

**KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

**EEG TABANLI ÇOKLU SENSÖR DESTEKLİ BİR İNSAN
MAKİNE ARAYÜZÜNÜN GELİŞTİRİLMESİ**

GÜRKAN KÜÇÜKYILDIZ

KOCAELİ 2017

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ





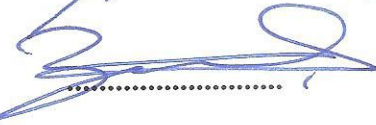
MEKATRONİK MÜHENDİSLİĞİ
ANABİLİM DALI

DOKTORA TEZİ

EEG TABANLI ÇOKLU SENSÖR DESTEKLİ BİR İNSAN
MAKİNE ARAYÜZÜNÜN GELİŞTİRİLMESİ

GÜRKAN KÜÇÜKYILDIZ

Prof.Dr. Hasan OCAK
Danışman, Kocaeli Univ.
Prof.Dr. Hüseyin Metin ERTUNÇ
Jüri Üyesi, Kocaeli Univ.
Doç.Dr. Serdar KÜÇÜK
Jüri Üyesi, Kocaeli Univ.
Doç.Dr. Şeref Naci ENGİN
Jüri Üyesi, Yıldız Teknik Univ.
Yrd.Doç.Dr. Barış BORU
Jüri Üyesi, Sakarya Univ.

Tezin Savunulduğu Tarih: 16.06.2017

ÖNSÖZ VE TEŞEKKÜR

Bu çalışmanın tüm aşamalarında yardımını esirgemeyen değerli hocam Prof. Dr. Hasan OCAK'a ve değerli çalışma arkadaşım Suat KARAKAYA'ya desteklerinden dolayı çok teşekkür ederim. Bu çalışma kapsamında özellikle deneylerin gerçekleştirilmesi ve sistemin donanımsal olarak toplanmasına yardımcı olan değerli arkadaşlarım Canberk ARICAN ve Gökhan TAŞÇI'ya ayrıca teşekkürü bir borç bilirim. Bu süreçte bana her türlü desteği sağlayan eşim Melahat KÜÇÜKYILDIZ'a sonsuz teşekkürler.

Ayrıca hayatım boyunca desteklerini esirgemeyen ve beni bugünlere getiren annem, babam ve kardeşime sonsuz teşekkürlerimi sunarım.

Mayıs – 2017

Gürkan KÜÇÜKYILDIZ

İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
TABLolar DİZİNİ	vi
SİMGELER DİZİNİ VE KISALTMALAR	vii
ÖZET.....	viii
ABSTRACT	ix
GİRİŞ	1
1. GENEL BİLGİLER.....	3
1.1. EEG ve EMG Sinyalleri	4
1.2. Literatür Taraması	7
1.3. Tezin Literatüre Katkısı.....	23
2. DENEY DÜZENEGİ	26
2.1. Sistemin Elektronik Tasarımı	27
2.2. Sistemin Mekanik Tasarımı.....	30
2.3. Sistemde Kullanılan Sensörler ve Sinyallerin Toplanması	31
2.3.1. EMG sensörü.....	32
2.3.2. EEG sensörü.....	33
2.3.3. Kinect sensörü.....	35
2.3.4. Sistemde kullanılan kamera	37
3. KINECT TABANLI GÜVENLİ SÜRÜŞ ALGORİTMASI.....	39
4. BİO-SİNYAL TABANLI KONTROL	47
4.1. Ön İşlemler ve Artifakt Eliminasyonu	48
4.2. Öznitelik Çıkartma	50
4.2.1. Zaman uzayı tabanlı öznitelikler	50
4.2.2. Frekans uzayı tabanlı öznitelikler	52
4.2.3. Dalgacık dönüşümü tabanlı öznitelikler.....	53
4.2.4. Ortak uzamsal örüntü	56
4.3. Öznitelik Seçme	59
4.3.1. Temel bileşen analizi.....	59
4.3.2. Genetik algoritma.....	62
4.4. Sinyal Sınıflandırma	66
4.4.1. Yapay sinir ağları	66
4.4.2. Destek vektör makineleri	70
4.4.3. Rastgele orman.....	75
4.4.4. Geliştirilen hibrid sınıflandırma algoritması.....	78
5. GÖZ HAREKETLERİ TABANLI KONTROL.....	80
5.1. Viola-Jones Algoritması ile Yüz Tespiti	81
5.2. Dairesel Hough Dönüşümü Kullanarak Göz Bebeği Tespiti	83
6. SONUÇLAR VE ÖNERİLER	86
6.1. Öznitelik Seçme Sonuçları	87
6.2. Örnek Veri Seti için Elde Edilen Sonuçlar.....	91
6.3. Deney Düzeneginden Elde Edilen Sonuçlar	95

6.3.1. Bilgisayar ortamındaki sonuçlar.....	95
6.3.2. Gerçek zaman test sonuçları.....	101
KAYNAKLAR	108
KİŞİSEL YAYIN VE ESERLER	116
ÖZGEÇMİŞ	119



ŞEKİLLER DİZİNİ

Şekil 1.1. Genel bir sinir hücresinin yapısı	5
Şekil 1.2. Sinir hücresindeki potansiyelin değişmesi.....	6
Şekil 1.3. Beyin empedans haritası	6
Şekil 1.4. EEG ölçüm başlığı	7
Şekil 1.5. Tekerlekli ve akülü sandalye	12
Şekil 1.6. Geliştirilen akülü sandalye.....	14
Şekil 1.7. Geliştirilen EEG tabanlı akülü sandalye	14
Şekil 1.8. Geliştirilen tekerlekli sandalye ve robotik kol sistemi.....	15
Şekil 1.9. Geliştirilen BCI tabanlı tekerlekli sandalye.....	16
Şekil 1.10. Geliştirilen EEG tabanlı tekerlekli sandalye ve robotik kol	17
Şekil 1.11. Geliştirilen görsel uyarıcılar tabanlı BCI sistemi.....	18
Şekil 1.12. Geliştirilen çoklu sensör destekli tekerlekli sandalye.....	19
Şekil 1.13. Geliştirilen dil hareketli tabanlı tekerlekli sandalye kontrolü.....	20
Şekil 1.14. Geliştirilen Kinect tabanlı tekerlekli sandalye	21
Şekil 1.15. Geliştirilen EMG ve Kinect tabanlı tekerlekli sandalye	21
Şekil 1.16. Geliştirilen el hareketleri tabanlı tekerlekli sandalye.....	22
Şekil 1.17. Geliştirilen akıllı telefon tabanlı tekerlekli sandalye	23
Şekil 2.1. Deney düzeneğinde kullanılan tekerlekli sandalye.....	26
Şekil 2.2. Sistemin genel mimarisi.....	27
Şekil 2.3. Geliştirilen kontrol kartının şematik çizimi	29
Şekil 2.4. Geliştirilen kontrol kartı.....	30
Şekil 2.5. Teknik çizim	31
Şekil 2.6. Sistem Bileşenleri	31
Şekil 2.7. Kullanılan EMG sensörü	32
Şekil 2.8. EMG bileklik tarafından tanınan hareketler	32
Şekil 2.9. EMG veri akış yönü	33
Şekil 2.10. Emotive EEG başlık.....	34
Şekil 2.11. Emotive EEG başlık veri alma programı	34
Şekil 2.12. EEG sensör için veri akış yönü.....	35
Şekil 2.13. Kinect sensör içyapısı	36
Şekil 2.14. Kullanılan kamera.....	37
Şekil 2.15. Göz hareketleri için veri akış yönü	38
Şekil 3.1. Kinect sensör koordinat düzlemi	40
Şekil 3.2. Orijinal ve düzeltilmiş zemin derinlik haritası.....	43
Şekil 3.3. Arka plan görüntüsü ve morfolojik işlemler uygulanmış görüntü.....	45
Şekil 3.4. Güvenli sürüş algoritması akış şeması.....	46
Şekil 4.1. Geliştirilen sistemin işaret akış şeması	47
Şekil 4.2. Gyro tabanlı artifakt eliminasyonu	49
Şekil 4.3. Göz kırpma tabanlı artifakt eliminasyonu.....	50
Şekil 4.4. Dönüşümlerin karşılaştırılması	55
Şekil 4.5. Ayırık dalgacık dönüşümü şeması	56
Şekil 4.6. Temel bileşen analizi akış şeması	62
Şekil 4.7. Genetik algoritmada çaprazlama.....	64

Şekil 4.8. Genetik algoritmada mutasyon	64
Şekil 4.9. Genetik algoritma akış diyagramı	65
Şekil 4.10. Yapay sinir ağları hücre yapısı	68
Şekil 4.11. Çok katmanlı YSA yapısı	68
Şekil 4.12. Lineer ayıraç	71
Şekil 4.13. Çok sayıdaki lineer ayıraç.....	72
Şekil 4.14. Sınıfları ayıran düzlem ile sınıflar arasındaki uzaklık	73
Şekil 4.15. Örnek Bir karar ağacı yapısı	76
Şekil 4.16. Sınıflandırma algoritması akış şeması	79
Şekil 5.1. Görüntü işleme akış şeması	80
Şekil 5.2. Viola-Jones algoritmasındaki dikdörtgenler.....	81
Şekil 5.3. Örnek resim ve resimden tespit edilen gözler.....	83
Şekil 5.4. Hough dönüşümü kartezyen koordinatlar	84
Şekil 5.5. Göz bebeği için aday daireler	85
Şekil 5.6. Göz bebeği merkezi ve etrafındaki kareler	85
Şekil 6.1. Deney düzeneğinden alınan verilerde genetik algoritma sonucu	89
Şekil 6.2. Örnek veri seti için genetik algoritma iyileştirme sonucu	90
Şekil 6.3. Deneydeki EOG kısımları.....	91
Şekil 6.4. EMG tabanlı kontrolde dikdörtgensel rota için sonuçlar	102
Şekil 6.5. EMG tabanlı kontrolde sinüzoidal rota sonuçları	103
Şekil 6.6. EMG tabanlı kontrolde eliptik rota sonuçları	104
Şekil 6.7. EEG tabanlı kontrolde sinüzoidal rota sonuçları	105
Şekil 6.8. Göz hareketleri tabanlı kontrol	106

TABLolar DİZİNİ

Tablo 2.1. Temin edilen tekerlekli sandalyenin özellikleri.....	26
Tablo 2.2. Kullanılan kamera özellikleri.....	37
Tablo 3.1. Kinect parametreleri.....	41
Tablo 4.1. Kullanılan Öznitelik Tablosu.....	58
Tablo 4.2. Genetik algoritmanın parametreleri	66
Tablo 6.1. Birinci denek için deney düzeneğinden elde edilen verilerde bütün EEG kanalları üzerinde genetik algoritma öznitelik seçim sonuçları	58
Tablo 6.2. Birinci denek için deney düzeneğinden elde edilen verilerde ortak uzamsal örüntü için genetik algoritma öznitelik seçim sonuçları.....	89
Tablo 6.3. Birinci denek için örnek veri setinde bütün kanallar üzerinde genetik algoritma öznitelik seçim sonuçları.....	90
Tablo 6.4. Birinci denek için örnek veri setinde ortak uzamsal örüntü için genetik algoritma öznitelik seçim sonuçları.....	90
Tablo 6.5. Örnek veriseti için sınıflandırıcıların karar tablosu	93
Tablo 6.6. Geliştirilen sınıflandırıcılar için belirginlik tablosu.....	94
Tablo 6.7. Kappa değerlerinin diğer çalışmalarla karşılaştırılması.....	95
Tablo 6.8. EMG sinyalleri için karar tablosu	96
Tablo 6.9. EMG sinyalleri için sınıflandırıcıların belirginlik değerleri	97
Tablo 6.10. EEG sinyal sınıflandırıcıları karar tablosu.....	98
Tablo 6.11. EEG sınıflandırıcıları için karar tablosu	99
Tablo 6.12. EEG sinyalleri için belirginlik tablosu	100
Tablo 6.13. Göz hareketleri için karar tablosu	101
Tablo 6.14. Göz hareketleri için belirginlik tablosu	101
Tablo 6.15. EMG tabanlı kontroldeki hatalar	105
Tablo 6.16. EEG tabanlı kontrolde hata değerleri.....	106
Tablo 6.17. Göz hareketleri tabanlı kontrol sonuçları.....	107

SİMGELER DİZİNİ VE KISALTMALAR

A	: Ayrıntı sinyali
b	: Bias değeri
C	: Crest faktör (%)
d	: İki nokta arasındaki uzaklık, (piksel)
e	: Euler sayısı
f	: Aktivasyon fonksiyonu
h_j	: YSA çıkışları
k	: Basıklık, (%)
k	: Boyut
n	: Örnek sayısı
s	: Çarpıklık, (%)
w	: Ağırlık değeri
X(k)	: k noktalı ayrık sinyal
x_j	: YSA girişleri
Y	: Yaklaşım sinyali
σ	: Standart sapma

Kısaltmalar

ALS	: Amiyotrofik Lateral Sklerozis
ANN	: Artificial Neural Networks (Yapay Sinir Ağları)
AY	: Ayrıntının Yaklaşımı
AZFD	: Ayrık Zamanlı Fourier Dönüşümü
BCI	: Brain Computer Interface (İnsan Bilgisayar Arayüzü)
DVM	: Destek Vektör Makineleri
EEG	: Elektroensefalografi
EMG	: Elektromiyografi
EOG	: Electrooculagram
FFT	: Fast Fourier Transform (Hızlı Fourier Dönüşümü)
GA	: Genetik Algoritma
HFD	: Hızlı Fourier Dönüşümü
KKT	: Karush - Khun - Tucker
k-NN	: k-Nearest Neighbour (k-En Yakın Komşu)
KTM	: Kural Tabanlı Metot
PWM	: Pulse Width Modulation (Darbe Genişlik Modülasyonu)
RF	: Random Forest (Rastgele Orman)
RMS	: Root Mean Square (Karelerin Ortalamasının Karekökü)
SDK	: Software Development Key (Yazılım Geliştirme Kiti)
SVM	: Support Vector Machine (Destek Vektör Makineleri)
YSA	: Yapay Sinir Ağları
YY	: Yaklaşımın Yaklaşımı

EEG TABANLI ÇOKLU SENSÖR DESTEKLİ BİR İNSAN MAKİNE ARAYÜZÜNÜN GELİŞTİRİLMESİ

ÖZET

İnsanlar, bilgisayar veya makinalarla iletişim kurmak ve onları kullanabilmek için klavye, fare, joystick, dokunmatik ekran gibi çeşitli araçlar kullanmaktadırlar. Bu araçları kullanabilmek için ise kasların kontrol edilmesi gerekmektedir. Çeşitli sebeplerle hareket yetenekleri zayıflamış veya hareket yeteneklerini tamamen kaybetmiş engelli hastaların bu yolla bilgisayar ve makinalarla iletişim kurmaları ve onları kullanabilmeleri mümkün olmamaktadır. Amiyotrofik lateral sklerozis (ALS), beyin kökü travması, beyin ya da omurilik yaralanması, serebral palsi, kas distrofileri ve çoklu skleroz gibi motor nöron problemleri, insanların hareket (motor) yeteneklerini etkilemekte ve kaslarını kullanmalarına engel olmaktadır. O halde, bu tür hastaların makinalarla iletişimini sağlamanın yollarından biri de beyindeki aktiviteyi tespit edip yorumlamaktan geçmektedir. Bu doktora çalışması kapsamında, Elektro-Ensefelo-Gram (EEG) işaretlerinin analizi ile önceden tanımlı kavramsal görevlerin (cognitive taks) gerçek-zamanlı olarak tespit edilebilmesi ve bu belirlenen görevlere bağlı olarak akülü sandalye sisteminin gerçek zamanlı olarak kontrol edilebilmesi amaçlanmıştır. Bu amaçla öncelikli olarak bilgisayar ortamına alınan EEG sinyalleri MATLAB ortamında yapay zeka teknikleri kullanılarak incelenmiş ve sinyalleri analiz edilebilecek modeller oluşturulmuştur. Geliştirilen modeller literatürde bulunan EEG veritabanları üzerinde de denenmiş ve başarılı sonuçlar elde edilmiştir. EEG sinyallerinin yanı sıra sisteme entegre edilen Elektro-Miyogram (EMG) sensörleri yardımıyla sistemin el hareketleri ile kontrolü sağlanmıştır. Sürüş güvenliğinin sağlanabilmesi için sisteme bir Kinect sensörü entegre edilmiştir. Kinect'den alınan derinlik görüntüleri işlenerek bir çarpışma engelleme algoritması geliştirilmiştir. Son olarak bir kamera kullanılarak sistemin göz hareketleri ile kontrolü sağlanmıştır. Geliştirilen sistem farklı kullanıcılar üzerinde hem benzetim ortamında hem de gerçek-zamanlı olarak test edilmiştir. Denekler, geliştirilen sistemi göz hareketleri ve kol hareketleri kullanarak kolaylıkla kontrol edebilmişlerdir. EEG tabanlı kontrolde de başarılı sonuçlar elde edilmiş ve sonuçların kullanıcı bağımlı olduğu gözlenmiştir. Ayrıca çevresel şartların da EEG tabanlı kontrolde başarımı etkilediği gözlenmiştir.

Anahtar Kelimeler: EEG, EMG, Güvenli Sürüş, Tekerlekli Sandalye.

DEVELOPMENT OF AN EEG AND MULTI SENSOR BASED HUMAN MACHINE INTERFACE

ABSTRACT

People use a variety of tools such as keyboards, mice, joysticks, touch screens to communicate and use computers or machines. In order to use these tools, one needs to be able to control his/her muscles. For those people with partial or complete disability, it is not possible to communicate and use machines in this way. Motor neuron problems such as amyotrophic lateral sclerosis (ALS), traumatic brain injury, brain or spinal cord injury, cerebral palsy, muscle dystrophy and multiple sclerosis affect people's motor skills and prevent them from using their muscles. Thus, one of the ways in which such patients can communicate with the machines is by interpreting the activity in his head. In this study, it is aimed to analyze the Electro-Encephalo-Gram (EEG) signals in real time to determine predefined cognitive tasks and to control a motorized wheelchair in real time depending on these tasks. For this purpose, EEG signals were processed using artificial intelligence techniques in MATLAB environment and models were developed to analyze the signals. The developed models have also been successfully tested on benchmark EEG databases in the literature. In addition to EEG based control, Electro-Myo-Gram (EMG) sensors integrated into the system have also been utilized to control the system with hand movements. A Kinect sensor was integrated in the system to ensure driving safety. A collision avoidance algorithm has been developed by processing depth images acquired from the Kinect sensor. The developed system also makes it possible to control the wheelchair by eye movements with the help of a camera. The proposed scheme has been tested on different subjects in both simulated environment and real-time. The subjects were able to easily control the developed system using eye and arm movements. Successful results were obtained in the EEG based control however the results were observed to be subject dependent. It has also been observed that environmental conditions affect system performance in EEG based control.

Keywords: EEG, EMG, Safe Navigation, Wheelchair.

GİRİŞ

Amyotrofik lateral skleroz (ALS) veya tetraplegia gibi hastalıklar insanların motor sinir hücrelerine zarar verebilmektedir. Böyle bir durumda insanlar, kaslarını kontrol yeteneğini kaybedebilir. Bu nedenle, bu insanların bilgisayarlar ile haberleşmesi için beyin bilgisayar ara yüzü (BCI) sistemleri geliştirilmiştir. Bu tez kapsamında beyin bilgisayar ara yüzü için EEG sinyalleri tabanlı bir sistem geliştirilmiştir. EEG sinyallerine ek olarak EMG sinyalleri ve göz hareketleri de incelenerek sistemdeki kontrol kaynakları çoğaltılmıştır. EEG deneylerinde öncelikli olarak kavramsal görevler belirlenmiş ve deneklerden bu kavramsal görevleri tekrarlaması istenmiştir. Benzer bir şekilde, sistemi kontrol edebilmek amacıyla EMG sinyalleri için de dört farklı el hareketi tanımlanmış ve sistemin yönlendirilmesi için deneklerden bu hareketleri tekrarlaması istenmiştir. Geliştirilen sinyal işleme algoritmaları ile kullanıcının ne yapmak istediği tespit edilmiş ve sonuca göre tekerlekli sandalyenin yönlendirilmesi yapılmıştır.

Tez çalışmasının ilk bölümünde problemin tanımı ve bu problemin çözümüne yönelik literatürde geliştirilmiş metotlar incelenecektir.

İkinci kısımda, genel olarak deney düzeneğinden bahsedilerek, sistemin mekanik ve elektronik olarak tasarımı detaylı olarak ele alınacaktır. Sistemde kullanılan sensörler ve bu sensörlerden gerçek zamanda veri alabilmek amacıyla yapılan çalışmalar incelenecektir.

Üçüncü kısımda ise sistemin görü tabanlı güvenli sürüşü incelenecektir. Bu kısımda Kinect sensöründen alınan derinlik görüntüsü kullanılarak geliştirilen görüntü işleme algoritması detaylı olarak anlatılacaktır.

Dördüncü kısımda, sistemin EEG ve EMG tabanlı kontrolü için geliştirilen sinyal işleme algoritmaları irdelenecektir.

Beşinci kısımda ise sistemin göz hareketleri ile kontrolü için geliştirilen görüntü işleme algoritması detaylandırılacaktır.

Son olarak altıncı kısımda ise tez kapsamında elde edilen sonuçlar gerçek zamanlı ve çevrim-dışı olmak üzere iki farklı başlıkta sunulacaktır.



1. GENEL BİLGİLER

Berger, 1929 yılında insan kafatasının üzerinden beyin dalgaları kaydetmiş ve bunlara Elektro-Ensefelo-Gram (EEG) adını vermiştir [1]. EEG sinyallerinin işlenmesine olan ilgi sayısal işaret işleme donanımlarının ve yazılımlarının gelişmesine paralel olarak son 30-40 yıldır hızla artmaktadır. Üzerinde birçok araştırma yapılmasına rağmen EEG tabanlı beyin bilgisayar ara yüzü konusu son yıllarda popülerliği hızla artan bir konudur. Beyin bilgisayar ara yüzleri sayesinde vücudunun sadece belirli kısımlarında bulunan kasları kontrol edebilen hastaların da artık makinelerle iletişimi sağlanabilmektedir. EEG sinyalleri kullanılarak geliştirilen bilgisayar insan etkileşiminde birçok farklı yöntem kullanılabilir. Bunlardan bazıları görsel uyarıcılara dayalı bir insan bilgisayar etkileşimi olmaktadır. Bu kapsamda gerçekleştirilen beyin bilgisayar ara yüzü uygulamalarında genellikle ortamda birbirinden farklı frekanslarda yanıp sönen iki ya da üç farklı led bulunmaktadır. Ledler farklı frekanslarda yanıp söndüğü için, kullanıcıların baktıkları ledlerin frekansındaki dalgalar beyin sinyallerinde baskın hale gelmektedir. Bu sayede, her bir lede farklı bir kavramsal görev verilerek EEG tabanlı beyin bilgisayar ara yüzü sağlanmaktadır. Beyin bilgisayar ara yüzü uygulamalarında kullanılan bir diğer yöntem de kullanıcılar için kavramsal görevler belirlenerek kullanıcılardan bu kavramsal görevleri gerçekleştirmeleri istenmektedir. Birçok farklı kavramsal görevler denenmesine rağmen en yaygın kullanılan kavramsal görevler, sakin kalma-rahatlama, matematiksel işlem çözme ve paragraf okuma kavramsal görevleridir. Bunların yanında sevilen birine mektup yazma gibi farklı kavramsal görevler de kullanılabilir. Bu tez çalışması kapsamında, başlangıç aşamasında iki farklı kavramsal görev (küp çevirme ve sakin kalma) tanımlanmış ve kullanıcılardan bu kavramsal görevleri gerçekleştirmeleri istenmiştir [2]. Fakat tekerlekli sandalyeyi kontrol etmek için iki kavramsal görev yeterli olmadığından, yukarıdaki gibi üç farklı kavramsal görev (sakin kalma, matematiksel işlem ve paragraf okuma) tanımlanmıştır.

EEG sinyalleri beyindeki aktiviteyi ölçerken, insan vücudundaki kas sinyallerinin ölçülmesi işlemi ise elektromiyogram (EMG) olarak isimlendirilmiştir. Kaslardaki gerilmeleri ve kasılmaları ölçtüğü için EMG sinyalleri EEG sinyallerine göre daha mekanik sinyaller olarak kabul edilmektedir. Tez çalışması kapsamında geliştirilen sistemde kullanıcılardan dört farklı el hareketi yapmaları istenmiştir. Bu el hareketler sırasıyla yumruk yapma, elleri serbest bırakma, eli sola ve sağa çevirme işlemleridir. Bu hareketlere bağlı olarak tekerlekli sandalyenin kontrolü sağlanmıştır. Bu hareketlerin yanında birçok farklı el hareketi de tanımlanabilmektedir. EMG sinyallerini toplamak için temin edilen kol bandının kendi ara yüzünde çift vuruş başta olmak üzere farklı hareketler bulunmaktadır.

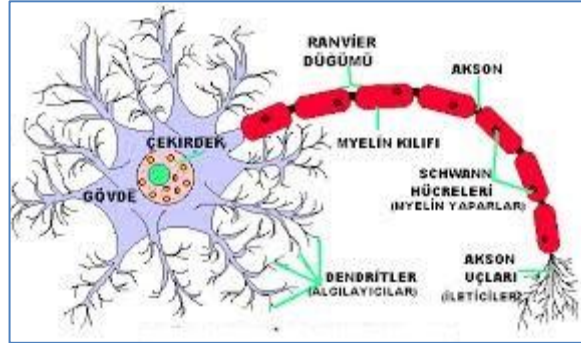
İnsan bilgisayar etkileşimi kapsamında kullanılan farklı yöntemlerden biri de göz hareketlerini takip etmektir. Kamera kullanılarak elde edilen görüntülerden, görüntü işleme teknikleri kullanılarak göz bebeği tespiti yapılabilmekte ve göz bebeğinin konumuna göre kullanıcının nereye baktığı belirlenebilmektedir. Bu sayede bir insan bilgisayar etkileşimi gerçekleştirilebilir. Görüntü işleme tabanlı sistemlerde ise genel görüntü işleme sorunları (ortamda bulunan ışık miktarının kontrol edilememesi, görüntüde gölgelerin oluşması) karşımıza çıkmaktadır. Bu tez çalışması kapsamında da bu tarz bir görüntü işleme tabanlı sistem geliştirilmiştir.

İnsan bilgisayar etkileşimi ile kontrol edilen sistemlerin en önemli sorunlarından biri de emniyet sorunudur. Bu sistemlerin emniyetini sağlamak amacıyla lazer tabanlı çözümler başta olmak üzere birçok farklı çözüm literatürde bulunmaktadır. Kinect sensörü de son zamanlarda sıklıkla kullanılan çözümlerden birisidir. Özellikle önceden çok pahalı derinlik kameralarıyla elde edilebilen derinlik görüntüsü, Kinect kamerası kullanılarak artık kolaylıkla elde edilebilmektedir. Derinlik görüntüsünü işleyen görüntü işleme algoritmaları, insan bilgisayar etkileşimi ile kontrol edilen sistemlerde çarpışma engelleyici birim olarak kullanılabilir. Bu çalışma kapsamında da sistemin emniyetli sürüşü Kinect tabanlı görüntü işleme teknikleri kullanılarak gerçekleştirilmiştir.

1.1. EEG ve EMG Sinyalleri

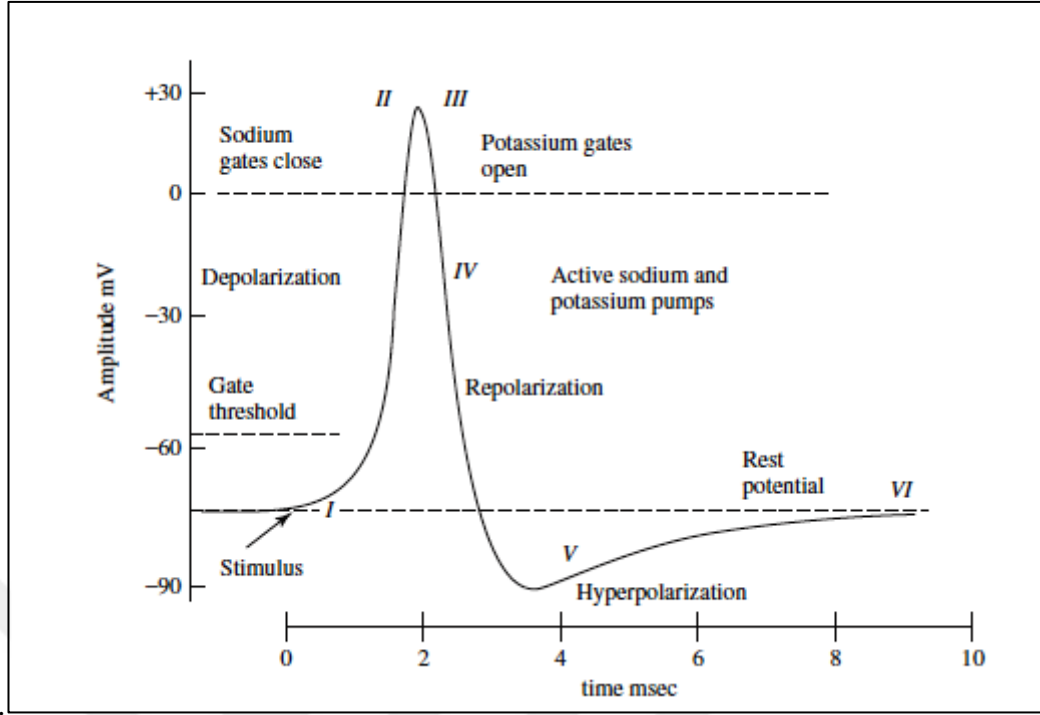
Elektroensefalografi (EEG), beyin dalgaları aktivitesinin elektriksel olarak izlenmesini ölçen yöntemdir. EEG sinyalleri sinir hücrelerindeki elektriksel

potansiyellerin deęişimlerinin ölçülmesi ile elde edilmektedir. Bir sinir hücresinin genel yapısı Şekil 1.1’de verilmiştir [3].




Şekil 1.1. Genel bir sinir hücresinin yapısı

EEG sinyallerin oluşabilmesi için sinir hücresindeki elektriksel potansiyelin deęişmesi gerekmektedir. Bir sinir hücresindeki potansiyelin deęişmesi işlemi altı aşamadan oluşmaktadır. Sinir hücresinin dentritine dış ortamdan belirli bir seviyenin üzerinde uyarıcı gelirse sinir hücresinde potasyum kanalları açılır. Bu açılma işlemi sırasında hücrenin potansiyeli -70 mV ile -55 mV arasında deęişirse ikinci aşamaya geçilir. İkinci aşamada diğer potasyum kanalları da açılır ve bu sayede hücre içerisindeki potansiyel $+30$ mV seviyelerine ulaşır. Üçüncü aşamada sodyum kanalları kapanır ve potasyum kanalları açılır. Bu işlem de-polarizasyon aşaması olarak isimlendirilmekte ve potasyum kanallarının açılması zaman aldığından bu işlem daha yavaş olmaktadır. Potasyum kanalların açılması ile beraber hücre kalan potansiyeline re-polarize olmaktadır. Re-polarizasyon işlemi genellikle bir aşım gitmekte ve bu aşım sonucu hücredeki potansiyel -90 mV seviyelerine düşmektedir. Bu işlem hiper-polarizasyon olarak adlandırılmaktadır. Hiper-polarizasyon sayesinde hücrenin başka bir uyarı alması engellenmektedir. Son olarak hiper-polarizasyon aşamasından sonra hücrede bulunan Sodyum/potasyum pompası hücredeki potansiyeli tekrar başlangıçtaki seviyeye çeker. Bütün bu aşamalarla ilgili olarak grafik Şekil 1.2’de verilmiştir [4]. EEG sinyalleri sinaptik uyarımlar sırasında oluşan akımların ölçülmesi ile elde edilmektedir. Hücrede oluşan potansiyel fark neticesinde meydana gelen bu akım bir cihaz tarafından ölçülebilen bir manyetik alan meydana getirmektedir.



Şekil 1.2. Sinir hücresindeki potansiyelin değişmesi

EEG ölçüm cihazı bu manyetik alanı ölçerek kaydeder. Beynin farklı kısımlarına bağlanan bu elektrotlar ile beyin sinyalleri ölçülmektedir. Beynin her kademesindeki empedans farklı olduğu için bağlanan elektrotların da empedansları da buna uygun olacak şekilde seçilmelidir. Kafanın farklı kısımlardaki empedans bilgileri Şekil 1.3'te verilmiştir [4].



Şekil 1.3. Beyin empedans haritası

İnsan kafatasına uygun elektrotlar bağlandıktan sonra EEG sinyalleri kaydedilmektedir. EEG sinyallerini daha doğru alabilmek için, sinyaller birçok farklı

kanallardan toplanmaktadır. Şekil 1.4'te EEG sinyallerinin ölçülebilmesi için kullanılan örnek bir düzenek verilmiştir [4].



Şekil 1.4. EEG ölçüm başlığı

EEG sinyalleri beyinde oluşan sinyaller iken, EMG sinyalleri ise kaslarda oluşan sinyallerdir. Aynı EEG sinyallerinde olduğu gibi EMG sinyallerinde de bir potansiyel alan oluşmaktadır. EEG sinyallerine göre EMG sinyallerinin yorumlanması daha kolay olmaktadır. Kasların kasılmasına dayanan bir sinyal olduğu için daha mekanik bir sinyal olarak değerlendirilebilir.

1.2. Literatür Taraması

EEG sinyallerinin 1929 yılında Berger tarafından bulunması sonrasında, bu sinyallerin yorumlanması üzerine birçok çalışmalar yapılmıştır [1]. Özellikle uyku kademelerinin ve epilepsi nöbetinin önceden belirlenmesi üzerine EEG tabanlı birçok farklı çalışma bulunmaktadır [5-9]. EEG sinyalleri üzerinde sıklıkla yapılan çalışmalardan biri de beyin bilgisayar ara yüzü üzerine yapılan çalışmalardır.

Wang ve ekibi yaptıkları çalışmada bir BCI sistemi geliştirmişlerdir. Yazarlar geliştirdikleri sistemde sol el, sağ el ve sağ ayağın in hareket ettirildiğinin düşünülmesi olmak üzere üç farklı kavramsal görevi ayırt etmeye çalışmışlardır [10]. Deneklerden veri toplamak amacıyla 118 kanal EEG ve 10 kanal EOG olmak üzere 128 kanallı bir veri toplama sistemi kullanılmıştır. Sistemde kullanılan cihazın örnekleme frekansı 1 KHz olup sistemde dahili olarak 0,05 Hz ile 200 Hz arasında bir bant geçiren sayısal filtre bulunmaktadır. Yazarlar, öznitelik olarak delta

bandındaki enerjileri kullanmışlardır. Çok sayıdaki EEG kanalından seçilen öznitelikleri azaltmak amacıyla ortak uzamsal örüntü algoritmasını kullanmışlardır. Yaptıkları çalışmada sınıflandırıcı olarak ise Fisher diskriminant sınıflandırıcısını kullanmışlardır. Geliştirilen sistem iki farklı denek üzerinde uygulanarak toplamda her bir sınıf için %93,45 ve %91,88 başarı elde etmişlerdir.

Miguel ve ekibi yaptıkları çalışmada geliştirdikleri BCI sisteminde üç farklı kavramsal görev için bir sınıflandırma problemi üzerinde çalışmışlardır [11]. Bu üç kavramsal görev sırasıyla sol elin hareket ettirildiğinin düşünülmesi, sağ elin hareket ettirildiğinin düşünülmesi ve özel olarak belirlenen bir harf ile başlayan kelimelerin oluşturulması olarak belirlenmiştir. Yazarlar geliştirdikleri algoritmayı üçüncü BCI yarışması veri seti V üzerinde denemişlerdir. Bu kapsamda üç farklı denekten her bir kavramsal görev için 15 saniyelik EEG sinyalleri toplanmıştır. Veri toplama cihazının örnekleme frekansı 512 Hz olarak belirlenmiştir. Alınan veriler 0,5 saniyelik zaman pencerelerine bölünerek işlenmiştir. EEG sinyallerindeki bant enerjileri öznitelik olarak kullanılmıştır. Geliştirilen algorithmada yapay sinir ağı (YSA) ve bulanık mantık tabanlı bir sınıflandırıcı kullanılarak farklı kavramsal görevler tespit edilmiştir. Yazarlar geliştirdikleri sınıflandırma algoritmasında birinci, ikinci ve üçüncü denekte sırasıyla %87,21 , %82,26 ve %58,72 başarı oranı elde etmişlerdir.

