



**T.C.  
ONDOKUZ MAYIS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
AKILLI SİSTEMLER ANA BİLİM DALI**

# **EOG TABANLI İNSAN BİLGİSAYAR ARABİRİM TASARIMI**

Yüksek Lisans Tezi

**Recep ARSLAN**

Danışman  
**Dr. Öğr. Üyesi Selim ARAS**

SAMSUN  
2022

T.C.  
ONDOKUZ MAYIS ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ  
AKILLI SİSTEMLER ANA BİLİM DALI



## EOG TABANLI İNSAN BİLGİSAYAR ARABİRİM TASARIMI

Yüksek Lisans Tezi

**Recep ARSLAN**

Danışman

**Dr. Öğr. Üyesi Selim ARAS**

SAMSUN  
2022

## TEZ KABUL VE ONAYI

**Recep ARSLAN** tarafından, **Dr. Öğr. Üyesi Selim ARAS** danışmanlığında hazırlanan “**EOG TABANLI İNSAN BİLGİSAYAR ARABİRİM TASARIMI**” başlıklı bu çalışma, jürimiz tarafından 10.5.2022 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	<b>Unvanı Adı Soyadı</b> <b>Üniversitesi</b> <b>Ana Bilim/Ana Sanat Dalı</b>	<b>İmza</b>	<b>Sonuç</b>
<b>Başkan</b>	Prof. Dr. Mehmet Serhat ODABAŞ Ondokuz Mayıs Üniversitesi Akıllı Sistemler Ana Bilim Dalı		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
<b>Üye</b>	Dr. Öğr. Üyesi Selim ARAS Ondokuz Mayıs Üniversitesi Akıllı Sistemler Ana Bilim Dalı		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
<b>Üye</b>	Dr. Öğr. Üyesi Nurettin ŞENYER Samsun Üniversitesi Yazılım Mühendisliği Ana Bilim Dalı		<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

ONAY

... / ... / ...

Prof. Dr. Ali BOLAT  
Enstitü Müdürü

## BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Yüksek Lisans tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi ?

Evet  (Gerekli ise ekler kısmına ekleyiniz)

Hayır

İmza

... / ... / 20...

Recep ARSLAN

## TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

**Tez Başlığı :** EOG TABANLI İNSAN BİLGİSAYAR ARABİRİM TASARIMI

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 22/8/2022 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 17

Tek kaynak oranı : % 3 çıkmıştır.

İmza

... / ... / 20...

Dr. Öğr. Üyesi Selim ARAS

# ÖZET

## EOG TABANLI İNSAN BİLGİSAYAR ARABİRİM TASARIMI

Recep ARSLAN  
Ondokuz Mayıs Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Akıllı Sistemler Ana Bilim Dalı  
Yüksek Lisans, Ağustos/2022  
Danışman: Dr. Öğr. Üyesi Selim ARAS

Bilgisayarların kullanılmaya başlamasından bu yana İnsan Bilgisayar Arabirimi (İBA) üzerine yapılan çalışmalar da artmıştır. İBA, insanların yaşamlarını kolaylaştırmada, birçok işi hızlıca sonuca ulaştırmada, birlikte iletişim kurmada ve bazı cihazların opere edilmesinde kullanılabilir. Birleşmiş Milletler 1992 yılından bu yana tüm dünyada engellilerin toplumsal yaşama katılımını ve onlara fırsat eşitliğini sağlamak için çalışmalarını sürdürmektedir. İBA'nın engelli bireylerin sorunlarının çözümünde büyük bir potansiyele sahip olduğu, ayrıca sosyalleşmelerine de katkıda bulunduğu görülmektedir. Bu çalışmada gözlerin istemli hareket ettirilerek kontrol edilmek istenen bir İBA için uygun sınıflandırma yöntemi araştırılmıştır.

Elektrookülogram (EOG) temelli İBA'nın kontrolü için yedi isteli göz hareketinin iki kanallı aksiyon potansiyelleri kullanılmıştır. Sınıflandırmanın gerçek zamanlı uygulamasındaki başarımının en önemli etkenlerinden birisi veri kümesini doğru şekilde oluşturmaktır. Kullanıcılardan kaynaklı sinyal farklılıklarını en aza indirmek için öncelikle veri kaydında özgün bir yöntem geliştirilmiştir. Veri seti, yedi farklı göz hareketi sırasında ölçülen elektrookülografi (EOG) işaretlerinden oluşmaktadır. Sayısal işaret işleme yöntemleri kullanılarak EOG sinyali ön plana çıkarılmıştır. Sinyallerin doğru şekilde ayrıştırılmasını sağlayacak geniş bir öznitelik çıkarma yöntem araştırması yapılmıştır. Bu öznitelikler hem klasik hem de derin öğrenme metotları ile sınıflandırılmıştır. Ayrıca öznitelik çıkarılmadan sinyalin ham haliyle yine derin öğrenme metotlarının sonuçları araştırılmıştır. Klasik sınıflandırma metotları ileri yönlü öznitelik seçim algoritması birlikte kullanılmıştır. Birçok öznitelik ve sınıflandırma yönteminin araştırıldığı, klasik ve derin öğrenme metotlarının karşılaştırıldığı çalışmamızda yedi komut için lightgbm sınıflandırma algoritması ile 95,66%, ham veri üzerinde yapılan derin öğrenme yöntemi ile ise %95.82 gibi yüksek bir oranda başarımlar elde edilmiştir.

Geliştirdiğimiz insan bilgisayar arabiriminin, ihtiyaç veya yardım belirtme, engelli birey eğitimi, bazı ihtiyaçların otomatik giderilmesi gibi birçok farklı uygulamaya entegre edilebilir düzeyde katkı sağlayabileceği değerlendirilmektedir.

**Anahtar Sözcükler:** Elektrookülografi, İnsan bilgisayar arabirimi, Makine öğrenmesi, Derin öğrenme.

# ABSTRACT

## EOG BASED HUMAN COMPUTER INTERFACE DESIGN

Recep ARSLAN

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Intelligent Systems Engineering

Master, August/2022

Supervisor: Assist. Prof. Dr. Selim ARAS

Since the beginning of computers, studies on Human Computer Interface (IBA) have also increased. IBA can be used to make people's lives easier, to achieve many tasks quickly, to communicate together and to operate some devices. Since 1992, the United Nations has been working to ensure the participation of disabled people in social life and equal opportunities for them. It is seen that IBA has a great potential in solving the problems of disabled people and also contributes to their socialization. In this study, the appropriate classification method for an IBA that is desired to be controlled by voluntary movements of the eyes has been investigated.

For the control of EOG-based IBA, two-channel action potentials of seven voluntary eye movements were used. One of the most important factors in the performance of classification in real-time application is to create the dataset correctly. In order to minimize signal differences caused by users, a unique method has been developed for data recording. The dataset consists of electrooculography (EOG) signs measured during seven different eye movements. EOG signal is highlighted by using digital signal processing methods. An extensive feature extraction method research has been carried out to ensure the correct separation of the signals. These features are classified by both classical and deep learning methods. In addition, the results of deep learning methods were investigated in the raw form of the signal without feature extraction. Classical classification methods are used together with forward feature selection algorithm. In our study, in which many features and classification methods were investigated and classical and deep learning methods were compared, a high success rate of 95.66%, was obtained with the lightgbm classification algorithm for seven commands and 95.82% with the deep learning method on raw data.

It is considered that the human computer interface we have developed can contribute to many different applications such as specifying needs or help, training for disabled individuals, and automatic fulfillment of some needs.

**Keywords:** Electrooculography, Human computer interface, Machine learning, Deep learning.

## ÖN SÖZ VE TEŞEKKÜR

Yüksek lisans eğitimim ve tez çalışmam boyunca bilgi ve deneyimleriyle beni yönlendirerek sabrı, yardımları ve desteklerini benden esirgmeden sürekli gayretlendiren, tez çalışması dışında da bana çok şey öğreten danışman hocam Sayın Dr. Öğr. Üyesi Selim ARAS'a, çalışmalarımda veri seti hazırlarken özverili şekilde yardımcı olan mesai ve öğrenci arkadaşlarıma (A. Furkan Kola, Erkan GÜNDÜZ, Selma ERCAN, Osman KÖMPE, Hasan AKÇA, Tuba ERDEM, Hakan ŞEN, Özlem BAHADIR, Turan BOZDEMİR, Ümit USTA, Ferhat GÜLBÜZ, Hasan TOK, Muhammed Mücahit NAS, Nur Sena BATUR, İsmail Oğuzhan ATALI, Najmuddin BABAJANOV, Murza İSMAİLOV, Anahan BABAJANOV), eğitim hayatım boyunca maddi ve manevi hiçbir yardımı esirgmeden koşulsuz bir şekilde yanımda olan aileme ve her zaman en büyük destekçim ve yardımcım olan eşim Seda ARSLAN ile oğullarım Ali Serden ARSLAN ve Yavuz Alp ARSLAN'a en içten duygularıyla teşekkürlerimi sunarım.

Recep ARSLAN

# İÇİNDEKİLER

TEZ KABUL VE ONAYI .....	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI .....	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI .....	ii
ÖZET .....	iii
ABSTRACT .....	iv
ÖNSÖZ VE TEŞEKKÜR .....	v
İÇİNDEKİLER.....	vi
SİMGELER VE KISALTMALAR.....	vii
ŞEKİLLER DİZİNİ .....	viii
TABLolar DİZİNİ .....	x
<b>1. GİRİŞ.....</b>	<b>1</b>
<b>2. İNSAN BİLGİSAYAR ARABİRİMİ .....</b>	<b>11</b>
2.1. Biyolojik Sinyal İzleme Cihazları .....	16
2.1.1. Biyolojik sinyallerin oluşumu .....	17
2.1.2. Biyolojik Sinyal İzleme Cihazları .....	17
2.2. EOG Temelli İnsan Bilgisayar Arabirimi .....	23
2.3. EOG Sinyallerinin Ölçülmesi ve Gözün Yapısı.....	24
2.3.1. Gözün Yapısı.....	26
2.3.2. Görme Olayı.....	28
2.3.3. Göz Kasları .....	28
2.4. Göz Takip Uygulamaları.....	31
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>35</b>
3.1. Sistem Analizi ve Tasarımı .....	35
3.1.1. Donanım Tasarımı .....	35
3.1.2. Sistem Tasarımı.....	36
3.2. EOG Kayıtlarının Alınması .....	37
3.3. Veri Ön İşleme .....	39
3.4. Öznitelik Çıkarma Yöntemleri .....	46
3.5. Sınıflandırma.....	50
3.5.1. LightGBM (LGMB) .....	53
3.5.2. Destek Vektör Makineleri Algoritması (DVM).....	54
3.5.3. K-en Yakın Komşu (KNN) .....	56
3.5.4. Rastgele orman (RandomForest) Algoritması .....	59
3.5.5. Karar Ağacı (Decision Tree) Algoritması: .....	62
3.6. Derin Öğrenme.....	63
<b>4. ANALİZ VE BULGULAR .....</b>	<b>69</b>
4.1. Makine Öğrenmesi Analiz ve Bulgular .....	72
4.1.1. LightGBM analiz ve bulgular .....	72
4.1.2. Random Forest Algoritması Analiz ve Bulgular.....	81
4.1.3. Destek Vektör Makineleri (DVM) Algoritması Analiz ve Bulgular.....	84
4.1.4. KNN Aloritması Analiz Ve Bulgular .....	86
4.1.5. Karar Ağacı Algoritması (ID3-Decision Tree) analiz ve bulgular.....	88
4.2. Ham Veri Analiz Bulgular .....	91
4.2.1. Derin Öğrenme Analiz ve Bulguları.....	91
4.2.2. Derin Öğrenme Bulguları .....	91
<b>5. SONUÇ VE ÖNERİLER.....</b>	<b>95</b>
<b>KAYNAKLAR .....</b>	<b>98</b>
<b>ÖZGEÇMİŞ .....</b>	<b>106</b>

## SİMGELER VE KISALTMALAR

ACM SIGCHI:	Association for Computing Machinery's Special Interest Group on Computer–Human Interaction ( Bilgisayar-İnsan Etkileşimi Konusunda Bilgisayar Makinelerinin Özel İlgi Grubu Derneği)
ALS	: Amyotrofik Lateral Skleroz
AUC	: Area under the ROC Curve (ROC Eğrisinin Altındaki Alan)
CNN	: Convolutional Neural Networks (Evrışimsel Sinir Ağları)
DSA	: Digital Signature Algorithm (Dijital İmza Algoritması)
EEG	: Elektroensefalografi
ECG	: Electrocardiogram
EKG	: Elektrokardiyografi
EMG	: Elektromiyografi
EOG	: Elektrookülografi
ERG	: Elektroretinografi
FPS	: Saniyelik Görüntü Sayısı
İBA	: İnsan Bilgisayar Arabirimi
IR LED	: Kızılötesi Işık (Infraruj LED)
KA	: Karar Ağaçları
KNN	: K-Nearest Neighbors ( K En Yakın Komşuluk)
k-EYK	: K-en Yakın Komşuluk
LDA	: Linear discriminant analysis ( Doğrusal Diskriminant Analizi)
LSTM	: Long- Short Term Memory ( Uzun Kısa Vadeli Hafıza Ağları)
OECD-AB	: Avrupa Ekonomik Kalkınma ve İşbirliği
PSG	: Polisomnografi
REM	: Rapid Eye Movement (Hızlı Göz Hareketi)
RF	: Random Forest
RNN	: Reccurent Neural Network (Özyinelemeli Sinir Ağı)
RO	: Rastgele Orman
ROC	: Receiver Operating Characteristic ( Alıcı İşletim Karakteristiği)
TUAS	: Tıkayıcı Uyku Apne Sendromu
SCI	: Spinal Cord İnjury (Omurilik Yaralanması)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
YSA	: Yapay Sinir Ağları

## ŞEKİLLER DİZİNİ

Şekil 2.1. İnsan-Bilgisayar Arabirim Türleri (Karpov and Yusupov, 2018) .....	13
Şekil 2.2. EKG işaretine ait dalga şekli (The ECG waveform)(Yakut vd, 2014) .....	19
Şekil 2.3. EMG sinyali örneği (Ayaz, 2019). .....	20
Şekil 2.4. EEG sinyallerinin frekans bantları (Sanei and Chambers, 2007) .....	20
Şekil 2.5. ERG bileşenlerin hangi bölgelerden kaynaklandığını gösteren retina resmi (Erginöz, 2007) .....	21
Şekil 2.6. Çeşitli elektrot uygulamaları .....	22
Şekil 2.7. EOG ölçüm devresinin blok şeması .....	23
Şekil 2.8. Elektrot bağlantısı ve sistemin blok gösterimi (Uşaklı ve Gürkan, 2009) .....	23
Şekil 2.9. Dört yönde göz hareketleri ve onlara karşılık gelen kaslar .....	25
Şekil 2.10. Üç çift ekstraokuler kas ve onların pozisyonu (MEB, 2012) .....	26
Şekil 2.11. Gözün Yapısı (Çakır ve Gündoğan, 2021).....	27
Şekil 2.12. Göz dışı kaslar (Acır vd, 2018) .....	28
Şekil 2.13. Gözün Hareketleri (Acır vd, 2018).....	29
Şekil 2.14. Aksiyon potansiyelinin yapısı .....	30
Şekil 2.15. Griye çevrilmiş kameradan akan göz görüntüsü (a), histogram germe uygulanmış görüntü (b), eşikleme, erozyon ve dilasyon uygulanmış görüntü (c), göz bebeği merkezinin vektörel hareket için tespit edilmesi (d). (Turan, 2021).....	34
Şekil 3.1. Donanım tasarımı .....	36
Şekil 3.2. Akış diyagramı .....	36
Şekil 3.3. EOG 2 kanallı kablo kullanımı.....	37
Şekil 3.4. Kayıt için oluşturulan uygulama örnekleri a) Sola bakma b) sağ göz kırpması c) iki göz kırpması .....	38
Şekil 3.5. Bir kayıt örneğindeki iki kanal sinyali ve etiketi.....	38
Şekil 3.6. Alçak geçiren filtre karakteristikleri a) ideal filtre b) pratik filtre .....	40
Şekil 3.7. IIR ve FIR giriş çıkış sinyal gösterimi(Kemal Dağ, 2013) .....	41
Şekil 3.8. Filtre Karakteristik Grafiği.....	42
Şekil 3.9. FIR filtre metotları.....	43
Şekil 3.10. Aynı mertebedeki ve kesme frekansındaki IIR düşük geçiren filtre metotları.....	43
Şekil 3.11 Chebyshev filtre karakteristiği (Yavuz vd, 2007).....	44
Şekil 3.12. Chebyshev bant geçiren süzgeç .....	46
Şekil 3.13. EOG komutlarının iki kanallı gösterimleri.....	47
Şekil 3.14. Karşılık matrisi (confusion matrix) .....	52
Şekil 3.15. İki sınıflı doğrusal DVM (Akca, 2020).....	55
Şekil 3.16. Çekirdek fonksiyonun özniteliklerinin uzaysal dönüşümü (Wang vd, 2011) .....	56
Şekil 3.17. Euclidean noktasal uzaklık hesaplaması temsili görünümü .....	57

Şekil 3.18. RO iki ağaçlı basit gösterimi (DevHunter, 2018).....	59
Şekil 3.19. RO yöntemine ait ağaç yapısı (Ok vd, 2011).....	61
Şekil 3.20. Örnek Karar Ağacı Yapısı (Çelik vd, 2022).....	62
Şekil 3.21. Basit RNN algoritması (Savaş, 2020).....	66
Şekil 3.22. Kısıtlı Boltzman Makinesi (Krizhevsky vd, 2012).....	67
Şekil 3.23. Örnek DBN bağlantı şeması (Krizhevsky vd, 2012).....	67
Şekil 4.1. Çalışmanın akış şeması.....	69
Şekil 4.2. İleri öznitelik seçim yöntemi ile elde edilen Lightgbm algoritması sonuçları .....	71
Şekil 4.3. LightGBM İterasyon başına hata oranı.....	73
Şekil 4.4. LightGBM Kolonların Önem Sırası .....	73
Şekil 4.5. LightGBM Kolon seçim grafiği .....	74
Şekil 4.6. LightGBM ağaç yapısı.....	75
Şekil 4.7. LightGBM karmaşıklık matrisi.....	76
Şekil 4.8. LightGBM Sınıflandırma Raporu.....	78
Şekil 4.9. LightGBM doğruluk grafiği.....	79
Şekil 4.10. LightGBM kayıp grafiği.....	80
Şekil 4.11. RF karmaşıklık matrisi.....	82
Şekil 4.12. RF sınıflandırma raporu.....	83
Şekil 4.13. DVM karmaşıklık matrisi.....	85
Şekil 4.14. DVM Sınıflandırma Raporu.....	85
Şekil 4.15. KNN Karmaşıklık Matrisi.....	87
Şekil 4.16. KNN sınıflandırma raporu.....	88
Şekil 4.17. Karar ağacı karmaşıklık matrisi.....	89
Şekil 4.18. Karar Ağacı (Decision Tree) Sınıflandırma Raporu.....	90
Şekil 4.19. Ham veri derin öğrenme hata oran grafiği.....	92
Şekil 4.20. Ham veri derin öğrenme doğruluk grafiği.....	92
Şekil 4.21. Derin Öğrenme karmaşıklık matrisi.....	93
Şekil 5.1. Arayüz tasarım a) Klavye tasarımı b) Menü tasarım.....	97

## TABLolar DİZİNİ

Tablo 3.1. IIR ve FIR filtre karşılaştırılması .....	41
Tablo 4.1. Eğitim kümesi sınıflandırma sonuçları .....	72
Tablo 4.2. Derin öğrenme eğitim başarıml sonuçları.....	93
Tablo 4.3. Derin öğrenme test başarıml sonuçları .....	94



# 1. GİRİŞ

İnsan, ihtiyaçları gereği birbiriyle yardımlaşan, çevresi ile sürekli iletişim halinde olma gereksinimi duyan bir canlıdır (Aytekin, 2018). Gelişen iletişim teknolojileri sayesinde insanların günlük iletişim ağı daha da genişlemiştir. Ancak toplumumuzda engelinden ya da hastalığından dolayı iletişim kurmakta zorlanan, hatta kendi ihtiyaçlarının büyük kısmını karşılayamayan bireyler de bulunmaktadır. Hareket etmekte zorlanan, bakıma muhtaç bireyler için çözüm olabilecek çok disiplinli bir çalışma alanı olan İnsan Bilgisayar Arabirimi (İBA) insanların bilgisayarlarla ve diğer teknoloji türleri ile nasıl etkileşim kuracağına araştırıldığı bir bilim dalı (Aras, 2021) olarak çözümler sunmaktadır. İBA teknoloji olarak hem yazılım hemde donanım dünyasını etkileşimli olarak birleştirir. İBA'nın tarihsel gelişimine bakıldığında yazılı kaynaklarda 1982 yılında ortaya çıktığı belirtilmesine rağmen daha eski disiplinlere dayandığı bilinmektedir (Lazar vd, 2017). Bilgisayar sistemleri İnsan Faktörleri Konferansının (ACM SIGCHI) 1983'te yapılmaya başlaması ile birlikte bu alanda yenilikçi çalışmalar ortaya konmaya başlanmış ve günümüze kadar İBA uygulamaları hayatımızda yer almıştır (MacKenzie, 2012). Nüfusun artması ve yaşlanması ile birlikte engelli birey sayılarının artması çözüm yolları aranmasına neden olmuştur. Teknolojinin gelişmesi ile birlikte İBA ile ilgili yapılan çalışmaların geçmişten günümüze hızlandığı görülmektedir.

