesi yapılmıştır (MIT LED Glove) [5]. 1983 yılında Gary Grimes tarafından Dijital Giriş Veri Eldiveni icat edilmiş ve patenti alınmıştır (Digital Entry Data Glove) [6]. Bu eldivenle el hareketlerinden alfa numerik karakterlerin üretimi amaçlanmıştır ve çok karmaşık bir devre yapısına sahip olup mesafe, titreşim, atalet sensörleri gibi çeşitli sensörlerden oluşan karmaşık yapıya sahiptir. 1987 yılında Görsel Programlama Dili Araştırma Kuruluşu (Visual Programming Language Research Inc.) tarafından yeni bir veri eldiveni geliştirilmiştir. Bu eldiven 5 ile 15 arasında sensör barındırmaktaydı ve bu sensörlerin çoğu esnemeyi ölçen sensörler olup fazladan parmak açısını ölçen sensörleri de bulunmaktadır [7]. 1989 yılında bu veri eldiveninin düşük fiyatlı versiyonu Mattel Intellivision şirketi tarafından ticarileştirilmiş olup Nintendo video oyun konsollarında kontrol cihazı olarak kullanılmıştır ve eldivenin adı Güç Eldiveni (Power Glove) olarak

adlandırılmıştır [8]. Her parmağın hareketini ölçmek için esnek plastik üzerine sürülmüş mürekkep direnç teknolojisi kullanılmıştır. 1995 yılına gelindiğinde Nissho Electronics şirketi tarafından Süper Eldiven (Super Glove) adında 10 ile 16 sensör içeren ve yine mürekkep direnç teknolojisi kullanan eldiven üretilmiştir [9]. Güç eldiveninin daha gelişmiş olarak P5 Eldiveni (P5 Glove) Essential Reality LLC. tarafından 2002 yılında ticarileştirilmiştir. Parmağa takılan çubukların kızılötesi bir alıcı önünden geçirilmesiyle parmak konumu hesaplanmaktadır [10]. Mascaro ve ekibi MIT Üniversitesi'nde Tırnak Eldiveni'ni geliştirmişlerdir. Bu eldivenin teknolojisinde tırnak renginin dokunma, bükme, eğme gibi durumlarda değişiminin tırnaklara yerleştirilen foto diyotlar vasıtasıyla algılanarak parmak durumları hesaplanmıştır [11]. 2002 yılında George Washington Üniversitesi'nde Hernandez ve ekibi tarafından 5 adet ivmeölçer deri eldiven üzerine monte edilerek parmak hareketleri algılanmaya çalışılmıştır ve tasarımlarını "AcceleGlove" olarak isimlendirmişlerdir [12]. Howard tarafından "Lightglove" adını verdiği eldiven sistemi geliştirilmiştir. Bu eldiven ile bilek altına monte edilmiş saat büyüklüğünde LED alıcı verici kablosuz cihaz ile parmak hareketleri ışığın bozulumundan yararlanılarak çıkarılmıştır [13]. Humanware Srl (Pisa, İtalya) şirketi tarafından "Humanglove" adında yeni bir eldiven piyasaya sürülmüş, bu eldivende ise Hall etkisi sensörleri ile parmakların konumu bilinmiştir [14]. 5D Technologies şirketi tarafından piyasaya sürülmüş bir başka eldiven (5DT Data Glove) parmak hareketlerini algılamak için esnek fiber optik kanallar kullanılmıştır [15]. Böylelikle ışığın yansıma yoğunluğuna göre parmağın hareketi tahmin edilmiştir.

Bu veri eldivenleri ile insan makine etkileşimi yapıları geliştirilmiş ve özellikle multimedya uygulamalarında bu eldivenler kullanılmıştır. 2013 yılına gelindiğinde ise Virginia Polytechnic Institute and State University'de Deba Pratim Saha, eldiven sistemlerinden farklı olarak MMG (Mechanomyogram) sinyalleri kullanarak 2 boyutlu giyilebilir bir joystick tasarımı yapmıştır [16]. MMG, kasların ürettiği düşük frekanslı mekaniksel sinyallerdir. Yapılan çalışmalar değerlendirildiğinde, eldiven sistemlerinin hareketleri algılamak için elektro-optik, Hall etkisi, basınç, ivmeölçer vb. karmaşık sensör teknolojileri içerdikleri için kırılğan, karmaşık ve pahalı olma gibi dezavantajlarının olduğu gözlemlenmiştir.

İnsan makine etkileşimi son yıllarda oldukça rağbet görmüş olup özellikle tanı, tedavi ve engellilerin yaşam kalitesini artırmak adına oldukça yararlı olmuştur. En sık görülen uygulamalar ise takma bir uzvun EMG sinyalleri ile kontrolü veya EEG sinyalleri ile beyin-bilgisayar ara yüzü (BBA) oluşturup bilgisayar kullanımını sağlamaktır. Dahası beyin-bilgisayar ara yüzü vasıtasıyla elektrikli sandalye gibi birtakım araçları kontrol etmek sayılabilir. Daha yeni uygulamalarda ise biyolojik sinyallerle oynanan oyunların piyasaya çıktığı görülmektedir. Çoğunlukla bu uygulamaların invazif olmayan uygulamalar olması nedeniyle kullanışlılığı ve geliştirilebilirliği artmaktadır.

EEG tabanlı BBA sistemlerinde kullanıcı bilişsel ya da zihinsel durumunu değiştirerek kontrol sinyali üretir [17]. Bu bilişsel ya da zihinsel durumlar, odaklanma, hayal etme, düşünme gibi farklı beyin görevleri ile EEG aktivitesindeki değişikliklerdir. BBA birçok cihazı kontrol etmek için kullanılır [18]. Örneğin, heceleyici uygulamaları için [19], [20], [21], tekerlekli sandalye kontrolü için [22], protez uzuv kontrolü için [23], fare imlecini kontrol etmek için [24], multimedya uygulamaları için [25] ve sanal gerçeklik oyunları için [26]. Ancak, düşük güvenilirlik, düşük doğruluk, düşük kullanıcı adaptasyonu ve düşük veri aktarım hızı gibi zorluklardan dolayı, EEG tabanlı BBA sistemleri bu uygulama alanlarında hala kabul edilebilir başarı seviyelerinde değildir [27], [28], [29], [30].

EEG tabanlı BBA sistemlerinin eksikliklerini telafi etmek ve performansı yükseltmek için EMG gibi bir başka biyolojik sinyal kullanılabilir. Çoklu biyolojik sinyal kullanımı güvenilirliği artırabilir. En az iki farklı biyolojik sinyal kullanan BBA, hibrit BBA sistemi olarak bilinir. Hibrit BBA sistemleri iki tip uygulama stiline sahiptir, birinci tipte biyolojik sinyaller seri veya ardışık kullanılırken ikinci tipte ise iki sinyal eş zamanlı veya paralel kullanılır.

Biyolojik işaretlerin eş zamanlı olarak kullanıldığı çalışmalar hakkında literatür taraması yapıldığında: 2010 yılında Punsawad ve ekibi EEG ve EOG sinyallerini kullanarak daha pratik bir insan makine etkileşiminin yapılabileceğini ileri sürmüşlerdir [31]. 2011 yılında Leeb ve ekibi el kontrolü görevleri için beyin ve kas sinyallerini birleştirmişlerdir [32], [33]. Yine 2011 yılında Roy ve ekibi, sinyalleri ayrı ayrı kullanmak yerine kombine EEG ve EMG sinyallerini kullanarak takma uzuvları kontrol etmişlerdir [34]. 2013 yılında Dulantha ve ekibi tarafından EEG ve EMG

sinyalleri kullanılarak hibrit bir çalışma yapılmış, EEG ve EMG'nin ayrı ayrı dezavantajlarının yok edilmesi amaçlanmıştır [27]. 2014 yılında Wang ve arkadaşları da hibrit bir EEG ve EOG ile tekerlekli sandalye kullanımı üzerinde çalışma yapmışlardır [35]. 2016 yılında Barachant ve ekibi birleştirilmiş (EEG&EMG) sinyallerinden motor modelleri çıkarmışlardır [36]. 2017 yılında Byeognam ve ekibi engelli bir insanın hareket niyetini bulmak için EEG ve EMG sinyallerini birleştirmişlerdir [37]. Yine 2017 yılında Rakesh ve arkadaşları bir tekerlekli sandalyeyi kontrol etmek için hibrit BBA (EEG & EMG) tasarlamışlardır [38].

Biyolojik işaretlerin ardışık olarak kullanıldığı çalışmalar hakkında literatür araştırması yapıldığında Wagner ve arkadaşları, 2014 yılında San Diego Eyalet Üniversitesi'nde EEG ve EMG kontrollü RC otomobil tasarladılar [39]. Otomobil sağa ve sola doğru zihinsel düşünce ile yönlendirilirken pazı kasının kasılıp gevşetilmesi ile de öne ve arkaya hareket ettirilmektedir. Powell ve ekibi de 2016 yılında EEG ve EMG kontrollü RC otomobil tasarlamışlardır [40]. Aracın yönünü değiştirmek için her iki koldan da EMG sinyalleri alınmaktadır, EEG sinyalleri aracı çalıştırmak yani hareket ettirmek ve durdurmak için kullanılmaktadır.

Literatürde hem hibrit olma hem de bir insansız hava aracını yönetmeye yönelik olan çalışma olması bakımından bu tez çalışmasına benzer bir çalışma Byung Hyung Kim ve ekibi tarafından 2014 yılında KAIST yani Kore Yüksek Bilim ve Teknoloji Enstitüsü'nde yapılmıştır [41]. Bu çalışmada İHA kontrolü hibrit EEG ve gözden 8 cm uzağa konumlandırılan göz hareketi izleme cihazı ile yapılmıştır. Bu çalışmada İHA'ya zihinsel olarak yoğunlaşarak İHA'nın havalanması sağlanmaktadır. İHA havalandıktan sonra kullanıcı gözünü sağ, sol, yukarı, aşağı hareket ettirerek yönlendirme yapmaktadır. Ancak göz hareketini algılayan kamera tabanlı cihazın kullanışsız, pahalı ve rahatsızlık verici olması uygulanabilirliğini azaltmaktadır.

Literatürdeki bu çalışmalardan farklı olarak bu tez çalışmasının önemi; daha önce de açıklandığı gibi eldiven ve MMG sistemlerine göre avantajı olan EMG sinyali kullanılarak giyilebilir joystick tasarımının yapılması, literatürde olmayan hibrit EEG ve EMG sinyalleri ile bir İHA'nın kontrolünün gerçekleştirilmesi ve bu anlamda da dört rotorlu insansız hava aracı kontrolüne yenilik getirilmesidir. Hibrit biyolojik sinyallerin kullanılmasında amaç iki biyolojik sinyalin de dezavantajlarının yok

edilmesini saęlamaktır. Yani olduka kararsız bir EEG sinyali ile kısmi başarılı İHA kontrolü yerine daha kararlı EMG sinyali ile birlikte kullanılarak daha etkili sonuçlar elde edilmiştir.



1. İNSAN MAKİNE ETKİLEŞİMİ

Biyolojik sinyaller zamanla değişen fiziksel büyüklükler olup makineleri veya sistemleri yönetmede kullanılabilirler. Söz konusu değişimler organların çalışma farklılıklarına göre olur. Örneğin bilek büküldüğünde veya el sıkıldığında koldaki kaslar iki durum için ayrı sinyaller üretir. Bu sinyallerin kontrol amaçlı kullanılması insan makine etkileşimini doğurmuştur. İnsan makine etkileşimi, insanın bilgisayarla ve dolayısıyla bilgisayara bağlı sistemlerle veya makinelerle etkileşimini ve iletişimini sağlayan yapılardır. Genellikle insan makine etkileşimi yapıları vücudumuzda var olan biyolojik sinyalleri kullanarak anlamlı komutların çıkarılmasını sağlarlar. Sinyalin vücuttan elektrotlarla alınıp, işlenip, komutların çıkarılmasını kapsar. Bu sebepten ötürü de genellikle engelliler veya yaşlılar için tasarlanırlar. Yapılan iş ise çoğunlukla protez bir uzvun kontrolü veya bir elektrikli sandalyenin kontrolü şeklindedir. İnsan makine etkileşiminde genellikle EMG, EEG ve EOG sinyalleri kullanılır. EEG sinyalleri kullanılan insan makine etkileşimi yapısına beyin-bilgisayar arayüzü de denir.

1.1. EMG Tabanlı İnsan Makine Etkileşimi


1.1.1. EMG Sinyalinin Tarihçesi

EMG'nin bulunuşu 17. yüzyılda Francesco Redi ile olmuştur. Redi, 1666 yılında vatoz balığı kaslarının elektrik ürettiğini öne sürmüştür. 1773 yılına gelindiğinde ise Walsh yılan balığında aynı hipotezi doğrulamıştır. 1792 yılında Galvani tarafından yapılan bir çalışma elektriğin kasların kasılmasını sağladığını göstermiştir. 1849 yılında Raymond kasın kasıldığı anda elektriksel aktivitesini kaydetmenin mümkün olduğunu keşfetmiştir. Bu elektriksel aktivitenin ilk olarak kaydı 1890 yılında Mayer tarafından yapılmış ve aynı zamanda da elektromiyogram terimi de Mayer tarafından adlandırılmıştır. 1922 yılında Gasser ve Erlander kaslarda üretilen elektriği göstermek için osiloskop kullanmışlardır [42]. Miyoelektrik sinyallerin değişken olmaları nedeniyle, bu sinyaller algılandıktan sonra kabaca bir bilgi elde edilir. EMG sinyalinin algılanma işlemi 1930'lardan 1950'lere kadar sürekli gelişmiş ve artık araştırmacılar gelişmiş elektrotlarla bu sinyalleri algılamaya başlamışlardır. Bugünkü anlamda vücuda iğne şeklinde elektrotlar yerleştirmeden deri yüzeyinden alınan yüzey EMG sinyallerinin kullanımı ise 1960'larda başlamıştır. Hardyck ve arkadaşları yüzey

EMG'sini 1966 yılında ilk kullananlar olmuşlardır. 1980'lerin ortalarına kadar elektrot teknolojisi gelişerek küçük, taşınabilir yükselticilerin gerekliliğini sağlamıştır. Son yıllarda ise gelişmiş elektrotlar sayesinde yüzey EMG'si kullanılmakta olup derindeki kaslar haricinde kas içi veya invazif elektrotlar kullanılmamaktadır.

1.1.2. EMG Sinyalinin Oluşumu

Vücuttaki elektriksel aktivite iyon (Na , Cl , K) konsantrasyonları farkı ile açıklanır. İki nokta arasındaki voltaj farkı farklı iyonik konsantrasyonlar ile meydana gelir. Şekil 1.1'de kasın kasılması ve dinlenme durumunda gerçekleşen iyon değişimleri gösterilmiştir [43][44].




Şekil 1.1. Kaslardaki iyon değişimleri

Şekil 1.1'de görüldüğü üzere dinlenme durumundaki iyonik dengede -70 -80 mV civarında bir gerilim (dinlenme potansiyeli) mevcuttur. Bunun sebebi iyon pompasının hücre içine devamlı olarak eksi yüklü iyonları pompalamasıdır. Dinlenme durumunda bir kasın uyarılıp iyon değişimi ile birlikte gerilimin meydana gelmesi sıralanırsa:

- Kasa sinir hücresinden uyarı veya dürtü gelir. Bu uyarı Na^+ yani sodyum kanallarının açılmasına neden olur. Eğer açılma dinlenme potansiyelini -70 mV'tan -55mV'a kadar yükseltecek açıklıktaysa süreç devam eder.
- -55mV'a ulaşıldığında yani eşik değerine ulaşıldığında daha fazla Na^+ kanalı açılır. Hücreye Na^+ girişi hücre membranını +30 mV'a kadar yükler. Bu noktadaki işleme depolarizasyon denir.
- Daha sonra Na^+ kanalları kapanır ve K^+ kanalları açılır. K^+ kanallarının açılması çok yavaş olduğundan depolarizasyon işlemi biraz zaman alır. Na^+ ve K^+ kanallarının aynı anda açık olması sistemi nötrleşmeye doğru götürür.

- K^+ kanallarının açık olması ile hücre membranı dinlenme potansiyeline doğru repolarize olur.
- Repolarizasyon işlemi dinlenme potansiyelini aşar (-90 mV civarına gelir). Bu işleme hiperpolarizasyon denir. Hiperpolarizasyon nörondan başka bir uyarı alınmasını engeller veya eşik değerini herhangi bir uyarı için daha da yükseltir. Hiperpolarizasyonun önemi ters yönlü başka bir uyarı gelmesini engeller. Başka bir anlatımla hiperpolarizasyon sinyalin tek yönlü iletimini sağlar.
- Hiperpolarizasyon işleminden sonra ise iyon pompası nihayet hücre membranını dinlenme durumuna yani -70 mV'a getirir.




Şekil 1.2. Kaslardaki iyon değişimlerinin ardından EMG'nin oluşumu.

Şekil 1.2'de görüldüğü üzere, EMG sinyalleri çoklu motor birim potansiyellerinin toplamıdır [45]. Çoklu motor birim potansiyellerinden oluştuğu için EMG sinyali rasgele sinyaldir.

1.1.3. EMG Sinyalinin Algılanması

EMG sinyalinin oluşumundan bahsedildikten sonra oluşan EMG sinyalinin algılanması işleminden bahsedilmelidir. Bir eşdeğer devre modeli elektrot yüzeyi ve deri arasındaki etkileşimin nasıl olduğunu anlamak için kullanılabilir.



Şekil 1.3. EMG sinyalinin elektrot devre modeli.

EMG sinyalinin oluşumundan sonra algılanması için elektrotlar ve kuvvetlendiriciler gereklidir. Şekil 1.3'te EMG sinyali ve bu sinyalin elektrotlarla nasıl alındığını gösteren devre modeli mevcuttur [46].

EMG sinyali vücutta oluşan iyonik akımların oluşturduğu elektriksel aktivitedir. İyonik aktivite olan EMG sinyalini ölçülebilen ve kaydedilebilen elektriksel aktiviteye dönüştüren yapılar elektrotlardır [47]. EMG sinyalleri iki tip elektrotla ölçülebilir. Bunlar;

1. İnvazif elektrotlar
2. İnvazif olmayan elektrotlardır.

İnvazif elektrotlar ilgili kasa daha yakın olmak için deriyi delerek içeri girecek şekilde tasarlanırlar ve genellikle iğne şeklindedirler. İnvazif olmayan elektrotlar ise yüzey elektrotları olarak da bilinirler ve deri yüzeyine yapıştırılacak şekilde tasarlanırlar. İnvazif elektrotlarla invazif olmayan elektrotlara göre daha iyi ölçüm yapılır; çünkü invazif elektrotlar derinin de altına inerek kasa en yakın noktadan ölçümleri alırlar. Böylece istenmeyen biyoelektrik sinyaller alınmamış olur ve biyoelektrik kaynak ile elektrot arasına fazla doku katmanı girmemiş olur. Fakat invazif olmayan elektrotlar klinik biyolojik sinyal ölçümlerinde invazif elektrotlara göre daha çok tercih edilirler.

Bunun sebebi ise invazif olmayan elektrotların kullanım olarak daha güvenli olmalarıdır yani daha az iltihap riski taşımalarının yanında daha kolay kullanıma sahiptirler ve hastalar için daha konforludurlar. Bu tezde kullanılan elektrotlar Şekil 1.4’te görüldüğü üzere, önceden jelli invazif olmayan türde elektrotlardır.



Şekil 1.4. Yüzey ve iğne elektrotları

İnvazif olmayan elektrotların biyolojik sinyalleri algılama performansı elektrot-deri empedansına bağlıdır. Yüksek elektrot-deri empedansı zayıf sinyal kalitesi, düşük sinyal genliği ve düşük sinyal-gürültü oranına neden olur. Elektrot-deri empedansını düşürmek için deri ile elektrot arasına iletken jel sürülür. Bu jel iyonik yüklerin elektrot yüzeyine transferi için iletken bir alan inşa eder. Ayrıca jel deri içerisine de nüfus ettiği için daha iletken bir alan meydana getirir. Nem, ter, deri tipi, elektrot boyutu, elektrot şekli, elektrotun yapım malzemesi, elektrolit jeli gibi etkenler elektrot-deri empedansını etkileyen etkenlerdir. Ayrıca elektrot-deri empedansı kişiden kişiye ve vücudun bir bölgesinden diğer bölgesine değişkenlik gösterir.

Elektrotların iyonik iletimi elektronik iletme çevirdiklerinden bahsedilmiştir, bu işlemin nasıl gerçekleştiğine göz atılmalıdır. Elektrot deri etkileşiminde elektrot ile jel arasında yük transferi için redoks denklemleri (oksidasyon ve redüksiyon), oluşmak durumundadır [48]. Denklem 1.1’de elektron kaybı ya da elektrottan deriye akım akışı olarak bilinen ve anotta meydana gelen oksidasyon verilmiştir. Denklem 1.2’de ise katotta meydana gelen elektron kazancı ya da deriden elektroda akım akışı olarak bilinen redüksiyon verilmiştir.



$$A^{m-} \leftrightarrow A + me^{-} \quad (1.2)$$

1.1.4. EMG Sinyalinde Gürültüler

EMG sinyalinin genliği 0-10 mV arasındadır. EMG sinyali çeşitli dokulardan geçerken birçok gürültü tarafından kirlenir. Bu istenmeyen elektrik sinyallerinin özelliklerini anlamak çok önemlidir [49]. EMG sinyalini kirleten gürültüleri şu şekilde sıralayabiliriz.

1. Elektronik cihazlarda var olan doğal gürültüler: Bu tip gürültüler bütün elektronik cihazlarda vardır ve engellenememektedir. Bu gürültüler sadece yüksek kaliteli devre elemanları kullanılarak ve iyi devre tasarımı yapılarak önlenabilmektedir. Bu gürültüler 0 Hz ile birkaç bin Hz arasında frekanslara sahiptir.
2. Çevresel gürültüler: Bu gürültülerin ana kaynağı elektromanyetik radyasyondur. Bu gürültülerin genliği bazen EMG sinyalinin genliğinden 3 kat kadar büyük olabilmektedir. Bu gürültülere maruz kalmamak neredeyse imkânsızdır. Örneğin 50 Hz şebeke gürültüsü güç kaynaklarından gelen çevresel bir gürültüdür.
3. Hareket gürültüleri: Bu gürültülerin frekansı 1-10 Hz arasındadır. Genliği ise EMG sinyali ile aynı seviyelerdedir. Bu gürültülerin ana nedeni elektrot kablosudur.
4. EMG sinyalinin doğal gürültüsü: EMG sinyali rasgele bir sinyaldir. Motor birim potansiyellerinin sayısı sinyali etkiler ve kararsızlaştırır. EMG sinyalindeki bilgi aktif motor nöronları sayısı ve kas fiberlerinin mekanik etkileşimi ile değişir.
5. EKG gürültüleri: Şüphesiz EKG sinyali vücuttaki en kuvvetli biyolojik sinyallerden biridir. EKG ve EMG sinyallerinin frekans aralıkları ve karakteristikleri benzer olduğu için EKG gürültülerinin giderilmesi oldukça güçtür.
6. Elektrot teması gürültüsü: Elektrot - deri teması EMG sinyalinin sinyal-gürültü oranını etkilemektedir. Bu yüzden deri, EMG sinyali alınmadan önce hazır hale getirilmelidir.

7. Transdüser gürültüsü: Bu gürültü elektrot-deri birleşiminde oluşur. Elektrotlar elektrot-deri dönüşümündeki iyonik akımları elektronik akımlara çevirirler. Bu nedenle bir transdüser görevi görürler. Empedans etkisi bu gürültülerin ana nedenidir ve Ag-AgCl elektrotlar kullanılarak bu gürültüler azaltılabilir.


EMG sinyali görüldüğü üzere birçok etken tarafından kirletilmektedir. EMG sinyali alındıktan ve kaydedildikten sonra bu gürültülerden arındırılmalıdır. Bu gürültülerden arındırma işlemi ilerleyen bölümlerde sunulacaktır.

1.1.5. EMG Elektrot Yerleşimi

EMG sinyali ile kas aktivitesi gözlemlenirken elde edilen elektriksel bilgi, elektrotun kas üzerinde nereye yerleştirildiğine oldukça bağlıdır. Elektrot yerleşimi kasın elektriksel davranışını göstermesi nedeniyle EMG ölçümlerinde ilgili kaslar üzerine aynı kişi ile yapılan ölçümlerde bütün oturumlarda aynı kas üzerine, farklı kişilerle yapılan ölçümlerde de aynı noktaya tutarlı bir şekilde yapılmalıdır [50]. Eğer elektrot yerleşimi farklı oturumlarda birbirinden santimetre seviyelerinde bile farklı noktalara yapılırsa ölçümler tutarsız hale gelir. Bu tez çalışmasında joystick hareketlerinin EMG sinyalleri alınacağı için elektrot bağlantısı başparmağı hareket ettiren kasların üzerine gelecek şekilde yapılmıştır. Başparmağı hareket ettiren kaslar;

1. Abductor Pollicis Longus
2. Extensor Pollicis Longus
3. Extensor Pollicis Brevis

Kasların vücutta bulundukları noktalar Şekil 1.5'te gösterilmiştir [51].



Şekil 1.5. a)Extensor Pollicis Longus b)Extensor Pollicis Brevis c)Abductor Pollicis Longus Kasları

1.2. EEG Tabanlı İnsan Makine Etkileşimi

1.2.1. EEG Sinyalinin Tarihçesi


EEG sinyalinin bulunuşu ile ilgili ilk çalışma İngiliz bilim adamı Richard Caton tarafından (1842-1926) yapılmıştır. Bu çalışma tavşan ve maymunların beynindeki elektriksel aktiviteyi algılamak üzerinedir. Caton, yaptığı deneylerin ilk raporunu ise 1875 yılında yayınlamıştır. Bu çalışma EEG sinyalleri üzerine yapılmış ilk çalışma olarak bilinmektedir. 1888 yılında Polonyalı bilim adamı Adolf Beck (1863-1942) Krakow Üniversitesi'nde yaptığı çalışmalarla Richard Caton'un çalışmasından habersiz ve bağımsız olarak hayvanlar üzerinde yapmış olduğu deneylerle Caton'un bulgularını doğrulamıştır [52]. 1913 yılına gelindiğinde Vladimir Neminsky, EEG salınımlarının frekansından bahsetmiştir. Vladimir Neminsky eserinde şöyle demektedir “Beyin yüzeyinden çoğunlukla saniyede 12 ile 20 arasında ve en fazla saniyede yaklaşık 35 salınımlı rastgele sinyaller alınmaktadır”. 1914 yılında Napoleon Cybulski ilk defa köpeklerde epilepsi teşhisi için EEG sinyalinden yararlanmıştır. Böylece beynin zengin ritmik aktivitesi özellikleri ortaya çıkmaya başlamıştır. 1929 ve 1938 arasında yaptığı çalışmalarıyla Hans Berger adlı bilim adamı insanlardan alınan ilk EEG kaydını gerçekleştirmiştir. Hans Berger alfa ve beta ritimlerini

bulmuştur, elektroensefalogram adını vermiştir ve elektroensefalogramın babası olarak anılmaktadır [53].

1938 yılında Herbert Jasper ve Brown Üniversitesi'nden Howard Andrews ilk defa gama dalgalarından bahsetmişlerdir. Kuzey Amerika'da araştırma aktiviteleri 1934 yılı dolaylarında başlamıştır. İnsan EEG'si üzerine Harvard Üniversitesi'nde ve Iowa Üniversitesi'nde 1930'lu yıllarda başlamıştır. Amerikan EEG Topluluğu 1947 yılında kurulmuş ve ilk uluslararası EEG konferansı Londra'da bu yıllarda gerçekleşmiştir. 1950'ler boyunca EEG birçok farklı bölgelere yayılmıştır. Bu yıllarda mikroeletrotlar icat edilmiştir. Fourier analizinin EEG sinyallerine uygulanması 1950'li yıllarda geliştirilmiştir. Uyku bozukluklarının EEG ile analizi de yine 1950'li yıllarda gerçekleşmiştir. Yeni doğan bebeklerde ve prematüre bebeklerde EEG analizi 1960'lı yıllarda başlamıştır. Tepkisel potansiyellerin özellikle görsel tepkisel potansiyellerin araştırılması ve akıl hastalıklarının teşhisi çalışmaları ise 1970'li yıllarda olmuştur [54].

1.2.2. EEG Sinyalinin Oluşumu

Merkezi sinir sistemi nöronlar arasına yerleşmiş sinir hücrelerinden oluşur. Her sinir hücresi axon, dentrit ve hücre gövdelerinden oluşur. Sinir hücreleri uyarı ya da dürtülere cevap verir ve bilgiyi uzun mesafelere iletir. Sinir tarafından taşınan bilgiye aksiyon potansiyeli denir. Aksiyon potansiyelleri nöron zarları boyunca iyonların değişimi nedeniyle oluşur. Daima hücre gövdesinde oluşurlar ve normalde tek yönde hareket ederler. Bir aksiyon potansiyelinin iletim hızı 1 ile 100 m/s arasındadır. Aksiyon potansiyelleri çok dürtü çeşidi ile başlatılırlar; algılayıcı sinirler kimyasal, ışık, elektrik, basınç, dokunma ve gerilme gibi birçok dürtüye cevap verirler. Bu olay Şekil 1.6'da gösterilmiştir [55].



Şekil 1.6. EEG sinyalinin oluşumu

Elektrotlar kortikal nöron zarındaki sinaps sonrası potansiyellerin neden olduğu potansiyel farklılıkları kaydeder. Bu iki elektrot farklı voltaj seviyelerindedirler ve bu farkı dalga şeklinde ölçer.


1. REST: Dinlenme durumunda, yarı geçirgen bir zar tarafından sodyum iyonları Na^+ nın çıkışı ve potasyum K^+ iyonlarının girişi sürdürülerek -70 mV'luk potansiyel fark sağlanır.
2. IPSP: Sinaptik zarın geçirgenliği K^+ ve Cl^- iyonlarına geçici olarak artırılır ve böylelikle akım akışı ile zar potansiyelini artırılır, hücre zarı boyunca da yoğunluk azaltılır.

3. EPSP: Seçici olmayarak zarın geçirgenliği bütün iyonlara sodyum da dahil olmak üzere artırılır. Geçici olarak yerel zar potansiyeli azaltılır ve hücre zarını depolarize edecek akım üretilir.
4. AP: Axon tepesinde bir aksiyon potansiyeli oluşturulur. Böylelikle iyon değişimleri ile iyonik bir iletim gerçekleştirilmiş olunur.

1.2.3. EEG Sinyalinin Algılanması

EEG sinyalinin vücuttan alınışı da tıpkı EMG sinyali gibidir. İyon değişimlerinin oluşturduğu dalgalar kafatasındaki elektrotlara ulaştığında metal elektrottan elektronları alır veya verir. Metaller elektron alışverişini kolayca yapabildikleri için herhangi iki elektrot arasında oluşan potansiyel voltmetre ile ölçülür. Bu voltajların zamanla ölçümü EEG sinyali verir. Tek bir nöronun oluşturduğu elektrik potansiyelinin EEG cihazı ile algılanması imkânsızdır. Bu nedenle EEG aktivitesi binlerce veya milyonlarca nöronun oluşturduğu aktivitelerdir [56].


EEG kaydında kullanılan elektrotlar ince, paslanmaz çelik, altın kaplı gümüş, saf gümüş, saf altın ve gümüş/gümüş-klorid (Ag/AgCl) gibi çok çeşitli malzemelerden yapılmaktadır. Bu elektrot tipleri aktif olarak araştırma ve klinik faaliyetlerde EEG algılanmasında ve kaydedilmesinde kullanılır. Herhangi iki veya daha fazla metal bir çözeltiye yani elektrolite batırıldığında DC ofset gerilimi oluşmasından dolayı ve bu ofset gerilimlerinin çoğunlukla kullanılan metalin elektrokimyasal özelliklerine bağlı olmasından dolayı ölçümlerde iki farklı malzemeden yapılmış elektrotlar kullanılmamalıdır. En sık kullanılan elektrotlar gümüş/gümüş-klorid (Ag/AgCl) içerirler. Gümüş/gümüş-klorid (Ag/AgCl) biyolojik dokularla hızlıca elektrokimyasal gerilimler oluşturur ve bunu düşük ofset değişkenliği ile sürdürür. Dahası Ag/AgCl tip elektrotlar alerjik bileşen içermedikleri gibi uzun süreli mükemmel elektriksel karalılığa sahiptirler [57] [58]. Farklı malzemelerin iyon değişim tepkileri Şekil 1.7’de verilmiştir.