Nezamfar ve ekibi geliştirdikleri BCI sisteminde olay tabanlı potansiyeller ve görsel uyarıcılara bağlı EEG sinyalleri üzerinde çalışmışlardır [12]. Ekranın köşelerinde yer alan karesel dama tahtası sistemde uyarıcı olarak görev yapmaktadır. Yazarlar geliştirdikleri sistemde topladıkları ilk 50 örneği kalibrasyon örnekleri olarak kabul etmişlerdir. Veriler toplanırken bir adet elektrot görsel korteks üzerine yerleştirilmiş ve bu elektrot üzerinden EEG sinyalleri 256 Hz örnekleme frekansı ile toplanmıştır. Sistemde 60 Hz'lik donanımsal bir çentik filtresi bulunmaktadır. Yazarlar, çentik filtresine ek olarak 5 Hz ile 100 Hz arasındaki sinyalleri geçiren bir bant geçiren filtre uygulamışlardır. Öznitelik olarak frekans bandındaki enerjilerin yanı sıra, zaman uzayı tabanlı bir şablon eşleme işlemi kullanmışlardır. Çapraz korelasyon ve durumsal olasılık tabanlı iki kademeli bir sınıflandırma algoritması kullanılarak elde edilen EEG sinyallerini sınıflandırılmıştır. Geliştirilen sistem üç farklı denek üzerinde denenmiş ve sırasıyla %95,5, %96 ve %97 başarı oranları elde edilmiştir.

He ve ekibi yaptıkları çalışmada giyilebilen robotlar için bir kablosuz BCI sistemi üzerinde çalışmışlar ve geliştirdikleri sistemi bir adet robot kol üzerinde denemişlerdir [13]. Geliştirilen sistemde EEG sinyallerini toplamak için 10-20 yerleşimine sahip bir EEG cihazı kullanılmıştır. Çalışmada, sakın kalmak, kaslarını hareket ettirdiğini düşünme ve kasları durdurduğunu düşünme olmak üzere üç farklı kavramsal görev tanımlanmıştır. Yazarlar topladıkları ham EEG sinyallerini bluetooth kullanarak bilgisayar ve tablet ortamına aktarmışlardır. EEG sinyalleri ön işleme tabi tutularak 5 Hz ile 35 Hz arasını geçiren bant geçiren filtre ile 50 Hz'lik bir çentik filtresinden geçirilmiştir. Sonrasında ise ayrık dalgacık dönüşümü alınarak sinyal üzerinde gürültü giderimi yapılmıştır. Bu aşamada üç farklı dalgacık (Haar, db3, db4) kullanılarak aralarındaki en iyi performans gösteren dalgacık seçilmiştir. Yazarlar öznelik çıkartma işlemi sırasında ortak uzamsal örüntü algoritmasını kullanmışlardır. Yapılan çalışmada lineer diskriminant analizi sınıflandırıcı olarak seçilmiştir. Geliştirilen sistem üç farklı denek üzerinde denenmiş olup sırasıyla %90, %95 ve %90 başarı oranları elde edilmiştir.

Severens ve ekibi yaptıkları çalışmada iki farklı kavramsal görevden oluşan BCI sistemini 12 farklı denek üzerinde denemişlerdir [14]. Kullanıcılar öncelikli olarak bir koşu bandı üzerinde ileriye ve geriye doğru yürütülmüşlerdir. Sonrasında ise kullanıcılardan bu yürüyüşleri hayal etmeleri istenmiştir. Geliştirilen sistemde 62 tane elektrot AFz elektrot pozisyonunda yerleştirilmiştir. Sistemde kullanılan cihazın örnekleme frekansı 500 Hz olarak belirlenmiştir. Alınan veriler 1,2 saniyelik zaman pencerelerine bölünerek işlem yapılmıştır. Yazarlar, elde ettikleri sinyalleri birkaç farklı ön işlemden geçirmiş ve bu ön işlemlere bağlı eliminasyonlar yapmışlardır. İlk olarak standart sapması 3,5'in üzerinde bulunan kanalları sinyal işleme aşamasında kullanmamışlardır. Bu işleme ek olarak her bir kanaldan ortalama değeri (DC bileşeni) çıkartılmıştır. Yazarlar EEG sinyalini etkileyen EMG hareketlerini gürültü olarak kabul etmiş ve EEG sinyallerini bu gürültüden ayırt edebilmek amacıyla kanonik bileşen analizini kullanmışlardır. Bu işlemlerden sonra, öznelik olarak 8 Hz'den başlayarak 32 Hz'e kadar 4 Hz çözünürlükle frekans bantlarındaki enerjileri kullanmışlardır. Geliştirilen sistemde sınıflandırıcı olarak bir lineer diskriminant analizi tercih edilmiş ve 12 kullanıcı için ortalama %70 başarı elde edilmiştir.

Duan ve ekibi geliştirdikleri BCI sisteminde görsel uyarıcılara ek olarak sağ ayağın hareket ettirildiğinin düşünüldüğü kavramsal görevi kullanmışlardır [15]. Yazarlar geliştirdikleri sistem ile bir insansı servis robotunun kontrolünü gerçekleştirmişlerdir. Geliştirilen hibrit sistemde görsel uyarıcılar ile servis robotunun ileri, sağa ve sola dönüş hareketleri, sağ ayağının hareket ettirildiğinin düşünülmesi ile de servis robotunun el uzvuyla bir şeyleri kavraması sağlanmıştır. Geliştirilen sistemde EEG sinyalleri örnekleme frekansı 256 Hz olan 16 kanallı bir EEG cihazı ile toplanmıştır. Kullanılan ölçüm sisteminde donanımsal olarak bulunan 50 Hz çentik filtresine ek olarak 5-60 Hz arasını geçiren bir bant geçiren filtre bulunmaktadır. Görsel olarak bulunan üç farklı uyarıcı sırasıyla 8, 10 ve 12,5 Hz frekanslarında çalışmaktadır. Frekans tabanlı öznitelikler kullanıldığında zaman bilgisi kaybedildiğinden, öznitelik çıkarım aşamasında kısa zamanlı Fourier dönüşümü tercih edilmiştir. Geliştirilen sistemde öznitelik olarak frekans bandındaki enerjilerin yanı sıra, zaman uzayı tabanlı bir şablon eşleme işlemi kullanmışlardır. Sınıflandırma aşamasında ise çapraz korelasyon tabanlı bir metotla görsel uyarıcıları sınıflandırma yoluna gitmişlerdir. Geliştirilen sistemde, ilk üç görsel uyarı kavramsal görevi için %89 doğruluk elde edilirken, ayak hareketlerinin düşünüldüğünün algılanmasında ise %73 doğruluk oranı elde edilmiştir.

Perez ve ekibi yaptıkları çalışmada görsel uyarıcılar tabanlı BCI sistemi kullanarak bir robot kolun kontrolünü gerçekleştirmişlerdir [16]. Beş eklemden oluşan robot kolun kontrolü iki adet servo motor kullanılarak gerçekleştirilmiştir. Kullanıcılardan, ekranda görülen görsel uyarı matrisi içerisindeki ilgili resim üzerine yoğunlaşmaları istenmiştir. Geliştirilen sistemde EEG sinyalleri 14 kanallı ve 128 Hz örnekleme frekansına sahip bir kablosuz EEG cihazı ile toplanmıştır. EEG cihazı ile topladıkları verileri MATLAB ortamına aktarmış ve yine MATLAB ortamında sinyal işleme algoritmaları geliştirmişlerdir. Sonrasında ise geliştirdikleri sinyal işleme algoritmalarını OpenVibe ortamında çalıştırmışlardır. Elde ettikleri sinyal işleme sonucunu Arduino kontrol kartına göndermiş ve bu kart yardımıyla servo motor sürücülerin kontrolünü sağlamışlardır. Yazarlar, geliştirdikleri sistemde %100 başarı elde etmiş olmalarına karşın geliştirdikleri sistemi bir de bozucu etki altında denemek amacıyla deneyler sırasında görsel ve işitsel gürültüler uygulamışlardır. Yapılan deneylerde işitsel bozucu etkiler altında yine %100 performans elde

edilebilirken, görsel bozucu etkiler altında ise en fazla %50 performans elde edilebilmiştir.

Danieala ve ekibi yaptıkları çalışmada geliştirdikleri BCI sisteminde görsel uyarıcılara bağlı EEG sinyallerini kullanarak bir oyun geliştirmişlerdir [17]. Geliştirilen sistemde bir adet kablosuz EEG cihazı ve verileri aktarmak amacıyla bir adet modem olarak kullanılabilir herhangi bir cihaz gerekmektedir. Geliştirilen sistemde üç farklı kavramsal görev tanımlanmıştır. Deneklerden bu kavramsal görevleri incelemeleri istenmiştir. Yazarlar, topladıkları EEG sinyallerini kendi geliştirdikleri ve t-Ride adını verdikleri algoritma ile işlemişlerdir. Geliştirilen algoritmada zaman uzayı tabanlı öznitelikler kullanılmıştır. Bu öznitelikler, orta noktaya göre simetri değeri, tepeden tepeye genlik, eğim değişimleri ve konveksliktir. Sınıflandırma aşamasında ise, eğitim aşamasındaki verilerden elde edilen öznitelikler ile yeni gelen sinyallerden elde edilen öznitelikler arasındaki Mahalanobis uzaklığına göre sınıflandırma yapan bir metot kullanmışlardır. Biri Alzheimer hastası olmak üzere 12 farklı denek üzerinde denenen sistemde %86,8 başarı oranı elde etmişlerdir.

Tomita ve ekibi yaptıkları çalışmada yakın kızılötesi spektroskopisi ve görsel uyarıcılar kullanarak bir BCI sistemi geliştirmişlerdir [18]. Yazarlar, EEG sinyallerine ek olarak on yedi adet kızılötesi sensörden örnekleme periyodu 70 ms olacak şekilde sinyal toplamışlardır. Kızılötesi sensörlerden elde edilen veriler bir üçüncü dereceden bir alçak geçiren filtreden geçirilmiştir. Benzer şekilde 500 Hz örnekleme frekansı ile toplanan EEG sinyalleri de üçüncü dereceden bir alçak geçiren filtreden geçirilmiştir. Yazarlar, kızılötesi sensörlerden alınan verileri kullanarak kullanıcıların herhangi bir kavramsal görevi gerçekleştirmediği durumları tespit edebilmişlerdir. EEG sinyallerini işleyerek kullanıcıların hangi kavramsal görevi gerçekleştirdiklerini tespit etmeyi başarmışlardır. Geliştirdikleri sistemi 13 farklı denek üzerinde denemişler ve %85 doğruluk oranı elde etmişlerdir.

Xu ve ekibi, geliştirdikleri BCI sisteminde P300 dalgaları ve görsel uyarıcılara bağlı EEG sinyalleri üzerinde çalışmışlardır [19]. Geliştirdikleri BCI sisteminde EEG sinyallerini toplamak amacıyla dokuz kanallı ve 1200 Hz örnekleme frekansına sahip bir cihaz kullanmışlardır. Yazarlar geliştirdikleri sistemde EEG sinyallerine ek olarak

EMG sinyallerini de kullanmışlardır. Görsel uyarıcıların yanında, EMG sinyallerini ölçebilmek amacıyla cilt üzerinden darbe veren elektriksel uyarıcılar da kullanmışlardır. Geliştirilen sistem iki farklı şekilde test edilmiştir. İlk olarak dört farklı görsel uyarıcı belirlenmiş ve dört sınıftan oluşan bir sınıflandırma problemi çözülmeye çalışılmıştır. Sonrasında ise, sınıf sayısı dörtten sekize çıkartılarak sınıflandırma problemi daha zorlu bir hale getirilmiştir. Yazarlar geliştirdikleri sistemi 29-35 yaş aralığında yedi farklı erkek denek üzerinde denemişler ve %80 seviyelerinde başarı oranı elde etmişlerdir.


Son yıllarda, engelli insanların topluma yeniden kazandırılması üzerine yapılan çalışmalar hızla artmaktadır. Kasların kontrol edilebilmesini sağlayan sinir hücreleri çeşitli sebeplerle zarar gören insanların mobilizasyonu geliştirilen tekerlekli sandalyelerle sağlanabilmektedir. Tekerlekli sandalye kullanıcıları, başlangıçta üretilen tekerlekli sandalyeleri kontrol edebilmek için tekerlekleri ya kendi kol kasları çevirmektedirler ya da diğer insanlar tarafından sürüşe ihtiyaç duymaktaydılar. Şekil 1.5’de gösterildiği gibi sandalyeler akülü hale geldikten sonra genellikle bir joystick mekanizması ile sistemin kontrolü sağlanabilmektedir. Mekanizmanın hareketi sistemin ön tarafına yerleştirilmiş olan motorlarla sağlanmaktadır. Diğer taraftan, joystick kullanılarak sistemin kontrol edilebilmesi için kullanıcıların el kaslarını kontrol edebilmesi gerekmektedir. Vücudunun herhangi bir kasını kontrol edemeyen ya da sadece çok ufak bir kısmını kontrol edebilen engelli hastaların bu yolla sandalyeyi kontrol edebilmesi mümkün olmamaktadır. Bu durumdaki bir hastanın akülü sandalyeleri kontrol edebilmesinin yollarından biri beyin sinyallerini yorumlayarak, bunu cihazı kontrol edebilecek bir elektriksel sinyale dönüştürmektir.




Şekil 1.5. Tekerlekli ve akülü sandalye

Bu amaçla beyin bilgisayar etkileşimi için kavramsal görevler ortaya çıkarmak ve sisteme özel bunu değerlendirmek gerekmektedir. Literatürde EEG sinyalleri ile akülü sandalyelerin kontrol edilmesi üzerine birçok çalışma yapılmıştır. Son yılların popüler konularından biri olan bu konu üzerine yapılan çalışmalar halen devam etmektedir. Kim ve arkadaşları tarafından geliştirilen EEG tabanlı akülü sandalye sisteminin hareket kontrolü tanımlanan beş adet kavramsal görev ile sağlanmaktadır [20]. Yazarlar, geliştirdikleri sistemde 16 elektrot kullanarak topladıkları EEG sinyallerini 256 Hz ile örnekleterek kaydetmişlerdir. Toplanan EEG sinyallerini gürültüden arındırmak için ortalama filtresi kullanan yazarlar, beş farklı kavramsal görev için beş farklı öznelik matrisi elde etmişlerdir. Geliştirilen sistem Şekil 1.6'da verilmiştir.

Tanaka ve arkadaşları da EEG sinyallerinde örüntülerinin tanınması için bir özyineli eğitim algoritması geliştirmişlerdir [21]. Yazarlar Şekil 1.7'de de gösterilen geliştirdikleri test düzeneğinde altı farklı denekten veri toplamışlardır. Her bir denekten sağa ve sola dönmeyi düşünmesini istemişler ve her iki yön için de her bir denekten 100'er adet veri toplamışlardır. Bir saniye süren her bir deney süresince EEG sinyallerini 1024 Hz ile örnekleterek kaydetmişlerdir. EEG sinyallerindeki gürültüleri gidermek için sinyalleri bant geçiren filtreden geçirmişlerdir. Yazarlar geliştirdikleri algoritma ile farklı denekler için sağa ve sola dönüşler için sırasıyla ortalama %80 ve %83 başarı elde etmişlerdir.




Şekil 1.6. Geliştirilen akülü sandalye



Şekil 1.7. Geliştirilen EEG tabanlı akülü sandalye

Ahıcı ve arkadaşları yaptıkları çalışmada hibrid BCI sistem tabanlı bir tekerlekli sandalyenin kontrolü üzerinde çalışmışlardır [22]. Geliştirilen sistemde tekerlekli sandalye sistemine ek olarak robotik bir kolun da kontrolünü sağlamışlardır. Geliştirilen sistemde ultrasonik sensörler tabanlı bir çarpışma engelleme modülü geliştirilmiştir. EEG kavramsal görevlerinde ise görsel uyarıcılara bağlı üç farklı kavramsal görev bulunmaktadır. Tekerlekli sandalyenin navigasyonu da kafa hareketleri ile sağlanmıştır. Geliştirilen sistemde 128 Hz örnekleme frekansına sahip


EEG sensörü kullanılmıştır. EEG sensöründen bir saniyelik pencerelerle alınan sinyaller işlenerek o anda gerçekleştirilen kavramsal görev ayırt edilmeye çalışılmıştır. Kafa hareketleri EEG cihazının içerisinde bulunan jiroskop sensörü yardımıyla tespit edilmiştir. Kullanıcıların x ve y eksenlerindeki kafa hareketlerinden altı farklı komut oluşturulmuştur. Yapılan deneylerde, bütün denekler %100 başarı ile tekerlekli sandalyenin kontrolünü gerçekleştirmişlerdir. Görsel uyarıcılar kullanılarak gerçekleştirilen robotik kol kontrolünde ise ortalama %81 başarı elde edilmiştir. Geliştirilen sistem Şekil 1.8’de verilmiştir.



Şekil 1.8. Geliştirilen tekerlekli sandalye ve robotik kol sistemi

Kun Tae ve ekibi yaptıkları çalışmada görsel uyarıcılar tabanlı EEG sinyalleri kullanarak bir tekerlekli sandalyenin kontrolünü sağlamışlardır [23]. Geliştirilen sistem Şekil 1.10’da verilmiştir. Yazarlar, sistemde bulunan bir EMG sensörü ile dil hareketlerini algılayarak sistemin acil durumlarda durdurulmasını sağlamıştır. 250 Hz örnekleme frekansı ile toplanan EMG sinyallerinin gücü önceden belirlenen bir eşiği geçtiği anda tekerlekli sandalye sistemi yavaşça durdurulmuştur. EEG sinyalleri

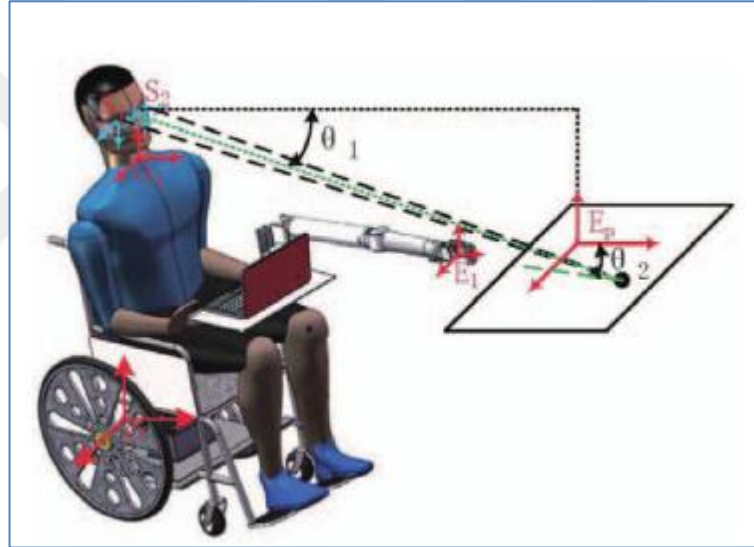
standart 10-20 yerleşimine ve 250 Hz örnekleme frekansına sahip bir cihaz kullanılarak toplanmıştır. Yazarlar geliştirdikleri sistemde EEG sinyallerini bir ön işlemde geçirerek gürültü giderimi işlemini gerçekleştirmişlerdir. Sonrasında ise ortak uzamsal örüntü algoritmasını kullanarak öznitelik çıkarmışlardır. Frekans uzayın tabanlı öznitelikler de çıkartılarak ayrıca öznitelik vektörüne eklenmiştir. Geliştirilen sistem dört sağlıklı erkek kullanıcı üzerinde denenmiştir. Yapılan deneyler sırasında bir hedef belirlenmiş ve kullanıcılardan hedefe ulaşması istenmiştir. Kullanıcıların beyin sinyallerini kullanarak 8 metre uzaklıktaki bu hedefe ortalama olarak 100 saniyede hedefe ulaşabildikleri gözlenmiştir.



Şekil 1.9. Geliştirilen BCI tabanlı tekerlekli sandalye

Chen ve ekibi yaptıkları çalışmada EEG ve EOG sinyallerini kullanarak bir BCI sistemi geliştirmişlerdir. Yazarlar yaptıkları çalışmada tekerlekli sandalyenin kontrolüne ek olarak bir de robotik kolun kontrolünü sağlamışlardır [24]. Geliştirilen sistem Şekil 1.10'da verilmiştir. Yazarlar EEG sinyallerindeki psikomotor analizlere göre hem tekerlekli sandalyeyi hem de robotik kolu kontrol etmeyi başarmışlardır. Geliştirilen sistemde EEG sinyallerini toplamak için bir adet kablosuz ve 128 Hz

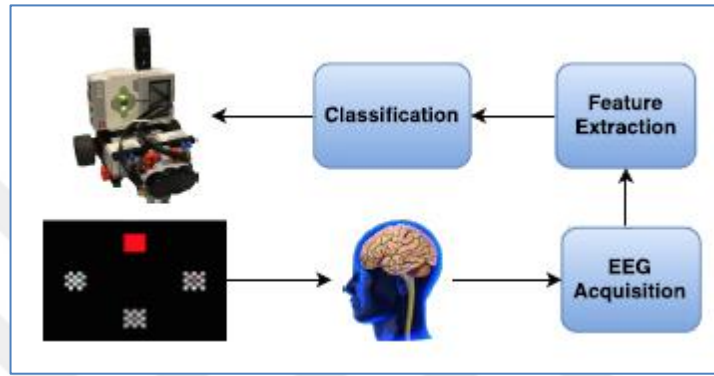
örnekleme frekansına sahip bir EEG cihazı kullanmışlardır. Yazarlar, geliştirdikleri sistemde elektrookulogram (EOG)sinyallerini (göz hareketlerini) tespit edebilmek için EEG cihazındaki ön kanallarda bulunan sensörlerden elde edilen EEG sinyallerini kullanmışlardır. Bu sinyallere ek olarak ise gözün konumunu algılamak için bir kamera kullanmışlardır. Yazarlar sinyal işleme aşamasında öznitelik çıkartmak amacıyla bağımsız bileşen analizi yöntemini kullanmışlardır. Bu adımda elde edilen öznitelikler yapay sinir ağları ile sınıflandırılarak elde edilen sonuca göre tekerlekli sandalyenin ve robotik kolun kontrolü sağlanmıştır. Yazarlar yaptıkları çalışmada geliştirdikleri sistemi bir denek üzerinde denemiş ve denegin robotik kolu başarılı bir şekilde kontrol ederek masanın üzerinde bulunan bir bardak suyu alabildiğini gözlemlemişlerdir.



Şekil 1.10. Geliştirilen EEG tabanlı tekerlekli sandalye ve robotik kol

Isaksen ve ekibi yaptıkları çalışmada görsel uyarıcılara bağlı olarak geliştirdikleri BCI sistemiyle bir tekerlekli sandalyenin kontrolü sağlamışlardır [25]. Yazarlar geliştirdikleri sistemde dört farklı görsel uyarıcı kullanmışlardır. Geliştirilen sistem Şekil 1.11’de verilmiştir. EEG sinyallerini toplamak için kullanılan cihaz standart 10/20 yerleşimine ve 600 Hz örnekleme frekansına sahiptir. Alınan EEG sinyalleri 5-30 Hz frekans bandını geçiren donanımsal bir bant geçiren filtreden geçirilmiştir. Bant geçiren filtreye ek olarak sistemde bir de 50 Hz’lik bir çentik filtresi bulunmaktadır. Yazarlar geliştirdikleri sistemde iki saniyelik EEG sinyallerinin ortalamasını almışlardır. Eğitim aşamasında toplanan verilerle test aşamasında elde

edilen sinyallerin korelasyonu incelenmiştir. Korelasyon sonucunda, elde edilen sinyalin test aşamasında elde edilen sinyallerden hangisine daha çok benzediği belirlenmiş ve sınıflandırma işlemi gerçekleştirilmiştir. Yazarlar geliştirdikleri sistemi %62'si erkek olan 20 sağlıklı kullanıcı üzerinde denemişlerdir. Bu deneylerin sonucunda ortalama %83 başarı oranı elde etmişlerdir. Yazarlar ayrıca BCI sistemlerinde başarı oranının çoklukla denek bağımlı olduğunu ve geliştirdikleri sistemin performansının da bu şekilde olduğunu vurgulamışlardır.



Şekil 1.11. Geliştirilen görsel uyarıcılar tabanlı BCI sistemi

BCI tabanlı sistemlerin yanında tekerlekli sandalye sistemi için literatürde birçok farklı kontrol mekanizması bulunmaktadır. Bu amaçla enkoder, LIDAR, Kinect, kamera, ultrasonik sensör ve EMG gibi birçok farklı sensör kullanılabilir. Araştırmacılar sensörleri kullanarak tekerlekli sandalyenin kontrolünü sağladıkları gibi çarpışma engelleme işlemini de gerçekleştirebilmektedir. Bu tez çalışması kapsamında geliştirilen sistem için de literatürdeki farklı çalışmalar incelenerek çoklu sensör destekli bir beyin bilgisayar arayüzü uyarlanmıştır.

Prassler ve arkadaşları yaptıkları çalışmada akülü tekerlekli sandalye sistemi için bir kontrol mekanizması geliştirmişlerdir [26]. Geliştirilen sistemde gömülü olarak bulunan bir mikro denetleyici ile jiroskop ve enkoder verilerini kullanmışlardır. Sistemde kullanılan ve mikro denetleyici ile haberleşen üç adet ultrasonik algılayıcı ile sistemin olası çarpışmaları engellenmiştir. Yine, sisteme entegre edilen bir LIDAR yardımıyla etraftaki engeller tespit edilmiş ve sistemin çarpışmasız geçebileceği noktalar hesaplanmıştır. Sistemin aynı zamanda joystick kullanarak da kontrol edilebilmesi sağlanmıştır. Sistemde bilgisayar olarak üzerinde Linux işletim sistemi bulunan ve Pentium II işlemcili bir adet gömülü bilgisayar kullanılmıştır.


Yazarlar geliştirdikleri sistemi insanların bulunduğu kalabalık ortamlarda denemişler ve başarılı bir şekilde çalıştığını gözlemlemişlerdir. Geliştirilen sistem Şekil 1.12’de verilmiştir.



Şekil 1.12. Geliştirilen çoklu sensör destekli tekerlekli sandalye

Kim ve arkadaşları yaptıkları çalışmada tekerlekli sandalye sistemi için dil hareketleri tabanlı bir kontrol mekanizması geliştirmişlerdir [27]. Dil hareketlerini algılamak amacıyla dilin üzerine bir adet halka yerleştirmişlerdir. Sonrasında ise ağız etrafına geliştirdikleri manyetik sensör dizisini yerleştirmişlerdir. Geliştirilen sistem Şekil 1.13’te verilmiştir. Geliştirilen sistemde aşağı, yukarı, sağ, sol, orta, orta-sol ve orta sağ olmak üzere yedi farklı sınıf kullanılmıştır. Yazarlar, öznitelik çıkarma aşamasında temel bileşen analizi yöntemini kullanmışlardır. Sınıflandırma aşamasında ise Mahalonobis uzaklığı tabanlı en yakın komşuluk algoritması kullanmışlardır. Geliştirdikleri sistemde sadece tekerlekli sandalyenin navigasyonu değil aynı zamanda tuş takımı kontrolü gibi birçok farklı görevler de yerine getirilebilmişlerdir. Çalışmada EEG sinyalleri tabanlı kontrolün gürültüden çok

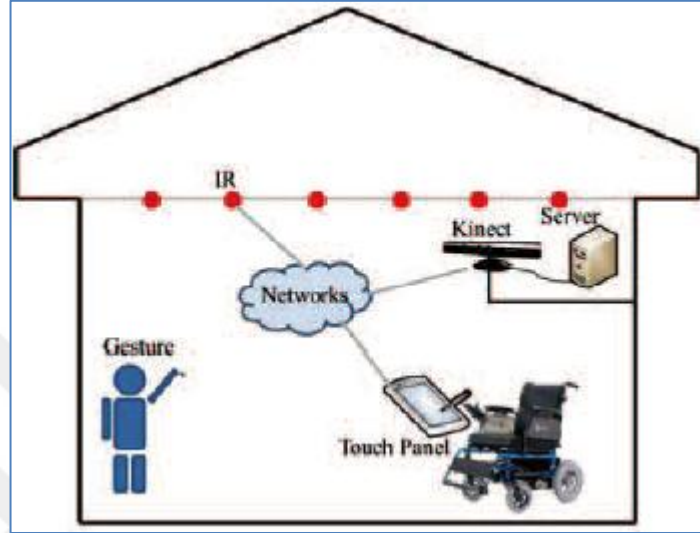
etkilendiğini belirtmişlerdir. Benzer şekilde EMG tabanlı kontrolde ise yorgunluğun sistem performansına olumsuz olarak etki ettiğini belirterek, geliştirdikleri sistemin her iki yöntemden de daha üstün olduğunu iddia etmişlerdir. Geliştirilen sistem yaşları 15 ile 40 arasında değişen 20 farklı denek üzerinde denenmiştir. Birkaç dakikalık eğitimden sonra bütün deneklerin sistemi başarılı bir şekilde kontrol edebildiği gözlenmiştir.



Şekil 1.13. Geliştirilen dil hareketli tabanlı tekerlekli sandalye kontrolü


Chang ve arkadaşları yaptıkları çalışmada tekerlekli sandalyenin navigasyonu için Kinect sensörü ve iç mekan konumlama tekniklerini kullanmışlardır [28]. Geliştirilen sistem Şekil 1.14’de verilmiştir. Geliştirilen sistemde, kullanıcılar tekerlekli sandalyeyi çağırmak için Kinect sensörü kullanmışlardır. Kinect sensörü için Microsoft tarafından geliştirilen yazılım geliştirme kiti (SDK)yazılımında bulunan iskelet algılama algoritması sayesinde kullanıcıların yaptıkları hareketler belirlenebilmiştir. Tekerlekli sandalyeyi çağırma ve park etmek amaçlı iki farklı hareket tanımlanmıştır. Eğer kullanıcı sağ elini omzundan yukarı bir seviyeye çıkartırsa tekerlekli sandalyeyi çağırma işlemi, her iki elini de omuz seviyesinden yukarıya çıkartırsa tekerlekli sandalyeyi park etme işlemi çalıştırılmaktadır. Yazarlar, iç mekan konumlama sisteminde kızıl ötesi diyotlardan yararlanmışlardır. Tavana yerleştirilen kızılötesi etiketlerden gelen sinyaller toplanmıştır. Üç farklı etiketten alınan sinyaller yardımı ile etiketlere olan uzaklıklar tespit edilmiş ve üçgenleştirme metoduyla da tekerlekli sandalyenin iç mekandaki konumu hesaplanmıştır. Sistem, tekerlekli sandalyenin çağırıldığını algıladığında, başlangıç konumunu belirleyerek

istenilen konuma gitmek için gerekli olan rota planlama işlemini yapmaktadır. Geliştirilen sistemde tekerlekli sandalyeyi kontrol edebilmek amacıyla gömülü bir donanım kullanılmıştır. Geliştirilen sistem üç farklı denek ile denenmiş ve sistemin başarılı bir şekilde çalıştığı gözlenmiştir.



Şekil 1.14. Geliştirilen Kinect tabanlı tekerlekli sandalye

Rohmer ve arkadaşları yaptıkları çalışmada noktasal lazer, EMG ve Kinect kullanarak bir tekerlekli sandalye yönlendirme asistanı geliştirmişlerdir [29]. Geliştirilen sistem Şekil 1.15'te verilmiştir.



Şekil 1.15. Geliştirilen EMG ve Kinect tabanlı tekerlekli sandalye

Kullanıcılar, sistemi kullanabilmek için gitmek istedikleri noktayı bir noktasal lazer yardımıyla belirtmektedirler. Onay ve iptal etmek için sırasıyla dişleri sıkarak ve göz kırpmak üzere iki farklı EMG hareketi tanımlanmıştır. Kinect kamerasından

elde edilen derinlik görüntüsü kullanılarak hedef noktasının ulaşılabilir olup olmadığı tespit edilmiştir. Geliştirilen algoritma, hedef noktasının ulaşılabilir olduğunu algıladığında, tekerlekli sandalye sistemini hedefe doğru yönlendirmektedir. Yazarlar EMG hareketlerinin sınıflandırılmasında ortalama %90 başarı elde etmişlerdir.

Kannan ve arkadaşları yaptıkları çalışmada tekerlekli sandalyeyi el hareketleriyle kontrol etmişlerdir [30]. Geliştirilen sistem Şekil 1.16'da verilmiştir. Sistemde kızılötesi diyotlar kullanılmıştır. Geliştirilen sistemde ileri, geri, sağ, sol, fren olmak üzere beş farklı el hareketi tanımlanmıştır. Yazarlar sistemi geliştirirken el boyutu ve açısı başta olmak üzere birçok farklı parametreyi göz önünde bulundurmuşlardır.



Şekil 1.16. Geliştirilen el hareketleri tabanlı tekerlekli sandalye

Gupta ve arkadaşları yaptıkları çalışmada tekerlekli sandalyenin kontrolü için nesnelerin internetini kullanmışlardır [31]. Geliştirilen sistem Şekil 1.17'de verilmiştir. Geliştirilen sistemde bir ataletsel ölçüm ünitesi (IMU) kullanılarak tekerlekli sandalyenin gittiği yol hesaplanmıştır. IMU kullanılarak tekerlekli sandalyenin her bir eksenindeki (x, y, z) ivme değerleri ve eksenindeki dönme açıları hesaplanmıştır. Kullanılan IMU sensörüne ek olarak bir akıllı telefonun (Samsung Galaxy S4) ivmeölçerinden alınan değerler kullanılmıştır. Her iki sensörden alınan veriler 32. dereceden 7 Hz kesim frekansına sahip bir alçak geçiren filtreden

geçirilmiştir. Yazarlar, çalışma sonucunda akıllı telefonunun ivmeölçeri kullanıldığında diğer sensörlere kıyasla konumu daha düşük hassasiyetle tespit edebildiklerini gözlemlemişlerdir.



Şekil 1.17. Geliştirilen akıllı telefon tabanlı tekerlekli sandalye

1.3. Tezin Literatüre Katkısı

Bu tez çalışması kapsamında farklı sensörler kullanılarak bir insan-makine ara yüzü geliştirilmiştir. Sistemde kullanılacak olan sensörler ticari seviyede herkesin kolaylıkla ulaşabileceği ve ucuz maliyetli olacak şekilde seçilmiştir. Bu nedenle, elde edilen sinyalin kalitesi profesyonel cihazlara oranla çok daha düşük olmaktadır. Bu durum EMG sinyalleri için ciddi bir handikap oluşturmamasına karşın EEG sinyalleri için ciddi bir sorun olarak karşımıza çıkmaktadır. Bu durum özellikle EEG sinyalleri kullanarak üç farklı kavramsal görevi ayırt edilmek istenildiğinde, problemi çok daha zor bir hale getirmektedir. Literatürde yapılan EEG tabanlı tekerlekli sandalye çalışmalarında, genellikle EEG sinyallerini toplamak için profesyonel cihazlar kullanılmıştır.

Çalışma kapsamında öncelikli olarak sensörlerden alınan ham verilerin bilgisayar ortamına aktarılması için bir yazılım geliştirilmiştir. Bilgisayar ortamına alınan veriler başlangıçta bir ön eliminasyon işlemine tabi tutulmuştur. Sonrasında ise geliştirilen özgün bir sinyal işleme algoritması ile işlenmiştir. Birçok farklı sınıflandırma teknikleri bir arada kullanılarak hibrit bir algoritma geliştirilmiştir. Geliştirilen hibrit algoritma diğer sınıflandırma algoritmalarının sonuçları karşılaştırılmış, geliştirilen algoritmanın diğer sınıflandırıcılara göre daha yüksek bir

başarım elde ettiği gözlenmiştir. Geliştirilen hibrit algoritma literatürde bulunan örnek bir veri seti üzerinde denenmiştir. Literatürde bu veri seti üzerinde yapılan birçok farklı çalışma bulunmaktadır. Tez kapsamında geliştirilen algoritma bu çalışmalar ile karşılaştırılmıştır. Bu kapsamda, geliştirilen algoritmanın literatürde yer alan algoritmalarından daha başarılı bir sonuç elde ettiği gözlenmiştir.

Algoritmanın, çevrim-dışı testlerde başarılı sonuçlar ürettiği gözlendikten sonra gerçek zamanlı testler üzerinde çalışmalar başlamıştır. Gerçek zamanlı çalışmalar bir adet tekerlekli sandalye üzerinde yapılmıştır. Gerçek zamanlı testlerde güvenliği sağlamak amacıyla bir çarpışma engelleme algoritması geliştirilmiştir. Bu amaçla sisteme bir adet Kinect sensörü monte edilmiştir. Kinect sensöründen alınan derinlik görüntüleri gerçek zamanlı olarak çalışabilen özgün bir görüntü işleme algoritması ile işlenerek tekerlekli sandalyenin etrafındaki engeller tespit edilmiştir. Çarpışma riski oluşturan yakın bir engel tespit edildiğinde sistemin acil olarak durması sağlanmıştır.

Kullanıcılardan geliştirilen bu sistemi gerçek zamanlı olarak kontrol etmesi istenmiştir. Bu amaçla farklı rotalar belirlenmiş ve kullanıcılardan bu rotaları takip etmeleri istenmiştir. Yapılan testler sonucunda kullanıcıların EMG sinyalleri ile sistemi rahatlıkla kontrol edebildiği gözlenmiştir. Fakat EMG tabanlı kontrolde belirli bir süre sonra yorulma nedeniyle kaslardaki sinyallerin genlik seviyelerinin azaldığı gözlenmiştir. Bu da sistemin performansını negatif yönde etkilemektedir. Yorulma süresi kullanıcıya göre değişmekle beraber ortalama 45-60 dakika arasındadır. EEG tabanlı kontrolde ise sonuçlar yine kullanıcı bağımlı olmakla beraber, çevresel şartlar da performansı önemli derecede etkilemektedir.