İBA ile ilgili yapılan arabirimler incelendiğinde, elektroensefalogram (EEG) ve elektromiyogram (EMG) ile Electrooculography (EOG) tabanlı çalışan sistemler üzerine analizler yapıldığı görülmektedir (Öner vd, 2015). Yapılan bu çalışmalarda EEG, EMG, EOG tabanlı sistemlerin tercih edilmesinin ana nedeni sinyal genliklerinin yüksek olması (Lopez ve Orosco, 2015 ) ve sınıflandırma analiz işleminin sonucunda başarı oranlarının daha yüksek olmasıdır. EEG ve EMG tabanlı İBA sistemleri verimli bir sistem kurmak için çok daha fazla ölçüm kanalına ihtiyaç duymaktadır. EOG tabanlı İBA sistemleri ise iki ölçüm kanalıyla aynı başarıyı sağlayabilirler.

ALS gibi hastalıklarla veya herhangi bir nedenden dolayı yatağa bağımlı kalmış, yüz kasları ile göz hareketleri dışında hareket kabiliyeti olmayan bireyler için daha çok EOG tabanlı İBA sistemler geliştirilmiştir. EOG negatif yüke sahip olan kornea ile pozitif yüke sahip retina arasındaki aksiyon potansiyelini ölçen fizyolojik bir metottur (Afandi, 2019). EOG sinyalleri korneadan retinaya göre daha pozitif olduğu bir dipolle modellenebilmektedir (Venkataramanan vd, 2005). EOG sinyallerinin EMG ve EEG

sinyallerine göre göz hareketlerini algılamada dezavantajları ve avantajları bulunmaktadır. En büyük dezavantajı korneaya ait retinal potansiyel farkın sabit olmaması ve yavaş bir şekilde değişmesidir (Tabkara vd, 2017). Bu sebeple sürekli ölçüm yapılması gerekmektedir. Bu durum toplanan veri sayısı artırmakta, donanımsal ve yazılımsal gecikmelere neden olmaktadır. Diğer bir dezavantajı ise çevresel gürültülerden, kişinin tansiyon veya yüz kaslarının yapısal bozukluklardan etkilenmesidir. Avantajlı olduğu durumlar ise ölçüm yapılan kullanıcıya herhangi bir zarar vermemesi, non-invaziv olması, ışığın olmadığı karanlık ortamlarda kişinin gözünün kapalı olduğu hallerde gözün hareketine ait potansiyel oluşturmasıdır (Brahmaiah vd, 2017). Toplanan bu sinyallerin İBA tarafından kullanılabilmesi ve yorumlanabilmesi için karar destek mekanizmalarına ihtiyaç duyulur. Karar destek mekanizmaları verimli bir çıktı ve sonuç verebilmek için büyük veri havuzlarını kullanırlar.

Son yıllarda bilgisayar arayüzleri istemli hareket yeteneğini kaybeden hastaların yaşam kalitesini artırmak (Güner ve Erkmen, 2018), farklı iletişim kanalı oluşturarak motor hareket fonksiyonlarda beyin koordinasyonunda oluşan hataları azaltmak ve asgari bir şekilde haberleşme/kontrol sağlamak (Samancı, 2019) amaçlı kullanılmaktadır. Bir çalışmada EOG sinyalleri elektrotlar yardımıyla alınmış, bir mikro denetleyici aracılığıyla yorumlanmış ve RF verici yardımıyla yorumlanan veri iletilmiştir (Gürkan vd, 2018). Uydu cihazı ile alınan veri ledlerle oluşturulan arayüze iletilerek herhangi bir sınıflandırma algoritması kullanmadan ledlerin yerleşimine göre yorumlanmıştır. EEG sinyallerinden alınan verilerin Pasif RC Alçak Geçiren bir filtreden geçirilerek geliştirilen bir çalışmada sinyal toplama modülü (Güner ve Erkmen, 2018) ile veriler toplanmıştır. Yine bu çalışmada toplanan veriler STM32 mikro denetleyici ile uygun formata dönüştürülerek şebeke gürültüsünden arındırılmış ve MikroSD karta kaydedilerek bluetooth modülü aracılığıyla bilgisayara aktarılmıştır. Geliştirilen bilgisayar arayüz yazılımı ile gerçek zamanlı istatistiksel veya makine öğrenmesi gibi matematiksel yaklaşımlara başvurularak analiz yapılmıştır. Neurosky Mindwave Mobile başlığı kullanılarak EEG sinyallerinin alındığı bir çalışmada üretilen arayüz yazılımı kullanılarak yinelenen olaylar uyarıcıya karşı verilen beyin yanıtlarını görsellere dökülerek incelenmiştir (Samancı, 2019). İncelenen verilerle P300 heceleme matrisi kullanılarak ThinkGear ve Blink Talk yazılımları ile uygulamalar yapılmıştır. Diğer bir çalışmada da, Ag-AgCl elektrotlar ile alınan EOG

sinyalleri Arduino Uno R3 aracılığıyla bilgisayar ortamına aktarılan veriler kullanılarak Matlab yazılımıyla üç farklı kullanıcı arayüz tasarlanmıştır. Bunlardan birincisi EOG sinyallerinin yüksek örnekleme frekansında incelemek için kullanırken, ikincisi daha düşük örnekleme frekansı ile gerçek zamanlı sinyal takibi için kullanmıştır (Menteş vd, 2020). Üçüncü olarak tasarlanan arayüz ise göz hareketlerini takip amaçlı kullanılmış ve dokuz adet karenin kişi seçimine göre boyanması sağlanmıştır. Bu çalışmalarda %90 üzerinde başarımlar sağlanmıştır. EOG gibi veri girdi birimleri ile oluşturulan büyük veriler veri madenciliği, dönüştürme, farklı verilerle birleştirme gibi işlemler ve makine öğrenimi ile derin öğrenme algoritmaları yardımıyla farklı alanlarda kullanılabilir hale gelmişlerdir (Öter vd, 2016).

Makine öğrenimi (Machine Learning) veya makine öğrenmesi, karmaşık örüntüleri deneyim ve verileri kullanma yoluyla otomatik olarak iyileştirilebilen daha akılcı karar verebilme becerisi kazandıran bilgisayar algoritmalarının incelenmesidir (Mitchell, 1997). Yapay zekanın bir parçası olarak da görünen makine öğrenmesi istatistik, olasılık kuramı, veri madenciliği, uyarlamalı denetim ve kuramsal bilgisayar bilimi gibi alanlarla da ilişkisi bulunmaktadır. Makine öğrenmesi ile kullanıcılar bilgisayarların öneri ve karar vermesi için kullanılacak algoritmaya büyük miktarda veriler girerler. Girilen bu veriler karar mekanizmaları tarafından tahminde bulunmak için “eğitim verileri” ve “test verileri” olarak rassal olarak ayrılırlar. Eğitilen veriler test verilerine uygulanarak anlamlı sonuçlar ile değerlendirilerek akıllı cihazlara sezgisel ve proaktif yeteneği kazandırılırlar. Daha çok nesnelerin interneti (IoT) içindeki cihazlarla ilişkilendirilen makine öğrenmesi akıllı telefonlarda ve cihazlarda, akıllı metin, konuşma tanıma, hesaplamalı fotoğrafçılık ve benzeri özellikler ile cihazlar içinde aktif olarak kullanılırlar. İnsanların öğrenme etkinliklerini simüle etmek için bilgisayarı nasıl kullanacaklarını öğrenmeleri kontrol yöntemleri olarak makine öğrenimine olan ilgiyi arttırmıştır. Bilgi birikiminin daha kolay olması yönüyle insan öğrenmesi ile karşılaştırıldığında makine öğrenmesi daha hızlıdır (López vd, 2016). Makine öğreniminin sağlık ile ilgili yapılan araştırmalarda EMG, EEG ve EOG gibi cihazlardan alınan veriler üzerine yapılan çalışmaların daha fazla olduğu görülmektedir. EMG sensörü kasların doğal elektriksel aktivitesine dayalı bir sensör olduğundan yapılan çalışmalar biyonik el (Bağcı, 2016), insan robot etkileşimi (Erin ve Boru, 2020), el hareketlerinin sınıflandırılması (Derdiyok vd, 2020), bel rahatsızlıklarının tespiti (Ünal, 2015) gibi kas hareketleri gerektiren durumlarda tercih

edilmiştir. EEG sensörleri ise beyindeki aktiviteleri ölçebilen bir sensör olduğundan yapılan çalışmalar gruplandırılacak olursak uyku alanında yapılan çalışmalar: uyku apnesi tespiti (JeyaJothi vd, 2020), uyku davranışı bozukluğunun değerlendirilmesi (Rechichi vd, 2021) uyku aşamalarının tespiti (Sharma vd, 2022), solunum ve uyku evreleme arasındaki ilişki (Coşkun, 2017), REM uyku davranışı bozukluğunun değerlendirilmesi (Rechichi vd, 2021), vücut statüsü ile uyku arasındaki ilişki (Yang vd, 2022) gibi çalışmalar yapılmıştır. EEG ile EEG Güç Spektrumu ile Travmatik Beyin Hasarından İyileşme Tahmini ve EEG Güç Spektrumu ile Travmatik Beyin Hasarından İyileşme Tahmini (Mohd Noor vd, 2022), EEG sinyallerinin epileptik rahatsızlıkların teşhisi için konvolüsyonel sinir ağları ve destek vektör makineleri ile tasnif edilmesi (Mutlu İpek, 2018) gibi hastalık teşhislerinde araştırmalar yapıldığı gibi EEG verilerinden sağ ve sol el hareket düşüncelerinin tespiti (Mishchenko, Kaya, Cömert, 2017), epoklar ile motor hayaline dayalı EEG işaretlerinin sınıflandırma doğruluğunun artırılması (Ergün ve Aydemir, 2018) gibi beyin aktiviteleri üzerinde çalışmalar da yapılmıştır.

Mevcut çalışmada kullanılan EOG cihazı retina içinde yer alan pigment epiteli potansiyelinin elektriksel olarak ölçülmesine dayanır. EOG ile ilgili yapılan makine öğrenmesi çalışmaları daha çok göz kas ve hareketlerine dayalı yapılan çalışmalardır. Alın bölgesinden alınan elektrookülogram (EOG) işaretleri ölçüm devresi tasarımı ve sınıflandırılması (Cömert, 2016) adlı çalışmada bir arduino ve EOG shield ile veriler alınmış ve bluetooth yardımıyla bilgisayara aktarılmıştır. Veri kümesi üzerinde 150 farklı öznitelik çıkarılarak bunlardan 51 en iyi öznitelik çıkarılmış, k-NN algoritması ile %94,20 başarımla elde edilmiştir. Veri seti üzerinde ayrıca Naive Bayes (NB), Destek Vektör Makinesi (SVM) ile YSA sınıflandırma metotları kullanılmış ve karşılıklı başarımla oranları değerlendirilmiştir.

Disleksi teşhisi konulmuş çocukların eğitiminde kullanılmak üzere en uygun yazı karakterlerinin tespiti için yapılmış bir çalışmada (İleri, 2020) farklı punto ve yazı karakterlerinden oluşan bir test sistemi geliştirilmiştir. Daha sonrasında 13 sağlıklı, 23 disleksi tanısı konulmuş bireyler üzerinde oluşturulan bu test sistemi kişilere okutularak eş zamanlı olarak Ag-AgCl tek kullanımlık elektrotlar aracılığıyla EOG sinyalleri kayıt edilmiştir. EOG sinyallerindeki tepe sayısı, okuma hızı, fraktal boyut, Hjort parametreleri özellikleri makine öğrenmesi algoritmaları ile analiz edilmiştir. Naive Bayes (NB), Destek Vektör Makineleri (DVM) ve K-En Yakın Komşu (KNN)

algoritmalarında %100 başarı elde edildiği görülmüştür. Rastgele Orman (RO) algoritmasında ise %98.97 başarı sınıflandırılma başarısı elde edilmiştir. Yapılan çalışmanın sonucunda kişiye özgü yazı karakteri belirlenmiş ve disleksi tanısı için yardımcı olabileceği ifade edilmiştir.

Uyku evrelerini inceleme konusunda EMG ve EEG kayıtları dışında farklı bir yaklaşımla EOG sinyalleri ele alınmıştır (Coşun, 2017). Uyku testi için düzenlenmiş laboratuvarında 15 hastadan sol göz EOG (EOG) ve sağ göz EOG (EOGR) sinyalleri elde edilmiştir. Uyku aşamaları uyanık (wake),REM, Non-REM-1, Non-REM-2, Non-REM-3 bölgelerinin zaman frekans domeninde 36 farklı öznitelik çıkarılmış ve makine öğrenimi algoritmalarına tabi tutulmuştur. Sınıflandırma da Naive Bayes, C4.5 karar ağacı (J48 decision tree), K-en yakın komşu algoritması (K-nearest neighbours classifier), YSA (Multilayer Perceptron), Random Forest gibi birçok algoritma denenmiştir. Çalışmada en yüksek başarıyı Random Forest algoritması ile %80.15 olarak bulunmuştur.

Görme engellilerin bilgisayar ve yazılı kaynaklara ulaşımını kolaylaştırmak için Sönmez ve Bulut (Bulut, 2006) çalışmalarında, bilgisayarda bulunan bir metni Brail alfabesine çevirerek parmak uçlarında hissedebilecekleri ve aynı zamanda duyabilecekleri bir İBA birimi geliştirmişlerdir.

EOG üzerine yapılan bir diğer çalışmada gözün sağa,sola,yukarı, aşağı bakma ve göz kırpma ile gözün tik hareketi sinyalleri kayıt edilmiştir (Erkaymaz, 2014). Çalışmada hareket özelliklerini çıkarabilmek için makine öğrenmesi ile öznitelikler çıkarılmış ve YSA ile Bulanık mantık üzerinde “hareket alanı” ve “hareket geçiş kontrol” algoritmaları çıkarmak için çalışmalar yapılmıştır. Yapılan çalışma sonucunda göz hareketleri başarılı bir şekilde tespit edilmiş ve bulanık mantık kontrol modeli geliştirilmiştir.

İnsan-Bilgisayar Arayüzü üzerine Tamura S. ve Tanno K.’nın yapmış olduğu çalışmada, EOG sinyalleri ile mouse kontrol sistemi geliştirilmeye çalışılmıştır. Dikey ve yatay olarak alınan EOG sinyalleri sayısal formlara dönüştürülmüş ve bilgisayar ortamına aktarılmıştır. Gözün yapmış olduğu beş farklı hareket yüksek bir sınıflandırma başarımı ile çalıştırılmış ve kullanılmıştır (Hiroki, 2010).

Lopez A. ve arkadaşları, EOG sinyalleri almak için kullanılan elektrotların çoklu kombinasyonlarla yüzün farklı noktalarına yerleştirilerek etkileri üzerine bir çalışma

yapmışlardır. Çalışmada elektrotların yerleşim düzenleri ve kombinasyonları hakkında bilgiler verilmiş ve sonuçları detaylı bir şekilde açıklanmıştır. Çalışmada elektrotların polarite ve genliklerinde farklılıklar olduğu iki kanallı yerine dört kanallı elektrotlar kullanılmasının hareketleri anlamlandırmada başarımı arttırdığı sonucuna varılmıştır (López vd, 2010).

EOG sinyallerinin alınması ve iletilmesi üzerine yapılmış imleç ve kontrol tasarımı çalışmasında bilgisayar, Tv veya akıllı bir cihazın bir imleç ile kontrolü amaçlanmıştır. Devre diferansiyel yükselteç ikinci dereceden alçak geçiren filtre, toplayıcı amplifikatör, ATMEGA-328 mikroişlemci ve HC-05 Bluetooth modülü ile kurulmuştur. Alınan veriler karşı donanımda bir Arduinio leonardo ve HC-05 modülü ile alınmış ve %95'e varan net sinyal ile imleç kontrolü sağlanmıştır [eog sinyal tabanlı imleç sistemi tasarımı ve uygulaması] (Karagöz, 2019).

Diğer bir çalışmada EOG sinyalleri ile gözün yapmış olduğu beş farklı hareket için sanal klavye arayüzü tasarlanmıştır. İki kanallı olarak kayıt edilmiş veriler filtre uygulamaları ile gürültüden arındırılmış KNN (k-Nearest Neighbor, k- 3 NN) algoritması ile %95 başarımla sınıflandırılmıştır. Çalışma için Delphi 0.6 ile arayüz hazırlanarak klavyeden rastgele gelen bir kelime 25 saniye içerisinde yazılmıştır. Deney yirmi kişi üzerinde denenmiş ve %100 başarımla elde edilmiştir (Uşaklı ve Gürkan, 2010).

L. Li ve X. Wu (Li ve Wu, 2011) çalışmalarında, EOG sinyalleri ile insan bilgisayar arayüzü üzerine yaptıkları çalışmada Midset adlı bir kulaklık ve göz hareketlerinden alınan verileri Bluetooth ile bilgisayara kablosuz olarak aktarmışlardır. Çalışma sonucunda göz hareketlerinin yapmış oldukları IBA multimedya yazılımını kullanmakta başarılı olduğu tespit edilmiştir. Bir oyun ekranında kullanıcı tarafından test edilen uygulamanın bir yardımcı birim olarak kullanılabileceği gibi sağlıklı bireyler içinde eğlence amaçlı olarak değerlendirebileceği belirtilmiştir.

Güvenlik alanında sürücülerin yorgunluk tespiti için EOG sinyalleri alınarak yapılan bir diğer çalışmada elektrotlar göz çevresine değil alın bölgesine yerleştirilmiştir. Yedi kanallı EOG sinyalleri NeuroScan sistemi ile bir gözlük yardımıyla 500 Hz örnekleme ile kayıt edilmiş ve gürültüyü gidermek amacıyla 125 Hz'ye düşürülmüştür. Bant geçiren filtre kullanılarak göz kapatma süreleri

kaydedilen videolar üzerinden zaman serilerinin göz kapatma yüzdesi hesaplanmıştır. İstatistiksel bir yöntem olan Regresyon Analizi için SVM kullanılarak 0,88'lik bir korelasyon katsayısı bulunmuştur. Deney dört kadın ve on erkek birey ile bir araç simülatörü kullanılarak sanal bir karayolu üzerinde uygulanmıştır. Çalışma sonucunda göz kapatma sürelerinin sürüş yorgunluğunun (Zhang vd, 2015) bir göstergesi olduğu kanıtlanmıştır.

S. Gürkan ve arkadaşlarının hareket yetenekleri kısıtlı hastalar üzerine yaptıkları çalışmalarında, her bir EOG sinyallinden alınan göz hareketi 251 adet örnekten oluşan 10 farklı denekten alınmıştır. İki kanallı sistemden 50 Hz örnekleme ile alınan verilerde gürültünün bastırılması için Hanning ve Butterworth filtreleri uygulanmıştır. Sinyaller sınıflandırılırken k-NN algoritması kullanılmış ve %95 (Öner ve Gürkan, 2015) başarımlar sağlanmıştır.

HMI üzerinde yapılan başka bir çalışmada Z. Hossain ve arkadaşları, gözün yapmış olduğu 4 ana yöndeki (aşağı, yukarı, sağ, sol) hareketi EOG sinyallerini elektrotlar yardımıyla filtrelerden geçirerek almıştır. Analog sinyalin sayısallaştırılması ile oluşan bu veriler Python programlama dilinin kütüphanesinde bulunan makine öğrenmesi algoritmaları SVM ve Doğrusal Diskriminant Analizi (Linear Discriminant Analysis, LDA) ile gerçek zamanlı olarak sınıflandırılmıştır.

Tasarlanan bir arayüzde bulunan imlecin orta noktadan sağa ve sola doğru hareket ettirilmesi sağlanmış çalışmanın felçli hastaların tekerlekli sandalyelerini kontrol edebileceği (Hossain vd, 2017) belirtilmiştir.

Tekerlekli sandalye kontrolü için yapılmış benzer bir çalışmada yine gözün dört farklı hareketi baz alınmış, EOG sinyalleri Arduino platformu içerisinde işlenerek tekerlekli sandalye kontrolü sağlayacak komut sinyallerine dönüştürülmüştür. Deneklerin elektrikli sandalyeyi %90 (Bhuyain vd, 2019) doğrulukla kontrol etmesi saptanmıştır.

Motor nöronları zarar görmüş bireyler için geliştirilen diğer bir çalışmada (EOG/EEG) sinyallerin güçlü yönlerini alarak kullanıcıların beyin kontrollü bir satranç oyunu oynayabileceği hibrit bir İBA arabirim çalışması yapılmıştır. Çalışmada beyin sinyalleri ve göz hareketleri ile bilgisayar ortamında bulunan satranç oyununda karakterlerin hareket etmesi sağlanmıştır. Yapılan hibrit sınıflandırma sonucunda %96 (Choi vd, 2018) oranında başarımlar sağlanmıştır.

