



İSKENDERUN TEKNİK
ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**TAŞINABİLİR EEG
CİHAZI TASARIMI VE
UYGULAMALARI**

Enver Kaan ALPTÜRK

**BİLGİSAYAR MÜHENDİSLİĞİ
ANABİLİM DALI**

ARALIK 2022



TAŞINABİLİR EEG CİHAZI TASARIMI VE UYGULAMALARI

Enver Kaan ALPTÜRK

YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ARALIK 2022

Enver Kaan ALPTÜRK tarafından hazırlanan “TAŞINABİLİR EEG CİHAZI TASARIMI VE UYGULAMALARI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Yakup KUTLU

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....
...

Başkan: Doç. Dr. Sertan ALKAN

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....
...

Üye: Dr. Öğr. Üye. Mustafa YENİAD

Bilgisayar Mühendisliği Anabilim Dalı, Ankara Yıldırım Beyazıt Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

.....
.....
...

Tez Savunma

Tarihi: 22/12/2022

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....

Doç. Dr. Ersin BAHÇECİ

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
 - Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
 - Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
 - Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
 - Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
 - Bu tezde sunduğum çalışmanın özgün olduğunu,
- bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Enver Kaan ALPTÜRK

...../...../.....

TAŞINABİLİR EEG CİHAZI TASARIMI VE UYGULAMALARI
(Yüksek Lisans Tezi)

Enver Kaan ALPTÜRK

İSKENDERUN TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

Aralık 2022

ÖZET

Elektroensefalografi (EEG) sinyalleri, kafatasına yerleştirilen elektrotlar vasıtasıyla beyinden alınan küçük genlikli ve düşük frekanslı elektriksel sinyallerdir. EEG sinyalleri dış etmenlerden kolaylıkla etkilenebilmektedir. Bu nedenle incelenmeleri sırasında çeşitli önlemlerden geçirilmeleri gerekmektedir. EEG sinyalleri beyin yapısı ve düşünce biçimleri hakkında bilgi edinmek amacıyla sıklıkla kullanılmaktadır. Çevresel etkilere, kalıtsal veya sonradan oluşan rahatsızlıklara göre değişen EEG sinyallerinin incelenmesi sonucu bazı kestirimler ve tespitler yapılması söz konusudur.

Bu tez kapsamında, EEG sinyallerinin toplanması, donanımsal olarak işlenmesi, kaydedilmesi, yazılımsal olarak işlenmesi ve sınıflandırılması ile ilgili bir dizi çalışma gerçekleştirilmiştir. EEG sinyallerinin toplanması için gerekli donanımsal ekipmanlar hakkında araştırmalar yapılmış ve bu araştırmalar sonucunda bir enstrümantasyon yükseltici tasarlanmıştır. Üretilen yükseltici ile piyasada bulunan benzer nitelikli yükselticiler ve tam donanımlı EEG kayıt cihazlarından bazıları karşılaştırılmıştır. Çalışmalar sonunda taşınabilir bir EEG kayıt cihazı tasarlanmıştır.

Tasarlanan cihaz, gümüş/gümüş klorür ($Ag/AgCl$) barındıran tek kullanımlık (disposable) elektrotlar ile sinyalleri enstrümantasyon yükselticiye iletmektedir ve burada yapılan bir dizi donanımsal işlemde sonra bir kablolu verici vasıtasıyla bilgisayara göndermektedir. Tasarlanan donanım için geliştirilen masaüstü uygulama sinyalleri alıp yazılımsal işlemlerden geçirmektedir ve bazı yüz mimiklerinin sınıflandırmasını gerçekleştirmektedir. Birkaç sınıflandırma yöntemi toplanan sinyaller üzerinde test edilmiştir ve karşılaştırma sonuçlarında en verimli algoritma uygulamaya eklenmiştir.

Anahtar Kelimeler : Elektroensefalografi (EEG), enstrümantasyon yükseltici, DVM, KNN, ÇKA, FFT
Sayfa Adedi : 51
Danışman : Doç. Dr. Yakup KUTLU

PORTABLE EEG DEVICE DESIGN AND APPLICATIONS

(M. Sc. Thesis)

Enver Kaan ALPTÜRK

ISKENDERUN TECHNICAL UNIVERSITY

INSTITUTE OF GRADUATE STUDIES

December 2022

ABSTRACT

Electroencephalography (EEG) signals are small amplitude and low frequency electrical signals received from the brain through electrodes placed on the skull. EEG signals can be easily affected by external factors. For this reason, they must be subjected to various pre-processes during their examination. EEG signals are frequently used to obtain information about brain structure and thought patterns. It is possible to make some predictions and determinations as a result of examining the EEG signals that change according to environmental effects, hereditary or subsequent disorders.

Within the scope of this thesis, a series of studies have been carried out on the collection, hardware processing, recording, software processing and classification of EEG signals. Research has been done on the hardware equipment required for the collection of EEG signals and an instrumentation amplifier has been designed as a result of these researches. The produced amplifier and some of the similar quality amplifiers and fully equipped EEG recorders available in the market were compared. At the end of the studies, a portable EEG recorder was designed.

The designed device transmits the signals to the instrumentation amplifier with disposable electrodes containing silver/silver chloride (Ag/AgCl), and sends them to the computer via a wireless transmitter after a series of hardware processes. The desktop application developed for the designed hardware receives the signals and processes them in software, and performs the classification of some facial expressions. Several classification methods have been tested on the collected signals and the most efficient algorithm in the comparison results has been added to the application.

Key Words : Electroencephalography (EEG), instrumentation amplifier, SVM, KNN, MLP, FFT

Page Number : 51

Supervisor : Assoc. Prof. Dr. Yakup KUTLU

TEŞEKKÜR

Bu tez çalışmasının yürütülmesi sırasında benden desteklerini hiçbir zaman esirgemeyen sevgili annem Solmaz ALPTÜRK, sevgili babam Hasan ALPTÜRK ve sevgili kardeşim Okan ALPTÜRK'e sonsuz teşekkürlerimi sunuyorum.

Yüksek lisans sürecimin başından sonuna kadar her anında manevi desteğini hissettiğim ve beni hiçbir zaman yalnız bırakmayan can yoldaşım sevgili Selya AÇIKEL'e gönülden teşekkür ediyorum.

Tezimin araştırma safhalarında yanlarına bulunduğum ve benden hiçbir yardımı esirgemeyen sevgili María Violeta ROMEO, Ettore Bruni VIOLETA, Carmen ROMEO ve Jesus VIOLETA'ya pandemi sırasında evimde hissetmemi sağladıkları ve güzel bir çalışma ortamı sağladıkları için teşekkür ediyorum (Quisiera agradecer a María Violeta Romeo, Ettore Bruni Violeta, Carmen Romeo y Jesus Violeta quienes estuvieron conmigo en la fase de Investigación de mi tesis y no escatimaron en ayudarme en todo momento, por hacerme sentirme como en casa durante la pandemia y proporcionandome un ambiente de trabajo agradable.).

Veri toplama ve analiz etme aşamalarımda bana her zaman destek olan ve çalışmalarım için gönüllü olmayı kabul eden sevgili Zeynep SAYDAM'a emekleri için sonsuz teşekkürlerimi sunuyorum.

Akademik alanda benden yardımlarını hiçbir zaman esirgemeyen başta danışmanım Doç. Dr. Yakup KUTLU olmak üzere bölümümüzün kıymetli akademisyenleri Doç. Dr. Sertan ALKAN, Dr. Öğr. Üyesi Ahmet GÖKÇEN ve Doç. Dr. İpek Abasıkeleş TURGUT'a teşekkür ediyorum.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ	x
SİMGELER VE KISALTMALAR.....	xii
1. GİRİŞ.....	1
2. MATERYAL VE YÖNTEMLER.....	14
2.1 AD620 Enstrümantasyon Yükseltici.....	14
2.2 AD8232 Enstrümantasyon Yükseltici.....	14
2.3 ESP 8266-12E Kablosuz Haberleşme Modülü	15
2.4 ESP-01 Kablosuz Haberleşme Modülü.....	16
2.5 RC Alçak Geçiren Filtre.....	17
2.6 Tek Kullanımlık Gümüş Klorür Elektrotlar	19
2.7 K En Yakın Komşu Algoritması	19
2.8 Destek Vektör Makineleri (DVM)	20
2.8.1 Doğrusal Ayrılabilen Sınıflar için DVM.....	20
2.8.2 Doğrusal Ayrılamayan Sınıflar için DVM.....	21
2.8.3 Çok Sınıflı Veriler için DVM	22
2.9 Çok Katmanlı Algılayıcı (ÇKA)	23
2.10 Hızlı Fourier Dönüşümü (FFT).....	24
2.11 Korelasyon Bazlı Öznitelik Seçimi	25
2.12 Yöntem	26

2.12.1 Öznitelik Çıkarımı.....	34
3. BULGULAR	36
4. SONUÇ VE ÖNERİLER.....	41
KAYNAKLAR	46



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 1.1. EEG sinyallerinin frekans aralıklarına göre incelenmesi.	2
Çizelge 2.1. Pearson korelasyon katsayılarına bağlı ilişki gücü.....	25
Çizelge 2.2. Korelasyon bazlı öznelik seçimi tablosu.	35
Çizelge 3.1. Sınıflandırma algoritmalarının nihai başarımlarının karşılaştırılması..	39



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Beynin lobları.	1
Şekil 1.2. Delta dalgaları.....	2
Şekil 1.3. Teta dalgaları.	3
Şekil 1.4. Alfa dalgaları.	3
Şekil 1.5. Beta dalgaları.	3
Şekil 1.6. Gama dalgaları.....	4
Şekil 1.7. Polarize olan (tersinmez) elektrot.....	4
Şekil 1.8. Polarize olmayan (tersinir) elektrot.	5
Şekil 1.9. Filtreleme yöntemlerinin grafikleri.....	6
Şekil 1.10. 10 – 10 elektrot sisteminin 128 elektrotlu olacak şekilde genişletilmesi ile oluşturulan 10 – 5 modeli.	7
Şekil 1.11 10 – 5 EEG elektrot modelinin gerçek pozisyonu.	8
Şekil 2.1. AD620 enstrümantasyon yükseltici entegre şeması.	14
Şekil 2.2. AD8232 entegre devre şeması.	15
Şekil 2.3. ESP 8266-12E kablosuz haberleşme modülü.....	16
Şekil 2.4. ESP-01 kablosuz haberleşme modülü.	17
Şekil 2.5. Birinci derece pasif alçak geçiren filtre şeması.	17
Şekil 2.6. Filtrelemede dereceye bağlı sinyal geçişi Bode büyüklüğü ve Bode fazı grafikleri.....	18
Şekil 2.7. Katman sayısına bağlı olarak kesme frekansının keskinliğinin değişimi.....	18
Şekil 2.8. Tek kullanımlık elektrotlar.	19
Şekil 2.9. K=5 için KNN sınıflandırıcısı.	20
Şekil 2.10. DVM ile elde edilen hiper düzlemler ve destek vektörleri.....	21
Şekil 2.11. Kernel fonksiyonlarıyla yüksek boyutlu uzayda hiper düzlemin belirlenmesi.	22
Şekil 2.12. Dört katmanlı ÇKA yapısı.	24
Şekil 2.13. RC pasif alçak geçiren filtre şeması üzerinde devre elemanlarının gösterimi.	27

Şekil 2.14. Uygulanan RC alçak geçiren filtrenin Bode grafiği.	27
Şekil 2.15. RC alçak geçiren filtreden önce elde edilen sinüs sinyali.	28
Şekil 2.16. RC alçak geçiren filtreden sonra elde edilen sinüs sinyali.	28
Şekil 2.17. AD620 kullanılarak tasarlanan devre.	29
Şekil 2.18. AD8232 kullanılarak tasarlanan devre.	29
Şekil 2.19. AD620 ve AD8232 ile göz kırpma sırasında kaydedilen EEG sinyalleri. ...	30
Şekil 2.20. AD620 ve AD8232 ile göz kırpma sırasında kaydedilen EEG sinyallerinin FFT analizi.	31
Şekil 2.21. Tasarlanan sistemin genel devre şeması.	32
Şekil 2.22. Yazılımsal filtreleme işleminden geçirilmeyen EEG sinyalinin grafiği.	33
Şekil 2.23. Yazılımsal filtreleme işleminden geçirilen EEG sinyalinin grafiği.	33
Şekil 2.24. EEG sinyallerine uygulanan yazılımsal işlemler.	35
Şekil 3.1. İşlenmemiş EEG verilerinin sınıflandırma sonuçları.	36
Şekil 3.2. İşlenmemiş verilerde korelasyon bazlı sınıflandırma sonuçları.	37
Şekil 3.3. Filtrelenmiş EEG verilerinin FFT uygulanarak özniteliklerinin çıkarılması ile yapılan sınıflandırma sonuçları.	37
Şekil 3.4. İşlenmiş EEG verilerinin özniteliklerinin korelasyon bazlı öznitelik seçim algoritması ile seçilen güçlü özniteliklerinin sınıflandırma sonuçları.	38
Şekil 3.5. Emotiv Epoc+ ve tasarlanan EEG kayıt cihazı ile yumruk sıkma hareketi sırasında kaydedilen sinyallerin zaman eksenindeki karşılaştırması.	39
Şekil 3.6. Emotiv Epoc+ ve tasarlanan EEG kayıt cihazı ile yumruk sıkma hareketi sırasında kaydedilen sinyallerin FFT'si alınarak frekans eksenindeki karşılaştırması. ...	40
Şekil 4.1. Tasarlanan cihazın 3 boyutlu modeli.	41
Şekil 4.2. ESP-01 kullanılarak tasarlanan kablosuz alıcı modül.	41
Şekil 4.3. Tasarlanan cihazın ve uygulamanın tüm aşamalarını gösteren diyagram.	42
Şekil 4.4. Taşınabilir EEG kayıt cihazı için tasarlanan kullanıcı arayüzü.	43
Şekil 4.5. Stabil ve gözler açık durumdayken mimik analizi.	44
Şekil 4.6. Dinlenme modunda ve gözler kapalı durumdayken mimik analizi.	44
Şekil 4.7. Gülme eylemi gerçekleştirilirken mimik analizi.	45

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

Hz	Hertz
KHz	Kilohertz
MHz	Megahertz
Ω	Ohm
Ag/AgCl	Gümüş/gümüş klorür
Zn/ZnSO₄	Çinko/çinko sülfat
μV	Mikrovolt
mV	Milivolt
dB	Desibel

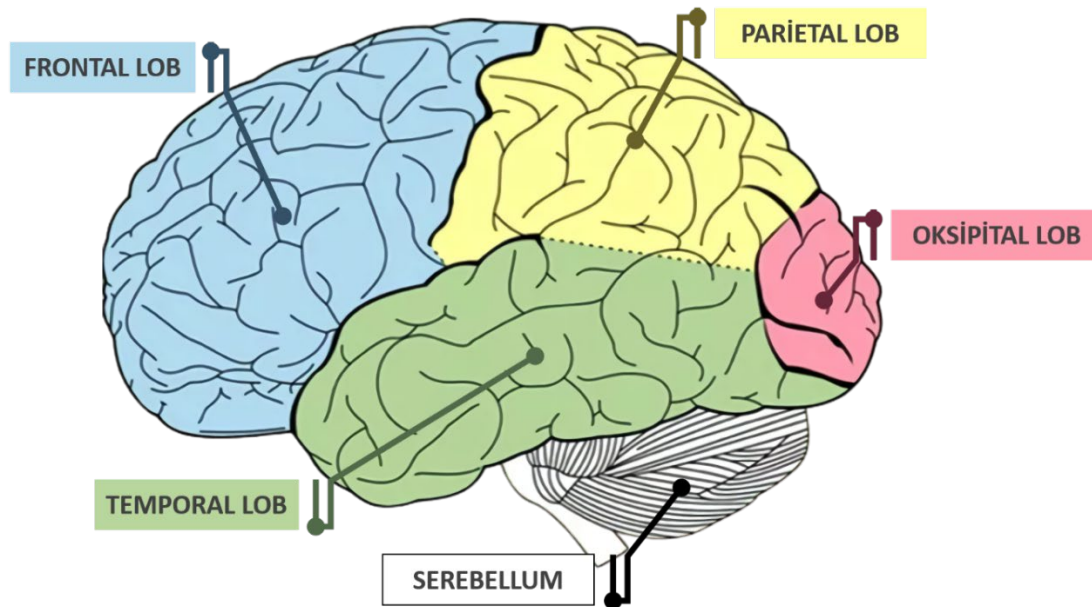
Kısaltmalar

Açıklamalar

EEG	Elektroensefalografi
YSA	Yapay Sinir Ağları
DVM	Destek Vektör Makineleri
ÇKA	Çok Katmanlı Algılayıcılar
FFT	Hızlı Fourier Dönüşümü

1. GİRİŞ

Beyin duygu ve düşünceleri, vücutta bulunan tüm sinirleri ve kasları kontrol eden merkezi yönetim görevindeki organdır. Beyin sol ve sağ yarım küre olarak bilinen iki bölüme ayrılmıştır. Her iki yarım küre de frontal, parietal, temporal ve oksipital olmak üzere dört lobdan oluşmaktadır (Chiron, ve diğerleri, 1997). Frontal lob beynin en büyük lobudur. Alnın arkasında bulunur ve planlama, problem çözme dürtü kontrolü, karar verme, dikkat, duygu kontrolü ve motor hareketlerinin kontrolü gibi işlevlerin yönetilmesini sağlar. Parietal lob frontal lobun arkasında bulunur ve vücudun farklı bölgelerinden gelen duyu bilgilerin işlendiği yerdir. Bu bölgenin hasar görmesi durumunda vücudun bölümlerini tanıyamama ve tespit edememe gibi sorunlarla karşılaşılabilir. Oksipital lob beynin en arka bölgesindedir. Görsel bilginin işlendiği ve diğer algılarla ilişkilendirildiği bölümdür. Bu lobda meydana gelecek hasarlar sonucunda görme bozuklukları ve algıda güçlük sorunları ortaya çıkabilmektedir. Temporal lob frontal ve parietal lobların altında bulunmaktadır. Beynin hafıza, ses ve konuşma işlevlerinden sorumlu bölümüdür. Bu bölgede oluşabilecek hasarlar sonucunda işitme, konuşma ve bazı duyu bozuklukları meydana gelebilmektedir (Kumar & Bhuvanewari, 2012). Beynin sol yarım küresinde bulunan loblar Şekil 1.1’de gösterilmiştir.