Literatürde bulunan EEG tabanlı tekerlekli sandalye uygulamalarının çoğunda yüksek maliyetli profesyonel EEG cihazları kullanılmıştır. Benzer şekilde EMG uygulamalarında da yine maliyetli cihazlar kullanılmıştır. Bu cihazların bir önemli dezavantajı da kablolu olmalarıdır. Bu çalışmada farklı olarak kablosuz ve uygun maliyetli cihazlar tercih edilmiştir.

Tekerlekli sandalye sistemlerinde güvenli sürüş sağlayabilmek amacıyla genellikle laser alan tarayıcı tabanlı çözümler kullanılmaktadır. Bu sistemler de yine maliyetli sistemler olarak karşımıza çıkmaktadır. Bu çalışmada, maliyetli sistemlere alternatif

olarak uygun maliyetli bir sensör olan Kinect kullanılmıştır. Düşük çözünürlükte olmasına rağmen, geliştirilen Kinect sensörü tabanlı güvenli sürüş algoritması da başarılı bir şekilde çalışmaktadır.

Geliştirilen sistemde motorlarda enkoder olmaması bir eksiklik olarak görülmektedir. Bu nedenle motorlarda hız veya konum kontrolü yapılamamaktadır. Bu nedenle darbe genişlik modülasyonu (PWM) tabanlı bir açık çevrim kontrolü yapılmıştır.



2. DENEY DÜZENEĐİ

Bu bölümde tez kapsamında kullanılan tekerlekli sandalye, sistemde kullanılan sensörler ve geliştirilen elektromekanik sistem hakkında bilgi verilecektir. Gerçek zamanlı deneylerin geliştirilebilmesi amacıyla Şekil 2.1’de gösterilen bir adet tekerlekli sandalye sistemi temin edilmiş ve üzerinde geliştirmeler yapılmıştır. Sistemin mekanik ve elektronik tasarımı detaylı bir şekilde bu bölümde irdelenecektir.



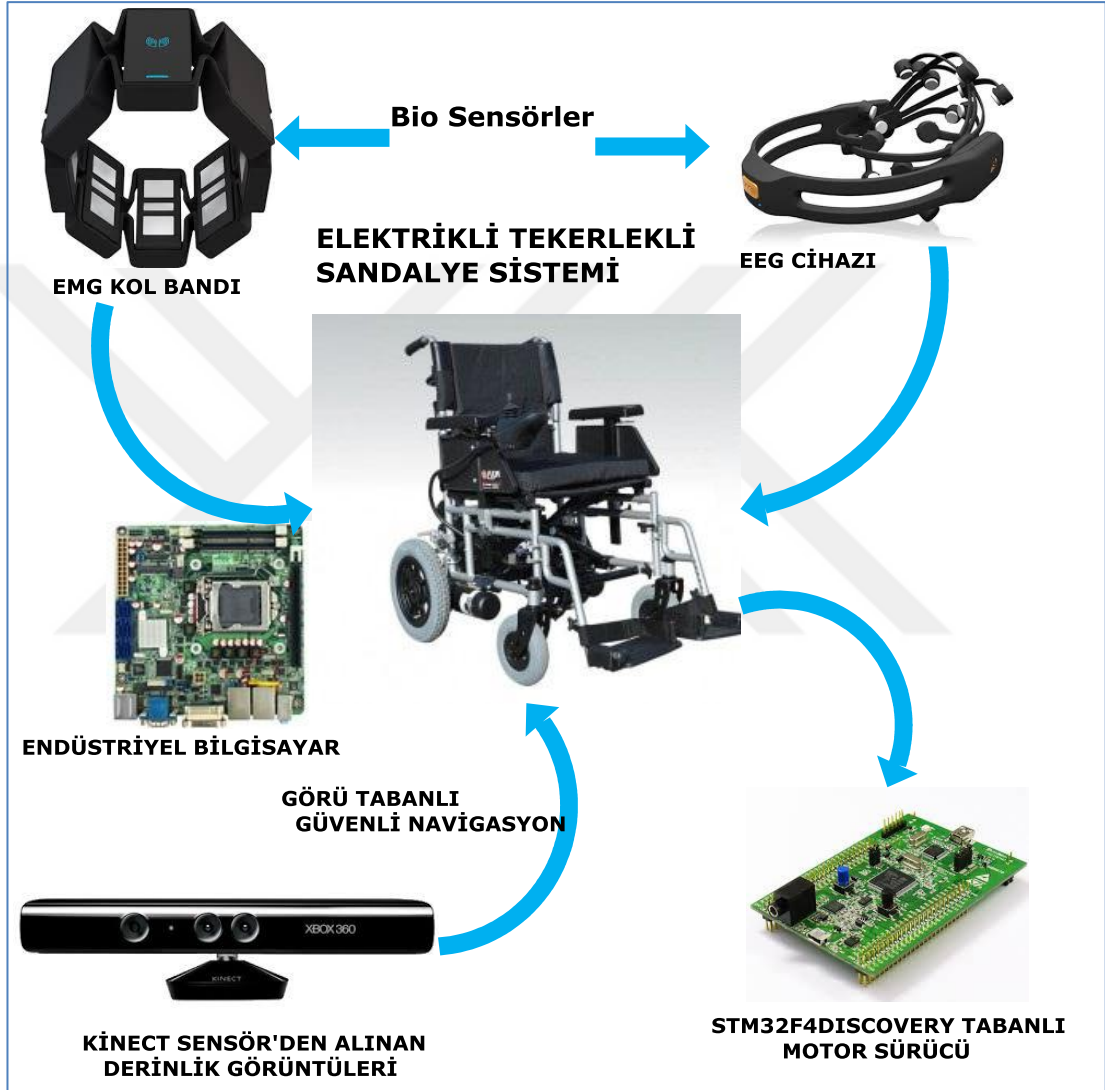
Şekil 2.1. Deney düzeneğinde kullanılan tekerlekli sandalye

Kullanılan tekerlekli sandalyenin teknik özellikleri Tablo 2.1’de verilmiştir [32]. Bu çalışma kapsamında tekerlekli sandalyenin kendi kontrolörü devre dışı bırakılarak, tez çalışmasına özel geliştirilen kontrolör kartı tarafından kontrol edilmesi sağlanmıştır.

Tablo 2.1. Temin edilen tekerlekli sandalyenin özellikleri

Parametre	Değeri
Akü Tipi	36A Jel Akü 2 Adet
Hız	7 Km
Taşıma Kapasitesi	150 Kg
Motor	400 Watt 2 Motion Tech

Bu bölümde öncelikli olarak deney düzeneğinin mekanik ve elektronik bileşenleri tanıtılacak, sonrasında ise sistemde kullanılan sensörler ve teknik özellikleri detaylı bir şekilde incelenecektir. Sistemin gerçek zamanlı olarak çalışabilmesi için sistem üzerinde yapılmış olan güncellemeler ayrıca incelenecektir. Tez kapsamında geliştirilen sistemin genel mimarisi Şekil 2.2’de verilmiştir.



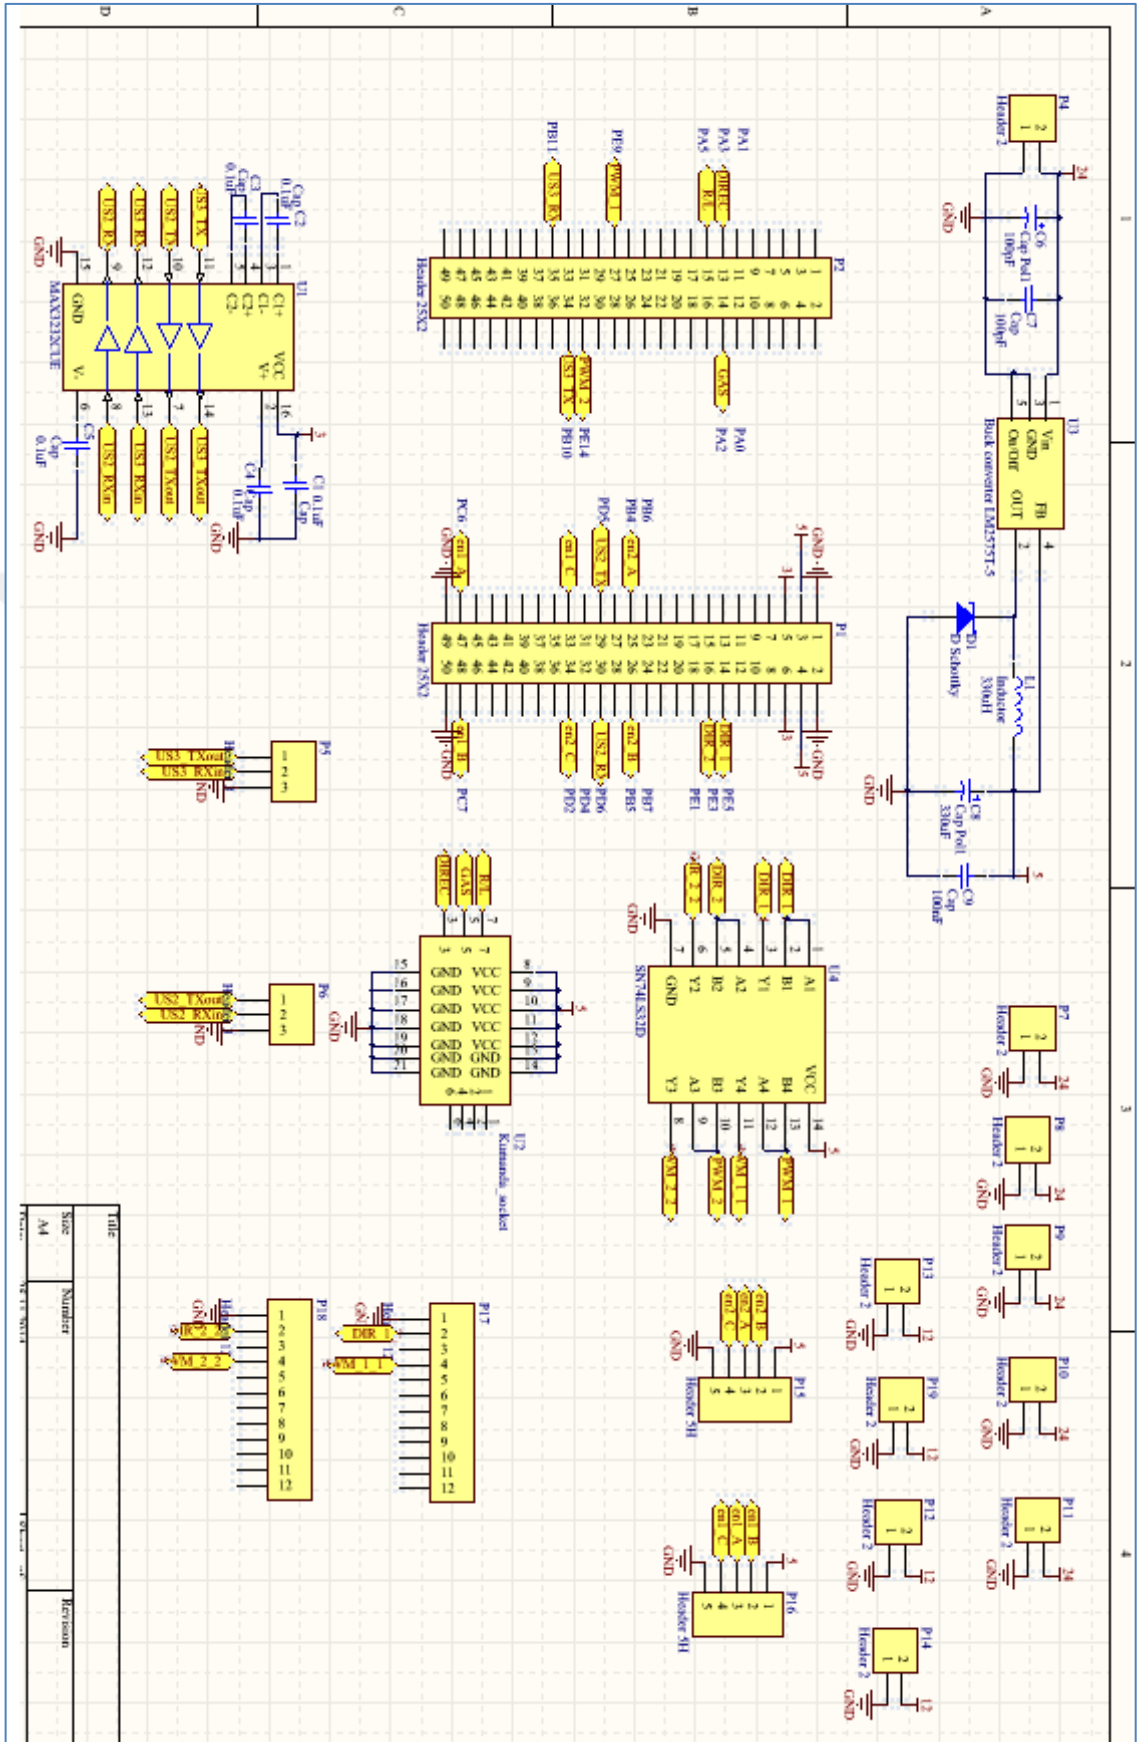
Şekil 2.2. Sistemin genel mimarisi

2.1. Sistemin Elektronik Tasarımı


Tez kapsamında kullanılan tekerlekli sandalyenin üzerinde kurulu olarak gelen kontrolör daha önce de ifade edildiği gibi devre dışı bırakılmış ve sistemin kontrolü özel olarak tasarlanan donanıyla kontrol edilmiştir. Sistemde bulunan farklı sensörlerden veri toplamak amacıyla sisteme bir adet endüstriyel bilgisayar entgre

edilmiştir. Geliştirilen Kinect tabanlı emniyetli sürüş algoritması da yine bu endüstriyel bilgisayar üzerinde çalışmaktadır. Ayrıca, geliştirilen sinyal ve görüntü işleme algoritmaları, motor kontrol kartı ile seri port üzerinden haberleşerek motorların hareketleri için gerekli sinyaller oluşturulmaktadır. Tekerlekli sandalyenin alternatif olarak uzak bir bilgisayardan da kontrolünü sağlamak amacıyla, sistem üzerindeki endüstriyel bilgisayar bio-sinyalleri işleyen uzak bir bilgisayar ile kablosuz ağ üzerinden UDP protokolü ile haberleşerek gelen hız bilgisine göre motorların hızlarını ayarlamaktadır. Sistemde kullanılan bilgisayarın enerjisini sağlamak amacıyla bir adet 24V-ATX dönüştürücü kullanılmıştır. Sistemin hareketini sağlayan motorlarda enkoder bulunmadığından PWM tabanlı açık çevrim kontrol yaklaşımı kullanılmıştır.

Stm32f4Discovery kartı birçok farklı özelliği ve uygun fiyatı ile günümüzde gömülü donanım geliştirmek isteyen kullanıcılar için etkili bir seçenek olarak karşımıza çıkmaktadır. Bu çalışma kapsamında geliştirilen motor sürücü kartının üzerinde de Stm32f4Discovery kartı bulunmaktadır. Geliştirilen kartın şematik ve PCB çizimleri sırasıyla Şekil 2.3 ve 2.4'te verilmiştir. Kart üzerinde kullanılan motor sürücülerini yüksek güçlü olacak şekilde seçilmiştir. Yapılan deneylerde sistemdeki DC motorların tekerlekli sandalyenin üzerinde boşken ve tekerlekler boşta iken 3A akım çektiği gözlenmiştir. Tekerlekli sandalyenin üzerinde herhangi biri olduğunda ise çekilen akımlar yaklaşık olarak 10A seviyelerine yükseldiği gözlenmiştir. Bu nedenle sisteme 23A'lık DC motor sürücülerini entegre edilmiştir. Sistem, sensörlerden alınan biyo-sinyallerle kontrol edilebildiği gibi, alternatif olarak uzaktan kumanda ile de kontrol edilebilmektedir. Sistemin güvenliğini sağlamak adına, uzaktan kumandanın devreye girmesi durumunda diğer tüm kontrol kaynakları yazılımsal olarak devre dışı bırakılmaktadır. Geliştirilen gömülü yazılım kodları eklerde verilmiştir.



Şekil 2.3. Geliştirilen kontrol kartının şematik çizimi



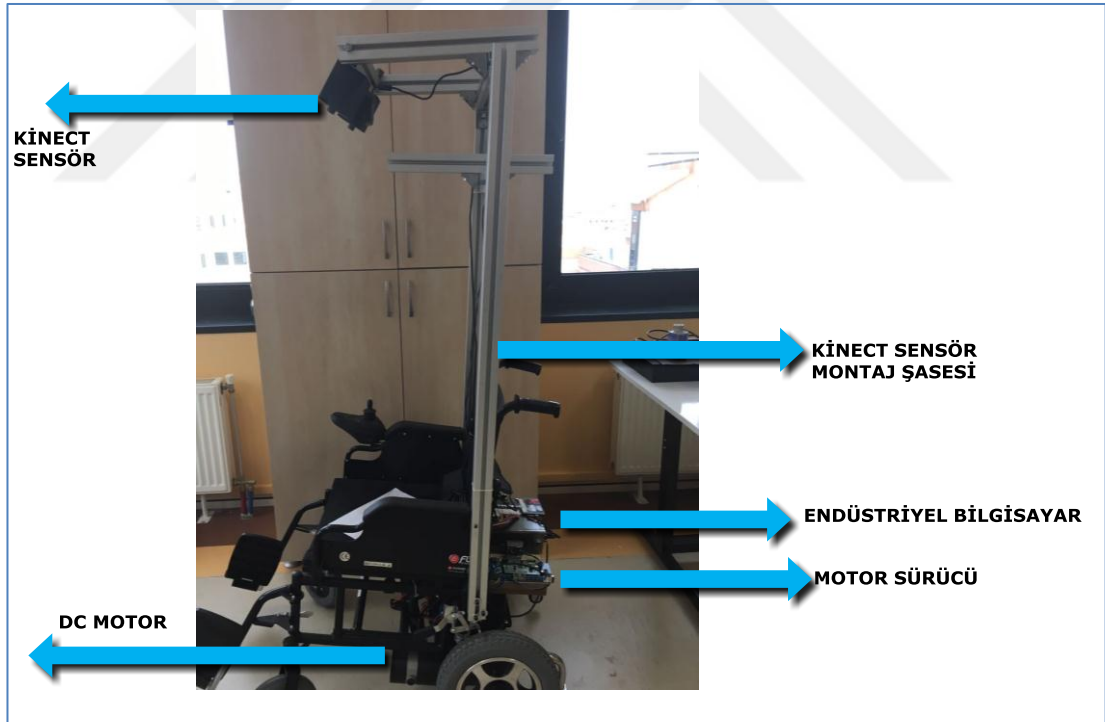
Şekil 2.4. Geliştirilen kontrol kartı

2.2. Sistemin Mekanik Tasarımı

Geliştirilen sistemde, elektronik revizyonlara ek olarak bazı mekanik revizyonlar da yapılmıştır. Kinect sensörünün, sandalyenin etrafında gördüğü alanı güvenli sürüş için optimize edecek şekilde sisteme monte edilmesi amacıyla geliştirilen mekanizmanın teknik çizimi Şekil 2.5'te verilmiştir. Ayrıca sistemin son hali ve sistemdeki bileşenlerin isimlendirilmesi de Şekil 2.6'da verilmiştir.



Şekil 2.5. Teknik çizim



Şekil 2.6. Sistem Bileşenleri

2.3. Sistemde Kullanılan Sensörler ve Sinyallerin Toplanması

Geliştirilen sistemde EEG ve EMG verilerinin toplanması için kablosuz EEG ve EMG sensörleri temin edilmiştir. Temin edilen sensörlerin özellikleri bu bölümde anlatılacaktır. Sensörler seçilirken kablosuz ve kolay kurulumuna sahip olması gibi

özellikler dikkate alınmıştır. Sensörlerden ham verilerin alınabilmesi için geliştirilen programların detayları da bu bölümde detaylandırılacaktır.

2.3.1. EMG sensörü

Tez çalışması kapsamında, EMG sinyallerini ölçmek amacıyla bir adet Thalmic Labs tarafından üretilen kablosuz kol bandı (myo-aramband) temin edilmiştir. Şekil 2.7’de temin edilen EMG kol bandı verilmiştir [33].



Şekil 2.7. Kullanılan EMG sensörü

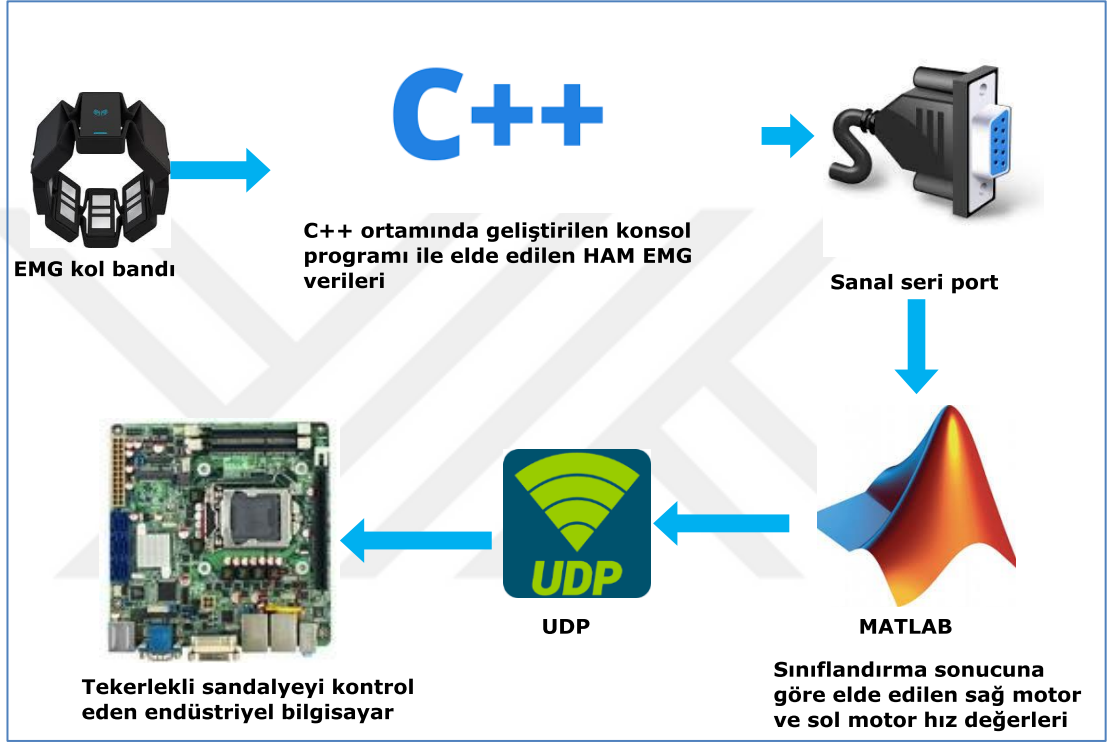
Temin edilen kol bandı bilgisayar ile bluetooth üzerinden haberleşmektedir. Thalmic Labs tarafından ücretsiz olarak verilen yazılım geliştirme kiti kullanılarak ham EMG ve GYRO verilerine ulaşmak mümkündür. Thalmic Labs EMG bilekliği ile beraber gelen yazılım, temel olarak beş farklı hareketi algılayabilmektedir. Arayüz kullanılarak farklı hareketler de tanımlanabilmektedir. Kol bandı tarafından tanımlanabilen temel hareketler Şekil 2.8’de verilmiştir.



Şekil 2.8. EMG bileklik tarafından tanınan hareketler

Ham EMG verileri Myo-Kol bandının yazılım geliştirme kiti (SDK) kullanılarak Visual Studio ortamına aktarılmıştır. Sistemin örnekleme frekansı 1 kHz olacak

şekilde ayarlanmıştır. Her bir kanaldan 1ms'de bir veri toplanmaktadır. Toplanan verilerin mutlak ortalama, standart sapma ve yaklaşık entropi değerleri her 50 örnek için hesaplanmıştır. Daha sonrasında hesaplanan bu değerler sanal seri port kullanılarak Matlab ortamında alınmıştır. C++ kullanılarak geliştirilen projenin kaynak kodları eklerde verilmiştir. EMG sensörü için veri akış yönü Şekil 2.9'da verilmiştir.



Şekil 2.9. EMG veri akış yönü

2.3.2. EEG sensörü

Tez çalışması kapsamında, EEG sinyallerini ölçmek amacıyla bir adet kablosuz EEG başlık temin edilmiştir. Şekil 2.10'da temin edilen EEG başlık verilmiştir. Temin edilen EEG başlığın temel özellikleri aşağıdaki gibidir;

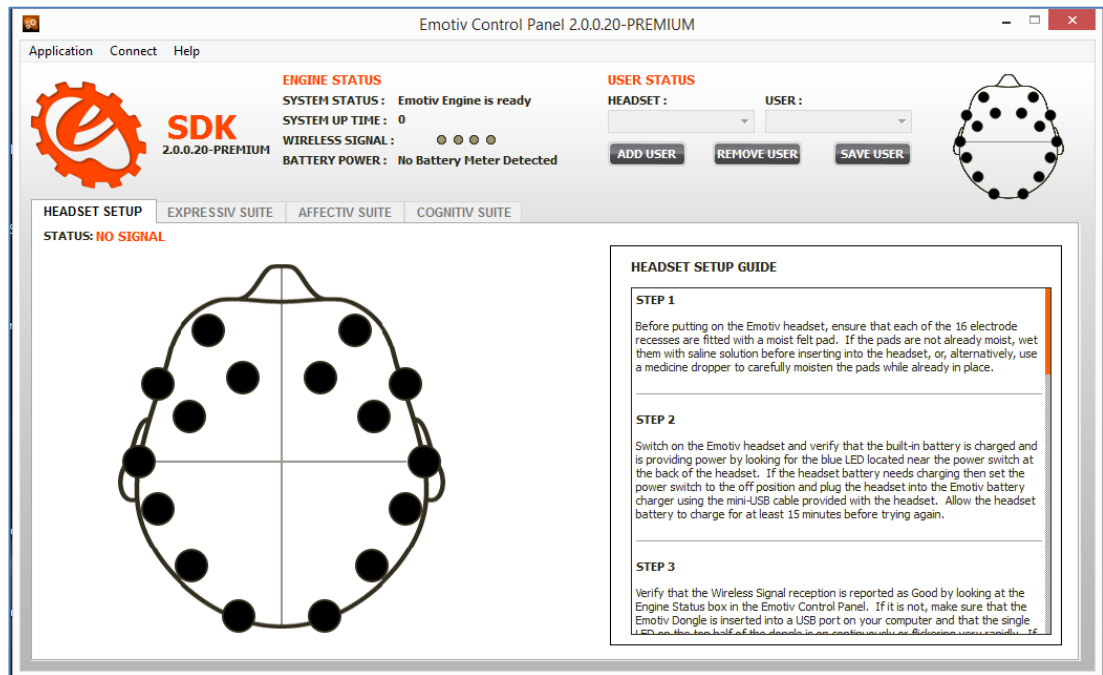
- 14 kanal ADC
- 128 Hz örnekleme periyodu
- 16 bit çözünürlük (1,95uV)
- 256 mVpp dinamik aralık
- 12 saat batarya ömrü
- Kablosuz 2,4 Ghz frekansında çalışma

- EEG ölçümü için uygun empedans.



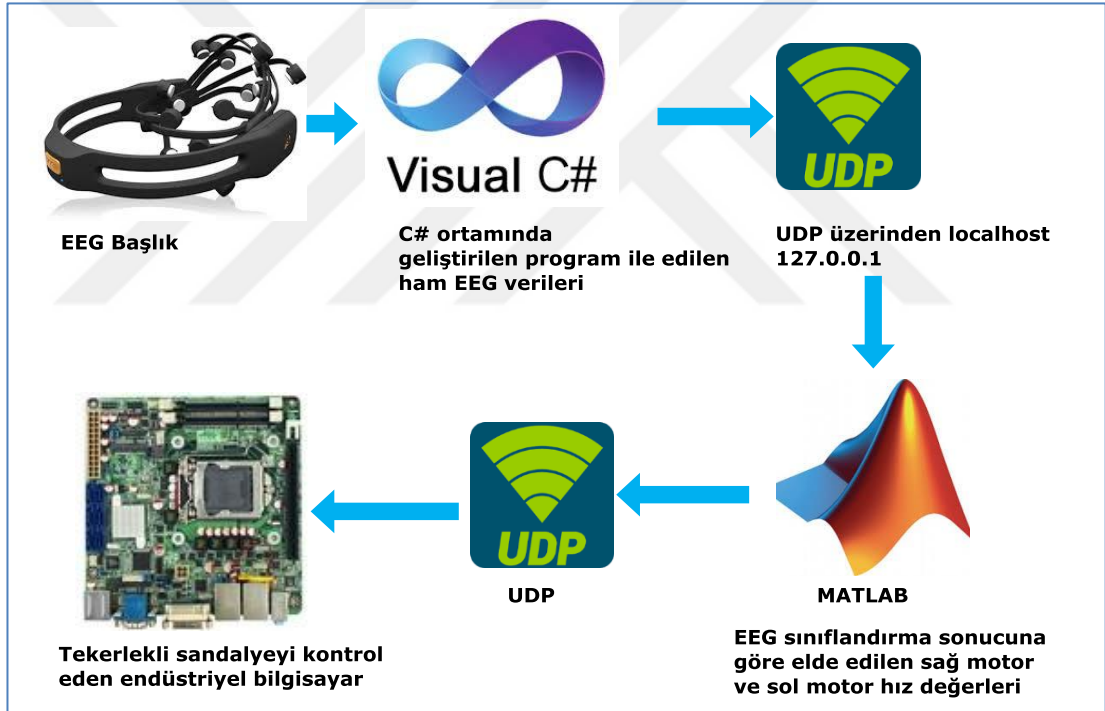
Şekil 2.10. Emotive EEG başlık

Emotive EEG başlığı kullanarak EEG sinyallerini toplayabilmek için Emotive SDK'sı içerisinde yer alan TestBench programı kullanılmıştır. Test Bench programı kullanılarak elde edilen EEG sinyalleri “edf” formatında kaydedilmektedir. Toplanan EEG verileri MATLAB ortamında geliştirilen bir programla işlenmiştir. Şekil 2.11’de Test Bench programının ara yüzü verilmiştir. Bu ara yüzde sensörlerin 10-20 yerleşimine göre yerleştirildiği görülmektedir. Arayüzde konumlandırılan sensörlerin gösterim renkleri empedans kalitesine göre değişmektedir. Sağlıklı bir EEG verisi alınabilmesi için sistemdeki tüm sensörlerin yeşil renkte olması gerekmektedir.



Şekil 2.11. Emotive EEG başlık veri alma programı

Geliştirilen sistemde EEG verilerinin gerçek zamanlı olarak toplanması gerekmektedir. Bu amaçla C# ortamında bir program geliştirilmiştir. Bu program yardımıyla EEG verileri gerçek zamanlı olarak MATLAB ortamına aktarılmıştır. Bu amaçla C# ve MATLAB ortamında geliştirilen iki ayrı program UDP üzerinden haberleştirilmiştir. Geliştirilen C# programının kaynak kodları eklerde verilmiştir. Gerçek zamanlı uygulamada her bir saniyede 14 kanaldan toplanan EEG verileri ile iki kanaldan elde edilen ve kafa hareketlerinin tespitinde önemli rol oynayan GYRO sinyalleri her biri 4096 byte olan bir ara bellek kullanılarak MATLAB ortamına gönderilmiştir. Verilerin gerçek zamanlı olarak elde edilmesini ve işlenmesini sağlayan Graphical User Interface (GUI)'nin kodları eklerde verilmiştir. EEG sensörü için veri akış yönü Şekil 2.12’de verilmiştir.




Şekil 2.12. EEG sensör için veri akış yönü

2.3.3. Kinect sensörü

Geliştirilen tekerlekli sandalye sisteminin güvenli sürüşünü sağlamak amacıyla sisteme bir adet Kinect sensörü dahil edilmiştir. Kinect, Microsoft tarafından 2010 yılında oyun amaçlı olarak çıkartılmıştır. Daha sonra yine Microsoft tarafından çıkartılan SDK kullanılarak derinlik görüntüsü kolaylıkla elde edilebilmekte ve bilgisayar ortamına aktarılabilir. Kinect piyasaya çıkmadan önce sadece çok

maliyetli kızılötesi kameralarla elde edilebilen derinlik görüntüsüne erişim, Kinect sensörü ile çok kolay hale gelmiştir. Bu nedenle Kinect tabanlı akademik çalışmaların sayısı gün geçtikçe artmaktadır [35-38].



Şekil 2.13. Kinect sensör içyapısı

Kinect sensörünün içyapısı Şekil 2.13'te verilmiştir. Şekilden de görülebileceği gibi kinect sensörün iç yapısında mikrofonlar, kızılötesi projektör, kızılötesi kamera, renkli kamera ve indikatör Led bulunmaktadır. Kinect sensörü, kızılötesi projektör ve kızılötesi kamera yardımıyla derinlik görüntüsünü elde edebilmektedir. Bu amaçla kızılötesi projektörden yayılan kızılötesi ışık sensörün etrafında bulunan nesnelere çarparak geri dönmektedir. Kızılötesi kamera ise geri dönen ışığın şiddetine göre bir uzaklık değeri hesaplamaktadır. Bu nedenle derinlik görüntüsünde hata olmaktadır. Kinect sensörünün yeni modelinde ise kızılötesi ışığın gidiş ve dönüş süresi hesaplanarak derinlik değerleri daha doğru bir şekilde elde edilmektedir.

Kinect sensör kullanılarak geliştirilen güvenli sürüş algoritması sistem üzerinde bulunan ve tekerlekli sandalyeyi kontrol eden bilgisayar üzerinde çalıştırılmıştır. Geliştirilen güvenli sürüş algoritması bir sonraki bölümde detaylı olarak ele alınacaktır.

2.3.4. Sistemde kullanılan kamera

Geliştirilen tekerlekli sandalye sisteminin göz hareketleri tabanlı kontrolü için sisteme bir adet web-cam entegre edilmiştir. Bu amaçla Logitech markasının ürettiği C270 model kamera kullanılmıştır. Kullanılan kamera Şekil 2.14’te verilmiştir. Kullanılan kameradan MATLAB ortamına alınan görüntüler işlenerek kullanıcının hangi yöne baktığı tespit edilmeye çalışılmıştır. Geliştirilen görüntü işleme algoritması detaylı olarak izleyen bölümlerde anlatılacaktır.



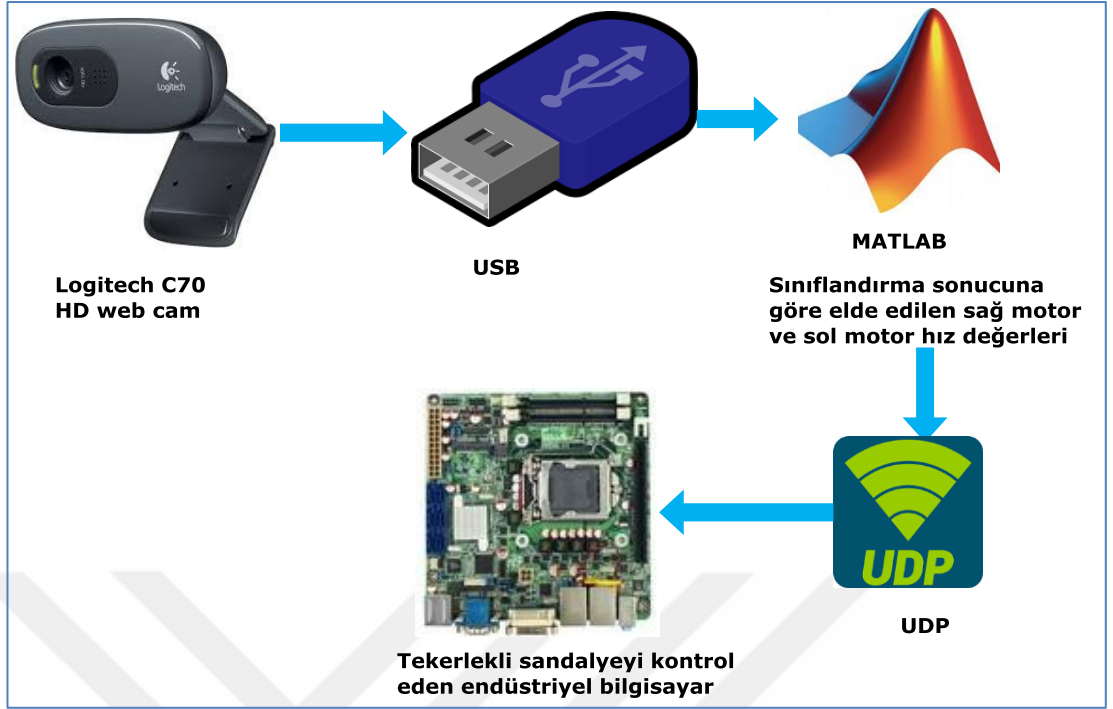
Şekil 2.14. Kullanılan kamera

Kullanılan kameranın özellikleri Tablo 2.2’de verilmiştir.