Şekil 1.7. Farklı elektrot materyallerinin kare dalgaya verdikleri tepkiler.

EEG alma sisteminde bir de referans elektrodu mevcuttur. Bu referans elektrodu idealde tamamen nötr olmalıdır ve beyin aktivitesi ölçümüne hiçbir katkısı veya etkisi olmamalıdır. Referans elektrotlarının sinyal alınacak bölgeden uzak olmaları gerekir. Vücutta referans elektrotları için en uygun yerler kulak memeleri, mastoidler (kulağın arka alt kısmı) ve burundur. Birçok modern EEG şapkalarında veya EEG başlıklarında referans elektrotunun yeri sabittir. Kulak memesine yerleştirilen referans elektrodu genelde iyi sonuçlar verir ve en çok kullanılandır çünkü kulak memesi EEG sinyalindeki gürültülerin birçoğunun kaynağı olan gözlerden ve yüz kaslarından oldukça uzaktır.

EEG sinyalleri alınırken beynin hangi bölgesinde hangi sinyallerin oluştuğunun ya da hangi işler için hangi bölgelerin aktif olduğunun bilinmesi oldukça önemlidir. Bunu yapabilmek için de öncelikle beynin lobları ve isimlendirmeleri çok önemlidir. Özellikle kafatasına yerleştirilecek olan elektrot adlandırmaları beyin loblarının baş harflerini içermesi sebebiyle beyin loblarının isimleri ve yerlerinin bilinmesi gerekir. Beyin loblarının isimlendirilmesi ve yerleri Şekil 1.8’de verilmiştir [59].




Şekil 1.8. Beyin lobları ve isimleri

1.2.4. EEG Sinyalinde Gürültüler

EEG sinyalleri vücuttaki en düşük genlikli biyolojik sinyallerden biridir. Bu nedenle EEG sinyalleri göz kırpması (EOG), kalp atışı (ECG) ve kas sinyallerinden (EMG) oldukça etkilenir. Çünkü belirtilen bu sinyaller EEG'ye göre daha baskındırlar. Bununla birlikte EEG sinyalleri 50 Hz şebeke gürültüsünden, elektrot temasına bağlı gürültülerden, çevrede var olan elektronik cihazların yaydığı elektromanyetik dalgalardan gelen bileşenler ile kirlenir. Özellikle göz kırpması (eye blink) gürültüsü oldukça baskındır ve bu gürültüyü yok etmeye yönelik çalışmalar oldukça fazladır.


1.2.5. EEG Elektrot Yerleşimi

EEG sinyalinin algılanması ilk yıllarında tek kanallı cihazlarla gerçekleştirilmiş olsa da günümüzde EEG çok kanallı cihazlarla alınmaktadır. Bu çok kanallı cihazların elektrotları da bilinçli olarak beynin bölgelerine yerleştirilir. EEG elektrotlarının yerleşimi 10-20 sistemi denilen uluslararası standarda göre yapılır. Bu sistemde her elektrot çeşitli harfler ve rakamlardan oluşur. Toplam 21 adet elektrottan oluşur. İlk bakıldığında anlamsız ve karmaşık gelen bu harf ve rakamlar aslında o elektrotun adresidir ve kolay anlaşılır yapıdadır. İsimlendirmede geçen F,T,C,P,O harfleri sırasıyla ve Latince isimleriyle “frontal”, “temporal” “central” “parietal” “occipital” loblarını ifade eder. Beynin bu lobları Şekil 1.9’da verilmiştir. Adlandırmadaki çift rakamlar o elektrotun kafatasının sağ yarısında olduğunu, tek rakamlar ise elektrotun sol yarıda olduğunu ifade eder. Küçük z harfi elektrotun sağ ve sol yarısı ayıran hat



Şekil 1.10. 10/10 Sistemi

10/10 sisteminde renkli olan elektrotlar standart olan 10/20 sistemine ait elektrotları göstermektedir. Toplam 69 adet elektrot içerir.



Şekil 1.11. 10/5 Sistemi

2. SİNYAL İŞLEME

Tezin bu bölümünde ilgili kaslara ve beynin ilgili bölgelerine tahribatsız (noninvasive) olarak yerleştirilen elektrotlar vasıtasıyla alınan EEG ve EMG sinyallerinin değerlendirilmesi yapılacaktır. EEG ve EMG sinyallerinin oluşumundan elektrotlarla bu sinyallerin alınması işlemleri önceki bölümde anlatılmıştır. Alınan ham sinyaller öncelikle eşlik eden gürültülerden arındırılacaktır. Bu gürültülerin neler oldukları her iki sinyal için önceki bölümde verilmiştir. Tablo 2.1’de verilen, EEG ve EMG sinyallerinin anlamlı ya da işe yarar kısımları, belirli frekans aralığındadır [61].

Tablo 2.1: EEG ve EMG sinyallerinin frekans aralıkları.


Tip	Frekansı
EEG	0-100 Hz
EMG	10-200 Hz

Ancak sinyallerin vücuttan alınması için kullanılan cihazlar örnekleme frekanslarına bağlı olarak sadece istenilen frekans aralıklarını almak yerine daha büyük frekanslı sinyalleri de alırlar. Bu nedenle ilk etapta istenmeyen aralıktaki sinyaller alçak geçiren filtre ve yüksek geçiren filtre kullanılarak yok edilir. Filtre kullanımından önce ise çok küçük genlikleri olan EEG ve EMG sinyallerine nazaran düşük frekanslı, gürültülü ve yüksek genlikli DC bileşen yok edilmelidir.

2.1. DC Sapma Geriliminin Yok Edilmesi


Bir elektrot iletken bir çözelti içerisine daldırıldığında elektron akmazken elektrot ile çözelti arasında elektriksel potansiyel farkı oluşur. Önceki bölümde anlatıldığı üzere iletken çözelti olarak görev yapan kısım deri-elektrot birleşimi ve kullanılan elektrot jelleridir. Oluşan elektrot potansiyeli; elektrot malzemesi, elektrolit yapısı ve sıcaklığın bir fonksiyonudur. DC sapma gerilimi birkaç mV ile birkaç volt seviyesindedir. Elektrotlarda oluşan ve önlenemeyen bu gerilimler yükselticinin girişine gelerek ölçmek istenen aktiviteden daha büyük genlikli ölçümlere neden olurlar [62]. Bu DC sapma geriliminin yok edilmesi hem sinyallerin frekans analizinde kullanılan fourier dönüşümü için hem de sıfır geçiş sayısı gibi bazı özellik çıkarma yöntemlerinin sağlıklı sonuçlar verebilmesi adına oldukça önemlidir. Çünkü fourier dönüşümünde DC sapma gerilimi yok edilmediği zaman 1 Hz’den daha düşük

frekanslı bölgede diğer frekansları gölgeleyen ve analizini zorlaştıran frekans genlikleri var olacaktır. Aynı şekilde sıfır geçiş sayısı özelliği kullanılmak istendiğinde sinyal sıfır noktasından hiç geçemeyeceği için doğru sonuçlar vermeyecektir.



Şekil 2.1. a) Ham EEG sinyali, b) DC sapma gerilimi yok edilmiş EEG sinyali

Şekil 2.1’de görüldüğü üzere, ham EEG sinyalinin analog dijital çeviriciye göre genliği ortalama 4110 seviyelerinde iken DC sapma gerilimi yok edildikten sonra genliği ortalama 0 seviyesindedir.



Şekil 2.2. Ham EEG sinyalinin fourier dönüşümü, a) DC sapma yok edilmeden, b) DC sapma yok edildikten sonra

Şekil 2.2 (a)’ ya bakıldığında düşük frekanslı 0 Hz’e yakın DC sapma sinyallerinin Fourier dönüşümündeki gücü diğer frekansları gölgelemektedir. Bu nedenle 0 Hz’e yakın bölgede çok yüksek güçlü bir tepe görülmektedir. Şekil 2.2 (b)’ de ise DC sapma gerilimi yok edildikten sonra çizdirilen fourier dönüşümü vardır. Burada ise anlamlı bir EEG frekans çizimi vardır; çünkü EEG bantlarına bakıldığında bantların çizimdeki frekans aralığında olduğu görülmektedir. Burada en yüksek frekanslı sinyalin 64


gözükmesi EEG sinyallerini almak için kullanılan cihazın örnekleme frekansının 128 Hz olmasından dolayıdır. Normalde 50 Hz civarında şebeke gürültüsünden dolayı bir tepe oluşması beklenir ancak EEG sinyalleri alınırken bilgisayarın beslemesi şebekeden çıkarılarak batarya ile çalıştırılarak alındığı için oluşmamıştır. EEG frekans bantları Tablo 2.2’de verilmiştir [63].

Tablo 2.2: EEG Sinyalinin Alt Bantları.


Band	Frekans aralığı
Delta	0.3-4 Hz
Theta	4-8 Hz
Alpha	8-13 Hz
Beta	13-30 Hz
Gamma	30-40 Hz

2.2. Yüksek Geçiren Filtre

Yüksek Geçiren Filtre (YGF) filtre frekansının üzerinde olan frekansları geçirip altında kalan frekansları ise süzmekte ya da engellemektedir. Yüksek geçiren filtre kullanarak odaklanmak istenilen frekans aralığının alt sınırı belirlenerek bu sınırın üzerindeki frekanslara yoğunlaşılabilir. Örneğin beta bandı ile çalışmak istendiğinde yüksek geçiren filtrenin frekansı 13 Hz’e ayarlanarak frekans alt sınırı belirlenir. Tabi bütün beta bandını elde etmek için ilerleyen kısımda bahsedilecek olan bir de 30 Hz frekanslı alçak geçiren filtre kullanılması gerekir. Alınan bir EEG sinyalinden ham EEG sinyalinin çekilebilmesi için 0 Hz ile örnekleme frekansının yarı frekansı aralığında olan sinyali, 0.3 Hz yüksek geçiren filtre ve 40 Hz alçak geçiren filtreden geçirilmesi gerekir.



a




b

Şekil 2.3. EEG sinyalinin fourier dönüşümü a) DC sapma yok edildikten sonra, b) 0.3 Hz alçak geçiren filtreden geçirildikten sonra

Şekil 2.3'te görüldüğü üzere 0.3 Hz yüksek geçiren filtreden sonra 0.3 Hz'den düşük sinyallerin baskınlığı 8-13 Hz aralığındaki alfa ritminden daha az hale gelmiştir.

2.3. Alçak Geçiren Filtre

Alçak geçiren filtre (AGF) belirlenen bir frekanstan yukarısını engelleyip alt frekansları geçiren filtredir. Alçak geçiren filtre kullanılarak odaklanmak istenilen frekans aralığının üst sınırını belirlenir. Bir yüksek geçiren filtre kullanarak alt frekans belirlendikten sonra istenilen frekans aralığına odaklanılmış olunur ve istenmeyen frekansa sahip sinyaller yok edilir.




Şekil 2.4. 4 saniyelik ham EEG ve filtrelenmiş EEG

Şekil 2.4'de mavi renkle çizdirilmiş olan sinyal sadece DC sapma gerilimi arındırılmış sinyal olup kırmızı renkli sinyal ise 0.3 Hz yüksek geçiren 40 Hz alçak geçiren filtre uygulanmış sinyaldir. Filtrelenmiş olan sinyalde diğer sinyale göre büyük salınımların olmadığı ve 0 seviyesinde küçük salınımlar olduğu görülmektedir. EEG sinyali için şu bilinmelidir; büyük salınımlar olan bir EEG sinyalinde DC kayma gerilimi veya elektrot temasından kaynaklanan gürültülerin fazlaca olduğu söylenebilir.

2.4. 50 Hz Notch Filtre

50 Hz Notch filtre günlük hayatta kullanılan bütün elektrikli veya elektronik cihazları besleyen şebekenin basmış olduğu 50 Hz'lik AC gürültüyü yok etmeye yarar. 50 Hz şebeke gürültüsü ilk bölümde anlatıldığı üzere düşük genlikli olan biyolojik işaretler üzerinde oldukça kirletici etkiye sahiptir. Maalesef alınan sinyaller 50 Hz şebeke gürültüsünden arındırılmadıkça anlamsız veriler haline gelmektedirler. 50 Hz Notch filtre aslında bir çeşit bant durduran filtredir.



Şekil 2.5. EMG sinyalini kirleten 50 Hz şebeke gürültüsü

Şekil 2.5’de hareketsiz ve kasılma olmayan bir kas üzerinden elektrotlarla alınan bir EMG sinyali ve bu sinyali kirleten bir 50 Hz şebeke gürültüsü görülmektedir. Görüldüğü üzere kasılmamış bir kas üzerinde en belirgin sinyaller düşük frekanslı deri-elektrot temasından kaynaklı sinyaller ve 50 Hz şebeke gürültüsüdür.

3. ÖZELLİK ÇIKARIMI

EEG ve EMG sinyalleri gürültülerden arındırıldıktan sonra bu sinyallere has özelliklerin ortaya çıkarılması gereklidir. Özellik çıkarımı bazen yüzlerce hatta milyonlarca örnekten oluşmuş bir veriyi sayısal bir değer ile temsil etmektir. Örneğin örnekleme frekansı 128 Hz olan EEG cihazı ile 100 saniyelik bir EEG verisinin alındığı varsayılırsa, EEG verisi $100 \times 128 = 12800$ adet örnekten oluşacaktır. Şüphesiz 12800 adet örnekten oluşan bir veriye bakıldığında anlaşılması ve değerlendirilmesi oldukça güç olacaktır. Bu nedenle özellik çıkarımı gereklidir yani 12800 adet örneğin neyi ifade ettiği bulunmalıdır. En genel özellik çıkarma yöntemi olan ortalama bulma tekniğini 12800 örnekli veriye uygulanırsa hepsinin ortalaması olan bir değer elde edilir. Böylelikle çok sayıda örneğin bir arada bulunduğu veriler anlamlı birer değere dönüştürülmüş olunur. Tablo 3.1’de kullanılan özellik çıkarma yöntemleri verilmiştir.

Tablo 3.1. : Kullanılan Özellik Çıkarma Yöntemleri

Zaman domenli özellikler	Frekans domenli özellikler
Ortalama	Ortalama Frekans
Ortalama Mutlak Sapma	Orta Frekans
Varyans	Asimetri Oranı
Standard Sapma	Spektral Benzerlik
Çarpıklık (Asimetri)	Özbağlanım Katsayıları
Basıklık	
Mobilite	
Biçim Katsayısı	
Tipik Değer	
Entropi	
Sıfır Geçiş Sayısı	
Eğim İşaret Değişimi Sayısı	
Wilson Genliği	
Dalga Boyu Uzunluğu	
Yüzdelik	
Çeyrek Kütle	

Tablo 3.1’de görüldüğü üzere hem zaman domenli hem de frekans domenli özellikler kullanılmıştır. Burada zaman domenli özellikler doğrudan sinyali oluşturan örneklerin genlikleri kullanılarak hesaplanırken, frekans domenli özellikler sinyalin Fourier dönüşümü ile frekans bilgisi çıkarıldıktan sonra hesaplanır.

Ortalama: Ortalama zaman domeninde en kolay ve en sıklıkla kullanılan özelliklerden birisidir. Ortalama ile alınan sinyal örneklerinin genlikleri toplanarak sinyal örneklerinin sayısına bölünmesiyle bulunur. İstatistikte birinci dereceden momente denk gelmektedir.

$$ORT = \frac{1}{N} \sum_{n=1}^N x_n \quad (3.1)$$

Ortalama Mutlak Sapma: Ortalama mutlak sapma özelliği örneklerin ortalamaya olan uzaklıkları farkının mutlak değerleri toplamıdır [64].

$$OMS = \frac{1}{N} \sum_{n=1}^N |x_n - ORT| \quad (3.2)$$

Varyans: İstatistikte 2. Dereceden moment olan varyans sinyalin enerjisini temsil etmektedir.

$$VAR = \frac{1}{N-1} \sum_{n=1}^N (x_n - ORT)^2 \quad (3.3)$$

Standard Sapma: Standard sapma sayesinde veri içerisindeki örneklerin ortalamaya yakınlığı hakkında bilgi sahibi olunur. Adından da anlaşılacağı gibi verilerin dağılımı ve bu dağılımın ölçüsü hakkında bilgi edinilir. Varyansın kareköküdür.

$$STD = \sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_n - ORT)^2} \quad (3.4)$$

Çarpıklık (Asimetri): İstatistikte 3. derece momente tekabül eder ve asimetrinin ölçütüdür [65]. Üçüncü dereceden moment aynı sinyalin standart sapmasının üçüncü kuvvetine bölünmesiyle elde edilir. Verinin simetriden ne kadar uzaklaştığının ölçütüdür.

$$\text{car} = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \text{ORT})^3}{\text{STD}^3} \quad (3.5)$$

Basıklık: Dördüncü derece momentin aynı sinyalin standart sapmasının dördüncü kuvvetine bölünmesi ile hesaplanır. Sinyalin ortalama etrafındaki yoğunluğunun derecesini ve ölçüsünü basıklık gösterir [66].

$$\text{bas} = \frac{\frac{1}{N} \sum_{n=1}^N (x_n - \text{ORT})^4}{\text{STD}^4} \quad (3.6)$$

Özbağlanım Katsayıları: Özbağlanım katsayıları biyolojik sinyaller için popüler özellik çıkarma yöntemlerinden birisidir.


$$x[n] = - \sum_{k=1}^p a_k x[n-k] + e[n] \quad (3.7)$$

Burada p modelin derecesi, $x[n]$ n sayıda örnekten oluşan veri sinyali, a_k gerçek değerli özbağlanım katsayılarıdır ve $e[n]$ önceki örneklerden bağımsız beyaz gürültü hata terimini temsil eder. Özbağlanım katsayıları sinyale uyan bir eşitliğin eldesi olarak düşünülmelidir. Özbağlanım katsayıları bir veri noktasının önceki birkaç veri noktasıyla ilişkili olduğunu varsayarak sinyali modellemeye çalışır. Bu yöntem biyosinyalleri modellemeye uygundur. Yule-Walker metodu gibi özbağlanım katsayılarını tahmin etmek için birçok farklı teknikler mevcuttur. Fakat Yule Walker metodu işlemsel olarak oldukça karmaşıktır. Bu metot otokorelasyon fonksiyonunun hesaplanmasındaki zorluklardan dolayı küçük veri parçalarında hatalı olabilmektedir. Bu nedenle p dereceli a_k 'yi hesaplamak için önceki derecenin $p-1$ a_k 'sini kullanarak geri dönüşümlü algoritma kullanımı önerilir. Bu metotlara örnek olarak Burg ve Levinson-Durbin algoritmaları verilebilir: Burg algoritması Levinson-Durbin algoritmasına göre daha kesin ve doğrudur. Çünkü daha fazla veri noktası kullanarak eşzamanlı olarak sadece ileri hataları değil aynı zamanda geri hataları da minimize eder. Geri dönüşümlü algoritmada modelin derecesini seçmek oldukça önemlidir. Çünkü model derecesinin yüksek oluşu veriye aşırı uyum yaparak fazla gürültünün de temsil edilmesini sağlar. Bunun yanında model derecesinin çok düşük seçilmesi ise

sinyalin yeterli temsil edilememesine neden olur. Bu nedenle uygun bir model seviyesi seçilmelidir. Model derecesinin hesaplanması için AIC (Akaike Information Criterion), Son tahmin hatası (Final Prediction Error), Özbağlanımlı Transfer Kriteri (Criterion Autoregressive Transfer), Minimum Tanımlama Uzunluğu (Minimum Description Length) gibi birçok yöntem vardır. AIC en genel kullanılanıdır ve bu çalışmada da bu yöntem kullanılmıştır, matematiksel modeli de aşağıdaki gibidir.

$$AIC(\rho) = \ln(\sigma_\rho^2) + 2\rho/N \quad (3.8)$$

Burada ρ model seviyesi, N sinyalin uzunluğu ve σ_ρ^2 ρ seviyesindeki hata dizisinin varyansdır [67].



Şekil 3.1. Özbağlanım katsayılarını belirlemek için çizdirilen Akaike kriteri

Şekil 3.1’de görüldüğü üzere alınan EMG sinyali için özbağlanım katsayılarının ilk 100 tanesi çizdirilmiştir. Bu katsayılardan 20’den sonrasının sinyali temsil etme adına çok az etkilerinin olduğu görülmektedir. Çizime bakıldığında özbağlanım katsayılarının ise 10’a kadar önemli etkilerinin olduğu görülmektedir. Gerek sinyalin iyi temsil edilmesi, gerek boyutun optimum tutulabilmesi için özbağlanım katsayıları 10 ile 20 arasında bir değer seçilmelidir. Bu örnekte özbağlanım katsayıları keyfi olarak 12 seçilmiştir.

Sıfır Geçiş Sayısı: Sıfır geçiş sayısı sinyalin frekans bilgisinin zaman domeni kullanılarak gösterilmesidir. Sıfır geçiş sayısı sinyalin genliğinin sıfır “0” olduğu

noktalar sayılarak elde edilir. Gerilim dalgalanmalarının veya bazı gürültülerinin etkisini azaltmak için eşik değeri kullanılabilir.

$$SGS = \sum_{n=1}^{N-1} [sgn(x_n \times x_{n+1}) \cap |x_n - x_{n+1}| \geq eşik]; \quad (3.9)$$

Eğim İşaret Değişimi Sayısı: Eğim işaret değişim sayısı, sinyalin genliğinin eğim işaretinin artıdan eksiye ve eksiden artıya geçiş sayısının sayılmasıdır. Sıfır geçiş sayısı gibi eşik konularak gürültülerin etkisi yok edilebilir [68].

$$EİD = \sum_{n=2}^{N-1} [f[(x_n - x_{n-1}) \times (x_n - x_{n+1})]]; \quad (3.10)$$

$$f(x) = \begin{cases} 1, & \text{eğer } x \geq eşik \\ 0, & \text{diğer durumlarda} \end{cases}$$

Dalga Boyu Uzunluğu: Dalga boyu uzunluğu sinyalin karmaşıklığının ölçüsüdür. Zaman domenindeki örnekler arasındaki genlik farklarının kümülatif uzunluğudur. Düzensiz rastgele duran bir ipin iki ucundan tutulup gerdirildikten sonra boyunun ölçülmesi işlemine benzetilebilir.

$$DBU = \sum_{n=1}^{N-1} |x_{n+1} - x_n| \quad (3.11)$$

Wilson Genliği: Wilson genliği sinyali oluşturan ardışık örneklerin belirli bir eşik değerini kaç kez aştığının sayısıdır.

$$WG = \sum_{n=1}^{N-1} [f(|x_n - x_{n+1}|)]; \quad (3.12)$$

$$f(x) = \begin{cases} 1, & \text{eğer } f(x) \geq eşik \\ 0, & \text{diğer durumlarda} \end{cases}$$

Entropi: Shannon entropisi ve logaritma enerji entropileri kullanılmıştır. Shannon entropisi olasılık yoğunluk fonksiyonudur ve girdi olarak olasılık yoğunluğunu alarak bunu bir sayıya dönüştürür [69]. Shannon entropisi rastgele dağılımın standardıdır ve

istatistik, bilgi teorisi ve kodlama teorisi alanlarında önemli role sahiptir [70]. Shannon entropisi Denklem 3.13’de verilmiştir [71].

$$E_j = - \sum_n E_{jn} \log E_{jn} \quad (3.13)$$

E_{jn} n anında j’inci seviye dalgacık enerji spektrumudur ve Denklem 3.14’de verildiği gibidir.

$$E_{jn} = |D_j(n)|^2 \quad (3.14)$$

Denklem 3.13’de yerine konursa;

$$E_j = - \sum_n |D_j(n)|^2 \log(|D_j(n)|^2) \quad (3.15)$$

Burada $D_j(n)$ dalgacık katsayısıdır. Log enerji entropisi Denklem 3.16’da verilmiştir.

$$E_j = \sum_n \log(|D_j(n)|^2) \quad (3.16)$$

Tipik Değer: Bu özellik sinyal içerisinde en çok tekrarlanan değeri bulmaya yarar. Tipik değer özelliği verinin boyutuna ve iki nokta arasındaki uzaklığa bağlıdır. Bu nedenle veriler eşit uzunlukta ve iki örnek arası eşit uzaklıkta olmalıdır. MATLAB programında “mode” komutu ile uygulanır.

Yüzdelik: Bu özellik sinyal örneğinin kullanışlı bir özetini elde etmeye yarar. Burada sinyal sinyalin başlangıç noktasından bitiş noktasına kadar 100 nokta seçilir. Daha sonra seçilen ardışık noktalar doğrusal enterpolasyon (ara değerlendirme) yapılarak birleştirilir. Örneğin 2.5, 25, 50, 75, 97.5 kombinasyonu sinyalin kullanışlı bir özetidir. Burada 50. örnek sinyalin orta değeridir. Bu özellik MATLAB’da “prctile” komutu ile uygulanır.

Çeyrek kütle: Çeyrek kütle özelliği tıpkı Yüzdelik özelliği gibidir fakat sinyali 100 noktaya bölmek yerine sadece 4 eşit parçaya böler. Çeyrek kütle özelliği sinyalin yayılımını veya saçılımını hesaplamak için gereklidir. Çeyrek kütle birinci ve üçüncü

çeyreğin farkıdır ya da 75. ve 25. yüzdelerinin farkıdır. MATLAB programında “iqr” komutu ile uygulanır.

Mobilite: Mobilite özellikle EEG sinyal analizinden sıklıkla kullanılan bir özellik çıkarma yöntemidir. Sinyalin birinci türevinin standart sapması alınıp, sinyalin standart sapmasına bölünmesi ile elde edilir. Sinyalin ortalama frekansı hakkında bilgi verir.

$$MOB = \frac{\sqrt{\frac{1}{N-1} \sum_{n=1}^N \left(x_n(t) \frac{dx}{dt} - ORT \right)^2}}{\sqrt{\frac{1}{N-1} \sum_{n=1}^N (x_n - ORT)^2}} \quad (3.17)$$

Biçim Katsayısı: Biçim katsayısı da mobilite özelliği gibi EEG sinyal analizinde sıklıkla kullanılan yöntemdir. Sinyalin birinci türevinin mobilitesinin, sinyalin mobilitesine bölünmesi ile elde edilir. Mobilite denkleminin karmaşık olması sebebiyle biçim katsayısı kısaca Denklem 3.18’de verilmiştir. Denklem 3.17’de yerine konularak tam hali elde edilir. Sinyalin frekans değişimleri hakkında bilgi verir.

$$BK = \frac{MOB_{x'}}{MOB_x} = \frac{\sigma_{x''}/\sigma_{x'}}{\sigma_{x'}/\sigma_x} \quad (3.18)$$

Diğer bir deyişle biçim katsayısı sinyalin ikinci mertebeden türevinin standart sapmasının, sinyalin birinci türevinin standart sapmasına bölümünün sinyalin mobilitesine bölünmesidir.

Frekans domeni özelliklerine geçmeden önce fourier dönüşümünün bilinmesi faydalıdır ve gereklidir.

Fourier Dönüşümü

Fourier dönüşümü sinyal işleme alanında sinyallerin frekans domeninde incelenmesine imkân sağlamasından dolayı yaygın bir şekilde kullanılmaktadır. Sinyaller aslında trigonometrik sinyallerin belli frekanslarda karışımıyla oluşurlar.


Fourier dönüşümüyle de sinyaller aslında trigonometrik sinyaller cinsinden temsil edilirler. Fourier dönüşümünün birkaç türü bulunmaktadır bunlar;

- Sürekli Fourier dönüşümü: Sürekli fourier dönüşümü tezde ve uygulamada çok fazla kullanılmadığı için üzerinde çok fazla durulmayacaktır. Denklem 3.19’da verilmiştir, ters Fourier dönüşümü ise Denklem 3.20’de verilmiştir [72].

$$S(\omega) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} s(t) e^{-j\omega t} dt \quad (3.19)$$

$$s(t) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{\infty} S(\omega) e^{j\omega t} d\omega \quad (3.20)$$

- Ayırık Fourier dönüşümü: Dış dünyadan alınan analog sinyaller genellikle analog dijital çeviriciler vasıtasıyla (ADC) dijitale çevrilir ve bilgisayara dijital olarak kaydedilir. Bu dijital veriler aslında ayırık veri noktalarıdır. Çünkü analog dijital çevirici tarafından düzenli aralıklarda alınmış sayı dizilerine dönüştürülür ve bu işleme “örnekleme” denir.



Şekil 3.2. a) Analog sinyal b) Örnekleme c) Ayırık zamanlı sinyal

Şekil 3.2’de ayırık zamanlı sinyalin oluşumu gösterilmiştir. Ayırık sinyaller oluşturulurken örnekleme frekansı oldukça önemlidir. Örnekleme frekansı düşük seçilirse sinyal yeterince temsil edilemez. Bu nedenle örnekleme frekansı analog sinyalin bileşeni olan en yüksek frekanslı sinyalin frekansının iki katı seçilmelidir. Bu Nyquist frekansı ve Nyquist teoremi olarak bilinir.

Fourier dönüşümünü bilgisayarlarda kullanabilmek için ayırık zamanlı Fourier dönüşümü geliştirilmiştir.

$$X_{AFD}[m] = \sum_{n=0}^{N-1} x[n]e^{-j\omega n} \quad (3.21)$$

$\omega = 2\pi f/F_s$ ve $f = mF_s/N$ olduğundan;

$$X[m] = \sum_{n=0}^{N-1} x[n]e^{-\frac{j2\pi mn}{N}} \quad (3.22)$$

Ters ayrık Fourier dönüşümü ise denklem 3.23.'de verilmiştir.

$$X[n] = \frac{1}{N} \sum_{m=0}^{N-1} X[m]e^{\frac{j2\pi mn}{N}} \quad (3.23)$$

Euler ilişkisi, $e^{jx} = \cos(x) + j\sin(x)$, denklem 3.22.'de yerine konursa ayrık Fourier dönüşümünün yeni hali denklem 3.24.'teki gibi olur.

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

Denklem 3.24.'te görüldüğü üzere artık ayrık fourier dönüşümü (AFD) her bir m frekansı için gerçek ve sanal kısımdan oluşmaktadır. Buna bağlı olarak genlik spektrumu denklem 3.25.'de faz spektrumu denklem 3.26.'ta verilmiştir.

$$|X[m]| = \sqrt{Re(X[m])^2 + Im(X[m])^2} \quad (3.25)$$

$$\theta(m) = \arctan\left(\frac{Im(X[m])}{Re(X[m])}\right) \quad (3.26)$$

Burada;


$$Re[m] = \sum_{n=0}^{N-1} x[n] \cos\left(\frac{2\pi mn}{N}\right) \quad (3.27)$$

$$Im[m] = - \sum_{n=0}^{N-1} x[n] \sin\left(\frac{2\pi mn}{N}\right) \quad (3.28)$$

- Hızlı Fourier dönüşümü: Uygulamada en çok kullanılan ve ayrık fourier dönüşümünün pratik şekli olan fourier dönüşümüdür. Fast Fourier Transform (FFT) olarak kaynaklarda ve literatürde geçmektedir. İşlemlerin karmaşıklığı önemli ölçüde azaltıldığı için hesaplamalar daha kolaydır ve zamandan tasarruf yapmayı sağlamaktadır. Cooley-Tukey hızlı fourier dönüşümü (HFD) algoritması olarak da bilinen bu algoritma denklem 3.29.'da gösterildiği gibi ifade edilir [73].

$$\begin{aligned}
\sum_{n=0}^{N-1} a_n e^{-\frac{2\pi i n k}{N}} &= \sum_{n=0}^{\frac{N}{2}-1} a_{2n} e^{-\frac{2\pi i (2n) k}{N}} + \sum_{n=0}^{\frac{N}{2}-1} a_{2n+1} e^{-\frac{2\pi i (2n+1) k}{N}} \\
&= \sum_{n=0}^{\frac{N}{2}-1} a_n^{cift} e^{-\frac{2\pi i (2n) k}{N}} + e^{-\frac{2\pi i k}{N}} \sum_{n=0}^{\frac{N}{2}-1} a_n^{tek} e^{-\frac{2\pi i n k}{N}}
\end{aligned} \tag{3.29}$$

- Kısa zamanlı Fourier dönüşümü: Fourier analizi durağan yani değişken olmayan sinyallerin analizinde oldukça başarılıdır. Fourier analizi durağan olmayan ve değişken frekansa sahip yani periyodik olmayan sinyalleri ele almakta yetersiz kalmaktadır. Birçok işaret kaynağı durağan olmayan sinyaller ürettikleri için kısa zamanlı fourier dönüşümüne (KZFD) ihtiyaç duyulmuştur. KZFD'de sinyalin tamamının alınarak fourier dönüşümü yapılmak yerine sinyal içerisinde sinyalin durağan kabul edilebileceği küçük aralıkların alınarak yerel fourier dönüşümleri yapılır. Bölerek Fourier alma işlemi bütün sinyal boyunca olur. Belirli bir genişlikte olan pencere, sinyalin başlangıcından sonuna doğru kaydırılarak her defasında fourier dönüşümü yapılarak gerçekleştirilir. Bu işlem Şekil 3.3. 'te gösterilmektedir [74].