Şekil 1.1. Beynin lobları.

Elektroensefalografi (EEG)


EEG, beyin nöronlarının haberleşmeleri sırasında ortaya çıkan küçük genlikli ve düşük

frekanslı elektrik sinyallerinin ölçümü için kullanılan yöntemdir. Türkçe'ye beyin çizgesi yöntemi olarak çevrilen yöntem, kafatasına yerleştirilen elektrotlar vasıtasıyla elde edilen elektriksel sinyallerin bilgisayar ortamına aktarılması ve incelenmesini içermektedir. EEG, 1929 yılında psikolojik tanı koyma amacı ile Hans Berger tarafından bulunmuştur (Tudor, Tudor, & Tudor, 2005). Hans Berger, alfa dalgaları olarak adlandırılan frekans aralığının da mucidi olarak bilinmektedir. Bu nedenle alfa dalgaları Berger dalgaları olarak da adlandırılmaktadır (İnce, Adanır, & Sevmez, 2021). EEG sinyalleri temel olarak 0,5 Hz ile 100 Hz arasındaki 5 ana frekans grubunda incelenmektedir. Bu frekans aralıkları Çizelge 1.1'de gösterilmiştir.

Çizelge 1.1. EEG sinyallerinin frekans aralıklarına göre incelenmesi.

Tür	Frekans Aralığı (Hz)
Delta	0.5 Hz – 3,5 Hz
Teta	4 Hz – 7 Hz
Alfa	8 Hz – 12 Hz
Beta	13 Hz – 30 Hz
Gama	30+ Hz


- *Delta*: Delta dalgaları ilk olarak W. Grey Walter tarafından 1936 yılında tanımlanmıştır (Walter W. , 1936). 0,5 Hz ile 3,5 Hz arasındaki frekans bandında bulunurlar ve en yüksek genliğe sahip EEG sinyalleridir. Genellikle yetişkinlerde derin uyku halinde görülmektedir (Kumar & Bhuvanewari, 2012). Şekil 1.2'de delta dalgalarına örnek bir grafik gösterilmiştir (Gamboa, 2005).



Şekil 1.2. Delta dalgaları.


- *Teta*: Teta dalgaları 1944 yılında ilk kez W. Grey Walter ve V. J. Dovey tarafından terim olarak kullanılmıştır (Walter & Dovey, 1944). 4 Hz ile 7 Hz arasındaki frekans bandında bulunan EEG sinyalleridir. İnsanlarda REM uykusu sırasında sıklıkla görülmektedir. Ayrıca meditasyonun teta dalgalarının yoğunluğunu arttırdığı Lee ve diğerleri (2018) tarafından yapılan çalışmada gösterilmiştir. Şekil 1.3'te teta dalgalarına örnek bir grafik

gösterilmiştir (Gamboa, 2005).




Şekil 1.3. Teta dalgaları.

- *Alfa*: Berger dalgaları olarak da bilinen alfa frekans aralığı Hans Berger tarafından tanımlanmıştır ve 8 Hz ile 12 Hz aralığında bulunmaktadır. İnsanlarda dinlenme sırasında gözlerin kapalı olduğu durumlarda daha çok gözlemlenmektedir (Tülay, 2009). Şekil 1.4'te alfa dalgalarına örnek bir grafik gösterilmiştir (Gamboa, 2005).




Şekil 1.4. Alfa dalgaları.

- *Beta*: Beta dalgaları, belirli motor hareketlerinin tetiklenmesi durumunda ortaya çıkan, beynin ön (frontal) lobundaki aktivitelerin oluşturduğu sinyallerde görülmektedir (Pfurtscheller, Stancfık Jr., & Neuper, 1996). 13 Hz ile 30 Hz arasındaki frekans bandı beta dalgaları olarak adlandırılmaktadır. Şekil 1.5'te beta dalgalarına örnek bir grafik gösterilmiştir (Gamboa, 2005).




Şekil 1.5. Beta dalgaları.

- *Gama*: Gama dalgaları 30 Hz üzeri EEG sinyallerini temsil eder. Gama dalgaları hiper uyanıklık sırasında duygusal aktivitelerin yoğunlaştığı anlarda elde edilir. Analog EEG cihazları 25 Hz üzerini kaydedemedikleri için gama dalgaları dijital EEG cihazları üretildikten sonra kaydedilmeye ve incelenmeye başlanmıştır (Kumar & Bhuvaneshwari, 2012). Şekil 1.6'da gama dalgalarına örnek bir grafik gösterilmiştir (Gamboa, 2005).

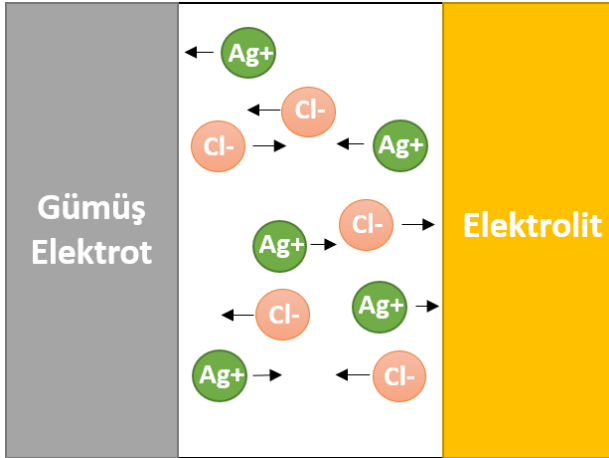


Şekil 1.6. Gama dalgaları.

EEG sinyalleri bazı özel elektrotlar vasıtasıyla toplanmaktadır. Genellikle biyolojik sinyallerin toplanmasında polarize olmayan (tersinir) elektrotlar tercih edilmektedir. Polarize olan (tersinmez) elektrotlarda (Şekil 1.7) akımın geçebilmesi için yüksek potansiyel farklar gereklidir. Polarize olmayan elektrotlarda (Şekil 1.8) elektrot-elektrolit ayırım bölgesinde akım çift yönlü ve serbest şekilde hiçbir enerjiye ihtiyaç duymadan geçebilir. Gümüş/gümüş klorür (Ag/AgCl) ve çinko/çinko sülfat (Zn/ZnSO_4) elektrotlar tersinir elektrotlar arasında en yaygın kullanılanlarıdır. Tek kullanımlık (disposable) elektrotlar tersinir elektrotlara örnektir (Elektrotlar, 2011).



Şekil 1.7. Polarize olan (tersinmez) elektrot.

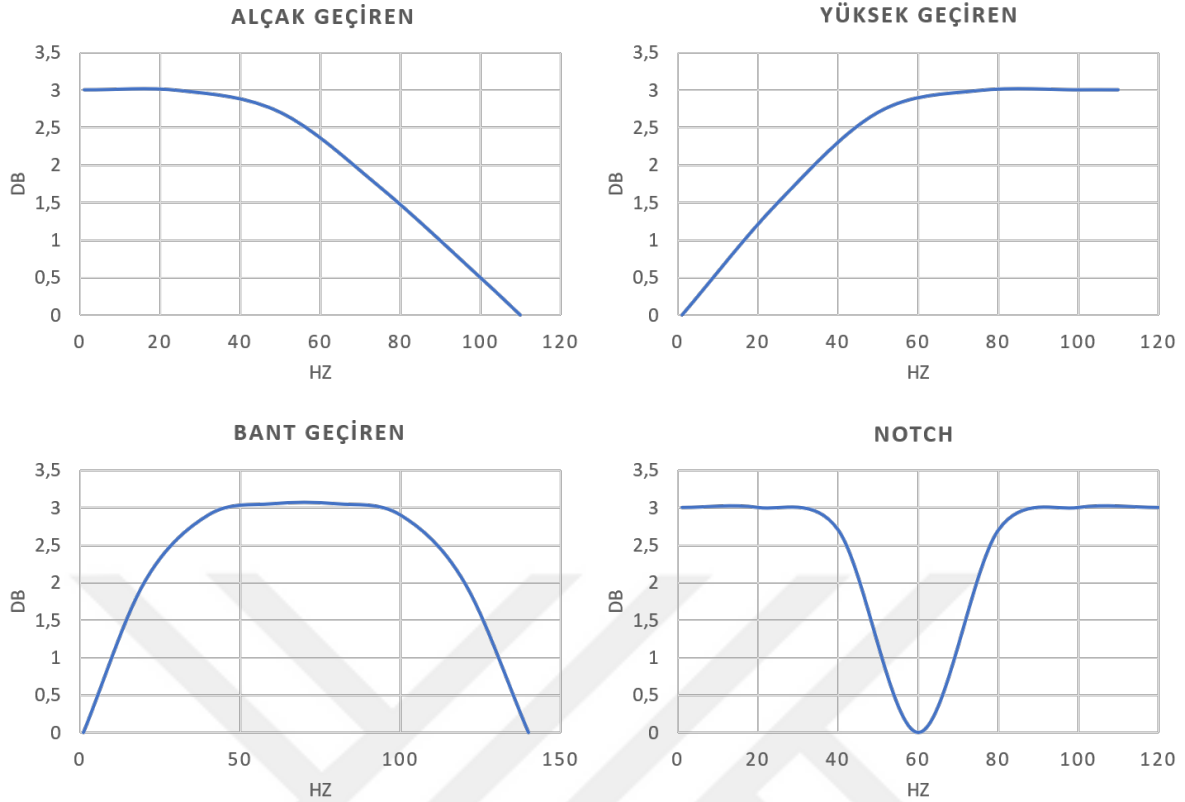


Şekil 1.8. Polarize olmayan (tersinir) elektrot.

EEG sinyalleri düşük frekanslıdır ve çevredeki bazı etmenlerden kolayca etkilenmektedir. Çevre etkisiyle sinyallerde oluşan bozulmalar gürültü olarak adlandırılmaktadır. Elektrotların uzun kablolar ile kullanıldığı durumlarda kablo hareketleri, elektrotların takıldığı bireyin yoğun kas aktiviteleri, çevredeki cihazlarda oluşan elektriksel dalgalanmalar, yüksek ses gibi etkiler sinyal kalitesini olumsuz yönde etkilemektedir. Bu nedenle sinyaller kullanılmadan önce bir dizi ön işlemden geçirilmelidir.

Ön işlemler donanımsal veya yazılımsal olarak gerçekleştirilebilir. Ön işlemler filtreleme ve yükseltme olmak üzere temelde iki aşamadan oluşmaktadır. Sinyallerin üzerinde oluşan gürültünün temizlenebilmesi için yüksek geçiren (high-pass), alçak geçiren (low-pass), bant geçiren (bandpass) ve notch filtre gibi filtreleme yöntemleri kullanılmaktadır. Bu filtreler belirlenen frekans aralıklarındaki sinyalin geçişine izin vererek gürültü olarak adlandırılan verileri engellemektedir. Şekil 1.9’da filtreleme işlemlerinin örnek grafikleri gösterilmiştir.

Alçak geçiren filtre, belirlenen frekans seviyesinin altındaki frekans değerine sahip olan verilerin geçişine izin vermektedir. Yüksek geçiren filtre, alçak geçiren filtrenin tam tersi niteliğindedir ve belirlenen frekans seviyesinin üzerindeki verilerin geçişine izin vermektedir. Bant geçiren filtre, alçak geçiren ve yüksek geçiren filtrelerin birleşimiyle belirli bir aralığın geçişine izine vermektedir. Notch filtre ise bant geçiren filtrenin tersi şeklinde çalışmaktadır. Genellikle şehir hatlarındaki gerilimden kaynaklanan gürültülerin engellenmesinde kullanılmaktadır.




Şekil 1.9. Filtreleme yöntemlerinin grafikleri.

Aynı tür filtrelerin birbiri ardına kullanılmaları sırasında yapılan her bir filtreleme işlemine katman adı verilmektedir. Katman sayısı arttıkça eşik filtreleme daha da keskinleşecektir. Şekil 1.9’da görüldüğü gibi filtreleme keskin bir şekilde yapılmamaktadır. Filtre çıkışında, belirlenen eşik değerinin üzerinde veya altında olan değerler de bulunmaktadır. Keskinliğin oluşması katman sayısının artırılması ile sağlanabilmektedir.


EEG sinyallerinin genlikleri genellikle $100 \mu V$ seviyesinden daha küçük olduğu için ve filtreleme işlemlerinden sonra da kayıplar meydana gelebileceği için bir de yükseltme aşamasından geçirilmeleri gerekmektedir. Genlik düzeyini μV seviyesinden mV seviyesine veya daha yüksek seviyelere çıkarılması işlemi yükseltme aşamasıdır. Yükseltme aşaması da tıpkı filtreleme gibi donanım ve yazılım katmanlarında gerçekleştirilebilir. Donanım katmanında gerçekleştirilen yükseltme için genellikle op-amplar yani işlemsel yükselteçler (operational amplifier) kullanılmaktadır. Üç op-amplı yükseltici devreler ise enstrümantasyon yükseltici (instrumentation amplifier) devreler olarak adlandırılmaktadır. Enstrümantasyon yükseltici devreler negatif geri beslemeye sahiptir. Bu özellik devre kazancını daha kararlı hale getirmektedir. Kazanç; bir devrenin çıkış geriliminin giriş gerilimine oranıdır (Biyopotansiyel Yükselteçler, 2012).

EEG kayıt sistemleri filtreleme ve yükseltme parametrelerini içinde barındırır. NeuroSky, Emotiv, OpenBCI, Nihon Kohden gibi firmalar EEG kayıt cihazları üretiminde önde gelen firmalardır. Piyasadaki EEG kayıt cihazları tek elektrotlulardan 256 elektrotlulara kadar çeşitli modellerde üretilmektedir. Uygulama alanına göre elektrot sayısı gereksinimi de değişmektedir. Şekil 1.10'da 10 – 10 EEG elektrot sistemi olarak bilinen şemanın 2001 yılında Robert Oostenveld ve Peter Praamstra tarafından 128 elektrotlu olacak şekilde genişletilmesi ile oluşturulan 10 – 5 modeli olarak adlandırdıkları EEG elektrot sistemi gösterilmiştir. Siyah ve gri dairelerle gösterilen elektrotlar 10 – 10 modelinde bulunan elektrotları temsil etmektedir. Beyaz daireler ise önerilen genişletmeyi göstermektedir (Oostenveld & Praamstra, 2001).



Şekil 1.10. 10 – 10 elektrot sisteminin 128 elektrotlu olacak şekilde genişletilmesi ile oluşturulan 10 – 5 modeli.

Şekil 1.11’de 10 – 5 EEG elektrot modelinin önerdiği elektrot diziliminin insan kafası üzerindeki gerçekçi pozisyonları gösterilmiştir (Oostenveld & Praamstra, 2001).



Şekil 1.11 10 – 5 EEG elektrot modelinin gerçek pozisyonu.

EEG sinyalleri beyin aktivitelerinin analizinde, bazı psikolojik, sinirsel ve zihinsel hastalıkların tespitinde, motor hareketlerinin kontrolüne dair çalışmalarda ve bazı eğlence uygulamalarında sıkça kullanılmaktadır.

Geçmiş çalışmalar

1997 yılında Schloegl ve diğerleri tarafından yapılan çalışmada, Nihon Khoden EEG cihazı ile 2 denekten C3 ve C4 kanallarından sağ ve sol el hareketlerinin hayalleri esnasında alınan 8 saniyelik sinyaller incelenmiştir. Adaptif otoresif (AAR) isimli bir yöntem önerilmiştir. Olay bağımlı desenkronizasyon ve olay bağımlı senkronizasyon yöntemlerine dayanan bu model temelde EEG sinyallerinin dalga tabanlı incelenmesidir. Önerilen yöntem olay bağımlı desenkronizasyon ve olay bağımlı senkronizasyon yöntemlerinin hata oranını düşürmüştür. Minimum hata oranı, birinci gönüllüde %15,6 ve ikinci gönüllüde %5,8 olarak ölçülmüştür (Schloegl, Neuper, & Pfurtscheller, 1997).

2012 yılında Jaime F. Delgado Saa ve Mujdat Çetin, C3, C4 ve CZ kanallarından sinyaller toplayarak Gizli Koşullu Rastgele Alanlar (HCRFs) isminde bir model önermiştir. Model, farklı beyin durumlarını sinyallerle modellemek için kullanılabilen gizli değişkenler içermektedir. Toplamda 9 denekten sinyaller alınmıştır. Sol ve sağ ellerin hareketlerinin hayalini temel almışlardır. Filtreleme için ortak mekânsal desen (CSP – Common Spatial Pattern) ve öznitelik çıkarımı için zaman-frekans analizi yöntemleri kullanılmıştır. Motor hareketlerinin hayallerinin sınıflandırılması için önerilen yöntemin sağ ve sol elin ayırımında kullanılabilmesi ve alfa-beta-sigma ve düşük gama dalgaları üzerindeki zamansal tepkimelerin üzerinde etkileri olduğu sonucuna varılmıştır (Delgado Saa & Çetin, 2012).

Bo Luan ve diğerleri 2012 yılında EEG sinyallerini cilt vidalı elektrotlar kullandıkları bir EEG kayıt devresi tasarlamışlardır. Birinci kademe yükselteç olarak INA118 ve işlemsel yükselteç olarak TLC277CP kullanılmıştır. Potansiyometre vasıtasıyla elde edilen sinyaller 5,76 ile 101 kat arasında artırılmıştır. 0.1 Hz ila 50 Hz arasında bir geçiş bandı sağlandığı ve yükseltici düzgün çalışsa da elektrotlara belirli bir kuvvet etki ettiğinde veya sistem gürültülü bir ortama yerleştirildiğinde, gürültü ve parazitlerin hala mevcut olduğunu belirtmişlerdir (Luan, Sun, & Jia, 2012).