Makine algoritmalarının biyomedikal verilerin işlenmesi ve sınıflandırılmasında verilerin ve miktarının artış gösterdiği durumlarda yetersiz kalması durumunda çok katmanlı bir öğrenme ağı kullanımı günümüzde zaruri hale gelmektedir. Karmaşık ve yüksek boyutlu gözlemsel verileri öğrenebilen derin öğrenme yöntemi ile tez çalışmam analiz edilmiştir. Derin öğrenme esasen çok-katmanlı bir öğrenme yapısı sergileyen insan beyninin çalışma prensibinden esinlenilerek tasarlanmıştır (Uyulan vd, 2019). Genellikle bir derin sinir ağı (DSA) (Deep Neural Network) giriş katmanı ve gizli katman ile bir çıkış katmanından oluşur. Giriş katmanı işlevi veriyi toplamakken gizli katman görevi ise verinin soyut özniteliklerini öğrenmektir. Çıkış katmanı ise son aşamada sınıflandırma işlemi yapar. Bir derin öğrenme uygulamasında saklı katmanların yüksek olması, derin öğrenmenin yüksek soyutlamaya dayalı özniteliklerin ve arasındaki ilişkilerin gözardı edilemeyeceği anlamına gelir (Roux ve Bengio, 2008) ve çalışmanın başarımının artırılması sağlanır. Birden fazla makine öğrenmesini içeren derin öğrenme algoritmaları ile büyük veri setlerine bakılarak eğitim modelleri kurulabilir tahmin ve yorumlar yapılabilir.

EEG sinyalleri ile epilepsiyi incelemek için yapılan başka bir çalışmada beyin aktivitesi sırasında oluşan elektriksel sinyaller nöbet tahmini için kullanılmıştır. Oluşan sinyaller öncelikli olarak bir evrişimli sinir ağları (CNN) ile genişletilerek, LSTM ağları ile birkaç modül ve bellek katmanı tarafından test edilmiştir. LSTM ağları dört farklı preiktal uzunluk kullanarak nöbet tahmin performansını değerlendirmek için seçilmiştir. Sonrasında EEG kanalları çapraz korelasyon ve grafik arasında zaman ve frekans alanı özellikleri ile sınıflandırılmıştır. Önerilen metodolojinin 185 nöbetin tamamını yüksek oranlarda tahmin edebildiği ve saatte 0.11–0.02 yanlış alarmlı ile düşük yanlış tahmin oranları (FPR) tespit edebildiği sonucuna varılmıştır (Tsiouris vd, 2018).

Uyku sırasında yaşanan kısmen solunum bozuklukları ve oksijen düzeyi düşüklüğü nedeniyle rahatsızlıklar uykunun kalitesini düşürmekte, Parasomnia ve hipersomnia gibi uyku bozukluklarına neden olmaktadır. Bir çalışmada bu alanda SLEEPNET (Uyku EEG nöral ağı) gibi uyku evreleme için özelleştirilmiş bir araç geliştirilmiştir. SLEEPNET, Massachusetts Genel Hastanesi Uyku Laboratuvarı tarafından 10.000'i aşkın hastadan toplanan verilerden oluşan en büyük uyku fiziyojisi veritabanında eğitilmiş, derin TSA mimarisi kullanılmıştır (Uyulan vd, 2019). SLEEPNET derin öğrenme algoritması ile %85.76'lık bir ortalama başarımla ve

%79.46'lık ek açıklama performansına ulaşılmıştır.

Kim ve ark, Obstrüktif uyku apnesinin tespitinde klasik yöntemler dışına çıkarılarak içinde electrocardiography (ECG), EMG, EEG ve EOG sinyallerinin de bulunduğu polisomnografi (PSG) cihazından alınan verileri kullanmışlardır. Alınan veriler çok boyutlu bir değerlendirme gerektirdiğinden çalışmalarında CNN algoritmasını kullanmışlardır. Veri setinin büyük olması ve modelin eğitiminde hızlı olunması açısından Nvidia RTX 3090 GPU tabanlı derin öğrenme yapılmıştır. Sınıflandırma sonucu uyku apnesinin ciddiyetine göre modelin doğruluğu, hafif, orta ve şiddetli vakalarda sırasıyla %94,3, %91,9, %91,9 ve %90,6 olarak bulunmuştur (Kim vd, 2022). Paisarnsrissomsuk, Ruiz, Alvarez (2020) uykudan Üç kanallı EEG sinyalleri ile uykudan önceki ve sonraki aşamalar da uyku apnesi üzerine yapmış oldukları çalışmalarında CNN algoritması ile 84.57% başarımlı sağlamışlardır.

Horlama uyku halinde iken solunumu gerçekleştiren yapıların titreşimi sonucu oluşan bir durumdur. Uyku apnesi teşhisinde önemli bir belirti olan horlama toplumumuzda yaygın olarak görülmektedir. Apnenin başlangıcı ve sonrasındaki horlama seslerinin değişiklikleri Tıkayıcı Uyku Apne Sendromu (TUAS) hastalarını, yatış bozukluğu ve yorgunluk nedeniyle basit horlayan insanlardan ayırt etmek için önemli bir bilgidir. Bu bilgidен yola çıkarak yapılan bir çalışmada sinyaller istatistiksel modellenmiş ve horlama bölütlerinin başlangıç ile bitiş noktaları belirlenmiştir. Sonrasında horlama seslerinden alınan verilerden farklı bölüt uzunlukları ile alt bölütler oluşturulmuştur. Bölütlerin spekrogram görüntüleri oluşturularak evrişimler sinir ağları yardımıyla derin öznitelikler çıkarılmıştır. Öznitelikleri çıkarılan sesler DVM ve evrişimsel Sinir ağları ile sınıflandırılmıştır. Çalışmanın sonucunda apne sorası horlama bölütlerinin basit horlama bölütlerine oranla sayıca az olduğu gözlemlenmiştir (Biswal vd, 2017).

İnsanlar ilgilerini çeken nesnelere kavramadan önce onu tanımlamak için uzun süreli bakma hareketi yaparlar. Yalnızca göz hareketleri ile nesnelere üç boyutlu olarak tanımlamak mümkün değildir. Cisim el ile döndürülerek kalan diğer yüzeylerinin görünmesi sağlanır. Hem vücut hareketleri kısıtlı ama göz kaslarını hareket ettirebilen hem de protez kol kullanan kişileri düşünerek yapılan bir çalışmada EOG sinyalleri alınarak protez kol hareket ettirilmeye çalışılmıştır. Kullanıcının göz hareketleri ile hareket ettirebildiği bir kamera ile alınan anlık görüntü yardımıyla silindirik, küresel, kübik ve konik şeklinde bulunan nesnelere tanımlanılması istenilmiştir. Evrişimli

Sinir Ağı (CNN) algoritması kullanılan çalışmada %93 başarımla sınıflandırma işlemi yapılmıştır (Roy vd, 2018).

Zou ve Zhang, EOG sinyallerine dayalı akıllı sağlık uygulamalarında kullanılan EOG tabanlı göz ile yazma komutlarını sağlam bir şekilde çözebilen ve ALS hastaları için sesli iletişim sağlayan yeni bir derin öğrenme metodu geliştirmeye çalışmışlardır. Çalışmaları, bilgisayarlı görme alanını yeniden şekillendiren ve akıllı sağlık alanında giderek daha önemli bir rol oynayan derin evrişimli sinir ağına (CNN) dayanmaktadır. Çalışmada ALS hastalarından alınmış 150 kelimelik bir japonca EOG veri seti kullanılarak buna karşılık gelen sesler analiz edilmiştir. Başarım oranı %90.55 olan çalışmada, kullanılan CNN derin öğrenme algoritması geliştirilerek CNN-word adında yeni bir algoritma önerilmiştir. Geliştirilen yöntem ile EOG sinyallerini otomatik olarak çözebilen bir yetkinliğe sahip algoritma olduğu sonucuna varılmıştır (Zou ve Zhang, 2021).

Ravichandran ve ark., ALS hastalarının tekerlekli sandalye veya günlük ihtiyaçlarını yerine getirmeye yardımcı olması için farklı cihazları kontrol amaçlı dört farklı EOG sinyallerini kullanmışlardır. Elektrotlar sol ve sağ gözün şakak kısmına, sol gözün alt kısmına ve referans nokta belirlemek amacıyla sol gözün kulak memesine yerleştirilmiştir. Çalışmada göz hareketleri olarak sola ve sağa bakma, aşağı bakma ve göz kırpma hareketini algılama amaçlanmıştır. Sinyaller 500 Hz'lik örnekleme ile alınmıştır. 120 veriden oluşan veri setinin DVM yardımıyla öznitelikleri çıkarılmıştır. Özniteliklerin sınıflandırılması sonucu LSTM'de %88,33 ve CNN algoritmasında %90,3 doğruluk göstermiştir (Ravichandran, Kamel, Al-Ezzi, Alsaih, ve Yahya, 2021). Benzer bir çalışmada Calp ve arkadaşları, EEG sinyalleri ile tekerlekli sandalye kontrolü amacıyla 10 kişiden aldıkları verileri kullanarak derin öğrenme algoritmaları ile makine öğrenme algoritmaları arasında karşılaştırma yapmışlardır. Random Forest (RF), Decision Trees (DT), Naive Bayes (NB), Support Vector Machines (SVM), k-Nearest Neighbors (k-NN) ve Logistic Regression (LR) gibi makine öğrenmesi algoritmaları Artificial Neural Network (ANN) derin öğrenme algoritması ile karşılaştırılmış ve ANN sınıflandırma da 99.5% başarımla %0.5 hata ile yüksek performans göstermiştir (Calp vd, 2022).

## 2. İNSAN BİLGİSAYAR ARABİRİMİ

İnsan bilgisayar arabirimi (İBA), insanların bilgisayarlarla ve diğer teknoloji türleri ile nasıl etkileşim kuracağını araştırdığı bir bilim dalıdır (Wazwaz, Ziada, Awawdeh, Tahboub, 2020). İBA insan sistemin kullanıcısı ve operatör konumundadır. İnsanların hareket kabiliyetlerindeki eksikliğin üstesinden gelmek ve kabiliyetlerin çok üstünde işler başarabilmek, dünya çapında çok sayıda şirketin ve araştırma ekibinin odak noktası haline gelmiş ve genellikle engelli insanlar için de kullanılan İnsan Bilgisayar Arayüzü İBA çatısı altında toplanmıştır. İBA'nın resmi olarak 1982 yılında ortaya çıktığı kabul edilmekte fakat temelinin daha eski farklı metotlarla çalışan mekanik sistemlere dayandığı bilinmektedir (Çetinel vd, 2017). 1983 yılında yapılan Bilgisayar Sistemlerinde İnsan Faktörleri Konferansı (ACM SIGCHI) ile önemi anlaşılmış günümüze kadar yenilikçi çalışmalar (Uşaklı ve Gürkan, 2010) ile hayatımızda yer almaya başlamıştır. Bilgisayar tabanlı teknolojilerin gelişmesi ile birlikte bilişim sistemlerinin birçok alanda kullanılması

İBA'ların yaygınlaşmasını sağlamıştır. Karpov ve Yusupov (2018) İnsan-Bilgisayar Arabirim türlerini Şekil 2.1'de gösterildiği gibi özetlemiştir.



Şekil 2.1. İnsan-Bilgisayar Arabirim Türleri (Karpov ve Yusupov, 2018)

İBA teknolojilerinin tarihsel gelişimine bakıldığında yarı iletken ve transistör teknolojisinin gelişmesi ile birlikte elektronik sektörü, büyük ve yüksek voltajlar gerektirmeyen ve böylece çocukların bile kullanımına uygun çok küçük cihazlar kullanarak kişinin cihazları kontrol etmesine olanak tanıyan yeni bir dönem açıldığı görülmektedir. Sensör alanındaki gelişmeler, insanların makineleri uzaktan algılama, izleme ve ekipmanı güvenli ve rahat bir konumdan kontrol etme becerilerini artırmıştır. Ancak, makine kontrolünü yeni zirvelere taşıyan kablosuz elektronik, bilgisayar ve biyomedikal mühendisliği alanlarındaki son gelişmelerdir. Bilgisayar alanındaki son gelişmeler, bilgisayarlı kontrol sistemlerinin kullanımını kolaylaştırmıştır. Böylece neredeyse tüm makineler yüksek hassasiyetle kontrol edilebilmektedir. Bu nedenle, bilgisayarlar gerekli işlemleri yapmak için programlandığından, kişinin bir makineyi veya cihazı kontrol etme yöntemini anlaması artık gerekli değildir. Kullanıcıların komut verebilecekleri klavye veya fare gibi cihazlar ile kontrol edilebilir mekanizmaları hareket ettirebilmeleri sağlanmaktadır. Böylece kullanıcının kaslı olup olmamasına bakılmaksızın büyük bir makineyi kontrol etmesi sağlanmaktadır. Kablosuz teknolojiler alanındaki devrim uzaktan koşulların algılanmasını ve herhangi bir yerden bir makinenin çalıştırılmasını kolaylaştırmıştır. Mars'a gönderilen robotik cihazların kontrolü, bunun başka bir gezegenden bile sağlanabileceğini göstermektedir. Cep telefonlarının, internetin ve kablosuz teknolojilerin mevcudiyeti ile dünyanın herhangi bir yerinden herhangi bir cihazı tam anlamıyla kontrol edebiliriz. Bu aynı zamanda cihazların ve durumların uzaktan izlenmesini de sağlamıştır. Bu, kişinin uzaktan, ev ve ofislerinden makineleri kontrol etmesini sağlar.

Uzak makineleri kontrol etme ve onlarla iletişim kurma yeteneğimize bir diğer önemli katkı, sinyal işleme ve sınıflandırmadaki ilerlemedir. Sinyal işleme ve sınıflandırma alanında büyük ilerleme kaydedilmiştir. Gelişmiş sinyal işleme, konuşmayı ve konuşmacıyı tanıyan konuşma analiz tekniklerinin geliştirilmesini sağlamıştır. Böylece ses kaydı, kullanıcının ne söylediğini elde etmek için kullanılabilir ve kullanıcının konuşması metne dönüştürülebilir hale gelmiştir. Bu artık çoğu bilgisayar, tablet ve cep telefonuna dahil edilmektedir. Böylece bilgisayar tabanlı sistemler sözlü komutlarla kontrol edilebilir ve konuşma tabanlı yazma sistemlerinin gelişmesine katkıda bulunur. Bu gelişim, makine kontrolü ve iletişim sistemlerinde

önemli bir adımdır, çünkü insanların cihazları ellerini kullanmadan veya “eller serbest” modunu kullanmadan kontrol etmesine olanak tanır.

Tıbbi gelişmeler, ömrümüzü uzatmış ve tarihte hiç olmadığı kadar uzun yaşamamızı sağlamıştır. Modern tıp aynı zamanda nöromusküler veya iskelet yaralanmaları geçirmiş birçok insanın hayatta kalma olasılığını da artırmıştır. Toplumumuzda, yaşlanmaya bağlı olarak zayıflamış, hastalık veya yaralanma nedeniyle çok sayıda eylemi gerçekleştirme yeteneğini kaybetmiş önemli sayıda insan bulunmaktadır. Bu nedenle, nüfusun çoğunluğunun rutin olarak yapacağı işlevleri yerine getirmek için yardımcı teknolojilere ihtiyaç duyan çok sayıda insanımız vardır. Yardımcı teknolojiler, tekerlekli sandalyeler, yapay eller, iletişim cihazları ve çevreyi yönetmek için kontrol arayüzleri gibi mobilite cihazlarından oluşur. Bu cihazların karmaşıklığı, hastaların ihtiyaç duyduğu destek düzeyine göre değişir. Hareket kaybı, travma veya hastalık gibi birçok nedenden kaynaklanabilir ve engelliliğin en büyük nedenidir. Her yıl omurilik yaralanmasından (SCI) muzdarip olan ve hayatta kalan insanların küresel tahmini, dünya çapında her yıl 130.000'den fazla kişidir (Ursula H., Pierre P., Sylvie, 2010). ). Türkiyede 1992 yılında Dr. Karacan ve arkadaşları tarafından 49 ili kapsayan epidemiyolojik bir çalışmada, travmatik omurilik yaralanmasının ortalama insidansı 12.7./1.000 000 olarak belirlenmiştir. Bu çalışmada erkeklerin kadınlara oranı 2.5:1 ve ortalama yaralanma yaşı  $35.5 \pm 15.1$  ( $35.4 \pm 14.8$  kadın  $35.9 \pm 16.0$  erkek için) olarak ifade edilmektedir (Karacan, Koyuncu, Pekel, Sümbüloğlu, Kirnap, Dursun, 2014). Bu hastaların çoğu hayatları boyunca tekerlekli sandalyeye veya yatağa bağımlı hale gelmektedir. Bununla birlikte, tekerlekli sandalye kullanıcılarının sayısı, SCI'den muzdarip olanlardan önemli ölçüde daha yüksektir. Bunun dışında bir kas iskelet sistemi rahatsızlığı olan ve insanların hareket kabiliyetlerini yitirmesine neden olarak sandalye ve yatağa bağımlı kılan ALS hastalığının, Türkiye’de toplam olarak 6000 ila 8000 civarı olduğu, her yıl yeni tanı alan hasta sayısının ise 1500 ila 3000 arasında değiştiği düşünülmektedir. Hastalığın %5-10’unda genetik geçiş söz konusu iken, geri kalan hastalarda hangi neden veya nedenlerin hastalığa yol açtığı bilinmemekte, genetik ve çevresel faktörlerin etkileşim göstererek bu karmaşık sürece neden olduğu düşünülmektedir (Tüylek, 2021).

Bilimsel ilerlemeyle birlikte artan farkındalık, engelli hastaların, yaşlıların ve genel olarak toplumun istek ve gereksinimlerinin değişmesine neden olmuştur. İnsanlar yataklarına ve hastanelere bağımlı kalmayı ya da onlarla ilgilenecek bir

bakıcıyı değil bağımsız olmayı istemektedirler. İnsanların doğuştan veya yaşamları sırasında oluşan kaza veya hastalıklar nedeniyle bakıma muhtaç hale gelmeleri ekonomik açıdan maliyet getirmektedir. Çünkü sağlık sistemi, düzenli görevlerini yerine getirirken yardıma ihtiyaç duyan artan sayıda insana bakım ihtiyacını destekleyememektedir. Engelliler veya yaşlılar için bağımsız yaşamı kolaylaştırabilen teknoloji, bu nedenle bir kazan-kazan durumudur. Bu durum, insanların bağımsız yaşam sürmelerine yardımcı olabilecek teknolojilere yönelik daha fazla kaynaklara yatırım yapmalarına sebep olmaktadır. (son cümleden sonra neden biyomedikale geçtiğini belirtmek adına burayı bağlaman lazım) şöyle olabilir istersen Biyomedikal mühendisliği yatırımların yapıldığı önemli alanlardan bir tanesidir. Biyomedikal mühendisliği insan merkezlidir ve son 50 yılda çok önemli ölçüde ilerlemiştir. Biyomedikal mühendisliği ve bilimi, beynin işleyişinin, sinir sisteminin ve kas kontrolünün ayrıntılarını keşfetmiştir. Bu gelişmeler, kullanıcıların herhangi bir hareket yapmak zorunda kalmadan doğrudan beyinlerinden veya sinirlerinden komutlar verebilmeleri için bir mekanizma sağlamıştır. Bu, kullanıcının yalnızca düşünceleriyle ve uzuvlarını hareket ettirmeden veya hatta komutlarını sözlü olarak ifade etmesine gerek kalmadan komuta edebildiği veya iletişim kurabildiği makine kontrolü kavramını yeni bir düzeye taşımıştır.

Birçok ALS ve SCI hastası ömür boyu bakım gerektirir ve bu sağlık sistemi için önemli bir maliyettir. Daha az varlıklı ülkelerde sayı daha fazladır ve kaynak yetersizliğinden dolayı bu insanların acısı daha fazladır. Teknolojinin ve toplumsal bilincin gelişmesiyle birlikte toplum, engellilerin makineleri kontrol edemediğini, iletişim kuramadığını veya eğlendiremediğini kabul etmekte zorlanmaktadır. Daha önce engellilerden kendi yetersizliklerini kabul etmeleri beklenirken, şimdi engelliler daha fazla bağımsızlık talep etmektedir. Yıllar içinde, engellilerin işlevlerini yerine getirmeyen uzuvlarını makineler ve bilgisayarlarla kontrol etmelerini sağlayan cihaz ve teknolojilerin sayısında artış olmuştur. Konuşma ve gözlerini hareket ettirme gibi tüm motor kontrolünü veya duyuusal yeteneklerini kaybetmiş insanlar için, doğrudan beyin aktiviteleri tarafından yönetilen ve düşüncelerine dayalı arayüzler gelişmiş ve gelişmeye devam etmektedir. Tüm bunlar İBA alanının çok hızlı gelişerek sektör haline gelmesini sağlamıştır. Engellilerin hayatını kolaylaştırmak, özgürlüklerinin bir kısmını geri kazanmalarına yardımcı olmak ve günlük aktivitelerini gerçekleştirmede onlara bağımsızlık vermek gibi daha önce yapılan çalışmaların üzerine İBA önemli

ölçüde daha üstün ve daha iyi olanaklar sunarak, yaşlılara ve zayıflara bağımsız olarak hayatlarını sürdürebilmeleri, işitme kaybı olan kişilerin duymalarını sağlamaları ve görme engelli kişilerin tekrar görmelerine yardımcı olmaları yönüyle yardımcı olmaktadır. İBA'lar aynı zamanda engellilerin eğlenmesini de kolaylaştırmakta, Web'de gezinmelerini, müzik dinlemelerini, iletişim kurmalarını ve film izlemelerini sağlamaktadır. İBA, sınırlı yeteneklere sahip insanlarla sınırlı değildir, aynı zamanda güçlü kuvvetli insanlar tarafından bilgisayar oyunları oynamak veya sürükleyici sanal gerçekliğe katılmak için de uyarlanmaktadır. Bunların dışında İBA teknolojisi ayrıca bir dizi savunma uygulamasına uyarlanmış ve şu anda araçları ve silahları kontrol etmek için kullanılmaktadır.