Şekil 3.3. Kısa süreli fourier dönüşümünün gerçekleştirilmesi

Şekil 3.3.'te dikdörtgen pencere durağan olmayan ve periyodik olmayan sinyal üzerinde kaydırılarak KZFD hesaplanır. Böylelikle şekilde de görüldüğü üzere sinyalin zamana bağlı olarak frekans değişimleri bulunur. Bu işlem Denklem 3.30'da gösterildiği gibi yapılmaktadır.

$$F_{KZFD}(\tau, f) = \int_{-\infty}^{\infty} s(t)w^*(t - \tau) \exp(-j2\pi ft) dt \quad (3.30)$$

Burada $s(t)$ Fourier dönüşümü yapılacak sinyal, $w(t)$ pencereleme fonksiyonu, f frekans, τ zaman parametresini (zaman aralığı), $F(\tau, f)$ de sinyalin f frekansı ve τ zaman dilimindeki KZFD'yi göstermektedir. KZFD'de her f frekansı için pencere $t = \tau$ değerine merkezlenerek $w(t - \tau)$ tarafından $s(t)$ sinyalinin pencere genişliğindeki zaman aralığının bilgisi elde edilir. HFD ile de zaman aralığındaki frekans dağılımı elde edilir [75]. KZFD'nin pratikte kullanılan ayrık formu Denklem 3.31'de verilmiştir.

$$F_{KSF D}[m, \omega] = \sum_{n=-\infty}^{\infty} x[n] \omega[n - m] e^{-j\omega n} \quad (3.31)$$

Başlıca pencereleme fonksiyonları şunlardır.

- **Dikdörtgensel pencere**

Dikdörtgensel fonksiyon tanımlandığı aralıkta bütün örnekleri 1'dir ve sinyalin budanmasını sağlar. Dikdörtgensel pencere fonksiyonu Denklem 3.32'de verilmiştir. ($n = 0, 1, 2, \dots, N-1$)

$$W(n) = 1 \quad (3.32)$$

Dikdörtgensel pencerenin fourier dönüşümü ise Denklem 3.33'de verilmiştir.

$$W(\omega) = \sum_{n=0}^{N-1} e^{-j\omega n} = e^{-j\omega \frac{N-1}{2}} \frac{\sin\left(\frac{N}{2}\omega\right)}{\sin\frac{\omega}{2}} \quad (3.33)$$

- **Üçgensel, Bartlett pencereleri**

Bu pencereleme fonksiyonları zaman domeninde üçgen şeklinde olan fonksiyonlardır. Üçgensel pencere sıfır olmayan değerlerle başlar ve biter, Bartlett fonksiyonu ise sıfır ile başlar ve biter. Üçgensel pencere fonksiyonu Denklem 3.34'de verilmiştir. ($n = 0, 1, 2, \dots, N/2$)

$$W(n) = \frac{n}{N/2} \quad (3.34)$$

Üçgensel pencerenin ayrık fourier dönüşümü Denklem 3.35'de verilmiştir.

$$W(\omega) = e^{-j\omega(\frac{N}{2}-1)} \left[\frac{\sin\left(\frac{N}{4}\omega\right)}{\sin\frac{\omega}{2}} \right]^2 \quad (3.35)$$

- **Blackman, Hamming, Hanning pencereleri**

Pencere fonksiyonları 2. ve 3. Dereceden kosinüs polinomlarından oluşur. Sırasıyla Blackman, Hamming ve Hanning pencerelerine ait denklemler sırasıyla Denklem 3.36. Denklem 3.37. ve Denklem 3.38’de verilmiştir. ($n = 0, 1, 2, \dots, N-1$)

$$W(n) = 0.42 + 0.5 \cos\left(\frac{2\pi}{N}(n - 25)\right) + 0.08 \cos\left(\frac{2\pi}{N}2(n - 25)\right) \quad (3.36)$$

$$W(n) = 0.54 - 0.46 \cos \frac{2\pi}{N} n \quad (3.37)$$


$$W(n) = \sin^2 \left[\left(\frac{n}{N} \right) \pi \right] = \frac{1}{2} \left[1 - \cos \left[\left(\frac{2n}{N} \right) \pi \right] \right] \quad (3.38)$$

- **Kaiser, Chebyshev, Gauss pencereleri**

Özel polinomlarla oluşturulan daha gelişmiş pencereleme fonksiyonlarıdır.

Hangi pencereleme yönteminin kullanılacağı işlenecek sinyalin tipine ve uygulamaya bağlıdır. Yan kulak gürültüleri için pencerenin genliğini küçültmek daima tercih edilir. Ana kulağın daraltılması ise yüksek çözünürlük meydana getirir.


Dikdörtgensel pencere en dar ana kulağa neden olurken yan kulak gürültülerini bastırmada zayıftır. Hann ve Hamming pencereleri yan kulak gürültülerini iyi bir şekilde bastırırken geniş bir ana kulağa neden olur. Kaiser penceresinde filtrenin uzunluğu, geçirilecek bant genişliğini ayarlar. Bant geçiren ve bant bastıran filtredeki dalgalanmayı kontrol eden değiştirilebilir parametreleri nedeniyle çok esnektir [76].



Şekil 3.4. Pencereleme fonksiyonları

Şekil 3.4’de görüldüğü gibi yukarıda bahsi geçen pencereleme fonksiyonları çizdirilmiştir. Bunlardan Hamming (mavi), Hanning (kırmızı), dikdörtgensel (sarı), üçgensel (yeşil), Blackmann (pembe) ve Kaiser (siyah) olanıdır. Bu çalışmada pencereleme tekniği olarak Hamming penceresi kullanılmıştır.

Ayrık fourier dönüşümü uygulanılırken uygulanan sinyalin sonsuz periyodik bir sinyalden çıkarılmış 1 tam döngü sinyal olduğu varsayılır. Fakat makineyle veya sensörle alınan bir sinyal ya da uzunca bir sinyalin içinden kesip alınan bir sinyal parçası her zaman tam periyodik bir sinyal değildir. Periyodik olan bir sinyalin başlangıç ve bitiş değeri ve yeri aynıdır. Sinyal bir noktadan alınmaya başlanır ve bir noktada sinyal alma işlemi kesilir. Her zaman sinyal alma işleminin kesildiği nokta tam Şekil 3.5’te görüldüğü gibi periyodik veya başlangıç değerine eşit bir nokta olamamaktadır [67]. Bu periyodik olmama durumu spektral sızıntılara sebep olmaktadır.



Şekil 3.5. Spektral sızıntı oluşumu

Pencereleme işlemi ayrıca başlangıç ve bitiş noktası aynı olmayan veya tam periyodik olmayan sinyallerin daha doğru analiz edilmesinde kullanılır. Spektral sızıntıların önlenmesinde kullanılır.

Aslında biyolojik sinyallerin frekans özelliklerinin ortaya çıkarılmasında Fourier dönüşümü vasıtasıyla elde edilen güç spektral yoğunluğu (GSY) ile sinyale ait birçok özellik çıkarılmaktadır. GSY kısaca gücün frekanslara dağılımını gösteren bir yöntemdir ve biyolojik sinyallerin işlenmesinde sıkça kullanılır.

Güç Spektral Yoğunluğu

Adından da anlaşılacağı üzere güç spektral yoğunluğu sinyal gücünün frekanslara nasıl dağıldığı ile ilgilidir. GSY bulunurken periyodogram, Welch ve özbağlanım Modeli (AR) yöntemleri sıklıkla kullanılmaktadır. Bu çalışmada güç spektral yoğunluğu kullanılarak beynin belirli görevler esnasında ürettiği sinyal frekansının nasıl değiştiği gözlemlenecektir.


- Periyodogram: Klasik spektral kestirim yöntemi olup HFD ile hesaplanan parametrik olmayan yöntemdir. Periyodogram'ın daha gelişmiş yapısı Welch yöntemi olup Welch'te sinyal çakışan pencereler ile bölümlenerek işlem yapılır. Periyodogram'ın denklemi Denklem 3.39'da verildiği gibidir.

$$P(f) = \frac{T_s}{K.M} \left| \sum_{n=0}^{M-1} x(n)w(n).e^{-j2\pi fn} \right|^2 \quad (3.39)$$

Burada $w(n)$ pencereleme fonksiyonudur ve K normalize sabitidir. T_s ayrik zamanlı sinyalin spektrum genliğini sürekli zamanlı sinyal spektrumuna eşitler.

$$K = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (3.40)$$

- Welch yöntemi: Periyodogramın daha gelişmiş versiyonu olup periyodogram yardımıyla hesaplanmaktadır. Welch yönteminde sinyal kısmen çakışan pencereler ile ele alınır. Daha sonra her bir pencere için periyodogram hesaplaması yapılır. En son işlem olarak da bütün pencere periyodogramlarının ortalaması alınarak Welch güç spektral yoğunluğu hesaplanmış olur. MATLAB programında bu işlem “pwelch” komutu ile yapılır. Ön tanımlı olarak pencereler 50 % çakışacak şekilde ve sinyal 8 eşit pencereye bölünecek şekilde Hamming penceresi ile yapılmaktadır. Pencerelerin 50 % üst üste binmesi gereksiz bilgiye neden olsa da Hamming penceresi gibi (Şekil 3.4'te mevcut) çakışan kısımlarda genliği düşük olan pencereler kullanılarak gereksiz bilgi önlenir. Söz konusu çakışan pencereler Şekil 3.6'da gösterilmiştir.



Şekil 3.6. 50 % çakışan Hanning pencereleri

Bu yöntemde dikdörtgensel pencere kullanılmaması çakışan miktarların ortaya çıkaracağı gereksiz bilgi açısından önemlidir. Welch metodu Denklem 3.41 ve Denklem 3.42 ile hesaplanmaktadır [77].

$$S_{xx}^{(i)}(f) = \frac{T_s}{K.M} \left| \sum_{n=0}^{M-1} x_i(n) w(n) e^{-j2\pi f n} \right|^2 \quad (3.41)$$

Burada $S_{xx}(f)$ i'inci pencerenin periyodogramıdır.

$$P_{Welch}^{(i)}(f) = \frac{1}{L} \sum_{i=0}^{L-1} S_{xx}^{(i)}(f) \quad (3.42)$$

Burada L pencere sayısıdır. Welch metodunda sinyalin tamamının periyodogramını almak yerine küçük küçük parçaların periyodogramlarını alıp ortalamalarını bulmak daha net sonuçlar vermektedir.

- **Özbağlanım Modeli (AR) ile GSY:** Bu yöntem GSY'nin parametrik hesabıdır. GSY sinyaldeki veri noktaları ile değil de sinyalin özbağlanım parametreleri ile hesaplanır. Özbağlanım metodu ile yapılan GSY hesabı frekans çözünürlüğü probleminden etkilenmemektedir. Sinyal düşük bant genişliğine sahip olduğunda diğer yöntemlere nazaran daha iyi sonuçlar vermektedir. Spektral içeriğin kestiriminde özbağlanım metodu daha az döngüye ihtiyaç duyar hatta bir döngü ile bile iyi bir spektral içerik sonucu alınabilir. Fakat özbağlanım metodu gürültülere karşı daha hassastır, bu nedenle sinyalde çok

gürültü varsa periyodogram veya Welch metodu kullanmak daha iyi sonuçlar vermektedir. Özbağlanım parametreleri ile yapılan GSY kestirimi Denklem 3.43 ve Denklem 3.44'te verilmiştir.


$$x[n] = - \sum_{k=1}^p a_k x[n-k] + e[n] \quad (3.43)$$

Denklem 4.43'te derecesi p olan özbağlanım modeli verilmektedir. $e[n]$, beyaz gürültü, a_k özbağlanımlı model katsayılarıdır ve MATLAB'da "arburg" fonksiyonu ile hesaplanır.

$$S(f) = \frac{\sigma^2}{\left| \sum_{k=1}^p \hat{a}(k) \exp(-j2\pi f k) \right|^2} \quad (3.44)$$


MATLAB'da "pburg" fonksiyonu ile özbağlanımlı model parametreleri ile GSY hesabı yapılır.

Aşağıdaki şekillerde (3.7-3.8-3.9-3.10-3.12) bir EEG sinyaline ait yukarıda anlatılan farklı yöntemlerle elde edilmiş GSY çizimleri mevcuttur.




Şekil 3.7. Hızlı fourier dönüşümü ile elde edilmiş GSY

Şekil 3.7'ye bakıldığında HFD ile çizdirilen GSY'nin frekans çözünürlüğünün oldukça düşük olduğu görülmektedir. Fakat HFD ile yapılan GSY ile sinyali oluşturan bileşenlerin hangi frekans aralıklarında güçlü veya zayıf oldukları kabaca anlaşılabilir.




Şekil 3.8. Periodogram yöntemi ile elde edilmiş GSY

Şekil 3.8’de periodogram yöntemi ile elde edilmiş GSY grafiği görülmektedir. Grafik Şekil 3.7’deki HFD yöntemi ile elde edilmiş GSY ile kıyaslandığında frekans çözünürlüğünün arttığı ve spektrum frekanslarının daha belirginleştiği görülmektedir.




Şekil 3.9. Welch yöntemi ile elde edilmiş GSY

Şekil 3.9’da Welch yöntemi ile elde edilmiş GSY çizimi görülmektedir. Görüldüğü üzere frekans çözünürlüğü iyice artmıştır. Bu çizimde standart Welch algoritması kullanılmış olup sinyal otomatik olarak 50 % çakışan 8 eşit hamming penceresine bölünmüştür. Her birinin periyodogramı bulunup daha sonra 8 periyodogramın ortalaması alınarak çizdirilmiştir. Burada kullanılan EEG sinyali örnekleme frekansı 128 Hz olan cihaz ile alınmış 1024 örnekten oluşan 8 saniyelik bir sinyaldir. Pencere genişliği ise sinyal 8 parçaya bölündüğü için 1 saniyedir başka bir deyişle 128 örnekten oluşmaktadır.




Şekil 3.10. Pencere genişliği azaltılarak Welch yöntemi ile elde edilmiş GSY

Şekil 3.10'da pencere genişliği azaltılarak Welch yöntemi ile elde edilmiş GSY'ye bakıldığında frekans çözünürlüğünün daha da arttığı görülmektedir. Burada pencere genişliği keyfi olarak 16 örnek alacak şekilde daraltılmıştır. Görüldüğü üzere pencere genişliğinin seçimi oldukça önemlidir ve dikkat edilmelidir. Güvenilir bilgi verecek kadar büyük, sinyalin durağan olmayan yapısını değerlendirebilecek kadar kısa olmalıdır [78]. Parametrik olmayan Welch metodu ile bulunan bu sonuç Şekil 3.12'deki parametrik yöntem olan özbağlanım parametreleri ile bulunan sonuçla kıyaslanmalıdır. Şekil 3.10'daki pencere genişliğinin azaltılması ile bulunan sonucun Şekil 3.9'daki sonuçtan daha çok Şekil 3.12'ye benzediği görülmektedir. Yani keyfi olarak 16 seçilmiş pencere genişliği 128 olan pencere genişliğine nazaran daha iyi sonuç vermiştir.




Şekil 3.11. Özbağlanım model seviyesini belirlemek için çizdirilmiş Akaike bilgi kriteri

Şekil 3.11’de özbağlanım parametreleri ile GSY çizimi için gerekli olan özbağlanım modelinin derecesini belirlemek için 20. Dereceye kadar çizdirilmiş Akaike bilgi kriteri mevcuttur. Bu kritere göre çizdirilen verinin azalmayı yavaşlattığı veya bitirdiği nokta olarak modelin derecesinin seçilmesi en optimum derece olarak kabul edilmektedir. Bu EEG sinyali için en optimum derece Şekil 3.11’de de görüldüğü üzere 8’dir ve 8 seçilmiştir. Model derecesinin optimum seçilmesi hesaplamaların doğruluğu için oldukça önemlidir. Eğer model derecesi optimumdan düşük seçilirse kurulan Özbağlanım modeli sinyali iyi temsil etmez. Eğer model derecesi optimumdan yüksek seçilirse sinyal içindeki gürültülerinde daha fazla temsil edileceğinden hesaplamalarda olumsuz etki edecektir.




Şekil 3.12. Özbağlanım parametreleri ile elde edilmiş GSY

Şekil 3.12’de Özbağlanım parametreleri ile elde edilmiş GSY görülmektedir. Özbağlanım parametreleriyle çıkarılmış olan GSY’nin yukarıda Şekil (3.7-3.8-3.9-3.10) da çizdirilen GSY’lerden farkı parametrik bir yöntem olmasıdır. Yani elde edilen GSY’nin diğerlerinden farkı doğrudan sinyal içerisindeki noktalardan hesaplanmak yerine sinyalin özbağlanım parametreleri ile hesaplanmasıdır. Görüldüğü üzere özbağlanım parametreleri ile frekans çözünürlüğü diğer yöntemlere nazaran iyice artmıştır. Parametrik olmayan yöntemlerle (HFD, Periodogram, Welch) elde edilen GSY’de performansı artırmak için doğru genişlikte seçilmiş kayan pencerelerin periyodogramlarını birleştirerek hesaplamak gerekmektedir. Parametrik olan özbağlanım (AR) metodunda ise özbağlanım modelinin derecesini doğru belirlemek gerekmektedir. Bu metodun dezavantajı spektrum hattını yumuşattığı için küçük değişimlerin ya da yüksek frekanslı bileşenlerin değişimlerinin görülebilmesi olabilir.



Şekil 3.13. Bütün GSY yöntemleri ile elde edilen sonuçların üst üste çizimi

Şekil 3.13.'de yukarıda ayrı ayrı yorumlanan bütün GSY yöntemlerinin sonuçları daha net yorumlanabilmesi amacıyla üst üste çizdirilmiştir. Burada mavi renkli çizim HFD ile elde edilmiş GSY'yi, sarı renkli çizim periyodogram ile elde edilmiş GSY'yi, kırmızı renkli çizim standart Welch yöntemi ile elde edilmiş GSY'yi, yeşil renkli çizim Welch yönteminin daraltılmış pencere genişliği ile elde edilen GSY'sini siyah renkli çizim ise Özbağlanım parametreleri ile çizdirilmiş GSY'yi göstermektedir. Çizimlere bakıldığında hepsinin paralel sonuçları olduğu görülmektedir. Gelişmiş yöntemlerle yapılan GSY çizimlerinin daha yumuşak bir çizim sergiledikleri görülmektedir. Buradan hareketle acaba en temel yöntem HFD ile elde edilen GSY, Kayan Ortalama Filtresi (KOF) ile filtrelenerek sık değişimler yumuşatılsa nasıl bir GSY çizimi ortaya çıkardı? Sorusu sorulmalıdır.



Şekil 3.14. KOF uygulanmış HFD ile elde edilmiş GSY ve Welch yöntemi ile elde edilmiş GSY

Şekil 3.14'te Kayan Ortalama Filtre uygulanmış Hızlı Fourier Dönüşümü (Siyah) ile elde edilmiş Güç Spektral Yoğunluğu ve Welch yöntemi ile elde edilmiş GSY (Kırmızı) görülmektedir. Kayan Ortalama Filtre sinyal üzerindeki bir noktanın değerinin o değer ile birlikte M sayıda komşu değerlerinin de toplanıp ortalamasının alınmasıyla hesaplanmaktadır. Böylece sinyal üzerindeki bütün noktalar birbirlerine daha yakın hale getirilerek yumuşak bir grafik elde edilmektedir. Denklem 3.45'te KOF'un nasıl uygulandığı mevcuttur.

$$y[i] = \frac{1}{M} \sum_{j=0}^{M-1} x[i + j] \quad (3.45)$$

Burada $x[]$ giriş sinyalini, $y[]$ çıkış sinyalini, M ise kaç adet komşu ile ortalama alınacağını gösterir. Daha iyi anlaşılması için Denklem 3.46. incelenebilir.

$$y[1] = \frac{x[1] + x[2] + x[3] + x[4] + x[5] + x[6] + x[7] + x[8] + x[9]}{9} \quad (3.46)$$

Burada HFD ile elde edilen GSY'yi yumuşatmak için M=9 seçildiği için Denklem 3.46'daki örnekte de M=9 seçilmiştir. Görüldüğü gibi sinyal içindeki bir değer ve keyfi seçilen M adet komşusu ile toplanıp ortalamaları alınarak her bir sinyal değeri tek tek hesaplanarak çizim yumuşatılır. Burada M değeri ne kadar büyük seçilirse çizimin yumuşaklığı o kadar artmaktadır.

Bu bilgilerden sonra Şekil 3.14 tekrar yorumlanacak olursa; KOF uygulanmış HFD GSY'si ile Welch ile hesaplanmış GSY şekilsel olarak birbirine çok yakın denebilir. Tek fark Welch ile hesaplanan GSY de birkaç Hz'lik frekans gecikmesinin olmasıdır. Hatta KOF uygulanmış HFD GSY'sinde güç genlik farkları daha belirgin olduğu için daha kolay yorumlama imkânı sağlayabilir.

Bu bilgilerden sonra GSY ile hesaplanan özellik çıkarma yöntemlerine devam edilirse:

Ortalama Frekans: Ortalama frekans ele alınan sinyali oluşturan birçok sinyalin frekanslarının ortalamasını verir ve sinyal hakkında önemli frekans bilgisini verir.

$$OF = \frac{\sum_{j=1}^M f_j P_j}{\sum_{j=1}^M P_j} \quad (3.47)$$

Burada, f_j j'inci frekansı, P_j j'inci güç spektrumunu, M ise frekans aralığının uzunluğunu gösterir.

Orta Frekans: Orta frekans sinyalin frekans spektrumunun eşit genlikte 2 bölgeye ayrılması ile bulunur. İkiye ayrılan noktadaki frekans değeri orta frekanstır.

$$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j \quad (3.48)$$

Burada, P_j j'inci güç spektrumunu, M ise frekans aralığının uzunluğunu gösterir.

Asimetri Oranı: Asimetri oranı adından da anlaşılacağı üzere simetrinin bozulma oranını ölçmeye yarayan bir özelliktir. Daha önceden de bahsedildiği gibi beynin iki yarım küresi vücudun farklı iki yarısını yönetirken farklı görevler için farklı sinyaller oluşturur. Asimetri oranı yarı küresel farklılıkları ortaya çıkaran bir özelliktir. Örneğin beynin sağ tarafı vücudun sol tarafını, beynin sol tarafı vücudun sağ tarafını yönetir. Bu nedenle sağ kolun hareketi hayal edildiğinde beynin sol tarafından alınan sinyaller daha yüksek güç spektrumuna, sol kolun hareket ettirildiği hayal edildiğinde beynin sağ tarafından alınan sinyaller daha yüksek güç spektrumuna sahiptir. Benzer şekilde matematiksel işlem yaparken beynin sol tarafı sağ tarafına göre daha yüksek güç spektrumuna sahiptir. Bu şekilde beynin simetrik olarak çalışmayıp asimetrik çalışması nedeniyle belli görevler için asimetri oranına (AO) bakılarak özellik çıkarımı yapılır. GSY ile hesaplanan AO formülü Denklem 3.49’da verilmiştir.

$$AO_{GSY} = \left[\frac{P_{sag} - P_{sol}}{P_{sag} + P_{sol}} \right] \quad (3.49)$$

Burada P_{sag} ; sağ yarım küredeki elektrottan alınmış EEG verisinin GSY’sini, P_{sol} ; sol yarım küredeki bir elektrottan alınmış EEG sinyalinin GSY’sidir.


Spektral Benzerlik: Spektral Benzerlik yine GSY ile türetilen bir özellik çıkarma yöntemidir. Spektral uyum sinyal GSY’lerinin korelasyonuna yani benzerliğine bakılarak hesaplanır. Korelasyon formülü Denklem 3.50’de verilmiştir.

$$KOR = \frac{1}{n-1} \sum_{i=1}^n \left(\frac{x_i - \bar{x}}{S_x} \right) \left(\frac{y_i - \bar{y}}{S_y} \right) \quad (3.50)$$

Burada x ve y ayrı iki sinyalin GSY’leridir. S; standart sapma, $\bar{x}$ ve $\bar{y}$ ise GSY’lerin ortalamalarıdır. Sinyallerin benzerliği arttıkça korelasyon 1 değerine yaklaşır.

Dalgacık Dönüşümü: Dalgacık dönüşümü tıpkı fourier dönüşümü gibi bir sinyalin frekans özelliklerinin analizi için kullanılan yöntemdir. Durağan olmayan sinyallerin analizinde fourier dönüşümünden veya HFD’den daha etkilidir. Dalgacık dönüşümü, diğer analiz yöntemlerinin ele alamadığı yönelim, kırılma noktaları ve süreksizlik gibi sinyal özelliklerini ortaya çıkarmada üstündür. Bu anlamda dalgacık dönüşümü bazı

bilim adamlarına göre matematiğin mikroskobudur ve ayarları iyi yapılmış bu mikroskopla sinyallerin detaylı incelenmesi avantajlı bir duruma dönüşmüştür. Bu çalışmada dalgacık dönüşümü (DD) ile EEG sinyalleri alt bantları olan alfa, beta, teta, gama ve delta bantları elde edilecektir. Dalgacık dönüşümü adından da anlaşıldığı üzere küçük sinyal parçacıkları yani dalgacıklar yardımıyla yapılmaktadır. Söz konusu dalgacıklar, belirli başlangıç ve bitiş noktaları olan sınırlı enerjili sinyallerdir. Fourier dönüşümünde kullanılan sınırsız enerjili büyük trigonometrik sinyallerden farklıdır. Trigonometrik sinyaller sonsuz ve düzgün yani periyodik birer sinyal olup dalgacık ise asimetrik, düzensiz ve periyodu olmayan yapıya sahiptir. Şekil 3.15'te çeşitli ana dalgacık sinyalleri gösterilmektedir.



Şekil 3.15. Ana dalgacık sinyalleri

Bir dalgacık, sinyalin rms merkezine yerleştirilebilecek küçük ve sınırlı enerjili sinyal parçacığını ifade eder. Bir dalgacığın ortalaması sıfırdır ve dalgacığın DC kayma gerilimi yoktur. Bir sinyalin dalgacık olabilmesi için aşağıdaki kriterleri sağlaması gereklidir [79].

1. Bir dalgacık sınırlı enerjiye sahip olmalıdır


$$E = \int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (3.51)$$

2. Bir dalgacık Denklem 3.52’de olduğu gibi frekans bileşeni içermemelidir ve Denklem 3.53’de olduğu gibi ortalaması sıfır olmalıdır.

$$\psi(0) = 0 \quad (3.52)$$


$$E = \int_{-\infty}^{\infty} \psi(t)dt = 0 \quad (3.53)$$

Gürültü filtreleme uygulamalarında da DD kullanılabilir. Filtre tasarımında ise Dalgacık band geçiren filtre gibi davranır [80]. KZFD ile GSY hesaplanırken pencereler kullanılmaktadır. Dalgacık dönüşümünde ise pencere görevini Şekil 3.15’teki gibi ana dalgacık sinyalleri üstlenmektedir. KZFD ile kullanılan pencereler sabit genişlikte ve genliktedirler fakat DD’de ana dalgacık fonksiyonlarının genişliği değişebilmektedir. Bu özellik analizin hem zaman hem de frekans domeninde çözünürlüğünü artırmaktadır. Bu yüzden Dalgacık dönüşümü KZFD’den daha üstündür. Ayrıca DD yerel analiz yapabilmektedir yani büyük bir işaretin küçük bir bölgesini analiz edebilmektedir. Örnek olarak Şekil 3.16’da sinüzoidal bir işaretin küçük bir bölgesinde gürültülerin neden olduğu süreksizlik verilebilir [81].




Şekil 3.16. Sinüzoidal sinyalde oluşmuş küçük süreksizlik

Şekil 3.16’daki sinüzoidal sinyalin HFD ve DD yapıldığında, Şekil 3.17’de görüldüğü üzere HFD’de sinyalin frekans bilgisinden başka bilgi bulunmaz ancak DD’de süreksizliğin tam olarak hangi zamanda gerçekleştiği de görülür [82].



Şekil 3.17. Süreksizlik içeren sinüs sinyalinin a) fourier b) dalgacık dönüşümü

Dalgacık analizinde yapılan iş; sinyalin seçilen ana dalgacığın ölçeklenerek ve ötelenerek oluşturdukları sinyallerin toplamı olarak ifade edilmesidir. Fourier dönüşümü de aynı işi yapmaktadır ancak farklı frekanslardaki sinüs sinyallerini kullanarak bu işi yapmaktadır. Şekil 3.18’de öteleme ve ölçekleme işlemleri gösterilmiştir [83].



Şekil 3.18. Ölçekleme ve öteleme işlemleri

Sürekli Dalgacık Dönüşümünün Matematiği: Sürekli Dalgacık Dönüşümünün (SDD) matematiksel ifadesi Denklem 3.54’te verilmiştir [84].

$$D(a, b) = \int_{-\infty}^{\infty} y(t) \psi_{a,b}^*(t) dt = 0 \quad (3.54)$$

Burada $\psi(t)$ ana Dalgacık, a ; ölçekleme parametresi, b ; öteleme parametresini, $D(a, b)$; Dalgacık katsayılarını göstermektedir.

$$\psi_{a,b}^*(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (3.55)$$

Ayrık Dalgacık Dönüşümünün Matematiği: Tıpkı fourier dönüşümünde olduğu gibi sürekli DD'nin çok fazla zaman alması ve büyük veriler gerektirdiğinden uygulamada kullanılması dezavantajlıdır. Bu nedenle ayrık DD geliştirilmiştir. Ayrık Dalgacık Dönüşümünün (ADD) formülü Denklem 3.56'da verilmiştir.

$$ADD(m, k) = \frac{1}{\sqrt{a_0^m}} \sum_k f(k) \psi^*(a_0^{-m}n - b_0k) \quad (3.56)$$

ADD formülü aslında Denklem 3.57'de verilen FIR filtrenin konvolüsyon denklemine benzer.

$$y(n) = \frac{1}{c} \sum_k x(k) h(n - k) \quad (3.57)$$

Böylelikle sinyalin düşük frekanslı bileşenlerden oluşan yaklaşım versiyonu Denklem 3.58'de verildiği gibi hesaplanırken yüksek frekanslı bileşenlerden oluşan detay versiyonu ise Denklem 3.59'da verildiği gibi hesaplanır.

$$a_1(n) = \sum_k h(k - 2n) a_0(k) \quad (3.58)$$


$$d_1(n) = \sum_k g(k - 2n) a_0(k) \quad (3.59)$$

Burada $h(n)$ ve $g(n)$ Dalgacık dönüşümü yapılacak olan a_0 sinyalini $a_1(n)$ yaklaşım versiyonuna ve $d_1(n)$ detay versiyonuna dönüştüren filtre katsayılarıdır. Eğer sinyal bir seviye daha DD'ye tabi tutulmak istenirse $a_1(n)$ işareti temel alınarak Denklem 3.58. ve Denklem 3.59. uygulanır. Yani Denklem 3.60. ve Denklem 3.61. elde edilir.

$$a_2(n) = \sum_k h(k - 2n) a_1(k) \quad (3.60)$$


$$d_2(n) = \sum_k g(k - 2n) a_1(k) \quad (3.61)$$

Eğer DD'ye devam edilecekse benzer şekilde işlemler devam ettirilir. Bu işlem adımları görsel olarak Şekil 3.19'da gösterilmiştir.