Tablo 2.2. Kullanılan kamera özellikleri

Parametre	Değeri
Çözünürlük	1280 x 720
Haberleşme ara yüzü	USB 2.0
Saniyedeki görüntü sayısı	30

Tablo 2.2’de de ifade edildiği gibi kameradan saniyede 30 görüntü alınmaktadır. Bu nedenle görüntünün alınması işlemi yaklaşık olarak 33 ms sürmektedir. Göz hareketleri tabanlı kontrol için veri akış yönü Şekil 2.15’te verilmiştir.



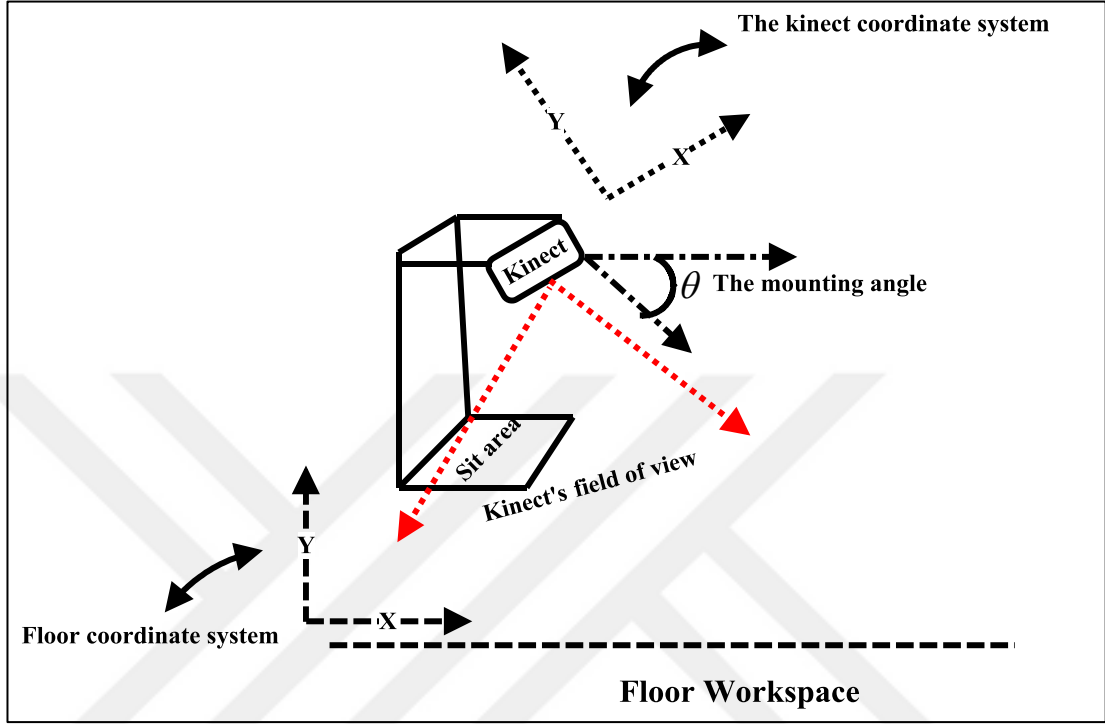
Şekil 2.15 Göz hareketleri için veri akış yönü

3. KINECT TABANLI GÜVENLİ SÜRÜŞ ALGORİTMASI

Bu bölümde tez kapsamında geliştirilen görü tabanlı güvenli sürüş algoritması detaylı olarak anlatılacaktır. Bu çalışmada Kinect sensöründen alınan derinlik görüntüleri kullanılarak bir güvenli sürüş algoritması geliştirilmiştir. Öncelikli olarak derinlik görüntüleri MATLAB ortamında gerçek zamanlı olarak alınmaktadır. Elde edilen görüntüler yine MATLAB ortamında geliştirilen algoritma ile işlenerek, tekerlekli sandalyenin etrafında hareketi engelleyebilecek bir engel olup olmadığı tespit edilmektedir. Algoritmanın çarpışma riski teşkil eden bir engel algılaması durumunda, kontrol kartına sistemin acil olarak durdurulması için bir sinyal gönderilmektedir. Kontrol kartının bu sinyali algılaması sonrasında başka kaynaklardan gelen herhangi bir kontrol komutu göz ardı edilmekte ve etrafında bulunan engeller kalkana kadar sistemin hareketi durdurulmaktadır. Tekerlekli sandalyenin etrafındaki engeller, Kinect sensöründen alınan derinlik görüntüsünün, sistemin ilk açılışında alınan 20 görüntünün ortalamasıyla elde edilen arka plan görüntüsünden çıkarılmasıyla algılanmaktadır. Bu nedenle ilk açılışta sistemin etrafında arka plana dahil olabilecek herhangi bir nesnenin olmaması gerekmektedir. Kinect sensörünün görüş alanı montaj yüksekliği ve açısına bağlı olarak değişmektedir. Montaj açısı çok küçük olursa, derinlik kamerası daha çok ileriye gösterecek, sistemin yakın çevresinden ve zeminden fazla bir görüntü alamayacaktır. Diğer taraftan, montaj açısı çok büyük olursa Kinect sadece tekerlekli sandalye etrafındaki kısıtlı bir alanı görebilecektir.

Kinect montaj açısı sıfır derece olmadığından, Kinect koordinat sisteminin x-y eksenleri ile zeminin koordinat sisteminin x-y eksenleri birbirleri ile paralel olmamaktadır. Zemin üzerinde bulunan noktaların zemin koordinat sistemine göre derinlik (z) değerleri sabit olmasına karşın, montaj açısından dolayı Kinect koordinat sistemine göre ölçülen derinlik değerleri sensörden uzaklaştıkça artmaktadır. Zemindeki bu farklılığı giderebilmek için iki koordinat düzlemi birbirleri ile paralel hale getirilmelidir. Bunun yapılabilmesi için bir koordinat dönüşümüne ihtiyaç vardır. Bu koordinat dönüşümü ile zemindeki bütün noktaların aynı derinlik değerine

sahip olması amaçlanmaktadır. Bu dönüşümün yapılabilmesi için Kinect sensörü dış matrisinin kamera kalibrasyonu metotlarıyla hesaplanması gerekmektedir. Sistem üzerinde kullanılan koordinat düzlemleri Şekil 3.1’de verilmiştir.



Şekil 3.1. Kinect sensör koordinat düzlemi

Kamera kalibrasyonu görüntü işleme uygulamalarında sıklıkla uygulanan bir yöntemdir [39-41]. Herhangi bir kameranın kalibrasyonunun yapılabilmesi için kameranın iç ve dış matrislerinin hesaplanması gerekmektedir. İç matris kameranın odak uzaklığı (f), kamera kalibrasyon katsayısı (c_x, c_y), piksel genişliği (s_x) ve piksel yüksekliği (s_y) gibi kamera parametrelerine bağlıdır. Bu parametrelere bağlı olarak elde edilen kamera iç matrisi Denklem (3.1)'deki gibi;

$$M_{\text{int}} = \begin{bmatrix} -\frac{f}{s_x} & 0 & -c_x \\ 0 & -\frac{f}{s_y} & -c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (3.1)$$

olacaktır.

Bu çalışmada Kinect derinlik kamerasının iç parametreleri SDK tarafından sağlanan değerler kullanılarak elde edilmiş ve bu değerler Tablo 3.1’de gösterilmiştir.

Tablo 3.1. Kinect parametreleri

Parametre	Değeri
f/s_x	591,040
f/s_y	594,21
c_x	242,73
c_y	339,30

Herhangi bir pikselin gerçek dünya koordinatları kamera iç matrisi M kullanılarak Denklem (3.2)’de verildiği gibi;

$$\begin{bmatrix} x_k \\ z_k \\ y_k \\ z_k \\ 1 \end{bmatrix} = M^{-1} \begin{bmatrix} i \\ j \\ 1 \end{bmatrix} \quad (3.2)$$

hesaplanabilmektedir. Kamera dış matrisi kamera yerleşime göre değişmektedir. Zemin üzerinde yer alan noktaların Kinect tarafından elde edilen derinlik değerleri, Kinect kamerasının x-y eksenini ile zemin düzleminin x-y eksenini arasındaki montaj açısı nedeniyle sensöre olan uzaklığa bağlı olarak değişmektedir. Zemin üzerindeki tüm noktaların sabit derinlik değerine sahip olabilmesi için Kinect koordinat sisteminin x ve y eksenleri etrafında döndürülerek zemin düzlemine paralel hale getirilmesi gerekmektedir. Denklem (3.3)’te x ve y eksenlerindeki rotasyon matrisleri;

$$R_x = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\theta) & -\sin(\theta) \\ 0 & \sin(\theta) & \cos(\theta) \end{bmatrix}, \quad R_y = \begin{bmatrix} \cos(\beta) & 0 & \sin(\beta) \\ 0 & 1 & 0 \\ -\sin(\beta) & 0 & \cos(\beta) \end{bmatrix} \quad (3.3)$$

verilmiştir. Bu denklemlerde yer alan θ ve β açıları x ve y eksenleri etrafındaki dönme açılarını ifade etmektedir. Her iki ekseninde de dönmeyi sağlayan rotasyon matrisi ($R=R_x R_y$) Denklem (3.4)’deki gibi;

$$R = \begin{bmatrix} \cos(\phi) & 0 & \sin(\phi) \\ \sin(\theta)\sin(\phi) & \cos(\theta) & -\sin(\theta)\cos(\phi) \\ -\cos(\theta)\sin(\phi) & \sin(\theta) & \cos(\theta)\cos(\phi) \end{bmatrix} \quad (3.4)$$

olacaktır. Bu denklemlerde z eksenindeki dönüş derinlik ölçümlerini etkilemediği için R_z rotasyon matrisi 0 derece dönme açısına denk gelen birim matris olarak kabul edilmiştir. Kinect koordinat sistemindeki bir nokta $p_k=[x_k \ y_k \ z_k]$ zemin koordinat sistemine paralel olan yeni koordinat sistemindeki bir noktaya $p_m=[x_m \ y_m \ z_m]$ Denklem (3.5) kullanılarak aşağıdaki gibi;

$$p_m=Rp_k \quad (3.5)$$

hesaplanabilmektedir. Denklem (3.5) aşağıdaki gibi;

$$\begin{aligned} x_m &= r_{11}x_k + r_{12}y_k + r_{13}z_k \\ y_m &= r_{21}x_k + r_{22}y_k + r_{23}z_k \\ z_m &= r_{31}x_k + r_{32}y_k + r_{33}z_k = d_m \end{aligned} \quad (3.6)$$

tekrar yazılabilir. Denklem (3.6)'daki r_{ij} elemanı R matrisinin i. satır ve j. sütun elemanıdır. Bu noktalardaki derinlik bilgisini gösteren d_m değeri zemindeki her bir eleman için sabit olmalıdır. Denklem (3.6)'nın son satırı tekrar yazıldığında Denklem (3.7) aşağıdaki gibi;

$$r_3^T p_m = d_m \quad (3.7)$$


elde edilmektedir. Denklem (3.7) 'de r_3 rotasyon matrisinin (R) son satırını, d_m ise zemindeki noktaların derinlik değerini ifade etmektedir. Zemin üzerinde yer alan bütün noktaların Denklem (3.8)'i sağlaması gerekmektedir. Bu nedenle r_3 'ü ve d_m 'yi çözebilmek amacıyla zemin üzerinde bulunan N adet nokta örnek olarak alınmıştır. Alınan N adet noktadan elde edilen N adet denklem matris formatında Denklem (3.8)'deki gibi;

$$\begin{bmatrix} p_{k1}^T & -1 \\ p_{k2}^T & -1 \\ p_{k3}^T & -1 \\ \cdot & \cdot \\ \cdot & \cdot \\ p_{kN}^T & -1 \end{bmatrix} \begin{bmatrix} r_3^T \\ d_m \end{bmatrix} = 0 \quad (3.8)$$

elde edilmektedir. Denklem (3.8) $Ax = 0$ formatında Denklem (3.9)'daki gibi;

$$A = \begin{bmatrix} p_{k1}^T & -1 \\ p_{k2}^T & -1 \\ p_{k3}^T & -1 \\ \cdot & \cdot \\ \cdot & \cdot \\ p_{kN}^T & -1 \end{bmatrix} x = \begin{bmatrix} r_3^T \\ d_m \end{bmatrix} \quad (3.9)$$


yazılabilmektedir. Denklem (3.9)ün çözümü tekil değer ayrıştırılması yöntemi ile elde edilebilmektedir. Denklem (3.9)ün çözümü ile elde edilen rotasyon açıları Denklem (3.5)'te yerine koyularak düzeltilmiş derinlik görüntüsü elde edilebilmektedir. Zeminin düzeltilmiş ve düzeltilmeden önceki örnek derinlik görüntüleri Şekil 3.2'de verilmiştir.



Şekil 3.2. Orijinal ve düzeltilmiş zemin derinlik haritası

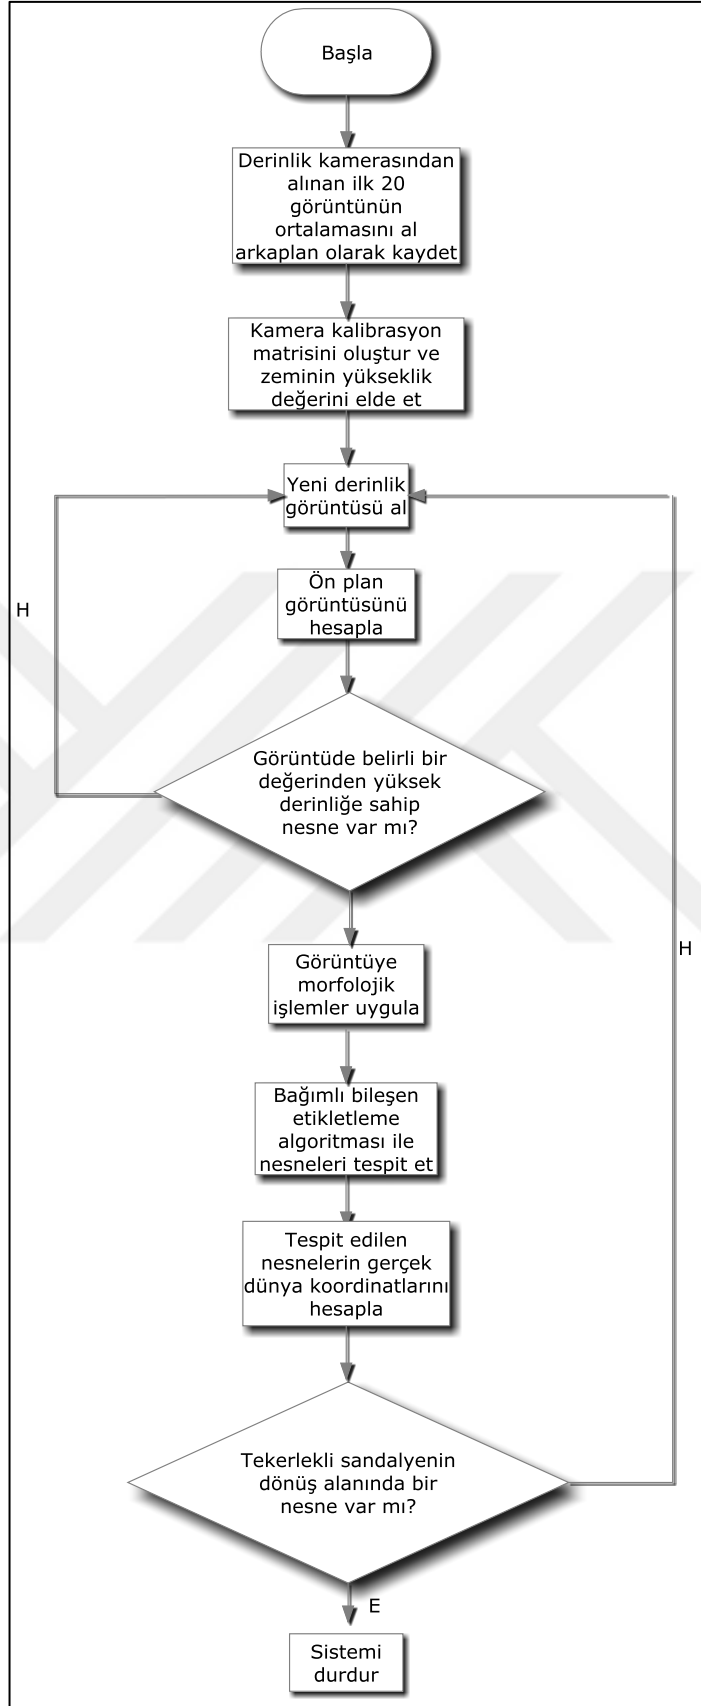
Geliştirilen görü tabanlı güvenli sürüş algoritması sistemin açılıştan sonraki ilk 20 görüntünün ortalamasını alarak sonucu arka plan görüntüsü olarak kaydetmektedir. Ortalama alma işlemi ile Kinect sensöründen elde edilen derinlik görüntüsünde

oluşan ve sıfır ortalamaya sahip olduğu varsayılan ölçüm hataların azaltılması hedeflenmiştir. Kinect sensörünün derinlik kamerası saniyede 30 görüntü verebildiği için görüntüler her 33 ms'de bir alınmıştır. Her yeni görüntü alındığında, alınan görüntü ile arka plan görüntüsünün farkı alınarak bir ön plan görüntüsü oluşturulmuştur. Elde edilen ön plan görüntüsündeki piksellerin sayısının belirli bir eşiği geçmesi durumunda, engel algılama işlemi başlatılmaktadır. Tekerlekli sandalye sisteminin etrafında bir engel olması durumunda, ilgili noktaların Kinect derinlik haritasındaki derinlik değerleri arka plan görüntüsüne göre daha düşük olacaktır. Bu nedenle, engel algılama işlemi ön plan ve arka plan görüntüsündeki derinlik değerlerinin karşılaştırılmasıyla gerçekleştirilmektedir. Tekerlekli sandalyenin oturma alanına denk gelen piksellerin derinlik değerleri deneğin hareket etmesi durumunda değişiklik göstereceğinden, oturma alanını da içine alan belirli bir bölge engel algılama işleminde dikkate alınmamaktadır. Bu amaçla ön plan görüntüsündeki belirlenen güvenli (çarpışma riski olan) bir bölgeye denk gelen piksellerin sayısından, yine ön plan görüntüsündeki deneğin oturma alanına denk gelen piksellerin sayısı çıkartılarak, sandalyenin hareket alanında engel olup olmadığı tespit edilmektedir. Elde edilen ön plan görüntüsü kullanılarak siyah-beyaz bir görüntü oluşturulmuştur. Elde edilen siyah beyaz görüntü üzerinde morfolojik işlemler uygulanarak görüntüdeki gürültülerin azaltılması amaçlanmıştır. Bu amaçla öncelikli olarak morfolojik açma işlemi yapılmıştır. Daha sonrasında ise morfolojik kapama ve bölge doldurma işlemleri uygulanarak görüntüdeki boşluklar giderilmiştir. Morfolojik işlemlerden sonra bağımlı bileşenleri etiketleme algoritması uygulanarak görüntüdeki nesnelere tespit edilmiştir. Tespit edilen nesnelere güvenli bölgeye denk gelenlerin alanı belirli bir eşiği geçmesi durumunda, çarpışma riski olduğu düşünülerek sistemin hareketi diğer gelen kontrol komutları dikkate alınmadan durdurulmuştur. Görüntü işleme algoritması engel algıladığı müddetçe sistemin hareketine izin vermemektedir. Elde edilen arka plan görüntüsü ve morfolojik işlemler uygulandıktan sonra elde edilen örnek görüntüler Şekil 3.3'te verilmiştir.



Şekil 3.3. Arka plan görüntüsü ve morfolojik işlemler uygulanmış görüntü


Geliştirilen görüntü işleme algoritmasının akış şeması Şekil 3.4'de verilmiştir. Yapılan deneylerde görüntü işleme tabanlı güvenli sürüş algoritmasının başarılı bir şekilde çalıştığı ve çarpışmaları engellediği gözlenmiştir. Ayrıca yine bu algoritmanın, tekerlikli sandalyenin merdiven boşluğuna yaklaşması halinde sistemi durdurarak güvenliği sağladığı gözlenmiştir. Geliştirilen bu güvenli sürüş algoritması yine bio-sinyal tabanlı kontrol deneylerinde sistemin kontrollü olarak durdurulması amacıyla kullanılmıştır. Sistem durdurulduktan sonra rota takip performansını değerlendirmek üzere konumu bir lazer metre ile manuel olarak ölçülmüştür.



Şekil 3.4. Güvenli sürüş algoritması akış şeması

4. BİO-SİNYAL TABANLI KONTROL

Bu bölümde sistemin bio-sinyal tabanlı kontrolü detaylı olarak ele alınacaktır. Bio-sinyal tabanlı kontroller için geliştirilen algoritmaları oluşturan kısımlar kapsamlı bir şekilde incelenecektir. Öncelikli olarak alınan sinyaller bir ön işlemden geçirilmektedir. Ön işlemlerden sonra ise, sırasıyla öznitelik çıkarma, öznitelik seçme sınıflandırıcının eğitimi ve sınıflandırma işlemi yapılmaktadır. Geliştirilen sistemin genel işaret akış şeması Şekil 4.1’de verilmiştir.



Şekil 4.1. Geliştirilen sistemin işaret akış şeması

Tez çalışması kapsamında sistemin EMG tabanlı kontrolü için dört farklı kol hareketi belirlenmiştir. Bu belirlenen kol hareketleri sırasıyla yumruk sıkma, elleri serbest bırakma, eli sola çevirme ve eli sağa çevirme işlemidir. Bu işlemlere bağlı olarak tekerlekli sandalyenin kontrolü sağlanmıştır. Geliştirilen algoritma yumruk sıkma hareketini algıladığında tekerlekli sandalyeyi sağa, elleri serbest bırakma işlemi algıladığında tekerlekli sandalyeyi sola ve eli sola çevirme işlemi algıladığında ise tekerlekli sandalyeyi düz götürmektedir. Yumruk sıkma ve elleri serbest bırakma işlemi sınıflandırıcılar tarafından daha yüksek doğruluklarla elde edildiğinden dolayı sistemdeki temel hareketler olarak bu ikisi seçilmiştir. Bunun nedeni ise yumru sıkma işleminde bütün kaslar kasıldığından her bir kanaldan elde edilen genlik değerleri belirgin bir şekilde yükselmekte benzer şekilde eller serbest bırakıldığında ise genlik değerlerinin belirgin bir şekilde düşmesidir. EMG sinyalleri için örnekleme frekansı 1 KHZ olarak ayarlanmıştır. Bu şekilde her 1 ms’de bir örnek alınmaktadır. Alınan 50 örnek için belirlenen öznitelikler MATLAB ortamında gönderilmekte ve gelen örneğin hangi sınıfa ait olduğu hesaplanmaktadır. Bu nedenle sistemin EMG tabanlı kontrolünde yaklaşık olarak saniyede 20 defa kontrol sinyali oluşturulabilmektedir.

Bu nedenle sistemin EMG tabanlı kontrolünde kullanıcılar başarılı bir şekilde kendilerine verilen farklı rotaları da başarıyla takip edebilmişlerdir.

Sistemin EEG tabanlı kontrolünde ise üç farklı kavramsal görev tanımlanmıştır. Bu kavramsal görevler şu şekildedir: Rahatlama, metin okuma ve matematiksel problem çözme işlemidir. Geliştirilen sınıflandırıcı, kullanıcının rahatlama kavramsal görevini yaptığını algıladığında tekerlekli sandalyeyi düz, metin okuma kavramsal görevini yaptığını algıladığında sola ve matematiksel problem çözme kavramsal görevini algıladığında ise tekerlekli sandalyeyi sola yönlendirmiştir. EEG tabanlı kontrolde EEG sinyalleri 1 saniyede bir olacak şekilde toplanarak MATLAB ortamında gönderilmiştir. Geliştirilen algoritma kullanıcının iki defa üst üste aynı kavramsal görevi yaptığını algıladığında tekerlekli sandalyenin istenilen yöne navigasyonunu sağlamıştır. Bu nedenle EEG tabanlı kontrolde bir kontrol sinyalinin motorlara gönderilebilmesi için en az 2 sn gereklidir.


Geliştirilen sistemde motorlarda enkoder bulunmadığından, sistem darbe genişlik modülasyonu (PWM) tabanlı bir açık çevrim kontrolü ile kontrol edilmiştir. Sağa dönmek için tekerlekli sandalyenin sol motorlarının PWM'leri arttırılmış benzer şekilde sola dönmek için tekerlekli sandalyenin sağ motorlarının PWM'leri arttırılmıştır.

4.1. Ön İşlemler ve Artifakt Eliminasyonu

Artifakt eliminasyonu özellikle EEG tabanlı uygulamalarda sıklıkla karşılaşılan bir sorundur. Literatürde bu işlem için geliştirilmiş birçok farklı yöntem bulunmaktadır [42-44]. Geliştirilen sistemde toplanan EEG sinyalleri offline olarak incelendiğinde sinyallerin deneğin kafa hareketlerinden ve göz kırpmalarından etkilendiği gözlenmiştir. Geliştirilen algoritmada artifakt içeren sinyalleri elemek ve bu sinyalleri sınıflandırıcının eğitiminde kullanmamak amacıyla jiroskop ve ön EEG kanalları tabanlı bir artifakt eliminasyon sistemi geliştirilmiştir.


EEG ölçüm başlığının örnekleme frekansı 128 Hz olarak belirlenmiştir. EEG sinyali her saniyede bir toplanacak şekilde ayarlanmıştır ve bu da saniyede 128 örnek değerine karşılık gelmektedir. Her bir saniyede alınan sinyalin artifakt içerip içermediğini tespit edebilmek için ilgili sinyallerde beraber gelen gyro değerleri

kontrol edilmiştir. Her bir pencere için x veya y eksenindeki gyro sinyallerinin birinci dereceden türevleri hesaplanarak bu değerlerin belirli bir eşğin altında olup olmadığı kontrol edilmiştir. Eğer, gyro sinyalleri belirli bir eşğin üstündeyse ilgili penceredeki EEG sinyalleri artifaktlı olarak kabul edilerek ihmal edilmiştir. Örnek bir gyro tabanlı artifakt eliminasyonu Şekil 4.2’de verilmiştir.



Şekil 4.2. Gyro tabanlı artifakt eliminasyonu

Şekil 4.2’de yeşil renkte gösterilen sinyaller sensörden alınan GYRO sinyallerini gösterirken, mavi renkteki sinyaller ise AF3 kanalındaki EEG sinyallerini göstermektedir. Kırmızı pencerelerde arasında kalan sinyaller de tespit edilen artifaktlardır. Yapılan deneylerde kafa hareketlerinin yanı sıra göz kırpmaları hareketinin de EEG sinyallerini etkilediği gözlenmiştir. Bu nedenle gyro tabanlı eliminasyona ek olarak bir de göz kırpmaları tespit edebilmek amacıyla ön EEG kanalları tabanlı bir yöntem geliştirilmiştir. Bu yöntemde ön EEG kanallarından (AF3 ve AF4) alınan sinyaller incelenmiştir. Her saniyede alınan bu sinyallerin birinci dereceden türevleri hesaplanmıştır. Bu hesaplanan değerlerin belirli bir eşğin üstünde olması durumunda sinyal artifaktlı olarak kabul edilerek işlemlerde ihmal edilmiştir. Şekil 4.3’de örnek bir kafa hareketleri tabanlı artifakt eliminasyonu verilmiştir.



Şekil 4.3. Göz kırpma tabanlı artefakt eliminasyonu

Geliştirilen sistemde EEG sinyalleri için bir ön eleme işlemi yapılırken EMG sinyalleri için bir ön işleme ihtiyacı duyulmamıştır. EMG sinyalleri EEG sinyallerine göre daha mekanik bir sistem olduğundan dolayı gürültülerden daha az etkilendiği gözlenmiştir.

4.2. Öznitelik Çıkartma

Öznitelik çıkartma işlemi sinyal işleme uygulamalarında genellikle ilk yapılan işlemidir. Öznitelik çıkartma genellikle sinyalin bütünü yerine sinyali daha küçük boyutlarda ifade edebilecek bir boyuta indirgeme işlemidir [45-47]. Bir sinyali ifade edebilmek için birçok farklı öznitelik kullanılabilir. Kullanılacak olan öznitelik değerleri genellikle sinyalin yapısına göre değişmektedir [48-50]. Bu öznitelikler zaman uzayı tabanlı öznitelikler olabileceği gibi birçok uzayda da olabilmektedir. Zaman uzayındaki öznitelikler sinyali tanımlamada yetersiz kaldığında, araştırmacılar frekans uzayı tabanlı öznitelikler başta olmak üzere birçok Hilbert Huang dönüşümü tabanlı, dalgacık dönüşümü tabanlı farklı öznitelikler kullanarak sinyalleri sınıflandırma yoluna gitmişlerdir.

4.2.1. Zaman uzayı tabanlı öznitelikler

Bu çalışmada da alınan EMG ve EEG sinyallerinden öznitelik çıkartma işlemi yapılmıştır. Zaman uzayından çıkartılan özniteliklerden bazıları mutlak ortalama değeri, standart sapma değeri, sıfır geçiş sayısı, çizgi uzunluğu ve yaklaşık entropi değeridir. Bu özniteliklerden sıfır geçiş sayısı sadece EMG sinyalleri için kullanılmıştır. Çizgi uzunluğu parametresi bir sinyalin tahmin edilebilirliğini ölçmektedir. Bir sinyalin çizgi uzunluğu Denklem (4.1)'deki gibi;

$$L = \sum_{j=1}^N |x_{j+1} - x_j| \quad (4.1)$$

hesaplanabilmektedir. Çizgi uzunluğu özneliğine ek olarak yaklaşık entropi değeri de sinyalin tahmin edilebilirliğini ölçmenin bir yoludur. Tahmin edilebilirliği az olan sinyaller, tahmin edilebilirliği daha yüksek olan sinyallere göre daha yüksek yaklaşık entropi değerine sahip olmaktadır. N elemanlı bir sinyalin $(y_i, i=1..N)$ sinyalin yaklaşık entropisini hesaplamak için gerekli adımlardan ilki Denklem (4.2)'de gibi;

$$X_i = \{y_i, y_{i+\tau}, y_{i+2\tau}, \dots, y_{i+(m-1)\tau}\}, \quad 1 \leq i \leq N-(m-1)\tau \quad (4.2)$$

hesaplanabilmektedir. Denklem (4.2)'de m parametresi alt uzayın boyutunu temsil ederken τ parametresi ise zaman gecikmesini temsil etmektedir. Her bir i değeri için Denklem (4.3)'deki gibi;

$$C_i^m(r) = \frac{1}{N-(m-1)\tau} \sum_{j=1} \theta(r - d(x(i), x(j))) \quad (4.3)$$

tanımlanabilmektedir. Denklem (4.3)'de yer alan θ fonksiyonu standart Heavyside fonksiyonudur ve Denklem (4.4)'teki gibi;

$$\theta(x) = \begin{cases} 1, & x \geq 0 \\ 0, & \text{aksi} \end{cases} \quad (4.4)$$

tanımlanabilmektedir. Denklem (4.3)'de yer alan r parametresi ise vektör karşılaştırma uzaklığıdır ve Denklem (4.5)'deki gibi;

$$d(x_i, x_j) = \max_{k=1,2,\dots,m} (|y(i+(k-1)\tau) - y(j+(k-1)\tau)|) \quad (4.5)$$

tanımlanabilmektedir. Bu denklemlere bağlı olarak $\phi^m(r)$ Denklem (4.6)'deki gibi;

$$\phi^m(r) = \frac{1}{N-(m-1)\tau} \sum_{i=1} \log C_i^m(r) \quad (4.6)$$

tanımlanabilmektedir. Son adımda ise verilen bir sinyalin yaklaşık entropi değeri Denklem (4.7)'de verildiği gibi;

$$ApEn = \varphi^m(r) - \varphi^{m+1}(r) \quad (4.7)$$

hesaplanabilmektedir. Zaman uzayında elde edilen öznitelikler EMG sinyallerinin sınıflandırılmasında kullanılmıştır. EEG sinyallerinde ise zaman uzayı özniteliklerine ek olarak bir de frekans bantlarındaki enerjiler ile dalgacık dönüşümü tabanlı öznitelikler kullanılmıştır.

4.2.2. Frekans uzayı tabanlı öznitelikler

Giriş kısmında da belirtildiği gibi EEG frekans bantları belirli frekans aralıklarına göre ayrılmıştır. Bu çalışmada da teta, alfa ve beta frekans bantlarındaki enerjiler EEG sinyalleri için öz nitelik olarak seçilmiştir. Bir sinyalin Fourier dönüşümü Denklem (4.8)'deki gibi;

$$X(e^{j\omega}) = \sum_{n=-\infty}^{n=+\infty} x[n]w[n-m]e^{-j\omega n} \quad (4.8)$$

hesaplanabilmektedir. Literatür EEG sinyallerinde frekanslarına göre isimlendirilen beş farklı dalga bulunmaktadır. Bu dalgalar alfa (α), theta(Θ), beta(β), delta ve gamma dalgalarıdır. Bu dalgalardan alfa ve beta dalgaları 1929 yılında Berger tarafından, gamma dalgaları 1938 yılında Jasper ve Andrews tarafından, delta dalgalarını 1936 yılında Walter tarafından, theta dalgaları da 1944 yılında Dovey ve Walter tarafından bulunmuştur [1,51-53]. Delta dalgalarının frekansı 0,5-4 Hz arasında değişmektedir. Delta dalgaları genellikle derin uyku esnasında ve uyanık kalma durumunda beyin tarafından salgılanmaktadır. Theta dalgalarının frekansı 4-7,5 Hz arasında değişmektedir. Theta dalgaları genellikle uyanıklık halinden uyku haline geçerken, derin meditasyonlarda, ilham verici durumlar esnasında ortaya çıkmaktadır. Theta dalgaları uyarıcının miktarına bağlı olarak başka frekanslarda da görülebilmektedir. Theta dalgaların değişimlerinin insan üzerindeki etkisinin incelenmesi hala devam etmektedir. Frekans aralığı 8-13 Hz arasında değişen alfa dalgaları ise beyin arka kısmında bulunan okipital bölge tarafından salgılanmaktadır. Alfa dalgaların genellikle sinüzoidal şekle sahip olan dalgalarıdır. Alfa dalgaları beyinden salgılanan sinyal içerisindeki dalgalarda en baskın tip olan dalgalarıdır ve genellikle rahatlama durumlarında ortaya çıkmaktadırlar. Alfa dalgalarının nasıl oluştuğuna dair araştırmalar hala devam etmektedir. Beta

dalgalarının frekansı (bazı literatürlerde üst limit verilmemesine rağmen) 14-26 Hz arasında değişmektedir. Beta dalgaları genellikle aktif düşünme, yoğunlaşma anında ortaya çıkan dalgalardır. Beta dalgaları kemikte oluşan hasarlar nedeni ile de ortaya çıkabilmektedir. 30 Hz'in üzerindeki beyin dalgaları (45 Hz'e kadar) gamma dalgaları (hızla beta dalgaları) olarak isimlendirilmektedir. Gamma dalgalarının oluşması çok kısa olmasına rağmen bu dalgalarının tespiti beyin hasarlarının belirlenmesinde önemli rol oynamaktadır. Gamma dalgaları ayrıca sağ veya sol parmakların hareketleri, dilin hareketi gibi beynin olay tabanlı senkronizasyonunda da kullanılmaktadır. EEG sinyallerinde belirtilen frekans aralığı dışarısında kalan sinyaller ab-normal sinyaller olarak adlandırılmaktadır. Sharbrough ab-normal EEG sinyallerini yaygın aralıkları düşük dalga ab-normalliği, bi-leteral EEG ab-normalliği ve fokal EEG ab-normalliği olarak üç farklı kısımda incelemiştir [54].

Bu çalışma kapsamında saniyede bir örnek alındığı için her bir pencerede 128 tane örnek bulunmaktadır. Bu nedenle, alınan sinyalde zaman uzayına geçebilmek için 128 noktalı hızlı Fourier dönüşümü kullanılmıştır. Sinyalin bilgisayar ortamında yapılan incelemelerinde delta bandındaki enerji değeri öznitelik olarak kullanılmasının sinyal performansını düşürdüğü gözlenmiştir. Bu nedenle, delta frekans bandındaki enerji bu çalışma kapsamında bir öznitelik olarak kullanılmamıştır.

4.2.3. Dalgacık dönüşümü tabanlı öznitelikler

Dalgacık dönüşümü, analizinde Fourier dönüşümünün yetersiz kaldığı sinyallerde kullanılabilir. EEG sinyalleri de genellikle zamanla frekansı değişen sinyaller oldukları için literatürde EEG sinyallerinde dalgacık dönüşümünün kullanıldığı birçok farklı çalışma bulunmaktadır [55-57]. Bu çalışma kapsamında EEG sinyalleri için frekans uzayı tabanlı özniteliklere ek olarak dalgacık dönüşümü tabanlı öznitelikler de kullanılmıştır. Eğer bir sinyalin frekansı zamanla değişmiyorsa, frekans uzayı tabanlı öznitelikler o sinyali ifade etmekte kullanılabilir. Frekansı zamanla değişen bir sinyalin Fourier dönüşümü kullanılarak neden analiz edilemeyeceğini anlayabilmek için Fourier dönüşümünün formülü incelenmelidir.