İBA artık mühendislik laboratuvarlarıyla sınırlı kalmayıp aynı zamanda modern tıbbın ayrılmaz bir parçası haline gelmiştir. Çalışma alanı, ALS gibi kas iskelet sistemi rahatsızlıkları olan kişilere iletişim ve göz hareketleri ile iletişim ve kontrol etme becerisi kazandırmıştır. Bunların yanı sıra, işitme engelli bireylere sesli iletişim yeteneği kazandırmak ve son zamanlarda görme engelli insanların tekrar görmelerine yardımcı olmak için çalışmalar yapılmıştır. İBA artık engelliler tarafından bilgisayarlarında klavyesiz yazı yazmak, başkalarıyla iletişim kurmak ve tekerlekli sandalyelerini kontrol etmek gibi bir çok uygulama için kullanılmaktadır. Bununla birlikte, mevcut sistemlerin zayıf güvenilirlik gibi sınırlamaları vardır. Araştırmaların temel odak noktaları, güvenilirliği artırmak, kullanıcıya daha fazla özgürlük vermek ve arayüzü kullanıcı için daha doğal hale getirmek haline gelmiştir. Cerrahi prosedürlerdeki ilerlemeler, insan beyninin daha iyi anlaşılması, kablosuz teknolojiler ve daha küçük ve daha akıllı elektronik cihazlar ile implante edilmiş sistemler artık geleceğin en önemli seçeneklerinden biri olarak görülmektedir. Gelecek vizyonunda akıllı araçlar ve diğer yöntemler gibi teknikleri kullanarak öğrenen ve kullanıcıya göre yapılandırılan sistemlerin kullanımına da daha fazla odaklanılmaktadır.

## **2.1. Biyolojik Sinyal İzleme Cihazları**

Tıbbi alanda kullanılan cihazlar, sağlık meslek grupları tarafından hastalıkların tanı, önleme, tedavi veya durumunun hafifletilmesi, yaralanma veya mağduriyetlerin giderilmesi amacıyla kullanılmaktadır. Hastalıkların ve rahatsızlıkların giderilmesinde yardımcı olması dışında yaşam kalitelerini arttırmayı sağlayan tıbbi cihazlar, anatomik ve fizyolojik faydalarını da beraberinde getirmektedir. Tıbbi cihazlar analiz ve değerlendirme yaparken biyolojik işaretleri okuyabilmek için biyosensörlere ihtiyaç

duyarlar. Biyosensörler, biyolojik süreçleri anlamamıza yardımcı olan bize gerekli olan bilgileri kodlayan ve fizyolojik değişimleri izlemek için tasarlanmış araçlardır (Tüylek, 2021). Bu sensörler ile gerçek zamanlı, iki veya daha fazla sinyal aktarım mekanizmasına dayalı çok modlu çalışabilmelerinden dolayı ayrıntılı analizler yapılabilmektedir.

### **2.1.1. Biyolojik sinyallerin oluşumu**

Biyolojik sinyaller, insan vücudunda bulunan beyin, kalp, kas ve sinir sistemi organlarının çeşitli faaliyetleri sonucunda oluşurlar. Organlar hareketleri veya akviteleri sırasında yapılarında elektrokimyasal değişimler ile aksiyon potansiyeli oluştururlar. Karmaşık yapıda olan bu sinyaller direkt olarak anlamlandırılmaz ve ölçülemezler. Ölçüm yapılabilmesi için elektrotlar yardımıyla algılanması ve işaretleme işlemlerinden geçirilmesi gerekir. Gözlemlenebilen bu veriler insan sağlığı hakkında bilgi vermekte ve hastalıkların tanı konmasında (teşhisinde) yararlanılmaktadır.


Canlıların en küçük yapı taşı olan hücrenin hemen hemen her zarında membran bulunmaktadır. Hücre membranları, eşik değeri üzerinde bir sinyal ile uyarıldıklarında bağlı oldukları yapıdaki diğer hücreleri bu uyarıları iletmektedirler. Bu uyarılma optik, kimyasal, elektriksel, termal veya mekanik olabilir. Hücre içerisinde  $Na^+$ ,  $Cl$  ve  $K$  iyonlarını barındırır. Mekanik kasılma ile birlikte iyonik yapıdaki bu elementler hücre zarı boyunca akması sonucu elektriksel sinyaller oluşur. Hücreler aksiyon yayılımı sırasında bir kere uyarıldıklarında tekrar uyarılmazlar bu nedenle yayılım tek yönlüdür. Hücrede uyarının yayılma hızı, hücrenin yapısına ve özellik ile sinir lifinin kalınlığına göre değişmektedir (Aytekin, 2018).

### **2.1.2. Biyolojik Sinyal İzleme Cihazları**

Biyolojik sinyaller insanların fizyolojik aktiviteleri ve hareketleri sonucunda aksiyon potansiyeli değişmesi sonucu olur. Bilim dünyası insanların bu aktivitelerini izlemek amacıyla EKG, EMG, EEG, ERG ,EOG gibi cihazları geliştirmiştir.

EKG sinyalleri, kalbin kasılması sırasında ortaya çıkan elektriksel aktivitelerin oluşturduğu biyolojik sinyallerdir. Bu sinyaller içinde kalp ritmi, frekansı ve yayılımı hakkında pek çok veri bilgisini içermektedir. Kalpten alınan analog sinyallerin ölçülmesinde ise EKG cihazı kullanılır. EKG verileri bize kalpten kaynaklanacak birçok hastalığın tanısı hakkında bilgi sunar. Şekil 2.2'de EKG sinyalinin göstermiş

olduğu yayılımı olup P-T dalgası ile Q-R-S kompleksinden oluşmaktadır. Bu yapılar kalp kasının kulakçık ile karıncıklarında meydana gelen elektriksel potansiyeli ifade etmektedir (Türker ve Tarımer, 2016).




Şekil 2.2. EKG işaretine ait dalga şekli (The ECG waveform)(Yakut vd, 2014)

Şekil 2.2' de bulunan, P dalgası kalbin atriyal aktivasyonunun yarattığı elektrik kuvvetleri-ni gösterir. PR aralığı ise, atriyal depolarizasyonun başlangıcın-dan kalbin karıncıklarından gelen erken kasılma (ventriküler) depolarizasyonun başlangıcına dek geçen ile-tim zaman dilimini gösterir. QRS aralığı da kalbin yapmış olduğu ventriküler aktivasyonun süresini gösterir ve ölçü birimi saniyedir. Toplam ventriküler sistolün süresini ise QT aralığı göstermektedir. Devamında oluşan ST segmenti ise ventriküler depolarizasyonun bitmesi ile repolarizasyonun (T dalgası) başlaması arasındaki aralığı bilgisini gösterir. T yayılımı ise kalbin karıncıklarında repolarizasyon tarafından oluş-turulan elektrik kuvvetleri gösterir.

EKG sinyalleri, vücutta göğüs, kol ve bacak bölgesine cilt üzerine yapıştırılan elektrotlardan gelen elektrikselsel aktiviteleri alınarak kalbin yarattığı elektrikselsel aktivitenin ölçülmesine olanak tanır. Elektrotların bağlı olduğu EKG cihazı ölçülen bu aktiviteleri grafiksel olarak dönüştürerek bir kağıda basar. Böylece hekim, ritim ve iletim bozuklukları, kalbin kanlanması, hipertrofi ya da farklı bir deyişle kalp kasının büyümesi gibi anormal durumları bu basılan kağıt ile tespit edebilir.

Elektromiyografi (EMG), çizgili kas veya sinir kasların biyopotansiyellerinin elektrikselsel aktivitesini ölçmek için kullanılan bir testir. Kaslarda meydana gelen bu elektrokimyasal olay ise Elektromiyogram cihazları yardımıyla ölçülür ve dijital

ortamlarda kayıt altına alınırlar. Kas ve sinir hücreleri uyarılabilen hücreler olduğundan “dinlenme” halinde dahi bir potansiyele sahiptirler. Uyarıldıklarında üzerlerinde “aksiyon” adı verilen bir potansiyel meydana gelir (Bronzino, 2000; Bronzino, 2006; Webster, 1998). Vücut sıvısı, yapısında sodyum (Na<sup>+</sup>) potasyum (K<sup>+</sup>) ve klor (Cl<sup>-</sup>) iyonları sayesinde hücreler eşik değerinin üstünde uyarıldıklarında bu uyarılmayı bütün hücrelere yayabilmektedirler. “Dinlenme” halinde iken hücrelerin iyonik bir yapıda olmasından dolayı, hücre içi ve dış ortam arasındaki iyonların farkı bir elektriksel potansiyel fark oluşturur ve bu değer -50 mV ile -120 mV arasında değişir (Kadefors, Kaiser, Petersen, 1968). EMG sinyalleri yüzey elektrodlar veya iğne elektrodları gibi iki çeşit elektrotlarla da ölçülebilirler. Şekil 2.3’ de örnek bir EMG sinyali gösterilmiştir.



Şekil 2.3. EMG sinyali örneği (Ayaz, 2019)

EMG sinyalleri tepeden tepeye 0-10mV aralıkta genliğe sahip olduklarından düşük potansiyele sahiptirler. Alınan bu sinyallerin daha iyi yorumlanabilmesi için çeşitli kuvvetlendirme devreleri ve yöntemleri ile yükseltilmesi gereklidir. EMG sinyalleri, tıbbi anomalilikler ile kas sistemlerinin aktivasyon seviyesini tespit etmek veya çizgili kas veya sinir kas bulunan canlıların biyomekanik hareketlerini analiz etmek için kullanılırlar.


Elektroensefalogram (EEG), beynin elektriksel aktivitesini beyin yüzeyinden veya saç derisi üzerinden ölçebilen düşük genlikli ( 1-400  $\mu$ V) nörolojik bir testir. Genellikle kişiye acı vermemesi için bu sinyaller saç derisi üzerinden alınmaktadır. EEG sinyalleri düşük genlikli olmasına rağmen 0.5-100 Hz aralığında geniş bir frekans bandına sahiptir. Klinik arařtırmaları genellikle 0.5 ile 30 hz aralığında yoğunlařmıřlardır. Frekans aralığı olarak 4 gruba ayrılmıřlardır. Bunlar:

- Delta ( $\delta$ ) Dalgaları: Frekansları aralığı 4 Hz altında olan ve genlikleri 20-400  $\mu$ V arasında deęiřen sinyallerdir. Beynin çok düşük aktivite gösterdięi derin uyku, genel anestezi gibi durumlarda karřılařılmaktadır.Çocukluk çağında ve saęlıklı yetişkinin uyku trasesinde normal olarak saptanabilirler.

- Teta ( $\theta$ ) Dalgaları: Frekansları aralığı 4-8 Hz olan ve genlikleri 5-100  $\mu$ V arasında deęiřen sinyallerdir. Beynin düşük aktivite gösterdięi stres,orta derinlikte anestezi, rüyalı uyku durumlarda karřılařılmaktadır.

- Alfa( $\alpha$ ) Dalgaları: Frekans aralığı 8-13 Hz aralığında ritmik dalgalardır. Yetiřkin bireylerin gözleri kapalı bir řekilde kafanın parieto-okcipital bölgesinden alınarak kayıtdedilirler. Gözlerin açılmasıyla zihni faaliyetle bloke olurlar. Normal bir insanda EEG trasesinde en karakteristik bulgudur.


- Beta ( $\beta$ ) Dalgaları: Frekans büyüklüęü 13 Hzin üzerinde olan dalgadır. Alfa dalgalarına göre daha küçüktürler ve uyanık bir yetiřkinden saçlı deri bölgelerinden alınarak kaydedilirler. řekil 2.4 de frekans bantları gösterilmiřtir.



řekil 2.4. EEG sinyallerinin frekans bantları (Sanei and Chambers, 2007)

EEG sinyalleri kafa travması, felç, beyin tümörü veya nöbetlerde beyin elektriksel aktivitelerinin ortaya çıktığı belirgin dalga türleri görülerek kişi üzerinde teşhis koymak için yardımcı sağlık sektöründe yaygın olarak kullanılmaktadır. EEG sinyallerinin kalitesini hastanın biyolojik yaşı, uyku durumu, ilaç kullanıp kullanmadığı, psikolojisi, hastanın doyunluk durumu, gözlerinin anlık durumu, , beyin hastalıkları duysal uyaranlar, droglar ve vücuttaki meydana gelen değişimlere bağlı olduğu durumlarda değişimler gösterebilir.

Elektroretinogram (ERG), gözün arka kısmındaki ışığa hassas fotoreseptörlerin, konilerin, çubukların ve gözün ışık algılayan retinadaki zarında birbirine bağlantılı sinir hücrelerinin yeteneklerini ölçmek ve tanımak amaçlı bir göz testidir. Göz hastalıklarında retinanın durumunu belirlemek için kullanılırlar. ERG sinyal alınabilmesi için ilk önce stroboskop gibi flash bir kaynak ile göz yüksek bir ışık kaynağına maruz bırakılır. Parlak ışık korneada kaydedilebilen, iki fazlı bir dalga şekli meydana getirir (Erginöz, 2004). ERG cihazı bu verileri Şekil 2.5’de gösterilen A ve B şeklinde ölçülebilen dalgalara çevirir.




Şekil 2.5. ERG bileşenlerin hangi bölgelerden kaynaklandığını gösteren retina resmi (Erginöz, 2007)

ERG dalgaları gençlikte tepe değerine ulaşırken yaşladıkça yavaş yavaş azalır. ERG cihazı Elektrookülogram (EOG) cihazlarının gelişmesi birlikte zamanla değerini yitirmeye başlamışlardır.

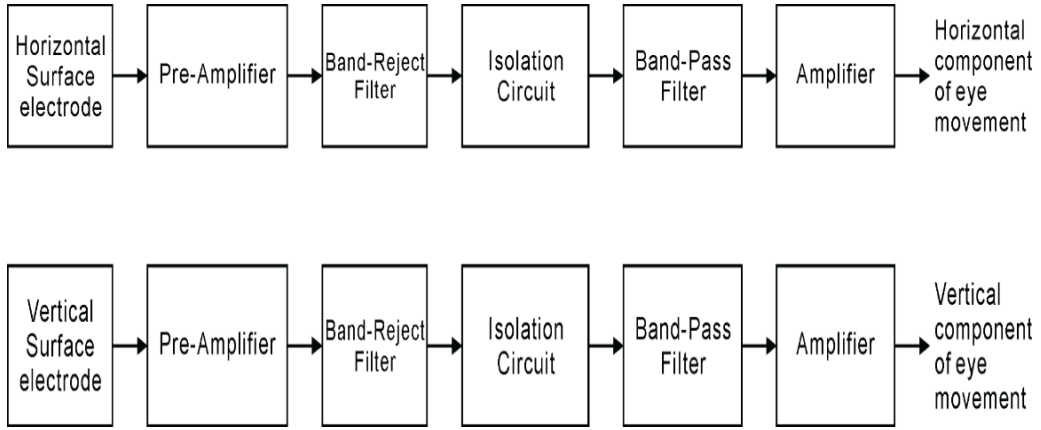
Elektrookülogram (EOG) cihazı ise retina içinde yer alan pigment epitelindeki elektrikselsel aktivite potansiyelinin ölçülmesidir. Gözün ön tarafı ile arkası arasında devamlı var olan potansiyel elektrik değişimi vardır (Menteş vd, 2020). Göz durağan

halde iken herhangi bir potansiyel fark oluşmaz. Göz hareket haline geçtiği zaman ise göz kaslarına bağlı olan elektrotlar sinyalleri alır ve pozitif bir potansiyel fark oluştururlar. Ölçüm içinde jel bulunan elektrotlar Ag-AgCl elektrotları ile vasıtasıyla yapılır. Elektrot geometrisi ve türü incelenen yapıya, gözlenen veya uygulanacak olan yerin potansiyeline göre iğne biçiminden 5 cm çapa kadar değişebilir. Elektrotların çeşitli elektrot uygulamaları Şekil 2.6'de gösterilmiştir. Elektrotlar yüzeysel uygulamalar için disk veya eliptik şekilde yapılan elektrotlara, dokuya iyi temas sağlamak için hafif bir iç büküklük verilir. Yüzey alanı büyüklüğüne göre yetişkin, efor veya pediatrik türleri vardır.



Şekil 2.6. Çeşitli elektrot uygulamaları

Göz yatay ve dikey hareketlerinde EOG sinyallerin ölçülebilmesi için dört adet pediatrik elektrot üst, alt, sağ ve sol göz alanlarına sırasıyla yerleştirilir ve beşinci olarak referans elektrot frontal loba yerleştirilirler. Göz sağa sola yukarı veya aşağı hareket yaptığında kas gücündeki değişimler eş zamanlı ölçüme sahip iki devre elemanı tarafından ölçülürler. Şekil 2.7'de bu ölçüm devresinin blok şeması gösterilmiştir. Göz yapmış olduğu dikey ve yatay hareket sonucu kas elektriksel aktivitesi değişmektedir. EOG 5 kat kazançlı ön anfi takımı yardımıyla tek kutuplu olarak veriler toplanır. İzolasyon devresi ile oluşabilecek sinyal ve hat kaynaklı sorunlar izole edilir. 0,05-30 Hz arasında bant geçiren filtre kullanılarak sinyallerdeki parazitlenmeler engellenir. Daha sonrasında EOG sinyalleri doğrudan doğruya osiloskop ve ekrana iletilebilir hale gelmiş olurlar.

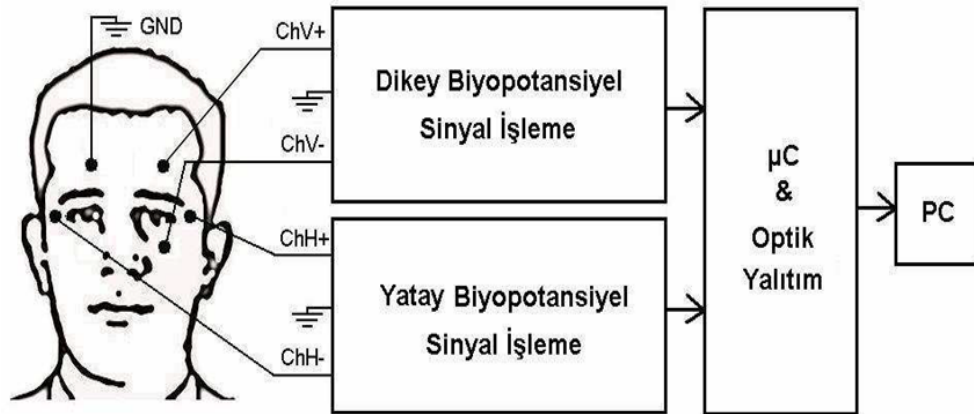


Şekil 2.7. EOG ölçüm devresinin blok şeması

Devre kaynaklı sorunların dışında EOG'nin sinyal bilgisini etkileyen faktörleri, elektrotların konumlandırılması, preadaptasyon zamanı, preadaptasyon zamanı, pupil dilatasyonu, göz çıkıklığı, ışık stimulusunun şiddeti, korneofundal potansiyel ve göz hareketlerinin ivme ve büyüklüğü şeklinde sıralayabiliriz.

## 2.2. EOG Temelli İnsan Bilgisayar Arabirimi

Gözün yatay veya dikey hareketlerini EOG cihazları yardımıyla anlamlı bir yöntemle ve iletişim kurma amacıyla hazırlanan bilgisayar destekli sistemlere EOG Temelli İnsan Bilgisayar Arabirimi denir. Sistemin çalışma prensibi şu şekildedir: yaralanma, hastalık, veya yaşlanmaya bağlı nedenlerden dolayı günlük hayatlarını sürdürmekte zorlanan kişilere, göz kaslarının hareketli olduğu yere bakış hareketlerini yakalamak için (+) ve (-) elektrotlar yerleştirilir. Başın hareketsiz herhangi bir yerine nötr durumu algılamak için ise EOG elektrotun (nötr) kısmı yerleştirilir. Elektrot bağlantısı ve sistemin blok gösterimi Şekil 2.8'da gösterilmiştir.



Şekil 2.8. Elektrot bağlantısı ve sistemin blok gösterimi (Uşaklı ve Gürkan, 2009)

Gözün yapmış olduğu sağa-sola bakma, yukarı-aşağı bakma, sol veya sağ gözü

kırma ile iki gözü kırpma hareketlerinin hepsini algılayabilmek için iki kanallı EOG cihazı seçilir. Tek bir göz hareketinin gerektiği durumlarda ise tek kanallı EOG cihazı seçilir. Kişinin diğer gözünde herhangi bir engel olmadığı sürece iki kanallı kullanılır. Bunun sebebi daha çok hareket alarak kişinin iletişim hızını ve İBA arabirimine sahip donanımların kabiliyetlerini etkili kullanmalarını sağlamaktır. Alınan sinyaller bir filtreden geçirilerek bilgisayara aktarılırlar. Gelen sinyaller makine veya derin öğrenme algoritmaları ile öznitelikleri çıkarılıp yorumlanarak İBA tarafından kullanıma hazır hale getirilirler.