Şekil 3.19. Dalgacık dönüşümünde detay ve yaklaşım sinyallerinin oluşumu

Şekil 3.19'da görüldüğü üzere DD ile sinyal, alçak geçiren ve yüksek geçiren filtreler vasıtasıyla alt bantlarına ayrılabilir. Şekil elde var olan sinyale göre çizilmiştir. Çalışmada kullanılacak olan EEG cihazının örnekleme frekansı 128 Hz'dir. Bu alt bantlar yaklaşım ve detay katsayıları ile ifade edilir. Dalgacık dönüşümünde Nyquist frekans kuralı geçerlidir. Yani sinyal örnekleme frekansının yarısı frekansa kadar işlenir. Çünkü 128 Hz ile örneklenmiş bir sinyal aslında 64 Hz'lik bir sinyaldir. Böyle olunca 1. Seviye DD ile sinyal bir alçak geçiren filtre ile 0-32Hz, bir yüksek geçiren filtre ile 32-64Hz aralığına ayrıştırılır. 2. Seviye DD ile sinyal bir alçak geçiren filtre ile 0-16Hz bir yüksek geçiren filtre ile 16-32Hz aralığına ayrıştırılır. 3. Seviye DD ile sinyal bir alçak geçiren filtre ile 0-8Hz bir yüksek geçiren filtre ile 8-16Hz aralığına ayrıştırılır. 4. Seviye DD ile sinyal bir alçak geçiren filtre ile 0-4Hz bir yüksek geçiren filtre ile 4-8Hz aralığına ayrıştırılır. Herhangi bir seviyede görüldüğü üzere iki adet sinyal elde edilir. Bu sinyallerden alçak geçiren filtre çıkışındaki düşük frekanslı olanlar yaklaşım katsayılarıdır (a'lar). Yüksek geçiren filtrenin çıkışındaki yüksek frekanslı olanlar detay katsayılarıdır (d'ler). Normalde alçak geçiren ve yüksek geçiren filtrelerden çıkan sinyaller giren sinyale eşit sayıda örneklerden oluşurlar. Dolayısıyla her bir dalgacık seviyesinde sinyalin örnek sayısı 2 katına çıkar. Ancak DD'de bu istenmeyen durumu engellemek için Şekil 3.20'de görüldüğü gibi aşağı örnekleme veya seyreltme yapılır, yani örnek sayısı yarıya düşürülür.



Şekil 3.20. 3/1 oranında aşağı örnekleme-seyreltme

Burada 4 seviyeli Dalgacık dönüşümü kullanılmasının sebebi EEG sinyallerinden delta, alfa, beta, teta ve gama sinyallerini elde etmektir. Bu sinyaller ve Dalgacık dönüşümündeki karşılıkları Tablo 3.2’de verilmiştir.

Tablo 3.2: EEG sinyalinin alt bantları ve dalgacık dönüşümünde karşılıkları


Band	Frekans Aralığı	Dalgacık Karşılığı	Frekans Aralığı
Delta	0,3-4 Hz	A4	0-4Hz
Theta	4-8 Hz	D4	4-8Hz
Alpha	8-13 Hz	D3	8-16Hz
Beta	13-30 Hz	D2	16-32Hz
Gamma	30-40 Hz	D1	32-64Hz

Tablo 3.2’de görüldüğü üzere EEG sinyalleri DD ile çok isabetli bir şekilde analiz edilebilmektedir. DD seviyesi ise tamamen kullanılan cihazın örnekleme frekansı ile sinyalin elde edilmek istenen alt bantlarına bağlıdır yani sinyalin doğasına bağlıdır.

Yaklaşım ve detay katsayıları birleştirilerek ana sinyal tekrar elde edilir. Yaklaşım ve detay katsayıları kullanılarak ana sinyal Denklem 3.62’deki gibi elde edilir.

$$s = a_4 + d_4 + d_3 + d_2 + d_1 \quad (3.62)$$

Şekil 3.21’de EEG sinyali ve Dalgacık dönüşümü kullanılarak elde edilen alt bantları çizdirilmiştir.



Şekil 3.21. Orijinal EEG ve alt bantları

Şekil 3.21’de EEG sinyalinin alt bantları DD ile elde edilmiştir. EEG sinyalindeki değişimler alt bantlarda gerçekleştiği için alt bantlara ayırma ihtiyacı duyulmaktadır. Genelde özellik çıkarma işlemi bütün EEG sinyalini alıp değerlendirmek yerine ayrı ayrı alt bantların özellikleri çıkarılarak yapılır. Beyinde her olayın belirli bir frekansı vardır ve bu yüzden belirli alt bantlarda oluşurlar. Tablo 3.3’te farklı zihinsel durumlarda oluşan alt bant tipleri sunulmuştur.

Tablo 3.3: EEG Sinyalinin Alt Bandları ve Oluşum durumları

Band	Frekans Aralığı	Mental durumlar
Delta	0,3-4 Hz	Bilinçsizlik, derin uyku
Theta	4-8 Hz	Uyuşukluk, Rüya
Alpha	8-13 Hz	Bilinçli, rahat, öğrenme
Beta	13-30 Hz	Düşünme, odaklanma, dikkatli
Gamma	30-40 Hz	Konsantrasyon,

Boyut İndirgeme: Literatürde sinyal özelliklerini ortaya çıkarmak için onlarca özellik çıkarma yöntemi vardır. Sinyaller sınıflandırılırken bu özelliklerden her zaman bir tanesi kullanılmaz. Sınıflandırmanın ya da analizin doğruluğunu artırmak için birden fazla özellik çıkarma yöntemi kullanılır. Kuşkusuz birçok özelliğin kullanıldığı sınıflandırma işleminde birbirine paralel eğilimler gösteren özelliklerin olduğu gibi

sonuca etkisi hiç olmayan ya da etkisi önemsiz olan özellikler de mevcuttur. Sonuca etkisi olmayan ya da önemsiz etkisi olan özellikler hem gereksiz yer işgal ederek büyük boyutlu verilerle çalışmaya yol açar hem de sınıflandırıcı performansını azaltarak sonucun doğruluğunu etkiler. Bu nedenle gereksiz özelliklerin ayırt edilip kullanılmaması sinyal işlemede oldukça önemlidir. Ayırt edilen gereksiz özelliklerin kullanılmamasıyla veri boyutu azalır ve sınıflandırıcı performansı da artar. Böylece bir yandan da zamandan tasarruf edilir. Bu tezde boyut indirgeme yöntemi olarak “Temel Bileşenler Analizi” (TBA) yapılacaktır. Literatürde bu analiz “Principal Components Analysis” (PCA) olarak geçmektedir.

Temel Bileşenler Analizi: Adından da anlaşıldığı üzere bu analiz sinyale ait olan özelliklerden en temel ya da en önemli olanlarının analiz edilmesini sağlar. Genelde veri tabanları binlerce özellikten ya da değişkenden oluşan milyonlarca veriden oluşur. Bu veri setleri makine öğrenmesinde kullanılmadan önce işlenmelidirler. Çünkü birçok gereksiz değişkenin kullanılması karmaşıklığa yol açar, bu nedenle gereksiz veri diskalifiye edilmelidir. Optimum değişken ya da özellik sayısı belirlenmelidir. Çünkü az özellik sayısı sonucun başarısını azaltacağı gibi çok fazla özellik sayısı da hem zaman hem de performansı olumsuz yönde etkilemektedir. Optimum sayıda seçilmiş özellik sayısı ise makine öğrenmesinin giriş ile çıkış arasında ilişki kurmasına yardımcı olacaktır.

Temel Bileşenler Analizi en genel kullanılan boyut indirgeme yöntemidir. TBA ile orijinal veri setinden çıkarılan daha küçük boyutlu veri seti ile orijinal olana yakın bilgi çıkarımı yapılır.

Temel Bileşenler Analizinin Matematiği: n sayıda katılımcıdan oluşan orijinal veri setinin özellikleri veya değişkenleri $X_1, X_2, \dots, X_m$ olduğu varsayılın, son durumda oluşan veri seti $n \times m$ boyutlu bir matristir. TBA ile orijinal veri maksimum değişkenlik doğrultusu boyunca döndürülerek farklı boyutta yeni bir matris oluşturulur. Boyut indirgeme yapılmadan önce veri setine ortalamaları 0 standart sapmaları 1 olacak şekilde denklem 3.63.’te verildiği gibi standardizasyon yapılmalıdır.

$$Z_i = (X_i - \mu_i) / \sigma_{ii} \quad (3.63)$$

Burada Z_i standardize edilmiş değerleri içeren $n \times 1$ lik matris, μ_i X_i nin ortalaması σ_{ii} X_i nin standart sapmasıdır. Standardizasyonun matris gösterimi Denklem 3.64'te verilmiştir.

$$Z = \left(V^{\frac{1}{2}}\right)^{-1} (X - \mu) \quad (3.64)$$

Burada $V^{\frac{1}{2}}$ $m \times m$ boyutlu diyagonal standart sapma matrisidir. Denklem 3.65'te gösterildiği gibidir. Standardizasyon yapılmasının amacı farklı özelliklerin birbirlerinin etkilerini gölgelememeleridir

$$V^{\frac{1}{2}} = \begin{bmatrix} \sigma_{11} & 0 & \dots & 0 \\ 0 & \sigma_{22} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_{mm} \end{bmatrix} \quad (3.65)$$

Simetrik kovaryans matrisi Denklem 3.66'da verilmiştir.

$$\Sigma = \begin{bmatrix} \sigma_{11}^2 & \sigma_{12}^2 & \dots & \sigma_{1m}^2 \\ \sigma_{12}^2 & \sigma_{22}^2 & \dots & \sigma_{2m}^2 \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{1m}^2 & \sigma_{2m}^2 & \dots & \sigma_{mm}^2 \end{bmatrix} \quad (3.66)$$

Burada σ_{ij}^2 X_i ile X_j arasındaki $i \neq j$ iken kovaryanstır ve Denklem 3.67'de verilmiştir.

$$\sigma_{ij}^2 = \frac{\sum_{k=1}^n (x_{ki} - \mu_i)(x_{kj} - \mu_j)}{n} \quad (3.67)$$

Kovaryans iki değişken arasındaki birlikte değişimi gösterir. Kovaryans pozitif ise bunun anlamı eğer bir değişken artarsa diğeri de artar yani birlikte hareket ederler. Kovaryans negatif ise bunun anlamı eğer bir değişken artarsa diğeri azalır şeklindedir. Kovaryans ölçeklendirilmemiştir bu nedenle ölçümün birimi değişirse kovaryansın değeri de değişir. Korelasyon katsayısı r_{ij} kovaryansı her bir standart sapma cinsinden ölçekleyerek bu sorunun üstesinden gelir [85]. Korelasyon katsayısının hesabı Denklem 3.68'de verilmiştir.

$$r_{ij} = \frac{a_{ij}^2}{a_{ii}a_{jj}} \quad (3.68)$$

Daha sonra özelliklerin ilişkilerini gösteren korelasyon matrisi (ρ) Denklem 3.69’da gösterildiği gibi hesaplanır.

$$\rho = \begin{bmatrix} \frac{\sigma_{11}^2}{a_{11}a_{11}} & \frac{\sigma_{11}^2}{a_{11}a_{22}} & \dots & \frac{\sigma_{1m}^2}{a_{11}a_{mm}} \\ \frac{\sigma_{12}^2}{a_{11}a_{22}} & \frac{\sigma_{22}^2}{a_{22}a_{22}} & \dots & \frac{\sigma_{2m}^2}{a_{22}a_{mm}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\sigma_{1m}^2}{a_{11}a_{mm}} & \frac{\sigma_{2m}^2}{a_{22}a_{mm}} & \dots & \frac{\sigma_{mm}^2}{a_{mm}a_{mm}} \end{bmatrix} \quad (3.69)$$


Bu bilgiler ışığında korelasyon matrisi Tablo 3.4’teki gibi hesaplanmış 8 özelliğten oluşan bir veri seti yorumlanırsa:

Görüldüğü üzere asal köşegenler 1’dir ve aslında aynı iki değişkenin korelasyonunu gösterir. Yani her bir özelliğin kendisi ile ilişkisidir ve o yüzden değeri 1’dir. Ö6 ile Ö4 ise bakıldığında farklı özellikler olmasına rağmen 0.98 benzerliğe sahiptir. Burada en yüksek benzerlik 1 ile ifade edilir. Aynı şekilde Ö6 ile Ö3 ve Ö6 ile Ö5 korelasyonu en yüksek yani ilişkileri en yüksek özelliklerdir. Bunun yanında Ö8 ile Ö7 -0.92 oranıyla birbirine en benzemeyen özelliklerdir işaretin “-” olması ters yönlerde etki ettiklerini göstermektedir.

Tablo 3.4:8 özellikli örnek veri setinin korelasyon matrisi

	Ö1	Ö2	Ö3	Ö4	Ö5	Ö6	Ö7	Ö8
Ö1	1	-0.12	0.19	-0.01	0.001	0.009	-0.08	-0.01
Ö2	-0.12	1	-0.36	-0.31	-0.29	-0.3	0.01	-0.11
Ö3	0.19	-0.36	1	0.92	0.85	0.91	-0.04	0.04
Ö4	-0.01	-0.31	0.92	1	0.87	0.98	-0.07	0.07
Ö5	0.001	-0.29	0.85	0.87	1	0.9	-0.11	0.1
Ö6	0.009	-0.3	0.91	0.98	0.9	1	-0.07	0.06
Ö7	-0.08	0.01	-0.04	-0.07	-0.11	-0.07	1	-0.92
Ö8	-0.01	-0.11	0.04	0.07	0.1	0.06	-0.92	1

Bu korelasyon matrisinin matris çizimi yapılıncı özellikler arasındaki ilişki daha kolay yorumlanabilmektedir. Şekil 3.22’de, Tablo 3.4.’teki korelasyon matrisinin matris çizimi bulunmaktadır.



Şekil 3.22. Tablo 3.4.'teki korelasyon matrisinin çizimi


Şekil 3.22'de görsel olarak hangi özelliklerin birbiri ile benzediği konusunda bilgi edinilebilir. Görüldüğü üzere birbirlerine en çok benzeyen Ö6 ile Ö4 arasında mükemmel bir benzerlik varken Ö7 ile Ö8 in en benzemeyen özellikler olduğu çizimde de görülmektedir.

Bu anlatımlardan sonra akla ilk gelen soru bu 8 özellikten hangilerinin temel bileşenler olduğu hangilerinin ise gereksiz ve atılması gerektiğidir. Daha önce de bahsedildiği gibi optimum özellik sayısı belirlenmelidir ve önemlidir. Bunun için belirli yöntemler vardır. Bir tanesi özdeğerlere bakmak diğeri ise yamaç-birikinti çizimi yapmaktır (scree plot). Tablo 3.5'te 8 özelliğin öz değerleri verilmiştir.

Tablo 3.5: 8 özelliğin özdeğerleri

Özellikler	Özdeğerler	% Varyans	Toplam Varyans
Ö1	3.9053	48.8166	48.8166
Ö2	1.9039	23.7992	72.6158
Ö3	1.0746	13.4323	86.0481
Ö4	0.8212	10.2655	96.3136
Ö5	0.1509	1.8857	98.1993
Ö6	0.0825	1.0313	99.2306
Ö7	0.0475	0.5937	99.8243
Ö8	0.0140	0.1756	100

Tablo 3.5’te görüldüğü üzere özdeğerler büyükten küçüğe sıralanır. Daha sonra o özelliğin etkisi, özelliğin özdeğerinin özellik sayısına bölümüyle hesaplanır. Örnek olarak 1. özelliğin etkisi hesaplanırsa $3.9053/8=0.488166$ yani ilk özellik veri setindeki bilginin 48.8166 % ’sını içermektedir. Yani neredeyse veri setinin içerdiği bilginin yarısı 1. özellikte diğer yarısı da geri kalan 7 özellikte mevcuttur. Kaç adet özelliğin alınıp kaç adet özelliğin atılması gerektiği değerlendiriciye bağlıdır. Örneğin bilginin 99 % ’unu isteyen biri için Ö8 ve Ö7 atılabilir hatta Ö6 bile atılabilir ya da bilginin 95 %’i yeterli olan bir uygulama için ilk 4 veri alınıp diğer 4 veri alınmayabilir. Bunun standardı yamaç-birikinti çizimi yapılarak standartlaştırılır. Şekil 3.23’te yamaç-birikinti çizimi yapılmıştır.



Şekil 3.23. Yamaç-birikinti çizimi

Yamaç – birikinti çiziminde özdeğerler özellik sayısına göre büyükten küçüğe çizdirilirler. Çizime bakıldığında çizimin yatay hale gelmeye başladığı özelliğe kadar olan özellikler gerekli diğerleri gereksizdir. Şekil 3.23’te görüldüğü üzere ilk 5 özellik gerekli geri kalan 3 özellik ise gereksizdir. Böylelikle 8 özellikten 3’ü atılmış orijinal veriyi 98.1993 % oranında temsil eden 5 özellikle işlemlere devam edilmiştir. Böylelikle veri 37.5 % oranında azaltılmıştır.


4. SINIFLANDIRMA

Sınıflandırma işlemi, önceden var olan birkaç farklı sınıfta örneklerin kullanılarak yeni alınacak olan örneklerin bu farklı sınıflardan hangisine ait olduğunu kestirme yöntemidir. Bu sınıflandırma işlemi eski ve yeni verilerin gürültülerden arındırılıp özelliklerinin çıkarılmasıyla yapılmaktadır. Sınıflandırma işlemi için çeşitli sınıflandırma algoritmaları kullanılır. Bu tez çalışmasında kullanılan sınıflandırma algoritmaları şunlardır;

- K-En Yakın Komşu
- Lineer Diskriminant Analizi
- Kuadratik Diskriminant Analizi
- Yapay Sinir Ağları
- Naive Bayes Sınıflandırıcısı
- Destek Vektör Makineleri

4.1. K-En Yakın Komşu

K-en yakın komşu (KNN) algoritması sınıflandırma işlemlerinde kullanılan en basit ve en kullanışlı sınıflandırıcılardan birisidir. Algoritması basit ve etkilidir. K-en yakın komşu algoritmasında test örneğinin diğer gruplardaki “k” sayıda örneklerle olan uzaklığı hesaplanır. Bu “k” sayıda örneğe olan uzaklıkların hesaplanarak en kısa uzaklığa göre sınıflandırma yapılmasından dolayı algoritmanın ismi K-en yakın komşu algoritmasıdır. Hesaplanan uzaklıklardan en kısa olanı hangisi ise örneğin o sınıfa ait olduğu varsayılır. Şekil 4.1’de seçilen örneğe ait komşu örneklerin mesafeleri gösterilmiştir.



Şekil 4.1. K-en yakın komşu mesafeleri

Burada mesafe hesabında kullanılan çeşitli mesafe algoritmaları mevcut olup bunlar;

- Öklid Mesafesi: Öklid mesafesi en yaygın kullanılan mesafedir. Öklid mesafesi iki nokta arasındaki düz çizginin uzunluğudur. Öklid mesafesini kullanmanın avantajı veri setine yeni örneklerin dâhil edilmesiyle eski örneklerin birbirlerine olan mesafelerinin değişmemesidir. Öklid mesafesi hesabı Denklem 4.1’de verilmiştir.

$$m_o(p, q) = \sqrt{\sum_{i=1}^R (p_i - q_i)^2} \quad (4.1)$$

Burada R özellik sayısıdır.

- Manhattan Mesafesi (City Block) : x-y düzleminde iki nokta arasındaki en kısa mesafe hipotenüs yani Öklid mesafesidir. Manhattan mesafesi ise x mesafesi ve y mesafesinin toplamıdır. Manhattan mesafesi, bir şehirde gezinirken karşıda beliren bir binanın bir köşesinden diğer köşesine giderken, doğrudan hipotenüsü ya da evin köşegeninden gitmek yerine x ve y duvarlarını yürüyerek gitmeye benzemektedir [86]. Manhattan Mesafesi hesabı denklem 4.2.’de verilmiştir.

$$m_m(p, q) = \sum_{i=1}^R |p_i - q_i| \quad (4.2)$$

- Kosinüs Mesafesi: İki örnek arasındaki açının kosinüsüdür. Denklem 4.3’te verilmiştir [87].


$$k_m(p, q) = \frac{\sum_{i=1}^R p_i q_i}{\sqrt{\sum_{i=1}^R p_i^2 \sum_{i=1}^R q_i^2}} \quad (4.3)$$

- Korelasyon Mesafesi: Korelasyon mesafesi iki rasgele örnek ya da iki vektör arasındaki istatistiksel mesafenin ölçümüdür [88]. Denklem 4.4’te verilmiştir.

$$m = 1 - \frac{(x_s - \bar{x}_s)(y_t - \bar{y}_t)'}{\sqrt{(x_s \bar{x}_s)(x_s \bar{x}_s)'} \sqrt{(y_t \bar{y}_t)(y_t \bar{y}_t)'}} \quad (4.4)$$

Burada $\bar{x}_s = \frac{1}{n} \sum_j x_{sj}$ ve $\bar{y}_t = \frac{1}{n} \sum_j y_{tj}$ dir.

En yakın komşu algoritması düşük boyutlu verilerde iyi sonuçlar verirken yüksek boyutlu verilerde performansı düşmektedir. K-en yakın komşu sınıflandırıcısı test sınıfının hangisi olduğuna karar vermek için, k sayıda yakın komşuların uzaklıklarını ölçerek ve çoğunluk kuralını uygulayarak sınıflandırma yapmaktadır. K için genellikle küçük ve tek sayı olan bir değer seçilir. Büyük k değeri eğitim setindeki gürültülü örneklerin etkisini azaltmaya yardımcı olurken hesaplama zorluğunu da artırmaktadır. K değerinin seçimi ile ilgili örnek gösterim Şekil 4.2’de mevcuttur.



Şekil 4.2. K parametresinin seçimi

Şekil 4.2 incelendiğinde k=1 seçildiğinde test örneği B sınıfında hesaplanırken k=3 seçildiğinde yine B sınıfında ancak k=5 seçildiğinde test örneği A sınıfına girmektedir. Görüldüğü üzere K-en yakın komşu algoritmasında k'nın seçimi önem arz etmektedir. Burada k'nın seçimi toplam örnek sayısına bağlıdır ve deneme yanılma ile bulunacağı gibi kural olarak örnek sayısının karekökü kadar bir değerde tek sayı olacak şekilde seçilmelidir. Yani buradaki örnek için k hesaplanırsa; toplam örnek sayısı 8'dir, 8'in kare kökü $\sqrt{8} \cong 3$ yani k=3 seçilmelidir. KNN algoritmasındaki adımlar özetlenirse:

1. K parametresi yani kaç komşuya yakınlığın kullanılacağı belirlenmelidir.
2. Test örneği ve bütün eğitim örnekleri arasındaki mesafe hesaplanır.
3. K sayıdaki en yakın komşular belirlenir.
4. En yakın komşuların sınıfı alınır.
5. Test örneğinin hangi sınıfa ait olduğu ise çoğunluğun olduğu sınıf olarak bulunur.

KNN algoritmasının avantajları

- K doğru seçilmişse aykırı değerlere karşı oldukça güçlüdür.
- Karar sınırları doğrusal olmayabileceğinden dolayı genellikle iyi bir sınıflandırma performansı sergiler.
- Algoritmanın anlaşılması ve uygulanışı oldukça kolaydır.

KNN algoritmasının dezavantajları

- Parametre hesabı vardır. K parametresinin bulunuşu genellikle deneme yanılma ile olur.
- Alakasız girişlere karşı güçlü değildir.
- Matematiksel hesaplamalar biraz fazladır çünkü her bir test örneği ile her bir eğitim örneklerinin mesafeleri hesaplanır

MATLAB'ın dâhili K-en yakın komşu algoritmasında hem en yakın komşulara bakılarak hem de rasgele komşulara bakılarak da sınıflandırma yapılabilir.

4.2. Diskriminant Analizi

4.2.1. Lineer Diskriminant Analizi

Linear Diskriminant Analizi (LDA) sınıfların Gauss dağılımına sahip olduğunu varsayarak sınıflandırma yapar. Bir sınıflandırıcı inşa etmek için her bir sınıf için Gauss dağılımının parametreleri hesaplanır. LDA'da sınıflar adından da anlaşılacağı üzere doğrusal ya da lineer bir çizgi ile ayrılırlar. LDA'nın terslenebilir kovaryans matrisli Gauss modelini veriye uydurması için yeterli veriye sahip olması gereklidir.

LDA bütün sınıflara ait kovaryans matrislerinin eşit olduğunu varsayar. LDA'nın sınıflandırma fonksiyonu Denklem 4.5'te verilmiştir.

$$f_i = \mu_i C^{-1} X_k^T - \frac{1}{2} \mu_i C^{-1} \mu_i^T + \ln(p_i) \quad (4.5)$$

Bu denklemde soldan sağa doğru olan terimler tek tek açıklanacak olursa. μ_i matrisi i nolu eğitim grubunun ortalamasıdır. C matrisi birleştirilmiş kovaryans matrisidir. Birleştirilmiş kovaryans matrisinin oluşumuna Denklem 4.6'da verilmiştir.

$$c_i = \frac{(x_i^o)^T x_i^o}{n_i} \quad (4.6)$$

c_i matrisi i nolu eğitim grubunun kovaryans matrisidir. x_i^o matrisi ise ortalaması düzeltilmiş veri matrisidir yani i nolu eğitim grubu özelliklerinden x_i global ortalama vektörünün μ (bütün sınıfın ortalaması) çıkarılmış halidir.

$$C(r, s) = \frac{1}{n} \sum_{i=1}^g n_i \cdot c_i(r, s) \quad (4.7)$$

Burada g grup sayısıdır.

X_k^T matrisi test grubu matrisinin transpozesidir. p_i terimi de olasılık önceliği vektörüdür, Denklem 4.8'de verilmiştir.

$$p_i = \frac{n_i}{N} \quad (4.8)$$

Burada n_i i nolu eğitim grubundaki örnek sayısı N ise bütün sınıfların örneklerinin toplam sayısıdır [89].

Anlatılanlar örnek sınıflandırma ile netleştirilir. 2'şer özellikli 1 ve 2 diye sınıflandırılmak üzere Denklem 4.9'daki gibi veri setinin olduğu varsayılır.

$$x = \begin{bmatrix} 2.95 & 6.63 \\ 2.53 & 7.79 \\ 3.57 & 5.65 \\ 3.16 & 5.47 \\ 2.58 & 4.46 \\ 2.16 & 6.22 \\ 3.27 & 3.52 \end{bmatrix} \quad ve \quad y = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \\ 2 \\ 2 \\ 2 \end{bmatrix} \quad (4.9)$$

Burada x matrisinde sütunlar özellikleri göstermekte satırlar ise örnekleri göstermekte olup y matrisi ise grup matrisidir. Öncelikle her iki gurubu Denklem 4.10'daki gibi ayrılır;

$$x_1 = \begin{bmatrix} 2.95 & 6.63 \\ 2.53 & 7.79 \\ 3.57 & 5.65 \\ 3.16 & 5.47 \end{bmatrix} \text{ ve } x_2 = \begin{bmatrix} 2.58 & 4.46 \\ 2.16 & 6.22 \\ 3.27 & 3.52 \end{bmatrix} \quad (4.10)$$

Her iki grubun (x_1 ve x_2) ortalamaları (μ_1 ve μ_2) Denklem 4.11.'deki gibi hesaplanır;

$$\mu_1 = [3.05 \quad 6.38] \quad \text{ve} \quad \mu_2 = [2.67 \quad 4.73] \quad (4.11)$$

Global ortalama vektörü yani bütün sınıfların ortalamaları Denklem 4.12.'de hesaplandığı gibidir.

$$\mu = [2.88 \quad 5.676] \quad (4.12)$$

x_i^o matrisi diğer bir deyişle ortalaması düzeltilmiş veri matrisi hesaplanırsa yani i nolu eğitim grubu özelliklerinden x_i global ortalama vektörünün μ (bütün sınıfın ortalaması) çıkarıldığı zaman eşitlik 4.13.'teki değerler elde edilir.

$$x_1^o = \begin{bmatrix} 0.060 & 0.951 \\ -0.357 & 2.109 \\ 0.679 & -0.025 \\ 0.269 & -0.209 \end{bmatrix} \text{ ve } x_2^o = \begin{bmatrix} -0.305 & -1.218 \\ -0.732 & 0.547 \\ 0.386 & -2.155 \end{bmatrix} \quad (4.13)$$

Böylelikle sıra kovaryans matrislerinin hesaplanmasına gelir ve kovaryans matrisleri Denklem 4.14.'teki gibi hesaplanır;

$$c_1 = \begin{bmatrix} 0.166 & -0.192 \\ -0.192 & 1.349 \end{bmatrix} \quad c_2 = \begin{bmatrix} 0.259 & -0.286 \\ -0.286 & 2.142 \end{bmatrix} \quad (4.14)$$

Birleştirilmiş kovaryans matrisi de Denklem 4.15.'te verildiği gibi hesaplanır.

$$\begin{aligned} \frac{4}{7} * 0.166 + \frac{3}{7} * 0.259 &= 0.206, \\ \frac{4}{7} * -0.192 + \frac{3}{7} * -0.286 &= -0.233 \text{ ve } \frac{4}{7} * 1.349 + \frac{3}{7} * 2.142 = 1.689 \end{aligned} \quad (4.15)$$

Toparlanınca;

$$C = \begin{bmatrix} 0.206 & -0.233 \\ -0.233 & 1.689 \end{bmatrix} \quad C^{-1} = \begin{bmatrix} 5.745 & 0.791 \\ 0.791 & 0.701 \end{bmatrix} \quad (4.16)$$

Son olarak olasılık öncelik fonksiyonu da Denklem 4.17'deki gibi hesaplanırsa sınıflandırmaya hazır bir lineer diskriminant fonksiyonu meydana gelecektir.

$$P = \begin{bmatrix} 0.571 \\ 0.429 \end{bmatrix} = \begin{bmatrix} 4/7 \\ 3/7 \end{bmatrix} \quad (4.17)$$

Bulunan değerler diskriminant fonksiyonunda yerine konulduğunda ve k test örneği maksimum f_i değerine sahip i nolu gruba atıldığında lineer diskriminant analizi ile sınıflandırma yapılmış olunur.


4.2.2. İkinci Dereceden (Kuadratik) Diskriminant Analizi

İkinci Dereceden Diskriminant Analizinde hem her bir sınıfa ait ortalamalar hem de her bir sınıfın kovaryansı değişiklik göstermektedir. İkinci dereceden Diskriminant Analizinde sınıflar elips, hiperbol veya parabollerle birbirinden ayrılırlar. Kuadratik Diskriminant Analizi (KDA)'nin formülü Denklem 4.18'de verilmiştir.

$$g_i(x) = -\frac{1}{2}(x - \mu_i)^T \Sigma_i^{-1}(x - \mu_i) - \frac{1}{2} \log(|\Sigma_i|) + \log(P(\omega_i)) \quad (4.18)$$

Burada μ_i ortalama vektörü, Σ_i kovaryans matrisi ve $P(\omega_i)$ her bir sınıfın olasılığının göstergesidir [90]. Sınıflandırma en büyük $g_i(x)$ 'in elde edildiği sınıfa yapılır.

KDA ve LDA'nın karar sınırları Şekil 4.3'te verilmiştir [91].




Şekil 4.3. KDA ve LDA karar sınırları

Şekil 4.3 incelendiğinde birbirine karışık sınıfların ayrımında KDA'nın daha iyi sonuçlar verebileceği görülmektedir.

4.3. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA)'da bahsedilen K-en yakın komşu ve LDA sınıflandırma yöntemleri gibi en çok kullanılan sınıflandırma algoritmalarından birisidir. Giriş büyüklükleri Şekil 4.4'te görüldüğü gibi ardışık katmanlar vasıtasıyla işlenir.