2013 yılında Howida A. Shedeed ve diğerleri tarafından yapılan bir çalışmada EEG sinyallerini toplamak için Emotiv EPOC cihazı kullanılmıştır. Sadece 4 kanaldan veri alınmıştır (AF3, F7, F3, FC5). 3 temel hareket esas alınmıştır (el açma, kol açma ve kapama). Öznitelik çıkarımı için dalgacık dönüşümü, hızlı Fourier dönüşümü (FFT – Fast Fourier Transform) ve temel bileşenler analizi (PCA – Principal component analysis) kullanılmıştır. Sınıflandırma içinse çok katmanlı algılayıcı sinir ağı modeli kullanılmıştır. Eğitim için 170, test için 30 örnek kullanılmıştır. Sinyallerin tamamı tek kişiden alınmıştır. Sınıflandırma oranları dalgacık dönüşümü için %91,1, FFT için %86,7 ve PCA için %85,6 olarak elde edilmiştir (Shedeed, Issa, & El-sayed, 2013).

L. Zhang ve diğerleri tarafından 2013 yılında iki bipolar gümüş klorür elektrot kullanılarak taşınabilir bir Beyin-Bilgisayar Arayüzleri (BCI) çalışması yürütülmüştür. Mod reddetme filtresi uygulanarak sinyaller 50 Hz şebeke geriliminden filtrelenmiş ve ardından genlikleri 13,5 kat arttırılmıştır. Son olarak 0,5 Hz pasif RC yüksek geçiren filtre ile düşük frekanslı gürültüyü filtrelemişler ve ana yükseltici olarak kullanılan INA118 ile sinyali 51 kat arttırmışlardır (Zhang, Guo, Wu, & Zhou, 2013).

2014 yılında Saugat Bhattacharyya ve diğerleri, 19 Elektrotlu NeuroWin EEG cihazı ile kol hareketleri sırasında alınan sinyalleri kullanarak robot kolun sağ, sol, ileri ve dur olmak üzere dört temel hareketini sağlamışlardır. Sinyaller alınırken P300 piki beklenmiştir. P300 piki görülünce işlem belirlenerek robot kola gönderilmiştir. Öznitelik çıkarımı için adaptif otomatik regresyon modeli kullanılmıştır. Sinyallerdeki gürültülerin temizlenmesi için Kalman filtresi kullanılmıştır. Sınıflandırma içinse destek vektör makineleri (DVM) kullanılmıştır. Motor hareketleri sırasında alınan sinyaller ile kullanılan yöntemler uyumlu çalışmış olup tepki süresi ortalama 1 saniye olarak hesaplanmıştır. Hesaplama hızından ödün vermemek için kullanılan DVM'nin başarılı olduğu anlatılmıştır (Bhattacharyya, Konar, & Tibarewala , 2014).

2015 yılında Xinyi Yong ve Carlo Menon tarafından, dirsek ve avuç hareketlerinin, bu hareketlerin hayal edilmesi ile kıyaslanmasına dayalı bir çalışma gerçekleştirilmiştir. 32 kanallı bir EEG kayıt cihazı ile veriler alınmıştır. Öznitelik çıkarımı için ortak mekânsal desen (CSP), filtre-bank ortak mekânsal desenler (FBCSP) ve logaritmik bant gücü (BP) kullanılmıştır. Sınıflandırmada ise lineer diskriminant analizi (LDA), lojistik regresyon (LR) ve DVM kullanılmıştır. Hayali kavrama ve dirsek hareketlerinin ikili sınıflandırması için, elde edilen ortalama doğruluk %66,9 olmuştur. Öte yandan, EEG sinyalinin üç sınıfını yani, dinlenme, hayali kavrama ve hayali dirsek hareketlerini sınıflandırırken elde edilen başarımlar %60,7 olarak elde edilmiştir (Yong & Menon, 2015).

Turky Alotaiby ve diğerlerinin 2015 yılında yaptıkları çalışmada literatürdeki çalışmaların en iyi yöntemleri seçilerek uygulamalı olarak karşılaştırılmıştır ve kanal seçimi konusunda fikir sunmuştur. DVM kullanılarak yapılan 118 elektrotlu BCI Competition III veri setinin sınıflandırılmasında tüm kanalları kullanarak elde edilen başarımlar %90,82 iken 8 kanallı sınıflandırma yapıldığında bu oran %94,63'e çıkmıştır. SCSP algoritmasının, tüm kanallar (C3, C4 ve CZ) ile karşılaştırıldığında, kanal sayısını azaltılınca sınıflandırma doğruluğunda %10'luk bir iyileşme ile en iyi sınıflandırma doğruluğunu elde ettiği gösterilmiştir. Bu makaledeki kapsamlı çalışma, sınıflandırma/algılama görevlerinin performansında, mevcut kanalların %10'u ile %30'u kadar küçük bir EEG kanalları kümesini kullanmanın mümkün olduğunu ortaya koymuştur (Alotaiby, Abd El-Samie, Alshebeili, & Ahmad , 2015).

2016 yılında Dany Bright ve diğerleri, Neurosky Mindwave Mobile Headset ile topladıkları verileri sınıflandırma yerine Neurosky üzerinden elde edilebilen dikkat seviyesi ölçümlerini

kullanarak robot kola 3 temel hareket yaptırmıştır. Yani herhangi bir sınıflandırma yöntemine başvurulmamıştır. Parmakları aç: 20-49, parmakları kapat: 50-69 ve yumruk yap: 70-100 dikkat seviyesine göre gruplandırılmıştır. EEG sinyallerinden elde edilen dikkat seviyelerine göre önceden belirlenmiş 3 hareket için gruplama yapılarak üç boyutlu yazıcıda oluşturulan bir robot kolun servo motorlarla hareketini sağlamışlardır (Bright, Nair, Salvekar, & Bhisikar, 2016).

Hari Krishna ve diğerleri 2016 yılında yaptıkları çalışmada motor hareketleri ve bu hareketlerin hayalleri arasındaki ilişki için kullanılan yöntemlerin geliştirilebileceğini göstermek amacıyla öznitelik çıkarımında çapraz korelasyon tekniğini ve sınıflandırmada K-fold çapraz doğrulama yöntemini kullanmışlardır. Sağ ve sol elin ve ayakların hareketlerini incelemek için 22 elektrottan sinyal alınmıştır. Kıyaslama için (DVM), K-en yakın komşu, LDA, Naïve Bayes ve ikili karar ağacı algoritmaları da kullanılmıştır ve önerilen yöntem ile karşılaştırılmıştır. Mevcut yaklaşımda, sınıflandırıcının performansını tahmin etmek için 6 kez çapraz doğrulama kullanılmıştır. Diğer yöntemlerin üzerine uygulandığında %29,82 oranında iyileştirildiği gözlemlenmiştir (Hari Krishna, Pasha, & Satya Savithri, 2016).

Sasweta Pattnaik ve S. Sabut, tarafından 2016 yılında yapılan bir çalışmada ayrık dalgacık dönüşümü (DWT – Discrete Wavelet Transform) kullanarak motor hareketleri sırasında alınan EEG sinyallerinin öznitelikleri çıkarılmıştır. Sınıflandırma için yapay sinir ağları (YSA) kullanılmıştır. Sinyaller C3, Cz ve C4 kanallarından alınmıştır. Toplam 280 örnek, eğitim için 140 örnek ve test için 140 örnek olacak şekilde ayrılmıştır. Motor hareketlerinin hayalleri ile sınıflandırılması için kullanılan YSA yönteminde ortalama, standart sapma ve tepe güç gibi üç girdili öznitelik vektörü, %78,57 olan iki girdili öznitelik vektörüne kıyasla %80,71'lik bir başarı oranı göstermiştir (Pattnaik, Dash, & Sabut, 2016).

2018 yılında Vladimir A. Maksimenko ve diğerlerinin yaptığı çalışmada, gerçek motor hareketleri ve hayali hareket arasındaki en önemli ayrımları gösteren beyin alanlarını ortaya çıkarmak için EEG sinyallerinin analizine çok katlı formalizm uygulanmıştır. Ardından EEG aktivitesinin zaman sıklığı dalgacık tabanlı analiz kullanarak, dikkate alınan beyin alanlarının yapısı ayrıntılı olarak analiz edilmiştir. Sonuç olarak, farklı beyin alanlarında meydana gelen ve motor hareketi veya hayali gerçekleştiğinde birbirleriyle etkileşime giren karakteristik farklılıklar ayırt edilmiştir. Sinyaller 20-43 yaş arası sağlıklı 12 erkek ve kadın

bireyden 19 kanallı bir EEG cihazı ile alınmıştır. Öznitelik çıkarımı için ampirik mod ayrışma (EMD –Empirical Mode Decomposition) kullanılmıştır. Tüm EEG kanallarından hesaplanan Hölder üsleri kümesini göz önünde bulundurarak, motor hareketleri, motor hareketlerinin hayali ve arka plan EEG arasındaki en önemli farklılıkların frontal lobda meydana geldiği bulunmuştur. Multifaktal ve zaman frekans analizine dayanarak, olay bağımlı desenkronizasyon ve olay bağımlı senkronizasyonun delta ve alfa frekans bantlarındaki etkisinin motor hareketleri ve motor hareketlerinin hayali ile ilişkili olduğu gösterilmiştir (Maksimenko, ve diğerleri, 2018).

2019 yılında Mohand Lokman Al-dabagve Nalan Özkurt tarafından literatürde kullanımı yaygın olan BCI Competition III Dataset IVa veri seti ile Emotiv Epoc+ kullanarak kaydettikleri sinyallerin kıyaslaması yapılmıştır. Öznitelik çıkarımı için çapraz korelasyon ve DWT kullanılmıştır. Sınıflandırma içinse DVM ve çok katmanlı YSA yöntemleri kullanılmıştır. YSA sınıflandırıcısı DVM'den daha iyi sonuçlar vermiştir. 14 kanallı Emotiv Epoc+ ile kaydedilen sinyaller çapraz korelasyon ile efektif kanalların belirlenmesi sonucunda %92'nin üzerinde başarımlı sunmuştur (Al-dabag & Özkurt, 2019).

2021 yılında Zhongke Gao ve diğerleri, EEG sinyallerinin sınıflandırılmasında kompleks ağ ve derin öğrenme yöntemleri üzerine bir derleme makalesi yazmışlardır. Çok kanallı EEG sinyallerine dayanan, evrişimli sinir ağı (CNN – Convolutional Neural Network) ile birleştirilmiş frekansa bağlı çok katmanlı beyin ağı (FDMB – frequency-dependent multilayer brain) modeli depresif bozukluğu tespit etmek için geliştirilmiştir ve %97,27'lik başarımlı sağlanmıştır. Eğitim sırasında, modelin performansını değerlendirmek için 5 katlı çapraz doğrulama yönteminin kullanıldığı bir yöntemde tüm deneklerde RP tabanlı uzamsal frekanslı CNN (SFCNN) modeli %96 başarımlı oranına sahip olmuştur. Tüm sonuçlar, kompleks ağ ve derin öğrenme kombinasyonunun, sinyal yorgunluğunu tanımak için güçlü bir kombinasyon yöntemi olduğunu göstermiştir (Gao, ve diğerleri, 2021).

Achim Buerkle ve diğerleri 2021 yılında yaptıkları çalışmada Emotiv Epoc+ ile 7 erkek ve 1 kadın bireyden örnekler alarak Motor hareketlerinin EEG sinyallerinin, harekete geçirmeden 513 milisaniye önce tamamlandığını göstermişlerdir ve bu komutu erken tespit ederek yapılacak işlevi önceden tahmin etmeyi amaçlamışlardır. Çalışmada AF3, F3, AF4, F4 kanalları kullanılmıştır. Filtreleme için Butterworth filtresi kullanılmıştır. Öznitelik çıkarımı için FFT ve PCA kullanılmıştır. Sınıflandırma içinse K-means ve DVM

algoritmaları kullanılmıştır. Kişi bazlı yapılan testlerde başarı oranı %84,98 – %92,08 arasında oluşmuştur. Hareket niyeti erken tahmin edilerek robot kol ile eş zamanlı aktivitelerin gerçekleştirilebileceği savunulmuştur (Buerkle, Eaton, Lohse, Bamber, & Ferreira, 2021).


Marzieh Moradi ve diğerleri 2021 yılında tasarladıkları taşınabilir EEG devresinde iki aşamalı tamamlayıcı metal-oksit-yarı iletken (CMOS – Complementary Metal–Oxide–Semiconductor) yükseltici kullanmışlardır. Yükseltici 0.1 – 212 Hz aralığında 70 dB orta bant kazancı ve -3 dB bant genişliği elde etmektedir. Ayarlanabilir alçak geçiren filtrenin kesme frekansı 100 olarak belirtilmiştir. Yükselticinin çıkışındaki dalgalanmaları azaltmak için sürekli zamanlı ikinci dereceden 100 Hz Gm-C alçak geçiren filtre kullanılmıştır. Yükselticinin çıkışında 92 dB bant genişliği elde edilmiştir (Moradi, Dousti, & Torkzadeh, 2021).

Bu tez kapsamında bir enstrümantasyon yükseltici olan AD8233 kullanılarak taşınabilir bir EEG kayıt cihazı tasarlanmıştır. EEG sinyallerinin toplanması sırasında gürültülerden temizlenebilmesi için donanımsal ve yazılımsal olarak filtrelemeler yapılmıştır. İlk olarak motor hareketleri ve yüz mimikleri üzerinde durulacağından frontal lobda bulunan FP1 ve FP2 kanallarının faz farkı alınacak şekilde 3 elektrotlu ve tek kanallı bir kompakt sistem oluşturulmuştur. Tasarlanan cihaz ile toplanan sinyallerin bilgisayar üzerinden kontrol edilebilmesi ve uygulamalar yapılabilmesi adına bir masaüstü yazılımı geliştirilmiştir. Yazılım üzerine yüz mimiklerinin taklit edildiği bir uygulama eklenmiştir. Tasarlanan cihaz ile toplanan sinyaller Emotiv EPOC+ kullanılarak alınan sinyaller ile kıyaslanmış ve performans değerlendirmesi yapılmıştır.

2. MATERYAL VE YÖNTEMLER

2.1 AD620 Enstrümantasyon Yükseltici

AD620 düşük maliyetli ve yüksek kazançlı bir enstrümantasyon yükselticidir. Bir kazanç direnci, bir pozitif ve bir negatif beslemeye ihtiyaç duymaktadır. Besleme gerilimini geçmeyecek şekilde bir sinyalin genliğini 10000 kata kadar yükseltebilmektedir. AD620, 1 KHz'de $9 \text{ nV}/\sqrt{\text{Hz}}$ düşük giriş voltajı gürültüsü ve 0,1 ila 10 Hz bandında uçtan uca $0.28 \mu\text{V}$ ve $0.1 \text{ pA}/\sqrt{\text{Hz}}$ giriş akımı gürültüsüne sahiptir. Bu nedenle özellikle medikal uygulamalarda bir ön yükselteç olarak kullanıma uygundur. Şekil 2.1'de AD620 entegre devre şeması ve giriş çıkış pinleri gösterilmiştir (Low Cost Low Power Instrumentation Amplifier AD620 Data Sheet, 2011).



Şekil 2.1. AD620 enstrümantasyon yükseltici entegre şeması.


AD620 enstrümantasyon yükselticinin kazancı 1 ve 8 numaralı pinleri arasına yerleştirilecek bir direnç ile sağlanmaktadır. Kazanç hesabı Eş. 2.1'deki gibi hesaplanmaktadır. Burada R_G kazanç direncini temsil etmektedir.

$$G = \frac{49,4K}{R_G} + 1 \quad (2.1)$$

2.2 AD8232 Enstrümantasyon Yükseltici

AD8232, biyopotansiyel ölçüm uygulamaları için üretilmiş entegre bir sinyal koşullandırma bloğudur. Hareket veya elektrot ile devre arsındaki mesafeden kaynaklı gürültülü koşulların oluşması durumunda küçük biyopotansiyel sinyalleri yükseltmek ve filtrelemek için tasarlanmıştır. AD8232 özel bir enstrümantasyon yükseltici (IA), bir işlemsel yükseltici

(A1), bir sağ bacak sürücü yükselticisi (A2) ve bir orta besleme referans tamponundan (A3) oluşmaktadır. Enstrümantasyon yükseltici, içerisinde 1 MHz RFI alçak geçiren filtre barındırmaktadır. Bununla birlikte tüm devrenin genel çıkış frekansı 1 KHz olarak ayarlanmıştır. Şekil 2.2’de AD8232 entegre devre şeması ve içerisinde bulundurduğu devre elemanları gösterilmiştir (Single-Lead, Heart Rate Monitor Front End AD8232 Data Sheet, 2020).




Şekil 2.2. AD8232 entegre devre şeması.

2.3 ESP 8266-12E Kablosuz Haberleşme Modülü

ESP 8266-12E günümüzde nesnelerin interneti (IOT) kapsamında birçok çalışmada kullanılmaktadır. Düşük maliyeti ve çok yönlü kullanımı sayesinde sıklıkla tercih edilmektedir. ESP8266-12E, sensörler ile entegre edilerek veya sadece kısa bir programlama ile bir pin giriş çıkışı aracılığıyla belirli uygulamalara izin veren yerleşik işleme ve depolama yeteneklerine sahiptir. Üzerinde bulunan ESP8266 yongası sayesinde kablosuz haberleşmeye olanak sağlamaktadır. Bu küçük yonga, mikro denetleyicilerin bir Wi-Fi ağına bağlanmasına ve AT komutlarını kullanarak basit TCP/IP bağlantıları yapmasına olanak tanımaktadır (Hanan, Gunawan, & Sumadiyasa, 2019). 2.4 GHz frekans bandında


haberleşmeye olanak sağlayan modül 802.11 b/g/n kablosuz ağ protokollerini uygulamaktadır. Üzerinde 0-1 V giriş değerine sahip analog giriş, birden fazla GPIO ve PWM girişleri bulunmaktadır (ESP-12E WiFi Module, 2015). Arduino IDE gibi yardımcı programların yanında doğrudan Python gibi programlama dilleri ile de programlanabilmektedir. Şekil 2.3'te ESP 8266-12E kablosuz haberleşme modülü gösterilmiştir.