Pek çok disipliner alanın araştırmalarına konu olan İBA “Kullanılabilirlik” kavramını odağına alması sebebiyle günlük hayatta pek çok insanın da deneyimlediği bir alandır. 'Kullanıcı dostu olma', 'insan faktörleri' ve 'kullanıcı deneyimi' gibi terimlerin yanı sıra tavsiye sütunları, tüketicilere yönelik kılavuzlar, karikatürler ve hatta reklamlar gibi pek çok alan insan bilgisayar etkileşimi içermektedir. Bilgisayar kullanan nüfusun artması, bilişim teknolojilerinin günlük hayatın ayrılmaz bir parçası haline gelmesi, akademik anlamda insan davranışlarının ve zihinsel süreçlerin anlaşılması ihtiyacının doğması ile bu alandaki çalışmalar önem kazanmıştır. İBA bilgisayar ve insan arasındaki etkileşimi konu edinmesinden dolayı insan davranışı, , bilişsel bilimler, psikoloji, bilgisayar birimleri ve yazılım mühendisliği yanında , grafik, ergonomi, , sosyoloji, endüstriyel tasarım, antropoloji ve eğitim bilimleri gibi alanlarla da ilişkili bir çalışma alanı olmasının yanı sıra erişim sağlanabilen teknolojilerin tasarlanması ile birlikte alınan değerlerin işlenmesi, değerlendirilmesi ve uygulanmasını sağlamaktadır.

Teknolojinin gelişmesi ile birlikte ve hastalıklar dışında, sağlıklı insanların göz hareketleri ile robotik kontrol, eğlence vb. alandaki ihtiyaçlar bu alandaki ilerlemeyi çok hızlandırmıştır. İnsanın kendi gücünün üstündeki işleri yapma isteği ile birlikte, hesaplama gücündeki ve yaygın ağ oluşturma yeteneklerindeki ilerlemeyle, geleceğin teknolojilerinin kullanıcı odaklı olması ve kişisel koşulları ve gereksinimlerine dayalı olarak her kullanıcıya özel olması bu alandaki yatırımların miktarlarının artmasına sebep olmuştur.

### **2.3. EOG Sinyallerinin Ölçülmesi ve Gözün Yapısı**

Gözün yapmış en önemli hareketi, , superior ve interior rekti kası, medial ve lateral recti kası superior ile interior oblik kaslarından oluşmaktadır sağlanır. Bu kaslar gözleri görüş alanının soyut alanına sabitleyen hareket yapmasını sağlayan

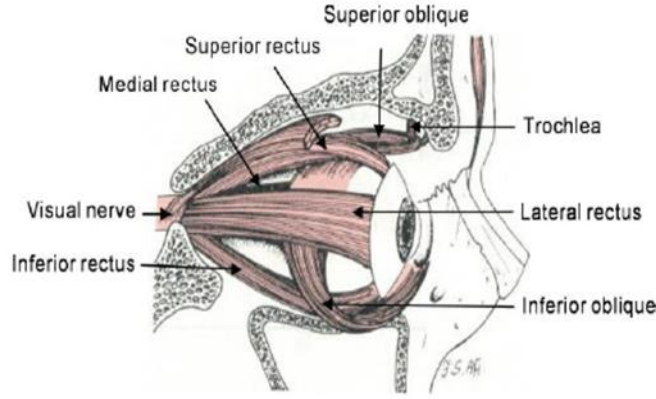
hareketlerdir. Bu hareket mekanizması, oksipital korteksin sekonder bakış alanı tarafından kontrol edilir (MEB, 2012). Rektus superior ve rektus inferior karşılıklı kasılırlar ve göz küresini yukarı veya aşağı doğru hareket ettirirler. Oblik kaslar, görüş alanını doksan derece olacak şekilde pozisyonda tutmak için göz küresini döndürürler. Her iki göz kasları dağılımı simetriktir bu sayede senkron çalışabilmektedirler. Gözlerin yapmış olduğu hareketler ve buna karşılık gelen kaslar Şekil 2.10'da



gösterilmiştir.

Şekil 2.9. Çeşitli elektrot uygulamaları

Görmenin gerçekleşmesi ve beyin tarafından algılanması için görüş sabitlemesi, hedefi retina ortasındaki alanı kilitlenmesi gerekir. Göz kaslarının hareketi ile obje görüntüsü fovea'nın ortasından fovea'nın kenarına doğru hareket ettirilerek, obje görüntüsünü geri fovea ortasına getirmek için refleks tepki, negatif geri besleme mekanizması üzerinden üç çift göz kasının hareketini düzenler (MEB, 2012). Şekil 2.10' de gözün kasları ve elektrotların yerleşim düzeni gösterilmiştir.



Şekil 2.10. Üç çift ekstraokuler kas ve onların pozisyonu (MEB, 2012)

Böylece görüntü yukarı doğru hareket edince göz küresi aşağı doğru hareket eder, görüntü sola gidince göz küresi sağa doğru hareket eder. Her iki hareket de sonunda görüntüyü fovea'nın ortasına geri getirir. Bunun için kilitlenen nesneye göz hareketleri yardımıyla en net görüntüyü elde edebilmek için her zaman fovea'nın ortasına konulacaktır.


Sistemde yatay ve dikey göz hareketlerini eş zamanlı ölçüm yapabilen iki devre bulunur. Beş kat kazançlı bir anfi takımı EOG sinyallerine ait tek kutuplu komponentleri toplamak için ön anfi olarak uygulanır. İzolasyon devresinin fonksiyonu, sinyali ve hat güç kaynağını izole etmektir.

Bant geçiren filtrenin bant genişliği 0,05 ile 30 Hz arasındadır. Alınan sinyallerin düşük olmasından dolayı zayıf sinyaller yükseltilir ve EOG sinyalleri direkt olarak osiloskoba iletilerek görüntülenir. EOG sinyallerinin oluşumunu daha iyi anlamak için gözün yapısı iyi bilmek gerekir. Eog sinyallerinin daha iyi anlaşılabilmesi için gözün yapısı ve göz takip uygulamalarının sınıflandırılması hakkında bilgi sahibi olunmalıdır.

### 2.3.1. Gözün Yapısı

Göz kendisine gelen ışık enerjisini elektro-kimyasal enerjiye çeviren bir aygıttır (Gündoğan, 2018). Atıf vermişsin zaten italik yapmaya gerek yok. Gözün dış duvarı dışarıdan iç kısma doğru Sert Tabaka (Tunica Fibrosa), Damar Tabaka (Tunica Vasculosa), Ağ Tabaka (Tunica Nervosa, Retina), Gözün Kamaraları ve Göz İçi Sıvılar ile gözün yardımcı yapılarından oluşur. Gözün ön kısmında yer alan sert tabaka, gözü ince bir tabaka ile kaplayarak gözün korunmasına ve gözün yüzeyindeki

saydam bir kubbe şeklinde olan korneadan giren ışınların gözün arka kısmında yer alan ağ tabakaya iletilmesini sağlar. Gözün beslenmesinde görevli damarları barındıran damar tabaka koroid, iris ve siliyer cisim adındaki üç cisimden meydana gelmektedir. İris lensin önünde yer alır ve yapısında bulunan kasların daralıp genişlemesi sonucu göze giren ışık miktarının kontrol edilmesini sağlar. Göze rengini veren kısımdır. İrisin dış kenarında komşu olan siliyer cisimi bulunur. Siliyer cismin yapısında bulunan kaslar (siliyer kaslar) lensin kalınlığını ayarlayarak uzaktaki ve yakındaki cisimlerin net görülmesini sağlar. Bu olaya akomodasyon denir. Gözün en içte bulunan kısım olan ağ tabaka pigment epitel ve duysal retinadan oluşur. Pigment epitel yapısındaki pigment epitel ile göz içersinde olan ışınların yansımalarını önler. Ağ tabakanın diğer kısmını oluşturan duysal retina ise fotoreseptörler ile renksiz olarak algılanan ışık sinirsel sinyallere dönüştürür. Şekil 2.12’de gözün yapısı gösterilmektedir.



Şekil 2.11. Gözün Yapısı ( Çakır ve Gündoğan, 2021)

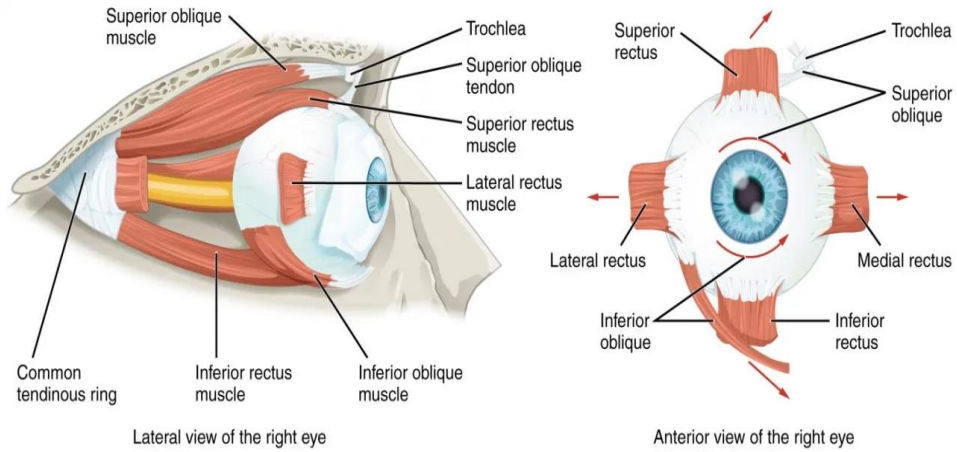
Gözün faaliyetleri sırasında göz içi yapıların stabil kalması ve göz küresinin şeklinin korunması gerekmektedir. Gözün kamaraları yapısında bulunan vitröz boşluk ile göz içi sıvılar da hüner aköz adındaki sıvıyla dolu olması sayesinde bu vazifeyi yerine getirmektedirler. Gözün anatomik ve gözün çalışmasına destek olan gözün yardımcı yapıları bulunur. Bu yapılar temel olarak orbita, göz kapağı, gözyaşı bezi, gözyaşı bezi kanalları ve kirpiklerden meydana gelmektedir. Orbita gözün anatomik olarak gözün yerleşim yeri olan kemikleri, göz kapağı ve kirpikler gözün dış etkenlerden korunmasını, göz yaşı bezleri ise salgıladıkları gözyaşı ile gözün sürekli nemli kalmasını sağlar.

### 2.3.2. Görme Olayı

Görme olayında üç adım bulunmaktadır. Bunlar: ışığın algılanması, ışığın odaklanması ve ışığa dair bilgilerin işlenerek beyne iletilmesidir. Işık ilk olarak korneaya ulaşır. Korneada kırılan ışınlar iris tarafından algılanır. İris, göze gelen ışık ışınlarının miktarına göre göz bebeğini ayarlayarak göz içerisinde işlenecek ışık miktarını düzenler. Göz bebeğinden geçen ışınlar göz merceğine ulaşır ve burada kırınımına uğrar. Ardından camsı cisimden geçen ışınlar ağ tabakada bulunan sarı leke üzerine düşer. Sarı lekede ise, ters görüntü meydana gelir. Beyinde oluşan ters görüntü, sarı lekede yer alan duyu almaçları sayesinde algılanır ve beyin ile sinirler görme merkezine taşınır. Beyindeki bulunan görme merkezinde ters görüntü düz bir şekilde algılanır ve bu sayede de görme olayı gerçekleşmiş olur (Kırgıl, 2019). Gözde oluşan görüntünün konumu göz kasları yoluyla sağlanır.

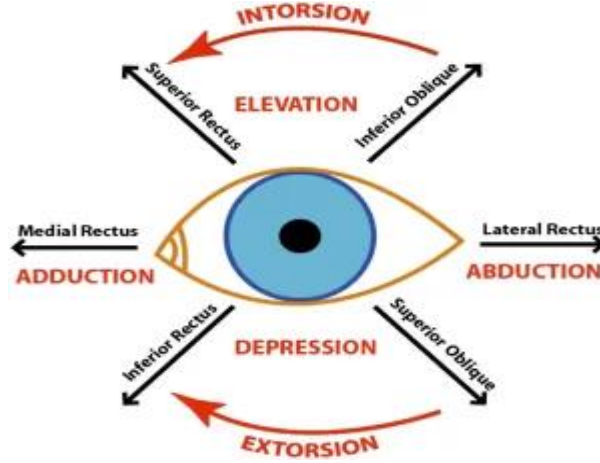
### 2.3.3. Göz Kasları

Göz kasları ekstraoküler kaslar olarak da bilinir. Göz dışında bulunan ve gözün hareketini sağlayan kaslar her hareketin çevresinde bulunan ve göz hareketlerini kontrol etmede gerekli olan kaslardır. İnsanların görme olayı sırasında görmeyi kolaylaştırıcı açısall, rotasyon gibi ayarlamalar yaparlar. Şekil 2.12’de göz dışı kaslar gösterilmiştir.



Şekil 2.12. Göz dışı kaslar (Acır vd, 2018)

Her iki gözün belirli yönlerde hareket etmesine izin veren spesifik fonksiyonlara sahip oblik kaslardır. Gözün yapmış olduğu göz hareketleri Şekil 2.13’de gösterilmiştir.



Şekil 2.13. Gözün Hareketleri (Acır vd, 2018)

Altı farklı kas vardır. Bunlar lateral, medial, inferior ve superior rektus, inferior ve superior. Bu kaslardan ilki olan Medial rektus yörüngede bulunan altı ekstraoküler kasta biridir. Her bir gözü burun yönünde içe doğru hareket etmeye yönlendiren bir kastaır. Yapılan harekete adduksiyon denir. Lateral rektus ise tam tersi bir işlemi gerçekleştirerek gözün burundan uzağa doğru yönlendirilmesini sağlar. Bu kasın yardımıyla gözün dışa doğru yapılan hareketine “abduction” denir.


Superior Rectus kası gözlerin yukarı doğru hareket etmesine, her bir gözün üst kısmını burun yönünde döndürmeye veya intorsiyona yardımcı olur. İnférieur rektus kası ise gözü aşağı doğru yönlendirmeyi ve depresyon gibi ters hareketleri gerçekleştirmeyi sağlar. Her iki ekstraoküler kas da gözlerin doku yapılarına eklemellenmelerine yardımcı olur.

Superior Oblique bu grupta bulunan en uzun kastaır ve sfendoid kemiğin gövdesinden göz küresinin superolateral yüzüne kadar uzanır. Bu kasın görevi, gözü kaçırma ve depresyon hareketlerini sağlar. İnférieur Rectus kası ise gözün kardinal yönlerde yörüngeinin dört düz kasından biridir. Birincil görevi göz küresinin depresyonudur. Göz küresinin hareketlerini kontrol etmek ve bakışın yönünü ayarlamak için diğer göz dışı kaslarla koordineli bir şekilde hareket eder.

Beyin ve omurilikten oluşan merkezi sinir sistemi her iki gözün hareketlerini koordine ederek aynı yöne bakmalarını sağlar. Örneğin sol göz dışarıya doğru hareket ettiğinde, sağ göz şaşılık gibi durumlar hariç burun yönüne hakaret ederek aynı yönü izler. İki gözün yapmış olduğu aynı yöndeki hareketlere versiyon denilir. Göz kasları çok hassas ve bağlantılı bir yapıya sahip olduğundan herhangi birinin zarar görmesi kasların felçlerine veya felçlenmelerine neden olabilir. Çift görme ve diplopi bu

duruma örnek verilebilir.

Sinir sistemi ve kas hücreleri ile basınç reseptörleri uygun bir uyararla uyarıldıklarında zar potansiyellerinde geçici bir değişim olur. Bu değişim eşik değeri aştığında hücreler arası bilgi iletimi sağlanır. Hücre zarında meydana gelen bu kısa süreli ani yükselme ve azalma olayına aksiyon potansiyeli denir. Bir aksiyon potansiyeli, negatiften pozitif doğru dinlenme zar potansiyelinin geçici olarak tersine çevrilmesi şeklinde gerçekleşir. Yeterli derecede uyarın veya uyarılabilen hücreden akım geçtiğinde, eylem potansiyeli adı verilen zar potansiyelinde değişim oluşur. Şekil 14’de bu değişikliğin genel hali gösterilmiştir.



Şekil 2.14. Aksiyon potansiyelinin yapısı

Aksiyon potansiyelinde değişim genellikle birkaç aşama ile ifade edilir. Bu işlemler, reseptörüne ile bağlanan parmağınızla bir tuşa basan bir nörotransmitter bezeri bir sinyale (veya uyarana) cevap olarak, birkaç  $\text{Na}^+$  kanalları açılıp konsantrasyon gradyanı sebebiyle  $\text{Na}^+$  'nın hücreye gönderilmesine izin vermektedir. Depolarize olan membran potansiyeli daha pozitif hale gelir.

Membran potansiyel farkı bir eşik basamağına (genellikle -55 mV civarında) geldiğinde aksiyon hareketi devam eder. Eğer istenilen potansiyele ulaşılmaz ise aksiyon potansiyelini oluşturma ve hücre deaktif membran potansiyel haline geri döner. Bir eşik seviyesine ulaşmak istemesinin sebebi aksiyon potansiyeline ya hep ya da hiç olayı denmesinin nedenidir.

Eşik seviyesine gelindikten sonra voltaj kaplı  $\text{Na}^+$  kanalları açılır ve  $\text{Na}^+$  iyonları hücreye dolar. Zar içinde oluşan potansiyel, negatiften pozitive geçer çünkü hücrenin içi dışarıya göre daha pozitif haldedir.. Membran potansiyeli +30 mV'ye geldiğinde – aksiyon potansiyelinin en yüksek değeri – voltaj kaplı potasyum kanalları

açılıp  $K^+$ , konsantrasyon gradyanı sebebiyle hücreyi terk eder. Membran potansiyel değeri yeniden yüklenir veya negatif yüklü dinlenme potansiyeline doğru geri hareket etmektedir.  $K^+$  iyonları, membran potansiyelinin stabil potansiyelinden birkaç birim düşük daha negatif olmasına sebep olduğundan, nöron sarıh olarak hiper polarize olur. Nöron, sodyum/potasyum nöronu nötr durumda zarı potansiyeline döndürdüğü refrakter bir döneme girmektedir.

Aksiyon potansiyeli yayılırken akson uzunluğu boyunca içeriği diğer nöronlara ileten akson terminallere göre hareket ederler. Yayılma hızları aksonun çapına ve miyelin kaplı olup olmadığına bağlıdır. Bu miyelin kılıflar akson ve elektrik akımının dışarı akmasını önleyerek aksiyon potansiyelinin daha hızlı olmasını sağlarlar. Beyindeki nöron hücreleri ile koordine olarak kasların senkron bir şekilde çalışmasını bu şekilde gerçekleştirmiş olurlar.

#### **2.4. Göz Takip Uygulamaları**

Dünyada engelliler toplumların önemli bir kısmını oluşturmaktadır. OECD-AB ve Türkiye verilerine göre, dünya nüfusunun %15'i engelli bireylerden oluşmaktadır. Başka bir deyişle dünyada “en büyük azınlık” kabul edilen 1 milyar engelli bulunmaktadır (Eyder, 2021). Türkiye’de Ulusal Engelli Veri Tabanı verilerine göre engelli kişi sayısı 1.559.222 kabul edilmektedir. Bunların %27’si 0-21 yaş, %36’sı 22-49 yaş, %37’si ise 50 ile 64 yaş aralığındadır. Yaş ilerledikçe bu oranın daha da arttığı istatistiksel olarak kanıtlanmıştır.

Doğurganlık hızındaki azalma ile birlikte nüfus piramidinde yapısal değişimler yaşanmakta ve buna bağlı olarak nüfusun yaş ortalaması ile yaşlı nüfus artmaktadır. Bu artış neticesinde insan beyin arayüzü kullanıcı algısını esas alan insan makine etkileşim temelli bilgi kanalları geliştirilmiştir. Beyin potansiyel durumuna dayalı eski bir İBA sistemi, kullanıcıları ile etkileşim kurma yetisini sağlamak ve periferik sinirler ve kaslara ait beynin normal sinyallerine benze olmayan kontrol kanalları sunmaktadır. İBA sistemin temel amacı hareket kabiliyetini yitirmiş kişiler ile iletişim imkanı sağlamak, yarı hareket yeteneğine sahip insanların durumda ise tekerlekli sandalye kontrolü gibi imkanlar sağlamak olmuştur.

Merkezi sinir sistemi dışında kalan ve vücudun en dış kısımlarına kadar uzanan sinirleri ifade eden periferik sinir sisteminin yanı sıra, kullanıcıların etkileşim için daha efektif bir bilgi kanalı oluşturması adına etkin alternatif fizyolojik parametre arayışı sonucu göz hareketleri ve takibi önem kazanmıştır. EOG, EMG, EKG gibi sensörlerin

ve donanımların gelişmesi göz hareketlerinin kontrol edilebildiği göz takip sistemlerinin umut verici olmasını sağlamıştır. Haberleşmede erişilebilen bit değerinin, ikili komutlarla sınırlı olmayışı ve kablosuz donanımlar gelişmesi ile birlikte önemi giderek artmaktadır. Arama ve seçim eylemleri için gözün çıktı olarak kullanımını fikri ile insan makine etkileşiminde göz hareketleri çalışmaları karşılık bulmaya başlamış ( Bolt, 1982) ve literatürde kullanıcı bakışlarına odaklanan ve arama görevlerini inceleyen çalışmalar yaygınlaşmıştır.