Şekil 4.4. Yapay sinir ağlarının blok diyagramı

İlk gizli katman nöronlarının çıkışları Denklem 4.19'da verilmiştir.

$$X^{ih1}(n) = \frac{1}{(1 + \exp(W^{ih1}(n) * \vec{f}(n) + \vec{b}^{ih1}(n)))} \quad (4.19)$$

İkinci gizli katman nöronlarının çıkışları Denklem 4.20'de verilmiştir.

$$X^{ih2}(n) = 1 / (1 + \exp(W^{ih2}(n) * \vec{X}^{ih1}(n) + \vec{b}^{ih2}(n))) \quad (4.20)$$

Ağın çıkışları denklem 4.21'deki gibidir.


$$\vec{Y}(n) = 1 / (1 + \exp(W^{ho}(n) * \vec{X}^{ih2}(n) + \vec{b}^{ho}(n))) \quad (4.21)$$

Burada $W^{ih1}(n)$ 'ler giriş özelliklerinin ilk gizli katmana olan ağırlıklarıdır. $\vec{b}^{ih1}(n)$ 'ler birinci gizli katmanın eğilimleridir. $W^{ih2}(n)$ 'ler ilk gizli katmandan ikinci gizli katmana olan ağırlıklardır. $\vec{b}^{ih2}(n)$ 'ler ikinci gizli katmanın eğilimleridir. $W^{ho}(n)$ 'ler ikinci gizli katmandan çıkışa olan ağırlıklardır ve $\vec{b}^{ho}$ 'ler çıkış katmanının eğilimleridir. $\vec{f}(n)$ 'ler özelliklerin değerleridir ve $\vec{Y}(n)$ 'ler sınıf indeksinde çıkış değerleridir. n ise eğitim örneğinin indeksidir [92].

YSA'nın matematiksel bilgisi verildikten sonra iş akışına bakılacak olunursa iş akışı aşağıdaki gibi olmaktadır.

1. Ağ oluşturulur: Ağ oluşturmak için giriş ve çıkış sayıları uygulanacak veriye göre seçilir, gizli katmanlar belirlenir, transfer fonksiyonları belirlenir, eğitim algoritmaları belirlenir.

YSA'da kullanılan en temel transfer fonksiyonları, "logaritmik sigmoid", "tanjant sigmoid" ve "lineer" fonksiyonlarıdır. Transfer fonksiyonları Şekil 4.5'te çizdirilmiştir.



Şekil 4.5. YSA transfer fonksiyonları

Transfer fonksiyonlarının matematiksel ifadeleri tanjant sigmoid için Denklem 4.22, logaritmik sigmoid için Denklem 4.23. ve lineer için Denklem 4.24.'te verilmiştir.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (4.22)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.23)$$

$$f(x) = x \quad (4.24)$$

YSA' ya verilecek olan veriler önce normalize edilmelidir.

2. Ağ Eğitilir: Ağı eğitimi, perseptronun öğrenmesidir. Perseptron öğrenmesinde en küçük ortalama karesel hata algoritması kullanılır.

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\} \quad (4.25)$$

Burada p_q ağı girişidir ve t_q ağı hedef çıkışıdır. Her bir giriş ağı uygulandığında, ağ çıkışı hedef ile kıyaslanır. Hata, ağ çıkışı ile hedef çıkış arasındaki fark olarak hesaplanır. Amaç bu hataların toplamının ortalamasını azaltmaktır. Ortalama karesel hata Denklem 4.26.'da verilmiştir.

$$OKH = \frac{1}{Q} \sum_{k=1}^Q e(k)^2 = \frac{1}{Q} \sum_{k=1}^Q (t(k) - a(k))^2 \quad (4.26)$$

En küçük ortalama kareler algoritması ortalama karesel hatayı azaltmak için ağırlıkları ve eğilimleri ayarlar.

3. Ağı kullanımı: Ağ eğitildikten ve sağlama yapıldıktan sonra herhangi bir girişe karşın çıkış hesaplanır.

Bir giriş katmanı normalde giriş özellikleri sayısı kadar nörona sahiptir ve aynı şekilde çıkış katmanı da sınıflandırma yapılacak sınıf sayısı kadar nörona sahip olmalıdır. Gizli katmanda ise nöron sayısı herhangi sayıda olabilir ve normalde deneme yanılma yöntemi ile doğru sayı bulunmaya çalışılır.

Eğitim, verilen girişlere karşılık istenen çıkışları elde etmek için yapılır ve bu denetlenen öğrenmedir. Eğitim, eğitim düşümü algoritmasını ve bu popüler eğitim metotlarından biri olan geri yayımlı algoritmayı kullanarak giriş ağırlıklarını değiştirerek çıkış hatasını minimize eder. Geri yayımlı algoritmanın eğitim hızını artırmak için ve doğruluğu artırmak için birçok varyasyonu mevcuttur. Yapay sinir ağları eğer yeterli sayıda katman ve nörona sahiplerse karmaşık birçok sınıflandırma probleminin üstesinden gelebilirler.

Yapay sinir ağları her eğitildiklerinde farklı doğrulukta sonuçlar verirler. Bunun sebebi her eğitimde ağırlık ve eğilim değerlerinin farklı seçilmesi ile verinin eğitim, test ve sağlama için farklı bölünmesidir. Sonuç olarak aynı problem üzerine oluşturulmuş farklı yapay sinir ağları aynı girişe karşın farklı sonuçlar verirler. Yüksek doğrulukta bir YSA elde etmek için ağ birçok kez eğitilmelidir.

4.4. Naive Bayes Sınıflandırıcı

Naive Bayes sınıflandırıcısı, özellikler her sınıfta birbirinden bağımsız olduğu zaman kullanılmak üzere tasarlanmıştır. Ancak bağımsızlık varsayımı geçerli olmadığında bile pratikte iyi çalıştığı görülmektedir. Naive Bayes Sınıflandırıcısı veriyi 2 adımda sınıflandırmaktadır.

1. Eğitim: Eğitim örnekleri kullanılarak, özelliklerin bağımsız olduğu varsayılarak olasılık dağılımının parametreleri tahmin edilir.
2. Test: Herhangi bir test örneği için, yöntem her sınıfa ait o örneğin sonsal olasılığını hesaplar

Naive Bayes Sınıflandırıcısı Denklem 4.27 ve Denklem 4.28'deki Bayes kuralına dayalı basit olasılıksal sınıflandırıcıdır.

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (4.27)$$

$$P(c|X) = P(x_1|c) \times P(x_2|c) \times \dots \times P(x_n|c) \times P(c) \quad (4.28)$$


Naive Bayes algoritmasının bir avantajı sınıflandırma işlemi için gerekli parametreleri hesaplamak için sadece değişkenlerin ortalama ve standart sapmalarını

kullanmasıdır [93]. Naive Bayes sınıflandırıcısının karar kuralı Denklem 4.29’da verilen olasılık yoğunluk fonksiyonuna göre daha olası olanın seçimine dayalıdır.

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (4.29)$$

4.5. Destek Vektör Makineleri

Destek vektör makineleri (DVM) Vladimir Vapnik tarafından geliştirilmiş ve 1995 yılında sınıflandırma probleminde kullanılmaya başlanmıştır. DVM Şekil 4.6’da görüldüğü gibi iki sınıfı ayırt eden en iyi ayırıcı düzlemi veya en ortadaki ayırıcı düzlemi bulmaya çalışır [94].



Şekil 4.6. Farklı ayırıcı düzlemler

Şekil 4.6 incelendiğinde H_3 düzlemi sınıfları iyi ayırt edememekte, H_1 düzlemi sınıfları ayırt etse de H_3 düzlemi bu sınıflandırma örneği için en iyi ayırt edici düzlemdir.

Doğrusal Ayrılabilir Veriler

İki ayrı verinin sınıflandırılacağı düşünülürse iki ayrı veri ve ait olduğu sınıflar Denklem 4.30’daki gibi olsun.

$$(x_1, y_1), (x_2, y_2) \dots \dots (x_n, y_n) \quad (4.30)$$

Burada $\{x_1, \dots, x_n\}$ kümesi veriler ve $y_i \in \{-1, +1\}$ olmak üzere sınıfları ifade etmektedir. Burada amaç iki veriyi en doğru şekilde ayıracak Denklem 4.31'deki gibi bir karar sınırını bulmaktır.

$$g(x) = \text{işaret}(f(x)) \quad (4.31)$$

Burada $f(x)$, Denklem 4.32'de verildiği gibidir.

$$f(x) = (w \cdot x) + b \quad (4.32)$$

(w, b) parametreleri ile tanımlanan karar sınırı Denklem 4.33 ve Denklem 4.34'te gösterildiği gibi formülize edilir.


$$w^T x_i + b \geq 1 \text{ eğer } y_i = 1 \quad (4.33)$$

$$w^T x_i + b \leq -1 \text{ eğer } y_i = -1 \quad (4.34)$$

Veya;

$$\text{işaret}((w \cdot x_i) + b) = y_i \quad i = 1 \dots n \quad (4.35)$$

Şekil 4.7'ye göre optimum karar sınırı payının $m = \frac{2}{\|w\|}$ olduğu görülmektedir [95].



Şekil 4.7. Destek vektörleri

Şekil 4.7'ye göre sınıf 1'e teğet olan karar düzleminin orjine dik uzaklığı $1 - |b|/\|w\|$ ve sınıf 2 ye teğet olan karar düzleminin orjine olan uzaklığı $|-1 - |b|/\|w\||$ 'dir. Bu iki karar düzleminin en uygun karar düzlemine uzaklıkları ise $1/\|w\|$ kadardır. Başka bir deyişle

iki paralel uç karar sınırının birbirine olan uzaklıkları $2/\|w\|$ kadardır. Buna göre iki karar sınırı arasındaki maksimum mesafe $\|w\|$ değerinin minimize edilmesi ile bulunabilir [96]. DVM'nin amacı bu iki vektör arasındaki mesafeyi maksimum yapmaktır. Bu karar düzlemleri arasındaki maksimum sınır Denklem 4.36. ile elde edilir.

$$\frac{1}{2} \|w\|^2 \quad (4.36)$$

Problemin çözümü için gerek çarpanlarının hesaplanmasının kolaylığı gerekse de doğrusal olmayan sınıflandırma durumuna daha kolay uyarlanabilmesi bakımından Denklem 4.37'deki gibi Lagrange formülasyonu uygulanır.

$$L_p = \frac{1}{2} \|w\|^2 - \sum_{i=1}^N a_i y_i (w^T x_i + b) + \sum_{i=1}^N a_i \quad (4.37)$$

Ancak karmaşık olan Denklem 4.37 Karush-Kuhn_Tucker (KKT) dönüşümü kullanılarak basitleştirilir.

$$\frac{\partial L_p}{\partial w} = 0 \rightarrow w = \sum_i a_i x_i y_i \quad (4.38)$$

$$\frac{\partial L_p}{\partial b} = 0 \rightarrow w = \sum_i x_i y_i = 0 \quad (4.39)$$

Şeklinde olup Denklem 4.37'de yerlerine yazılırsa;

$$\begin{aligned} L_p &= \frac{1}{2} (w^T w) - w^T \sum_i a_i x_i y_i - b \sum_i a_i y_i + \sum_i a_i \\ &= -\frac{1}{2} (w^T w) + \sum_i a_i = \sum_i a_i - \frac{1}{2} \sum_{ij} a_i a_j y_i y_j x_i^T x_j \end{aligned} \quad (4.40)$$

Şeklinde problemin çözümü elde edilir.

Doğrusal Ayrılamayan Veriler

Eğer veriler doğrusal olarak ayrılamıyorsa problemin çözümü için yapay değişkenler $\zeta_i = 1, 2, \dots, N$ kullanılır. Yeni koşullar Denklem 4.41. ve Denklem 4.42’de olduğu gibidir.

$$w^T x_i + b \geq 1 - \zeta_i \quad \text{eğer } y_i = 1 \quad (4.41)$$

$$w^T x_i + b \leq -1 + \zeta_i \quad \text{eğer } y_i = -1 \quad (4.42)$$

Lagrange formülasyonu Denklem 4.43’teki gibi düzenlenir;

$$L_p = \frac{1}{2} \|w\|^2 + C \sum_i \zeta_i - \sum_i a_i \{y_i(w^T x_i + b) - 1 + \zeta_i\} - \sum_i \mu_i a_i \quad (4.43)$$

Burada C düzenleme parametresidir ve DVM eğitim aşamasında belirlir, μ_i yapay değişkenlerin pozitif değerde kalmasını sağlayan Lagrange parametresidir. Yine bu Lagrange’nin çözümü için KKT uygulanırsa;

$$\frac{\partial L_p}{\partial w} = w - \sum_i a_i x_i y_i = 0 \quad (4.44)$$

$$\frac{\partial L_p}{\partial b} = - \sum_i a_i y_i = 0 \quad (4.45)$$

$$\frac{\partial L_p}{\partial \zeta_i} = C - a_i - \mu_i = 0 \quad (4.46)$$

Eşitlikleri Denklem 4.43’te yerlerine yazılırsa;


$$L_p = \sum_i a_i - \frac{1}{2} \sum_{ij} a_i a_j y_i y_j x_i^T x_j \quad (4.47)$$

Şeklinde problemin çözümü elde edilir.

5. UYGULAMA ARAÇLARI VE UYGULAMA ADIMLARI

5.1. Dört Rotorlu İnsansız Hava Aracı

Günümüzde birçok yorucu ve zahmetli işlerde insanlar yerine robotlar görev almaktadır. Dört rotorlu insansız hava araçları da bu tip işlerde kullanılan robotlardan biridir. Dört rotorlu insansız hava araçları dişey ve yatay uęabilme askıda kalabilme dişük hızda uęabilme ve manevra kabiliyetlerinin helikopter ve uęaklara göre daha iyi olması sebebiyle kullanım alanı gün geętikęe geniřlemektedir. Bu kullanım alanlarından bazıları řöyle sıralanabilir, çekim yapma, havadan görüntü alma, reklamcılık, organizasyon, askeri uygulamalar, tarım, hayvancılık, iletim hatları denetimi, sınır devriyeleri, yangın önleme gibi birçok alanda daha kullanılmaktadırlar. Dört rotorlu İHA 4 eřit pervane ile rotora sahip olup uęuşunu ve her türlü manevralarını tamamen 4 adet pervanenin dönüř hızlarını deęiřtirerek yapmaktadır. řekil 5.1’de Dört rotorlu İHA’nın manevraları ve pervanelerin dönüř yönleri gösterilmiřtir.



řekil 5.1. İHA’nın dönme açıları yuvarlanma, yunuslama ve yönelme

řekil 5.1’den faydalanılarak dört rotorlu İHA’nın uęma prensibi anlatılacak olunursa; öncelikle İHA’da sağ-sol motorları aynı yönde-ön arka motorları aynı yönde ve sağ-sol motorlarına da zıt yönde dönerler böylelikle İHA’nın gövde merkezine olan toplam moment “0” olur.

Yükseklik: İHA’nın yükselmesi veya havada askıda kalabilmesi için bütün motorların řekil 5.1’de gösterildięi gibi eřit hızlarda dönmeleri gerekmektedir. Motorlara verilen

gücün miktarı arttıkça İHA yükseklik kazanır. Motorların gücü eşit bir şekilde azaltılınca da İHA alçalır. Yükselip alçalma hareketi bir İHA'nın en kolay manevrasıdır denebilir. Çünkü bütün motorlara eşit miktarda güç uygulanır.

Yunuslama (θ): İHA'lar yunuslama manevrası denen manevra ile ileri geri hareketlerini gerçekleştirir. Bu hareketi yaparken İHA ileri doğru hareket ettirilmek istenirse sağ-sol motor çiftinin hızları değiştirilmeden arka motorun hızı artırılıp ön motorun hızı da azaltılırsa denge bozulmuş ve İHA sabit kalmak yerine ileri doğru hareket etmiş olur. Burada önemli olan sağ-sol ve ileri-geri motor çiftleri ters yönde döndürülerek toplam momentin "0" olması sağlanmasıdır. Yeni durumda artan arka motor hızı ve azalan ön motor hızı nedeniyle denge de bozulmuş olur. Bu nedenle arka motorun hızının artırılması ve ön motor hızının azaltılması sağ-sol motor çiftinin momentinin toplamını karşılayacak biçimde ayarlanmalıdır.

Yuvarlanma (ϕ): İHA'lar yuvarlanma manevrası denen manevra ile sağ sol hareketlerini gerçekleştirirler. Bu hareketi yaparken İHA sağa doğru hareket ettirilmek istenirse ileri-geri motor çiftinin hızları değiştirilmeden sol motorun hızı artırılıp sağ motorun hızı da azaltılırsa denge bozulmuş ve İHA sabit kalmak yerine sağa doğru hareket etmiş olur. Burada önemli olan ileri-geri ve sağ-sol motor çiftleri ters yönde döndürülerek toplam momentin "0" olması sağlanmasıdır. Yeni durumda artan sol motor hızı ve azalan sağ motor hızı nedeniyle denge de bozulmuş olur. Bu nedenle sol motorun hızının artırılması ve sağ motor hızının azaltılması ileri-geri motor çiftinin momentinin toplamını karşılayacak biçimde ayarlanmalıdır.

Yönelme (ψ): Daha önce de bahsedildiği üzere ileri-geri motorları bir yönde ve sağ-sol motorları diğer yönde dönmekte olup İHA'nın gövde merkezinde toplam moment sıfırlanmaktadır. Yönelme hareketi yönelmenin gerçekleştirileceği yöndeki momentin artırılması ile olmaktadır. Yani ya sağ-sol motorlarının hızları eşit azaltılarak veya artırılarak ya da ileri-geri motorlarının hızları eşit azaltılarak ya da artırılarak sağa veya sola yönelme sağlanır. Sağa dönen motor çiftleri sola, sola dönen motor çiftleri sağa moment oluşturur.

Dört Rotorlu insansız hava aracının durum denklemleri Denklem 5.1- Denklem 5.6 arasında verilmiştir.

$$\ddot{x} = (\sin\psi\sin\theta + \cos\psi\sin\theta\cos\phi)\frac{u_1}{m} \quad (5.1)$$

$$\ddot{y} = (-\cos\psi\sin\phi + \sin\psi\sin\theta\cos\phi)\frac{u_1}{m} \quad (5.2)$$

$$\ddot{z} = -g + (\cos\theta\cos\phi)\frac{u_1}{m} \quad (5.3)$$

$$\ddot{\phi} = \frac{(I_y - I_z) \cdot q r}{I_x} + \frac{u_2}{I_x} \quad (5.4)$$

$$\ddot{\theta} = \frac{(I_z - I_x) \cdot r p}{I_y} + \frac{u_3}{I_y} \quad (5.5)$$

$$\ddot{\psi} = \frac{(I_x - I_y) \cdot p q}{I_z} + \frac{u_4}{I_z} \quad (5.6)$$

Bu denklemlerde (θ, ϕ, ψ) sırasıyla yunuslama, yuvarlanma ve yönelme açılarını gösterir. (I_x, I_y, I_z) sırasıyla x, y, z eksenlerindeki eylemsizlik momentleridir. (u_1, u_2, u_3, u_4) sırasıyla yükseklik, yuvarlanma, yunuslama ve yönelme girişlerini göstermektedir ve Denklem 5.7 ile Denklem 5.10 arasında verilmiştir.

$$u_1 = u_{yükseklik} = b(\Omega_1^2 + \Omega_2^2 + \Omega_3^2 + \Omega_4^2) \quad (5.7)$$

$$u_2 = u_{yuvarlanma} = l \cdot b(\Omega_4^2 - \Omega_2^2) \quad (5.8)$$

$$u_3 = u_{yunuslama} = l \cdot b(\Omega_1^2 - \Omega_3^2) \quad (5.9)$$

$$u_4 = u_{yönelme} = d(\Omega_1^2 - \Omega_2^2 + \Omega_3^2 - \Omega_4^2) \quad (5.10)$$

Bu denklemlerdeki b ve d katsayıları aerodinamik etkilere bağlı sabitlerdir. Ω_i motorların dönme hızını, l pervane eksenini ile ağırlık merkezi arasındaki mesafe yani İHA'nın kol uzunluğudur. Durum denklemlerinin daha detaylı çıkarımı için [97] numaralı referanstaki yüksek lisans tezimi inceleyiniz.

Şekil 5.2'de tezde kullanılan oyuncak Dört Rotorlu İnsansız Hava Aracı görülmektedir.



Şekil 5.2. Kullanılan oyuncak İHA

Şekil 5.2’de tez çalışmasında kullanılan İHA, oyuncak İHA olup boyutları avuç içine sığacak boyutlarda ve dışında İHA’ya sabitlenmiş çarpmalara karşı koruma amaçlı kafes bulunmaktadır.

5.2. 3 Boyutlu Sanal Gerçeklik Oyun Ortamı

Bu tez çalışmasında gerçek 4 rotorlu insansız hava aracına uygulanan biyolojik sinyallerle çıkarılmış komutlar, gerek analizlerin daha iyi yapılabilmesi gerekse de çeşitliliğin artırılmak istenmesi nedeniyle bir sanal gerçeklik oyununa da uygulanmıştır. Bu sanal gerçeklik uygulaması bir nevi benzetim ortamı sağlamıştır. Uygulamanın yapılmasının bir diğer nedeni de sanal gerçeklik oyunlarının çağımızın en popüler oyun ortamları ve gelişimlerinin başlarında olmasıdır. Sanal gerçeklik oyunu Unity 3D oyun yazılımı ile yapılmıştır. Unity kullanılma sebepleri aşağıdaki gibi sıralanabilir:

1. Öğrenciler için lisans gerektirmemesi ve ücretsiz olması
2. Mağazada ücretli veya ücretsiz objelerin hazır olarak sunulması
3. Windows, Android, İOS gibi birden fazla işletim sistemi tarafından desteklenmesi


4. Kullanışlı olması
5. Oyun tasarımında sürükle-bırak özelliğinin olması ve kod yazmadan da oyun tasarımını sağlaması

EEG İHA'yı yükseltip alçaltırken EMG ise sağa, sola, geri, ileri yönlendirirken kullanılmaktadır. Kişi İHA'yı yükseltmek isteyince İHA'ya odaklanması ve havalandığını hayal etmesi yeterli olmaktadır. İHA'yı alçaltmak için ise dikkatini dağıtması ve rahatlaması yeterlidir. EMG ile İHA'nın manevraları kontrol edilirken kişi elinde bir joystick varmış ve bu joysticki sağa çekerken yaptığı hareketin EMG'si İHA'yı sağa, sola çekerken yaptığı hareketin EMG si İHA'yı sola, aynı şekilde ileri ve geri çekerken yaptığı hareketin EMG'si ise İHA'yı ileri ve geri hareket ettirir. Şekil 5.3'te EMG hareketleri verilmiştir.



Şekil 5.3. EMG hareketleri ve elektrot yerleşimleri a) sağ b) sol c) ileri d) geri e) sabit

Şekil 5.4'te kullanılan EMG cihazı ve elektrotları görülmektedir.



Şekil 5.4. a)Kullanılan EMG cihazı b) Tahribatsız elektrotlar

Kullanılan EMG cihazı Olimex firmasının olup açık kaynak kodlu tek kanallı bir EMG cihazıdır. Fiyatı yaklaşık 30 € civarında olup düşük bütçeli uygulamalarda kullanılabilir niteliktedir. Cihaz ile ilgili bazı bilgiler Tablo 5.1’de verilmiştir.

Tablo 5.1: Olimex EMG cihazının özellikleri

Örnekleme Frekansı	256 Hz
ADC Çözünürlüğü	10 bit
Kanal Sayısı	1
Haberleşme Türü	Seri Port (Kablo ile)
Elektrot Tipi	Önceden Jelli, Ag/AgCl



Şekil 5.5. a) Kullanılan elektrotlar b) EEG cihazı (Emotiv EPOC+)

Şekil 5.5'te kullanılan EEG cihazı ve elektrotları gösterilmektedir. Emotiv EPOC+ EEG cihazının her geçen gün bilim dünyasında popülerliğinin artması, fiyatının medikal seviyedeki cihazlara oranla uygun olması ve piyasada fiyat/performans oranı en yüksek cihazlardan biri olması ile birlikte birçok çalışmada kullanılmış olması tercih sebebi olmuştur. Cihazın bir diğer iyi özelliği de elektrotlarının sabit bir yapı üzerinde bulunması ve doğrudan kafatasına oturtularak kullanılmaya başlanması ve kablosuz oluşudur. Cihazın özellikleri Tablo 5.2'de verilmiştir.

Tablo 5.2: Emotiv Epoc+ EEG cihazının özellikleri


Örnekleme Frekansı	2048 Hz içinde, 128Hz alınan
ADC Çözünürlüğü	14 bit
Band Genişliği	0.2-43Hz
Kanal Sayısı	14
Haberleşme Türü	Bluetooth (Kablosuz)
Elektrot Tipi	Solüsyonlu Ag/AgCl

Oyundan kareler Şekil 5.6. ile Şekil 5.10. arasında verilmiştir.




Şekil 5.6. Oyunun ana menüsü

Şekil 5.6'da oyunun ana menüsü gösterilmektedir. Ana menüden bölüm seçimi ve bazı ayarlamalar yapılmaktadır.




Şekil 5.7. Oyunun birinci bölümü

Şekil 5.7’de oyunun birinci bölümü gösterilmektedir. Birinci bölümde oyuncu şehir gezintisi yapabilmektedir.




Şekil 5.8. Oyunun ikinci bölümü

Şekil 5.8’de oyunun ikinci bölümü gösterilmektedir. İkinci bölümde oyuncu teknolojik şehirde keşif yapabilmektedir.




Şekil 5.9. Oyunun üçüncü bölümü

Şekil 5.9’da oyunun üçüncü bölümü gösterilmektedir. Üçüncü bölüm oyundan ziyade performans testlerinin yapıldığı bölümdür. Bu bölümde tasarlanan sistemin performansı gerçek kumanda ile kıyaslanmaktadır. Kıyaslama için çeşitli yolların ne doğrulukta takip edildiğine bakılmaktadır. Yolun ve İHA’nın anlık koordinatları hem ekranın sol üst köşesinde yazdırılmakta hem de MATLAB’da takip başarısının hesabı için sürekli olarak text (txt) uzantılı dosyaya kaydedilmektedir.



Şekil 5.10. Oyunun dördüncü bölümü

Şekil 5.10’de oyunun dördüncü bölümü gösterilmektedir. Dördüncü bölümde oyuncu bir kale ve doğal şekillerden oluşmuş bölgeyi keşif yapmaktadır. Bu oyunda bölümlerin geliştirilmesi tarafımızca yapılabilir olup ek olarak yarışma tarzı bölümler, engellerden kaçma bölümleri gibi bölümler eklenip uygulama zenginleştirilebilir. Sanal gerçeklik oyununa komutlar MATLAB programı tarafından sinyaller işlenip komutlar çıkarıldıktan sonra gönderilmektedir. Bilgisayar ortamındaki sinyal işleme ve komut gönderme işlemleri Şekil 5.11’de gösterilmiştir.




Şekil 5.11. Bilgisayar ortamındaki akış şeması

MATLAB yazılımının anlaşılır ve kolay olması için grafik arayüzü de tasarlanmıştır.

5.3. Sinyal İşleme Grafik Arayüzü

Tasarlanan grafik arayüzü sayesinde hem kullanıcının kafasının karışması engellenmiş hem de kullanıcının adım adım yönlendirilmesi sağlanmıştır.




Şekil 5.12. Grafik arayüzünün ilk açıldığındaki görüntüsü

Grafik arayüzünü tanıtmak gerekirse başlangıçta Şekil 5.12'deki ekranla açılmaktadır. Kullanıcı arayüzünün karmaşıklığının azaltılması için işlemler yukarıdan aşağıya doğru sıralı bir şekilde ilerler ve işlem yapılacak alan seçildiğinde o işlem ile ilgili ayarlanacak parametreler arayüzde belirir. Böylelikle kullanıcı hangi parametrenin nereyle ilgili olduğunu da bilir. Kullanıcı ilk başta eski veri ile mi yoksa yeni veri ile mi devam edeceğini belirler. Eski veri seçildiğinde bilgisayarda önceden kayıtlı olan EEG ve EMG verileri kullanılarak sınıflandırıcılar eğitilir ve yeni alınan sinyaller bu eski sinyallere göre sınıflandırılır. Eski verileri kullanmak oyuna daha çabuk geçmeyi sağlar fakat daha doğru sonuçlar alınması için her defasında yeni veriler alınması önerilir. Çünkü biyolojik sinyaller ortamdan ortama ve kişiden kişiye değişmektedir.

Daha sonra başlat butonuna basılarak devam edilir. Başlat butonuna basıldıktan sonra aşağıdaki kutucuğa bir takım bilgiler girilmesi istenir. Bu bilgiler; cihazın kaç kanalından veri alınacağı, cihazın örnekleme frekansı, kaç farklı hareket veya sinyalin sınıflandırılacağı, her bir hareket için kaç örnek alınacağı gibi bilgilerdir. Yine bu bölümde sinyal alma işlemi ve alınan sinyalin hangi harekete ya da zihinsel olaya bağlı

olduğunun etiketlenerek veri setinin oluşturulması işlemleri sağlanır. Şekil 5.13'te örnek olarak gösterilmiştir.




Şekil 5.13. Veri alınması ve etiketlenmesi

Bu adımdan sonra “filtrele” kutucuğu işaretlenerek sinyalin filtrelenmesine geçilir. Kutucuk seçilince yan tarafında filtre parametreleri girilmesi istenir. Bu parametreler Yüksek Geçiren Filtre frekansı, Alçak Geçiren Filtre Frekansı ve Filtre derecesidir. Şekil 5.14'te gösterilmiştir.



Şekil 5.14. Filtreleme adımı ve parametreleri

50 Hz notch filtresi ve detrend filtresi filtrele butonuna basılır basılmaz otomatik olarak her sinyale uygulanmaktadır bu nedenle grafik ara yüzünde herhangi bir işlem yapılmaz. Filtreleme işleminden sonra yapılacaksa dalgacık dönüşümü adımına geçilir. Dalgacık dönüşümü EEG için gereklidir fakat EMG için çok fazla önemli değildir. Kullanılan Emotiv Epoc marka cihazın örnekleme frekansı 128 Hz olması nedeniyle EEG alt bantlarını kapsayacak şekilde bir DD uygulandığında 4 seviyeli DD yeterli olmaktadır. Bu nedenle arayüzde 4 seviyeli bir DD yapılmaktadır. Dalgacık kutucuğu seçildiğinde Tablo 4.2'ye göre alfa, beta, teta, delta veya gama bantlarına denk gelen D1, D2, D3, D4 ve A4'ten istenilen alt bant seçilir. Yine en sağdaki kutucuğa da kullanılmak istenen dalgacık tipi yazılır. Örneğin “db8” dalgacığı yazılabilir. Dalgacık dönüşümü alanı Şekil 5.15'te verilmiştir.



Şekil 5.15. Dalgacık dönüşümü adımı ve parametreleri

DD adımıdan sonra özellik çıkarımı adımı gelmektedir. Buradan bir veya birkaç özellik seçilebilir. Şekil 5.16’da özellik seçimi alanı görülmektedir.

Şekil 5.16. Özellik seçme adımı ve parametreleri


Sonraki adım hangi sınıflandırıcının seçileceği ve o sınıflandırıcıya ait performansın gösterileceği bölümdür. Kullanıcı bu bölümde bir sınıflandırıcı seçer ve gerçek zamanlı oyuna geçmeden önce çevrimdışı bir sınıflandırma yaparak sınıflandırıcının performansını görür. Bu bölüm Şekil 5.17’de mevcuttur.

Şekil 5.17. Sınıflandırıcı seçme adımı

Sınıflandırıcı algoritması seçildikten sonra “Sınıflandırıcı performansını gör” butonuna basılarak önceden kaydedilmiş veri ile çevrimdışı bir sınıflandırma yapılır. Çevrimdışı sınıflandırma ile sınıflandırıcı performansları önceden test edilir ve gerçek zamanlı uygulamalarda kullanılmak üzere en başarılı sınıflandırıcı seçilir. “Gerçek Zaman Sınıflandır” butonuna basılarak anlık gelen veriler en başarılı sınıflandırıcı ile gerçek zamanlı olarak sınıflandırılıp sanal gerçeklik oyununa veya İHA’ya gönderilir.

5.4. Gerçek Oyun Kumandası

Oyun da EMG performansını ölçmek için gerçek fiziksel bir kumanda tasarımı da yapılmıştır. Söz konusu kumanda tıpkı normal bir İHA kumandasına benzer yapıda olup üzerinde 2 adet joystiğe sahiptir. Kumanda ile sağ, sol, ileri, geri, aşağı, yukarı komutları bilgisayarın mikrofon soketi girişinden gönderilmektedir. Kumanda Şekil 5.18’de görülmektedir.