Bir sinyalin ayrık zamanda Fourier dönüşümü Denklem (4.8)'deki gibi hesaplanabilmektedir. Denklem (4.8) incelendiğinde toplama işleminin sınırlarının

zaman uzayındaki bütün değerler boyunca değiştiği görülmüştür. Bu nedenle Fourier dönüşümünde zaman bilgisi kaybolmaktadır. Fourier dönüşümünde sadece sinyalde hangi frekans bileşenlerinin bulunduğu bilgisi elde edilebilmektedir. Bu nedenle zaman bilgisinin kaybolmaması için birçok farklı yöntem geliştirilmiştir. Bu yöntemlerin başında Kısa Zamanlı Fourier Dönüşümü (STFT) gelmektedir. Bu yöntemde sinyal parçalara bölünerek elde edilmektedir. Bir sinyal için STFT Denklem (4.9)'daki gibi;


$$X(m, \omega) = \sum_{n=-\infty}^{n=+\infty} x[n]w[n-m]e^{-j\omega n} \quad (4.9)$$

hesaplanabilmektedir. Denklem (4.9)'da w fonksiyonu pencereleme amaçlı kullanılmaktadır. Genellikle Gauss veya Hann fonksiyonu seçilmektedir. Bu yöntem incelendiğinde ise bu yöntemin önemli bir eksikliğinin çözünürlük problemi olduğu gözlenmiştir. Bütün incelenen pencerelerin aynı boyutta olması karşımıza önemli bir sorun olarak çıkmaktadır. Bu durum nedenle Denklem (4.10)'daki gibi;

$$\Delta f \times \Delta t = 1 \quad (4.10)$$

gösterilmektedir. Denklem (4.10)'da verilen Heissenberg Belirsizlik İlkesi gereği zaman çözünürlüğünü arttırdığımızda frekans çözünürlüğü azalmakta, frekans çözünürlüğünü arttırdığımızda ise zaman çözünürlüğü azalmaktadır.

Yüksek frekanslı sinyallerin, zamanda hızlı değiştikleri için yüksek zaman çözünürlüğü ile incelenmesi gerekmektedir. Düşük frekanslı sinyaller ise yüksek frekans çözünürlüğü ile incelenmesi gerekmektedir. Bu nedenle dalgacık dönüşümü tanımlanmıştır. Dönüşümlerin karşılaştırılması Şekil 4.4'de verilmiştir.



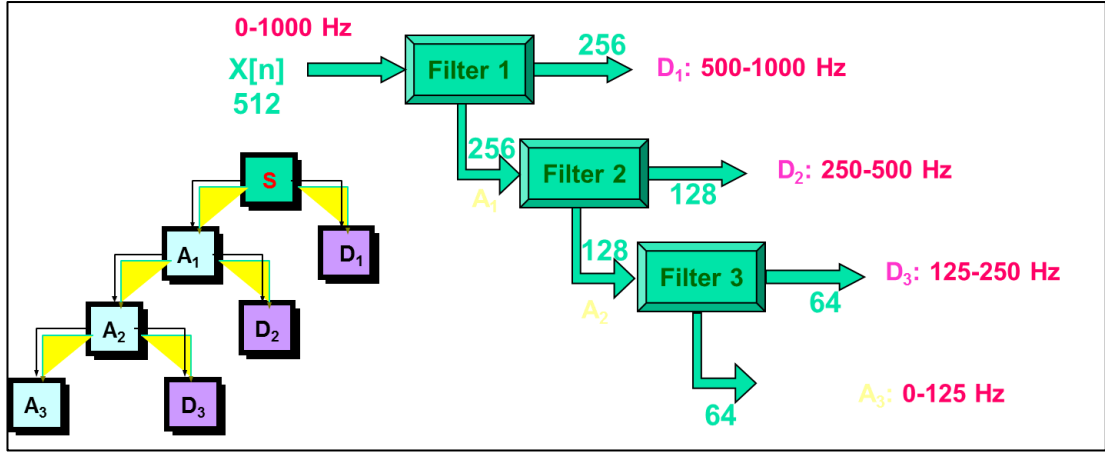
Şekil 4.4. Dönüşümlerin karşılaştırılması

Bir sinyalin sürekli dalgacık dönüşümü Denklem (4.11)'deki gibi;

$$\gamma(\tau, s) = \frac{1}{\sqrt{|s|}} \int x(t) \gamma' \left(\frac{t-\tau}{s} \right) dt \quad (4.11)$$

hesaplanabilmektedir. Buradaki γ temel dalgacık fonksiyonunu gösterirken τ zamandaki pencerenin kaydırılmasını, s ise pencerenin ölçekleme katsayısını göstermektedir. Ölçekleme (s) parametresinin 1'den büyük olması dalgacık sinyalinin genişletilmesi anlamına gelmekte iken s parametresinin 1'den küçük olması dalgacık sinyalinin daraltılması anlamına gelmektedir.

Ayrık dalgacık dönüşümünde ise sinyalin yaklaşık ve detay olmak üzere iki kısma ayırmaktadır. İki kısma ayırma işlemi için sinyal biri alçak geçiren biri yüksek geçiren olmak üzere iki tane filtreden geçirilir. Sinyalin alçak geçiren kısmı temel diğer kısmı ismi ayrıntı kısmı olarak isimlendirilmektedir. Bu işlem istenen seviyeye kadar devam etmektedir. Ayrık Dalgacık Dönüşümü için örnek bir şema Şekil 4.5'de verilmiştir.



Şekil 4.5. Ayırık dalgacık dönüşümü şeması

Bu tez çalışması kapsamında sinyal Haar dalgacığı kullanılarak üçüncü seviyeye kadar kısımlara ayrılmıştır. Son ayırma işleminden sonra elde edilen yaklaşık kısmın enerjisi öznitelik olarak seçilmiştir.

4.2.4. Ortak uzamsal örüntü

Ortak uzamsal örüntü (CSP) ilk olarak 1999 yılında H. Ramoser tarafından EEG verilerini sınıflandırmak amacıyla kullanılmıştır [58]. CSP algoritmasının temelinde, iki sınıf arasındaki farkı belirgin hale getirmek gelmektedir.

CSP algoritması şu aşamalardan geçmektedir. Bir EEG deneyi için ham EEG verilerinin olduğu matrisi E kabul edilirse, bu matrisin satır sayısı N ve sütun sayısı T olacaktır. Buradaki N EEG cihazındaki kanal sayısı iken T ise her bir kanaldaki örnek sayısını göstermektedir. E matrisinin uzamsal kovaryans matrisi Denklem (4.12)'deki gibi;

$$C = \frac{EE^t}{\text{trace}(EE^t)} \quad (4.12)$$

hesaplanabilmektedir. Denklem (4.12)'de yer alan trace ifadesi matrisin izini göstermektedir ve köşegendeki elemanların toplamı olarak hesaplanabilmektedir. Uzamsal kovaryans matrisi her iki sınıf için de ayrı ayrı hesaplanmaktadır. Sonrasında ise birleşik kovaryans matrisi, C_1 ve C_r matrisleri iki farklı sınıftan elde edilen kovaryans matrisleri olmak üzere iki kovaryans matrisinin toplanması ile elde Denklem (4.13)'deki gibi;

$$C_c = \overline{C}_1 + \overline{C}_r \quad (4.13)$$

hesaplanabilmektedir. Elde edilen birleşik kovaryans matrisi olan C_c genel matris açılımını kullanarak özdeğer ve özvektörler ile Denklem (4.14)'deki gibi;

$$C_c = U_c \lambda_c U_c^t \quad (4.14)$$

yazılabilmektedir. Denklem (4.14)'de yer alan U_c değerleri C_c matrisinin özvektörlerinin oluşturduğu matris olurken, λ_c ise özdeğerlerden oluşan köşegen matristir. Denklem (4.15) kullanılarak U_c tarafından gerilen uzaydaki varyansları eşitleyebilmek için bir dönüşüme ihtiyaç duyulmaktadır. Denklem (4.15) kullanılarak bu dönüşümü yapabilecek P matrisi aşağıdaki gibi;

$$P = \sqrt{\frac{1}{\lambda_c} U_c^t} \quad (4.15)$$

elde edilebilmektedir. P matrisi ile C_1 ve C_r matrisleri ile kullanılarak S_1 ve S_r matrisleri Denklem (4.16) kullanılarak aşağıdaki gibi;

$$S_1 = P \overline{C}_1 P^t, S_r = P \overline{C}_r P^t \quad (4.16)$$

elde edilmektedir. Dönüşüm yapıldıktan sonra elde edilen S_1 ve S_r matrislerinin özvektörlerinin aynı olması gerekmektedir. B matrisi bu ortak özvektörler olduğunda, S_1 ve S_r matrislerini genel matris açılımı ile Denklem (4.17)'deki gibi;

$$S_1 = B \lambda_1 B^t, S_r = B \lambda_r B^t \quad (4.17)$$

yazılabilmektedir. Denklem (4.17)'de elde edilen özdeğerlerin oluşturduğu köşegen matrisin ise birim matris olması gerekmektedir. Bu durum Denklem (4.18)'deki gibi;

$$\lambda_r + \lambda_1 = I \quad (4.18)$$

açıklanmıştır. Bu nedenle S_r matrisindeki en yüksek özdeğere sahip özvektör S_1 matrisindeki en düşük özdeğere sahiptir. Benzer şekilde de S_1 matrisindeki en yüksek özdeğere sahip özvektör S_r matrisindeki en düşük özdeğere sahiptir. Bu özellik

nedeniyle B matrisinin özdeğerleri iki sınıfın ayrılma işleminde kullanışlı bir hale gelmektedir. B matrisinin ilk ve son özvektörleri iki sınıfı birbirinden en iyi ayıran özniteliklerdir. B ve P matrisleri kullanılarak W iz düşüm matrisi Denklem (4.19)'daki gibi;

$$W=(B^TP)^T \quad (4.19)$$

elde edilebilmektedir. Bu iz düşüm matrisi kullanılarak ham EEG verisinin eşleştirilmiş hali Denklem (4.20)'deki gibi;

$$Z=WE \quad (4.20)$$

hesaplanabilmektedir. Denklemde (4.19)'da elde edilen W^{-1} matrisinin sütunları ortak uzamsal örüntü olarak adlandırılmaktadır. Tez çalışması kapsamında kullanılan öznitelikler Tablo 4.1'de verilmiştir.

Tablo 4.1. Kullanılan Öznitelik Tablosu

Öznitelik adı	EEG sınıflandırma	EMG sınıflandırma
Mutlak ortalama değer	+	+
Standart sapma	+	+
Çizgi uzunluğu	+	+
Sıfır geçiş sayısı	-	+
Yaklaşık entropi	+	+
Bant enerjileri	+	-
Ortam uzamsal örüntü	+	-
Dalgacık Tabanlı	+	-

Kullanılan öznitelik vektörünün boyutu yüksek olduğu için gerçek zamanlı deneylerde bu öznitelik vektörünün boyutunun azaltılması sistem performansına

olumlu olarak etki yapmaktadır. Öznitelik vektörünün boyutlarının azaltılması sistemin işlem yükünü azalttığı gibi aynı zamanda model karmaşıklığını azaltmakta ve sonuçlarının da daha doğru olarak çıkmasını sağlamaktadır. Bir sonraki bölümde kullanılan öznitelik vektörünün boyutlarının azaltılması için tez kapsamında uygulanan yöntemler detaylı bir şekilde ele alınacaktır. Sıfır geçiş sayısı genellikle EMG sinyallerinden çıkartılan öznitelik olduğu için bu çalışma kapsamında da sıfır geçiş sayısı EMG sinyallerinde kullanılmıştır. Bant enerjileri de EEG sinyalleri için tanımlanmıştır. Bu nedenle bant enerjileri de EEG sinyalleri için kullanılmıştır.

4.3. Öznitelik Seçme

Öznitelik seçme işlemi de öznitelik çıkartma işlemi kadar önemli bir işlemdir. Eğer öznitelik sayısı çok yüksek olursa bu sisteme hesapsal yük getireceği gibi aynı zamanda model karmaşıklığın da neden olmaktadır. Bu nedenle öznitelik vektörünün boyutlarının azaltılması işlemi gereklidir. Bu işlem için matematiksel optimizasyon yöntemleri kullanılabileceği gibi sezgisel optimizasyon yöntemleri de kullanılabilir [59-61]. Matematiksel yöntemlerden olan temel bileşen analizi ile sezgisel yöntemlerden olan genetik algoritma bu tez kapsamında elde edilen verilere uygulanmıştır. Bu tez çalışması kapsamında çalışmada da her iki metot kullanılarak bir boyut azaltma yöntemine gidilmiştir. Bu boyut indirgeme işlemi sonucunda sistemin sınıflandırma performansının yükseldiği gözlenmiştir. Kullanılan her iki yöntemin karşılaştırılması da yapılmıştır.

4.3.1. Temel bileşen analizi

Temel bileşenler analizi ilk olarak 1930 yılında Harold Hotelling tarafından bulunduktan sonra Sirovich tarafından 1987 yılında yayımlanan makale veri setlerinin analizlerinde sıklıkla kullanılmaya başlanmıştır [62,63].

Temel bileşen analizi veri setinin istatistiksel özelliklerine bağlı bir boyut azaltma yöntemidir. Temel istatistiksel özellikleri incelediğimizde bağımlı bileşen analizi için kullanılan ilk özellik ortalama özelliğidir. Bir sinyalin ortalama değeri Denklem (4.21)'deki gibi;

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i \quad (4.21)$$

hesaplanmaktadır. Bu denklemdaki N değeri sinyalin boyutunu, x_i değeri ise sinyaldeki her bir elemanı göstermektedir. Standart sapma ise bir sinyalin dağılımı hakkında bize bilgi vermektedir ve Denklem (4.22)'deki gibi;

$$s = \sqrt{\frac{\sum_{i=1}^N (x_i - \bar{X})^2}{(N-1)}} \quad (4.22)$$

hesaplanabilmektedir. Tıpkı standart sapma gibi varyans da bize sinyalin dağılımı hakkında bilgi vermektedir. Standart sapmanın karesi olan varyans Denklem (4.23)'deki gibi;

$$s^2 = \frac{\sum_{i=1}^N (x_i - \bar{X})^2}{(N-1)} \quad (4.23)$$

hesaplanabilmektedir. Denklem (4.23)'de elde edilen varyans denklemi Denklem (4.24)'deki gibi;

$$s^2 = \frac{\sum_{i=1}^N (x_i - \bar{X}) \times (x_i - \bar{X})}{(N-1)} \quad (4.24)$$

tekrar yazılabilmektedir. Denklem (4.24)'de bulunan ikinci ($x_i - \bar{X}$) ifadesi yerine ($y_i - \bar{Y}$) yazılırsa x ve y değişkenleri arasındaki kovaryans Denklem (4.25)'deki gibi;

$$\text{Cov}(x,y) = \frac{\sum_{i=1}^N (x_i - \bar{X}) \times (y_i - \bar{Y})}{(N-1)} \quad (4.25)$$

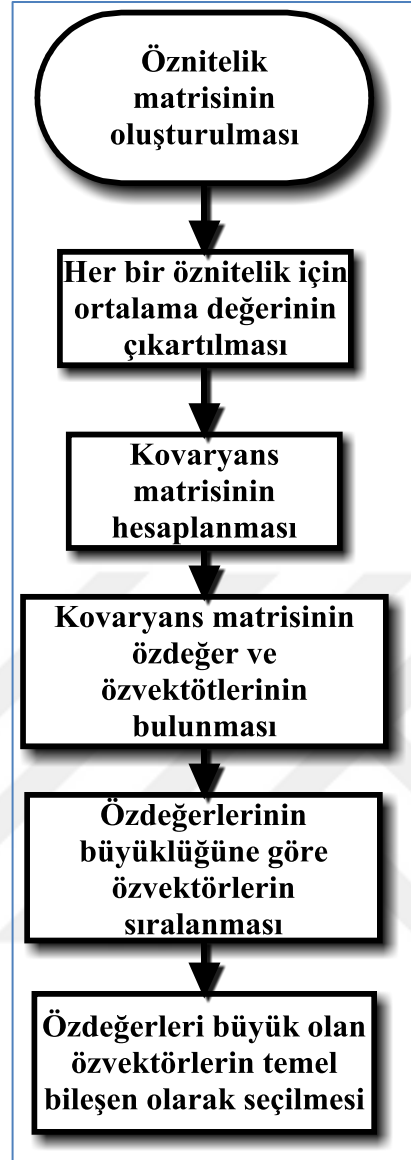
elde edilir. Kovaryans değerinin işareti bize bu iki değişkenin değişimi hakkında bilgi vermektedir. Eğer kovaryansın işareti pozitif olursa iki değişken beraber artıyor anlamına gelirken, eğer kovaryansın işareti negatif ise iki değişkenden biri artıyorken diğeri azalıyor anlamına gelmektedir.

Görüldüğü gibi kovaryans değeri iki deęişken için tanımlıdır. Fakat genellikle veri setleri çok boyutlu olmaktadır. Bu nedenle N boyutlu veri seti için kovaryans matrisi oluşturulur. Üç boyutlu deęişkenler örnek veri seti için oluşturulan kovaryans matrisi Denklem (4.26)'daki gibi;

$$C = \begin{bmatrix} \text{cov}(x,x) & \text{cov}(x,y) & \text{cov}(x,z) \\ \text{cov}(y,x) & \text{cov}(y,y) & \text{cov}(y,z) \\ \text{cov}(z,x) & \text{cov}(z,y) & \text{cov}(z,z) \end{bmatrix} \quad (4.26)$$

hesaplanabilmektedir. Denklem (4.17) incelendiğinde oluşturulan kovaryans matrisinin köşegenlerinde yer alan elemanların varyans olmaktadır. Ayrıca yine elde edilen kovaryans matrisinin hem karesel hem de simetrik olduğu görülmektedir.

Temel bileşen analizinde elde edilen kovaryans matrisinin öz deęerleri ve öz vektörleri bulunmaktadır. Bu işlem için tekil deęer ayrıştırması yöntemi kullanılmaktadır. Kovaryans matrisinin öz deęerleri ve öz vektörleri elde edildikten sonra bu öz vektörler arasında öz deęerlerin büyüklüğüne göre bir sıralama yapılmaktadır. En büyük öz deęere sahip olan öz vektör verinin temel bileşeni olarak kabul edilmektedir. Temel bileşen analizi için yapılan beş adımdan oluşan akış şeması Şekil 4.6'da verilmiştir.



Şekil 4.6. Temel bileşen analizi akış şeması

Tez çalışması kapsamında EMG sinyalleri için çıkartılan özniteliklerden bir boyut azaltma yöntemine gidilmemiştir. Öznitelik vektörünün boyutu yüksek olan EEG sinyalleri için boyut azaltımı işlemi yapılarak 90 olan öznitelik vektörünün boyutu 60'a indirilmiştir.

4.3.2. Genetik algoritma

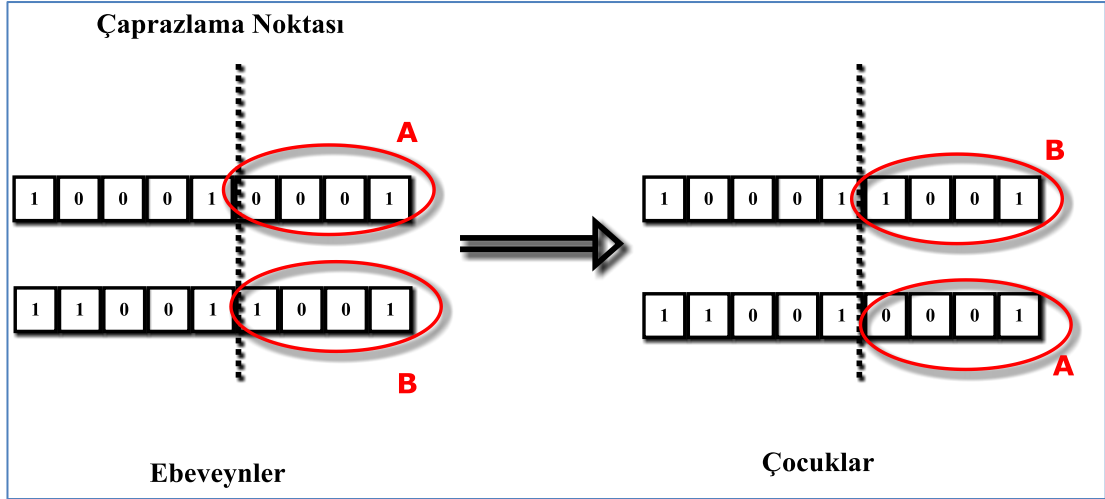
Genetik algoritma temelde Darwin'in evrim sürecini örnek olarak geliştirilen ilginç ve başarılı sonuçlar elde edebilen bir sezgisel optimizasyon yöntemidir. Bu yöntem ilk olarak 1975 yılında Holland ve arkadaşlarının yaptıkları çalışmalar neticesinde

ortaya çıkmıştır [64]. Bu çalışmadan sonra genetik algoritmalar birçok farklı probleme uyarlanabilir yapıda olduğundan dolayı birçok farklı alanda uygulanmıştır [65-67].

Genetik algoritmanın çalışma mantığı doğal evrim sürecinin çalışma mantığına dayanmaktadır. Evrim sürecinde canlılar buldukları doğal ortama adapte olurlar ve de zamanla bu adaptasyon süreci canlıların ortama adaptasyonu en iyi olacak hale gelene kadar devam etmektedir. Evrimin temel yasası en iyilerin hayatta kalması zayıfların ise elenmesidir. Evrim yapısı içerisinde her zaman güçlü olanlar yaşar ve çoğalırken güçsüz olanlar yaşayamaz ve çoğalamazlar.

Genetik algoritmanın birçok avantajı bulunmaktadır. Bunların başında uyarlanabilir bir algoritma olması gelmektedir. Birçok farklı optimizasyon problemine uygulanabilmektedir. Türevsel bilgi gerektirmemesi ve karmaşık maliyet fonksiyonunun parametrelerini geniş bir spektrumda araştırılarak en iyi çözümün bulunması genetik algoritmalar için ciddi bir avantaj oluşturmaktadır.


Genetik algoritmalarındaki önemli terimler gen, kromozom, popülasyon ve mutasyon terimleridir. Gen kalıtsal molekülde bulunan ve organizmanın karakterlerinin tayininde rol oynayan kalıtsal birimlere denmektedir. Kromozom birden fazla genin bir araya geliştirerek oluşturduğu yapıya denirken, birden çok kromozomun bir araya gelmesiyle popülasyon oluşmaktadır. Genetik algoritmalarda elde edilecek sonucun lokal minimum veya lokal maksimum takılmasını önlemenin en önemli yollarından biri de çaprazlamadır. Genetik algortmada çaprazlama işlemi Şekil 4.7'de verilmiştir.



Şekil 4.7. Genetik algortmada çaprazlama

Çaprazlama ile ebeveynlerdeki bulunan genler çaprazlama noktasından itibaren yer değiştirir. Bu sayede yeni bireylerde daha iyi bir çözüm elde edilebilir.

Eğer genetik algoritma belirli bir adımda daha iyi bir sonuç elde edemezse mutasyon uygulanarak genin yapısı değiştirilir. Bu sayede lokal minimum noktalarda takılma önlenmektedir. Genetik algortmada mutasyon Şekil 4.8’de verilmiştir.

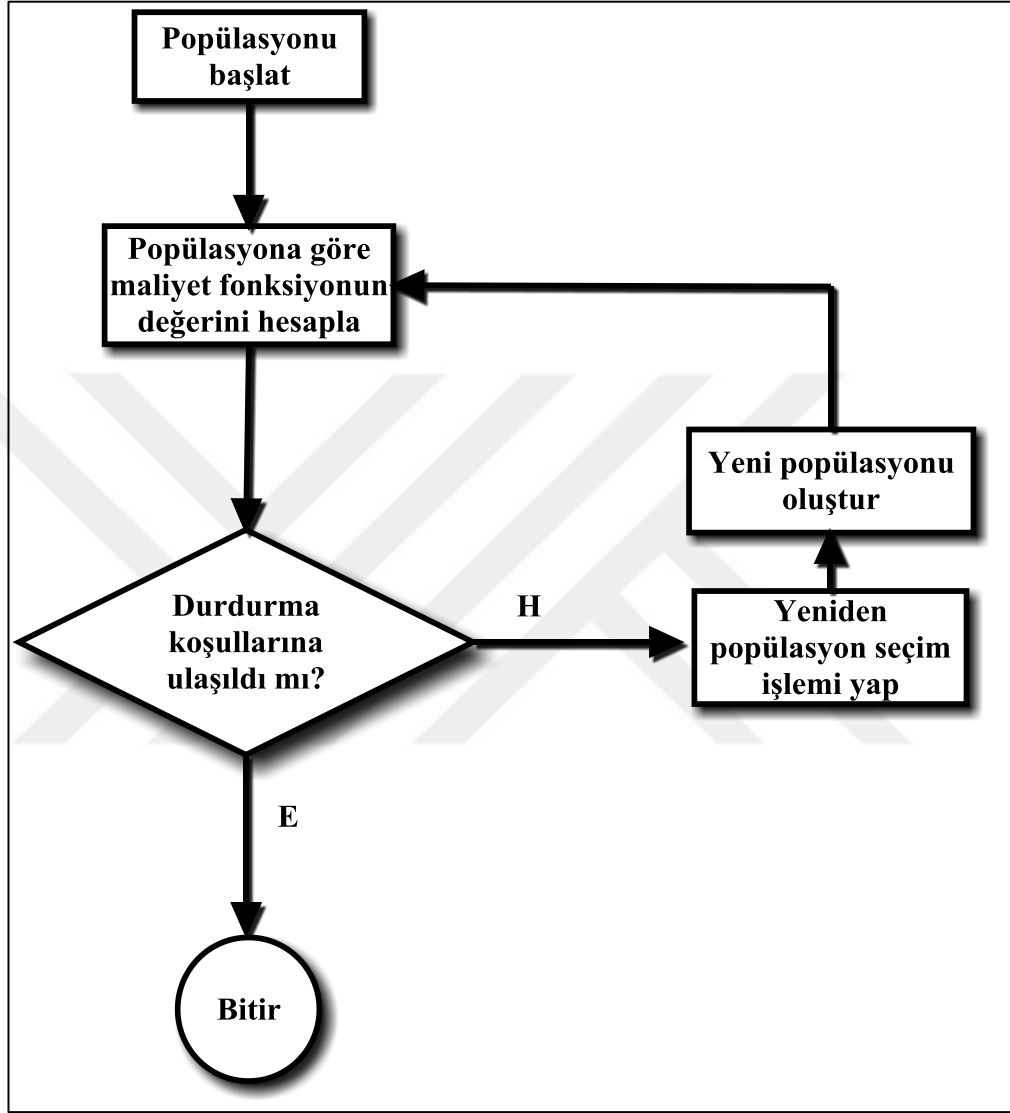


Şekil 4.8. Genetik algortmada mutasyon

Bu çalışma kapsamında elde edilen öznetelik sayısı kromozom olarak belirlenmiştir. Sınıflandırma sonucunda hatalı sınıflandırılan örnek sayısı maliyet fonksiyonu olarak kabul edilmiştir. EEG sinyalleri için üç farklı sınıf olduğundan dolayı bu çalışma kapsamında kullanılan maliyet fonksiyonu Denklem (4.27)’deki gibi;

$$v(e) = \sum_{j=1}^3 e_j \quad (4.27)$$

hesaplanabilmektedir. Denklem 4.18'deki e_j ifadesi için her bir sınıf için hatalı elde edilen sınıfları belirtmektedir. Genetik algoritmanın genel akış diyagramı Şekil 4.9'da verilmiştir.



Şekil 4.9. Genetik algoritma akış diyagramı

Şekil 4.9'dan da görülebileceği gibi, genetik algoritma durdurma koşullarına ulaştığında durdurularak daha fazla jenerasyon oluşturulması engellenmiştir.

Bu çalışma kapsamında genetik algoritma bilgisayar ortamındaki veriler için çalıştırılmıştır. Çalışma kapsamında her bir kromozom bir özneliğe karşılık gelmektedir. Çalışma kapsamında genetik algoritmanın parametreleri Tablo 4.2'deki gibi ayarlanmıştır.

Tablo 4.2. Genetik algoritmanın parametreleri

Parametre adı	Değeri
Popülasyonun boyutu	100
Bir bireydeki gen sayısı	90
Elit sayısı	2
Çaprazlama oranı	0,8
Mutasyon oranı	0,8
Maximum jenerasyon sayısı	200
Durdurma kriteri	40 jenerasyon ya da 5dakika boyunca herhangi bir iyileşme olmaması

4.4. Sinyal Sınıflandırma

Bu bölümde geliştirilen tez kapsamında kullanılan sınıflandırma teknikleri hakkında kısaca bilgi verilecektir. Tez kapsamında geliştirilen algorithmada yapay sinir ağları (YSA), destek vektör makineleri (DVM) ve rastgele orman (RO) algoritmaları kullanılmıştır. Bu üç farklı sınıflandırıcı kısaca açıklandıktan sonra geliştirilen hibrid algoritma açıklanmıştır.

4.4.1. Yapay sinir ağları

Yapay sinir ağları, insan sinir sisteminin öğrenme yöntemine benzer bir şekilde geliştirilmiş bir öğrenme algoritmasıdır. Yapay sinir ağları ilk olarak 1943 yılında McCulloch ve Walter Pitts tarafından modellenmiştir [68]. Fakat 1943 yılında modellenmesine rağmen 1984 yılına kadar kullanılamaz olarak düşünülmüştür. Bunun nedeni ise Minsky ve Papert tarafından yazılan kitaptır [69]. Bu kitapta yazarlar yapay sinir ağlarının doğrusal olmayan problemler üzerinde uygulanamayacağını meşhur bir problem olan “Xor” problemi ile ispatlamışlardır. 1984 yılında Hopfield tarafından yapılan çalışmalar ile YSA'nin


genelleştirilebileceği ve ünlü bir problem olan gezgin satıcı problemi gibi problemleri çözebileceği ispatlanmıştır [70]. Bu çalışmalardan sonra 1988 yılında Broomhead tarafından radyal tabanlı fonksiyonlar modeli geliştirilmiştir [71]. Bu çalışmalar sonrasında ise YSA'lar optimizasyon problemleri başta olmak üzere birçok farklı sınıflandırma problemlerinde de kullanılmıştır [72-74]. YSA'lar da insan sinir sistemi gibi nöronlardan oluşmaktadır. Tıpkı insan sinir sisteminde olduğu gibi bu nöronlar da birbirlerine direkt bağlanabileceği gibi karmaşık şekillerde de bağlanabilmektedir. İnsan sinir sisteminde bulunan nöronlar gibi YSA'daki nöronların da çok sayıda girişi ve tek bir çıkışı bulunmaktadır. Nöronlara gelen her bir girişin ağırlıkları farklı olmaktadır. Girişlerden farklı olarak da bazı nöronlara besleme (bias) da eklenmektedir. Genel olarak nöronun çıkışını Denklem (4.28)'deki gibi;

$$r = \sum_{i=1}^N w_i \times x_i + b \quad (4.28)$$

elde edilebilmektedir. Eğer nörona besleme bulunmazsa nöron b değeri sıfır olmaktadır. Denklem (4.28)'de bulunan N giriş sayısını, w her bir girişin ağırlığı, x giriş değerini ve b besleme değerini göstermektedir. Bu nörondan çıkış değeri elde etmek için ise Denklem (4.29) kullanılarak elde edilen toplam bir aktivasyon fonksiyonundan geçirilmiştir. Nörondan çıkış elde etmek için kullanılan aktivasyon fonksiyonunu ϕ ile gösterirsek nöronun çıkışı Denklem (4.29)'daki gibi;


$$y = \phi(r) = \phi \left(\sum_{i=1}^N w_i \times x_i + b \right) \quad (4.29)$$

elde edilmektedir. Çıkış elde etmek için kullanılan aktivasyon fonksiyonu problemin yapısına uygun olarak farklı şekillerde olabilmektedir. Bu fonksiyonlardan bazıları sigmoid fonksiyon, eşik fonksiyonu veya hiperbolik tanjant fonksiyonlarıdır. Belirtilen nöron yapısı Şekil 4.10'da verilmiştir.



Şekil 4.10. Yapay sinir ağları hücre yapısı

Bir nöronun çıkışı farklı katmanlardaki nöronların girişi olmaktadır. Bu sayede birçok farklı katman kullanılarak oluşturulan YSA yapısının çıkışı hesaplanabilmektedir. Bu şekilde çok katmanlı bir yapay sinir ağı modeli oluşturulur [75]. Örnek çok katmanlı YSA yapısı Şekil 4.11’de verilmiştir.



Şekil 4.11. Çok katmanlı YSA yapısı

Hücresinin çıkışı her zaman istenilen değeri vermeyebilir bu nedenle hücredeki ağırlıkların değiştirilmesi gerekmektedir. Bu ağırlıkların değiştirilmesi işlemi yapay sinir ağlarında öğrenme işlemidir. Yapay sinir ağlarında öğrenme için birçok farklı algoritma kullanılmıştır. Geri yayılım algoritması da bu algoritmaların başında yer almaktadır. Geri yayılım algoritmasında bir hücreden elde edilen çıkış değeri y_i ile ve hücreden asıl elde edilmesi istenen değer d_i ile gösterildiğinde i . nörondaki hata Denklem (4.30)'deki gibi;

$$e_i = d_i - y_i \quad (4.30)$$

hesaplanabilmektedir. Geri yayılım algoritmasının amacı ise her bir hücredeki yer alan hataların karesel toplamı olan maliyet fonksiyonunu minimum yapmaktır. Minimum yapılması istenen maliyet fonksiyonu Denklem (4.31)'deki gibi;

$$E = \frac{1}{2} \sum_i (e_i)^2 = \frac{1}{2} \sum_i (d_i - y_i)^2 \quad (4.31)$$

elde edilebilmektedir. Bu maliyet fonksiyonunun minimum amaçla delta kuralı kullanılmaktadır. Delta kuralı çıkışta oluşan hata nedeniyle ağırlıklardaki değişimi ifade etmektedir. Buradaki delta değeri nöronda kullanılan aktivasyon fonksiyonunun türevidir. Bir nöron için delta değeri ile yeni ağırlık değerleri sırasıyla Denklem (4.32) ve Denklem (4.33) 'deki gibi;

$$\delta_i = \varphi'(y_i) \times e_i \quad (4.32)$$

$$w_i^* = w_i + \delta \times x_i \quad (4.33)$$

hesaplanmaktadır. Görüldüğü gibi delta kuralının uygulanması sırasında ağırlığın öğrenmesi hızına bir etki bulunmamaktadır ve bu nedenle ağırlığın öğrenmesi yavaş olabilmektedir. Bu nedenle bir η öğrenme katsayısı Denklem (4.33)'e yerleştirilmiştir. Bu sayede öğrenme işlemi kademeli olarak gerçekleştirilmiş ve bu işlem kademeli (gradyent) azalış işlemi olarak adlandırılmıştır. Hücredeki ağırlıkların hesaplanması için kullanılan son Denklem (4.34)'deki gibi;

$$w_i^* = \eta \times \delta \times x_i \quad (4.34)$$

verilmiştir. Geri yayılım algoritmasında her bir yinleme işleminde ileri yayılım yapılarak çıkışlar elde edilir ve hata değerleri için tekrar geri yayılım yapılır. Bu işlem maliyet fonksiyonu minimum değeri alana kadar devam etmektedir.

4.4.2. Destek vektör makineleri

Destek vektör makineleri (DVM) Vapnik tarafından örüntü tanıma ve sınıflandırma işlemlerini yapabilmek amacıyla 1995 yılında geliştirilen bir öğreticili sınıflandırma algoritmasıdır [76]. DVM'lerin temelleri istatistiksel öğrenme teorisi ve yapısal risk minimizasyonuna dayanmaktadır. DVM literatürde birçok farklı alanda verilerin sınıflandırılması amacıyla kullanılmıştır [77-81].

Destek vektör makinelerinin amacı sınıflandırma işlemi için bir hiperdüzlem yardımıyla iki sınıfı birbirinden ayırmak için en uygun fonksiyonu tahmin etmektir. Veriler sınıflandırılırken birden çok düzlem elde edilebileceğinden, destek vektör makinelerinin amacı gerekli olan en uygun hiperdüzlemin elde edilmesidir.


İki boyutlu uzayda bu destek vektörü bir doğrudur ve denklemini de bir doğru denklemini olup Denklem (4.35)'daki gibi;

$$x_2 = mx_1 + c \quad (4.35)$$

yazılabilmektedir. Bu denklem, Denklem (4.36)'daki gibi;

$$f(x) = w_1x_1 + w_2x_2 - c \quad (4.36)$$

tekrar düzenlenebilir. Eğer sınıflar lineer olarak ayrılabilirse iki boyut için elde edilen vektör Şekil 4.12'de de görüldüğü gibi lineer ayıraç olarak da tanımlanmaktadır ve aşağıdaki denklemdeki gibi açıklanabilmektedir.