Şekil 2.3. ESP 8266-12E kablosuz haberleşme modülü.

2.4 ESP-01 Kablosuz Haberleşme Modülü


ESP-01 oldukça küçük bir boyuta ve ultra düşük güç teknolojisine sahiptir. ESP-01 akıllı ev otomasyonları, giyilebilir elektronik ürünler, kablosuz konum algılama cihazları ve diğer ağ bağlantısı gereksinimi duyulan birçok uygulamada yaygın olarak kullanılmaktadır. İçerisinde bulunan mikroişlemci analog girişe sahiptir ancak ESP-01 DIP soket modelinde bu girişe erişilebilir bir bağlantı tasarlanmamıştır. 2.4 GHz frekans bandında çalışmaktadır ve 802.11 b/g/n protokollerini uygulamaktadır. UART ve GPIO arayüzlerine sahiptir ve bu sayede seri haberleşmeye olanak tanımaktadır (ESP-01 802.11 b/g/n Wi-Fi Module V1.2, 2017). ESP-01 DIP model kablosuz haberleşme modülü Şekil 2.4'te gösterilmiştir.



Şekil 2.4. ESP-01 kablosuz haberleşme modülü.


2.5 RC Alçak Geçiren Filtre

Alçak geçiren filtre, bir kondansatör (C) ve bir dirençten (R) oluşan, kesme frekansı olarak belirlenen değerden daha yüksek frekans değerine sahip olan sinyalleri zayıflatan ve daha düşük frekansa sahip olan sinyalleri ileten elektronik devrelerdir. Alçak geçiren filtreler aktif ve pasif olarak tasarlanabilmektedir. Pasif alçak geçiren filtreler uygulandıklarında çıkış sinyali giriş sinyalinden daha zayıf olmaktadır. Aktif alçak geçiren filtrelerde ise çıkışı yükseltmek için devreye bir op-amp bağlanmaktadır. Bir direnç ve bir kondansatörden oluşan alçak geçiren filtreler birinci derece alçak geçiren filtre olarak tanımlanmaktadır. Şekil 2.5'te birinci derece pasif alçak geçiren filtreler için örnek bir şema gösterilmiştir.




Şekil 2.5. Birinci derece pasif alçak geçiren filtre şeması.

RC pasif alçak geçiren filtrenin frekans geçişine etkisi Şekil 2.6'da örneklendirilmiştir.



Şekil 2.6. Filtrelemede dereceye bağlı sinyal geçişi Bode büyüklüğü ve Bode fazı grafikleri.

Grafikte de görüldüğü gibi kesme frekansından daha yüksek frekanslar filtrelenmiş olsalar da yine de tam olarak elemine edilememişlerdir. Çıkış sinyalinin frekansını daha keskin biçimde filtrelemek için filtrelerin derecelerinin yükseltilmesi gerekmektedir. Derece yükseltme işlemi arka arkaya her bir filtre devresinin girişine bir önceki filtrenin çıkışı bağlanarak katman sayısının artırılmasıyla gerçekleştirilmektedir. Şekil 2.7’de katman sayısının kesme frekansı üzerindeki etkisi gösterilmiştir (Inductiveload, 2007).



Şekil 2.7. Katman sayısına bağlı olarak kesme frekansının keskinliğinin değişimi.

Pasif alçak geçiren filtrelerde kesme frekansı direnç ve kondansatörün seçimi ile belirlenmektedir. Genel kesme frekansı formülü Eş. 2.2’de gösterilmiştir.

$$F = \frac{1}{2\pi RC} \quad (2.2)$$

2.6 Tek Kullanımlık Gümüş Klorür Elektrotlar

Tek kullanımlık (disposable) elektrotlar özellikle EKG ölçümlerinde sıklıkla kullanılan ve kullanıldıktan sonra atılan genellikle düşük maliyetli elektrotlardır. Elektrot ve elektrolit tabakalardan oluşmaktadır. Elektrot tabaka, genellikle Ag/AgCL veya Zn/ZnSO₄ olarak üretilmektedir. Elektrolit tabaka ise elektrot tabakaya yapışık jel ve sünger olarak üretilmektedir (Elektrotlar, 2011). İki tabaka arasındaki veri akışı çift yönlü ve neredeyse kayıpsız şekilde gerçekleştirilmektedir. Şekil 2.8’de tek kullanımlık elektrotlara bir örnek gösterilmiştir.




Şekil 2.8. Tek kullanımlık elektrotlar.

2.7 K En Yakın Komşu Algoritması

K en yakın komşu algoritması (KNN), en basit makine öğrenmesi algoritmalarından biridir. K, veri kümesindeki bilinmeyen bir noktanın kendisine en yakın komşu sayısını temsil etmektedir. K değeri genellikle tek sayı olarak seçilmektedir. Bunun nedeni en az iki sınıflı veri kümelerinde en yakın komşu sayılarının eşit çıkabilme olasılığıdır. Bilinmeyen bir örnek veri setine eklendiğinde KNN sınıflandırması yeni eklenen örneğin veri kümesindeki diğer örneklerle olan uzaklıklarını hesaplamaktadır. Uzaklık hesaplama yöntemi olarak n Manhattan uzaklığı (Eş. 2.3), Öklid uzaklığı (Eş. 2.4) ve Minkowski uzaklığı (Eş. 2.5) gibi ölçüm teknikleri kullanılmaktadır (Açıl, 2019). Sınıflandırma sonucunda yeni eklenen örneğe K adet en yakın komşusunun bulunduğu sınıfın etiketi verilmektedir. K=1 olarak belirtildiği takdirde yeni örnek kendisine en yakın örneğin bulunduğu sınıfa dahil

edilmektedir. Şekil 2.9’da K=5 için KNN sınıflandırıcısının yeni örneği nasıl sınıflandırdığı gösterilmiştir.



Şekil 2.9. K=5 için KNN sınıflandırıcısı.

$$\sum_{i=1}^k |x_i - y_i| \quad (2.3)$$

$$\sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2.4)$$

$$\left(\sum_{i=1}^k (|x_i - y_i|^q) \right)^{1/q} \quad (2.5)$$

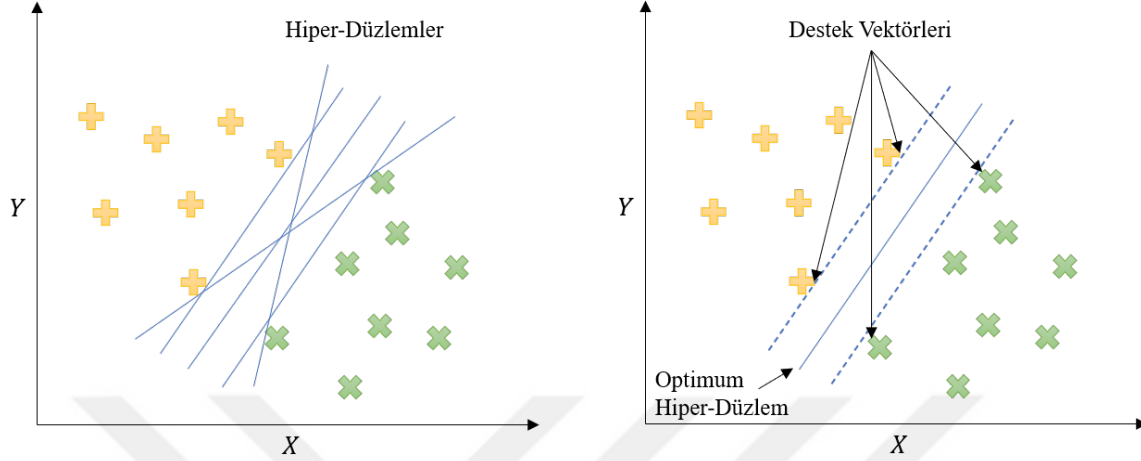
2.8 Destek Vektör Makineleri (DVM)

Destek vektör makineleri, istatistiksel öğrenme teorisine dayalı, vektör uzayı tabanlı bir makine öğrenme yöntemidir. DVM, temelde iki sınıfı doğrusal olarak birbirinden ayıran keskin bir düzlem oluşturmak için tasarlanmıştır. Bu alanda başarılı sonuçlar elde edilmesini sağlayan algoritma daha sonra doğrusal olmayan ve çok sınıflı problemler için kullanılabilir şekilde genişletilmiştir.

2.8.1 Doğrusal Ayrılabilen Sınıflar için DVM

Doğrusal ayrılabilen verilerin sınıflandırılmasında genellikle örneklerin sınıf etiketleri $\{-1, +1\}$ şeklinde gösterilmektedir. Örnekler, eğitim verisi işlenirken elde edilen karar

fonksiyonu ile sınıflara ayrıştırılmaktadır. Bu karar fonksiyonu kullanılarak eğitim verilerini doğrusal olarak ayırabilecek hiper düzlem oluşturulmaktadır (Şekil 2.10).



Şekil 2.10. DVM ile elde edilen hiper düzlemler ve destek vektörleri.

İki sınıflı yapıları birbirinden ayırabilmek için birden çok hiper düzlem çizilebilir. DVM bu hiper düzlemler arasında en optimum olanı, kendisine en yakın noktalar arasındaki uzaklığın en fazla olduğu hiper düzlemi belirleyerek bulmaktadır (Kavzoğlu & Çölkesen, 2010). Eş. 2.6'da optimum hiper düzlemin bulunması için kullanılan karar fonksiyonu gösterilmiştir.

$$f(x) = \text{sign} \left(\sum_{i=1}^k \lambda_i y_i (x \cdot x_i) + b \right) \quad (2.6)$$

2.8.2 Doğrusal Ayrılamayan Sınıflar için DVM


Doğrusal olarak ayrıştırılması mümkün olmayan veri kümelerinde eğitim verilerinin bir kısmının hesaplanan hiper düzlemin diğer tarafında kalması problemi oluşmaktadır. Söz konusu problemin çözümü girdi uzayında doğrusal olarak ayrılamayan verinin özellik uzayı olarak tanımlanan yüksek boyutlu bir uzayda görüntülenmesi ile sağlanmaktadır. DVM, radyal temelli (Eş. 2.7) ve çok terimli (Eş. 2.8) Kernel fonksiyonlarının yardımıyla doğrusal olmayan dönüşümler yaparak yüksek boyutta verileri doğrusal olarak ayırabilmektedir (Şekil 2.11 (Kavzoğlu & Çölkesen, 2010)).

$$K(x, y) = e^{-\gamma |x-y|^2} \quad (2.7)$$

$$K(x, y) = (x \cdot y + 1)^n \quad (2.8)$$

Kernel fonksiyonlarının kullanımıyla beraber DVM'nin sınıflandırıcı karar fonksiyonu Eş. 2.9'daki şekilde tanımlanmaktadır (Ayhan & Erdoğan, 2014).

$$f(x) = \text{sign}((w^n, x_i) + b) = \text{sign}\left(\sum_{i=1}^n y_i a_i (\phi(x_i) \cdot \phi(x_j))\right) \quad (2.9)$$



Şekil 2.11. Kernel fonksiyonlarıyla yüksek boyutlu uzayda hiper düzlemin belirlenmesi.

2.8.3 Çok Sınıflı Veriler için DVM

Sınıf sayısının ikiden daha fazla olduğu durumlarda DVM algoritması yetersiz kalmaktadır. Bu sorunun çözümü için bire bir (one versus one) ve bire çok (one versus all) şeklinde ayırım yapan ikili sınıflandırıcılar oluşturulmaktadır.

Bire bir sınıflandırıcısı, her bir sınıf ikilisi için yeni bir DVM eğitmektedir. Eğitilen DVM'ler arasında en çok +1 etiketine sahip olan sınıf belirlenmektedir ve atama buna göre yapılmaktadır.

Bire çok sınıflandırıcısı ise yeni veriyi öncelikle bir sınıfa dahil etmektedir. Geriye kalan tüm sınıflar tek bir sınıf olarak kabul edilerek sınıf sayısı kadar iterasyonla yeni DVM'ler üretilerek birbirleri ile kıyaslanmaktadır. Bu işlem matematiksel olarak Eş. 2.10'daki gibi ifade edilmektedir.

$$\beta_0^{(n)} + \beta^{nT} x_0 \quad (2.10)$$

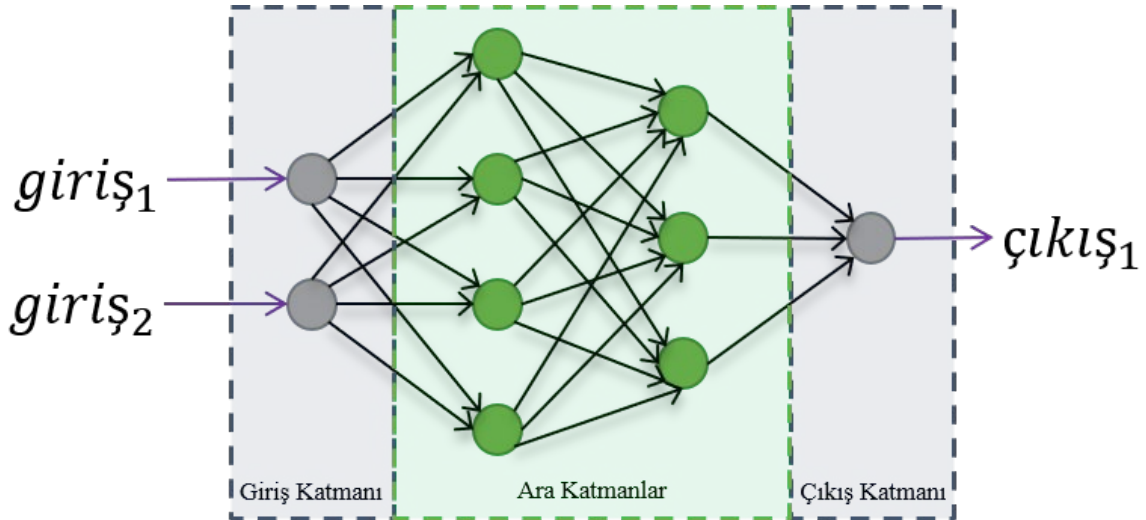
Oluşan n adet DVM için β_0 ve β vektörleri bulunarak yeni veri en yüksek x_0 değerinin bulunduğu sınıfa dahil edilmektedir (Metlek & Kayaalp, 2020).

2.9 Çok Katmanlı Algılayıcı (ÇKA)

Çok katmanlı algılayıcılar (ÇKA), tam bağlantılı bir ileri beslemeli yapay sinir ağı (YSA) modelidir. Bir ÇKA, bir giriş katmanı, bir gizli katman ve bir çıkış katmanı olmak üzere en az üç düğüm katmanından oluşmaktadır. Giriş düğümleri dışında her düğüm, doğrusal olmayan bir aktivasyon fonksiyonu kullanan bir nörondur. ÇKA, eğitim için geri yayılım adı verilen denetimli bir öğrenme tekniği kullanmaktadır. Çoklu katmanları ve doğrusal olmayan aktivasyonu, ÇKA'yı doğrusal bir algılayıcıdan ayırır. Bu özelliği sayesinde doğrusal olarak ayrılabilen verileri ayırt edebilmektedir (Cybenko , 1989).

Veriler ilk aşamada giriş katmanına iletilmektedir. Giriş katmanı gelen verileri ilk ara katmana iletmektedir. Ara katmanlar problemin karmaşıklığına ve hata oranının yüksekliğine bağlı olarak birden fazla olacak şekilde tasarlanabilmektedir. Her katmanın çıkışında elde edilen veriler sonraki katmana girdi olarak verilmektedir. Son ara katmandan çıkan veriler çıkış katmanındaki düğümlere aktarılmaktadır ve önceki katmanlardan gelen verileri işleyerek ağın çıkışını belirlemektedir. Şekil 2.12'de iki giriş, bir çıkış ve iki ara katmanı bulunan dört katmanlı bir ÇKA modeli gösterilmiştir.

ÇKA'larda bazı nöronlar, biyolojik nöronların aksiyon potansiyellerini veya tetikleme frekansını modellemek için geliştirilmiş doğrusal olmayan bir aktivasyon fonksiyonu kullanmaktadır. Yaygın olarak kullanılan her iki aktivasyon fonksiyonu da sigmoiddir ve Eş. 2.11 ve Eş. 2.12'deki şekilde tanımlanmaktadır. İlk eşitlik -1 ile 1 arasında değişen bir hiperbolik tanjant, ikinci eşitlik ise şekil olarak benzer ancak 0 ile 1 arasında değişen lojistik fonksiyondur. Burada y_i , i 'inci düğümün (nöron) çıktısını, v_i ise giriş bağlantılarının ağırlıklı toplamını temsil etmektedir.



Şekil 2.12. Dört katmanlı ÇKA yapısı.

$$y(v_i) = \tanh(v_i) \quad (2.11)$$

$$y(v_i) = (1 + e^{-v_i})^{-1} \quad (2.12)$$

Öğrenme, algılayıcıda her veri parçası işlendikten sonra beklenen sonuca kıyasla çıktındaki hata miktarına bağlı olarak bağlantı ağırlıklarını değiştirerek gerçekleşir. Bu denetimli öğrenmeye bir örnektir ve doğrusal algılayıcıdaki en küçük ortalama kareler algoritmasının bir genelleştirmesi olan geri yayılım yoluyla gerçekleştirilmektedir (Murtagh, 1991).

2.10 Hızlı Fourier Dönüşümü (FFT)

Hızlı Fourier dönüşümü (Fast Fourier Transform – FFT) sinyal işleme uygulamalarında frekans analizinde oldukça yaygın kullanılan bir algoritmadır. FFT, bir dizinin Fourier dönüşümünü ya da ayrık Fourier dönüşümünü hesaplayarak bir sinyali bulunduğu uzaydaki – ki bu genellikle zaman uzayıdır – gösteriminden frekans uzayındaki gösterimine dönüştürmektedir (Heideman, Johnson, & Burrus, 1984).