İnsanların göz hareketleri asıl olarak kişinin dikkatinin zaman hareketlerini içerisinde değişiminin göstergesidir (Kahneman, 1973). İnsan bilgisayar etkileşimi, fare hareketi ve görsel odağın hareketli olarak birbirinin yerine geçmesi anlamına gelmektedir.. Gözün hareketlerini esas alan sistemler kısıtlı olmayan odaklanmalar ve belirli bir ilgi alanında bakışların kaldığı aralıklı süreler dikkate alınarak tasarlanmaktadır. Bu göstergeler genellikle görsel tarama, bir cismin aranması sırasında ve kişiler bir zihinsel aktiviteye angaje olduklarında ortaya çıkmaktadır (Yarbus, 1967). Seçimin belirli kursora tıklanması fare imlecinin göz hareketleri ile yer değiştirmesinden daha zorlu bir süreçtir. Bu yüzyılda birçok çözüm geçirilen süreye (dwell time) bağlantılı önerilmiştir. Bu hareket ile, kullanıcının ön tanımlı bir zamanında, hareket edeceği cisme/objeye odaklı olması gerekmektedir. Bu yöntemde geçirilen sürenin optimizasyonu problemi önem taşımaktadır. Çok kısa olduğunda istemsiz olarak komut oluşmakta ve hataya sebep olabilmekte, çok uzun tutulduğu zaman ise deneyimli kullanıcıların demotive olması ve ilgiyi kaybetmeleri söz konusu olabilmektedir. Bilhassa zaman içinde değişen uyaranlar (Zander vd, 2011) ile oluşturulan karmaşık durumlar esnasında geçirilen zamanın tanımlanması mümkün olmayacaktır.

Göz takibi temelli etkileşim kullanan araçlar bazı kısıtlamalar olmasına rağmen teknik sistemler ile etkileşim içeren rahat ve doğal araçlardır.

#### **2.4.1 İnteraktif Göz Takip Uygulamaları**

Göz takip sistemleri birçok farklı tekniğin birleşmesiyle kullanıcının görsel ve dikkat süreçlerinin nicel bilgisi alınılarak kullanılmaktadır. Genel olarak göz takip sistemlerinin yapısı, “interaktif” ve “tanılayıcı” uygulamalar (Duchowski,2007) olarak ikiye ayrılmaktadır. İnteraktif göz takip sistemi uygulamaları göz bakış verilerini göz hareketlerine göre anlık etkileşim için kullanılmaktadır. Kendi içinde seçmeli ve bakışa bağlı olarak ikiye ayrılmaktadır. Seçmeli sistemler göz hareketlerini bilgisayara

bir veri giriş birimi gibi kullanarak kullanıcıya göz hareketlerine bağlı seçim yapmasını sağlar.


#### **2.4.2 Seçmeli Göz Takip Uygulamaları**

Yatağa bağımlı kalınan durumlarda kişinin göz ve yüz kaslarını hareket ettiremediği durumlarda iletişim niteliğini artırmak için daha çok seçmeli göz takip uygulamaları göz bakışını fare imleci gibi bir seçme aygıtı olarak kullanarak yaşam konforunu arttırmayı hedeflemektedir. Göz kaslarına yerleştirilen elektrotlar ile alınan analog sinyaller bir EOG, EKG veya EMG cihazı ile sayısallaştırılarak bilgisayar ortamına aktarılır. Gözün sağa sola ve diğer yönlere baktığında oluşan sayısal sinyaller bir bilgisayar ortamında makine öğrenmesi veya derin öğrenme yöntemleri ile yorumlanıp kullanıcının yapmış olduğu tercihler bir fare imleci yardımıyla bir arayüz üzerinde gerçekleşmesi sağlanır. Seçmeli göz takip uygulamaları kendi içinde bakışa bağlı, görüntü tabanlı ve model tabanlı göz takip uygulamaları olarak üç gruba ayrılırlar.

Bakışa bağlı göz takip uygulamaları, çeşitli nörolojik bozukluklar veya felç (inme) gibi kas hastalıkları nedeni ile kişinin gözleri dışında uzuvlarını hareket ettiremediği durumlarda kişi ile iletişim kurmak için tercih edilir. Kişi göz hareketleri ile gözünü hareket ettirir ve karmaşık multimedya ortamlarında hızlı seçim yaparak kendisini ifade etmesini sağlar. Bakışa bağlı sistemler görüntü tabanlı ve model tabanlı olarak ikiye ayrılmaktadır.

Görüntü tabanlı göz takip uygulamalarının çalışma prensibi ise öncelikle göz bebeğini gelişmiş bir kamera ve sensör ile izleyerek kişinin nereye, hangi sıklıkla, ne kadar süre baktığını nitel veriye dönüştürür. Dönüştürülen veri görüntü işleme teknolojisi ile anlamlandırılarak uygulamaya dönüştürülmesini sağlar. Sistem ilk başta göz bebeğinin düzgün şekilde algılanabilmesi için IR LED'le aydınlatılır ve hemen peşine kızıl ötesi ışınlar göze gönderilir. Gözün saydam tabakasından yansıyan ışınlar göz bebeğini ayırt edebilen algoritmalar tarafından ayrıştırılarak nesne olarak tanımlanır. Tanımlanan bu nesne kameraların gücüne göre farklı FPS ile alınarak işlenir. Alınan görüntünün işlenebilmesi ve her koşulda çalışabilmesi için görüntü griye çevrilerek histogram germe yapılır. Göz bebeğinin beyaz kısımlarının alınmasının ardından siyah kısmının tespiti için görüntüye eşikleme (threshold) ve ters çevirme (invert) uygulanır ve arka planın siyah, göz bebeğinin ise beyaz olması sağlanır. Görüntü ikili (binary) halde iken erezyon ve dilasyon uygulanır, oluşan

gürültü ve küçük görüntüler yok edilerek sadece göz bebeği ayırt edilir. Göz bebeği daire biçiminde X ve Y koordinatlarından oluşan tek bir nokta belirlenir ve kişiye göre kalibrasyon yapılır. Alınan X ve Y koordinatları bilgisayar ara uygulamaları ile fare imleci gibi kullanılması sağlanır. Şekil 2.15’da gözün hareketlerinin tespiti için yapılan hareketler görüntülenmektedir.



Şekil 2.15. Griye çevrilmiş kameradan akan göz görüntüsü (a), histogram germe uygulanmış görüntü (b), eşikleme, erozyon ve dilasyon uygulanmış görüntü (c), göz bebeği merkezinin vektörel hareket için tespit edilmesi (d). (Turan, 2021)

Model tabanlı yöntemde ise kişi bir gözlük kullanarak model geometrisini doğrudan manipüle ederek çözünürlüğü azaltmayı amaçlar. Geometrik nesnelerin çözünürlüğünü basitleştirme tekniği ile izleyiciden uzaklaşarak kişi sanal bir ortamda göz hareketleri ile kendini yönlendirebilir ve ifade edebilir. Üç boyutlu nesnelere kişi gözünü hareket ettirdiği yöne doğru her bir göz için bir veya iki ekranla gönderilen yayın ile cihazın arasına yerleştirilen lensler yardımıyla iki boyutlu (2D) görüntüye yeni bir bakış açısı kazandırılarak stereoskopik bir 3D görüntü oluşturulur. Oluşturulan görüntüler 360 derece tasarlanmış üç boyutlu bir evren içinde olduğundan kişi kendini sanallaştırılmış gerçek bir dünyada gibi nesnelere etkileşimde bulunabilir. Günümüzde VR gibi gerçek zamanlı çalışan uygulamalarda kullanılır.

### 3. MATERYAL VE YÖNTEM


#### 3.1 Sistem Analizi ve Tasarımı

Sistem, bir amacı gerçekleştirmek üzere bir arada çalışan, birbiriyle ilişkili parçalardan oluşan, girdi ve çıktıları ve sınırları belirli olan bir bütündür. Başka bir deyişle sistem, aralarında ilişki bulunan bileşenlerden oluşmakta ve belli bir amaca yönelmektedir (Erdal, 2022). Yazılım sektörü bir sistemi, o sisteme uygun yazılımla buluşturmaya ve sistemin bu yazılımla varlığını daha verimli, etkili ve kaliteli bir şekilde devam ettirmesine olanak sağlamayı amaçlamaktadır. Tutarlı ve iyi işleyen bir sistem için sistemik yaklaşım gereklidir (Turkau Araştırma, 2021). Bu insan arayüz arabirimi çalışmasında bir bilgisayar ve insan etkileşimi olduğundan tasarım iki kısımdan meydana gelmektedir. Birinci tasarım aşaması kişilerden veri alınabilmesi için donanım aşamasından ikincisi ise alınan verilerin anlamlandırılabilmesi için yazılım analiz tasarımından oluşmaktadır.

##### 3.1.1 Donanım Tasarımı

Eog sinyalleri yaklaşık 0-100 Hz frekans bandında ve düşük bir genlik aralığı olan 50-3500  $\mu$ V civarında olduğundan bir dış elektriksel etken, örneğin mikrodenetleyiciye veri transfer sırasında kopukluklar veya harici gürültü atılmış olsa bile, kas aktivitesinden hariç potansiyeller, örneğin göz hareketi, kayıta bozulmalara sebep olabilir (Pfurtscheller, Da Silva, 1999). Hassasiyetin yüksek olması ve elde edilen sinyaldeki gürültünün arındırılabilmesi için seçilecek olan filtrenin de frekans aralığına uygun olması gerekmektedir. Sistemin azami çalışması ve istenilen orjinal sinyale yakın olabilmesi için örnekleme oranının yüksek seçilmesi sistemin senkron veya asenkron çalışmalarda doğruluk oranını yükseltecektir.

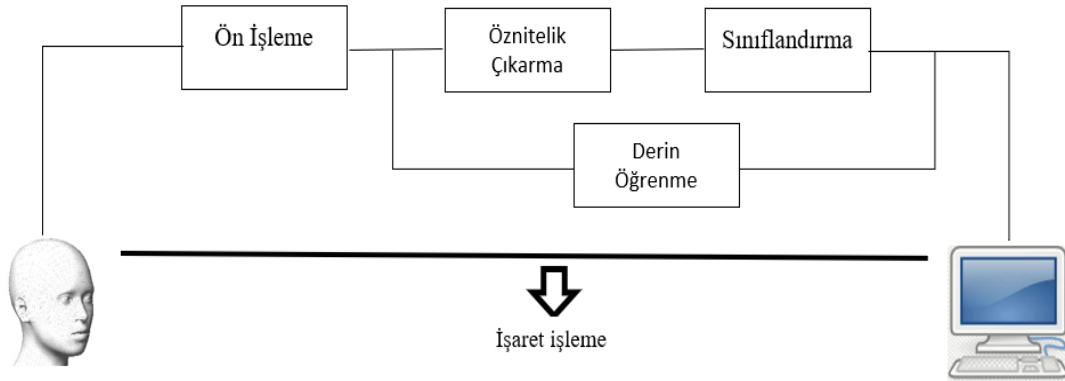
Analog sinyali dijital sinyale çeviren mikrodenetleyicinin veri transferinin seri ve yüksek olması dolayısıyla düzgün EOG sinyali elde edebilmek için iletim hızının yüksek olması gerekmektedir. Şekil 3.11'de yapılan donanım tasarımı gösterilmektedir.



Şekil 3.1. Donanım tasarımı

### 3.1.2 Sistem Tasarımı

Donanım tasarımı ile kurulan alt yapının devamı olarak işlenecek verilerin bilgisayar sistemlerinin verimli bir şekilde çalışması için sistematik bir yaklaşım gereklidir. Sistem tasarımı ile donanımsal bilgiler modüler ve algoritmik bir yapıya dönüştürülmüş ve Şekil 3.2’de de görüldüğü gibi akış diyagramı ile işlem basamakları belirlenmiştir.




Şekil 3.2. Akış diyagramı

Tasarlanan akış diyagramı Şekil 3.2’de de görüldüğü gibi ilk basamak olan ön işleme aşamasında bir arduino uno ve iki adet Olimex EOG/EMG kartı ve bağlantı elektrotları ile veri alınırken Chebyshev bant geçiren filtre kullanılarak Matlab programı ile kayıtlar alınmıştır. Alınan ham veriler birleştirildikten sonra iki değerlendirmeye alınmıştır. Birinci etapta öznitelik çıkarılarak python sklearn kütüphanesinde makine öğrenmesi ile sınıflandırmaya tabi tutulmuştur. İkinci etapta ise “ilişkisel” ve “etiketli” alınan ham veriler python pandas ile sklearn kütüphaneleri

kullanılarak analize tabi tutulmuştur. çıkan sonuçlar karşılaştırılmış ve yorumlanmıştır. Sistemin bağlantı şeması Şekil 18'de gibi kurulmuştur.

### 3.2 EOG Kayıtlarının Alınması


EOG sinyallerinden veri alınırken iki kanallı bir yapı kullanılmıştır. Kanal-1 gözün yatay hareketlerini algılayabilmek için Kanal-2 ise gözün dikey hareketlerini algılayabilmek için kullanılmıştır. Kanal-1 sinyallerinin alınabilmesi için eksi elektrot gözün sol çukur kısmına artı elektrot gözün sağ çukur kısmına yerleştirilmiştir. Kanal-1 ve Kanal-2 nötr elektrod için alın yüz hatlarında bulunan ve en hareketsiz nokta olan alın bölgesi referans nokta olarak seçilmiştir. Kayıtlar 1000-Hz örnekleme ile alınmıştır. Derin öğrenme ve Makine öğrenmesinde doğruluğun sağlanması, verilerin düzgün ve anlaşılır olması için tüm kişilerde aynı referans noktalar seçilmiştir. Seçilen referans noktalarının gösterimi Şekil 3.3'de gösterilmiştir.



Şekil 3.3. EOG 2 kanallı kablo kullanımı


Eog tabanlı insan bilgisayar arabirimi için yedi farklı göz hareketi belirlenmiştir. Bu göz hareketleri; sola ve sağa bakma, yukarı ve aşağı bakma, sol ve sağ gözün ayrı kırılması ile iki gözün aynı anda kırılmasından oluşmaktadır. Kayıtlar biri erkek çocuk, yedi bayan ve 17 erkek toplam yirmi beş farklı bireyden 20'şer adet alınmıştır. Her kayıta yedi farklı göz işaretinden rastgele oluşturulmuş ikişer adet komut örneği bulunmaktadır. Daha sonra her komut otomatik ayrıştırılarak toplam 1120 adetlik geniş bir veri seti oluşturulmuştur. Kayıtlarda senkronizasyonunu sağlamak için ekranda gözün noktayı takip edeceği bir uygulama oluşturulmuş ve bireyler ekrandan 50 cm uzağa oturtulduktan sonra onlardan bu noktanın kayıt sonuna kadar takip edilmesi istenmiştir. Uygulama, rastgele bir şekilde seçtiği yedi komuttan biri için noktayı ilgili kısma hareket ettirip tekrar başlangıç noktasına döndürmektedir. Göz kırma durumları için nokta yerine çarpı (x) işareti kullanılmıştır. Kayıt alımı için

MATLAB’da oluşturulan ekran uygulamasının üç farklı örneği Şekil 20’de de gösterilmektedir.



Şekil 3.4. Kayıt için oluşturulan uygulama örnekleri a) Sola bakma b) sağ göz kırpma c) iki göz kırpma

Komutlar arasında gözün akdamasyon sağlaması ve tepki süresinin verimli olması için kısa süre bekleme yapılmaktadır. Her kayıta sırası rastgele belirlenen komutların etiketleri için ayrı bir kayıt daha oluşturulmuştur. Bu etiketler Bu etiketler sayesinde, kayıtların alınmasından sonra komut sinyalleri sınıflarına göre otomatik olarak ayrıştırılabilmektedir. İki kanallı EOG kayıt alımı için örnek bir Şekil 3.5’de gösterilmektedir.




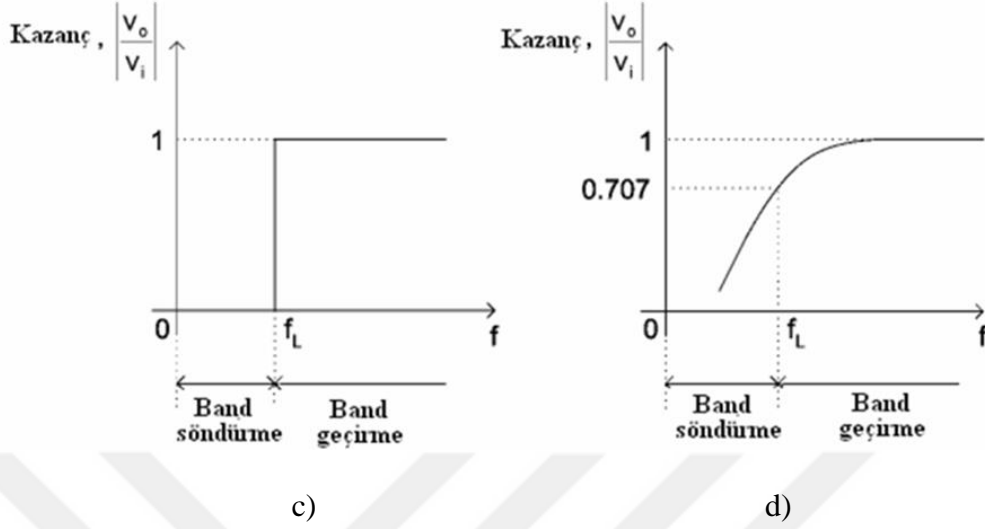
Şekil 3.5. Bir kayıt örneğindeki iki kanal sinyali ve etiketi

### 3.3 Veri Ön İşleme

Elektronik sistemlerde istediğimiz sinyallere karşı iç veya dış etkenlerden dolayı oluşan istenmeyen sinyallere gürültü denir. Analog sinyaller üzerinde oluşan gürültüleri gidermek için ise filtreleme işlemleri uygulanır. Filtreleme işlemi zaman ve frekans domenine bakılarak tanımlanırlar. Filtre, zaman alanındaki sinyali giriş olarak alır, frekans içeriğini değiştirerek zaman alanında bir sinyal verir. Filtreler, sinyali temizlemeden analize kadar farklı şekillerde kullanılırlar. Bazı uygulamalarda, filtreler, istenmeyen frekans içeriğini azaltarak bir zaman alanı sinyalini koşullandırmak için kullanılırlar. Bazende analiz edilirken belirli bir karakteristiği sinyal verisine eklemek için kullanılırlar. Filtreler analog sinyaller gibi sürekli halde olan sinyaller için (DTA Mühendislik, 2021) sistemlerde veya dijital olarak (önceden kaydedilmiş bir sinyalin PC’de manipülasyonu için) uygulanabilirler.

Filtre çeşitleri kendi içlerinde yüksek geçiren, alçak geçiren, bant geçiren ve band durduran şeklinde sınıflandırılırlar. Yüksek geçiren filtreler düşük frekansta olan sinyalleri yükseltmek amacıyla kullanılır. Belirli bir frekans üzerinde kalan sinyalleri zayıflatmak isteniyor ise alçak geçiren filtreler kullanılır. Örneğin, ses kaydı içerisinde yüksek frekanslarda bulunan cızırtıları gidermek için kullanılırlar. Eğer frekans belirli bir bant aralığında olması isteniyorsa, sinyalin sadece belirli bir kısmını filtreden geçirerek bant geçiren filtre kullanılır. Bunun dışında eğer sinyal içinde belirli bir aralıkla olan frekansı silmek için ise band durduran filtre kullanılır. Bu filtreler analog sinyaller üzerinde uygulanırlar. Şekil 3.6’da bu filtre çeşitleri gösterilmiştir.

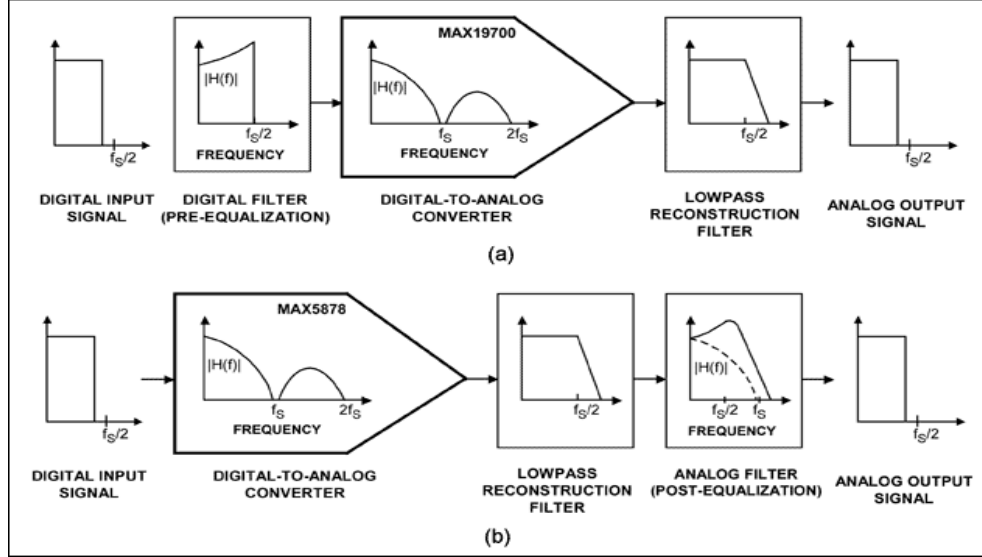




Şekil 3.6. Alçak geçiren filtre karakteristikleri a) ideal filtre b) pratik filtre  
Yüksek geçiren filtre karakteristikleri c) ideal filtre d) pratik filtre

Dijital sinyalleri işlemek için ise Finite Impulse Response (FIR) ve Infinite Impulse Response (IIR) adında iki sayısal filtre çeşidi kullanılır. Sayısal filtreler analog sinyaller üzerinde çalışan, giriş sinyalini istenilen çıkış sinyaline dönüştüren filtrelerdir. Bu filtrenin amacı karmaşık halde bulunan sinyalleri birbirinden ayırt etmek, sinyaldeki gürültüyü azaltarak sinyal kalitesini arttırmak, ve bozulmuş sinyalin tekrar elde edilmesi olarak sayılabilir. Bu sayısal filtrelerde istenilen filtre özellikleri, istenilen genlik ve faz yanıtı bakımından frekans bölgesinde tanımlanırlar. Sonrasında frekans tepkisi özelliklerini belirlemek için IIR ve FIR tepki sayısı belirlenir. Arzu edilen frekans tepkisi veya probleme göre FIR veya IIR filtresinin hangisinin seçileceği belirlenir. Şekil 3.7' de bu filtrelere ait giriş ve çıkış sinyalleri gösterilmiştir. IIR ve FIR filtresinde kullanılan denklemler Şekil 3.1 ve 3.2'de gösterilmiştir.