Şekil 5.18. Tasarlanan gerçek oyun kumandası

Kumanda bir arduino uno platformu üzerine inşa edilmiş olup programlanabilir yapıdadır. Joystiklerden okunan analog gerilimlere göre bilgisayarın mikrofon girişi ADC sine her komut için arduino uno tarafından farklı frekansta PWM darbesi gönderilmek suretiyle komut gönderimi yapılmaktadır. Gönderilen farklı frekanstaki PWM darbelerinin ortalaması ise bilgisayarda hesaplanıp hangi komutun geldiği çözülmektedir. Ayrıca kumanda üzerine monte edilmiş 2.4 GHz RF alıcı verici de bulunmaktadır. Bu sayede üzerinde 2.4 GHz'lik bir RF alıcısı bulunan ve iletişim protokolü bilinen herhangi bir İHA, oyuncak vb gibi nesneler bu kumanda ile kontrol edilebilmektedir. Ayrıca kumanda programlanabildiği için seri port üzerinden de bilgisayara komut gönderimi mümkündür. Bu uygulamada komutlar seri porttan gönderilmek yerine seri porttan daha hızlı iletilebilen ses kartı üzerinden yapılmaktadır.

5.5. İHA'ya Komut Gönderimi İçin Kumanda Tadilatı

Bilgisayardan gelen EEG ve EMG sinyallerinden çıkarılan komutları insansız hava aracına kablosuz olarak göndermek için orijinal İHA kumandasına bir takım tadilatlar yapılmıştır. Orijinal kumanda incelendiğinde insansız hava aracına komut gönderen joystiklerin aslında birer potansiyometre gibi kullanıldıkları saptanmıştır. Kumanda üzerinde bulunan mikroişlemcinin analog bacaklarına değişen gerilimler verdikleri görülmüştür. Kumanda içerisindeki mikroişlemci ise potansiyometrelerden veya joystiklerden okuduğu gerilimi kullanarak insansız hava aracına komutlar göndermektedir. Bu çalışmada bir nevi dijital joystik tasarlanıp orijinal joystikler devre dışı bırakılarak bunların bağlı oldukları yerlere dijital olanlar lehimlenmiştir. Harici bir mikrokontrolcü kullanılarak bilgisayardan gelen verilere göre yazılımsal olarak joystiklerin ürettikleri gerilimlere denk gerilimler üretilmiştir. Bu gerilimler harici mikrokontrolcüde oluşturulan PWM sinyalinin alçak geçiren filtreden geçirilip doğrultularak elde edilmiştir. Söz konusu işlem Şekil 5.19'da gösterilmektedir.



Şekil 5.19. DAC elektronik devresi


Burada PWM sinyalinin üst kısmında şarj olan kapasitör, PWM sinyalinin alt bölgesinde gerilim sağlayarak sabit bir gerilim elde edilmesine neden olur. Böylelikle sürekli bir DC analog gerilim elde edilmiş olur. Aslında bu işlem bir DAC tasarımıdır yani günümüzde birçok mikrokontrolcüde bulunmayan dijital analog çeviricidir. Bu gerilimler son olarak İHA kumandasında ilgili noktalara tatbik edilerek istenen komutların İHA'ya gönderilmesi sağlanmıştır. Tasarlanan dijital analog çevirici ve kumanda Şekil 5.20'de görülmektedir.



Şekil 5.20. DAC tasarımı

Şekil 5.20.'de görüldüğü gibi 4 adet RC filtre tasarlanıp kumandaya monte edilmiştir. Montaj işlemi orijinal joystickler iptal edilerek onların yerine RC filtrenin çıkışı lehimlenerek yapılmıştır. 4 adet RC filtreden ilki motor hızı için yani yükselip alçalma için, ikincisi sağ-sol yönelme için, üçüncüsü ileri-geri yönelme için dördüncüsü ise z-ekseninde ya da kendi etrafında dönme için tasarlanmıştır. 1 adet 10k ohm direnç ve 1 adet 10 uf kapasitörden oluşmaktadır.

Kumandaya komutlar harici bir mikroişlemci ve RC filtre ile verilmektedir. Bilgisayardan EEG ve EMG verilerinin işlenmesinden elde edilen komutlar, bilgisayar üzerinde bulunan ve aslında iyi bir dijital analog çevirici ve analog dijital çevirici olan ses kartından analog gerilim olarak alınmaktadır. Kulaklık fişi olarak bilinen stereo fiş bilgisayarın kulaklık soketine yerleştirilir. Stereo fişin diğer ucu ise kumandaya bağlı harici mikroişlemcinin analog pinlerinden birine bağlanır. MATLAB programında sinyal işleme sonucu çıkarılan komutlara özel üretilmiş “wav” ses dosyaları vasıtasıyla her komut için kulaklık soketine ayrı müzik tonları iletilir yani ayrı gerilim seviyeleri üretilir. Kısacası, MATLAB tarafından komut yerine geçen 6 ayrı komut için 6 ayrı ses dosyaları yürütülür. Yürütülen ses dosyalarının voltaj seviyesinden de hangi komut olduğu mikrokontrolcü tarafından bilinir. Ses dosyaları ise Audacity adlı program vasıtasıyla istenilen şekilde üretilir. 0V ile 1.8V aralığında istenilen seviyede gerilim üreten “wav” ses dosyaları veya sinüs, kare, testere dişi formatlarında sesler oluşturulabilmektedir. Ayrıca frekans ayarı da yapılabilmektedir. Audacity programıyla oluşturulmuş bir ses dalgası Şekil 5.21’de görülmektedir.



Şekil 5.21. Audacity programında oluşturulmuş 50 Hz PWM ses dalgası

Şekil 5.22’de komple kumanda tadilatı görülmektedir.




Şekil 5.22. Tasarlanan İHA kumandası

Şekil 5.22’de görüldüğü üzere yukarıdan aşağıya doğru tasarlanan İHA kumandasının elemanları tanıtılırsa;


En üstte stereo fiş bulunur. Bu fiş kulaklık soketine yerleştirilerek birer ses olan komutlar algılanır. Stereo fişin açık ucu ise ara mikroişlemcinin A0 analog bacağına lehimlenmiştir. Bu bacadan yürütülen ses dosyası analog olarak algılanıp hangi komut olduğu çıkarılır. Ara mikroişlemci, DAC yapısına bağlıdır. DAC yapısına ara mikroişlemci tarafından PWM sinyali gönderilip DAC çıkışında kumandaya gerekli komut gerilimleri üretilir. Bu komut gerilimleri joystiklerin sağladığı gerilimler ölçülerek belirlenir.

5.6. Uygulamanın Gerçekleştirilmesi

Uygulama gerçekleştirilirken öncelikle bilinmesi gereken EEG ve EMG sinyallerinin ayrı cihazlarla alındıktan sonra, ayrı ayrı filtrelenip, ayrı ayrı işlenip yine ayrı ayrı komutlarının çıkarıldığıdır. Bu anlamda uygulamada iki ayrı biyolojik sinyalin ayrı ayrı değerlendirilip yine İHA veya oyunda farklı yönlendirmelerde kullanıldıkları akla gelmelidir. İki biyolojik sinyalin birleştirilmesi, birlikte filtrelenmesi veya birlikte işlenip komutların çıkarılması söz konusu değildir. Sinyaller ayrıca birbirlerini etkilememektedir. İki farklı sinyalin ortak noktaları ise aynı bilgisayar üzerinde işlenmeleridir. Bilinmesi gereken diğer husus İHA için ve oyun için çıkarılan komutların eş zamanlı değil de seçilen uygulamaya göre çıkarılmasıdır. Yani oyun oynanırken, İHA için oluşturulan ses komutları çıkarılmaz ya da İHA kullanılırken, oyun için tuş komutları çıkarılmaz.




Şekil 5.23'te uygulama özetlenmiştir. Sinyal alma aşaması, sinyal işleme aşaması ve komutların çıkarılıp İHA ve oyun ortamlarına uygulama aşaması olmak üzere 3 farklı aşama mevcuttur.



Şekil 5.24. Sinyal alma aşaması


Şekil 5.24'te sinyal alma aşaması görülmektedir. Sinyal alma aşamasında insan vücudundan diğer bir deyişle kafatasından ve başparmak kaslarından sırasıyla EEG ve EMG sinyalleri alınmaktadır. EEG sinyalleri örnekleme frekansı 128 Hz olan Emotiv EPOC cihazının tek kanalından başka bir deyişle FP1 kanalından saniyede 128 örnekten oluşan paketler halinde alınmaktadır. EMG sinyalleri ise örnekleme frekansı 256 Hz olan tek kanallı Olimex EMG cihazından saniyede 256 örnekten oluşan paketler halinde alınmaktadır.

EEG ve EMG sinyalleri tahribatsız elektrotlar yardımıyla alınır. Alınan ham sinyaller sinyal işleme aşamasına iletilir.




Şekil 5.25. Sinyal işleme aşaması (sinyal filtreleme)

Şekil 5.25’de sinyal işleme adımlarından sinyal filtreleme işlemi görülmektedir. Kafatasından alınan ham EEG ve başparmak kasından alınan ham EMG sinyalleri birçok gürültüye ya da istenmeyen bileşenlere sahiptir. Bu istenmeyen bileşenler özellik çıkarma adımına geçilmeden önce yok edilmelidir. EEG sinyali filtrelenirken DC sapma yok edilir. Alçak geçiren filtre ile EEG sinyalinin en yüksek frekanslı bileşeni olan 40 Hz’den yüksek frekanslı bileşenler yok edilir. Böylelikle 50 Hz gürültüsü için gerekli olan notch filtre kullanılmaz. Son olarak yüksek geçiren filtre ile EEG sinyalinin en düşük bileşeni olan 0.3 Hz’den düşük frekanslı bileşenler yok edilir. EMG sinyali filtrelenirken aynı şekilde DC sapma gerilimi yok edilir. 50 Hz gürültüsü notch filtre ile yok edilir. Son olarak da EMG sinyali için 10 Hz’den düşük frekanslı gereksiz bileşenler yüksek geçiren filtre ile engellenir. EMG filtrelerken alçak geçiren filtre kullanılmamasının sebebi EMG sinyalinin üst frekansının yüzlerce Hz olmasından dolayıdır. Kullanılan cihazın örnekleme frekansı 256 Hz olduğu için üst frekansı sınırlama ihtiyacı duyulmamıştır. Sinyaller filtrelendikten sonra özellik çıkarma aşamasına geçiş yapılır.



Şekil 5.26. Sinyal işleme aşaması (özellik çıkarma)


Şekil 5.26’da sinyal işleme aşamasından özellik çıkarma bölümü gösterilmektedir. Filtreleme aşamasından gelen filtrelenmiş ham sinyallerin frekans ve zaman domenli özellikleri çıkarılır. EEG sinyali için 3. dereceden özbağlanım katsayıları, varyans, entropi, mobilite ve biçim katsayısı özellikleri kullanılmıştır. EMG sinyali için 7. dereceden özbağlanım katsayıları, ortalama mutlak sapma, dalga boyu uzunluğu, tipik değer, entropi, 1. çeyrek kütle, 3. çeyrek kütle özellikleri kullanılmıştır. Bu özellikler belirlenirken öncelikle tek başına sınıflandırma işleminde gösterdikleri performanslara bakılmıştır. Tek başına kullanıldığında yüksek sınıflandırma doğruluğu veren özellikler bir araya getirilmiştir. Bir sonraki aşama olan sınıflandırma aşaması için Şekil 5.26’da görüldüğü üzere EEG sinyallerinden 1×7 ’lik özellik vektörü oluşturulmuş. EMG sinyallerinden ise 1×13 ’lük özellik vektörü oluşturulmuştur. Böylelikle sinyal alma aşamasında alınan 1×128 ’lik EEG sinyal vektörü 1×7 ’lik özellik vektörüne dönüştürülmüştür. 1×256 ’lık EMG sinyal vektörü ise 1×13 ’lük özellik vektörüne dönüştürülmüştür.



Şekil 5.27. Sinyal işleme aşaması (sınıflandırma)


Şekil 5.27’de sınıflandırma işlemi görülmektedir. Sınıflandırma işlemi sinyalin özellikleri çıkarıldıktan sonra yapılır. EEG ve EMG sinyalleri ayrı ayrı sınıflandırıcılar tarafından sınıflandırılır. EEG eğitim seti, 100 adet 10’ar saniyelik rasgele zihinsel yoğunlaşma ve yoğunlaşmayı durdurma durumlarından elde edilen EEG verisinin özellikleri çıkarılarak hazırlanmıştır. EMG için aynı şekilde eğitim seti, 1’er saniyelik 100 adet rasgele sağ, sol, ileri, geri joystick hareketleri yapılarak elde edilen EMG verisinin özellikleri çıkarılarak hazırlanmıştır. EEG sınıflandırma test edilirken aynı şekilde test seti, 100 adet 10’ar saniyelik EEG verisinin özellikleri çıkarılarak hazırlanmıştır. EMG içinde aynı şekilde test seti, 100 adet 1’er saniyelik EMG sinyalinin özellikleri çıkarılarak hazırlanmıştır. Sınıflandırıcıların başarısı ise test setindeki 100 örnekten kaçının doğru sınıflandırıldığına bakılarak yüzde olarak belirlenmiştir. Bu sonuçlara göre EEG sinyalleri en başarılı sınıflandırma algoritması olan ve tezin sonuçlar bölümünde daha detaylı sonuçları verilen YSA ile sınıflandırılır. EMG sinyalleri ise en başarılı sınıflandırma algoritması olan ve yine tezin sonuçlar bölümünde daha detaylı sonuçları verilen LDA ile sınıflandırılır. Sınıflandırıcılar

karar sınırlarını belirlemesi için önceden eğitilirler. Eğitim seti ile eğitilen en başarılı sınıflandırıcılar gerçek zamanlı alınan EEG ve EMG sinyallerini ayrı ayrı sınıflandırır. Yani anlık olarak hangi joystick hareketinin yapıldığını veya hangi zihinsel görevin gerçekleştirilmekte olduğunu sınıflandırır. Bu sınıflandırmanın ardından her sınıfa ait komut üretimi yapılarak komutlar oyuna veya İHA ya iletilir.



Şekil 5.28. Oyun için komut çıkarımı

Şekil 5.28’de oyun için sınıflandırma işlemine göre komut çıkarımı gösterilmiştir. Gerçek zamanlı gelen EEG ve EMG sinyalleri başparmağın hareketine ve zihinsel yoğunlaşma durumuna göre sınıflandırıldıktan sonra sınıflara göre komutlar üretilir. Bu komutlar oyunda kullanılan tuşlara basma işlemidir. Oyun klavyeden oynanırken yükselme için F tuşu, alçalma için F tuşunu bırakma, ileri gidiş için yön tuşlarından yukarı tuşu, geri gidiş için yön tuşlarından aşağı tuşu, sağa gidiş için yön tuşlarından sağ tuşu, sola gidiş için yön tuşlarından sol tuşuna basılır. Bundan dolayı çıkarılan komutlar, bu tuşlara basma işlemidir. Tuşlara basma işlemi MATLAB programı tarafından oluşturulan robot vasıtasıyla “robot.keyPress” komutu ile gerçekleştirilir. Bu işlem Şekil 5.28’da gösterildiği gibi yapılmaktadır. Böylelikle tuşlara elle basılmadan MATLAB tarafından ilgili tuşun görevi yerine getirilir ve oyun bu sayede klavyeden oynanıyormuş gibi zihinsel EEG ve başparmak kas hareketinin oluşturduğu EMG ile oynanmış olur.



Şekil 5.29. İHA için komut çıkarımı


Şekil 5.29’da İHA için çıkarılan komutların şeması verilmiştir. Şekil incelendiğinde yükselme komutu için süresi 0.05s olan ve Audacity programında keyfi olarak genliği 0.1 olarak belirlenen ve bu genlik değerinde kulaklık soketine voltmetre bağlandığında bilgisayarın en yüksek ses seviyesinde 0.18V gerilim üreten bir ses MATLAB tarafından 0.05s boyunca yürütülür. Aynı şekilde alçalma komutu için 0.05s boyunca Audacity genliği 0.2 olan ve kulaklık soketinde 0.36V gerilim çıkışı olan bir ses MATLAB tarafından yürütülür. Diğer sesler ve özellikleri şekil üzerinde etiketlenmiştir. Şekilde G harfi Audacity programındaki sesin genliğini, V harfi sesin kulaklık soketinde ölçülen gerilimini, S sesin süresini göstermektedir. Bu sesler “wav” uzantılı seslerdir. MATLAB ortamında ses yürütme işlemi “audioread” ve “sound” sesleri ile yapılmaktadır. Bu sesler ara mikroişlemci ile bilgisayarın kulaklık soketinden analog olarak ara mikroişlemci tarafından okunur. RF kumandanın anlayacağı gerilim değerlerine DAC yardımıyla dönüştürülür. Böylelikle joystiklere dokunulmadan MATLAB’dan yürütülen sesler ile İHA yönetilmiş olur. Bu işlem için RF kumandaya tadilat gerçekleştirilmiş olup kumanda içindeki mikroişlemcinin analog bacaklarına bağlı olan joystikler iptal edilmiştir. Joystiklerin bağlı olduğu yerlere kendi tasarımı olan DAC’lar lehimlenmiştir. Şekil 5.11’de İHA

kumandasının yönetiminde kullanılan joysticklerin konumuna ve yönüne bağlı olarak ürettiği gerilim değerleri verilmiştir.



Şekil 5.30. Kumanda joysticklerinin konumlarına göre ürettiği gerilimler

Şekil 5.30'da sol tarafta bulunan yükselme alçalma joystick'i en aşağı ya da minimum konumundayken 0 V verirken en yukarı konumda ya da maksimum konumda iken 3.3 V gerilim vermektedir. Bu nedenle yükselme komutu için bilgisayardan üretilen 0,18 V gerilim vermektedir. Bu nedenle yükselme komutu için bilgisayardan üretilen 0,18 V'luk kulaklık portu gerilimi İHA'yı istenen yüksekliğe ulaştıracak 0 V – 3.3 V arasında bir değere ara mikroişlemci tarafından algılanıp DAC tarafından ayarlanır. Bu tezde yükselme için DAC tarafından 1.9 V üretilmektedir. Bu değer İHA'nın yavaş yavaş yükselmeye başladığı değer olup daha hızlı yükselme istenirse isteğe bağlı olarak 1.9 V'dan büyük 3.3 V'dan küçük bir değer seçilebilir. Aynı şekilde ileri komutu için orta değer olan 2.47 V değeri, geri komutu için 0.825 V değeri, sağ komutu için 2.47 V ve sol komutu için 0.825 V değerleri seçilmiştir. Seçilen değerler Şekil 5.11'de kırmızı renkli çizgi ile işaretlenmiştir. Bu değerler keyfi değerler olup İHA manevrasının hızlılık veya yavaşlık durumuna göre daha yüksek veya daha düşük değerler seçilebilir. Son olarak Şekil 5.12'de kulaklık soketinden alınan gerilim değerlerinin ara mikroişlemci ve DAC ile RF kumandaya uygulanması gösterilmiştir.



Şekil 5.31. Bilgisayardan İHA'ya komut gönderimi

Şekil 5.31'de kulaklık soketine gönderilen ses komutlarının algılanıp İHA kumandasına oradan da İHA'ya kumanda vasıtasıyla RF olarak gönderilmesi gösterilmektedir. MATLAB'da sinyal işlenip komutlar çıkarıldıktan sonra 6 farklı komut yükselme, alçalma, ileri, geri, sağ, sol için 6 farklı genlikte ses 0.18 V, 0.36 V, 0.72 V, 1.07 V, 1.42 V, 1.57 V yine MATLAB tarafından yürütülür. Bu sesler ara mikroişlemci tarafından algılanıp ilgili komut kumandanın anlayacağı gerilim seviyesine dönüştürülür. Örnek olarak kulaklık soketindeki gerilimin 1.07 V olduğu varsayılın. Şekil 5.29.'da gösterildiği üzere 1.07 V sol komutunu temsil etmekte olup ara mikroişlemci ve DAC tarafından kumandanın sol komutu için alması gereken 0.825 gerilim değerine dönüştürülmelidir. Dönüştürülen gerilim J2 joystiğinin bağlı

olduđu dahili mikroişlemcinin analog bacađına tatbik edilir. Böylelikle MATLAB tarafından yürütölen bir sesin tanınıp, kullanılabilir seviyeye dönüştürölüp İHA ya gönderilmesi sağlanmış olunur. Şekil 5.31’de 6 farklı ses 6 farklı renkle gösterilmekte olup aynı renkli oklar ve yazılar aynı komutun değeriğini temsil etmektedir. Örnek olarak 0.18 V yani yükselme komutu beyaz renkli oklarla temsil edilmektedir. 0.18 V olarak kulaklık soketinden algılanan gerilim değeri Şekil 5.29’da mevcut olan yükselme komutuna denk gelmektedir. Yükselme komutu J1 joystiđine 1.9 V olarak uygulanmak üzere DAC yapısına 388 görev döngölü PWM darbesi oluşturularak elde edilmektedir.

DAC yapısının çıkışını ayarlamakta PWM darbeleri kullanılmaktadır. 10 bit ADC çözünürlüğüne sahip Arduino mikroişlemcisi ile istenen çıkış ($\text{çıkış} = \text{PWM} * 5 / 1024$) formölü ile hesaplanmaktadır. Burada 5 sayısı mikroişlemcinin besleme girişinin 5V olduđu anlamında 1024 ise 10 bit (2^{10}) çözünürlüğüne sahip olduđunu göstermektedir.

SONUÇLAR

Bu tez çalışmasında, hem teorik hem oyun hem de gerçek insansız hava aracı üzerinde yapılan çalışmalar neticesinde elde edilmiş sonuçlar ayrı ayrı başlıklar halinde sunulmuştur.

TEORİK SONUÇLAR

Teorik sonuçlar, İHA'yı yükseltip alçaltmaya yarayan EEG sinyalleri ile İHA'yı ileri, geri, sağa, sola yönlendirmekte kullanılan başparmak EMG sinyallerinin MATLAB ortamında sınıflandırılmasını içermektedir. EMG sınıflandırma işlemi, yaşları 25 ile 28 arasında değişen sağlıklı 8 katılımcıdan alınan başparmak EMG sinyalleri ile yapılmıştır. Katılımcılardan 1'er saniyelik toplam 200'er örnek alınmıştır. Bu örneklerin 100 tanesi eğitimde diğer 100 tanesi testte kullanılmıştır. EMG sınıflandırması, hem eğitim ve test gurubu aynı katılımcıdan oluşturulmuş veri seti ile hem de eğitim ve test gurubu farklı katılımcılardan oluşturulmuş veri seti ile gerçekleştirilmiştir. Çalışmanın bu şekilde yapılmasının nedeni en güçlü ve kararlı sınıflandırıcıyı kolayca belirlemektir. Sınıflandırılan sinyaller ileri, geri, sağ ve sol joystick hareketlerine ait EMG sinyalleridir. Performans ölçütü olarak 100 örnek arasından doğru sınıflandırılan örneklerin sayısı kullanılmıştır. Buna ek olarak bütün sınıflandırıcıların sınıflandırma süreleri de karşılaştırılmıştır. Sınıflandırma süreleri karşılaştırılarak gerçek zamanlı uygulama için en başarılı sınıflandırıcının yanında en hızlı sınıflandırıcı da belirlenmektedir. Özellik çıkarımı yöntemi olarak, öz bağlantım katsayıları, ortalama mutlak sapma, dalga boyu uzunluğu, tipik değer, entropi ve 1. ile 3. çeyrek kütle kullanılmıştır.

Kullanılan sınıflandırıcıların farklı tipleri olmasından ötürü detaylı performans sonuçları ayrı tablolar halinde verilmiştir. Tablolarda 'A' harfi sınıflandırma işleminin eğitim ve test gurubu aynı katılımcıdan alınan veri seti ile yapıldığı anlamına gelmektedir. Tabloda 'F' harfi ise sınıflandırma işleminin eğitim veri setinin farklı test veri setinin farklı katılımcılardan alınan veri seti ile yapıldığı anlamına gelmektedir.

Tablo S.1:EMG sınıflandırması için DA sınıflandırıcısının tipleri ve sonuçları

DA	Doğrusal		Karesel		Diyagonal Doğrusal		Diyagonal Karesel		Mahalanobis	
	A	F	A	F	A	F	A	F	A	F
Performans	92.750	56.571	75.000	33.714	91.625	59.571	87.625	45.714	73.500	33.857
STD	6.204	17.998	3.817	16.879	3.961	17.415	4.565	25.617	3.703	16.945
Süre	0.0106		0.0066		0.0011		0.0014		0.0025	

Tablo S.1’de diskriminant analizinin farklı türlerinin performans, standart sapma (STD) ve sınıflandırma süreleri kıyaslanmıştır. Kıyaslama işlemi eğitim ve test grubu aynı katılımcıdan oluşturulan ve farklı katılımcılardan oluşturulan durumlar için ayrı ayrı değerlendirilmiştir. Bu tablodan anlaşıldığı üzere eğitim ve test grubu aynı katılımcıdan alındığında en iyi performans 92.75 % lik oranla doğrusal diskriminant analizi sınıflandırıcısı ile elde edilmiştir. Eğitim grubu farklı, test grubu farklı katılımcıdan alındığında ise en iyi performans 59.571 % lik oranla diyagonal doğrusal diskriminant analizi sınıflandırıcısı ile elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.2: EMG sınıflandırması için EYK sınıflandırıcısının tipleri ve sonuçları

EYK	Mesafe Kural	Öklid		Manhattan		Kosinüs		Korelasyon	
		A	F	A	F	A	F	A	F
Performans	3-en yakın	82.625	73.142	82.625	66.285	81.750	59.285	81.875	59.571
STD		2.973	4.525	3.020	9.304	3.693	8.518	3.522	8.182
Süre		0.0097		0.0081		0.0050		0.0047	
Performans	Rastgele	82.375	70.142	82.250	67.142	80.625	59.285	81.250	59.428
STD		4.068	6.618	3.195	7.883	3.292	8.769	3.453	8.791
Süre		0.0083		0.0091		0.0040		0.0043	
Performans	Birliktelik	42.625	28.428	43.125	27.714	39.625	22.000	39.500	22.000
STD		6.045	9.015	6.1281	9.268	12.949	10.739	12.501	10.535
Süre		0.0086		0.0087		0.0047		0.0047	

Tablo S.2’de k-en yakın komşu sınıflandırıcısının farklı türlerinin performans, standart sapma (STD) ve sınıflandırma süreleri kıyaslanmıştır. Kıyaslama işlemi eğitim ve test

grubu aynı katılımcıdan oluşturulan ve farklı katılımcılardan oluşturulan durumlar için ayrı ayrı değerlendirilmiştir. Bu tablodan anlaşıldığı üzere eğitim ve test grubu aynı katılımcıdan alındığında en iyi performans 82.625 % 'lik oranla Öklid mesafesince en yakın 3 komşunun belirlediği sınıflandırma ile elde edilmiştir. Eğitim gurubu farklı, test grubu farklı katılımcıdan alındığında ise en iyi performans 73.142 % 'lik oranla yine Öklid mesafesince en yakın 3 komşunun belirlediği sınıflandırma ile elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.3: EMG sınıflandırması için Naive bayes sınıflandırıcısının tipleri ve sonuçları

Naive Bayes	Gauss		Çekirdek	
	A	F	A	F
Performans	76.250	44.857	87.000	44.857
STD	9.837	24.044	5.631	24.155
Süre	0.0075		0.1044	

Tablo S.3’de Naive Bayes sınıflandırıcısının farklı türlerinin performans, standart sapma (STD) ve sınıflandırma süreleri kıyaslanmıştır. Kıyaslama işlemi eğitim ve test grubu aynı katılımcıdan oluşturulan ve farklı katılımcılardan oluşturulan durumlar için ayrı ayrı değerlendirilmiştir. Bu tablodan anlaşıldığı üzere eğitim ve test grubu aynı katılımcıdan alındığında en iyi performans 87.000 % 'lik oranla çekirdek tabanlı sınıflandırıcı tipi ile elde edilmiştir. Eğitim gurubu farklı, test grubu farklı katılımcıdan alındığında ise en iyi performans 44.857 % 'lik oranla yine çekirdek tabanlı sınıflandırıcı ile elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.4: EMG sınıflandırması için DVM sınıflandırıcısının tipleri ve sonuçları

DVM	Doğrusal		Karesel		Polinomsal		Rbf	
	A	F	A	F	A	F	A	F
Performans	78.375	40.000	77.000	39.428	66.25	34.714	29.375	20.000
STD	6.696	13.868	4.407	12.081	5.175	9.638	3.814	0.000
Süre	0.9737		1.4295		1.1649		0.2832	

Tablo S.4’de destek vektör makinesi sınıflandırıcısının farklı türlerinin performans, standart sapma (STD) ve sınıflandırma süreleri kıyaslanmıştır. Kıyaslama işlemi

eğitim ve test grubu aynı katılımcıdan oluşturulan ve farklı katılımcılardan oluşturulan durumlar için ayrı ayrı değerlendirilmiştir. Bu tablodan anlaşıldığı üzere eğitim ve test grubu aynı katılımcıdan alındığında en iyi performans 78.375 % 'lık oranla doğrusal karar sınırına sahip destek vektör makinesi ile elde edilmiştir. Eğitim gurubu farklı, test grubu farklı katılımcıdan alındığında ise en iyi performans 40.000 % 'lık oranla yine doğrusal karar sınırına sahip destek vektör makinesi ile elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.5: EMG sınıflandırması için YSA sınıflandırıcısının sonuçları


YSA	YSA Yapısı: ileri beslemeli geri yayılım ağı kullanılmış olup, gizli katman kullanılmamıştır. Giriş ve çıkış katmanlarının transfer fonksiyonu “tansig” eğitim fonksiyonu “trainlm” olarak seçilmiştir.	
	A	F
Performans	74	63.142
STD	10.823	13.056
Süre	0.0159	

Tablo S.5’de yapay sinir ağları sınıflandırıcısının performans, standart sapma (STD) ve sınıflandırma süreleri verilmiştir. Kıyaslama işlemi eğitim ve test grubu aynı katılımcıdan oluşturulan ve farklı katılımcılardan oluşturulan durumlar için ayrı ayrı değerlendirilmiştir. Bu tablodan anlaşıldığı üzere eğitim ve test grubu aynı katılımcıdan alındığında en iyi performans 74.000 % 'lık oranla elde edilmiştir. Eğitim gurubu farklı, test grubu farklı katılımcıdan alındığında ise en iyi performans 63.142 % 'lık oranla elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Elde edilen bulguların daha anlaşılır ve net bir şekilde yorumlanabilmesi için Tablo S.1-TabloS.5 arasında verilen en başarılı sınıflandırıcı performansları aynı figürde çizdirilerek kıyaslanmıştır. Şekilde ‘_A’ indisi sınıflandırma işleminin eğitim ve test gurubu aynı katılımcıdan alınan veri seti ile yapıldığı anlamına gelmektedir. Şekilde ‘_F’ indisi ise sınıflandırma işleminin eğitim veri setinin farklı test veri setinin farklı katılımcılardan alınan veri seti ile yapıldığı anlamına gelmektedir.


Şekil S.1’deki kutu grafiği sınıflandırma işleminin eğitim ve test gurubu aynı katılımcıdan alınan veri seti ile yapıldığı bütün deney sonuçlarının bir özetidir. Her bir

kutu üzerindeki orta çizgi medyan (orta) değeri göstermektedir. Kutuların üst çizgisi üçüncü çeyrek kütleyi, alt çizgisi ise birinci çeyrek kütleyi göstermektedir. Kutu üzerindeki çubuk en büyük değeri, kutu altındaki çubuk ise en küçük değeri ifade etmektedir.



Şekil S.1. Aynı kişilerle EMG sınıflandırma algoritmalarının kıyaslanması

Şekil S.1’de sınıflandırma işleminin eğitim ve test gurubu aynı katılımcıdan alınan veri seti ile yapıldığı sınıflandırmalardan en iyi performansın LDA ile elde edildiği görülmektedir. En kötü performansın ise YSA sınıflandırıcısı ile elde edildiği görülmektedir. Bu sonuçlara göre, joystick hareketleri (sağ, sol, ileri, geri) sınıflandırıcı bir katılımcı ile eğitilip aynı katılımcı ile test edildiğinde doğrusal ayırt edilebilir formda olmaktadır. Bu varsayımın yapılma nedeni LDA’nın sınıflandırma yaparken kullandığı karar sınırının doğrusal bir vektör olması ve LDA’nın en yüksek başarı oranına sahip olmasıdır. LDA’nın ortalama başarı oranı 92.75 %’dir. Hatta bazı oturumlarda LDA’nın başarı oranı 100 % olduğu görülmektedir. KDA ve DVM_Q gibi karar sınırı doğrusal olmayan sınıflandırıcıların başarı oranları ise doğrusal olan LDA ve DVM gibi sınıflandırıcılardan daha düşüktür.