Şekil 4.12. Lineer ayıraç

Denklem (4.36) çok boyutlu uzaylar için Denklem (4.37)'deki gibi;

$$f(x) = W^T x - c = 0 \quad (4.37)$$

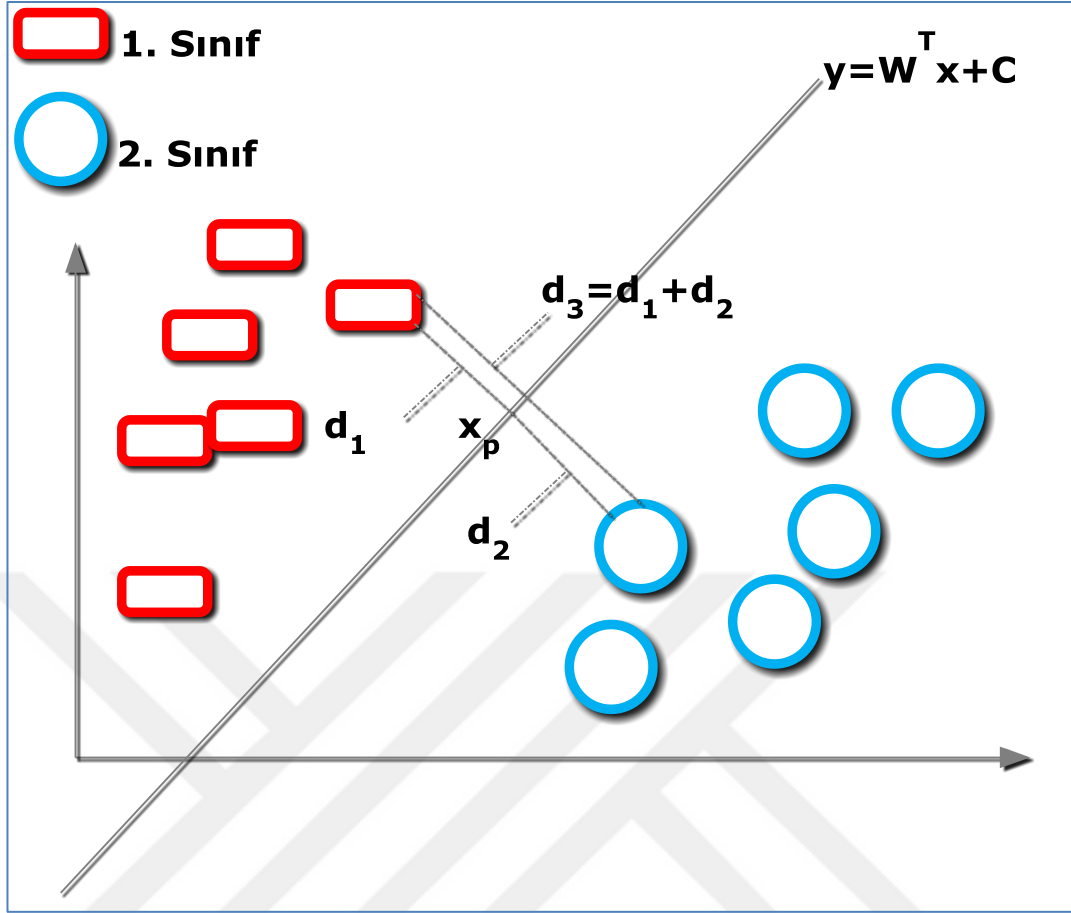
ifade edilebilir. Elde edilen hiperdüzlemin boyutu bölünmek istenen uzayın boyutundan 1 eksik olmaktadır. Bu nedenle aslında hiperdüzlem iki boyutlu uzay için bir doğru, üçboyutlu uzay için bir düzlem ve çok boyutlu uzay için bir hiperdüzlem olarak adlandırılmaktadır. Ede edilen hiperdüzlem $W^T x > c$ ve $W^T x < c$ olmak üzere uzayı iki parçaya bölmektedir. Buradaki W vektörü hiperdüzlemin oryantasyonunu (eksen ile yapılan açığı) belirlerken, c sabiti ise hiperdüzlemin pozisyonunu belirlemektedir.

Fakat Şekil 4.13'de de gösterildiği gibi iki sınıfı ayıran sonsuz sayıda doğru (düzlem) bulunmaktadır. Destek vektör makineleri ise bu düzlemler arasında bir optimizasyon yaparak en uygununu bulur.



Şekil 4.13. Çok sayıdaki lineer ayıraç

Bu amaçla da destek vektör makinelerinin iki sınıfı arasındaki uzaklığı maksimum yapacak hiperdüzlemi bulmalıdır. Bu amaçla düzlem üzerindeki x_p noktasından sınıfların düzleme en yakın olan noktaya olan vektörün dik uzaklığına bakılmaktadır. Bu dik uzaklığı maksimum yapacak olan düzlem en iyi düzlem olarak seçilmektedir. Bu düzlemi çevreleyen vektörlere ise destek vektörlere denmektedir.



Şekil 4.14. Sınıfları ayıran düzlem ile sınıflar arasındaki uzaklık

En uygun hiperdüzlem Şekil 4.14’de verildiği gibi elde edilen destek vektörlerinin ortasında yer almaktadır. Bu nedenle d_1 ve d_2 uzaklıkları birbirine eşittir. Bu nedenle d_3 uzaklığı $d=2/\|w\|$ olarak hesaplanabilmektedir. Buradaki sınırlar arasındaki maksimum uzaklığın elde edilebilmesi için $\|w\|^2$ fonksiyonunun minimize edilmesi gerekmektedir. Buradaki d_3 ’ün maksimize edilmesini amaçlayan optimizasyon problemi, farklı bir formata dönüştürülerek bir minimizasyon problemine çevrilmiştir. Minimum çözümünün bulunması istenen amaç fonksiyonu Denklem (4.38)’deki gibi;

$$\text{Amaç Fonksiyonu : Min } \|w\|^2 \times 0.5 \quad (4.38)$$

elde edilmektedir. Yukarıda verilen amaç fonksiyonu incelendiğine bu fonksiyonun doğrusal bir fonksiyon olmadığı anlaşılmaktadır. Doğrusal olmayan modellerde ise en iyi çözümün Karush Kuhn Tucker (KKT) şartlarının sağlanması gerekmektedir [82,83]. KKT koşullarının dört farklı şartı bulunmaktadır. Bu şartlardan ilki amaç

fonksiyonunun gradiyenti ile kısıt fonksiyonlarının gradiyentlerinin her kısıt için tanımlanmış parametlerle çarpımlarının toplamı sıfıra eşit olmalıdır. İlk KKT şartının genel matematiksel olarak ifadesi Denklem (4.39)'daki gibi;

$$\Delta f(x^*) + \sum_{j=1}^m \mu_j + \Delta g_j(x^*) + \sum_{j=1}^r \lambda_j + \Delta h_j(x^*) = 0 \quad (4.39)$$

verilmiştir. Bu denklemde yer alan g ve h fonksiyonları ise kısıt fonksiyonlarıdır. İkinci bir şart olarak bulunan çözüm alacağı değerlerde tamamlayıcı koşulları yerine getirmelidir. İkinci KKT şartının genel olarak matematiksel ifadesi de Denklem (4.40)'deki gibi;

$$x^* \left(\Delta(f(x^*) + \sum_{j=1}^r \lambda_j + \Delta h_j(x^*)) \right) = 0 \quad (4.40)$$

verilmiştir. Üçüncü bir şart olarak ise bulunan çözümler, kısıt fonksiyonları ile belirlenen bütün kısıtlara uymalıdır. Örnek olarak verilen g ve h fonksiyonları için kısıtlar Denklem (4.41)'deki gibi;

$$\begin{cases} g_j(x^*) = 0, j=1 \dots m \\ h_j(x^*) \leq 0, j=1 \dots r \end{cases} \quad (4.41)$$

tanımlanabilmektedir. KKT koşullarının son şartı olarak ise çözümler problemde verilen kısıtlar için elde edilen çarpanlardan verilen ek şartların sağlanması gerekmektedir. Son şartın ifadesi de Denklem (4.42)'deki gibi;

$$\begin{cases} \lambda_j * h_j(x^*) \\ \lambda_j \leq 0, j=1 \dots r \end{cases} \quad j=1 \dots r \quad (4.42)$$

verilmiştir. DVM'lerin çözümünde kullanılan tek kısıt fonksiyonu bulunmaktadır ve Denklem (4.43)'deki gibi;

$$\text{Kısıt fonksiyonu : } y (wx + b) \geq 1 \quad (4.43)$$

verilmiştir. DVM'ler için kullanılan amaç fonksiyonu ve kısıtlar göz önüne alındığında bu problemin çözümünde kullanılan Lagrange fonksiyonu Denklem (4.44)'deki gibi;

$$L_p(w,b,\alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i [y_i (w \cdot x_i) + b] + \sum_{i=1}^n \alpha_i \quad (4.44)$$

verilmiştir. Kullanılan Lagrange fonksiyonu Cortes, Vapnik ve daha sonra Burges'in çalışmaları ile edilmiştir. Bu eşitliklerde her bir α_i Lagrange çarpanlarıdır. L_p , Lagrange çarpanlarını en büyükleyen, w ağırlık vektörü ve b sabitini en küçükleyen bir fonksiyondur. Denklem (4.44) eşitliğindeki model, Denklem (4.43) eşitliğinde verilen kısıt altında çözüldüğünde, her bir eğitim verisi için bir tane Lagrange çarpanı elde edilir. Lagrange çarpanları içerisinde sıfırdan büyük değer alanlar vektörler de destek vektörleri olarak adlandırılmıştır [84]. Bu vektörler sınırların üzerinde yer alan vektörlerdir.

4.4.3. Rastgele orman

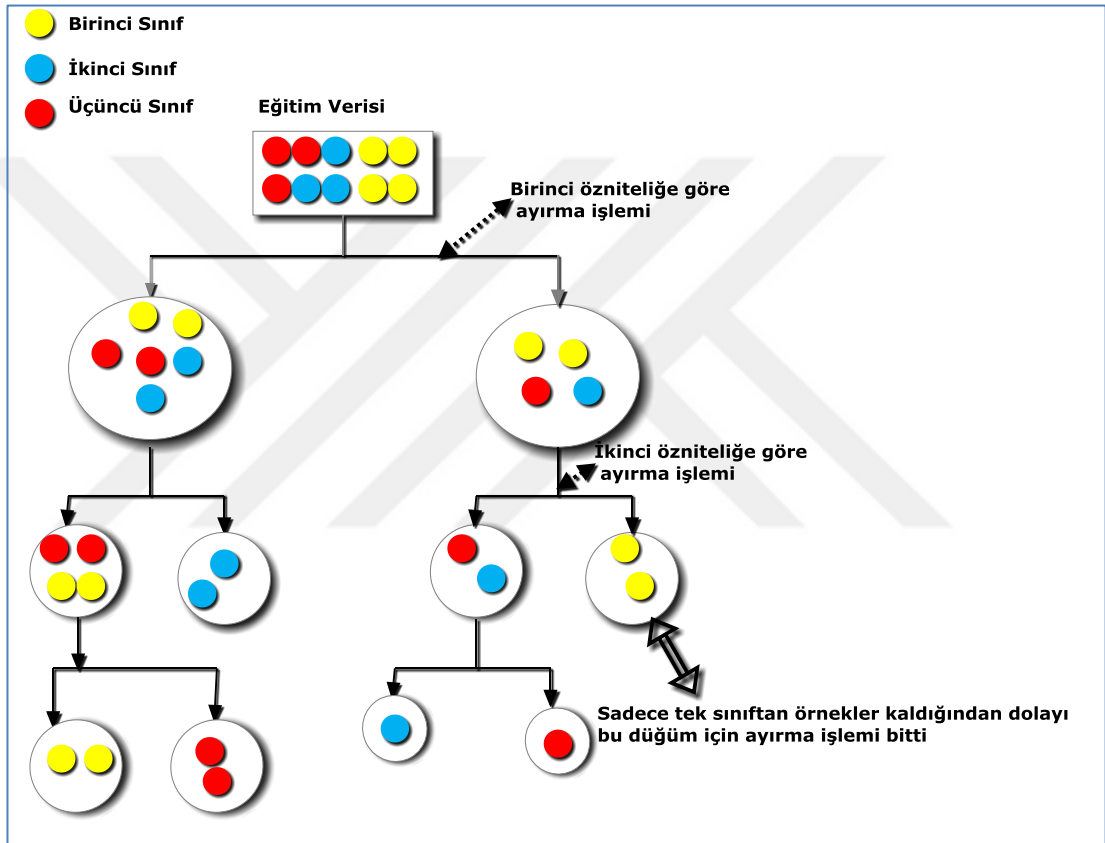
Rastgele Orman (RO) algoritması birden çok karar ağaçlarının bir araya gelmesiyle oluşturulan öğreticili bir makine öğrenme algoritmasıdır. RO algoritmasının temelini oluşturan karar ağaçları ilk olarak 1963 yılında Morgan ve Sonquist tarafından önerildikten sonra 1984 yılında Breiman tarafından önerilen regresyon ve sınıflandırma ağaçları (CART) algoritması ile sınıflandırma işleminde sıklıkla kullanılmaya başlanmıştır [85,86].

Bir karar ağacı oluşturulurken kullanılan veri seti sadece bir sınıftan oluşan veriler kalasıya kadar düğümlere bölünür. Bu düğümlerin her biri bir dal olarak isimlendirilmektedir. Bu düğümlere bölmek için ise iki tane kriter kullanılmaktadır. Bu kriterler regresyon kriteri ve gini indeksidir. Bu kriterler sırasıyla Denklem (4.45) ve Denklem (4.46)'deki gibi;

$$R_{ss} = \sum_{sol} (y_i - y_l)^2 + \sum_{sag} (y_i - y_r)^2 \quad (4.45)$$

$$Gini = N_l \sum_{k=1}^K p_{kl}(1-p_{kl}) + N_r \sum_{k=1}^M p_{kr}(1-p_{kr}) \quad (4.46)$$

tanımlanabilmektedir. Denklem (4.36)'da yer alan y_l ve y_r değerleri sırasıyla sol ve sağ düğümlerde yer alan verilerin ortalamasını oluşturmaktadır. Denklem (4.37)'de yer alan N_l ve N_r değerleri sırasıyla sağ düğümde ve sol düğümde yer alan elemanların sayılarını verirken, p_{kl} ve p_{kr} değerleri de sırasıyla sağ ve sol taraftaki sınıfların oranını göstermektedir. Verilen eğitim verisi kullanılarak üç sınıf için yapılan örnek bir ayırma işlemi ve elde edilen ağaç yapısı aşağıdaki Şekil 4.15'de verilmiştir.



Şekil 4.15. Örnek Bir karar ağacı yapısı

Bir ağaç için oluşturulan bu yapının en büyük dezavantajı ise veri setine bağlı olmasıdır. Veri seti değiştiğinde bu yapıda oluşacak değişikliklerden dolayı tek bir ağaç yapısı sınıflandırma işlemlerinde yeterli olmamaktadır. Bu nedenle tek bir ağaç yerine birçok ağacın bir araya gelmesinden bir yapı oluşturulur. Bu yapıya orman adı verilmektedir. RO algoritmasında ise eğitim verisinden rastgele olarak seçilen birçok farklı alt uzay oluşturulmaktadır. N adet örnekten oluşan bir veri seti Denklem (4.46)'deki gibi düşünüldüğünde rastgele oluşturulan alt uzaylar Denklem (4.47)'deki gibi;

$$S = \begin{bmatrix} f_{A1} & f_{B1} & f_{C1} & \cdot & \cdot & C_1 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ f_{AN} & f_{BN} & f_{CN} & \cdot & \cdot & C_N \end{bmatrix} \quad (4.47)$$

olmaktadır. Denklem (4.47)'deki f_{A1} ifadesi birinci örneğin A özneliğini gösterirken, f_{BN} ifadesi N. örneğin B özneliğini göstermektedir. Bu denklemde yer alan C değerleri ise o örneğin ait olduğu sınıfı göstermektedir. N adet örnekten rastgele olarak seçilen M adet örneğin denklemi de Denklem (4.48)'deki gibi;

$$S_1 = \begin{bmatrix} f_{A12} & f_{B12} & f_{C12} & \cdot & \cdot & C_{12} \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ f_{A20} & f_{B20} & f_{C20} & \cdot & \cdot & C_{20} \end{bmatrix},$$

$$S_2 = \begin{bmatrix} f_{A2} & f_{B2} & f_{C2} & \cdot & \cdot & C_2 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ f_{A8} & f_{B8} & f_{C8} & \cdot & \cdot & C_8 \end{bmatrix}, \quad (4.48)$$

M

$$S_M = \begin{bmatrix} f_{A4} & f_{B4} & f_{C4} & \cdot & \cdot & C_4 \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot & \cdot \\ f_{A9} & f_{B9} & f_{C9} & \cdot & \cdot & C_9 \end{bmatrix}$$

olmaktadır. Yukarıdaki belirtilen M adet alt uzay rastgele olarak seçilmiştir. Ne kadar rastgele olarak seçilirse örnekler arasındaki korelasyon azalacağından sonuç da o kadar doğru olmaktadır. Her bir alt veri kümesinden oluşturulan ağaçların sonucu T_i ile gösterildiğinde RO algoritmasının sonucu Denklem (4.49)'daki gibi;

$$RO = \frac{1}{M} \sum_{i=1}^M T_i \quad (4.49)$$

hesaplanabilmektedir. Denklem (4.29)'dan da anlaşılacağı gibi rastgele orman sonucu rastgele olarak oluşturulan ağaçlarının sonuçlarının ortalamasıdır. Tek bir ağaçtan elde edilen sınıflandırıcı güçlü bir sınıflandırıcı olmazken, bu şekilde bir

orman yapısı kullanılarak elde edilen sınıflandırıcı güçlü bir sınıflandırıcı olmaktadır. Tek ağaç yapısının en büyük dezavantajı olan veri setinin değişiminden etkilenmesi durumu, bu sayede elimine edilmiştir.

4.4.4. Geliştirilen hibrid sınıflandırma algoritması

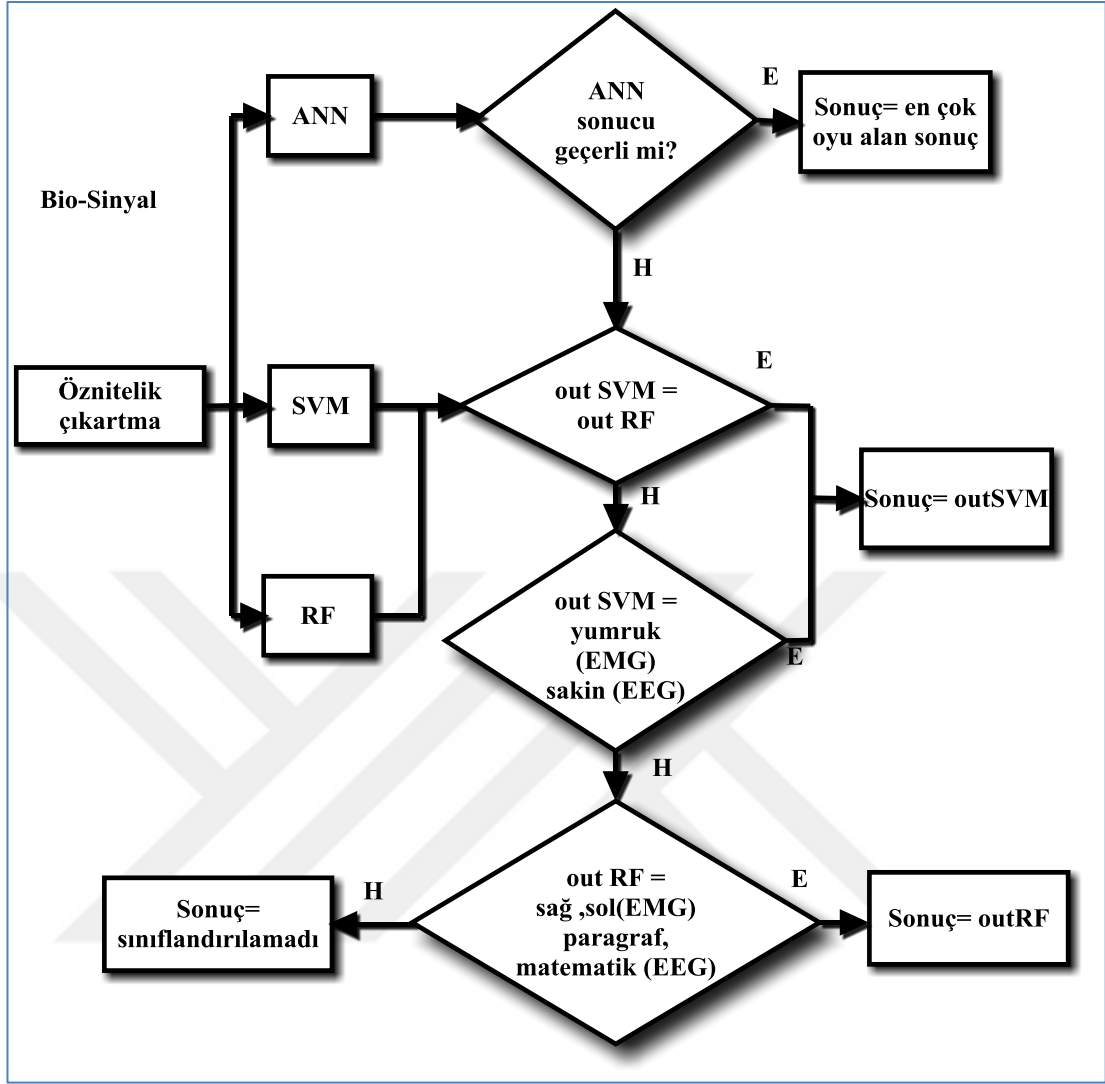
Bu çalışma kapsamında yukarıda açıklana üç farklı sınıflandırma algoritması kullanılmıştır. Bu kısımda kullanılan sınıflandırıcının parametreleri ve bu üç sınıflandırıcının sonucuna bağlı olarak geliştirilen algoritma açıklanacaktır.

Tez kapsamında kullanılan YSA yapısında iki adet gizli katman kullanılmıştır. Her bir katmanda ise 40 adet nöron kullanılmış olup, aktivasyon fonksiyonu olarak ise sigmoid tanjant fonksiyonu kullanılmıştır. YSA'nın öğrenme algoritması olarak ise geri yayılım algoritması kullanılmıştır. Geliştirilen algoritmada YSA sonucunun geçerli olabilmesi için bir hata bandı kullanılmıştır. Eğer elde edilen sonuç bu hata bandı içerisindeyse YSA'nın sonucu geçerli olarak kabul edilmiştir. Eğer elde edilen sonuç bu hata bandının dışındaysa YSA sonucu ihmal edilerek geliştirilen algoritmada dikkate alınmamıştır. Bu çalışma kapsamında kullanılan YSA yapısındaki hata bandı 0,2 olarak belirlenmiştir. Bütün bu parametreler off-line veri üzerinde yapılan testler sonucunda deneme yanılma yöntemiyle bulunmuştur.

DVM sınıflandırıcılarında ise en önemli parametrelerden biri çekirdek fonksiyonunun şeklidir. Bu tez çalışması kapsamında kullanılan DVM sınıflandırıcının çekirdek fonksiyonu ikinci dereceden karesel bir fonksiyon seçilmiştir.

RO algoritmalarında ise gelişmiş ağaç sayısı en önemli parametrelerden biridir. Bu çalışma kapsamında kullanılan orman yapısında gelişmiş ağaç sayısı 50 olarak belirlenmiştir. Ağaç sayısının yanısıra sisteme torbalama hatası da eklenerek geliştirilen orman yapısının gürültülere karşı daha gürbüz olması sağlanmıştır.


Bu üç farklı sınıflandırıcı kullanılarak geliştirilen sınıflandırma algoritmasının akış şeması Şekil 4.16'da verilmiştir.



Şekil 4.16. Sınıflandırma algoritması akış şeması

5. GÖZ HAREKETLERİ TABANLI KONTROL

Bu tez çalışması kapsamında sistemin bio-sinyal tabanlı kontrolüne ek olarak bir de göz hareketleri tabanlı kontrolü yapılmıştır. Bu amaçla bir adet web kameradan MATLAB ortamına alınan görüntüler, geliştirilen görüntü işleme algoritması ile işlenerek tekerlekli sandalyenin navigasyonu sağlanmıştır. Geliştirilen görüntü işleme tabanlı sistemin akış şeması Şekil 5.1’de verilmiştir.



Şekil 5.1. Görüntü işleme akış şeması

Akış şemasından da görülebileceği gibi öncelikli olarak elde edilen görüntüden Viola-Jones algoritması kullanılarak yüzün tespiti yapılmaktadır. Yüz tespit edildikten sonra gözlerin ve gözbebeğinin tespiti yapılmaktadır. Göz bebeğinin tespiti için ise Hough dönüşümü kullanılmıştır. Bu aşamadan sonra ise görüntüden gradyan tabanlı öznitelikler çıkartılmıştır. Tespit edilen göz bebeği etrafındaki beyazlıklar da öznitelik vektörüne dahil edilmiştir.


Sistemi göz hareketleriyle kontrol edebilmek için üç farklı sınıf tanımlanmıştır. Program başlangıç aşamasında sağa, sola ve ortaya bakarken alınan onar adet görüntüden elde edilen görüntüler sınıflandırıcının eğitiminde kullanılmıştır. Sınıflandırıcı olarak bir önceki kısımda detaylı olarak açıklanan rastgele orman algoritması kullanılmıştır.

Yeni bir görüntü alındığında ise sistemde yine öznitelikler çıkartılarak eğitim aşamasında oluşturulan sınıflandırıcıya giriş olarak verilmiştir. Eğer sınıflandırıcının sonucu sol ise tekerlekli sandalye sol tarafa, sağ ise sağ tarafa, orta ise tekerlekli sandalye düz gidecek şekilde bir kontrol uygulanmıştır. Geliştirilen görüntü işleme algoritmasının elde ettiği sonuçlar bir sonraki bölümde incelenecektir.

5.1. Viola-Jones Algoritması ile Yüz Tespiti

Tez çalışması kapsamında geliştirilen görüntü işleme algoritmasında Viola-Jones algoritması kullanılarak görüntüdeki insan yüzü tespit edilmiştir. Viola-Jones algoritması 2001 yılında ortaya çıkarmış olmalarına rağmen 2004 yılında yazdıkları makale ile geliştirdikleri yöntemi daha detaylı olarak açıklamışlardır [87]. Viola-Jones tarafından yapılan çalışmalara kadar yüz tanıma alanında geliştirilen uygulamalar gerçek zamanlı olarak çalışmamaktaydı. Yazarlar geliştirdikleri algorithmada 240 x 320'lik görüntüde saniyede 15 video görüntü işlemeyi başarmışlardır.

Yazarlar geliştirdikleri algoritmalarda Haar özniteliklerini kullanmışlardır. Haar öznitelikleri ismini Haar dalgacıklarından alsa da onlardan farklı olarak üç farklı tip dikdörtgenden oluşmaktadır. Oluşturulan dikdörtgenler Şekil 5.2'de verilmiştir.



Şekil 5.2. Viola-Jones algoritmasındaki dikdörtgenler

Yukarıdaki dikdörtgenlerin beyaz kısımlarında kalan pikseller toplanıp, siyah kısımda kalan pikseller çıkartılarak bir değer elde edilir. Elde edilen bu değer bir öznitelik olarak seçilmiştir. Bu elde edilen değerler belirli bir eşik üzerindeyse orada yüz vardır denilebilmektedir. Eğer elde edilen değer belirli bir eşik altındaysa orada yüz yoktur denilebilmektedir. Bu şekilde bir sınıflandırıcı

oluşturulduğu görülmektedir. Fakat bu elde edilen sınıflandırıcı zayıf bir sınıflandırıcıdır ve tek başına başarımı çok düşük olmaktadır. Bu nedenle bu pencerelerin bütün resim boyunca kaydırılması gerekmektedir. Fakat makalede de belirtildiği gibi bu işlem için birçok farklı pencere seçilebilmektedir. Yazarların makalede de vurguladıkları gibi 24 x 24'lük bir resim için 160000'den fazla sayıda dikdörtgen oluşmaktadır. Sonuç olarak dikdörtgenlerin içerisinde kalan piksellerin toplanması için milyonlarca işlem gerekmektedir. Bu işlem yükü de algoritmanın gerçek zamanlı olarak çalışabilmesinin önündeki en büyük engel olarak karşımıza çıkmaktadır. Bu noktada yazarlar makalelerinde integral imge kavramını önermişlerdir. İntegral imgenin formülü Denklem (5.1)'deki gibi;

$$I_1(x,y) = \sum_{x' \leq x, y' \leq y} I(x',y') \quad (5.1)$$

hesaplanabilmektedir. Denklem (5.1)'den de görülebileceği üzere integral imgedeki piksellerin değerleri elde edilirken orijinal imgedeki her bir pikselin sol ve üstünde kalan piksellerin toplamı bulunmaktadır. Bu sayede normal bir imgede bir alandaki pikseller toplanması işlemi çok zaman alırken integral imgede bu işlem için dört köşesinin referansı kullanılarak istenilen boyuttaki dikdörtgenin toplamı bulunabilmektedir. Yazarlar sundukları bu integral imge yapısı sayesinde toplam hesabında işlemleri çok azaltmışlardır.


Fakat bir resimde birden fazla sayıda öznelik çıkmaktadır. Yazarların da belirttiği gibi 24 x 24'lük bir resimden 160000'in üstünde bir öznelik çıkmaktadır. Bu özneliklerin içerisinde işe yarayanların seçilmesi işleminin yapılması gerekmektedir. Bu işlem için zayıf sınıflandırıcılar birleştirilerek güçlü bir sınıflandırıcı elde edilmektedir. Zayıf sınıflandırıcılar lineer kombinasyonundan oluşturulan güçlü bir sınıflandırıcının formülü Denklem (5.2)'deki gibi;

$$F(x) = \alpha_1 f_1(x) + \alpha_2 f_2(x) + \alpha_3 f_3(x) \dots \quad (5.2)$$

hesaplanabilmektedir. Bu denklemde bulunan α katsayıları her bir sınıflandırıcının ağırlığını göstermektedir. Denklemdeki formül uygulandıktan sonra elde edilen hataya göre ağırlıklar tekrar hesaplanarak güçlü bir sınıflandırıcı elde edilmektedir.

Bu sayede birçok farklı öznelikten sayı azaltılarak içerisinde en uygun olanlar seçildi. Fakat yine de 24 x 24'lük pencerenin bütün bir resim boyunca gezdirilmesi gerekmektedir. Yazarlar yazdıkları makalede çıkardıkları öznelik sayısını 200'e düşürmüş olmalarına rağmen 384 x 288'lik resim için resmi bu şekilde bir sınıflandırıcı ile taramak 0,7 saniye sürmüştür. Bu da geliştirilen algoritmanın gerçek zamanlı olarak çalışmamasına neden olmaktadır. Yazarlar bu aşamada Rowley tarafından geliştirilen iki katmandan oluşan yapay sinir ağları ile yüz tespiti yapan algoritmadan esinlenerek kas kat sınıflandırıcı yöntemini geliştirmişlerdir. Bu yöntemde resimde içerisinde yüz bulunmayan birçok alt pencereyi hiç işleme sokmayan bir sınıflandırıcı geliştirmişlerdir. Bu sayede geliştirilen algoritmanın doğruluğunda herhangi bir değişiklik olmazken algoritma 10 kat hız kazanmıştır.

Tez kapsamında geliştirilen uygulamada, yüz tespiti için MATLAB ortamında hazır olarak bulunan komutlar kullanılmıştır. Yüzün ardından yine MATLAB komutları kullanılarak sağ ve sol gözlerin imge içerisindeki yerleri tespit edilmiştir. Bu aşamadan sonra ise imgede gözbebeğinin tespiti uygulaması yapılmıştır. Örnek bir görüntü ve elde edilen yüz görüntüsü Şekil 5.3'de verilmiştir.



Şekil 5.3. Örnek resim ve resimden tespit edilen gözler

Daha sonrasında ise imgede tespit edilen gözlerden sonra bir sobel kenar filtresi uygulanmıştır.

5.2. Dairesel Hough Dönüşümü Kullanarak Göz Bebeği Tespiti


Hough dönüşümü ilk olarak Duda ve Hart tarafından 1972 yılında önerilmesine rağmen, bu tekniğin görüntü işleme algoritmalarında sıklıkla kullanılmaya başlanması 1981 yılında Dana H.B yayımlanan makale sayesinde [88,89]. Bu

makale sayesinde Hough dönüşümünün sadece imgedeki doğruları değil aynı zamanda parametrik olarak ifade edilebilen daire ve elips gibi şekilleri de tespit edebileceği anlaşılmıştır.

Hough dönüşümü temelde imgede herhangi bir rotasyonda bulunan bir doğruyu tespit edebilmek amacıyla kullanılabilir. Genel olarak bir doğru denklemi x-y uzayında $y=mx+b$ olarak gösterilmektedir. Bu denklemde m doğrunun eğimini temsil etmektedir. Bu eğim değeri sonsuz değer alabileceğinden hesaplanabilmesi zor olmaktadır. Bu nedenle kartezyen uzayda bir doğru Denklem (5.3)'deki gibi;

$$\rho = x \cos(\theta) + y \sin(\theta) \quad (5.3)$$

ifade edilebilmektedir. Denklem (5.3)'de yer alan ρ değeri orijinden olan uzaklığı gösterirken θ değeri ise doğrunun x eksenine yapılan açıdır. Doğrunun parametrelerinin değişimi Şekil 5.4'de verilmiştir.



Şekil 5.4. Hough dönüşümü kartezyen koordinatlar


Hough dönüşümü kullanılarak sadece doğrular değil daireler de tespit edilebilmektedir. Bu tez çalışması kapsamında da elde edilen göz imgesinden gözbebeğinin tespiti için Hough dönüşümü kullanılmıştır. Kullanılan Hough dönüşümü ile tespit edilen daireler arasından içerisindeki siyah piksel sayısı en yüksek olan daire gözbebeğinin olduğu daire seçilmiştir. Örnek görüntü için gözbebeği olmaya aday daireler Şekil 5.5'de gösterilmiştir.



Şekil 5.5. Göz bebeği için aday daireler

Bu daireler içerisinde kapladığı alandaki en fazla sayıda siyah piksele sahip olan daire gözbebeğinin bulunduğu daire olarak seçilerek diğerleri elenmiştir.

Gözbebeğinin bulunduğu dairenin içerisindeki siyah piksellerin ağırlık merkezinin x ve y eksenlerindeki ortalama değerleri bulunarak bir öznitelik olarak kaydedilmiştir. Bu özneliğin yanı sıra bulunan merkezden dairenin alanı kadar bir sol tarafa bir de sağ tarafa dikdörtgen çizilerek buralardaki beyaz piksel sayısı hesaplanmıştır. Her iki yöndeki beyaz piksel sayısı ve bu iki değer birbirlerine olan oranları da birer öznitelik olarak seçilerek öznitelik vektörüne dahil edilmiştir. Örnek görüntü için elde edilen merkez noktası ve etrafında çizilen dikdörtgenler Şekil 5.6'da verilmiştir.



Şekil 5.6. Göz bebeği merkezi ve etrafındaki kareler

Gradyent tabanlı öznitelikler ek olarak kullanılan bu öznitelikler ile sistemde eğitim yapılmıştır. Çıkarılan öznitelik vektörleri rastgele orman sınıflandırıcısına giriş olarak verilmiştir. Yapılan deneylerde elde edilen sonuçlar bir sonraki bölümde incelenecektir.

6. SONUÇLAR VE ÖNERİLER

Bu tez çalışması kapsamında geliştirilen sınıflandırma algoritmasının performansını üç aşamada incelenmiştir. İlk olarak geliştirilen algoritma literatürde bulunan BCI IV yarışmasında kullanılan veri seti üzerinde denenmiştir. Bu veri setinde dokuz farklı denek bulunmaktadır. Geliştirilen algoritmanın sonuçları her bir denek için kappa değeri hesaplanarak verilmiştir. Kappa değeri iki değişkenin birbirine ne kadar benzediğinin bir ölçüsüdür. Her bir denek için hesaplanan kappa değerleri literatürde yapılan çalışmalarla karşılaştırılmıştır.

Sonrasında ise deney düzeneği kullanılarak deneklerden elde edilen EEG ve EMG verileri bilgisayar ortamında incelenmiş ve geliştirilen algoritma denenmiştir. Geliştirilen hibrid algoritmanın ve diğer sınıflandırıcıların elde ettiği sonuçlar verilmiştir. Geliştirilen algoritmanın diğer sınıflandırma yöntemlerinden üstün olduğu görülmüştür.

EEG sinyal işleme aşamasında sakin kalma ve küp döndürme olmak üzere iki farklı kavramsal görev tanımlanmış ve bu sınıflar birbirinden ayırt edilmeye çalışılmıştır. İki sınıf ayırma probleminde geliştirilen algoritmanın başarı oranının %99 seviyelerinde olduğu görülmüştür. İki sınıfın tekerlekli sandalyeyi yönlendirme işleminde yetersiz kalacağı düşünüldüğünden tanımlanan kavramsal görev sayısı üçe çıkartılmıştır. Kavramsal görev sayısı üçe çıkarıldığında, sınıflandırma performansının %80 seviyelerine düştüğü gözlenmiştir. Diğer taraftan, %80'lik performansın da sistemi yönlendirmede yeterli olduğu görülmüştür.