Şekil 3.6. IIR ve FIR giriş çıkış sinyal gösterimi(Kemal Dağ, 2013)



Şekil 3.7. IIR ve FIR giriş çıkış sinyal gösterimi(Kemal Dağ, 2013)

FIR filtre ve IIR filtre denklemleri ise aşağıda belirtilmiştir.

$$\text{FIR Filter Equation: } y(n) = \sum_{k=0}^N a(k)x(n-k) \quad (3.1.)$$

$$\text{IIR Filter Equation: } y(n) = \sum_{k=0}^N a(k)x(n-k) + \sum_{j=0}^p b(j)y(n-j) \quad (3.2.)$$

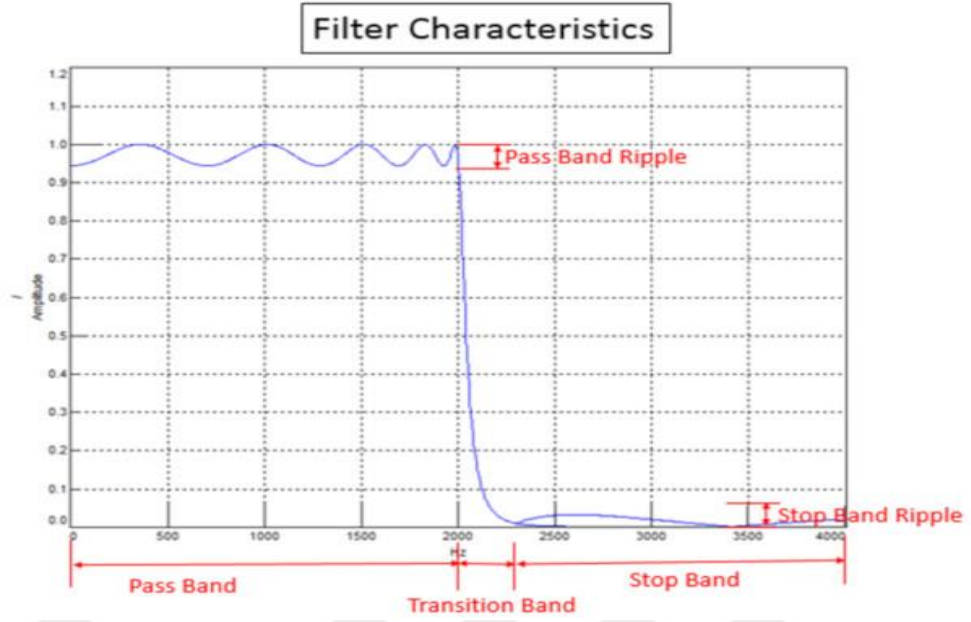
IIR ve FIR filtrelerinin arasındaki matematiksel fark, IIR filtresinin çıkışının bir kısmının girdi olarak kullanılarak “recursive” (özyinelemeli) olmasıdır. FIR ve IIR filtre arasındaki farklar Tablo 1’de gösterilmiştir.

Tablo 3.1. IIR ve FIR filtre karşılaştırılması

Özellik	IIR	FIR
Hesaplama Hızı	Hızlı	Yavaş
Faz / Gecikme	Sabit Değil	Sabit
Stabilite	Daha az Stabil	Stabil

IIR filtresi daha düşük bir merteye veya terim sayısı kullanarak FIR filtresinin yapabildiği özellikte işlemler yapabilir. Fakat FIR filtresine göre faz ve stabilite sorunları vardır. FIR filtresi kullanıldığı durumlarda sonuç alınabilirken bazı durumlarda IIR filtresinden kesin sonuçlar alınamayabilmektedir. Daha yüksek filtreleme, daha keskin filtreleme gerektirdiğinden amaca ve stabil çalışma durumlarına göre verimlilikleri kıyaslanarak bu iki filtreden biri tercih edilir.

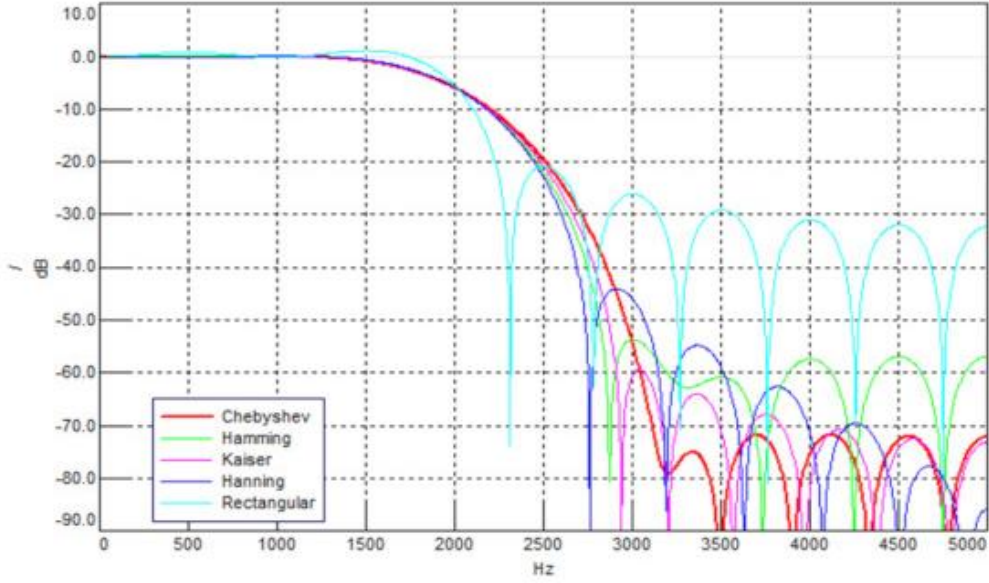
Filtrelerin karakteristiğini geçirenliği, geçiş ve durdurma bandı gibi nitelikleri belirlemektedir. Bir filtrenin genel karakteristiği Şekil 3.8’de gösterilmiştir.



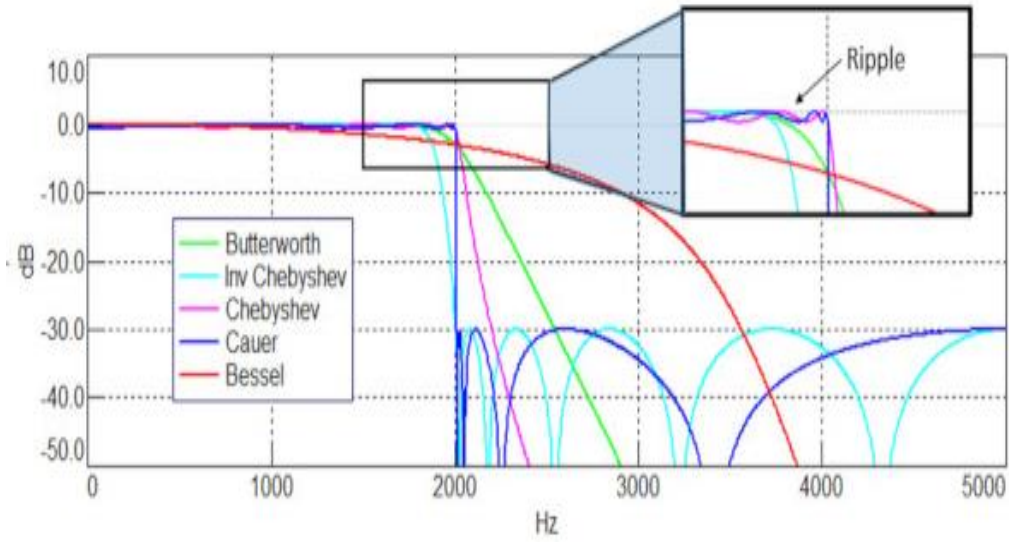
Şekil 3.8. Filtre Karekteristik Grafiği

Filtre uygulamaları sonucunda yöntemlerin etkilediği dört ana filtre özelliği vardır. Bunlar geçirme bandı, geçiş genliği, durdurma bandı ve grup gecikmesi/faz özellikleridir. Geçirme bandında veriler doğrudan çıkış zaman sinyaline gönderilirler. Geçirme bandındaki veriler orjinal zaman sinyali ile aynı olmalı ve dalgalanma olmamalıdır. Dalgalanmalar genellikle frekans fonksiyonunda küçük değişikliklere neden olurlar. İdeal olan ise bu bantta filtrenin tam olarak genliği olmalıdır. Geçiş genişliği uygulamaya bağlı olarak geçirme ve durdurma bantları arasındaki geçiş genliğinin frekans açısından dar olması istenir. Geçiş bandının uzunluğu yöntem ve filtreleme işleminin ne kadar hızlı gerçekleştirildiğini gösterir. Durdurma bandı ise filtrenin dalgalanması olup olmadığını gösterir. Bazı durumlarda genlik önemli olmadığı kadar küçük olabilir bu durumda durdurma bandı önemsiz olarak kabul edilir. Filtrelerin çıkış zamanında sinyalinde bir gecikme oluşur. Bu durumlarda ileri ve geri bir zaman bir sinyal gecikmeyi kaldırır. Gurup gecikmesi/ faz sinyal zaman dilimini bu tip durumlarda bakılır. Fazın kritik olduğu ve sıfırı fazlı filtre işlemimin kullanılmadığı durumlarda dikkate alınması gereken bir husustur.

FIR ve IIR filtreleri farklı metotlar ile yapılabilir. Şekil 3.8'da FIR Şekil 3.9'de ise aynı mertebedeki ve kesme frekansındaki IIR düşük geçiren metotların grafiksel gösterilmiştir.




Şekil 3.7. FIR filtre metotları



Şekil 3.8. Aynı mertebedeki ve kesme frekansındaki IIR düşük geçiren filtre metotları

FIR filtre metotları olarak Chebyshev, Hamming, Kaiser, Hanning, Rectangular kullanılır iken IIR filtre metotları olarak Butterworth, Cauer, Bessel, Inv Chebyshev ve Chebyshev yöntemleri kullanılır. Bu çalışmada her iki filtre metotlarında kullanılan Chebyshev filtresini kullanıldı. Chebyshev filtresi FIR yöntemleri içerisinde durdurma bandında en düşük dalgalanma miktarına ve en geniş geçiş bandına sahiptir. IIR filtre metotları içerisinde dalgalanmayı makul görebilen ve ters Chebyshev'den daha dik düşüş yapıya sahiptir. Şekil 3.10'de Chebyshev filtre karakteristiği gösterilmiştir.



Şekil 3.9 Chebyshev filtre karakteristiği (Yavuz vd, 2007)

Chebyshev filtresi geçiş bandında 3 db'lik dalgalanma yapabilir ve Butterworth filtresinden 10 dB kadar söndürme bandında daha fazla zayıflatma başarımı gösterebilmektedir (Valkenburg, 1982).

Chebyshev filtresi için zayıflama;

$$a_n = 10 \log [1 + \varepsilon^2 C_n(\omega)] \text{ dB} \quad (\text{Baran, 2020}) \quad (3.3)$$

n. dereceden Chebyshev polinomu Eşitlik 3.2.'de gösterilmiştir (Çınar, 2019)

$$C_n = \cosh n \cosh^{-1}(\omega) \quad (3.4)$$

$$|H(j\omega)| = \frac{1}{\sqrt{1 + \varepsilon^2 C_n(\omega)}} \quad (\text{Han, Kamber, Pei, 2011}) \quad (3.5)$$

Geçirme bandındaki maksimum zayıflatma  $C_n(\omega) = 1$  olduğunda olur.

$$a_{\max} = 10 \log [1 + \varepsilon^2] \quad (\text{Kavzoğlu ve Çölkesen, 2010}) \quad (3.6)$$

$$7 \varepsilon = \sqrt{10^{0.1 a_{\max}} - 1} \quad (\text{Vapnik, 1995}) \quad (3.7)$$

n: filtrenin derecesi

$a_n = \text{dB}$  cinsinden geçiş bandı dalgalanmasıdır.

Chebyshev filtrenin parametrelerinin bulunması için, tasarlanacak filtrenin derecesi (n), geçiş bandında istenilen maksimum zayıflama değeri (amax) ve geçirme

durdurma bant frekans deęerleri bilinmelidir. Chebyshev polinomu elde edebilmek için kutup deęerleri formülü ařaęıda gösterilmiřtir.

$$a = \frac{1}{n} \sinh^{-1}(10^{0.1a_{\max}} - 1)^{-1/2} \quad (\text{Vapnik, 2000}) \quad (3.8.)$$

$$a_k = \pm \sinh a \sin \frac{2k+1}{2n} \pi \quad (\text{Akca, 2020}) \quad (3.9.)$$

$$\beta_k = \pm \cosh a \cos \frac{2k+1}{2n} \pi \quad (\text{Wang, Miao, Xie, 2011})$$

$$p = \sigma + j\beta \quad (\text{Cheng, 2009})$$

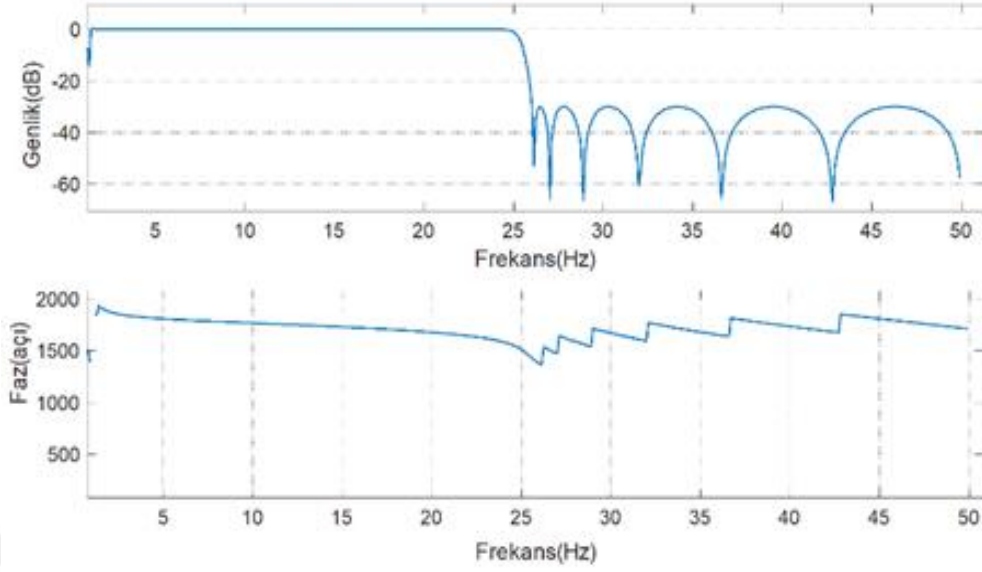
Kutup bulunduktan sonra filtrenin kesim ya da merkez frekansı ( $0\omega$ ) (Yavuz vd, 2007) ve kalite faktörü (Q) bulunabilir. Filtreleme iřleminin derecesi büyüdükçe kutup deęerlerinin sayısı artacaęından polinomun bulunması güçleřecektir. Örnek olarak ařaęıda 2. dereceden bir filtrenin polinom eřlikleri (Dilki Bařar, 2020) gösterilmiřtir.

$$s^2 + 2as + a^2 + \beta^2 \quad (\text{Dilki ve Bařar, 2020}) \quad (3.10.)$$

$$\omega_0 = \sqrt{a^2 + \beta^2} \quad (\text{Hu vd, 2016}) \quad (3.11.)$$

$$Q = \sqrt{a^2 + \frac{\beta^2}{2a}} \quad (\text{Prasath vd, 2017}) \quad (3.12.)$$

Aksonlarda meydana gelen deęiřim, kaslarda meydana gelen titreřim, gözün yapmış olduęu kırpma veya saę-sol hareketinden kaynaklanan gürültüler gibi etkenler EOG gürültülerini yok etmek için standart yaklařım, lineer sayısal filtrelerdir (Acır vd, 2018). Literatürde, EOG iřaretleri 0.1 Hz ile 20 Hz arasında anlamlı iřaretlerdir. Düşük frekansta olduklarından üzerlerinde gürültüler oluřmaktadır. Çalışmada EOG sinyallerindeki istenmeyen bileřenleri ve gürültüleri azaltmak için, kayıp miktarını düşük tutması ve geniř bir geçiř bandına sahip olmasından dolayı Chebyshev filtreleme metodu seçilmiřtir. Őekil 3.11'de Chebyshev bant geçiren süzgeç grafięi genlik ve faz daęılımları gösterilmiřtir.

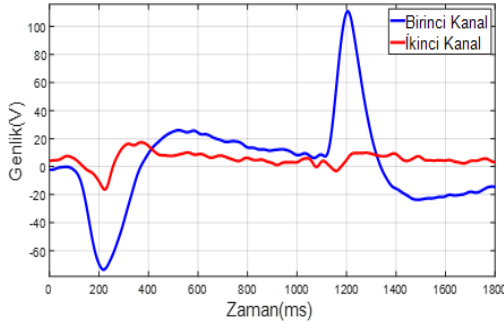


Şekil 3.10. Chebyshev bant geçiren süzgeç


### 3.4 Öznitelik Çıkarma Yöntemleri

Makine öğrenimi, örüntü tanıma ve görüntü işleme alanlarında kullanılan öznitelik çıkarımı (özellik çıkarımı), girdi olarak verilen ölçülmüş verileri kullanarak türetilmiş değerler (öznitelikler) oluşturur. Türetilen bu değerlerin amacı, öğrenme sürecini kolaylaştırarak bilgilendirici ve daha iyi anlaşılabilir olması ile uzman kişiler tarafından hızlı bir şekilde yorumlanmasını sağlamaktır.


Büyük ve karmaşık veri kümelerinden çıkarım yapılabilmesi için yüksek bir bellek alanına veya işlemci gücüne ihtiyaç duyulduğundan daha hızlı ve minimum donanım gereksinimi ile işlem yapabilmek için öznitelik çıkarımı ile boyut indirgeme yapılır. Boyut indirgeme ile öznitelik çıkarımının araştırılması sınıflandırma başarımını direk olarak etkilemektedir. Sınıflandırma başarımını yükseltmek ve doğru bir öznitelik çıkarımında bulunmak için öznitelik belirleme işlemi rastgele yapılmamalı ve farklı sınıflara ait veriler görselleştirilmelidir. Bunun yanında ayrıştırıcı olabilecek öznitelikler şekiller üzerinden değerlendirilmelidir. Bu çalışmada kaydı alınan yedi farklı komut sinyalinin görselleri Şekil 3.12’de sunulmuştur.




a) Sola bakma işareti




b) Sağa bakma işareti




c) Yukarı bakma işareti




d) Aşağı bakma işareti



e) Sağ göz kırpma işareti



f) Sol göz kırpma işareti



g) İki göz kırpma işareti

Şekil 3.11. EOG komutlarının iki kanallı gösterimleri

Çalışma için öncelikli olarak öznitelik çıkarımı için literatür taraması yapılmış ve öznitelik çıkarma işleminden önce sinyallerin görselleri dikkatle incelenmiştir. Literatürde 48 farklı öznitelik tespit edilmiş bunlardan çalışmaya uygun olmayan ve matlab programında sinyal üzerinde analizler yapılarak gereksiz görülen öznitelikler çıkarılmıştır. Sonuç olarak 20 farklı özniteliğin araştırılmasının uygun olacağı değerlendirilmiştir.

Bu özniteliklerden ilki işaretlerin enerji analizidir. Enerji analizi, anlamlı verinin hangi kanalda bulunduğu (dikey ya da yatay) ve verinin göz kırpma hareketi mi, herhangi bir pozisyona yönelme hareketi mi olduğunun belirlenmesine yardımcı olmaktadır. Aynı zamanda sol göz kırpma hareketinde bir kanalda veri olmamasından dolayı bu hareketi diğer kırpma hareketlerine göre ayırmaktadır. Enerji formülü aşağıda gösterilmiştir.

Buradan bir işarettaki örnek sayısını örneklerin genliklerini ifade etmektedir. Kullanılan özniteliklerin birkaç tanesi verilerin minimum ve maksimum değerleri ile ilgilidir. Bu iki değer direkt öznitelik olarak da kullanılmıştır.

Sinyallerin minimum ve maksimum değerlerinin formülü;

$$\text{Minimum ; } x_{\min} = \min(x) \quad (3.14.)$$

$$\text{Maksimum : } x_{\max} = \max(x) \quad (3.15.)$$

Bu değerler işaretlerin maksimum ve minimum tepelerinin genliklerini belirleyerek kırpma ve yönelme hareketleri arasında farkları gözlemlenmede kullanılmıştır. Bu iki özniteliğin bir ürünü olan diğer iki öznitelik ise iki tepe noktası arasındaki genlik farkı ve iki tepe noktası arasındaki zaman farkıdır. Yine bu öznitelikler de kırpma ve yönelme hareketlerini ayırmada oldukça etkilidir.