FFT algoritmaları ayrık Fourier dönüşümündeki dönüşüm matrisinin seyrek matrislere ayrıştırılarak N adet veriye sahip bir dizinin ayrık Fourier dönüşümünün karmaşıklığını $O(N^2)$ 'den $O(N \log N)$ 'e dönüştürmektedir. Veri boyutunun fazla olması durumunda FFT, standart Fourier dönüşümlerinden çok daha hızlı çalışmaktadır. Eş. 2.13'te bir dizinin FFT ile frekans uzayındaki gösterimine dönüştürülmesi için kullanılan denklem gösterilmiştir (Alptürk & Kutlu, 2020).

$$X_k = \sum_{n=0}^{N-1} x(n) e^{-i(2\pi \times k \times \frac{n}{N})} \quad (2.13)$$

Sayılar teorisi, grup teorisi ve karmaşık sayı temelli, Prime-factor FFT algoritması, Bruun'un FFT algoritması, Rader'in FFT algoritması, Chirp Z-dönüşümü ve altıgen hızlı Fourier dönüşümü gibi birçok farklı FFT algoritması bulunmaktadır. Ancak genel olarak en yaygın kullanılan FFT algoritması adını JW Cooley ve John Tukey'den alan Cooley–Tukey FFT algoritmasıdır. IEEE'ye ait olan Computing in Science & Engineering adlı dergide FFT “20. Yüzyılın En Önemli 10 Algoritması” listesinde kendisine yer bulmuştur (Dongarra & Sullivan, 2000).

2.11 Korelasyon Bazlı Öznitelik Seçimi

Korelasyon, bağımlı ve bağımsız değişkenler arasındaki doğrusal ilişkiyi ve ilişki yönünü gösteren istatistiksel bir ölçüdür. Korelasyon ilişkisinin gücünü analiz edebilmek için korelasyon katsayıları kullanılmaktadır. İlk olarak Francis Galton tarafından bulunan Pearson çarpım-moment korelasyon katsayısı yaygın olarak kullanılan katsayı modelidir (Eş. 2.14). Bu modelde katsayılar $[-1, +1]$ aralığında bir değer almaktadır. Pozitif değerler aynı yöndeki doğrusal ilişkiyi, negatif değerler ise ters yöndeki doğrusal ilişkiyi göstermektedir. Korelasyon katsayısının 0 olduğu durumlarda söz konusu değişkenler arasında doğrusal bir ilişki bulunmamaktadır (Miles & Banyard, 2007). Person korelasyon katsayılarına göre ilişki durumları Çizelge 2.1'de gösterilmiştir.

Çizelge 2.1. Pearson korelasyon katsayılarına bağlı ilişki gücü.

Pearson korelasyon katsayısı (r)	İlişki Gücü
$r = 0.00 - 0.25$	Çok Zayıf İlişki
$r = 0.26 - 0.49$	Zayıf İlişki
$r = 0.50 - 0.69$	Orta İlişki
$r = 0.70 - 0.89$	Güçlü İlişki
$r = 0.90 - 1.00$	Çok Güçlü İlişki

$$\rho_{X,Y} = \frac{E(XY) - E(X)E(Y)}{\sqrt{E(X^2) - E^2(X)} \sqrt{E(Y^2) - E^2(Y)}} \quad (2.14)$$

Eş. 2.14'te belirtilen X ve Y değerleri değeri iki bağımsız değişkeni temsil etmektedir. E değişkeni ise bu iki bağımsız değişken için matematiksel beklenti değeridir.

2.12 Yöntem


Bu tez çalışmasında AD620 ve AD8232 ile iki farklı devre tasarımı gerçekleştirilmiştir. İki enstrümantasyon yükselticiye de bir RC pasif alçak geçiren devresi bağlanmıştır ve sonuçlar birbiri ile karşılaştırılmıştır. Karşılaştırma sonucunda daha düşük maliyetle daha yüksek performans elde edilen AD8232 kullanılarak taşınabilir EEG cihazının tasarımı gerçekleştirilmiştir.

Her iki enstrümantasyon yükseltici entegresine de aynı RC pasif alçak geçiren filtre devresi bağlanmıştır. AD620 ve AD8232'nin çıkış frekansları 1 KHz olarak tasarlanmıştır. EEG sinyallerinin bu frekans seviyesinde tespit edilmesi kas hareketleri ve çevredeki diğer etkiler de göz önünde bulundurulduğunda imkânsız olacaktır. Bu nedenle EEG sinyallerinin okunabilir olduğu frekans seviyesinde bir alçak geçiren filtre ihtiyacı oluşmuştur. 100 Hz üzerinde frekansa sahip olan sinyaller EEG sinyallerinin tespit edilmesini ve işlenmesini zorlaştırmaktadır. Bu nedenle yaklaşık 100 Hz kesme frekansına sahip bir alçak geçiren filtre kullanılması gerekmektedir. RC pasif alçak geçiren filtre için kesme frekansı Eş. 2.2'deki formül ile hesaplandığından bu çalışmada $R = 15,6\Omega$ ve $C = 100 \mu F$ olarak kullanılmıştır. Alçak geçiren filtrenin minimum sayıda devre elemanı içermesi taşınabilir bir tasarım için önemli olduğundan ve bu devre elemanlarının kolay ulaşılabilir olmasının maliyeti düşüreceğinden piyasada kolayca temin edilebilen 1 adet 10Ω , 1 adet $5,6\Omega$ direnç ile birlikte 1 adet $100\mu F$ kondansatör kullanılarak sistemin nihai RC pasif alçak geçiren filtresi tasarlanmıştır. Eş. 2.15'te kullanılan kondansatör ve dirençler ile kesme frekansı 102,02 Hz olarak belirlenmiştir.


$$\begin{aligned}
 F_{\text{kesme}} &= \frac{1}{2\pi RC} \\
 &= \frac{1}{2\pi \times 15,6\Omega \times 100\mu F} \\
 &= \frac{1}{2\pi \times 15,6 \times 10^{-4}} \\
 &= \frac{1}{2\pi \times 15,6 \times 0,0001} \\
 &= 102,02 \text{ Hz.}
 \end{aligned} \tag{2.15}$$

Kesme frekansı için kullanılan formülde direnç değeri ohm (Ω) cinsinden, kondansatör değeri ise Farad (F) cinsinden verilmektedir. RC alçak geçiren filtre için kullanılan 100

mikro Farad (μF) 0,0001 Farad'a eşittir. Şekil 2.13'te bu çalışmada kullanılan devre elemanlarının RC pasif alçak geçiren filtre şeması üzerindeki değerleri gösterilmiştir. Tasarlanan filtrenin Bode grafiği ise Şekil 2.14'te gösterilmiştir.




Şekil 2.13. RC pasif alçak geçiren filtre şeması üzerinde devre elemanlarının gösterimi.




Şekil 2.14. Uygulanan RC alçak geçiren filtrenin Bode grafiği.

RC alçak geçiren filtre uygulandıktan sonra 100 Hz kesme frekansından daha düşük sinyaller tespit edilebilir ve işlenebilir duruma gelmiştir. Filtrenin test edilmesi amacıyla bir sinyal üretici ile tasarlanan devreye 180 Hz örnekleme frekansına sahip 10 saniyelik sinüs sinyalleri gönderilmiştir. Şekil 2.15'te sinyal üreticiden gürültülü bir ortamda doğrudan alınan sinüs sinyalinin grafiği gösterilmiştir. Şekil 2.16'da ise RC alçak geçiren filtre bağlanarak elde edilen sinyalin grafiği gösterilmiştir.



Şekil 2.15. RC alçak geçiren filtreden önce elde edilen sinüs sinyali.

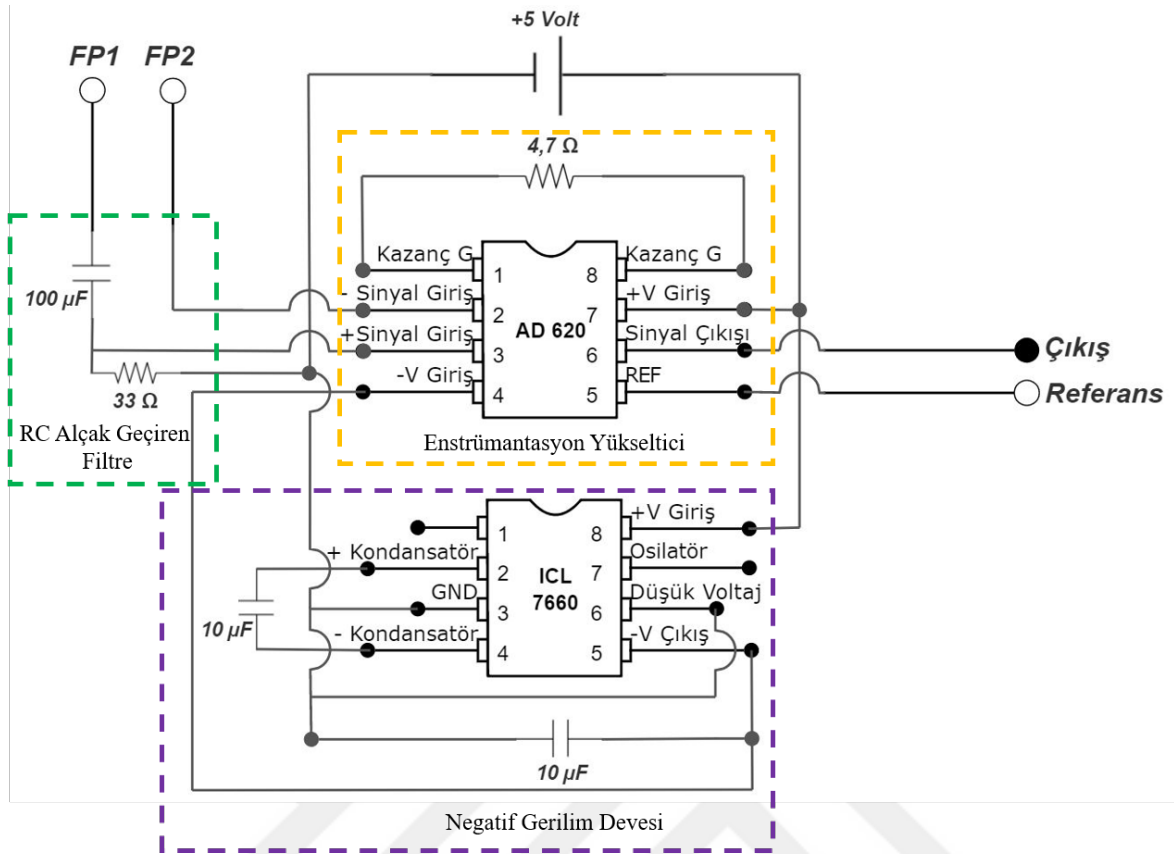


Şekil 2.16. RC alçak geçiren filtreden sonra elde edilen sinüs sinyali.

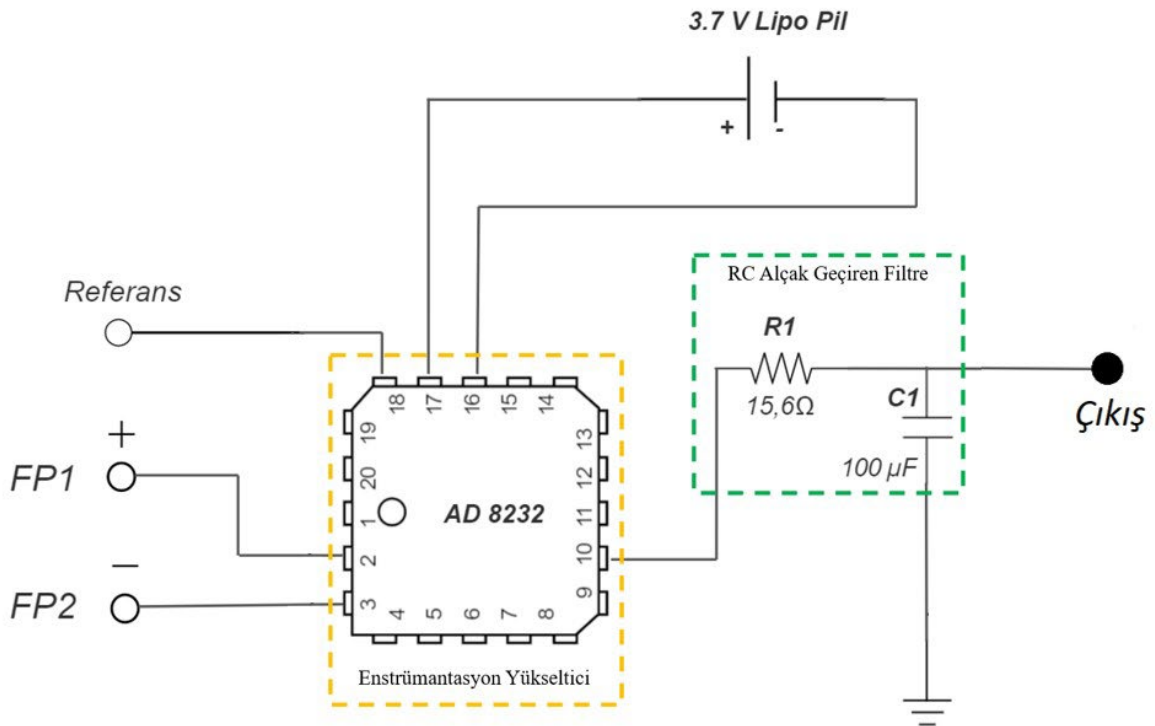
RC alçak geçiren filtrenin 102,02 Hz kesme frekansına sahip olması, yüksek frekanslı gürültülerin 1 mV seviyesindeki sinüs sinyalinden ayrıştırılmasını sağlamıştır. Grafikler incelendiklerinde filtreleme işleminin ardından sinyal gücünde zayıflama meydana geldiği görülmektedir. Bu zayıflama yüksek seviyede olmadığından göz ardı edilebilir. Donanımsal filtrelemelerin sonucunda sinyal gücünde zayıflama kaçınılmazdır. Hem bu nedenle hem de donanım maliyetini düşük tutmak amacıyla donanımsal RC pasif alçak geçiren filtre tek katmanlı tercih edilmiştir. Katman sayısının artması hem üretim ve alan maliyetini arttıracaktır hem de sinyal genliğinin daha da küçülmesine sebep olacaktır.

RC pasif alçak geçiren filtrenin tasarımı tamamlandıktan sonra AD620 ve AD8232 enstrümantasyon yükselticiler ile birleştirilerek Şekil 2.17 ve Şekil 2.18'de gösterilen devreler oluşturulmuştur.

AD620, bir negatif beslemeye ihtiyaç duyduğundan devreye ICL7660 DC çevirici entegresi bağlanmıştır. Bu sayede AD620'nin 4 numaralı pininden negatif besleme ekstra bir güç jeneratörü olmadan sağlanabilmiştir. AD8232 ise kendi içerisinde DC çevirici modülü bulundurduğundan negatif beslemeye ihtiyaç duymamaktadır. Bu nedenle ve yine içerisinde belirli gürültüleri engellemek için halihazırda filtreler bulundurduğu için AD620'den daha düşük bir maliyete sahiptir.

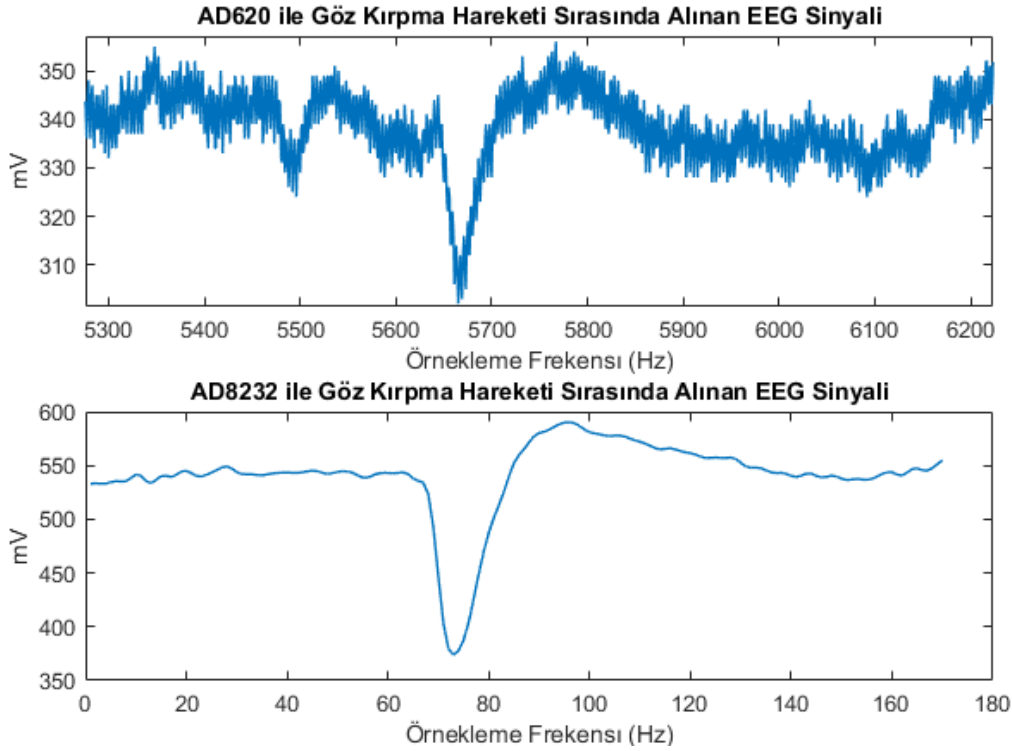


Şekil 2.17. AD620 kullanılarak tasarlanan devre.