Gerçek zamanlı testlerde kullanıcılardan belirli bir rotayı takip etmeleri istenmiştir. Bu rotalar sırasıyla eliptik, karesel ve sinüzoidal rotalardır. Yapılan deneylerde kullanıcıların bütün rotaları EMG kullanarak takip edebildikleri gözlenmiştir. EEG tabanlı kontrolde ise çevresel şartların çok etkili olduğu gözlenmiştir. Kullanıcıların ortam gürültülerden etkilendikleri ve başarılarının düştüğü gözlenmiştir. Bu nedenle gerçek zamanlı EEG tabanlı kontrol deneyleri kontrollü

ortamlarda yapılmıştır. EEG tabanlı kontrollerde kullanıcıların konsantrasyonlarının da önemli olduğu gözlenmiştir. EMG ile sistemi başarılı bir şekilde kontrol edebilen dört denekten bir tanesi EEG ile sistemin kontrolünü sağlayamamıştır. Kasları kontrol etmek, beyin sinyallerini kontrol etmekten daha kolay olduğu için böyle olmasının da normal olarak değerlendirilmesi gerekmektedir. Göz hareketleri tabanlı kontrol ise tek bir denek üzerinde denenmiş ve başarılı sonuçlar elde edilmiştir.

Literatürde sınıflandırma algoritmalarının performansları genellikle iki performans ölçütü kullanılarak karşılaştırılmıştır. Bu performans ölçütleri, duyarlılık ve belirleyicilik, Denklem (6.1) ve Denklem (6.2)'deki gibi;

$$\text{Duyarlılık} = \frac{TP}{(TP+FN)} \quad (6.1)$$

$$\text{Belirleyicilik} = \frac{TN}{(TN+FP)} \quad (6.2)$$

hesaplanabilmektedir. Denklem (6.1)'de yer alan değişkenlerden TP değeri, bir sınıfa sınıflandırıcı tarafından doğru bir şekilde atanan elemanların sayısıdır. FN ise ilgili sınıfa sınıflandırıcı tarafından yanlış atanan elemanların toplamıdır. TN değeri ise sınıflandırıcı tarafından ilgili sınıf haricinde kalan diğer sınıflara doğru bir şekilde atanan elemanlarının toplamıdır. FP değeri ise gerçekte ilgili sınıf olmadığı halde, sınıflandırıcı tarafından o sınıfa atanan elemanların toplamıdır.

6.1. Öznitelik Seçme Sonuçları

Tez çalışması sırasında EEG verilerinden öznitelik seçme amacıyla genetik algoritma ve PCA kullanılmıştır. Bu işlemler sadece EEG verileri üzerinde uygulanmıştır. Literatürde bulunan EEG verileri ile deney düzeneğinden elde edilen EEG verileri üzerinde öznitelik seçme işlemi birbirinden bağımsız olarak çalıştırılmıştır. Genetik algoritma kullanılırken her bir öznitelik bir kromozom olarak ifade edilmiştir. Her bir genin yapısında da bir özneliğin olması veya olmaması durumu sırasıyla 1 ve 0 olmak üzere bit şeklinde kodlanmıştır.

Genetik algoritma sezgisel bir yöntem olduğu için her seferinde aynı sonuçları elde etmemektedir. Bu nedenle genetik algoritma aynı veriler için 100 defa çalıştırılmış

ve belirli bir eşiğin üzerinde seçilen öznitelikler ayırıcı öznitelik olarak kabul edilmiştir. Sonrasında ise sınıflandırıcı sadece bu öznitelikler kullanılarak eğitilmiş ve test edilmiştir. Yapılan çalışmalar sonucunda deney düzeneğinden elde edilen veriler için genetik algoritma tarafından her bir kanal için seçilen öznitelikler örnek bir denek için Tablo 6.1’de verilmiştir.

Tablo 6.1. Birinci denek için deney düzeneğinden elde edilen verilerde bütün EEG kanalları üzerinde genetik algoritma öznitelik seçim sonuçları


	Ortalama	Çizgi uzunluğu	Standart sapma	Yaklaşık entropi	Alfa band enerjisi	Beta band enerjisi	Theta band enerjisi	Ayrıntı Sinyal enerjisi
AF3	-	-	-	-	+	+	+	-
AF4	-	-	-	-	+	+	-	-
F3	+	-	-	+	+	+	-	-
F4	-	+	+	-	+	+	+	+
F7	+	+	+	-	-	-	+	+
F8	-	-	-	-	+	+	-	-
FC5	-	-	-	-	-	+	-	-
FC6	+	-	-	+	-	+	-	+
T7	-	-	-	-	-	+	+	+
T8	-	-	-	-	+	+	+	-
P7	+	+	+	+	+	+	+	+
P8	-	-	-	-	+	+	+	-
O1	-	-	-	-	+	+	+	-
O2	+	-	-	+	+	+	+	-

İlgili özneliğin karşısındaki ‘+’ işaret özneliğin GA tarafından öznelik vektörüne dahil edildiği, ‘-’ işareti ise dahil edilmediğini ifade etmektedir. Tablodan da görülebileceği gibi genetik algoritma ön kanallardaki (AF3, AF4) zaman uzayı tabanlı öznelikleri seçmemektedir. Bu durum, EEG sinyallerinde ön kanalların gürültüden en çok etkilenen kanallar olması ile açıklanabilir. Bu özneliklere ek olarak kanallardan bağımsız ortak uzamsal örüntü tabanlı öznelikler de kullanılmıştır. Ortak uzamsal örüntü kullanılırken, ham EEG sinyali dokuz farklı frekans aralıklarına bölünerek işlem yapılmıştır. Genetik algoritmanın ortak uzamsal örüntü özneliklerinin arasından seçtiği sonuçlar Tablo 6.2’de verilmiştir. Tablodan da görülebileceği gibi genetik algoritma (8-30) Hz arasındaki frekans bileşenlerini seçmektedir. Bu da aslında alfa, beta, theta bantlarındaki enerjilerin farklı kavramsal görevlerde değiştiğini göstermektedir.

Tablo 6.2. Birinci denek için deney düzeneğinden elde edilen verilerde ortak uzamsal örüntü için genetik algoritma öznelik seçim sonuçları

	(0-4)	(4-8)	(8-12)	(12-16)	(16-20)	(20-24)	(24-28)	(28-32)	(32-36)
Ortak Uzamsal Örüntü	-	-	+	+	+	+	+	-	-


Genetik algoritmanın deney düzeneğinden toplanan veriler üzerinde elde edilen sınıflandırma sonuçlarını nasıl iyileştirdiğinin grafiği ise Şekil 6.1’de verilmiştir. Eğer genetik algoritma hiçbir özneliği seçmezse, ceza fonksiyonun değeri en üst sınır değerine eşitlenmiştir. Şekilden de görülebileceği gibi genetik algoritma ilerleyen jenerasyon boyunca istenilen fonksiyonun performansını arttırmaktadır. Her bir jenerasyonda elde edilen en iyi ve en kötü sonuçlar verilmiştir. Sınıflandırıcıların ise optimal öznelikler ile elde ettiği performanslar sınıflandırıcıların performans değerlendirme tablolarında verilecektir.



Şekil 6.1. Deney düzeneğinden alınan verilerde genetik algoritma sonucu

Genetik algoritma tabanlı öznelik seçme işlemi literatürde bulunan örnek EEG verileri (BCI yarışması IV veri seti 2a) üzerinde de denenmiştir. Bu sinyallerde ise 22 kanal EEG, 3 kanal EOG sinyalleri bulunmaktadır.

Sinyallerin bilgisayar ortamında yapılan incelemesinde EOG kanallarındaki sinyallerden öznelikler çıkartıldığında sınıflandırma başarımının düştüğünü gözlenmiştir. Bu nedenle, öznelik çıkartma işlemi sırasında bu 3 EOG kanalları kullanılmamıştır. Genetik algoritma tabanlı öznelik seçme işlemi ise kalan 22 EEG kanallarından elde edilen sinyallerden çıkartılan öznelikler üzerinde denenmiştir. Literatürdeki veriler için kanallar üzerinde gerçekleştirilen öznelik seçme sonuçları birinci denek için Tablo 6.3’de verilmiştir.



Şekil 6.2. Örnek veri seti için genetik algoritma iyileştirme sonucu

Tablo 6.3. Birinci denek için örnek veri setinde bütün kanallar üzerinde genetik algoritma öznelik seçim sonuçları

Kanal Numarası	Ortalama	Çizgi uzunluğu	Standart sapma	Yaklaşık entropi	Alfa band enerjisi	Beta band enerjisi	Theta band enerjisi	Ayrıntı Sinyal enerjisi
1	-	-	-	-	+	+	+	-
2	-	-	-	-	+	+	-	-
3	+	-	-	+	+	+	-	-
4	-	+	+	-	+	+	+	+
5	+	+	+	-	-	-	+	+
6	-	-	-	-	+	+	-	-
7	-	-	-	-	-	+	-	-
8	+	-	-	+	-	+	-	+
9	+	+	+	-	-	-	+	+
10	-	-	-	-	+	+	-	-
11	-	-	-	-	-	+	-	-
12	+	-	-	+	-	+	-	+
13	+	+	+	-	-	-	+	+
14	-	-	-	-	+	+	-	-
15	-	-	-	-	-	+	-	-
16	+	-	-	+	-	+	-	+
17	-	-	-	-	-	+	+	+
18	-	-	-	-	+	+	+	-
19	+	+	+	+	+	+	+	+
20	-	-	-	-	+	+	+	-
21	-	-	-	-	+	+	+	-
22	+	-	-	+	+	+	+	-

Tablo 6.4. Birinci denek için örnek veri setinde ortak uzamsal örüntü için genetik algoritma öznelik seçim sonuçları

	(0-4)	(4-8)	(8-12)	(12-16)	(16-20)	(20-24)	(24-28)	(28-32)	(32-36)
Ortak Uzamsal Örüntü	-	+	+	+	+	+	-	-	-

Genetik algoritmanın örnek veriseti için sınıflandırma sonuçlarını ne kadar iyileştirdiği Şekil 6.2’de gösterilmiştir. Şekilden de görülebileceği gibi her bir jenerasyonda genetik algoritmanın seçtiği öznelikler kullanılarak sınıflandırıcının performansı arttırılmıştır. Şekil 6.2’de her bir jenerasyondaki ortalama, en iyi, en kötü sonuçlar verilmiştir. Tablo 6.3’de ise birinci denek için 22 kanaldan elde edilen zamansal öznelikler üzerinde yapılan öznelik seçme işleminin sonuçları gösterilmiştir. Deney düzeneğinden elde edilen verilerde olduğu gibi gürültüden etkilenebilecek kanallardaki (ilk 6 kanal) zamansal öznelikler genelde seçilmemiştir. Bu kanallar göz çevresine yakın olan kanallardır. Ortak uzamsal örüntü tabanlı öznelikler üzerinde uygulanan öznelik seçme işlemi Tablo 6.4’de verilmiştir. Tablodan da görülebileceği gibi genetik algoritma delta bandını seçmemektedir.

6.2. Örnek Veri Seti için Elde Edilen Sonuçlar

Tez çalışması kapsamında geliştirilen algoritmanın testi için 2007 yılında yapılan BCI yarışması için toplanan veri seti kullanılmıştır. Bu yarışma kapsamında, EEG sinyalleri dokuz farklı denekten dört farklı kavramsal görev olacak şekilde toplanmıştır. Kullanılan kavramsal görevler sırasıyla şu şekildedir: Sol elin hareket ettirildiğinin düşünülmesi, sağ elin hareket ettirildiğinin düşünülmesi, iki ayağın hareket ettirildiğinin düşünülmesi ve son olarak da dilin hareket ettirildiğinin düşünülmesi. Her bir denekten sinyaller farklı günlerde yapılan iki farklı oturum ile toplanmıştır. Sinyaller toplanırken başlangıç aşamasında toplanan sinyallerin ilk 5 dakikası EOG sinyallerin etkisinin azaltılması amacıyla ihmal edilmiştir. Yapılan deneylerin ilk beş dakikasını üç farklı kısma ayırmak mümkündür: İlk iki dakika gözler açık, sonraki iki dakika gözler kapalı ve sonraki bir dakikada gözler hareketli. Deney aşamaları Şekil 6.3’de verilmiştir [90].



Şekil 6.3. Deneydeki EOG kısımları

Sistemde EEG sinyallerini toplamak için kullanılan cihazın örnekleme frekansı 250 Hz olarak belirlenmiştir. Kullanılan sinyal yükselticinin hassasiyeti 100 uV olacak

şekilde ayarlanmıştır. Örnekleme işleminden sonra 0,5 Hz ile 100 Hz arasında çalışan bir bant geçiren filtre ve 50 Hz'lik sayısal çentik filtre kullanılmıştır. 22 tane EEG kanalına ek olarak üç adet de EOG kanalı bulunmaktadır. EOG kanallarının örnekleme frekansı da yine 250 Hz olacak şekilde ayarlanmıştır. EEG sinyallerinde olduğu gibi EOG sinyallerinde de aynı frekanslarda bant geçiren ve çentik filtreleri kullanılmıştır. EEG sinyallerinden farklı olarak bu sinyallerde yükselticinin hassasiyeti 1 mV olacak şekilde ayarlanmıştır. Geliştirilen sinyal işleme algoritmasında öncelikli olarak alınan sinyal, 2-30 Hz frekanslarını geçiren 20. dereceden bir bant geçiren filtreden geçirilmiştir. Tez çalışması kapsamında sinyaller 1,25 saniyelik zaman pencerelerine bölünerek işlem yapılmıştır. Her bir denek için toplamda 144 adet örnek bulunmaktadır. Geliştirilen sınıflandırma algoritmasında, sınıflandırıcılar ilgili deneğin verilerinin %50'si kullanılarak eğitilmiş, kalan % 50'si ise test aşamasında kullanılmıştır. Sınıflandırıcılardan elde edilen karar tablosu bütün denekler için toplam olarak Tablo 6.5'de verilmiştir. 324 tane sol el örneğinden 210 tanesi önerilen kural tabanlı sınıflandırma algoritması tarafından, doğru bir şekilde sol el olarak sınıflandırılmıştır. Bu durumda geliştirilen sınıflandırıcının sol el sınıfı için duyarlılığı Denklem (6.1) kullanılarak 0,648 olarak hesaplanmaktadır. Geliştirilen sınıflandırıcının sağ el, ayaklar ve dil hareketleri için duyarlılık değerleri sırasıyla 0,651, 0,663 ve 0,669 olarak hesaplanmaktadır. YSA, DVM, RO ve geliştirilen sınıflandırıcı olmak üzere bütün sınıflandırıcıların ortalama duyarlılık değerleri ise sırasıyla 0,595, 0,629, 0,642 ve 0,657 olarak hesaplanmaktadır. Hesaplamalar yapılırken sınıflandırılmayan örnekler FN olarak kabul edilmiştir. Geliştirilen algoritmanın yanlış sınıflandırma performansı %35 olarak hesaplanmıştır. Diğer sınıflandırıcılar YSA, DVM ve RO'nin ise yanlış sınıflandırma performansları sırasıyla %36, %38 ve %41 olarak hesaplanmıştır. Geliştirilen algoritmanın diğer sınıflandırıcılardan daha üstün bir performans gösterdiği tespit edilmiştir. Bütün öznelikler yerine genetik algoritma tarafından seçilen öznelikler kullanıldığında ise geliştirilen sınıflandırıcının başarımının daha da yükseldiği gözlenmiştir.

Tablo 6.5. Örnek veriseti için sınıflandırıcıların karar tablosu

	Sınıflandırıcı	Sol El	Sağ El	Ayaklar	Dil	Sınıflandıramayan
Sol El	YSA	189 (,583)	70	46	9	10
	DVM	195 (,601)	59	22	23	25
	RO	200 (,617)	48	44	32	0
	KTM	210 (,648)	40	25	26	23
	KTM+GA	220 (,679)	30	20	21	337
Sağ El	YSA	82	190 (,586)	18	21	13
	DVM	90	203 (,626)	11	10	10
	RO	77	207 (,638)	10	30	0
	KTM	70	211 (,651)	10	21	12
	KTM+GA	60	223 (,688)	11	19	11
Ayaklar	YSA	27	36	200 (,617)	46	15
	DVM	28	20	208 (,641)	32	36
	RO	51	32	212 (,654)	29	0
	KTM	28	36	215 (,663)	37	8
	KTM+GA	28	34	222 (,685)	36	4
Dil	YSA	72	19	33	193 (,595)	7
	DVM	42	3	32	210 (,648)	37
	RO	45	29	36	214 (,660)	0
	KTM	21	42	35	217 (,669)	9
	KTM+GA	36	29	31	221 (,682)	7

KTM+GA önerilen kural tabanlı sınıflandırıcının GA tarafından seçilen özniteliklerle elde ettiği sonuçlardır.

Tablo 6.6'da ise sinyal sınıflandırıcıların belirleyicilik değerleri hesaplanmıştır. Geliştirilen sinyal işleme algoritmasında kullanılan YSA, DVM, RO ve geliştirilen kural tabanlı sınıflandırıcılarının ortalama belirleyicilik değerleri ise sırasıyla 0,876, 0,904, 0,880 ve 0,889 olarak hesaplanmıştır. Bu sonuçlara göre geliştirilen

sınıflandırma algoritması diğer sınıflandırıcılardan daha yüksek ortalama belirginlik seviyesine sahiptir. Fakat geliştirilen sınıflandırıcıda bütün öznitelikler yerine GA tarafından seçilen optimal öznitelikler kullanıldığında sınıflandırma performansının arttığı gözlenmiştir.

Tablo 6.6. Geliştirilen sınıflandırıcılar için belirginlik tablosu

Sınıflandırıcı	Sol El	Sağ El	Ayaklar	Dil	Ortalama
YSA	0,813	0,871	0,900	0,966	0,876
DVM	0,835	0,915	0,933	0,959	0,904
RO	0,822	0,887	0,907	0,923	0,880
KTM	0,877	0,878	0,928	0,940	0,899
KTM+GA	0,872	0,904	0,936	0,921	0,908

KTM+GA önerilen kural tabanlı sınıflandırıcının GA tarafından seçilen özniteliklerle elde ettiği sonuçlardır.

Kappa değeri sınıflandırıcıların karşılaştırılmasında sıklıkla kullanılan bir parametredir ve Denklem (6.3)'deki gibi;

$$K = \frac{\text{Pr}(a) - \text{Pr}(e)}{1 - \text{Pr}(e)} \quad (6.3)$$

hesaplanmaktadır. Kappa değeri iki örneğin birbiriyle ne kadar uyduğunu ölçmektedir. Tez çalışması kapsamında geliştirilen algoritmanın her bir denek için elde ettiği kappa değerleri ve bu değerlerin literatürde yapılan çalışmalarla karşılaştırılması Tablo 6.7'de verilmiştir.

Ang ve ekibi ilk olarak yaptıkları CSP tabanlı çalışma ile bu yarışmayı kazanan ekip olmuşlardır. Bu ekip ortalamada elde ettikleri 0,57 kappa değeri ile yarışmaya katılan ekipler içerisinde en yüksek değeri elde etmişlerdir. Sonrasında ise Gauy ve ekibi yaptıkları çalışma ile Ang ve ekibini bazı deneklerde geçmiş olmalarına karşın, 0,5 ortalama kappa değeri elde ederek Ang ve ekibinin ortalama başarımının altında kalmışlardır. Nicolas ve ekibi ise bazı deneklerde daha düşük kappa değerleri elde etmesine rağmen ortalama kappa değerinde 0,62 değerini elde ederek Ang ve ekibinin başarımını geçmişlerdir. Tez çalışması kapsamında geliştirilen sınıflandırma algoritması ise bazı deneklerde Nicolas'ın önerdiği modelin altında kappa değerleri elde etmesine karşın ortalamada daha yüksek kappa değerleri elde etmiştir. Geliştirilen sınıflandırma algoritması GA tarafından seçilen öznitelikler

kullanıldığında ise her bir denekte Nicolas tarafından önerilen modele eşit veya daha yüksek kappa değerleri elde etmektedir.

Tablo 6.7. Kappa değerlerinin diğer çalışmalarla karşılaştırılması

Denek Numarası	Ang (Kazanan) [92]	Gouy- Pailler [93]	Nicolas[94]	KTM	KTM+GA
Denek 1	0,68	0,66	0,77	0,69	0,77
Denek 2	0,42	0,42	0,39	0,43	0,45
Denek 3	0,75	0,77	0,87	0,88	0,90
Denk 4	0,48	0,51	0,55	0,66	0,70
Denek 5	0,40	0,50	0,47	0,60	0,62
Denek 6	0,27	0,21	0,32	0,38	0,42
Denek 7	0,77	0,30	0,74	0,90	0,92
Denek 8	0,75	0,69	0,79	0,80	0,82
Denek 9	0,61	0,46	0,72	0,70	0,72
Ortalama	0,57	0,50	0,62	0,67	0,70

KTM+GA önerilen kural tabanlı sınıflandırıcının GA tarafından seçilen özniteliklerle elde ettiği sonuçlardır

6.3. Deney Düzeneginden Elde Edilen Sonuçlar

Deney düzenegi kullanılarak elde edilen sonuçlar iki kısımda incelenecektir. İlk kısımda bilgisayar ortamında elde edilen sonuçlar değerlendirilecektir. İkinci kısımda ise tekerlekli sandalye kullanılarak gerçek zamanda elde edilen rota takip sonuçları verilecektir. Bilgisayar ortamındaki sonuçlar verilirken, bütün öznitelikler kullanıldığında elde edilen sonuçlar ile optimal öznitelikler kullanıldığında elde edilen sonuçlar karşılaştırılacaktır. Sonrasında ise kullanıcıların gerçek zamanda elde ettiği sonuçlar incelenecek ve başarı oranları karşılaştırılacaktır.

6.3.1. Bilgisayar ortamındaki sonuçlar

Çalışma kapsamında deneklerden elde edilen EEG ve EMG sinyalleri ilk olarak bilgisayar ortamına alınarak işlenmiştir.

EMG sinyalleri için dört farklı denekten dört farklı sınıf (yumruk yapma, elleri serbest bırakma, eli sola çevirme, eli sağa çevirme) için sinyaller toplanmıştır. Her bir sınıf için 2 saniyelik örnekler toplanmıştır. Her 50 ms'de bir örnek alındığından dolayı her bir sınıfta 40 örnek bulunmaktadır. Her bir işlem 10 farklı deney için tekrarlandığından dolayı her bir sınıftan 400 örnek üzere toplamda 1600 örnek

oluşmaktadır. Bu örneklerden rastgele seçilen %70 'i sınıflandırıcıların eğitimi için kullanılırken % 30'u test için kullanılmıştır.

Tablo 6.8. EMG sinyalleri için karar tablosu

	Sınıflandırıcı	Yumruk	Serbest	Sol	Sağ	Sınıflandırılmayan
Yumruk	YSA	220 (,458)	130	79	20	31
	DVM	407 (,848)	1	25	34	13
	RO	385 (,802)	0	44	51	0
	Önerilen	408 (,850)	1	20	25	26
Serbest	YSA	0	474 (,988)	6	0	0
	DVM	3	472 (,983)	2	2	1
	RO	0	478 (,996)	2	0	0
	Önerilen	0	479 (,998)	1	0	0
Sola Çevirme	YSA	11	122	328 (,683)	19	0
	DVM	82	2	335 (,698)	10	51
	RO	51	0	400 (,833)	29	0
	Önerilen	28	2	405 (,844)	37	8
Sağa Çevirme	YSA	8	48	141	282 (,588)	1
	DVM	85	3	32	323 (,673)	37
	RO	41	0	37	402 (,838)	0
	Önerilen	28	1	35	407 (,848)	9

Her bir sınıftan alınan 120 örnek test için kullanılmıştır. Bu işlem her bir kullanıcı için tekrarlandığında ise dört kullanıcı için, her bir sınıfta toplamda 480 örnek bulunmaktadır. EMG sinyallerini sınıflandırmada kullanılan sınıflandırıcıların karar tablosu Tablo 6.8'de verilmiştir. 480 tane bulunan yumruk örneğinden 408 tanesi önerilen kural tabanlı sınıflandırma algoritması tarafından, doğru bir şekilde yumruk olarak sınıflandırılmıştır. Bu durumda geliştirilen sınıflandırıcının yumruk sınıfı için duyarlılığı Denklem (6.1) kullanılarak 0,85 olarak hesaplanmaktadır. Geliştirilen sınıflandırıcının ellerin serbest bırakılması, sola çevrilmesi ve sağa çevrilmesi için

duyarlılık değerleri sırasıyla 0,99, 0,844 ve 0,848 olarak hesaplanmaktadır. YSA, DVM, RO ve geliştirilen sınıflandırıcı olmak üzere bütün sınıflandırıcıların ortalama duyarlılık değerleri ise sırasıyla 0,679, 0,801, 0,867 ve 0,885 olarak hesaplanmaktadır. Hesaplamalar yapılırken sınıflandırılmayan örnekler FN olarak kabul edilmiştir. Geliştirilen algoritmanın yanlış sınıflandırma performansı %9,3 olarak hesaplanmıştır. Diğer sınıflandırıcılar YSA, DVM ve RO'nin ise yanlış sınıflandırma performansları sırasıyla %30,4, %14,6 ve %13,3 olarak hesaplanmıştır. Geliştirilen algoritmanın diğer sınıflandırıcılardan daha üstün bir performans gösterdiği tespit edilmiştir.

Tablo 6.9. EMG sinyalleri için sınıflandırıcıların belirginlik değerleri

Sınıflandırıcı	Yumruk	Serbest	Sol	Sağ	Ortalama
YSA	0,987	0,791	0,843	0,972	0,898
DVM	0,882	0,995	0,959	0,968	0,951
RO	0,936	1	0,942	0,944	0,955
Önerilen	0,961	0,997	0,961	0,956	0,969

Tablo 6.9'da ise EMG sinyal sınıflandırıcıların belirleyicilik değerleri verilmektedir. Geliştirilen sinyal işleme algoritmasında kullanılan YSA, DVM, RO ve geliştirilen kural tabanlı sınıflandırıcılarının ortalama belirleyicilik değerleri sırasıyla 0,860, 0,945, 0,945 ve 0,961 olarak hesaplanmıştır. Bu sonuçlara göre geliştirilen sınıflandırma algoritması diğer sınıflandırıcılardan daha yüksek ortalama belirginlik değerine sahiptir.

EEG sinyalleri için ilk olarak iki sınıf kullanılarak sınıflandırma yapılmıştır. Bu aşamada DVM ve YSA kullanılmıştır. Kullanılan sınıflandırıcılar için elde edilen karar tablosu Tablo 6.10'da verilmiştir. İki kavramsal görevin sınıflandırılması işleminde sadece YSA ve DVM sınıflandırıcıları kullanılmıştır. İki kavramsal görev bulunan EEG sinyalleri iki denekten 35 saniye boyunca toplanmıştır. Bu işlem 20 defa tekrarlanarak EEG sinyalleri toplanmıştır. Sinyaller işlenirken 250 ms'lik zaman pencerelerine bölünmüştür. Bu nedenle her bir sınıf için 5600 örnek elde edilmiştir. Küp döndürme işleminde ise 352 tane örneğin artifakt içerdiği tespit edildiğinden dolayı sınıflandırma işlemine dahil edilmemiştir. DVM sınıflandırıcının duyarlılık ve belirginlik değerleri sırasıyla 0,99 ve 0,98 olarak bulunmuştur. DVM sınıflandırıcısının doğruluk oranları sakin kalma kavramsal görevi için %98,4, küp

döndürme kavramsal görevi için %99,8 ve ortalama doğruluk değeri ise %99,1 olmaktadır.

Tablo 6.10. EEG sinyal sınıflandırıcıları karar tablosu

	Sınıflandırıcı	Küp döndürme	Sakin Kalma
Küp döndürme	DVM	5165 (%99,8)	83
	YSA	5038 (%96)	210
Sakin Kalma	DVM	9	5551 (%98)
	YSA	112	5448 (%99,1)

Benzer şekilde iki kavramsal görevin sınıflandırma işlemi kullanıldığında ise YSA sınıflandırıcının duyarlılık ve belirginlik değerleri sırasıyla 0,97 ve 0,96 olarak bulunmuştur. YSA sınıflandırıcısının doğruluk oranları sakın kalma kavramsal görevi için %96, küp döndürme kavramsal görevi için %98 ve ortalama doğruluk değeri ise %97 olmaktadır.

Görüldüğü gibi iki sınıf sınıflandırma probleminde sınıflandırma algoritmalarının başarımları çok yüksek olmaktadır. Fakat önceki bölümlerde de bahsedildiği gibi iki tane kavramsal görev tekerlekli sandalyenin yönlendirilmesinde yeterli olmamaktadır. Bu nedenle üç farklı kavramsal görev tanımlanmıştır. Bunlar sırasıyla sakın kalma, paragraf okuma ve matematiksel problemleri çözme kavramsal görevleridir. EMG deneylerini dört farklı denek başarı ile gerçekleştirmesine rağmen deneklerden birinin EEG deneylerinde başarılı bir sonuç elde edemediği gözlenmiştir. Bu nedenle bu çalışma kapsamında EEG sinyalleri üç farklı denek üzerinden toplanarak elde edilmiştir. Her bir denekten her bir kavramsal görev için 10 saniye boyunca sinyaller toplanmıştır. Toplanan sinyaller birer saniyelik zaman pencerelerine bölünerek sınıflandırma işlemine tabi tutulmuştur. EEG sinyalleri için geliştirilen sınıflandırıcı algoritmasının karar tablosu Tablo 6.11’de verilmiştir.

Tablo 6.11. EEG sınıflandırıcıları için karar tablosu

	Sınıflandırıcı	Sakin	Paragraf Okuma	Matematiksel Problem Çözme	Sınıflandırılmayan
Sakin	YSA	43 (,478)	40	4	3
	DVM	75 (,833)	7	6	2
	RO	72 (,800)	10	8	0
	KTM	81 (,900)	0	0	9
	KTM+GA	83 (,922)	0	0	7
Paragraf Okuma	YSA	0	69 (,767)	12	9
	DVM	0	65 (,722)	7	18
	RO	2	73 (,811)	15	0
	KTM	5	74 (,822)	11	0
	KTM+GA	3	77 (,855)	10	0
Matematiksel Problem Çözme	YSA	3	20	64 (,711)	3
	DVM	0	15	65 (,722)	10
	RO	6	15	69 (,767)	0
	KTM	0	14	76 (,844)	0
	KTM +GA	0	10	80 (,888)	0

KTM+GA önerilen kural tabanlı sınıflandırıcının GA tarafından seçilen özniteliklerle elde ettiği sonuçlardır.

Tablo 6.11’de yer alan sınıflandırıcıların karar tablosundaki değerlere bakarak geliştirilen sınıflandırıcının ve diğer yöntemlerin duyarlılık değerleri Denklem (6.1) kullanılarak hesaplanabilmektedir. Tabloda yer alan değerler, EMG karar tablosunda da olduğu gibi bütün deneklerden alınan örneklerin toplamıdır. DVM sınıflandırıcının rahatlama kavramsal görevi için duyarlılığı diğer sınıflandırıcılardan daha yüksek olduğu görülmektedir. Diğer bir yandan RF sınıflandırıcının paragraf okuma ve matematiksel problem çözme kavramsal görevlerinde daha iyi sonuçlar elde etmektedir. Tez çalışması kapsamında geliştirilen kural tabanlı sınıflandırıcı 90 tane sakin kalma örneğinden 81 tanesini doğru şekilde sınıflandırmıştır. Denklem (6.1) kullanılarak geliştirilen sınıflandırıcının rahatlama kavramsal görevi için duyarlılık değeri 0,9 olarak hesaplanmaktadır.

Benzer şekilde geliştirilen sınıflandırıcının diğer sınıflar olan paragraf okuma ve matematiksel problem çözme için duyarlılık değerleri 0,822 ve 0,844 olarak hesaplanmıştır. Kullanılan diğer sınıflandırıcılar olan YSA, DVM, RO ve geliştirilen sınıflandırıcı için ortalama duyarlılık değerleri 0,767, 0,899, 0,828 ve 0,904 olmaktadır.

Tablo 6.12. EEG sinyalleri için belirginlik tablosu

Sınıflandırıcı	Sakin	Paragraf Okuma	Matematiksel Problem Çözme	Ortalama
YSA	0,982	0,459	0,862	0,767
DVM	1	0,809	0,887	0,899
RO	0,926	0,766	0,793	0,828
KTM	0,950	0,868	0,894	0,904
KTM+GA	0,983	0,944	0,944	0,957

KTM+GA önerilen kural tabanlı sınıflandırıcının GA tarafından seçilen özniteliklerle elde ettiği sonuçlardır.

Önerilen sınıflandırma algoritmasının yanlış sınıflandırma oranı %11 olmakta iken diğer sınıflandırıcılar olan YSA, DVM ve RO için yanlış sınıflandırma oranı sırasıyla %30,7, %12,9 ve %20,7 olmaktadır. EMG tabanlı kontrolde olduğu gibi EEG tabanlı sinyal işleme de geliştirilen sınıflandırıcının diğer sınıflandırıcıların üzerinde bir performans gösterdiği gözlenmiştir. Örnek veri setinde olduğu gibi deney setinden elde edilen verilerde geliştirilen algorithmada bütün öznitelikler yerine genetik algoritma tarafından seçilen öznitelikler kullanıldığında ise sınıflandırıcının performansının arttığı gözlenmektedir.

Tablo 6.12’de de gösterildiği gibi belirginlik değeri EEG sınıflandırıcıları için hesaplanmıştır. YSA, DVM, RO ve geliştirilen sınıflandırıcı incelendiğinde ortalama belirginlik değerleri 0,767, 0,899, 0,828 ve 0,904 olmaktadır. En yüksek duyarlılığa sahip olmanın yanında geliştirilen algoritmanın en yüksek belirginliğe sahip olduğu da görülmektedir.

EMG ve EEG tabanlı kontrolün yanında göz hareketleri tabanlı kontrol için de örnek görüntüler bilgisayar ortamına alınarak sınıflandırma yapılmıştır. Alınan görüntülerden öncelikli olarak gözler elde edilmektedir. Sonrasında ise ortaya, sağa ve sola bakma olarak üç adet sınıf tanımlanmıştır. Göz hareketleri tabanlı kontroldeki deneyler tek bir kullanıcı için yapılmıştır. Bu kullanıcıdan alınan görüntüler beşinci

bölümde detaylıca anlatılan algoritma ile bilgisayar ortamında işlenmiştir. Göz hareketleri tabanlı kontrolü deneyen denekten, her bir sınıf için 360 adet görüntü alınmıştır. Bu verilerden %70'i sınıflandırıcının eğitimi için kullanılmış olup kalan %30'u ile de geliştirilen sınıflandırıcı test edilmiştir. Geliştirilen görüntü işleme tabanlı kontrol algoritmasında sınıflandırıcı olarak RO sınıflandırıcısı kullanılmıştır. RO sınıflandırıcısının karar tablosu Tablo 6.13'de verilmiştir. Geliştirilen algoritma, alınan görüntüde göz bebeği tespit edilemediğinde ise öznitelik çıkartma işlemi yapamamaktadır ve bu nedenle ilgili örneği kaydetmemektedir.

Tablo 6.13. Göz hareketleri için karar tablosu

	Ortaya bakış	Sağa bakış	Sola bakış
Ortaya bakış	107 (0,99)	0	1
Sağa bakış	5	103 (0,95)	0
Sola bakış	0	2	106 (0,98)

Tablo 6.14. Göz hareketleri için belirginlik tablosu

Sınıflandırıcı	Ortaya bakış	Sağa bakış	Sola bakış
RO	0,97	0,99	0,99


108 tane bulunan ortaya bakış örneğinden 107 tanesi önerilen RO tabanlı sınıflandırma algoritması tarafından, doğru bir şekilde ortaya bakış olarak sınıflandırılmıştır. Bu durumda geliştirilen sınıflandırıcının ortaya bakış sınıfı için duyarlılığı Denklem (6.1) kullanılarak 0,99 olarak hesaplanmaktadır. RO sınıflandırıcının ellerin sağa bakış ve sola bakış için duyarlılık değerleri sırasıyla 0,95, 0,98 olarak hesaplanmaktadır. Geliştirilen görüntü işleme algoritmasının bütün sınıflar için yanlış sınıflandırma performansı %2 olarak hesaplanmıştır. Tablo 6.14'de ise geliştirilen sınıflandırıcının belirginlik tablosu verilmiştir. Tablo 6.14 incelendiğinde ise RO sınıflandırıcının en düşük belirginlik oranının ortaya bakış sınıfında olduğu görülmüştür.

6.3.2. Gerçek zaman test sonuçları

Bu tez çalışması kapsamında geliştirilen sınıflandırma algoritması gerçek zamanlı olarak alınan sinyaller üzerinde çalıştırılmıştır. Bu amaçla üç farklı rota tanımlanmış ve kullanıcılardan bu rotaları takip etmesi istenmiştir. Tekerlekli sandalye belirli

aralıklarla, önu bilinçli bir şekilde kapatılarak geliştirilen güvenli sürüş algoritması ile durdurulmuştur. Bu esnada tekerlekli sandalyenin konumu bir lazermetre ile ölçülerek kaydedilmiştir. Konum ölçümlerinde tekerlekli sandalyenin merkez noktası referans alınmıştır. Ölçüm almak için tekerlekli sandalyenin durdurulması, kullanıcıların performansını olumsuz olarak etkilemekte ve konum hatalarını arttırmaktadır.