Şekil S.2. Farklı kişilerle EMG sınıflandırma algoritmalarının kıyaslanması

Şekilden S.2’de sınıflandırma işleminin eğitim ve test gurubu farklı katılımcıdan alınan veri seti ile yapıldığı sınıflandırmalarda en iyi performansı 73.142 % ‘lik ortalama başarı oranı ile EYK sergilemektedir. En kötü performans ise KDA tarafından sergilenmiştir. Bu deneylerde LDA’nın performansı, EYK’dan düşüktür. Bunun nedeni, hareketler arasındaki doğrusal ayırt edici karar sınırının doğrusal olmayan hale dönüşmesidir. Ayrıca, katılımcılar arasındaki elektrotların yerleşim noktalarının tam olarak aynı yerler olmaması, kas yapısı ve EMG sinyal seviyelerinin katılımcıdan katılımcıya değişmesi doğrusal ayırt edici sınırın bozulmasındaki önemli bir etkidir.

Bu durumda KDA ve DVM_Q gibi doğrusal olmayan sınıflandırıcılardan daha yüksek performans beklenebilir. Ancak sonuçlara bakıldığında bu sınıflandırıcılarında iyi performans sergilemedikleri görülmektedir. Bunun nedeni ise bozulan doğrusal ayırt edici sınırın doğrusallık derecesinin bahsedilen sınıflandırıcıların karar sınırlarının doğrusallık derecesinden düşük olmasıdır.

EYK sınıflandırıcısının daha başarılı olma nedeni ise EYK sınıflandırıcısının parametrik olmayan bir sınıflandırıcı olmasıdır. Yani EYK'nın karar sınırı hakkında bir varsayım yapmamasından dolayıdır. Diğer doğrusal olmayan sınıflandırıcılar küresel bir karar sınırı olduğunu varsayarlar; ancak EYK'nın karar sınırı her örnek için yereldir. EYK sınıflandırıcısında eski verilere yeni veri eklendiğinde tekrar hesaplama yapılmaz, bütün hesaplamalar test aşamasında yapılmaktadır. EYK'ya ait olan bu özelliklerden dolayı karar sınırı yüksek derecede doğrusal olmadığı (nonlineer) durumlarda EYK sınıflandırıcısı diğer sınıflandırıcılardan daha yüksek performans sergilemektedir. EYK'nın bir diğer avantajı da standart sapmasının hem aynı hem de farklı katılımcılarla yapılan sınıflandırmada daha düşük olmasıdır. Yani daha kararlı bir sınıflandırıcı olarak ortaya çıkmaktadır.

Sınıflandırma süreleri bakımından ele alındığında ise hem LDA hem de EYK sınıflandırıcıları diğer sınıflandırıcılardan daha hızlıdır.

Katılımcıların sistemi birkaç defa kullanması veya biraz deneyim kazanması performansı oldukça etkilemektedir. Çünkü sistemi ilk defa kullanan katılımcılar sınıflandırıcıyı eğitirken yaptıkları hareketi, test ederken aynı şekilde yapamamaktadırlar. Bundan dolayı sistemi yeni kullanan katılımcılar ile deneyimli katılımcıların sınıflandırma başarıları farklı olmaktadır. Hareketin aynı olmasından kasıt parmağın kasılma miktarıdır. Katılımcı oyunu oynamadan önce sınıflandırıcıyı eğitirken genelde parmağını daha az kasmaktadır. Oyun oynarken ise heyecanın da etkisiyle başparmağını daha fazla kasmaktadır. Böyle olunca sınıflandırıcı aynı iki hareketi farklı olarak algılamaktadır.

Aynı değerlendirmeler ve kıyaslamalar EEG sinyalleri üzerinde de yapılmıştır. EEG sinyali ile dört rotorlu insansız hava aracı yükseltilip alçaltılmaktadır. Önce sanal gerçeklik oyunu katılımcıya gerçek insansız hava aracı kumandası ile oynatılmaktadır. Bu esnada hem katılımcının kumanda ile oyundaki rota planlamasını ne ölçüde doğru takip ettiği ölçülmekte, hem de rotayı takip ederken EEG sinyalleri alınmaktadır. Katılımcının oyun oynarken EEG sinyallerinin alınma sebebi, katılımcının zihinsel yoğunlaşma aktivitesinden faydalanmaktır. Katılımcı oyun oynamaya başladığı anda oyuna zihinsel olarak yoğunlaşır. Bu yoğunlaşma İHA'yı yükseltmek için istenen zihinsel aktivitedir. Bunun için beynin ön lobundaki dikkat ve yoğunlaşma bölgesi

üzerinden FP1 elektrotu ile EEG sinyalleri alınmaktadır. Katılımcı oyuna odaklandığı zaman insansız hava aracının yükselmesi sağlanırken, alçaltma işlemi ise katılımcının dikkatini oyundan alması ile sağlanmaktadır. Bunun için yaşları 28 ile 30 arasında değişen 4 sağlıklı katılımcıdan 11 oturumda her oturumda 15'er dakikalık EEG verisi alınarak deneyler yapılmıştır. Kullanılan özellikler ise 3. dereceden Öz bağlantım katsayıları, varyans, entropi, mobilite ve biçim katsayısıdır.

Tablo S.6: EEG sınıflandırması için DA sınıflandırıcısının tipleri ve sonuçları

DA	Doğrusal	Karesel	Diyagonal Doğrusal	Diyagonal Karesel	Mahalanobis
Performans	70.6	72.4	68.6	69.8	69.2
STD	14.728	14.569	10.996	13.147	15.061

Tablo S.6'da diskriminant analizinin farklı türlerinin performans ve standart sapma (STD) değerleri kıyaslanmıştır. Bu tablodan anlaşıldığı üzere en iyi performans 72.4 % 'lük oranla karesel diskriminant analizi sınıflandırıcısı ile elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.7: EEG sınıflandırması için EYK sınıflandırıcısının tipleri ve sonuçları

EYK	Mesafe Kural	Öklid	Manhattan	Kosinüs	Korelasyon
Performans	3-En yakın	61.6	61.6	60.4	60.8
STD		7.763	7.763	12.285	11.745
Performans	Rastgele	61.6	61.6	60.4	60.8
STD		7.763	7.763	12.285	11.745
Performans	Birliktelik	31.2	31.2	24.4	25.4
STD		14.702	14.702	21.161	20.828

Tablo S.7'de k-en yakın komşu sınıflandırıcısının farklı türlerinin performans ve standart sapma (STD) değerleri kıyaslanmıştır. Bu tablodan anlaşıldığı üzere en iyi performans 61.6 % 'lık oranla Öklid ve Manhattan mesafelerince en yakın 3 komşu ile rastgele 3 komşunun belirlediği sınıflandırmalar tarafınca sergilenmiştir. Ancak bu sınıflandırıcının en genel ve yaygın yapısı olan Öklid mesafesince k-en yakın

komşularının alınması daha doğrudur. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.8: EEG sınıflandırması için Naive bayes Sınıflandırıcısının tipleri ve sonuçları

Naive Bayes	Gauss	Çekirdek
Performans	67.6	72.6
STD	11.345	11.157

Tablo S.8’de Naive Bayes sınıflandırıcısının farklı türlerinin performans ve standart sapma (STD) değerleri kıyaslanmıştır. Bu tablodan anlaşıldığı üzere en iyi performans 72.6 % ‘lık oranla çekirdek tabanlı Naive Bayes sınıflandırıcısı ile elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.9: EEG sınıflandırması için DVM sınıflandırıcısının tipleri ve sonuçları


DVM	Doğrusal	Karesel	Polinomsal	RBF
Performans	71.2	69.6	67.2	66.6
STD	12.081	9.605	15.324	12.258

Tablo S.9’da destek vektör makineleri sınıflandırıcısının farklı türlerinin performans ve standart sapma (STD) değerleri kıyaslanmıştır. Bu tablodan anlaşıldığı üzere en iyi performans 71.2 % ‘lık oranla doğrusal destek vektör makinesi ile elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.

Tablo S.10: EEG sınıflandırması için YSA sınıflandırıcısının sonuçları

YSA	İleri beslemeli geri yayılım ağı kullanılmış olup, gizli katman kullanılmamıştır. Giriş ve çıkış katmanlarının transfer fonsiyonu “tansig” eğitim fonsiyonu “trainlm” seçilmiştir.
Performans	85.6
STD	10.616

Tablo S.10’da yapay sinir ağları sınıflandırıcısının performans ve standart sapma (STD) değerleri verilmiştir. Bu tablodan anlaşıldığı üzere YSA ile en iyi performans 85.6 % ‘lık oranla elde edilmiştir. Söz konusu değerler tabloda kalın ve italik olarak belirtilmiştir.




Şekil S.3. EEG sınıflandırma algoritmalarının kıyaslanması

Şekil S.3’de verilen değerler, EEG sinyalinin sınıflandırılması üzerine bütün sınıflandırıcı performanslarının kıyaslandığı bir grafikdir. Bu grafiğe göre YSA sınıflandırma algoritması 85.6 %’lık ortalama başarı oranı ile en başarılı sınıflandırıcı olmaktadır. Ayrıca bazı testlerde YSA’nın başarısı 100 % seviyelerine ulaşmaktadır. Doğrusal karar sınırı olan LDA ve doğrusal olmayan karar sınırına sahip KDA’nın sonuçları kıyaslandığında KDA, LDA’ya göre daha başarılıdır. En kötü performans noktaları kıyaslandığında en kötü değer LDA ile elde edilmiştir. Bu sonuç iki ayrı EEG sinyalinin doğrusal olarak sınıflandırılmayacağını ve doğrusal olmayan bir karar sınırına ihtiyaç duyulduğunu göstermektedir. EYK sınıflandırıcısı EMG sınıflandırmada olduğu gibi en düşük standart sapmaya sahip olup en kararlı sınıflandırıcı olmaktadır. Fakat başarı seviyesi diğer sınıflandırıcılara nazaran daha düşüktür. Bunun sebebi EYK sınıflandırıcısının çok boyutlu veya çok özellikli verileri sınıflandırma yeteneğinin düşük olmasıdır. Daha etkili özellikler bulunup özellik sayısı azaltılırsa EYK sınıflandırıcısının başarısı artma eğilimine girebilir.


OYUN ORTAMINDAKİ SONUÇLAR

Oyun 4 farklı bölümden oluşmaktadır. Oyunun ilk iki bölümü kullanıcı ile arayüz etkileşiminin adaptasyonunu sağlayacak bölümler olup, eğitim ve alışma bölümleri olarak değerlendirilebilecek bir ortam olarak tasarlanmıştır. Oyunun 3. bölümünde iki farklı yol ya da rota planlaması yapılmıştır. Katılımcılardan bu iki farklı rota planlamasını ilk etapta gerçek İHA kumandası ile takip etmeleri istenmektedir. Daha sonra ise EEG ve EMG cihazları takılarak EEG ve EMG sinyalleri ile oyundaki rota planlamasını takip etmeleri istenmektedir. Son olarak hem gerçek kumanda ile yapılan takibin doğruluk oranı, hem EEG ve EMG sinyalleri ile yapılan takibin doğruluk oranı hem de EEG ve EMG sinyalleri ile yapılan takibin gerçek kumandaya göre başarısı test edilmiştir. Başarı oranları rota takibinin asıl rotaya göre korelasyonu ile hesaplanmıştır.




Şekil S.4. a) Oyun ortamındaki birinci yol b) MATLAB’a aktarılmış çizimi

Şekil S.4’de oyun ortamında oluşturulmuş birinci yol olup performans testlerinin yapılması amacı ile Unity 3D programında tasarlanmıştır. Bu yolun koordinatları x ve y düzlemlerinde çıkarılmış olup rota planı takibinin performansı bu koordinatlara göre yapılmaktadır. Birinci yol ikinci yola göre zorluk derecesi bakımından daha kolaydır. Keskin dönüşleri bulunmamaktadır ve katılımcılar oyunu ilk olarak bu yolda oynamaktadırlar. Uzunluk olarak da ikinci yola nazaran daha kısadır.



Şekil S.5. a) Oyun ortamındaki ikinci yol b)MATLAB’a aktarılmış çizimi

Şekil S.5’de oyun ortamında oluşturulmuş ikinci yol verilmiş olup performans testlerinin yapılması amacı ile Unity 3D programında tasarlanmıştır. Bu yolun koordinatları da x ve y düzlemlerinde elde edilmiş olup rota planı takibinin performansı bu koordinatlara göre yapılmaktadır. Bölümün ikinci yolunda sağa ve sola keskin dönüşler bulunmaktadır ve katılımcılar oyunu ilk olarak birinci yolda oynadıktan sonra ikinci yola geçmektedirler.



Şekil S.6. Gerçek kumanda ile birinci rota planlamasının takibi


Şekil S.6’da gerçek İHA kumandası ile birinci rota planlamasının takibi görülmektedir. Şekilden anlaşıldığı üzere rotanın İHA kumandası ile yüksek doğrulukla takip edildiği açıktır. Yeşil renkle temsil edilen katılımcının 1050x1100 ve 950x500 noktalarında rotadan çıktığı görülmektedir. Bunun nedeni kumanda joystiğinin o bölgelerde arızalanmasıdır. Tablo S.11’de ve Şekil S.6’daki çizimin korelasyon yöntemi sayesinde benzerlik oranları veya takip performansları sayısal olarak belirtilmiştir.

Tablo S.11: Gerçek kumanda ile birinci rota planlamasının takip performansları

Katılımcı	X - Eksenli takip performansı	Y - Eksenli takip performansı	Ortalama performans
1	97.98 %	97.55 %	97.76 %
2	99.34 %	98.78 %	99.06 %
3	95.64 %	96.15 %	95.89 %
Genel Ortalama:			97.57 %

Tablo S.11’de gerçek kumanda ile birinci rota planlamasının takip performansları verilmiştir. Bu verilere göre siyah renkle temsil edilen katılımcı 99.06 % benzeme oranıyla neredeyse birinci yolu birebir takip etmiştir. Kumanda ile ortalama 97.57 %

performans ile birinci rota planı üç katılımcı tarafından yüksek doğrulukta takip edilmiştir.




Şekil S.7. EEG ve EMG sinyalleri ile birinci rota planlamasının takibi

Şekil S.7’de EEG ve EMG sinyalleri ile birinci rota planlamasının takibi görülmektedir. Şekilden anlaşıldığı üzere rotanın EEG ve EMG sinyalleri ile yüksek doğrulukla takip edildiği görülmektedir. Şekil S.6’daki kumanda ile takibe nazaran rota planı ile üst üste çakışmalar daha azdır. Tablo S.12’de, Şekil S.7’deki çizimin korelasyon yöntemi kullanılarak benzerlik oranı veya takip performansları sayısal olarak hesaplanmıştır.

Tablo S.12: EEG ve EMG sinyalleri ile birinci rota planlamasının takip performansları

Katılımcı	x-ekseni takip performansı	y-ekseni takip performansı	Ortalama performans
1	98.94 %	99.06 %	99.00 %
2	99.06 %	99.40 %	99.23 %
3	99.20 %	99.47 %	99.33 %
Genel Ortalama:			99.18 %

Tablo S.12’de EEG ve EMG sinyalleri ile birinci rota planlamasının takip performansları verilmiştir. Ortalama 99.18 % performans ile birinci rota planı üç katılımcı tarafından yüksek doğrulukta takip edilmiştir.




Şekil S.8. EEG ve EMG sinyalleri ile takibin ortalaması ile kumanda ile takibin ortalaması

Şekil S.8’de EEG ve EMG sinyalleriyle takibin kumandayla takibe benzerliği görülmektedir. Şekilden de anlaşıldığı üzere Tablo S.11 ve Tablo S.12’deki verilerin doğrulandığı görülür. Mavi renkli çizim ile kırmızı renkli çizimin birbiri ile aynı olmasa da birbirlerine ana hatlarıyla çok benzedikleri görülmektedir. Tablo S.13’de, Şekil S.8’deki çizimin korelasyon yöntemi kullanılarak benzerlik oranı sayısal olarak hesaplanmıştır.

Tablo S.13: EEG ve EMG sinyalleri ile takibin kumanda ile takibe benzerlik oranı

X - Ekseni benzerlik	Y - Ekseni benzerlik	Ortalama benzerlik
99.29 %	99.23 %	99.26 %

Tablo S.13’de EEG ve EMG sinyalleriyle takibin kumanda ile takibe benzerlik oranı verilmiştir. EEG ve EMG sinyalleriyle takip kumanda ile takibe ortalama 99.26 % oranında benzemektedir.



Şekil S.9. Gerçek kumanda ile ikinci rota planlamasının takibi


Şekil S.9’da gerçek İHA kumandası ile ikinci rota planlamasının takibi görülmektedir. Şekilde görüldüğü üzere, rotanın İHA kumandası ile yüksek doğrulukla takip edildiği açıktır. Tablo S.14’de, Şekil S.9’daki çizimin korelasyon yöntemi ile benzerlik veya takip performansları sayısal olarak belirtilmiştir.

Tablo S.14: Gerçek kumanda ile ikinci rota planlamasının takip performansları

Katılımcı	x-ekseni takip performansı	y-ekseni takip performansı	Ortalama performans
1	98.82 %	99.45 %	99.13 %
2	97.35 %	98.85 %	98,10 %
3	98.39 %	98.92 %	98.65 %
Genel Ortalama:			98.62 %

Tablo S.14’de gerçek kumanda ile ikinci rota planlamasının takip performansları verilmiştir. Bu verilere göre kırmızı renkle temsil edilen katılımcı 99.13 % benzeme oranıyla neredeyse ikinci yolu birebir takip etmiştir. Kumanda ile ortalama 98.62 %

performans ile ikinci rota planı üç katılımcı tarafından yüksek doğrulukta takip edilmiştir.




Şekil S.10. EEG ve EMG sinyalleri ile ikinci rota planlamasının takibi

Şekil S.10'da EEG ve EMG sinyalleri ile ikinci rota planlamasının takibi görülmektedir. Şekle bakıldığında rotanın EEG ve EMG sinyalleri ile yüksek doğrulukla takip edildiği görülmektedir. Tablo S.15'de, Şekil S.10'daki çizimin korelasyon yöntemi kullanılarak benzerlik oranı veya takip performansları sayısal olarak hesaplanmıştır.

Tablo S.15: EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları

Katılımcı	X - Ekseni takip performansı	Y - Ekseni takip performansı	Ortalama performans
1	97.94 %	99.14 %	98.54 %
2	97.62 %	98.93 %	98.27 %
3	96.04 %	98.81 %	97.42 %
Genel Ortalama:			98.07 %

Tablo S.15’de EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları verilmiştir. Ortalama 98.07 % performans ile ikinci rota planı üç katılımcı tarafından yüksek doğrulukta takip edilmiştir. Birinci rota planı takibine göre performansın azda olsa düşmesi ikinci rota planının zorluğundan kaynaklanmaktadır.



Şekil S.11. İkinci rota planlamasında EEG ve EMG sinyalleri ile takibin ortalaması ile kumanda ile takibin ortalaması

Şekil S.11’de EEG ve EMG sinyalleriyle takibin kumandayla takibe benzerliği görülmektedir. Şekilden anlaşıldığı üzere Tablo S.14 ve Tablo S.15’deki verilerin doğrulandığı görülmektedir. Mavi renkli çizim ile kırmızı renkli çizimin birbiri ile aynı olmasa da birbirlerine ana hatlarıyla çok benzedikleri anlaşılmaktadır. Tablo S.16’da, Şekil S.11’deki çizimin korelasyon yöntemi kullanılarak benzerlik oranı sayısal olarak hesaplanmıştır.

Tablo S.16: EEG ve EMG sinyalleri ile takibin kumanda takibine benzerlik oranları

X - Ekseni benzerlik	Y - Ekseni benzerlik	Ortalama benzerlik
99.38 %	99.94 %	99.66 %

Tablo S.16’ da EEG ve EMG sinyalleriyle takibin kumanda ile takibe benzerlik oranı verilmiştir. EEG ve EMG sinyalleriyle takip kumanda ile takibe ortalama 99.66 % oranında benzemektedir. Bu oran doğal olarak birinci rota takibinde ki sonuçlara oldukça yakındır.


GERÇEK İHA ÜZERİNDE YAPILAN DENEYLERİN SONUCU

Sistemin gerçek İHA üzerinde denenebilmesi için oluşturulmuş 2 farklı yol ya da rota planlaması bulunmaktadır. Bu rotalardan ilki 8 rakamı şeklinde olup ikincisi zikzak şeklinde planlanmıştır. Bu iki farklı rota planlaması ilk etapta gerçek İHA kumandası ile takip edilmektedir. Daha sonra ise EEG ve EMG cihazları takılarak EEG ve EMG sinyalleri ile platform üzerindeki rota planlaması takip edilmektedir. En sonunda ise hem gerçek kumanda ile yapılan takibin doğruluk oranı, hem EEG ve EMG sinyalleri ile yapılan takibin doğruluk oranı hem de EEG ve EMG sinyalleri ile yapılan takibin gerçek kumandaya göre başarısı test edilmiştir. Bu testler Şekil S.12’de görülen 22x28 noktadan oluşan platform üzerinde gerçekleştirilmiştir.




Şekil S.12. Gerçek İHA’da deneyler için oluşturulan platform

Şekil S.12’de zemine yapıştırma bantları ile oluşturulan deney platformu görülmektedir. Kırmızı işaretlenen noktalar kare şeklinde olan fayansların köşeleridir.



Şekil S.13. İHA'nın uçuşu sırasında lazer işaretleyici (yuvarlak içine alınmış)

İnsansız hava aracının altına Şekil S.13'de görüldüğü üzere lazer işaretleyici monte edilmiştir. İHA rota planları üzerinde uçurulurken kamera vasıtasıyla lazer işaretleyicinin işaretlediği noktalar video olarak kaydedilmiştir. Daha sonra kaydedilen video ağır çekimde izlenerek İHA'nın geçtiği koordinatlar MATLAB ortamına elle girilmiştir. Bu deneyler sadece tez öğrencisi tarafından iki rota planlaması için ikişer defa yapılmıştır. Başarı oranları oyunda olduğu gibi rota takibinin asıl rotaya göre korelasyonu ile hesaplanmıştır.




Şekil S.14. İki farklı oturumda gerçek kumanda ile elde edilen birinci rota planlamasının takibi

Şekil S.14'te gerçek İHA kumandası ile platform üzerinde ki birinci rota planlamasının takibi görülmektedir. Şekle bakıldığında rotanın İHA kumandası ile yüksek doğrulukla takip edildiği görülmektedir. Platformdaki takibin oyundaki takibe göre daha başarısız gibi görünmesinin sebebi oyundaki alanın platformdaki alandan daha büyük olmasından kaynaklanmaktadır. Tablo S.17'de, Şekil S.14'deki çizimin korelasyon yöntemi ile benzerlik veya takip performansları sayısal olarak belirtilmiştir.

Tablo S.17: Kumanda ile birinci rota planlamasının takip performansları

Oturum	X - Eksen takibi performansı	Y - Eksen takibi performansı	Ortalama performans
1	94.35 %	98.62 %	96.48 %
2	94.37%	98.71 %	96.54 %
Genel Ortalama:			96.51 %

Tablo S.17'de gerçek kumanda ile birinci rota planlamasının takip performansları verilmiştir. Kumanda ile ortalama 96.51 % performans ile birinci rota planı yüksek doğrulukla takip edilmiştir.




Şekil S.15. İki farklı oturumda EEG ve EMG sinyalleri ile birinci rota planlamasının takibi

Şekil S.15'te EEG ve EMG sinyalleri ile birinci rota planlamasının takibi görülmektedir. Şekilden anlaşıldığı üzere rotanın EEG ve EMG sinyalleri ile yüksek doğrulukla takip edildiği görülmektedir. Şekil S.14'deki kumanda ile takibe nazaran biraz daha başarısız görünmesinin nedeni İHA'nın komut gönderilmeyen zamanlarda sürüklenmesinden kaynaklanmaktadır. Tablo S.18'de, Şekil S.15'teki çizimin korelasyon yöntemi kullanılarak benzerlik oranı veya takip performansları sayısal olarak hesaplanmıştır.

Tablo S.18: EEG ve EMG sinyalleri ile birinci rota planlamasının takip performansları

Oturum	X-Eksen takip performansı	Y-Eksen takip performansı	Ortalama performans
1	91.48 %	99.21 %	95.34 %
2	80.88 %	95.27 %	88.07 %
Genel Ortalama:			91.70 %

Tablo S.18’de EEG ve EMG sinyalleri ile birinci rota planlamasının takip performansları verilmiştir. Ortalama 91.70 % performans ile birinci rota planı yüksek doğrulukta takip edilmiştir.




Şekil S.16. Kumanda ile EEG ve EMG sinyalleri ile yapılan rota takibinin benzerlikleri

Şekil S.16’da EEG ve EMG sinyalleriyle takibin kumandayla takibe benzerliği görülmektedir. Şekilden anlaşıldığı üzere Tablo S.17 ve Tablo S.18’deki verilerin doğrulandığı görülür. Mavi renkli çizim ile kırmızı renkli çizimin birbiri ile aynı olmasa da birbirlerine ana hatlarıyla çok benzedikleri görülmektedir. Tablo S.19’da, Şekil S.16’daki çizimin korelasyon yöntemi kullanılarak benzerlik oranı sayısal olarak hesaplanmıştır.

Tablo S.19: Kumanda ile EEG ve EMG sinyalleri ile yapılan rota takibinin benzerlik oranları

X-Ekseni benzerlik	Y-Ekseni benzerlik	Ortalama benzerlik
86.48 %	95.18%	90.83 %

Tablo S.13’de EEG ve EMG sinyalleriyle takibin kumanda ile takibe benzerlik oranı verilmiştir. EEG ve EMG sinyalleriyle takip kumanda ile takibe ortalama 90.83 % oranında benzemektedir. Bu oranın oyuna göre düşük olmasının sebebi İHA’nın komut almadığı durumlarda sürüklenmenin etkisiyle konumunu koruyamamasından dolayıdır.




Şekil S.17. İki farklı oturumda gerçek kumanda ile elde edilen ikinci rota planlamasının takibi

Şekil S.17’de gerçek İHA kumandası ile ikinci rota planlamasının takibi görülmektedir. Şekilden anlaşıldığı üzere rotanın İHA kumandası ile yüksek doğrulukla takip edildiği açıktır. Tablo S.20’de, Şekil S.17’deki çizimin korelasyon yöntemi ile benzerlik oranı veya takip performansları sayısal olarak belirtilmiştir.

Tablo S.20: Kumanda ile ikinci rota planlamasının takip performansları

Oturum	X-Ekseni takip performansı	Y-Ekseni takip performansı	Ortalama performans
1	89.19 %	98.94 %	94.06 %
2	94.87 %	99.63 %	97.25 %
Genel Ortalama:			95.65 %

Tablo S.20’de gerçek kumanda ile ikinci rota planlamasının takip performansları verilmiştir. Kumanda ile ortalama 95.65 % performans ile ikinci rota planı yüksek doğrulukta takip edilmiştir.




Şekil S.18. İki farklı oturumda EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları

Şekil S.18’de EEG ve EMG sinyalleri ile ikinci rota planlamasının takibi görülmektedir. Şekilden anlaşıldığı üzere rotanın EEG ve EMG sinyalleri ile yüksek doğrulukla takip edildiği görülmektedir. Tablo S.21’de, Şekil S.18’deki çizimin korelasyon yöntemi kullanılarak benzerlik oranı veya takip performansları sayısal olarak hesaplanmıştır.

Tablo S.21: EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları

Oturum	X-Ekseni takip performansı	Y-Ekseni takip performansı	Ortalama performans
1	97.66 %	99.59 %	98.62 %
2	94.68 %	99.04 %	96.86 %
Genel Ortalama:			97.74 %

Tablo S.21’de EEG ve EMG sinyalleri ile ikinci rota planlamasının takip performansları verilmiştir. Ortalama 97.74 % performans ile ikinci rota planı yüksek doğrulukta takip edilmiştir. Birinci rota planı takibine göre performansın artması ikinci rota planının kolaylığından kaynaklanmaktadır.



Şekil S.19. EEG ve EMG sinyalleri ile ikinci rota planlaması takibinin kumanda ile takibe benzerliği

Şekil S.19’da EEG ve EMG sinyalleriyle takibin kumandayla takibe benzerliği görülmektedir. Şekilden anlaşıldığı üzere Tablo S.20 ve Tablo S.21’deki verilerin doğrulandığı görülmektedir. Mavi renkli çizim ile kırmızı renkli çizimin birbiri ile aynı olmasa da birbirlerine ana hatlarıyla çok benzedikleri anlaşılmaktadır. Tablo S.22’de, Şekil S.19’daki çizimin korelasyon yöntemi kullanılarak benzerlik oranı sayısal olarak hesaplanmıştır.

Tablo S.22: EEG ve EMG sinyalleri ile ikinci rota planlaması takibinin kumanda ile takibe benzerlik oranları

X-Ekseni benzerlik	Y-Ekseni benzerlik	Ortalama benzerlik
90.77 %	99.04 %	94.90 %

Tablo S.22’de EEG ve EMG sinyalleriyle takibin kumanda ile takibe benzerlik oranı verilmiştir. EEG ve EMG sinyalleriyle takip kumanda ile takibe ortalama 94.90 % oranında benzemektedir.

Bu tez çalışmasında elde edilen sonuçlara göre, oyun içerisinde iki farklı rota ve 9 oturum, gerçek İHA üzerinde iki farklı rota planlaması ve 6 oturum gerçekleştirilmiştir. Testler incelendiğinde teoride hesaplanan bulgular hem oyun ortamında hem de gerçek İHA üzerinde elde edilen sonuçlarla örtüşmektedir. Tablo S.23’te görüldüğü üzere EEG + EMG sinyalleri kullanılarak oyun ortamında İHA ile rota takibinin başarı oranı 98.62 %, gerçek İHA üzerinde başarı oranı 94.72 % olarak elde edilmiştir. Bu iki rota takip başarı oranı ortalaması da 96.67 %’dir. EEG+EMG ile kontrolün, kumanda ile kontrole olan benzerliği ise oyunda 99.46 %, gerçek İHA üzerinde benzerlik oranı 92.86 % olarak elde edilmiş olup ikisinin ortalaması da 96.16 % ‘dir.

Tablo S.23: Uygulama ortamlarında elde edilen sonuçlar.

Uygulama Ortamı	Kontrol Yöntemi	Rota Planı 1 Sonuçları	Rota Planı 2 Sonuçları
OYUN	Kumanda	97.57 %	98.62 %
	Ort. Performans		98.09 %
	EEG+EMG	99.18 %	98.07 %
	Ort. Performans		98.62 %
	Kumanda ile EEG+EMG benzerlik oranı	99.26 %	99.66 %
	Ort. Benzerlik		99.46 %
GERÇEK İHA	Kumanda	96.51 %	95.65 %
	Ort. Performans		96.08 %
	EEG+EMG	91.70 %	97.74 %
	Ort. Performans		94.72 %
	Kumanda ile EEG+EMG benzerlik oranı	90.83 %	94.90 %
	Ort. Benzerlik		92,86 %

Tablo S.23’den anlaşıldığı üzere uygulamada bulunan sonuçların teoride bulunan sonuçlardan daha iyi olduğu görülmektedir. Bunun nedeni hem oyunda hem de gerçek İHA kontrolünde EEG sinyallerinin sadece İHA’yı yükseltme ve alçaltma yönlendirmeleri için kullanılmış olmasıdır. EEG sinyalleri ile İHA’ya sadece yükselme komutu gönderilmekte ve İHA önceden ayarlanan yüksekliğe otomatik ulaşmaktadır. EMG sinyalleriyle de İHA, bu sabit yükseklikte sağa-sola, ileri-geri yönlendirilmektedir. Aynı şekilde iniş için EEG ile komut gönderilmekte ve İHA alçalmaktadır. Böylelikle oldukça kararsız olan EEG sinyallerinden azami ölçüde faydalanılmış olunmaktadır. Performans azaltıcı etkisi de önlenmiştir. Bundan dolayı rota takibinde sadece EMG kullanılmaktadır ve EMG’nin başarısı, rota takibinde belirleyici olmaktadır.