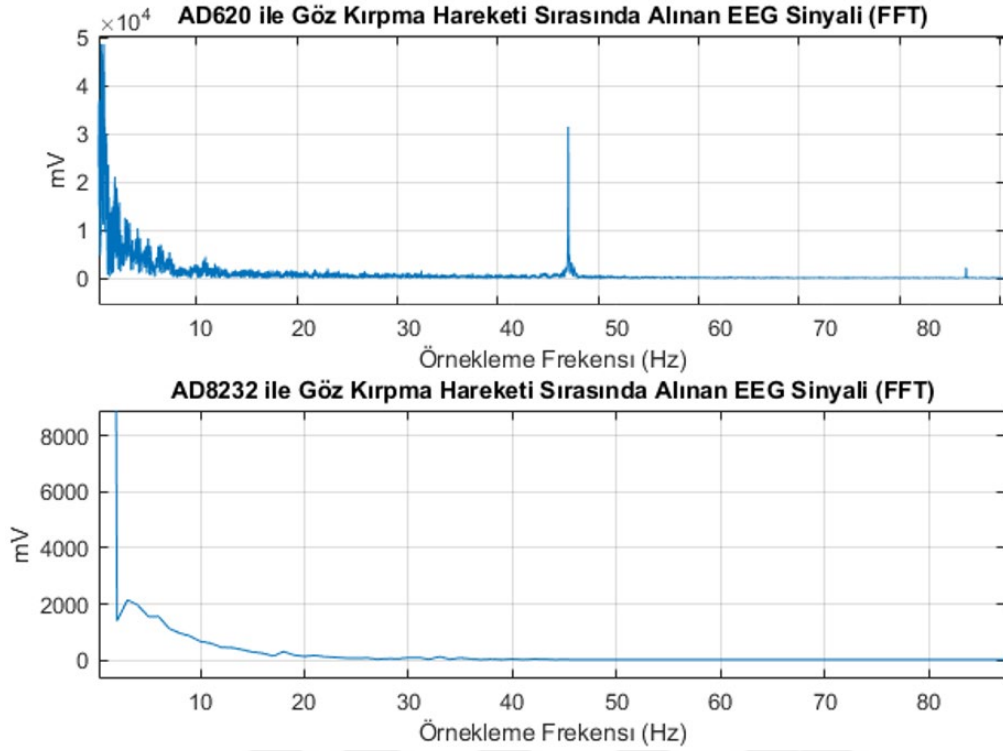
Şekil 2.18. AD8232 kullanılarak tasarlanan devre.

Tasarlanan devreler ile göz kırpma hareketi sırasında EEG sinyalleri kaydedilmiştir. Göz kırpma, yüksek genlikli pikler yaratabileceği için tespiti ve incelenmesi kolay olacağından bu hareket tercih edilmiştir. Şekil 2.19'da iki devreden alınan sinyallerin karşılaştırması gösterilmiştir. AD620 ile alınan sinyallerde yüksek frekanslı gürültüler gözlemlenmiştir.



Şekil 2.19. AD620 ve AD8232 ile göz kırpma sırasında kaydedilen EEG sinyalleri.

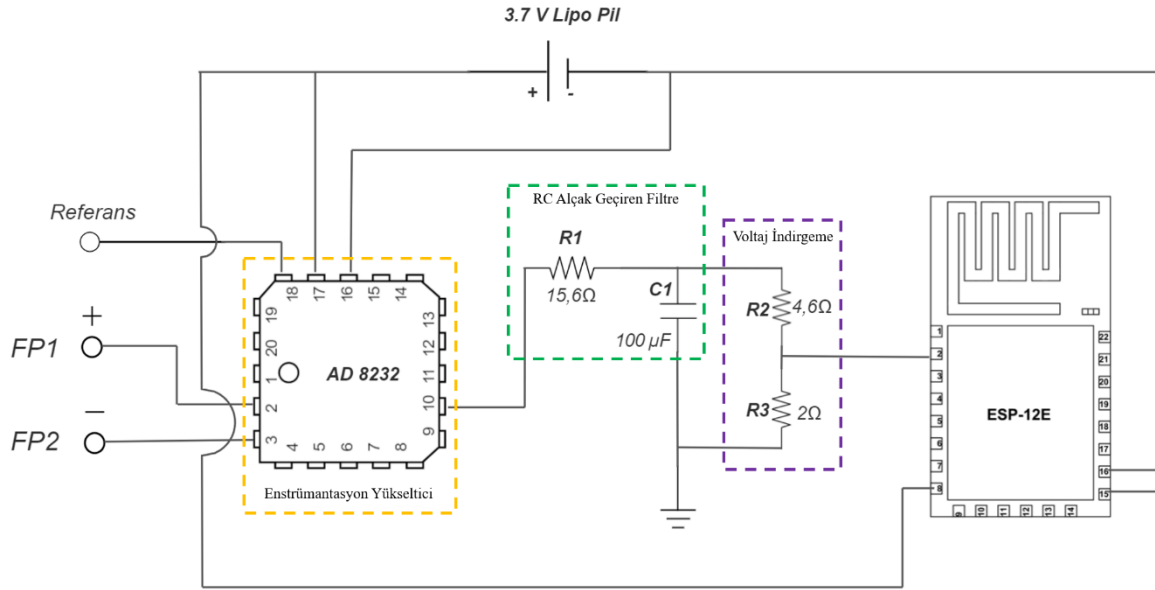
Frekans analizi yapılması için iki sinyalin de FFT'si alınarak karşılaştırılmıştır (Şekil 2.20). Frekans analizinde açıkça görüleceği üzere AD620 ile alınan sinyallerde 45-50 Hz. arasında yüksek miktarda gürültü bulunmaktadır. Bu durum EEG sinyallerinin gama dalgalarının tespit edilebilirliğini oldukça zorlaştıracaktır. Gürültünün yüksek olduğu frekans aralığı için notch filtre uygulaması yapılabilir ancak bu anlamlı 50 Hz altı EEG sinyallerini de sönmeyeceğinden yalnızca gama dalgalarının kullanılmayacağı spesifik çalışmalar için kullanışlı olacaktır. Ayrıca ekstra bir filtre fazladan maliyet anlamına geleceğinden tasarlanacak olan cihaza gürültü bakımından daha verimli olan, dolayısıyla maliyeti daha düşük ve kapladığı alan daha küçük olan AD8232 tercih edilmiştir. Çalışmanın bundan sonraki kısımlarında AD8232 baz alınarak devam edilecektir.



Şekil 2.20. AD620 ve AD8232 ile göz kırpma sırasında kaydedilen EEG sinyallerinin FFT analizi.

Enstrümantasyon yükseltici ve RC pasif alçak geçiren filtrenin test aşamaları sonuçlandırıldıktan sonra filtre çıkışı ESP 8266-12E kablosuz haberleşme modülünün analog girişine bağlanmıştır. ESP 8266-12E üzerinde bulunan analog pin 3.3 V desteklememektedir. Giriş gerilimi 0-1 V arasında olmak zorundadır. Bu nedenle filtre çıkışında elde edilen ve 3.3 V olan çıkış geriliminin indirgenmesi gerekmektedir. Bu indirgemeyi sağlamak için Eş. 2.16'da gösterilen denklem kullanılmaktadır. R_1 direnci sinyalin girişine bağlandıktan sonra R_1 ve R_2 'nin birbirine seri bağlandığı noktadan çıkış alınarak voltaj indirgenmesi gerçekleşmektedir. Şekil 2.21'de tasarlanan sistemin genel devre şeması gösterilmiştir.

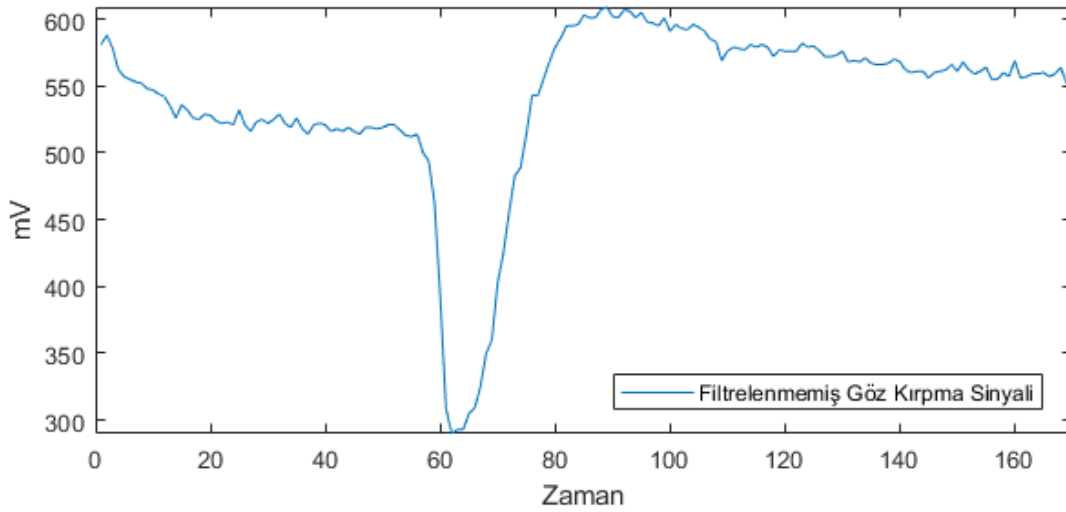
$$V_{\text{çıkış}} = V_{\text{giriş}} \frac{R_2}{R_1 + R_2} \quad (2.16)$$



Şekil 2.21. Tasarlanan sistemin genel devre şeması.


ESP 8266-12E programlanarak analog girişinden aldığı verileri ESP-01 kablosuz haberleşme modülü kullanılarak tasarlanan kablosuz alıcıya Wi-Fi direkt bağlantısı üzerinden göndermesi sağlanmıştır. Wi-Fi direkt, iki Wi-Fi modülünün birbirleri ile doğrudan seri haberleşmelerini sağlamaktadır. Modüllerin birbirleri dışındaki kablosuz haberleşme araçları tarafından görünmemeleri ve TCP bağlantısı kurarak veri kaybı yaşamadan haberleşmeleri için ideal bir yöntemdir.

Sinyallerin bilgisayara aktarılması için Python programlama dili kullanılarak ESP-01 kablosuz haberleşme modülü ile tasarlanan kablosuz alıcıdan elde edilen sinyallerin anlık olarak işlenebileceği ve kaydedilebileceği bir masaüstü uygulaması geliştirilmiştir. Uygulama üzerinde sinyallere anlık olarak yazılımsal alçak geçiren filtre uygulanmıştır ve kullanıcı arayüzünde filtrelenmiş sinyalin yanı sıra FFT ve histogram grafiklerine de yer verilmiştir. Yazılımsal alçak geçiren filtrenin kesme frekansı 100 Hz olarak belirlenmiştir. Yazılımsal filtre 4 katmanlı olacak şekilde programlanmıştır. Bu sayede donanımsal RC pasif alçak geçiren filtreden çıkan sinyaller ile birlikte toplamda 5 katmanlı bir alçak geçiren filtre oluşturulmuştur. Şekil 2.22'de yazılımsal alçak geçiren filtre uygulanmayan EEG sinyalinin gerçek zamanlı grafiği gösterilmiştir. Sinyalde yüksek frekanslı gürültüler bulunduğu açıkça görülmektedir.



Şekil 2.22. Yazılımsal filtreleme işleminden geçirilmeyen EEG sinyalinin grafiği.

Şekil 2.23'te Şekil 2.22'deki sinyal ile eşzamanlı olarak alınan ve yazılımsal alçak geçiren filtre uygulanarak gürültülerden arındırılan EEG sinyalinin grafiği gösterilmiştir.



Şekil 2.23. Yazılımsal filtreleme işleminden geçirilen EEG sinyalinin grafiği.

Sinyaller üzerinde ilk olarak FFT ile frekans analizi yapılmaktadır. FFT ile frekans spektrumu çıkarılan sinyallerin her 4 Hz'lik veri bloğu için öznitelik çıkarımları yapılmaktadır. Bunun nedeni delta, teta, alfa, beta ve gama dalgalarının ayrımını yapabilmek ve beyinsel aktivitelerin hangi dalga grubunda ne kadar etkili olduğunu anlayabilmektir. Bu sayede farklı aktiviteler sırasında kaydedilen sinyallerin öznitelikleri arasında farklar oluşacağından sınıflandırma başarımının artması hedeflenmiştir.

2.12.1 Öznitelik Çıkarımı

FFT uygulanan sinyallerin her 4 Hz'lik bloğu için 6 adet öznitelik çıkarım yöntemi uygulanmıştır. Bu yöntemler sırasıyla veri bloğunun ortalaması, maksimum noktası, minimum noktası, standart sapması, çarpıklık değeri ve basıklık değeridir (Alptürk & Kutlu, 2020). Ortalama, minimum nokta ve maksimum nokta belirlendikten sonra standart sapma hesaplanarak öznitelikler dizisine eklenmektedir. Eş. 2.17'de 4 Hz'lik blok için kullanılan standart sapma genel denklemi gösterilmiştir (Spiegel & Stephens, 1999). Eş. 2.17'de belirtilen formülde n , veri kümesindeki eleman sayısını, x_i , i indisindeki değeri, \bar{x} ise veri kümesinin aritmetik ortalamasını temsil etmektedir.

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i + \bar{x})^2} \quad (2.17)$$

Çarpıklık değeri Eş. 2.18'de gösterilen denklem ile hesaplanmaktadır. Burada \bar{x} örneklem ortalamasını, x_i i indisinde bulunan değeri, m_3 örneklem üçüncü merkez momentini ve m_2 örneklem varyansını temsil etmektedir (Spiegel & Stephens, 1999).

$$g_1 = \frac{m_3}{m_2^{\frac{3}{2}}} = \frac{\sqrt{n} \sum_{i=1}^n (x_i + \bar{x})^3}{(\sum_{i=1}^n (x_i + \bar{x})^2)^{\frac{3}{2}}} \quad (2.18)$$

Son öznitelik olarak basıklık değeri hesaplanmaktadır ve öznitelikler dizisine eklenmektedir. Basıklık değeri Eş. 2.19'da gösterilen denklem ile hesaplanmaktadır. Burada m_4 örneklem ortalaması etrafındaki örneklem dördüncü momentini, m_2 ise ortalama etrafındaki ikinci momenti temsil etmektedir. Ayrıca diğer denklemlerle benzer şekilde \bar{x} örneklem ortalamasını ve x_i i indisinde bulunan değeri temsil etmektedir (Spiegel & Stephens, 1999).

$$g_2 = \frac{m_4}{m_2^2} - 3 = \frac{n \sum_{i=1}^n (x_i + \bar{x})^4}{(\sum_{i=1}^n (x_i + \bar{x})^2)^2} - 3 \quad (2.19)$$

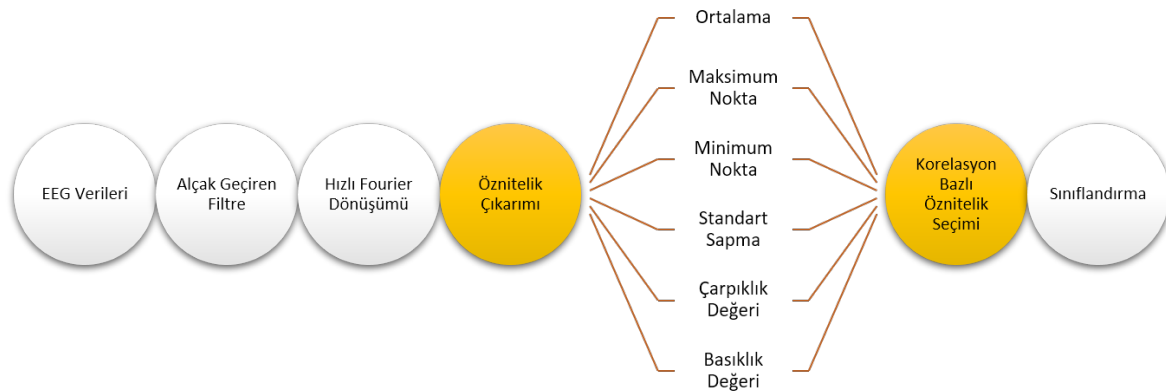
Öznitelik çıkarımları FFT veri setinde bulunan 100 Hz'lik verinin her 4 Hz'lik bloğu için arka arkaya yapılmaktadır. Elde edilen öznitelikler bir dizide tutulmaktadır ve sınıflandırma

fonksiyonlarına gönderilmektedir. Her 1 saniyelik EEG sinyali için 100 FFT verisi oluşmaktadır. Bunun sebebi kesme frekansının 100 Hz olarak belirtilmiş olmasıdır. 4 Hz'lik veri blokları ayrıştırıldığında her saniye için 25 adet veri bloğu oluşmaktadır. Her veri bloğu için 6 öznitelik çıkarıldığı için toplamda saniyedeki EEG kaydı başına 150 öznitelik elde edilmektedir. Bu aşamadan sonra korelasyon bazlı öznitelik seçimi yapılmaktadır ve 0,7 olarak belirlenen eşik değerinden daha güçlü öznitelikler sınıflandırma için seçilmektedir. Çizelge 2.2'de 10 öznitelik için korelasyon matrisi ve eşik değerinden daha güçlü olan özniteliklerin seçimi gösterilmiştir.

Çizelge 2.2. Korelasyon bazlı öznitelik seçimi tablosu.