EMG tabanlı kontrolde dört farklı denek için dikdörtgenel rotada elde edilen sonuçlar Şekil 6.4’de gösterilmiştir.



Şekil 6.4. EMG tabanlı kontrolde dikdörtgenel rota için sonuçlar

Şekil 6.4’de verilen dikdörtgenel rota sonuçları incelendiğinde konum hatalarının köşelerde arttığı gözlenmektedir. Saat yönünde ve sürekli bir sola dönüş yapma işlemi kullanıcıları zorlamaktadır. Özellikle köşelerdeki dönüşlerden sonra tekerlekli sandalyeyi rotada tutma işleminin zorluğu görülmektedir. Bu nedenle, özellikle bu köşe dönüşlerinden sonra hata oranlarının arttığı görülmektedir. Kullanıcılar arasındaki performans farkları da kullanıcıların tecrübe düzeyleri ile açıklanabilmektedir. Bu deneyler kapsamında birinci denek en tecrübeli denek olup tezi geliştiren ekipte yer almaktadır.

EMG tabanlı kontrolde dört farklı denek için sinüzoidal rotada elde edilen sonuçlar Şekil 6.5’de gösterilmiştir.

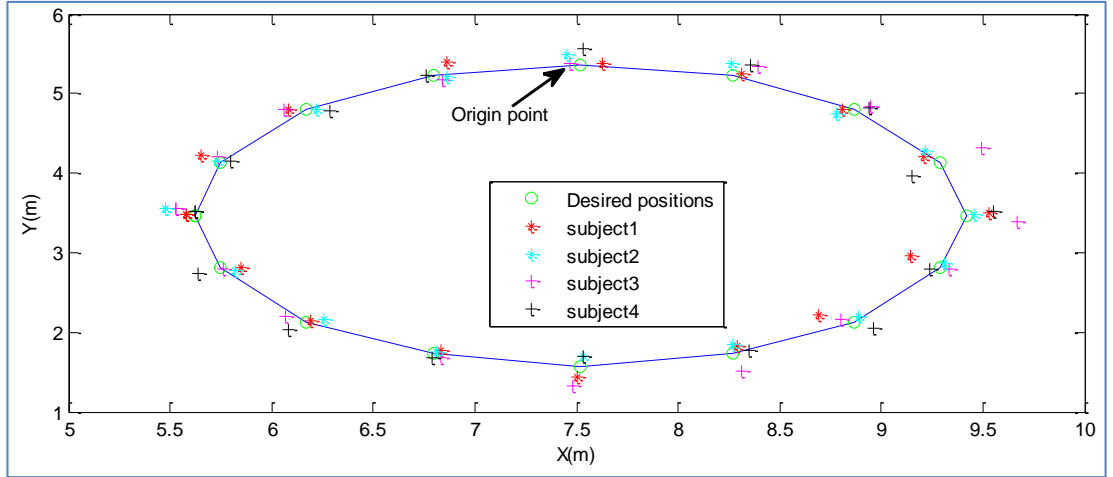


Şekil 6.5. EMG tabanlı kontrolde sinüzoidal rota sonuçları

Kullanıcılar EMG kullanılarak yapılan kontrollerde bu rotaları başarılı bir şekilde takip etmişlerdir. Yerel extremum noktalarındaki dönüşler sinüzoidal rotadaki zorluklar olarak karşımıza çıkmaktadır. Bu noktalarda rotadaki anlık ve keskin dönüşler bulunduğundan bu noktalarda konum hatalarının arttığı gözlenmiştir. Kullanıcılar bu noktalarda tekerlekli sandalyeyi rotada tutabilmek için ani dönüşler yapmak zorunda kalmışlardır.


EMG tabanlı kontrolde dört farklı denek için eliptik rotada elde edilen sonuçlar Şekil 6.6'da gösterilmiştir. Deneklerin tekerlekli sandalyeyi saat yönünde döndürmesi istenmiştir. Eliptik rotada deneklerin, tekerlekli sandalyeyi rotada tutabilmek için sürekli olarak döndürmesi gerekmektedir. Diğer rotaların aksine denekler bu rotadaki her bir noktada zorlanmışlardır.

Yapılan deneylerde, tekerlekli sandalyenin EMG tabanlı kontrolünde denek tecrübesinin yanı sıra yorgunluğun da önemli bir parametre olduğu gözlenmiştir. Yorgunluk süresi denekler arasında 45 dakika ile 1 saat arasında değişmektedir.



Şekil 6.6. EMG tabanlı kontrolde eliptik rota sonuçları

EEG tabanlı kontrolde, her bir saniyede alınan EEG sinyalleri işlenerek sonuçlar elde edilmiştir. EEG sinyalleri çevresel şartlardan çok etkilendiği için EEG tabanlı kontrol deneyleri kontrollü ortamda yapılmıştır. Deneyler sırasında deneklerin bir kavramsal görevden diğer kavramsal görevlere geçişi sırasında bir zaman gerekliliği ortaya çıkmıştır. Bu nedenle eğer geliştirilen algoritma iki defa ardışık olarak gelen EEG sinyallerinde aynı sonucu elde ederse tekerlekli sandalyeye bir dönüş komutu gönderilmiştir. Eğer geçerli bir dönüş komutu gelirse tekerlekli sandalyenin navigasyonu sağlanmış aksi takdirde ise tekerlekli sandalye durdurulmuştur. Bu nedenle EEG tabanlı kontrolde tekerlekli sandalyeye bir komutun gönderilebilmesi için en az iki saniye gerekmektedir. Bu nedenle EEG tabanlı kontrolde yörüngesi sıklıkla değişen ve yüksek manevra kabiliyeti isteyen rotaların takip edilmesi mümkün olmamaktadır. Bu nedenle EEG tabanlı kontrolde, deneklerden sadece sinüzoidal rotanın takip edilmesi istenmiş olup diğer rotalar ihmal edilmiştir. Bu çalışma kapsamında EMG tabanlı kontrolde başarılı bir rota takibi yapabilen deneklerden bir tanesi EEG tabanlı kontrolde başarılı olamamıştır. EEG tabanlı kontrolde üç farklı denek için sinüzoidal rotada elde edilen sonuçlar Şekil 6.7’de gösterilmiştir.



Şekil 6.7. EEG tabanlı kontrolde sinüzoidal rota sonuçları

Her iki bio-sinyal tabanlı kontrolde elde edilen sonuçlardaki konum hatalarının RMS değerleri x konum vektörünü göstermekle beraber Denklem (6.4)'deki gibi;

$$e_{\text{RMSE}} = \sqrt{\frac{\sum_{n=1}^N (x_n^d - x_n^*)^2}{N}} \quad (6.4)$$

Hesaplanabilmektedir. Denklem (6.4)'de yer alan N kaç tane noktadan konum ölçümü alındığını göstermektedir. x_n^d rota üzerinde varılması istenilen hedefler olup x_n^* ise rota üzerinde gidilen noktalar olmuştur.

Tablo 6.15. EMG tabanlı kontroldeki hatalar

EMG tabanlı kontrolde konum hataları	Dikdörtgenel rota (m)	Sinüzoidal Rota (m)	Eliptik Rota (m)
Denek 1	0,1294	0,1154	0,1154
Denek 2	0,1816	0,1546	0,1088
Denek 3	0,1585	0,1607	0,1473
Denek 4	0,1654	0,1468	0,1187

EMG tabanlı kontrolde en tecrübeli denek olan birinci denek için dikdörtgenel, sinüzoidal ve eliptik rotalar için sırasıyla pozisyon hataları sırasıyla 0,1294 m, 0,1154


m ve 0,1154 m'dir. Diğer deneklerin performansları 1 numaralı deneğe göre düşük kalmaktadır. Bütün deneklerin EMG tabanlı rota performansları Tablo 6.15'de verilmiştir. Önceden de bahsedildiği gibi her bir adımda tekerlekli sandalyeyi durdurmak performansın azalmasına neden olduğu için tekerlekli sandalye durdurulmadan ilerlemesinde performans artmaktadır.

EEG tabanlı kontrolde kullanıcıların performansı Tablo 6.16'da verilmiştir. EEG tabanlı kontrollerde ise elde edilen konum hataların EMG tabanlı kontrollere göre daha yüksek olmaktadır. Beyin sinyallerini kontrol etmek, kas sinyallerini kontrol etmekten daha zor olduğundan dolayı bu da beklenen bir durumdur.

Tablo 6.16. EEG tabanlı kontrolde hata değerleri

EEG tabanlı kontrolde konum hataları	Sinüzoidal rota (m)
Denek 1	0,2804
Denek 2	0,5180
Denek 3	0,3258

Göz hareketleri tabanlı kontrol ise tek bir denek üzerinde sadece sinüzoidal rota üzerinde denenmiştir. Elde edilen sonuç Şekil 6.8'de verilmiştir.



Şekil 6.8. Göz hareketleri tabanlı kontrol

Göz hareketleri tabanlı kontrolde kullanıcıların performansı Tablo 6.17'de verilmiştir.

Tablo 6.17. Göz hareketleri tabanlı kontrol sonuçları

EEG tabanlı kontrolde konum hataları	Sinuzoidal rota (m)
Denek1	0,3258

Göz hareketi tabanlı kontrolde edilen konum hataların EMG tabanlı kontrollere göre daha yüksek, EEG tabanlı kontrole göre daha az olmaktadır. Göz hareketlerini sağlarken aynı zamanda sistemi kontrol etmek zor olduğundan bu durum beklenen bir durumdur.



KAYNAKLAR

- [1] Berger H., On the human electroencephalogram, *Psychiatrie and Nervenkrankheiten*, 1929, **87**(52),7-70.
- [2] Gurkan K., Suat K., Hasan O., Omer S., Brain-Computer Interface with Low Cost Commercial EEG Device, *International Symposium on Innovative Technologies in Engineering and Science*, Valensiya, İspanya, 7-8 Ekim 2015.
- [3] www.bbc.de/competition/iv/desc_2a.pdf (Ziyaret tarihi: 27 Mayıs 2015).
- [4] www.bbc.de/competition/v/desc_2b.pdf (Ziyaret tarihi: 21 Mayıs 2015).
- [5] Samaneh K., Saeid S., Emma L. A., Dijk D. J., Tensor Based Singular Spectrum Analysis for Automatic Scoring of Sleep EEG, *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2015, **23**(1), 1-9.
- [6] Liang S. F., Kuo C. E., Hu Y. H., Pan Y. H., Wang Y. H., Automatic Stage Scoring of Single-Channel Sleep EEG by Using Multiscale Entropy and Autoregressive Models, *IEEE Transactions on Instrumentation And Measurement*, 2012, **61**(6), 1649-1657.
- [7] Antoine P., Harry W., Florian C., Detection of Cortical Slow Waves in the Sleep EEG Using a Modified Matching Pursuit Method With a Restricted Dictionary, *IEEE Transactions on Biomedical Engineering*, 2012, **50**(10), 2808-2817.
- [8] Ana C., Christoph M. M., Pieter V. M., Serge V., Gijis P., Directed Functional Brain Connectivity Based on EEG Source Imaging: Methodology and Application to Temporal Lobe Epilepsy, *IEEE Transactions On Biomedical Engineering*, 2016, **63**(12), 2619-2628.
- [9] Li D., Pu W., Yi B., Jiayan D., Yongjie L., Leiting C., Cheng L., Dezhong Y., Local Multimodal Serial Analysis for Fusing EEG-fMRI: A New Method to Study Familial Cortical Myoclonic Tremor and Epilepsy, *IEEE Transactions On Autonomous Mental Development*, 2015, **7**(4), 311-319.
- [10] Junhua L., Yijun W., Liqing Z., Andrzej C., Jung T. P., Decoding EEG in Cognitive Tasks With Time-Frequency and Connectivity Masks, *IEEE Transactions On Cognitive And Developmental Systems*, 2016, **8**(4), 298-308

- [11] Izguerdo J. M. C., Ibarrola J., Miguel A., Improving Motor Imagery Classification With a New BCI Design Using Neuro-Fuzzy S-dFasArt, *IEEE Transactions On Neural Systems And Rehabilitation Engineering*, 2012, **20**(1), 2-7.
- [12] Hooman N., Umut O., Shalini P., Kenneth H., Barry O., Deniz E., Decoding of Multichannel EEG Activity from the Visual Cortex in Response to Pseudorandom Binary Sequences of Visual Stimuli, *International Journal of Imaging Systems Technology*, 2011, **21**(1), 139-147.
- [13] Wei H., Yue Z., Haoyue T., Changyin S., Wei F., A Wireless BCI and BMI System for Wearable Robots, *IEEE Transactions On Systems, Man, and Cybernetics*, 2016, **47**(7), 936-946.
- [14] Marianne S., Monica P. H., Bart N., Jason F., Jacques D., Using Actual and Imagined Walking Related Desynchronization Features in a BCI, *IEEE Transactions On Neural Systems And Rehabilitation Engineering*, 2013, **23**(5), 877-886.
- [15] Feng D., Dongxue L., Wenyu L., Zhao Z., Design of a Multimodal EEG-based Hybrid BCI System with Visual Servo Module, *IEEE Transactions On Autonomous Mental Development*, 2015, **7**(4), 332-341.
- [16] Perez A. F., Oliver M. A., Salas G., Development of a Brain-Computer Interface Based on Visual Stimuli for the Movement of a Robot Joints, *IEEE Latin America Transactions*, 2016, **14**(2), 477-484.
- [17] Daniela D. V., Valerio F. A., Giovanni M., Michele R., Eugenio D. S., Brain-computer interface using P300: a gaming approach for neurocognitive impairment diagnosis, *IEEE International High Level Design Validation and Test Workshop*, Bari, Italy, 7-8 Ekim 2016.
- [18] Tomita Y., Vialette F. B., Dreyfus G., Yasue M., Hovagim B., Andrzej C., Bimodal BCI Using Simultaneously NIRS and EEG, *IEEE Transactions On Biomedical Engineering*, 2014, **61**(4), 1274-1284.
- [19] Minpeng X., Hongzhi Q., Lan M., Changcheng S., Lixin Z., Baikun W., Tao Y., Dong M., Channel Selection Based on Phase Measurement in P300-Based Brain-Computer Interface, *The Plos One Journal*, 2013, **8**(4), 606-616.
- [20] Kim K. T., Carlson T., Lee S. W., Design of a Robotic Wheelchair with a Motor Imagery based Brain-Computer Interface, *IEEE International Winter Workshop on Brain-Computer Interface*, Gangwon, Güney Kore, 18-20 Şubat 2016.
- [21] Kazuo T., Kazuyuki M., Hua O. W., Electroencephalogram-Based Control of an Electric Wheelchair, *IEEE Transactions on Robotics*, 2005, **21**(4), 762-766.

- [22] Fred A., Jhon M., Christian P., Francisco C., Hybrid BCI System to Operate an Electric Wheelchair and a Robotic Arm for Navigation and Manipulation Tasks, *IEEE International Workshop on Advanced Robotics and its Social Impacts*, Shanghai, Çin, 8-10 Temmuz 2016.
- [23] Kim K. T., Heung S., Seong W. L., Commanding a Brain-Controlled Wheelchair using Steady-State Somatosensory Evoked Potentials, *IEEE Transactions On Neural Systems And Rehabilitation Engineering*, 2016, **99**(1), 1-12.
- [24] Sun Q., Tang Y., Singularity Analysis Using Continuous Wavelet Transform for Bearing Fault Diagnosis, *MSSP*, 2002, **16**(6), 1025-1041.
- [25] Jonas I., Ali M., Sadasivan P., Comparative Study of Pseudorandom Sequences used in a c-VEP Based BCI for online Wheelchair Control, *IEEE 38th Annual International Conference of the Engineering in Medicine and Biology Society (EMBC)*, Orlando, USA, 16-20 Ağustos 2016.
- [26] Prassler E., Scholz J., Fiorini P., Motion coordination between a human and a mobile robot, *IEEE/RSJ International Conference on Intelligent Robots and Systems*, Lausanne, İsviçre, 1-4 Kasım 2002.
- [27] Jeonghee K., Xueliang H., Julia M., Jaimee H., Anne L., Maysam G., Evaluation of a Smartphone Platform as a Wireless Interface Between Tongue Drive System and Electric-Powered Wheelchairs, *IEEE Transaction on Biomed Engineering*, 2012, **59**(6), 1787-1796.
- [28] Chang C. L., Chen C. C., Chen C. Y., Lin B. Y., Kinect-based Powered Wheelchair Control System, *International Conference on Intelligent Systems Modelling & Simulation (ISMS)*, Bangkok, Tayland, 29-31 Ocak 2013.
- [29] Rohmer E., Paulo P., Eleri C., Mauro B., Giulio R., Laser based Driving Assistance for Smart Robotic Wheelchairs, *IEEE Conference on Emerging Technologies & Factory Automation (ETFA)*, Lüksemburg, Lüksemburg, 8-11 Eylül 2015.
- [30] Kannan R. M., Ramesh N. N., Sai M. P., Mithun M., Gest-BOT – A highly convenient locomotive solution for the elderly and physically challenged, *IEEE Global Humanitarian Technology Conference*, Seattle, USA, 21-24 Ekim 2012.
- [31] Manik G., Catherine H., Behzad M. H., Stephen H., A Comparison between Smartphone Sensors and Bespoke Sensor Devices for Wheelchair Accessibility Studies, *IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP)*, Singapur, Singapur, 7-9 Nisan 2015.
- [32] www.fulmaks.com.tr (Ziyaret tarihi: 27 Mayıs 2015).

- [33] www.myo.com (Ziyaret tarihi: 27 Mayıs 2015).
- [34] www.emotiv.com (Ziyaret tarihi: 27 Mayıs 2015).
- [35] Michael J. L., Benjamin Y. C., Peter A. B., Simulating Kinect Infrared and Depth Images, *IEEE Transactions on Cybernetics*, 2016, **46**(12), 3018-3031.
- [36] Carro R. C., Huerta E. B., Caporal R. M., Hernandez J. C., Cruz F. R., Facial Expression Analysis with Kinect for the Diagnosis of Paralysis Using Nottingham System, *IEEE Latin America Transactions*, 2016, **14**(7), 3418-3426.
- [37] Enrico B., Pietro P., Stefano B., Alberto D. B., Reconstructing High-Resolution Face Models From Kinect Depth Sequences, *IEEE Transactions On Information Forensics And Security*, 2016, **11**(12), 2843-2853.
- [38] Neto L. B., Felipe G., Vanesa R. M. L. M., Luiz C. M., Dinei F., Maria C. C. B., Anderson R., Siome G., A Kinect-Based Wearable Face Recognition System to Aid Visually Impaired Users, *IEEE Transactions On Human-Machine Systems*, 2017, **47**(1), 52-64.
- [39] Nagaran P., Saravanaa P. S., GA-based camera calibration for visionassisted robotic assembly system, *IET Computer Vision Journal*, 2016, **11**(1), 50-59.
- [40] Li F., Hicham S., Jason D., Christian S., Mark L., David C., John Z., Wong A., Simultaneous Projector-Camera Self-Calibration for Three-Dimensional Reconstruction and Projection Mapping, *IEEE Transactions On Computational Imaging*, 2017, **3**(1), 74-83.
- [41] Edson M., Paula D., Kersting A. P., Centeno J. A. S., Alvaro L. M., A Study on In Situ Calibration of an Off-The-Shelf Digital Camera Integrated to a Lidar System, *IEEE Journal of Selected Topics in Applied Earth Observations And Remote Sensing*, 2016, **9**(12), 5513-5523.
- [42] Park H. J., Jeong D. U., Park K. S., Automated Detection and Elimination of Periodic ECG Artifacts in EEG Using the Energy Interval Histogram Method, *IEEE Transactions on Biomedical Engineering*, 2002, **49**(12), 1526-1533.
- [43] Rajesh P., Madhukar P. J., Senthilnathan S., Katholil G., Thimmakudy S. R., Suppression of Eye-Blink Associated Artifact Using Single Channel EEG Data by Combining Cross-Correlation With Empirical Mode Decomposition, *IEEE Sensors Journal*, 2016, **16**(18), 6947-6954.
- [44] Shuyan H., Gangtie Z., Björn P., Driver fatigue detection from electroencephalogram spectrum after electrooculography artefact removal, *IET Intelligent Transport Systems Journal*, 2013, **7**(1), 105-113.
- [45] Renlong H., Qingshan L., Yubao S., Xiaotong Y., Hucheng P., Javier P., Antonio P., Robust Matrix Discriminative Analysis for Feature Extraction

From Hyperspectral Images, *IEEE Journal Of Selected Topics in Applied Earth Observations and Remote Sensing*, 2017, **10**(5), 2002-2011.

- [46] Asaari M. S. M., Suandi S. A., Bakhtiar A. R., Geometric feature extraction by FTAs for finger-based biometrics system, *IET Biometrics Journal*, 2016, **6**(3), 157-164.
- [47] Doulah U. S. M. B. A., Fattah S. A., Zhu W. P., Ahmad M. O., DCT domain feature extraction scheme based on motor unit action potential of EMG signal for neuromuscular disease classification, *The Journal of Healthcare Technology*, 2014, **1**(1), 26-31.
- [48] Jianhong W., Liyan Q., Yongqiang Y., YangQuan C., Fractional Envelope Analysis for Rolling Element Bearing Weak Fault Feature Extraction, *Ieee/Caa Journal of Automatica Sinica*, 2017, **4**(2), 353-360.
- [49] Xi P., Bo Z., Rui Y., Huajin T., Zhang Y., Bag of Events: An Efficient Probability-Based Feature Extraction Method for AER Image Sensors, *IEEE Transactions On Neural Networks And Learning Systems*, 2017, **28**(4), 791-803.
- [50] Dangdang D., Xianpei W., Jiachuan L., Meng T., Guowei Z., Jieming Z., Feature extraction of GIS partial discharge signal based on S-transform and singular value decomposition, *IET Journal of Science, Measurement & Technology*, 2017, **11**(2), 186-193.
- [51] Jasper H. H., Andrews H. L., Electro-encephalography III. normal differentiation of occipital and precentral regions, *The journal of Arch. Neurophysiolgy Psychiatry*, 1938, **39**(1), 96–115.
- [52] Walter W.G., Traps, tricks and triumphs in EEG, *The journal of Electroencephalography Clinical Neurophysiolgy*, 1936, **22**(4), 393–407.
- [53] Jasper H. H., Andrews H. L., Electro-encephalography III. normal differentiation of occipital and precentral regions, *The journal of Arch. Neurol. Psychiatry*, 1938, **39**(1), 96–115.
- [54] Sharbrough F., Chatrian G. E., Lesser R. P., Lüders H., Nuwer M., Picton T. W., American Electroencephalographic Society Guidelines for Standard Electrode Position, *Nomenclature Journal of Clinic Neurophysiolgy*, 1991, **8**(1), 200-210.
- [55] Kim D. I., Tae Y. C., Yoon S. H., Gyul L., Shin Y. J., Wavelet-Based Event Detection Method Using PMU Data, *IEEE Transactions on Smart Grid*, 2017, **8**(3), 1154-1161.
- [56] Robert S. K., Saurabh C., Efficient technique for rice grain classification using back-propagation neural network and wavelet decomposition, *IET Journal of Computer Vision*, 2016, **10**(8), 780-787.

- [57] Guang H., Heng L., Jixin L., Ning S., Kun D., Xiaofei L., Multi-band joint local sparse tracking via wavelet transforms, *IET Journal of Computer Vision*, 2016, **10**(8), 894-904.
- [58] Pfurtscheller G., Guger C., Ramoser H., EEG-based brain-computer interface using subject-specific spatial filters, *Journal of Engineering Applications of Bio-inspired Artificial Neural Networks*, 1999, **1607**(1), 248-254.
- [59] Jundong L., Huan L., Challenges of Feature Selection for Big Data Analytics, *IEEE Journal Of Intelligent Systems*, 2017, **17**(1), 9-15.
- [60] Aristos A., Athos A., Constantinos S. P., Privacy preserving data publishing of categorical data through k-anonymity and feature selection, *Journal of Healthcare Technology*, 2016, **3**(1), 16-21.
- [61] Sreevani A., Murthy C. A., Bridging Feature Selection and Extraction: Compound Feature Generation, *IEEE Transactions On Knowledge and Data Engineering*, 2017, **29**(4), 757-770.
- [62] Harold H., The consistency and ultimate distribution of optimum statistics, *Transactions on American Math Society*, 1931, **32**(1), 847-859.
- [63] Kirby M., Sirovich L., Application of the karhunen-lo`eve procedure for the characterization of human face, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, **12**(1), 103–108.
- [64] Holland J. H., *Adaptation in Natural and Artificial Systems*, 1st ed., MIT Press, Cambridge, 1975.
- [65] Bernard B. M., Hamid R. K., Kjell G. R., Optimization of Vehicle-to-Vehicle Frontal Crash Model Based on Measured Data Using Genetic Algorithm, *IEEE Transactions on Content Mining*, 2017, **5**(1), 1-8.
- [66] Tim M., Ludovic G., Franco R., A Parametric Genetic Algorithm Approach to Assess Complementary Options of Large Scale Wind-solar Coupling, *IEEE/CAA Journal of Automatica Sinica*, 2017, **4**(2), 260-272.
- [67] Yanan W., Xiuzhen C., Jianhua L., Wanyu H., A Genetic-Algorithm-Based Information Evolution Model for Social Networks, *Journal of Services and Applications*, 2016, **1**(1), 234-249.
- [68] Warren M., Walter H. P., A Logical Calculus of Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 1943, **5**(1), 115-133.
- [69] Marvin M., Seymour P., *Perceptrons: an introduction to computational geometry*, 1st ed., Prentice Hall, New Jersey, 1969.

- [70] Hopfield J. J., Neurons with graded response have collective computational properties like those of two-state neurons, *Journal of Biophysics*, 1984, **81**(1), 3088-3092.
- [71] Broomhead D. S., David L., Multivariable Functional Interpolation and Adaptive Networks, *Journal of Complex Systems*, 1988, **2**(1), 321-355.
- [72] Xinzhi L., Kexue Z., Xie W. C., Pinning Impulsive Synchronization of Reaction–Diffusion Neural Networks With Time-Varying Delays, *IEEE Transactions on Neural Networks and Learning Systems*, 2017, **28**(5), 1055-1067.
- [73] Bo S., Zidong W., Hong Q., Event-Triggered State Estimation for Discrete-Time Multidelayed Neural Networks With Stochastic Parameters and Incomplete Measurements, *IEEE Transactions on Neural Networks and Learning Systems*, 2017, **28**(5), 1152-1163.
- [74] Manel D., Mohamed A. H., Belgacem B., Abdellatif M., Cryptography of medical images based on a combination between chaotic and neural network, *IET Journal of Image Processing*, 2016, **10**(11), 830-839.
- [75] Hao Z., Huaicheng Y., Congzhi H., Mengling W., Guaranteed Cost Filtering for Discrete-time Multi-layer Neural Networks with Time-varying Delays and Unideal Measurements, *Proceedings of the IEEE International Conference on Information and Automation*, Ningbo, Çin, 12-15 Ağustos 2016.
- [76] Corinna C., Vladimir V., Support-Vector Networks, *Journal of Machine Learning*, 1995, **20**(1), 273-297.
- [77] Shiao H. T., Vladimir C., Jieun L., Brandon V., Edward E. P., Benjamin H. B., Gregory A. W., SVM-Based System for Prediction of Epileptic Seizures From iEEG Signal, *IEEE Transactions On Biomedical Engineering*, 2017, **64**(5), 1011-1022.
- [78] Yongqian L., Ying S., David I., Yu Z., Shuang H., Jie Y., A Hybrid Forecasting Method for Wind Power Ramp Based on Orthogonal Test and Support Vector Machine (OT-SVM), *IEEE Transactions On Sustainable Energy*, 2017, **8**(2), 451-457.
- [79] Dinesh S., Debaditya R., Krishna C. M., DiP-SVM : Distribution Preserving Kernel Support Vector Machine for Big Data, *IEEE Transactions on Big Data*, 2017, **3**(1), 79-90.
- [80] Chanika S., Jie C., Hongsheng Z., GA-SVM Algorithm for Improving Land-Cover Classification Using SAR and Optical Remote Sensing Data, *IEEE Geoscience And Remote Sensing Letters*, 2017, **14**(3), 284-288.

- [81] Sandeep R., Kailash C. R., ECG Signal Analysis Using DCT-Based DOST and PSO Optimized SVM, *IEEE Transactions on Instrumentation and Measurement*, 2017, **66**(3), 470-478.
- [82] Kuhn H. W., Tucker A. W., Nonlinear programming, *Proceedings of 2nd Berkeley Symposium*, Berkeley, California, ABD, 31 Temmuz-12 Ağustos 1950.
- [83] Karush W., Minima of Functions of Several Variables with Inequalities as Side Constraints, Yüksek Lisans Tezi, Chicago Üniversitesi, Matematik Bölümü, Chicago, Illinois, 1939.
- [84] Steve G., Support Vector Machines for Classification and Regression, *University of Southampton*, AIM-1606, 1-52, 1998.
- [85] James N. M., John A. S., Problems in the Analysis of Survey Data and a Proposal, *Journal of the American Statistical Association*, 1963, **58**(302), 415-434.
- [86] Leo B., Jerome F., Charles J. S., *Classification and Regression Trees*, 1st ed., Wadsworth & Brooks, California, 1984.
- [87] Paul V., Michael J. J., Robust Real-Time Face Detection, *International Journal of Computer Vision*, 2004, **57**(2), 137–154.
- [88] Richard O. D., Peter E. H., Use Of The Hough Transform To Detect Lines And Curves In Pictures, *Communication ACM Journal* , 1972, **15**(1), 11-15.
- [89] Dana H. B., Generalizing The Hough Transform To Detect Arbitrary Shapes, *Pattern Recognition Journal*, 1981, **13**(2), 111-122.
- [90] www.bbc.de/competition/iv/desc_2a.pdf (Ziyaret tarihi: 27 Mayıs 2015).
- [91] James N. M., John A. S., Problems in the Analysis of Survey Data and a Proposal, *Journal of the American Statistical Association*, 1963, **58**(302), 415-434.
- [92] Leo B., Jerome F., Charles J. S., *Classification and Regression Trees*, 3rd ed., Taylor & Francis, Abingdon, 1984
- [93] Paul V., Michael J. J., Robust Real-Time Face Detection, *International Journal of Computer Vision*, 2004, **57**(2), 137–154.

KİŞİSEL YAYIN VE ESERLER

- [1] **Gurkan K.**, Karakaya S., Ocak H., Omer S., Design and Implementation of a Multi Sensor Based Brain Computer Interface for a Robotic Wheelchair, *The journal of Intelligent and Robotic Systems*, 2017, **5**(1), 17-25.
- [2] **Gurkan K.**, Hasan O., Development and Optimization of DSP Based Real Time Lane Detection Algorithm on a Mobile Platform, *Turkish Journal of Electrical Engineering & Computer Sciences*, 2014, **22**(6),1484-1500.
- [3] Karakaya S., **Gurkan K.**, Ocak H., A New Mobile Robot Toolbox for MATLAB, *The journal of Intelligent and Robotic Systems*, 2017, **6**(1), 22-30.
- [4] Karakaya S., **Gurkan K.**, Ocak H., Point Stabilization Technique Using Model Predictive Control and Exact Euclidian Distance Transform Methods, *The Sigma Journal of Engineering and Natural Sciencesof*, 2017, **6**(1), 22-30.
- [5] Suat K., **Gurkan K.**, Hasan O., Zafer B., Obstacle and Optimal Heading Direction Detection Algorithm on a Mobile Robot Platform, *Signal Processing and Communications Applications Conference SIU 2012*, Fethiye, Türkiye, 1 – 4 Nisan 2012.
- [6] **Gurkan K.**, Hasan O., Mobil Robot Platformu Üzerinde Dsp Tabanlı Gerçek Zamanlı Şerit Tespiti Algoritmasının Geliştirilmesi ve Optimizasyonu, *Signal Processing and Communications Applications Conference SIU 2012*, Fethiye, Türkiye, 1 – 4 Nisan 2012.
- [7] Selcuk K., **Gurkan K.**, Hasan O., Zafer B., Görü Tabanlı Manyetik Süspansiyon Sistemi, *Signal Processing and Communications Applications Conference SIU 2012*, Fethiye, Türkiye, 1 – 4 Nisan 2012.
- [8] Orkun K., **Gurkan K.**, Suat K., Hasan O., Kamera ve Lazer Kullanılarak Lidar Sistemi Geliştirilmesi, *Otomatik Kontrol Ulusal Toplantısı-TOK2013*, Malatya, Türkiye, 1 – 4 Mayıs 2013.
- [9] İsmail Ö., **Gurkan K.**, Suat K., Hasan O., Kinect Tabanlı Robot Kolu Kontrolü, *Otomatik Kontrol Ulusal Toplantısı-TOK2013*, Malatya, Türkiye, 1 – 4 Mayıs 2013.

- [10] Suat K., **Gurkan K.**, Hasan O., Bulanık Mantık Hız Kontrolü Destekli Distance Transform Yol Planlama, *Otomatik Kontrol Ulusal Toplantısı-TOK2013*, Malatya, Türkiye, 1 – 4 Mayıs 2013.
- [11] Suat K., **Gurkan K.**, Hasan O., Image Processing Based Low Cost Range Finder, *International Conference Mechanika*, Kaunas, Litvanya, 1 – 4 Haziran 2013.
- [12] Suat K., **Gurkan K.**, Can T., Hasan O., Image Processing Based Low Cost Range Finder, *IEEE Conference of Mechatronika*, Brno, Çek Cumhuriyeti, 21 – 24 Eylül 2014.
- [13] Suat K., **Gurkan K.**, Hasan O., Kinematic Model Based Path Tracking Algorithm For Differential Drive Mobile Robots, *Signal Processing and Communications Applications Conference SIU 2014*, Trabzon, Türkiye, 19 – 22 Mayıs 2014.
- [14] Orkun K., **Gurkan K.**, Suat K., Hasan O., Image Processing Based Indoor Localization System, *Signal Processing and Communications Applications Conference SIU 2014*, Trabzon, Türkiye, 19 – 22 Mayıs 2014.
- [15] Ocak H., Murat A., **Gurkan K.**, Suat K., Hasan O., Image Processing Based Package Volume Detection with Kinect Sensor, *Signal Processing and Communications Applications Conference SIU 2015*, Malatya, Türkiye, 19 – 22 Mayıs 2015.
- [16] **Gurkan K.**, Suat K., Hasan O., Real Time Control of a Wheel Chair based on EMG and Kinect for the Disabled People, *Tip Teknolojileri Ulusal Kongresi*, Muğla, Türkiye, 22 – 24 Temmuz 2015.
- [17] Suat K., Hasan O., **Gurkan K.**, Orkun K., A Hybrid Indoor Localization System Based on Infra-red Imaging and Odometry, *International Conference on Image Processing, Computer Vision, & Pattern Recognition*, Vegas, USA, 25 – 27 Ağustos 2015.
- [18] **Gurkan K.**, Suat K., Hasan O., Omer S., Brain-Computer Interface with Low Cost Commercial EEG Device, *3. International Symposium on Innovative Technologies in Engineering and Science*, Valensiya, İspanya, 22 – 24 Eylül 2015.
- [19] Suat K., **Gurkan K.**, Hasan O., A Bug-Based Local Path Planning Method for Static and Dynamic Environments, *3. International Symposium on Innovative Technologies in Engineering and Science*, Valensiya, İspanya, 22 – 24 Eylül 2015.
- [20] Suat K., **Gurkan K.**, Hasan O., A Hybrid Posture Stabilization Method for Mobile Robots, *International Congress on Academic Researches INES2016*, Antalya, Türkiye, 22 – 25 Nisan 2016.

- [21] Suat K., **Gurkan K.**, Hasan O., Speed Control Adaptation on Static Trajectories, *International Congress on Academic Researches INES2016*, Antalya, Türkiye, 22 – 25 Nisan 2016.
- [22] Suat K., **Gurkan K.**, Hasan O., Detection of Obstacle-Free Gaps for Mobile Robot Applications Using 2-D LIDAR Data, *International Congress on Natural and Engineering Sciences, ICNES2016*, Üsküp, Makedonya, 24 – 26 Eylül 2016.
- [23] Suat K., **Gurkan K.**, Hasan O., A Hybrid Posture Stabilization Method for Mobile Robots, *International Congress on Academic Researches INES2016*, Antalya, Türkiye, 22 – 25 Nisan 2016.



ÖZGEÇMİŞ

Eylül 1986'da Beşikdüzü/Trabzon'da doğmuştur. 1998 yılında ilkokulu Uşak Mehmetçik İlköğretim Okulu'nda ve ortaokul ve lise öğrenimini ise, Uşak - Orhan Deniz Anadolu Lisesi'nde 2004 yılında tamamlamıştır. 2004 yılında girdiği ÖSS sınavında Kocaeli Üniversitesi Elektronik ve Haberleşme Mühendisliği bölümünü kazanmıştır ve 2008 yılında Elektronik Mühendisi olarak mezun olmuştur. 2009 yılı Haziran ayında, Uşak Üniversitesi Mühendislik Fakültesi Elektronik Mühendisliği Bölümü'nde araştırma görevlisi olarak göreve başlamıştır ve halen görevine devam etmektedir. 2011 yılı Şubat ayında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim Dalı'nda Doktora eğitimine başlamıştır.