Buna rağmen yine de teoride EMG’nin ortalama sınıflandırma başarısı 92.75 % iken uygulamada ortalama 96.67 % olarak saptanmış olup bu sonuç ile küçümsenemeyecek bir başarı elde edilmiştir. Bunun da nedeni oyunda ve gerçek İHA kontrolündeki İHA’nın hareket hızı EMG sinyalinin alınıp, işlenip, komuta dönüştürülüp oyuna veya İHA’ya gönderilene kadar geçen süre baz alınarak optimize edilmesidir. Böylelikle kullanıcı tarafından yanlış komut gönderilse bile İHA çok fazla yer değiştirmeden bu hatadan dönülebilmektedir. Ayrıca rota takibinde kullanıcı hangi hareketi önceden yapacağını bilmektedir ve bu da rotaya aşinalık ve kullanma kolaylığı açısından bir avantajdır.

Yapılan deneylere göre EEG ve EMG ile kontrolün performansı kumanda kadar iyi sonuçlar vermektedir. Deneylerde EEG ve EMG sinyalleri ile bir İHA’nın kontrol edilebildiğini gösterebilmek adına İHA’nın hızı belirli sınırlar içerisinde kullanılmıştır. Çok daha hızlı komut göndermek gereken bir yapı için kesinlikle EEG ve EMG sinyalleri, kumanda ile kontrole göre çok daha yavaş kalacaktır. Bu olumsuzluk EMG ve EEG ile kontrolün yanlışlığından veya yetersizliğinden ziyade sinyalin alınıp, işlenip, komut olarak gönderilmesinin zaman almasından kaynaklanmaktadır. Bu eksiklik bilişim alanında kullanılan hızlı sistemlerle çözülebilir. Bu nedenle hızlı sistemlerde kumanda ile daha başarılı sonuçlar alınabilir. Fakat yavaş sistemlerde EEG ve EMG sinyalleri ile kontrol daha rahat ve zahmetsizdir. Çünkü eller meşgul olmamakla birlikte kumanda gibi bir yük taşınmamaktadır.

Değinilmesi gereken diğ er bir husus oyundaki ve ger ek İHA kontrol ndeki rota takibinin  izimleridir. Bu  izimler incelendiğ inde oyuna ait rota ve rotayı takip etme  izimlerinin birbiri ile neredeyse  akıřtığ ı g r lmektedir. Bařarı oranı 95 % seviyelerindedir. Fakat ger ek İHA kontrol nde rotalar ve takip  izimleri ana hatlarıyla birbirlerine benzemektedirler. Bunun nedeni İHA'ya monte edilmiř lazer iřaretleyicinin g sterdiğ i noktaların sonradan videodan izlenerek manuel olarak MATLAB ortamına aktarılmasıdır. Sınırlı sayıda noktaların MATLAB ortamına aktarılması nedeniyle yumuřak bir  izim yerine daha keskin hatları olan  izimler ortaya  ıkmıřtır. Yani s rekli bir  izim yerine  rneklenmiř bir  izim oluřmuřtur.

Bir diğ er husus ise oyundaki rota planlarının 8000x3500 noktadan oluřan bir d zlem  zerinde bulunması nedeniyle takipteki hatanın  ok b y k seviyeler dıřında hissedilmemesidir. Oysaki ger ek İHA ile yapılan testlerde platform d zlemi 22x28 noktadan oluřmakta ve k   k oranda bir sapma bile  ok belli olmaktadır. Yani kısacası oyundaki rota takibi  izimlerine de odaklanıldığında aslında m kemmel bir takip yerine ger ek İHA kontrol ndeki takip gibi bir takibin olduğ  g r lm řt r.

TARTIŞMA VE ÖNERİLER

Bu tez çalışmasında EEG ve EMG sinyalleri ile hem bilgisayar oyunundaki İHA hem de gerçek bir İHA kontrolü üzerine çalışılmıştır. Elde edilen sonuçlar teoride, oyunda ve gerçek dünyada birbirleri ile uyumludur. Böylelikle birçok aleti, oyuncacı veya makineyi kontrol etmekte kullanılan pahalı eldivenlere, joystiklere veya kumandalara alternatif sunulmuştur. Kısmi ortopedik engelli bireylere kullanışlı bir sistem tasarlanmış, birçok alanda veya sektörde oldukça sık kullanılan dört rotorlu insansız hava aracı kontrolüne yeni bir boyut kazandırılmıştır. Ayrıca sanal gerçeklik üzerine kurulu özgün bir bilgisayar oyunu kullanıcılar için tasarlanmıştır. Bu amaç için EEG ve EMG sinyalleri bir arada kullanılmıştır.

Bu çalışmada, başparmak EMG sinyallerinin kullanılma nedenleri, başparmak kaslarının kolay yerde olması ve sinyale ulaşmanın zahmetsiz olmasıdır. Başparmak EMG sinyalinin etkin ve kolay bir şekilde alınmasının yanında başparmağın 0-360 derece arasındaki açılarda harekete sahip olmasıdır. Bu özelliklerinden dolayı özellikle yön ve yönlendirme kavramı bulunan işlemlerde serbestliğinin yüksek olması bir avantaj olarak ortaya çıkmıştır. Başparmak hareketlerinin bir diğer avantajı da sınırlı alanda kolayca hareket ettirilmesidir. Tek kanallı bir EMG cihazı ile bile başparmağın hareketleri yüksek doğrulukta sınıflandırılmaktadır. Bu nedenle İHA yönlendirmede başparmak hareketleri son derece kullanışlı olmuştur.

Yoğunlaşma durumuna bağlı EEG sinyallerinin avantajı; beynin yoğunlaşma veya dikkatini toplama anında ön lobda aktivitesi artmaktadır. Ön lobdan FP1 elektrodu ile veri almak diğer noktalara göre daha kolaydır. Çünkü alın bölgesinde saç gibi sinyal kalitesini etkileyecek unsurlar bulunmamaktadır. Yoğunlaşma zihinsel aktivitesi, hayal etme aktivitesine göre kişiden kişiye göre daha az değişkendir ve daha sürdürülebilirdir. Bu nedenle yoğunlaşma zihinsel aktivitesinin kullanımı diğer beyin aktivitelerine göre daha etkin sonuçların elde edilmesine olanak tanımaktadır.

Bu çalışmada daha kaliteli ve daha çok kanallı biyolojik veri alma cihazları kullanılarak daha başarılı ve fonksiyonlu uygulamalar geliştirilebilir. EEG ve EMG sinyallerinin MATLAB ortamında ayrı ayrı ve ardışık bir şekilde işlenmesi hız problemi doğurmaktadır. Bu hız problemi paralel işlem yapabilme yeteneğine sahip

yapılar kullanılması halinde büyük çoğunlukla aşılacaktır. Bir diğer hız sınırlayıcı problem de kullanılan veri alma cihazlarının örnekleme frekanslarının düşük olmasıdır. Örnekleme frekansı yüksek cihazlar kullanılarak daha kısa süreli ve daha çok bilgi içeren sinyaller elde edilebilmektedir. Böylelikle kısa süreli sinyaller vasıtasıyla birim zaman süresince daha çok komut çıkarımı yapılabilmektedir.

Bu çalışmada kullanılan oyuncak İHA yerine daha gelişmiş, bilgisayardan wi-fi veya bluetooth ile yönetilebilen profesyonel İHA kullanılması halinde sistemin kullanışlılığı ve performansı daha da artacaktır. Çünkü kullanılan İHA'ya komut gönderiminde kullanılan ses dosyaları 0,05 saniye gibi belirli bir süreyi işgal etmektedir. Bu süre hızlı değişkenlik gösteren sistemler için oldukça uzun bir süredir. Bu seslerin ara mikroişlemci tarafından algılanıp DAC ile istenilen gerilimlere çevrilip kumandaya aktarılması gecikmelere sebep olmaktadır. Ayrıca bu tezde kullanılan İHA'da konum koruma veya konum kilitleme özelliği bulunmamaktadır. Bu nedenle oyuncak İHA kullanıcı tarafından komut gönderilmese bile doğal sürüklenmelerle konumunu sürekli olarak değiştirmektedir. Bu sürüklenmeyle konum değiştirme rota takibinde sapmalara ve zorluklara neden olmuştur. Bu nedenle komut gönderilmediğinde anlık konumunu değiştirmeyen kaliteli İHA ile çalışmalar yapılmalıdır.

Bu sistemin aktif olarak kullanılabilmesi için kullanılan biyolojik veri alma cihazlarının taşınabilir, kablosuz ve kuru elektrot sistemine sahip olması önemlidir. EEG cihazının elektrotları solüsyon ile ıslatılarak kullanılmaktadır. Bu nedenle kullanıcıya hem rahatsızlık vermekte hem de zamanla solüsyon miktarındaki azalmalar sinyal kalitesini düşürmektedir. Sürekli olarak elektrotlara solüsyon takviyesi ise zaman kaybına yol açmaktadır. Ayrıca solüsyon maliyetini de doğurmaktadır. Kullanılan EMG cihazının kablolu tip olması ise hareketi kısıtlamakta ve ayrıca hareket anında veya kabloların sallanması durumunda EMG sinyaline gürültüler bindirmektedir. Bu nedenlerden dolayı kuru elektrot sistemine sahip kablosuz cihazlar kullanılmalıdır.

Bu tez uygulamasında biyolojik veri alma cihazlarından alınan veriler bir bilgisayarda işlenmekte ve bilgisayardan komutlar iletilmektedir. Ancak bilgisayarın varlığı hem uygulamanın kullanışlılığını düşürmekte hem de taşınabilirlik ve maliyet açısından

bilgisayar bir yük olmaktadır. Bu nedenle gerçekleştirilen uygulama Raspberry ya da benzeri mikrobilgisayar yapıları ile uygulanarak bilgisayar problemi ortadan kaldırılabılır ve sistem yüksek oranda taşınabilir hale dönüştürülebilir. Sisteme ayrıca atalet sensörleride eklenerek daha çok ve daha etkin komutların çıkarımı sağlanabilmektedir.

Böyle bir çalışma CPU (Merkezi İşlem Birimi) ile klasik sinyal işleme adımları ile yapılması yerine son yıllarda kullanımı oldukça artan daha hızlı GPU (Grafik İşlemci Ünitesi) ile derin öğrenme yöntemleri kullanılarak da yapılabilir. Böylece daha hızlı sistemler geliştirilmiş olur.



KAYNAKLAR

1. Reilly R. B. and Lee T. C., “Electrograms (ECG, EEG, EMG, EOG),” Technol. Heal. Care, vol. 18, no. 6, pp. 443–458, Ocak. 2010.
2. Mcadams E., “Bio-Medical CMOS ICs,” Springer, no. Aralık 2010, pp. 31–124, 2011.
3. Sturman D. J. and Zeltzer D., “A survey of glove-based input,” IEEE Comput. Graph. Appl., vol. 14, no. 1, pp. 30–39, Ocak 1994.
4. Liu H., et al, Human motion sensing and recognition : a fuzzy qualitative approach. ISBN: 978-3-662-53692-6, 2017
5. Dipietro L., Sabatini A. M., and Dario P., “A Survey of Glove-Based Systems and Their Applications,” Appl. Rev., vol. 38, no. 4, 2008.
6. Peddie J., Augmented reality : where we will all live. .2017, ISBN: 978-3-319-54502-8
7. Nandnikar D.,et al, “Sensorized Glove for Rehabilitation Purpose,” Int. J. Eng. Res. Gen. Sci., vol. 3, no. 3, pp. 189–194, 2015.
8. <http://www.angelfire.com/ca7/mellott124/glove1.htm>. [Eriřim Tarihi: 12-Eylöl-2017].
9. LaViola J. J., “A survey of hand posture and gesture recognition techniques and technology.”,Brown University, 1999
10. Pamplona V. F., et al, “The Image-Based Data Glove.” Proceedings of Symposium on Virtual Reality (SVR'2008), João Pessoa, (ISBN: 857669174-4). pp. 204-211,2008
11. Mascaro S. and Asada H. H., “Finger posture and shear force measurement using fingernail sensors: Initial experimentation.” Robotics and Automation Conference, Seoul, Korea 2001.
12. Hernandez-Rebollar J. L., Kyriakopoulos N., and Lindeman R. W., “The AcceleGlove: A Whole-Hand Input Device for Virtual Reality.”Acm Siggraph,p.259,2002
13. S. H. Howard Bruce, “Lightglove: Wrist-Worn Virtual Typing and Pointing.” <http://www.cs.columbia.edu/~feiner/courses/mobwear/resources/Lightglove.pdf>. [Eriřim Tarihi: 12-Eylöl-2017].

14. "Humanglove." : <http://www.hmw.it/en/humanglove.html>. [Eriřim Tarihi: 12-Eylöl-2017].
15. "Data Gloves | 5DT." [Online]. Available: <http://www.5dt.com/data-gloves/>. [Eriřim Tarihi: 12-Eylöl-2017].
16. Saha D. P., et al, "Design of a Wearable Two-Dimensional Joystick as a Muscle-Machine Interface Using Mechanomyographic Signals," Virginia Polytechnic Institute and State University, 2013.
17. Mason S. G. and Birch G. E., "A brain-controlled switch for asynchronous control applications," IEEE Trans. Biomed. Eng., vol. 47, no. 10, pp. 1297–1307, Ekim. 2000.
18. Postelnicu C. C., Talaba D., and Toma M. I., "Controlling a Robotic Arm by Brainwaves and Eye Movement," Springer, Berlin, Heidelberg, 2011, pp. 157–164.
19. Donchin E., Spencer K. M., and Wijesinghe R., "The mental prosthesis: assessing the speed of a P300-based brain-computer interface," IEEE Trans. Rehabil. Eng., vol. 8, no. 2, pp. 174–179, Haziran 2000.
20. Blankertz B. et al., "The Berlin Brain-Computer Interface Presents The Novel Mental Typewriter Hex-O-Spell" Proceedings of the 3rd International Brain-Computer Interface Workshop and Training Course, Graz, Austria, 2006, pp. 108-109.
21. Blankertz B., et al, "A Note on Brain Actuated Spelling with the Berlin Brain-Computer Interface," in Universal Access in Human-Computer Interaction. Ambient Interaction, Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, pp. 759–768.
22. Vanacker G., et al., "Context-based filtering for assisted brain-actuated wheelchair driving," Comput. Intell. Neurosci., vol. 2007, p. 25130, Jul. 2007.
23. Guger C., et al, "Prosthetic Control by an EEG-based Brain- Computer Interface (BCI)." Proc. aaate 5th european conference for the advancement of assistive technology, 1999.
24. Vaughan T. M., et al., "The Wadsworth BCI Research and Development Program: At Home With BCI," IEEE Trans. Neural Syst. Rehabil. Eng., vol. 14, no. 2, pp. 229–233, Haziran. 2006.
25. Ebrahimi T., Vesin J. M., and Garcia G., "Brain-computer interface in multimedia communication," IEEE Signal Process. Mag., vol. 20, no. 1, pp. 14–

24, Ocak 2003.

26. Lotte F. et al., “Combining BCI with Virtual Reality: Towards New Applications and Improved BCI.” Springer, 2013.
27. Dulantha Lalitharatne T., et al “Towards Hybrid EEG-EMG-Based Control Approaches to be Used in Bio-robotics Applications: Current Status, Challenges and Future Directions,” PALADYN J. Behav. Robot. Rev. Artic., vol. 4, no. 2, pp. 147–154, 2013.
28. Wolpaw J. R., et al “Brain-computer interfaces for communication and control,” Clin. Neurophysiol., vol. 113, no. 6, pp. 767–91, Haziran 2002.
29. Wolpaw J. R., McFarland D. J., and Vaughan T. M., “Brain-computer interface research at the Wadsworth Center,” IEEE Trans. Rehabil. Eng., vol. 8, no. 2, pp. 222–6, Haziran 2000.
30. Vaughan T. M., Wolpaw J. R., and Donchin E., “EEG-based communication: prospects and problems,” IEEE Trans. Rehabil. Eng., vol. 4, no. 4, pp. 425–30, Aralık 1996.
31. Punsawad Y., Wongsawat Y., and Parnichkun M., “Hybrid EEG-EOG brain-computer interface system for practical machine control,” in 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology, 2010, pp. 1360–1363.
32. Leeb R., H., et al, “A hybrid brain–computer interface based on the fusion of electroencephalographic and electromyographic activities,” J. Neural Eng., vol. 8, no. 2, p. 25011, Nisan 2011.
33. Leeb R., et al, “Multimodal Fusion of Muscle and Brain Signals for a Hybrid-BCI,” in 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology, 2010, pp. 4343–4346.
34. Roy R., Konar A., and Tibarewala, “Control of artificial limb using EEG and EMG - a review,” in AICTE Sponsored National Conference, BERA-2011, At JIS College of Engineering, India, 2011.
35. Wang H., et al, “An asynchronous wheelchair control by hybrid EEG-EOG brain-computer interface,” Cogn. Neurodyn., vol. 8, no. 5, pp. 399–409, Ekim 2014.
36. Barachant A., et al, “Extraction of motor patterns from joint EEG/EMG recording: A Riemannian Geometry approach,” 6th International Brain-Computer Interface Meeting, Monterey, May 2016

37. Kim B., et al, "Cross-association analysis of EEG and EMG signals according to movement intention state," *Cogn. Syst. Res.*, vol. 44, pp. 1–9, Ağustos 2017.
38. Rakesh H., et al, "EEG & EMG Controlled Driving Aid for Electric Wheelchairs: Review," *Int. J. Adv. Netw. Appl.*, no. 4.
39. Gilstrap Andrew W. A., Kendal H., Chris W., "Neuro Drive | SDSU." http://mechanical.sdsu.edu/mechanical/neuro_drive.aspx? [Erişim Tarihi: 24-Eylül-2017].
40. Powell Andrew I. J., Christian W., James K., "GetRekt's EMG / EEG Controlled RC Car | Hackaday.io." <https://hackaday.io/project/15310-getrekts-emg-ee-g-controlled-rc-car>. [Erişim Tarihi: 24-Eylül-2017].
41. Kim B. H., Kim M., and Jo S., "Quadcopter flight control using a low-cost hybrid interface with EEG-based classification and eye tracking," *Comput. Biol. Med.*, vol. 51, no. Ağustos 2014, pp. 82–92,
42. Raez M. B. I., Hussain M. S., and Mohd-Yasin F., "Techniques of EMG signal analysis: detection, processing, classification and applications.," *Biol. Proced. Online*, vol. 8, pp. 11–35, 2006.
43. Nazmi N., et al, "A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions," *Sensors*, vol. 16, no. 8, p. 1304, Ağustos 2016.
44. "ActionPotentials." <http://hyperphysics.phy-astr.gsu.edu/hbase/Biology/actpot.html>. [Erişim Tarihi: 22-Temmuz-2017].
45. Gökhan K., "Mayoelektrik Protez Elin Yapay Zeka Metotları Kullanılarak Gerçek Zamanlı Olarak Denetlenmesi," Ondokuz Mayıs Üniversitesi, 2011.
46. Salerud E. G., "Electrodes & Measurement Systems Current transport in electrolytes.," "lecture notes", 2007
47. Albulbul A., "Analyzing the Effect of an Externally Applied Force on the Electrode-Skin Impedance," Carleton University, 2013.
48. Neuman M. R., *The Biomedical Engineering Handbook: Second Edition*. CRC Press LLC, 2000.
49. Amrutha N., Arul V. H., "A Review on Noises in EMG Signal and its Removal," *Int. J. Sci. Res. Publ.*, vol. 7, no. 5, 2017.

50. Scott D., "Important Factors in Surface EMG Measurement," Bortec Biomedical, Calgary.
51. "Extensor pollicis brevis." http://webcache.googleusercontent.com/search?q=cache:http://boneandspine.com/muscles-of-hand-and-wrist/&gws_rd=cr&dcr=0&ei=E2fuWdaMGcy6Utzou6gB. [Eriřim Tarihi: 24-Ekim-2017].
52. Malmivuo J. and Plonsey R., Bioelectromagnetism : principles and applications of bioelectric and biomagnetic fields. Oxford University Press, 1995.
53. Ahmed O. J. and Cash S. S., "Finding synchrony in the desynchronized EEG: the history and interpretation of gamma rhythms.," Front. Integr. Neurosci., vol. 7, p. 58, 2013.
54. Sanei S. and Chambers J., EEG signal processing. John Wiley & Sons, 2007.
55. "Generatot of EEG." [http://www.laxtha.com/bhbae/EEG_intro/eeggen1.html]. [Eriřim Tarihi: 27-Temmuz-2017].
56. Mattice C., Brooks R., and T. L. Lee-Chiong, Fundamentals of sleep technology. Wolters Kluwer/Lippincott Williams & Wilkins Health, 2012.
57. Tong S. and Thakor N. V., Quantitative EEG analysis methods and clinical applications. Artech House,Boston, pp:40-121, 2009.
58. Hari R. and Puce A., MEG-EEG primer. .ISBN: 978-0190497774,2017
59. Kamel N. and Malik A. S., EEG/ERP analysis : methods and applications.: ISBN 9781138077089,2017
60. "Brain_TaskMap_en." http://soft-dynamics.com/pdf/Brain_TaskMap_en.pdf. [Eriřim Tarihi: 27-Temmuz-2017].
61. Proakis J. G. and Manolakis D. G., Digital signal processing: principles, algorithms, and applications. Prentice Hall, 1996.
62. Niedermeyer E., Lopes da Silva F. H., Electroencephalography: basic principles, clinical applications, and related fields. . Williams & Wilkins; 4th edition,1999, ISBN: 978-0683302844
63. Li K.,International Conference on Intelligent Computing for Sustainable Energy and Environment., ICSEE 2010, Wuxi, China, Eylöl 17-20, 2010,
64. Rasheed S., "A Multiclassifier Approach to Motor Unit Potential Classification

for EMG Signal Decomposition,” University of Waterloo, 2006.

65. Chowdhury R., Reaz M., Ali M., Bakar A., K. Chellappan, T. Chang, “Surface Electromyography Signal Processing and Classification Techniques,” *Sensors*, vol. 13, no. 9, pp. 12431–12466, Sep. 2013.
66. Bozkuş Kahyaoğlu S., “Denetim Etkinliğini Artırmada Verinin Analizi”, Ders Notu, Mayıs 2016, Antalya
67. Palaniappan R., *Biological signal analysis*. Studentia Ventus Publishing, 2011.
68. Başpınar U., “Elektromiyogram sinyallerinin sınıflandırılması ve bağımsız bileşen analizi ile işlenmesi,” Marmara Üniversitesi, 2014.
69. Jacobs K., *Quantum Measurement Theory and its Applications*. Cambridge: Cambridge University Press, 2014.
70. Batu T., Dasgupta S., Kumar R., Rubinfeld R., “The complexity of approximating entropy,” in *Proceedings of the thirty-fourth annual ACM symposium on Theory of computing - STOC '02*, 2002, pp. 678–687.
71. El-Zonkoly A. M., “Fault diagnosis in distribution networks with distributed generation,” *Electr. Power Syst. Res.*, vol. 81, no. 7, pp. 1482–1490, Temmuz 2011.
72. Sevgi L., “Numerical Fourier Transforms DFT and FFT,” : *IEEE Antennas and Propagation Magazine*, Volume: 49, Issue: 3, pp. 238–243, 2007.
73. Demren E., “Dalgacık Dönüşümünün Fourier Dönüşümü İle Karşılaştırılması Ve Uygulama,” İstanbul Teknik Üniversitesi, 2015.
74. Stanković S., “Time-Frequency Analysis and Its Application in Digital Watermarking,” *EURASIP J. Adv. Signal Process.*, vol. 2010, pp. 1–21, 2010.
75. Alkan A., S. Y. , “Kapasitör Anahtarlama Sonucu Oluşan Geçici Salınımların Frekans ve Zaman Frekans Domeninde Analizi,” *Elektrik-Elektronik-Bilgisayar Mühendisliği 12. Ulusal Kongresi*, 2007.
76. Altın C., Bascil M. Serdar, Karakuş M. Ö., Er O., “Sentetik Açıklıklı Odaklanma Tekniği ile Ultrasonik Konum Netleştirme Ultrasonic Location Clarification Using Synthetic Aperture Focusing Technique,” in *Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu*, 2012.
77. Karamustafaoğlu G., “Polisomnografi Sinyallerinin İşlenmesi İle Uyku

Apnesinin Otomatik Teşhisi,” İstanbul Üniversitesi, 2014.

78. Gundars K. R. R., Steven L. C., “Impact of Window Length and Decorrelation Step on ICA Algorithms for EEG Blind Source Separation.,” in BIOSIGNALS, pp. 55–60.,2012
79. Addison P. S., The illustrated wavelet transform handbook : introductory theory and applications in science, engineering, medicine, and finance. Institute of Physics Pub, 2002.
80. Chan A. K., Peng C., Wavelets for sensing technologies. Artech House, 2003.
81. OKTAY T. D., “Elektrik Güç Sistemlerindeki Geçici Olayların Dalgacık Analizi Ve Olasılıksal Sinir Ağları Yöntemiyle Sınıflandırılması,” Yıldız Teknik Üniversitesi, 2007.
82. Misiti M., Misiti Y., Oppenheim G., Poggi J.-M., “MATLAB ® User’s Guide Wavelet Toolbox.”
83. Özkan A., “Dalgacık Analizi ile Yüksek Gerilim Aygıtlarından Alınan İşaretlerin Değerlendirilmesi,” İstanbul Teknik Üniversitesi, 2010.
84. Sunjay S., “Wavelets : A Mathematical Microscope,” in 8. Biennial International Conference & Exposition on Petroleum Geophysics, 2010.
85. Larose D. T., Data Mining Methods and Models. Hoboken, NJ, USA: John Wiley & Sons, Inc., 2006.
86. Jyoti Bora D., Kumar Gupta A., “Effect of Different Distance Measures on the Performance of K-Means Algorithm: An Experimental Study in Matlab,” Int. J. Comput. Sci. Inf. Technol., vol. 5, no. 2, pp. 2501–2506, 2014.
87. Bhattacharyya S. and Dutta P., Handbook of research on computational intelligence for engineering, science, and business. Information Science Reference, 2013.
88. Hasan K., Ahamed A., Ahmad M., and Rashid M. A., “Prediction of Epileptic Seizure by Analysing Time Series EEG Signal Using k -NN Classifier,” Appl. Bionics Biomech., vol. 2017, 2017.
89. Teknomo K., “Linear Discriminant Analysis (LDA) Numerical Example.” [http://people.revoledu.com/kardi/tutorial/LDA/Numerical Example.html](http://people.revoledu.com/kardi/tutorial/LDA/Numerical%20Example.html). [Erişim Tarihi: 17-Ağustos-2017].

90. Llamado Soria M. and Martinez J. P., “An ECG classification model based on multilead wavelet transform features,” in 2007 Computers in Cardiology, pp. 105–108.,2007
91. Bravo H. C., “CMSC858P Supervised Learning Methods,” "lecture notes", March 2010.
92. Temurtas F., “A comparative study on thyroid disease diagnosis using neural networks,” Expert Syst. Appl., vol. 36, no. 1, pp. 944–949, Ocak 2009.
93. Vijayarani S., Dhayanand S., and M. P. Research Scholar, “Data Mining Classification Algorithms For Kidney Disease Prediction,” Int. J. Cybern. Informatics, vol. 4, no. 4, pp. 13–25, 2015.
94. İbrahim E. H., “Destek Vektör Makineleri ile Tahmine Dayalı Modelleme ve Bir Uygulama,” İstanbul Üniversitesi, 2011.
95. Rana K. O., “Destek Vektörü Makineleri Tabanlı Hata Bulma, Tanıma ve Hata Toleranslı Kontrol Yöntemleri,” İstanbul Teknik Üniversitesi, 2010.
96. Hüseyin E., “Güç Kalitesi İçin Dalgacık Dönüşümü ve Destek Vektör Makine Tabanlı Bir Olay Tanıma Tekniğinin Geliştirilmesi,” Fırat Üniversitesi, 2010.
97. Altın C., “Dört Rotorlu İnsansız Hava Aracının Yükseklik ve Konum Kontrolü,” Bozok Üniversitesi, 2013.

EKLER

EK-1 Etik Kurul Raporu



T.C.
BOZOK ÜNİVERSİTESİ REKTÖRLÜĞÜ
KLİNİK ARAŞTIRMALAR ETİK KURULU

KLİNİK ARAŞTIRMALAR ETİK KURULU KARARI

TOPLANTI TARİHİ	: 24.08.2017
TOPLANTI SAYISI	: 5
DOSYA KAYIT NUMARASI	: 2017-07-10
KARAR NUMARASI	: 2017-KAEK-189_2017.08.24_01
ARAŞTIRMA YÜRÜTÜCÜSÜ	: Yard. Doç. Dr. Orhan ER
YARDIMCI ARAŞTIRMACILAR	: Araş. Gör. Cemil ALTIN

Üniversitemiz Mühendislik – Mimarlık Fakültesi Elektrik – Elektronik Mühendisliği Bölümü öğretim üyesi Yard. Doç. Dr. Orhan ER'in sorumluluğunda yürütülecek olan “Dört rotorlu insansız hava aracının görsel geri beslemeli birleştirilmiş EEG ve EMG biyolojik sinyalleri ile kontrolü” başlıklı çalışma dosyası “İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik”, “İyi Klinik Uygulamaları Kılavuzu” ve “Bozok Üniversitesi Klinik Araştırmalar Etik Kurulu Yönergesi” ne göre değerlendirilmiştir. Çalışmanın etik açıdan uygunluğuna oy birliği ile karar verilmiştir.


Yard. Doç. Dr. Ayça ÇAKMAK (Başkan)


Doç. Dr. Murat KORKMAZ (Üye)

Doç. Dr. Seyhan KARAÇAVUŞ (Üye)

(Görevli izimli)
yeri değişikliği AC

Yard. Doç. Dr. Muhammet Serdar BAŞÇIL (Üye)
(İzinli)


Yard. Doç. Dr. Rıza ÇİTİL (Üye)

Ziraat Yük. Müh. Harun ASLAN (Üye)


Av. Fatih DEMİRCİ (Üye)

ÖZGEÇMİŞ

1988 yılında Niğde’de doğan Cemil ALTIN, ilköğretim ve orta öğrenimini sırasıyla Niğde Atatürk İlköğretim okulu ve Niğde Anadolu Lisesinde tamamlamıştır. 2006 yılında kazandığı Karadeniz Teknik Üniversitesi Elektrik-Elektronik Mühendisliği bölümünde 1. ve 2. Sınıfı okuduktan sonra 3. Sınıfı Erasmus programı çerçevesinde Dalarna Üniversitesi’nde/İsveç okumuştur. 4. Sınıfı ise Farabi programı çerçevesinde Erciyes Üniversitesinde tamamlayarak lisans eğitimini 2011 yılında başarıyla tamamlamıştır.

2012 yılında yüksek lisans eğitimine Bozok Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Anabilim Dalında başlamıştır. Yrd. Doç. Dr. Orhan ER danışmanlığında hazırladığı “DÖRT ROTORLU İNSANSIZ HAVA ARACININ YÜKSEKLİK VE KONUM KONTROLÜ” başlıklı teziyle Yüksek Lisans öğrenimini 2013 yılında tamamlamıştır.

2013 yılında doktora eğitimine Bozok Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Anabilim Dalında başlamıştır. Yrd. Doç. Dr. Orhan ER danışmanlığında hazırladığı “DÖRT ROTORLU İNSANSIZ HAVA ARACININ GÖRSEL GERİ BESLEMELİ BİRLEŞTİRİLMİŞ EEG VE EMG BİYOLOJİK SİNYALLERİ İLE KONTROLÜ” başlıklı doktora tezini 2017 yılında sunmuştur. 2011 yılından beri Bozok Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümünde Araştırma Görevlisi olarak çalışmaktadır.

İletişim Bilgileri

Adres :Bozok Üniversitesi

Mühendislik Fakültesi

Elektrik-Elektronik Mühendisliği Bölümü

Cemil Çiçek Bulvarı, Divanlı Yolu 7. km.

66200/ YOZGAT

Telefon : (539) 376 35 56

Faks : (354) 242 10 05

E-posta : cemil.altin@bozok.edu.tr