Öznitelik	1	2	3	4	5	6	7	8	9	10
1	1,000	0,674	0,959	0,990	0,763	0,671	0,769	0,655	0,729	0,706
2	0,674	1,000	0,794	0,572	0,802	0,794	0,837	0,617	0,709	0,733
3	0,959	0,794	1,000	0,919	0,842	0,743	0,851	0,722	0,792	0,756
4	0,990	0,572	0,919	1,000	0,702	0,600	0,701	0,617	0,678	0,650
5	0,763	0,802	0,842	0,702	1,000	0,808	0,962	0,905	0,859	0,730
6	0,671	0,794	0,743	0,600	0,808	1,000	0,918	0,485	0,791	0,756
7	0,769	0,837	0,851	0,701	0,962	0,918	1,000	0,770	0,869	0,774
8	0,655	0,617	0,722	0,617	0,905	0,485	0,770	1,000	0,714	0,540
9	0,729	0,709	0,792	0,678	0,859	0,791	0,869	0,714	1,000	0,826
10	0,706	0,733	0,756	0,650	0,730	0,756	0,774	0,540	0,826	1,000


Güçlü özniteliklerin seçimi sonrasında elde edilen yeni öznitelik kümesi KNN ve DVM ve ÇKA algoritmaları ile sınıflandırılmıştır ve sonuçlar birbiriyle karşılaştırılmıştır. Şekil 2.24'te sinyaller bilgisayara aktarıldıktan sonra uygulanan tüm işlemlerin aşamaları gösterilmiştir.



Şekil 2.24. EEG sinyallerine uygulanan yazılımsal işlemler.


3. BULGULAR

Bu tez çalışmasında 4 kadın ve 7 erkek olmak üzere 20-26 yaş aralığındaki 11 sağlıklı gönüllüden, kendilerinden istenen 3 durum (dinlenme durumu, göz kırpma ve gülme durumu) sırasında; her durumdan 10 tekrar olmak üzere 120 Hz örnekleme frekansına sahip toplamda 330 EEG sinyali verisi toplanmıştır. Sinyallerin özniteliklerinin çıkarılması, korelasyon bazlı güçlü özniteliklerin seçiminin yapılması ve sınıflandırılması sonucunda elde edilen veriler birbirleriyle karşılaştırılmıştır. Karşılaştırmada ham verilerin, FFT uygulanarak öznitelikleri çıkarılmış verilerin ve korelasyon bazlı güçlü özniteliklerin seçiminden sonra elde edilen verilerin sınıflandırma sonuçları kullanılmıştır. Şekil 3.1’de işlenmemiş EEG verilerinin doğrudan 3 sınıflandırma yöntemi ile sınıflandırılmasıyla elde edilen sonuçlar gösterilmiştir. Üç yöntemde de gülme durumunun doğru sınıflandırma oranının oldukça düşük olduğu gözlemlenmiştir. Göz kırpma durumunun başarımlar yüzdesi de kabul edilebilir düzeyin altında kalmıştır. %75 ve üzeri başarımlar yüzdesine sahip olan tek sınıf dinlenme durumu olmuştur. Dinlenme durumunda sınıflandırma başarımlarını en yüksek algoritma KNN algoritması olmuştur.



Şekil 3.1. İşlenmemiş EEG verilerinin sınıflandırma sonuçları.


Şekil 3.2’de işlenmemiş verilerde korelasyon bazlı öznitelik seçimi yapılarak sınıflandırma gerçekleştirildiğinde ortaya çıkan başarımlar yüzdeleri gösterilmiştir.



Şekil 3.2. İşlenmemiş verilerde korelasyon bazlı sınıflandırma sonuçları.

İşlenmemiş verilerde korelasyon bazlı öznelik seçiminin de başarımlarında etkisinin hiç olmadığı görülmüştür.

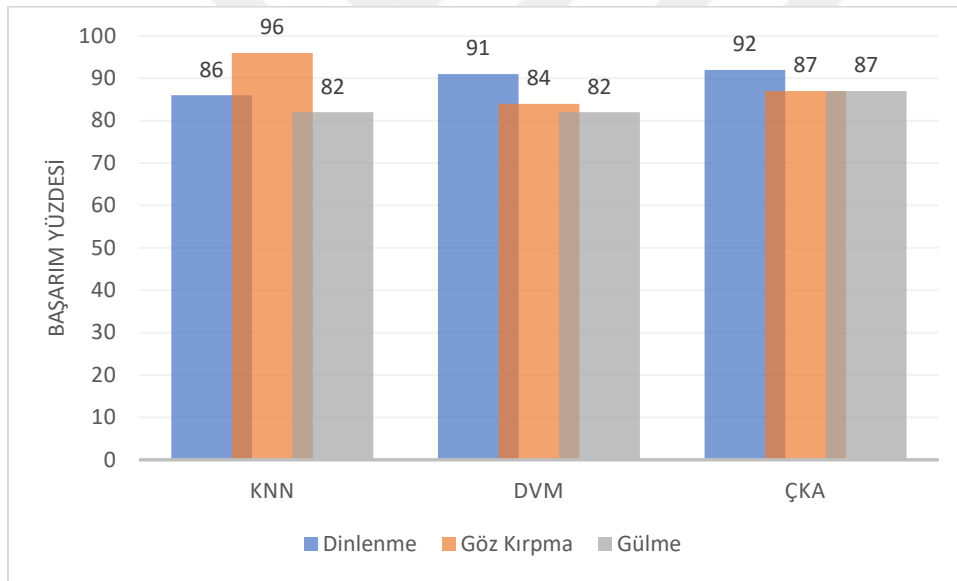
Elde edilen bulgular doğrultusunda EEG verilerinde filtreleme yapılmadan ve öznelik çıkarımı gerçekleştirilmeden yapılan sınıflandırma işlemlerinin başarımları oldukça düşük bulunmuştur.



Şekil 3.3. Filtrelenmiş EEG verilerinin FFT uygulanarak özneliklerinin çıkarılması ile yapılan sınıflandırma sonuçları.

İşlenmemiş EEG sinyallerinin yazılımsal alçak geçiren filtre ile filtrelenmesi ve Şekil 2.24'te gösterilen öznelik çıkarma yöntemleri ile özneliklerinin çıkarılmasının ardından yapılan sınıflandırma sonuçları Şekil 3.3'te gösterilmiştir. Başarımda işlenmemiş verilere oranla yüksek bir artış görülmüştür. Üç sınıflandırma algoritmasında da işlenmemiş verilerde oldukça düşük başarımlar görülen gülme durumu sinyallerinin sınıflandırma başarımları büyük artış göstermiştir.

Öznelik çıkarma yöntemlerinin uygulanmasının ardından korelasyon bazlı öznelik seçimi ile güçlü öznelikler seçilerek halihazırda kabul edilebilir düzeyde olan başarımların daha da yükseltilmesi amaçlanmıştır. Şekil 3.4'te bu tez kapsamında önerilen öznelik seçim ve sınıflandırma yöntemlerinin tümü kullanılarak elde edilen başarımların sonuçları gösterilmiştir.



Şekil 3.4. İşlenmiş EEG verilerinin özneliklerinin korelasyon bazlı öznelik seçim algoritması ile seçilen güçlü özneliklerinin sınıflandırma sonuçları.


Elde edilen bulgular doğrultusunda kullanılan yöntemlerin sınıflandırma başarımlarını oldukça arttırdığı gözlemlenmiştir. Tüm işlemlerin ardından 3 sınıflandırma algoritmasında da en düşük başarımlar %82 olarak ölçülmüştür. Çizelge 3.1'de bu tez çalışmasında kullanılan sınıflandırma algoritmalarının nihai sınıflandırma başarımları gösterilmiştir. Bu başarımlara göre en yüksek başarıma sahip sınıflandırma algoritması ÇKA olmuştur. En düşük başarıma sahip durum gülme durumu olmuştur. Bunun en büyük nedeni gülme

sırasında oldukça fazla kasta kasılma meydana gelmesi ve EEG sinyallerinin tespitini zorlaştırılmasıdır.

Çizelge 3.1. Sınıflandırma algoritmalarının nihai başarımlarının karşılaştırılması.


Oranlar/Algoritmalar	KNN	DVM	ÇKA
En Düşük	%82	%82	%87
Ortalama	%88	%85,7	%88,7
En Yüksek	%96	%91	%92

Elde edilen sonuçlar doğrultusunda tasarlanan cihazın EEG sinyallerinin toplanması ve işlenmesi konusunda oldukça kullanışlı olduğu gözlemlenmiştir. Bununla birlikte güvenilirliği kabul görmüş güncel bir EEG kayıt cihazı olan Emotic Epoc+ ile karşılaştırma yapılması adına her iki cihazdan da yumruk sıkma eylemi sırasında sinyaller kaydedilmiştir ve hem zaman ekseninde hem de frekans ekseninde incelenmiştir. Yumruk sıkma eylemi bir motor hareketi olduğundan ve beynin frontal lobu tarafından yönetildiğinden bu eylem seçilmiştir. Şekil 3.5'te her iki cihazdan alınan sinyallerin zaman eksenindeki karşılaştırması gösterilmiştir.



Şekil 3.5. Emotiv Epoc+ ve tasarlanan EEG kayıt cihazı ile yumruk sıkma hareketi sırasında kaydedilen sinyallerin zaman eksenindeki karşılaştırması.

Her ne kadar zaman eksenindeki iki grafikte de sinyallerin genliklerinin ve frekanslarının benzerliđi grlyor olsa da frekans ekseninde de inceleme gerekleřtirilmesi, karřılařtırmanın dođruluđu aısından nem arz etmektedir. Bu nedenle iki sinyalin de FFT'si alınarak frekans bandında analizi yapılmıřtır (řekil 3.6).




řekil 3.6. Emotiv EPOC+ ve tasarlanan EEG kayıt cihazı ile yumruk sıkma hareketi sırasında kaydedilen sinyallerin FFT'si alınarak frekans eksenindeki karřılařtırması.

İki sinyalin frekans analizi yapıldıđında aynı eylem iin benzer sonular rettiđi gzlenmiřtir. Yumruk sıkma hareketi tm motor hareketleri gibi beta dalgaları rettiđinden 13-30 Hz. bandındaki sinyallerde hareketlenmeler olduđu her iki cihazdan alınan kayıtlarda net bir řekilde grlmřtr. Bu bulgular dođrultusunda tasarlanan cihazın frontal lobda iřlenen verilerin tespitinde ve incelenmesinde kullanılabilirliđi dođrulanmıřtır.

4. SONUÇ VE ÖNERİLER

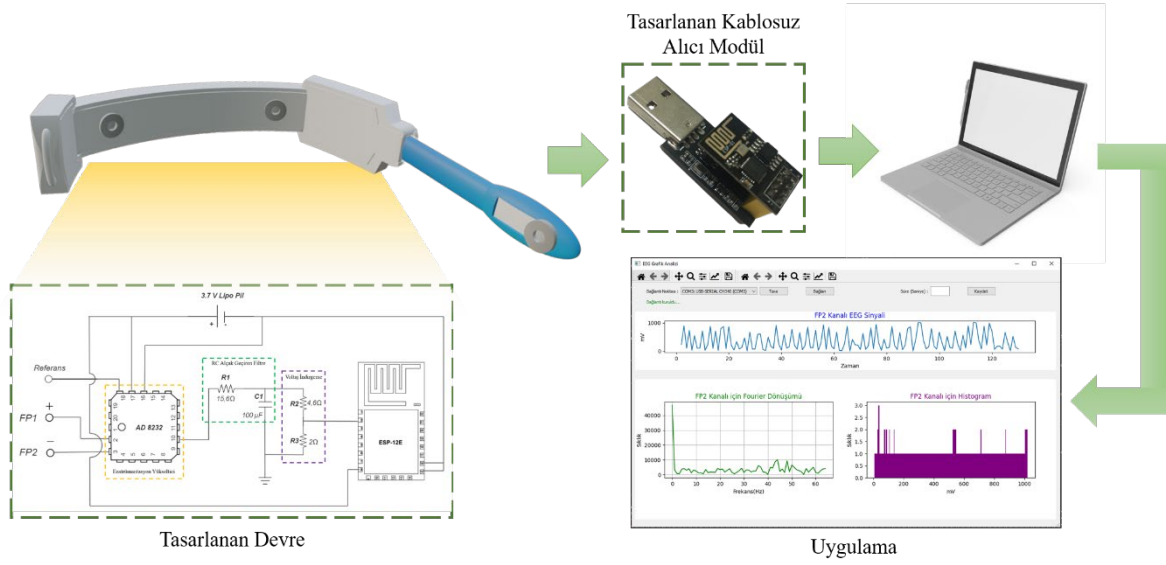
Bu tez kapsamında taşınabilir bir EEG ölçüm ve kayıt cihazı tasarımı sunulmuştur ve tasarlanan cihaz uygulamalar ile desteklenmiştir. Kafatası üzerindeki FP1 ve FP2 kanallarının faz farkına dayalı sinyal toplama özelliğinde olan EEG cihazı 1 referans girişi olacak şekilde tasarlanmıştır. 3 elektrotlu ve tek kanallı yapıya sahiptir. Donanımsal RC pasif alçak geçiren filtre ile gürültülü sinyal oluşmasının önüne geçmektedir. Tasarlanan cihazın üç boyutlu tasarım modeli Şekil 4.1’de gösterilmiştir. Alın bölgesindeki FP1 ve FP2 kanallarına denk gelecek şekilde eklenen iki elektrot ve sağ kulak arkasındaki P10 kanalına denk gelecek şekilde bir referans elektrodu cihaza entegre edilmiştir. Şekil 4.2’de ESP-01 kullanılarak tasarlanan kablosuz alıcı modül ve Şekil 4.3’te cihazın donanım ve uygulama katmanlarının genel diyagramı gösterilmiştir.



Şekil 4.1. Tasarlanan cihazın 3 boyutlu modeli.



Şekil 4.2. ESP-01 kullanılarak tasarlanan kablosuz alıcı modül.



Şekil 4.3. Tasarlanan cihazın ve uygulamanın tüm aşamalarını gösteren diyagram.

EEG sinyallerinin sınıflandırılması için işlenmemiş verilerin yazılımsal alçak geçiren bir filtre ile gürültülerden arındırılması, ardından FFT uygulanarak frekans bloğu bazında öznitelik çıkarılması ve korelasyon bazlı öznitelik seçimi ile güçlü özniteliklerin seçilerek sınıflandırma başarımının yükseltilmesi için 3 aşamalı bir yöntem önerilmiştir. Önerilen yöntem ile elde edilen verilerin KNN, DVM ve ÇKA algoritmaları ile sınıflandırılması sonucunda başarımların oldukça yükseldiği gösterilmiştir.

Üretilen taşınabilir EEG ölçüm cihazının mimik ve motor hareketleri gibi frontal loba bağlı işlevlerin gerçekleştirilmesi sırasında topladığı sinyallerin anlamlı olduğu önerilen yöntem ve uygulanan algoritmalarla kanıtlanmıştır.

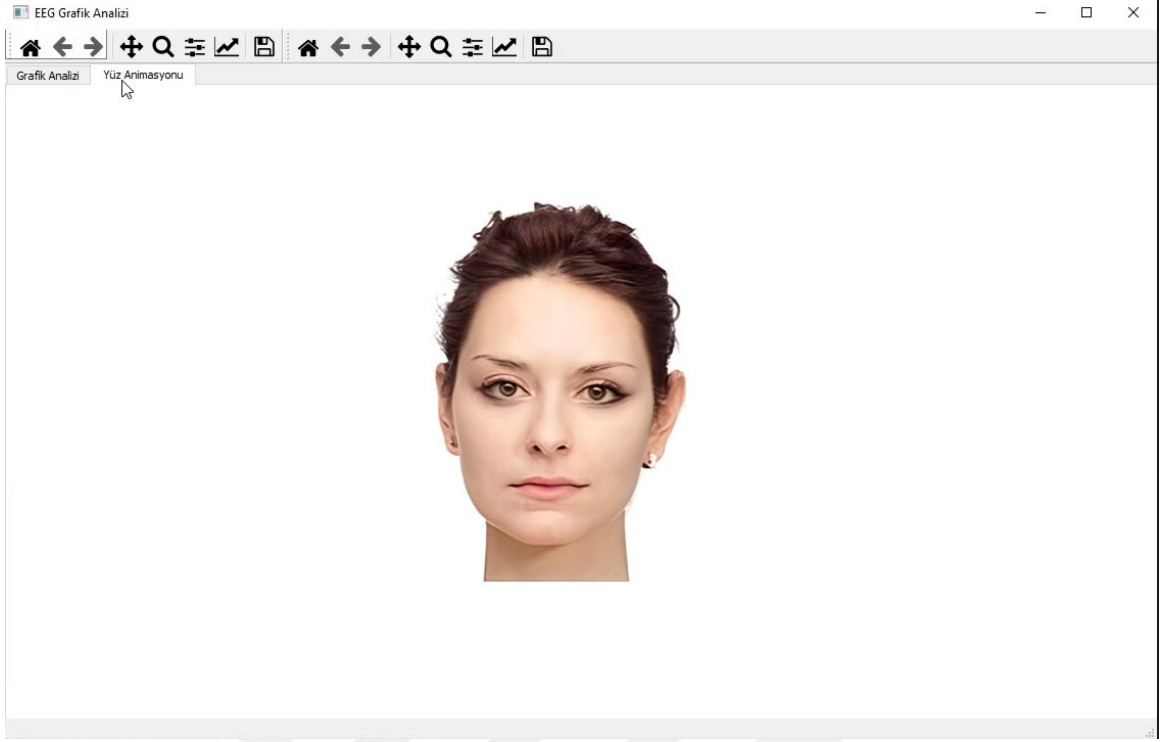
EEG sinyallerinin incelenmesi için tasarlanan kullanıcı arayüzü üzerinde taşınabilir EEG cihazından anlık olarak aktarılan ve filtrelenen sinyallerin grafiği, FFT uygulandıktan sonraki frekans bandı grafiği ve histogram grafiği gösterilmektedir. Cihaz ile bağlantı durumu da arayüz üzerinde gösterilmekte olup bağlantı devam ettiği sürece aktarılan verilerin saniye cinsinden belirtilen süre boyunca kaydedilmesine olanak tanınmaktadır. Şekil 4.4'te kullanıcı arayüzünün "Grafik Analizi" sekmesi gösterilmiştir.



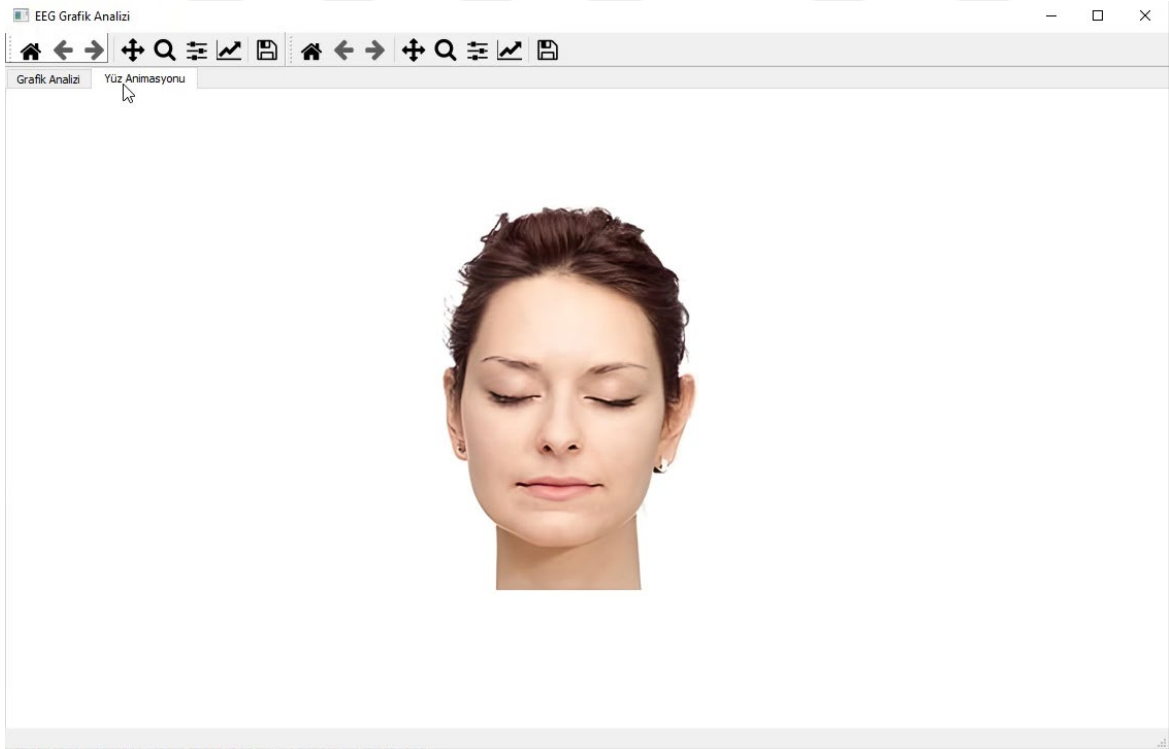
Şekil 4.4. Taşınabilir EEG kayıt cihazı için tasarlanan kullanıcı arayüzü.

Arayüz üzerinde anlık sınıflandırma yapılarak duygu ve mimik analizi de gerçekleştirilmektedir. Yüz animasyonu sekmesine geçildiğinde uygulama, sınıflandırmaları otomatik olarak başlatıp EEG cihazının bağlı olduğu kişinin yüz mimiklerini en doğru şekilde tahmin etmeye çalışmaktadır. Şekil 4.5'te yüz animasyonu sekmesinde stabil durumda ve gözler açık şekilde alınan sinyallerin anlık sonuçları gösterilmiştir.

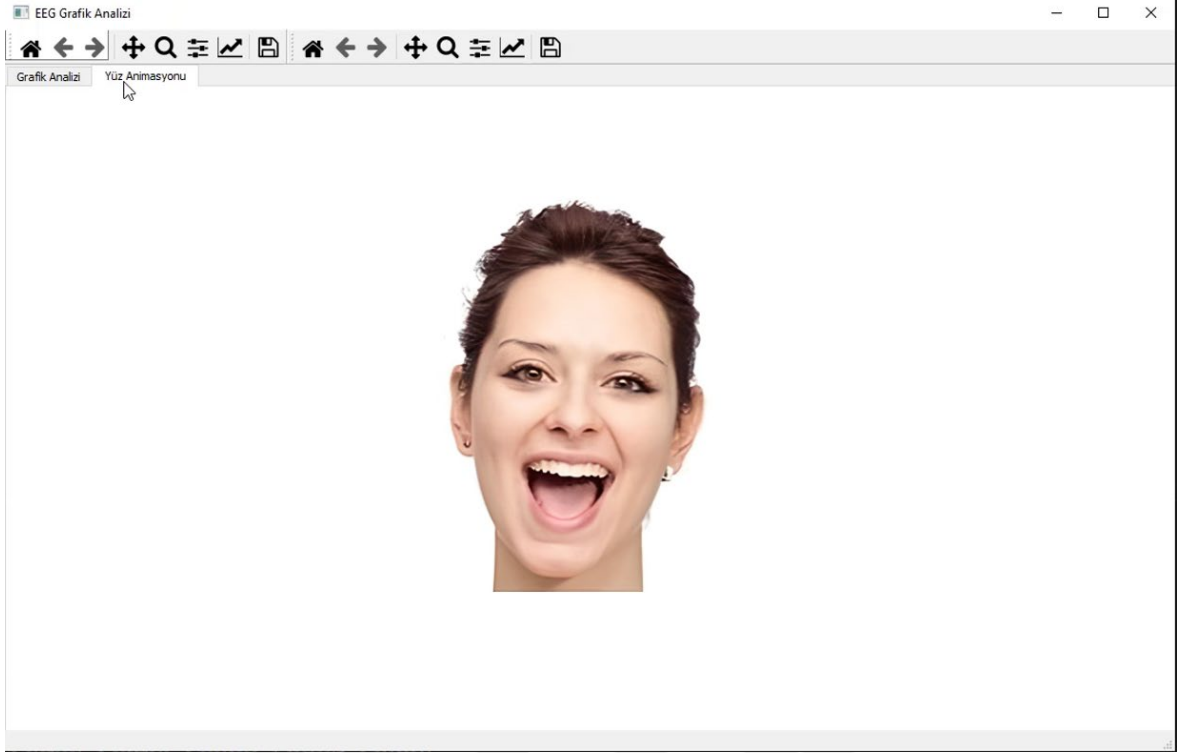
Şekil 4.6'da dinlenme moduna geçerken gözlerin kapatılması sırasında ve Şekil 4.7'de gülme eylemi sırasında yapılan sinyal analizi ile uygulamanın verdiği sonuç gösterilmiştir. Eylemler her bir saniyede alınan EEG sinyallerinin işlenerek mimik hareketinin sınıflandırma sonucunda tespit edilmesiyle uygulamanın yüz animasyonu sekmesinde gösterilmektedir.



Şekil 4.5. Stabil ve gözler açık durumdayken mimik analizi.



Şekil 4.6. Dinlenme modunda ve gözler kapalı durumdayken mimik analizi.



Şekil 4.7. Gülme eylemi gerçekleştirilirken mimik analizi.

KAYNAKLAR

- Açıl, T. (2019). *Güncel Makine Öğrenmesi Teknikleri ile İris Görüntülerinden Cinsiyet Analizi*. (Master's thesis, İskenderun Teknik Üniversitesi/Mühendislik ve Fen Bilimleri Enstitüsü/Elektrik-Elektronik Mühendisliği Anabilim Dalı).
- Al-dabag, M. L., & Özkurt, N. (2019). EEG motor movement classification based on cross-correlation with effective channel. *Signal, Image and Video Processing*(13), 567–573.
- Alotaiby, T., Abd El-Samie, F., Alshebeili, S., & Ahmad , I. (2015). A review of channel selection algorithms for EEG signal processing. *EURASIP Journal on Advances in Signal Processing*(66).
- Alptürk, E. K., & Kutlu, Y. (2020). Analysis of Relation between Motor Activity and Imaginary EEG Records. *Journal of Artificial Intellicence with Application*(1), 5-10.
- Ayhan, S., & Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi University Journal of Economics and Administrative Sciences*, 1(9), 175-201.
- Bhattacharyya, S., Konar, A., & Tibarewala , D. (2014). Motor imagery, P300 and error-related EEG-based robot arm movement control for rehabilitation purpose. *International Federation for Medical and Biological Engineering*(52), 1007–1017.
- Biyopotansiyel Yükselteçler. (2012). *Biyomedikal Cihaz Teknolojileri*. içinde Ankara: Milli Eğitim Bakanlığı.
- Bright, D., Nair, A., Salvekar, D., & Bhisikar, S. (2016). EEG-based brain controlled prosthetic arm. *Conference on Advances in Signal Processing (CASP)* (s. 479-483). Pune, Hindistan: IEEE.
- Buerkle, A., Eaton, W., Lohse, N., Bamber, T., & Ferreira, P. (2021). EEG based arm movement intention recognition towards enhanced safety in symbiotic Human-Robot Collaboration. *Robotics and Computer-Integrated Manufacturing*(70).
- Chiron, C., Jambaque, I., Nabbout, R., Lounes, R., Syrota, A., & Dulac, O. (1997). The right brain hemisphere is dominant in human infants. *Brain: a journal of neurology*, 6(120), 1057-1065.
- Cybenko , G. (1989, Aralık). Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals and Systems*(2), 303–314.
- Delgado Saa, J., & Çetin, M. (2012). A latent discriminative model-based approach for classification of imaginary motor tasks from EEG data. *Journal of Neural Engineering*(9).
- Dongarra, J., & Sullivan, F. (2000, Ocak). Guest Editors Introduction to the top 10 algorithms. *Computing in Science & Engineering*, 2(1), 22-23.
- Elektrotlar. (2011). *Biyomedikal Cihaz Teknolojileri* (s. 5-21). içinde Ankara: Milli Eğitim Bakanlığı.

- ESP-01 802.11 b/g/n Wi-Fi Module V1.2.* (2017). Ağustos 04, 2022 tarihinde Ai-Thinker: https://docs.ai-thinker.com/_media/esp8266/docs/esp-01_product_specification_en.pdf adresinden alındı
- ESP-12E WiFi Module.* (2015). Ağustos 04, 2022 tarihinde Ai-Thinker: https://docs.ai-thinker.com/_media/esp8266/docs/esp12e_datasheet.pdf adresinden alındı
- Gamboa, H. (2005, Aralık). *Electroencephalography*. Temmuz 22, 2022 tarihinde Wikipedia: <https://en.wikipedia.org/wiki/Electroencephalography> adresinden alındı
- Gao, Z., Dang, W., Wang, X., Hong, X., Hou, L., Ma, K., & Perc. (2021). Complex networks and deep learning for EEG signal analysis. *Cognitive Neurodynamics*, 3(15), 369-388.
- Güntekin, B., Emek-Savaş, D. D., Kurt, P., Yener, G. G., & Başar, E. (2013). Beta oscillatory responses in healthy subjects and subjects with mild. *NeuroImage: Clinical*, 39-46.
- Hanan, Gunawan, A., & Sumadiyasa, M. (2019). ater Level Detection System Based on Ultrasonic Sensors HC-SR04 and ESP8266-12 Modules with Telegram and Buzzer Communication Media. *Instrumentation Mesure Métrologie*, 8(3), 305-309.
- Hari Krishna, D., Pasha, I., & Satya Savithri, T. (2016). Classification of EEG Motor Imagery Multi Class Signals Based on Cross Correlation. *Procedia Computer Science*(85), 490-495.
- Heideman, M. T., Johnson, D. H., & Burrus, C. S. (1984). Gauss and the history of the fast Fourier transform. *IEEE ASSP Magazine*, 1(4), 14-21.
- İnce, R., Adanır, S. S., & Sevmez, F. (2021). The inventor of electroencephalography (EEG): Hans Berger (1873–1941). *Child's Nervous System*, 37(9), 2723-2724.
- Inductiveload. (2007). *Plot of the gain of Butterworth low-pass filters*. Ağustos 14, 2022 tarihinde <https://commons.wikimedia.org/w/index.php?curid=2940360> adresinden alındı
- Kavzoğlu, T., & Çölkesen, İ. (2010). Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. *Harita Dergisi*, 7(144), 73-82.
- Kumar, J. S., & Bhuvaneswari, P. (2012). Analysis of Electroencephalography (EEG) signals and its categorization—a study. *Procedia engineering*(38), 2525-2536.
- Lee, D. J., Kulubya, E., Goldin, P., Goodarzi, A., & Girgis, F. (2018). Review of the Neural Oscillations Underlying Meditation. *Frontiers in neuroscience*(12), 178.
- Low Cost Low Power Instrumentation Amplifier AD620 Data Sheet.* (2011). Analog Devices: <https://www.analog.com/media/en/technical-documentation/data-sheets/ad620.pdf> adresinden alındı
- Luan, B., Sun, M., & Jia, W. (2012, Mart). Portable amplifier design for a novel EEG monitor in point-of-care applications. *38th Annual Northeast Bioengineering Conference (NEBEC)*, 388-389.

- Maksimenko, V. A., Pavlov, A., Runnova, A. E., Nedaivozov, V., Grubov, V., Koronovslii, A., & Hramov, A. E. (2018). Nonlinear analysis of brain activity, associated with motor action and motor imaginary in untrained subjects. *Nonlinear Dynamics*, 4(91), 2803-2817.
- Metlek, S., & Kayaalp, K. (2020). *Makine Öğrenmesinde, Teoriden Örnek MATLAB Uygulamalarına Kadar Destek Vektör Makineleri*. İktisad Yayınevi.
- Miles, J., & Banyard, P. (2007). *Understanding and Using Statistics in Psychology: A Practical Introduction*. SAGE.
- Moradi, M., Dousti, M., & Torkzadeh, P. (2021, Nisan 28). Designing a Low-Power LNA and Filter for Portable EEG Acquisition Applications. *IEEE Access*(9), 71968 - 71978.
- Murtagh, F. (1991). Multilayer perceptrons for classification and regression. *Neurocomputing*(2), 183-197.
- Oostenveld, R., & Praamstra, P. (2001). The five percent electrode system for high-resolution EEG and ERP measurements. *Clinical Neurophysiology*, 112(4), 713-719.
- Pattnaik, S., Dash, M., & Sabut, S. K. (2016). DWT-based feature extraction and classification for motor imaginary EEG signals. *International Conference on Systems in Medicine and Biology (ICSMB)* (s. 186-201). IEEE.
- Pfurtscheller, G., Stancfik Jr., A., & Neuper, C. (1996). Post-movement beta synchronization. A correlate of an idling moto rearea? *Electroencephalographyand clinicalNeurophysiology*(98), 281-293.
- Schloegl, A., Neuper, C., & Pfurtscheller, G. (1997). Subject specific EEG patterns during motor imaginary [sic.: for imaginary read imagery]. *Proceedings of the 19th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. 'Magnificent Milestones and Emerging Opportunities in Medical Engineering'*. Chicago: IEEE.
- Shedeed, H., Issa, M., & El-sayed, S. (2013). Brain EEG signal processing for controlling a robotic arm. *8th International Conference on Computer Engineering & Systems (ICCES)* (s. 152-157). IEEE.
- Single-Lead, Heart Rate Monitor Front End AD8232 Data Sheet*. (2020). Temmuz 30, 2022 tarihinde Analog Devices: <https://www.analog.com/media/en/technical-documentation/data-sheets/ad8232.pdf> adresinden alındı
- Spiegel, M. R., & Stephens, L. J. (1999). *Schaum's outline of theory and problems of statistics*. Erlangga.
- Tudor, M., Tudor, K., & Tudor, L. (2005). Hans Berger (1873-1941)--the history of electroencephalography. *Acta medica Croatica: casopis Hravatske akademije medicinskih znanosti*, 59(4), 307-313.
- Tülay, E. E. (2009, Haziran). *BEYİN ELEKTRİKSEL AKTİVİTESİNİN ÖLÇÜMÜ VE SİNYAL ANALİZİ*. (Doctoral dissertation, İstanbul Kültür Üniversitesi/Fen Bilimleri Enstitüsü/Bilgisayar Mühendisliği Anabilim Dalı).

- Walter, W. (1936). THE LOCATION OF CEREBRAL TUMOURS BY ELECTRO-ENCEPHALOGRAPHY. *The Lancet*, 228(5893), 305-308.
- Walter, W., & Dovey, V. (1944). Electro-Encephalography in Cases of Sub-Cortical Tumour. *Journal of neurology, neurosurgery, and psychiatry*, 7(57), 57-65.
- Yong, X., & Menon, C. (2015). EEG Classification of Different Imaginary Movements within the Same Limb. *PLoS ONE*, 4(10).
- Zhang, L., Guo, X.-j., Wu, X.-p., & Zhou, B.-y. (2013, Aralık). Low-cost circuit design of EEG signal acquisition for the brain-computer interface system. *6th International Conference on Biomedical Engineering and Informatics*, 245-250.



EKLER

(Ekler Tezin arka kapağında CD ortamında verilmiştir.)



DİZİN

A

Alfa · 2, 3

B

basıklık · 34

Beta · 2, 3

Beyin · 1, 9

Bode · 18, 27

Ç

Çarpıklık · 34

D

Delta · 2

direnç · 17, 18, 26

DVM · iv, xii, 10, 11, 12, 35, 39

E

EEG · 1, iv, v, xii, 1, 2, 4, 5, 7, 8, 9,
10, 11, 12, 13, 26, 32, 33, 35,
36, 37, 38, 39, 41, 42, 43

Elektroensefalografi · iv, xii, 1

elektrot · 4, 5, 7, 8, 9, 14, 19

enstrümantasyon yükseltici · iv,
6, 13, 14, 26

ESP · 15, 16, 17, 31, 32

F

Farad · 26

FFT · iv, v, xii, 9, 12, 32, 33, 34,
36, 37, 42

Filtre · 6, 17

G

Gama · 2, 4

K

Kazanç · 6

kesme frekansı · 13, 17, 18, 26,
32

KNN · iv, v, 19, 20, 35, 36, 39, 42

kondansatör · 17, 26

N

Naive Bayes · 39

O

op-amp · 17

ortalama · 10, 11, 34

Ö

öznitelik · 9, 11, 33, 34, 35, 36,
37, 38

S

standart sapma · 11, 34

T

Teta · 2, 3

W

Wi-Fi · 15, 32



TEKNOVERSİTE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