Sinyallerin maksimum-minimum genlik ve maksimum-minimum zaman farkının formülü ;

$$y_{\max-\min} = y(\max(x) - y(\min(x))) \quad (3.16.)$$

$$x_{\max-\min} = \max(x) - \min(x) \quad (3.17.)$$

Maksimum ve minimum özniteliğinin birlikte kullanımı ile bir başka öznitelik türetilmiştir. Bu öznitelik minimum ve maksimum noktalar arasındaki eğimdir. Bu öznitelik sola ve sağa bakma işaretlerini, ayrıca yukarı ve aşağı bakma işaretlerini

birbirinden rahatça ayırabilmektedir. Çünkü eğim özneliği, maksimum tepe noktasının minimum tepe noktasından önce geldiği işaretlerde negatif değer, aksi takdirde pozitif değer almaktadır. Ayrıca bu öznelik yönelme işaretlerinde tepe noktaları arasındaki zaman farkı büyük olduğundan, nispeten küçük değerler alırken, kırpma işaretlerinde tepe noktalar arasındaki zaman farkı küçük ve genlik farkı büyük olduğundan, büyük eğim değerleri alır.

Sinyallerin maksimum-minimum arası eğiminin formülü ;

$$m = \frac{|y(\max(x)) - y(\min(x))|}{\max(x) - \min(x)} \quad (3.17.)$$

Kullanılan bir başka öznelik çeyrekler açıklığıdır. Bu öznelik işaretlerde anlamlı kısımların hangi zaman dilimlerinde yoğunlaştığını anlamada yardımcı olur.

Sinyallerin çeyrekler açıklığının formülü ;

$$IQR = iqr_x \quad (3.18.)$$

Aynı amaçla kullanılan bir başka öznelik standart sapmadır. Buradan bir işaretteki örnek sayısını örneklerin genliklerini, sinyalin ortalama değerini göstermektedirler.

Sinyallerin standart sapmasının formülü ;

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.19.)$$

Kullanılan özneliklerden varyans standart sapmanın karesi, etkinlik ise varyansın kareköküdür. Bu öznelikler verinin sinyaldeki dağılımını belirlemektedirler. Her komut sinyali iki kanallı kaydedildiği için öznelikler de kanallar da ayrı ayrı hesaplanmış ve bir öznelik vektörü elde edilmiştir. Formülleri aşağıda gösterilmiştir.

Sinyallerin varyansının formülü ;

$$A = S^2 \quad (3.20.)$$

Sinyallerin etkinlik değerlerinin formülü ;

$$e = \sqrt{\text{var}(x)} \quad (3.21.)$$

Temel olarak öznitelik seçme yöntemleri bir arama tekniğine ve oluşturulan alt kümelerin sayısının performanslarının değerlendirilmesine dayanır. Makine öğrenmesinde kullanılan algoritmalarının amacı bu seçilen özniteliklerin sayısını azaltmak, gereksiz görülenleri ortadan kaldırmak ve doğruluk oranını arttırarak performansı yükseltmektir. Yöntem olarak öznitelik seçilimi denetimli, denetimsiz ve ikisinin arasında olan yarı denetimli olarak 3 gruba ayrılırlar. Bu yöntemler makine öğrenme araçları ve kütüphaneleri içinde kendine özgü ve gömülüdür. Sınıflandırma problemlerinin çözümüne yönelik olan denetimli öznitelik seçimi, öznitelik ve sınıfların etiketi arasındaki korelasyon ve ilişkiyi esas alır. Burada özniteliklerin önemi ve uygunlukları değerlendirilir. Siber Saldırıları için Rastgele Orman Algoritması Kullanılarak Öznitelik Seçimi Bir öznitelik kümesi  $X = (x^1, x^2, \dots, x^k)$  ve sınıf etiketi  $C$ 'ye sahip belirli bir  $D = (X, C)$  veri kümesi için, denetimli model sınıflandırma doğruluğunu maksimuma çıkaran  $S \subseteq X$  ideal öznitelik altkümelerini bulmayı amaçlamaktadır (Cai vd, 2018). Denetimsiz öznitelik seçim yöntemleri ise tüm öznitelik kümesinin veri dağılımını en iyi koruyan öznitelikleri seçme esasına dayanır. Öznitelik kümesi içinde kümeleme yeteneğine göre en önemli optimal alt kümesini arar ve bu işlem yeni seçilen öznitelikli kümeleme sonuçlarını değiştiremeye kadar işlem devam eder. Bu yöntemin amacı öznitelik seçiminin geçerliliğinin ve tahmininin doğruluğunu geliştirmektir (Cai vd, 2018). İki yöntemin arasında bir seçim yöntemi olan yarı denetimli yöntem ise eğitilen öğrenme modelinin performansını iyileştirmek için kullanılır. Cai ve arkadaşları bu yöntemde puanlama işlemi çoğunlukla uygulanmakta ve varyans puanı, Laplacian puanı, Fisher puanı ve kısıtlama puanı olmak üzere dört kategoride puanlama yapmaktadır.

### 3.5 Sınıflandırma

Sınıflandırma, bir eğitim verisi üzerinden veriyi alt sınıflara dağıtarak elde ettiği öğrenmeyi yeni gelecek veriler için de kullanarak yeni veriyi uygun bir sınıfa yerleştirme işidir. Başka bir ifade ile veri kümesinde bulunan değerlerin bazı özellikler göz önünde bulundurularak hedeflenen işleme kendi veri seti veya başka veri setleri üzerinde öğrenerek en uygun algoritma veya algoritmalar aracılığıyla belli kategorilere ayırma işlemidir[239]. Veri madenciliğinde kullanılan önemli yöntemlerden birisi olan sınıflandırma yöntemi bir hastaya ait verilerin alınarak hastanın hastalığı ile ilgili sınıflandırma yapılması, biyologların yeni karşılaştıkları bir canlı türünün hangi sınıfa

ait olduğunun tespiti gibi pek çok alanda kullanılmaktadır. Sınıflandırmanın amacı farklı veri setlerindeki örüntüyü keşfetmek ve öğeleri ortaya çıkarmaktır. Sınıflandırma algoritmaları ulaşılmak istenen bilgiyi hedefleyerek, veriyi ortak özelliklerine göre belirli gruplara (sınıflara) ayırmaktadır (Çınar, 2019; Han vd, 2011 ).

Veri sınıflandırma işlemlerinde veri setinin eğitim ve test kümesi olarak ayrılması önemlidir. Çıkartılan özniteliklerin başarımı, eğitim kümesinde bulunan maksimum başarımı öznitelik kombinasyonunun, test kümesi üzerindeki sınıflandırma başarımı ile bulunur. Sınıflandırma iki aşamalı bir model kurulması ile başlar. İlk olarak veri setinin analiz edilmesi için “eğitim verisi” (training data) ile sınıflandırma modeli oluşturulur. İkinci aşamada ise elde edilen sınıflandırma modeli, yeni bir veri kümesine uygulanarak sınıfların içinde bulunan nitelikler ortaya çıkarılır. Tahmin edilmeye çalışılan modelin ve sonuçlarının performansının değerlendirildiği yeni veri setine ise test verisi denilmektedir. Eğitim verisinin çeşitliliğinin ve gerçekleştirilen iterasyonun fazla olması test verisinin başarımına etki etmektedir.

Eğitim ve test verisi ayrıştırma işlemleri farklı şekillerde yapılabilmektedir. Örneğin, bütün veri seti içinden %75’lik kısmı eğitim, %25’lik kısmı test verisi seçilebilir. Eğitim veri seti ne kadar büyük olursa uygulamanın sonuçlarının doğruluğu ve kullanılabilirlik göstergesini o kadar arttırmaktadır. Bunun paralelinde büyük veriler yüksek kapasiteli bilgisayarlar gerektirmektedir. Çalışmada eğitim kümesi %80, test kümesi ise %20 seçilmiştir.


Sinyallerin sınıflandırılması, makine öğrenmesi süreci için en önemli kısımlardan bir tanesidir. Çünkü gerçek zamanlı olarak bir sinyalin tanınabilmesi o sinyalin öncesinden bilgisayarda sınıflandırılmış olmasına bağlıdır. Test aşamasında yapılan denemeler sınıflandırılarak ortak bir tanıma kümesi oluşturulup yeni sinyallerin hangi kümeye dâhil olduğu tahmin edilmek istenmiştir.

Sinyalleri sınıflandırmak için birçok yöntem geliştirilmiştir. Bunlardan sıkça kullanılan öznitelik çıkarma işlemine dayalıdır. Öznitelik çıkarma işlemi çok örnekli sinyaller için oldukça önemlidir. Çünkü sınıflandırma aşamasında örnek sayısı fazla birçok sinyal bulunduğundan sınıflandırma işlemleri uzun sürebilmektedir. Örneğin, çalışmamıza ait veri setimizde bulunan her bir sinyal 3600 örnekten oluşmaktadır ve bu örneklerden bini aşkın bulunmaktadır. Süreci hızlandırmak için kullanılacak öznitelikler ile bu 3600 örnek onlu sayılara indirgenecek ve sınıflandırma işlemleri

daha hızlı bir şekilde gerçekleştirilebilecektir.

Sinyaller için öznitelikleri çıkarıldıktan sonra, sınıflandırma aşamasında da birçok algoritma mevcuttur. Bu çalışmada Matlab kütüphanesinde bulunan O'Bard, Bryce ve Kiran (2018) benzeri bir çalışmada kullandığı Classification Learner uygulaması özniteliklerin sınıflandırma başarımlarını değerlendirmek ve sinyalleri sınıflandırmak için kullanılmıştır. Uygulama başarımının daha doğru değerlendirilebilmesi için k-fold çapraz doğrulama yöntemi kullanılmıştır. Çapraz doğrulama yapılırken veri rastgele olarak karıştırılır ve k alt gruba ayrılır ve verileri eğitip test etmek için bu alt gruplar kullanılır. Çalışmamızda k değeri 10 olarak seçilmiştir.

Bir sınıflandırma modelinin başarısı atanan doğru veriler ve yanlış veriler arasındaki örnek sayısı karşılaştırılarak belirlenmektedir. Doğru bir modelin başarısını doğruluk(DSO), duyarlılık (Sensitivity), özgüllük(Specificity), hassasiyet (Precision) ve AUC (Eğri altında kalan alan) gibi ölçütler belirlemektedir. Karşılık matrisi (confusion matrix) ile bu ölçütler hesaplanır. Doğruluk sınıflandırma oranı örnek sayısının toplam örnek sayısına bölünmesi ile bulunur. Duyarlılık (Sensitivity) ise doğru sınıflandırılmış pozitif örnek sayısının toplam örnek sayısına bulunması ile bulunur. Diğer bir ölçüt olan hassasiyet, doğru pozitif değerlerin tahmin etme oranıdır. Son olarak AUC ise sınıfların ayırt edilebilme başarısını gösterir. Çalışmada bulunan örnek Karşılık matrisi Şekil 3.13'de gösterilmiştir.



Şekil 3.12. Karşılık matrisi (confusion matrix)

Çalışma kapsamında sınıflandırma probleminin çözümünde literatürde var olan python sklearn kütüphanesi içerisinde bulunan makine öğrenme algoritmaları ile denenmiş ve içlerinden en iyi performans veren algoritmalar Destek Vektör Makinesi (SVM), K-en Yakın Komşu (KNN), Rastgele orman (RandomForest) ve Karar Ağacı (Decision Tree-ID3) algoritmaları ele alınmıştır.

### 3.5.1 LightGBM (LGMB)

LightGBM, Microsoft DMTK (Distributed Machine Learning Toolkit) projesi kapsamında 2017 yılında geliştirilmiş histogram tabanlı bir boosting algoritmasıdır. Diğer algoritma türlerine göre yüksek işlem hızı, büyük verileri işleyebilmesi ve daha az kaynak tüketimi olması ile birlikte yüksek tahmin oranı, paralel öğrenme ve gpu öğrenimini desteklemesi sonucunda 20 kat hızlı çalışan bir algoritmadır. Değişkenleri sürekli halden değişken kesitli hale getirerek performans ve hesaplama maliyetini azaltır. Bu yeteneği ile makine öğrenmesi algoritmalarında verilerin eğitilme süresini kısaltarak bilgisayarların kaynak tüketimini düşürürler.

LightGBM algoritması, gradyan hızlandırma ile çalışan bir karar ağacı tabanlı bir algoritmasıdır (Microsoft, 2022). Diğer karar ağacı algoritmalarından farklı olarak eğitim aşamasında yaprak odaklı (leaf-wise) büyüme stratejisini kullanmasıdır (Ke vd, 2017; Lee ve Pottier, 2009; Li vd, 2019). Çoğunlukla karar ağacı tabanlı yöntemler ağacın seviyesine odaklı (level-wise) büyüme stratejisini kullanmaktadır (Üstüner ve Şanlı, 2019). LGBM diğer algoritması diğerlerinden başarımının yüksek olmasını sağlayan iki özgün tekniğinin olmasıdır. Birincisi olan gradyan tabanlı tek yönlü örnekleme (Gradient-based One-Side Sampling, GOSS) tekniği, tek yönlü örnekleme ile örnek sayısını azaltarak verinin tümü yerine alt örneklerden veri kümesi kullanması şeklinde çalışır. İkinci teknik olan ayrıcalıklı özellik destekleme ise seyrek yapıda özellikleri birleştirerek daha yoğun olmayan özellikler oluşturarak öğrenme aşamasındaki karmaşıklık seviyesini azaltır. Bu iki özellik dolaylı olarak algoritmanın hızlı çalışmasını sağlar.

LightGBM algoritmasını optimize eden ve başarıyı arttıran parametreleri bulunmaktadır. Bunlar aşırı öğrenmeyi engellemek için `learning_rate`, `max_dept`, `num_leaves`, `min_data_in_leaf` parametreleri ile öğrenim süresini hızlandıran `feature_fraction`, `bagging_fraction` ve `num_iteration` parametreleridir.

Num\_leaves, ağaçta bulunacak yaprak sayısını belirtir. Aşırı öğrenmeyi kullanmak için kullanılan en önemli parametredir. Aşırı öğrenmeyi engellemek için  $2^{(\max\_dept)}$ 'den küçük olması gerekir. Örneğin,  $\max\_depth = 7$ , num\_leaves değerini 127 seçildiğinde aşırı öğrenmeye neden olur. Değeri 70 veya 80 gibi seçmek daha doğru sonuçlar elde edilmesini sağlayabilir.

Max\_dept, kurulan ağacın limitlerini belirlemek için kullanılır. Çok dallanma aşırı öğrenmeye, az dallanma eksik öğrenmeye neden olacağından neden olur optimum değer seçilmelidir.

Min\_data\_in\_leaf, aşırı öğrenmeyi engelleyen en önemli parametredir. İdeal değeri verinin büyüklüğüne bağlıdır. Değer büyük olması ağacın büyümesini engellerken eksik öğrenmeye neden olabilir.


Learning\_rate, karar ağacını ölçeklendirmek için kullanılır ve 0-1 arasında değer alır. Değerin küçük olması iyi tahmin gücüne yardımcı olurken öğrenme süresini arttırır ve aşırı öğrenmeye neden olabilmektedir.

Feature\_fraction her bir iterasyonda kullacak değişken sayısı belirtir. Diğer bir olan parametre bagging\_fraction her iterasyonda kullanacak veri sayısını, num\_iteration öğrenme süresinde kullanılan iterasyon sayısını belirtir. Bu değişkenler öğrenme süresi ile doğrudan ilişkilidir. Sayılar ne kadar az olursa öğrenim süresi o kadar az olur. Eksik öğrenmenin verimli çalışabilmesi değişkenlerin optimum değer alması ile doğru orantılıdır.

### 3.5.2 Destek Vektör Makineleri Algoritması (DVM)

İstatistiksel öğrenmesine dayalı bir kontrollü sınıflandırma algoritması olan DVM, başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir (Kavzoğlu ve Çölkesen, 2010). DVM denetimli bir makine öğrenme algoritmasıdır. Çalışma prensibi iki sınıfın birbirinden hiper-düzlemin tanımlanması esasına diğer bir ifade ile iki sınıfı ayırabilen en uygun karar fonksiyonun tahmin edilmesi adyanır (Vapnik, 1995; Vapnik, 2000). En basit haliyle DVM yönteminde amaç, iki sınıflı iki değişkenli bir sınıflandırmada ilgili öznitelik elemanlarını ayıran doğruyu bulmaktır. Şekil.1 de gösterildiği gibi, bir sınıfa ait öznitelikler (+1) diğer sınıfa ait olanlar ise (-1) ile gösterilir. İlk olarak iki boyutlu düzlem üzerine veriler yerleştirilir. Sonrasında öznitelikleri ayıran doğru bulunur. Şekil 3.14'de iki boyutlu





Şekil 3.14. Çekirdek fonksiyonun özniteliklerinin uzaysal dönüşümü (Wang vd, 2011)

Üç ve üçün üstünde sınıf bulunması durumunda öznitelikler her biri ayrı çıkışa atanır. Bu atanma biçimi “iki sınıflı” atanma biçiminin genişletilmesine dayanmaktadır.

### 3.5.3 K-en Yakın Komşu (KNN)

K-en yakın komşu, makine öğrenme algoritmaları içinde denetimli öğrenmede sınıflandırma ve regresyon analizi yapmak için kullanılan algoritmadır. Makine öğrenme algoritmaları içinde en basit olan ve başarısı nedeniyle fizyolojik sinyallerin analizinde literatürde en popüler algoritmadır. Diğer denetimli algoritmalarından farklı olarak eğitim aşamasında sahip değildir (Wang vd, 2011; Arif vd, Malagore vd, 2012). Yavaş bir öğrenme türü olduğundan büyük veri setlerinde kullanımı pek uygun değildir.

KNN algoritması esas olarak, bir K bilinmeyen noktanın en yakın komşularının miktarıdır. Eğitim setindeki bulunan tüm verileri hesaba katmaz, sadece k ve k'dan daha az farklılığı olan kayıtlar ele alınır (Cheng, 2009). “k” değeri burada küçük ve pozitif bir değerdir. k değerinin küçük veya büyük seçilmesi sınıflandırma işlemi yapılmasında hatalara sebebiyet verir. K değeri genellikle eğitim setinde bulunan öznitelikler yada özelliklerin yarısı kadar bir değer olarak belirlenir. k değeri genellikle kullanıcı tarafından belirlenen, en uygun değeri bulmak için deneme yanılma yöntemiyle atanan bir değerdir. k değeri genellikle tek sayı seçilir. K-NN sınıflandırma da çıktı olarak sınıfın üyelik bilgisi verilir. Komşuluk bilgisine bakılarak eğer k=1 ise nesne en yakın komşuları arasındaki yaygın sınıfa atanır. Regresyon analizinde ise cismin özellik bilgisidir. Sınıflandırma en yakın komşularının ortalaması alınarak

belirlenir. KNN algoritmasında “k” noktaya en yakın kaç noktanın katılacağı formülü aşağıdaki gibidir.

$$Y = (x_1 + x_2 + \dots + x_k) / k \quad (3.23.)$$


Formülde Y değeri eğitim setinde son durumu, x değeri en yakın medodid sahip küme ve k değeri ise küme sayısını belirtir. Knn algoritmasında temel amaç benzer nokta ve değişken gruplarının aynı sınıfa ait olmasını sağlamaktır. Bu noktada bulunurken önceden seçilmiş bir mesafe ölçütü kullanılarak sınıfı bilinmeyen verinin yakınlığı hesaplarak elde edilir (Dilki ve Başar, 2020). Mesafe hesaplamada en çok kullanılan uzaklık ölçüsü, Euclidean uzaklığıdır (Hu vd, 2016). Euclidean uzaklığı Öklid Uzayı  $R^n$  içinde noktası verilen iki noktanın uzaklığının hesaplanması şeklinde ifade edilir.

n boyutlu uzayda Euclidean (Öklidyen) uzaklık formülü;

$$\sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (3.24.)$$

şeklindedir. Burada p ve q değerleri herhangi bir iki noktayı belirtir. Üçgendeki pisagor bağlantısı gibi iki nokta arasındaki mesafe dik açı olacak şekilde ifade edilir.

Euclidean noktasal uzaklık hesaplaması temsili görünümü;



Şekil 3.15. Euclidean noktasal uzaklık hesaplaması temsili görünümü

Euclidean uzaklık uzaklığı dışında Chebyshev, Manhattan, Minkowski gibi farklı uzaklık hesaplama ölçütleri de kullanılabilir (Prasath, vd., 2017). Bu uzaklık değerlerini ait fonksiyonlar aşağıdaki gibi gösterilmiştir.

$$\begin{aligned}
dist_{\min kowski}(x_1, x_2) &= \sqrt{\sum_{i=1}^n |x_{1i} - x_{2i}|^2} \\
dist_{\text{manhat tan}}(X_1, X_2) &= \sum_{i=1}^n |x_{1i} - x_{2i}|^2 \\
dist_{\text{chebyhev}}(X_1, X_2) &= \max |x_{1i} - x_{2i}|^2
\end{aligned} \tag{3.25.}$$

KNN sınıflandırılmasında problemin çeşidine göre mesafe ölçümü uygulanmalıdır. Literatürde farklı uzaklık ölçütleri kullanılarak kNN algoritması özelinde daha doğru sınıflandırmalar yapılabileceğini gösteren çalışmalar mevcuttur. Çalışmada mesafe ölçümü için Euclidean yöntemi kullanılmıştır.

KNN algoritması ile kurulmuş modelin başarısını ölçmek için genel olarak 3 indikatör kullanılır. Bunlar:

Jaccard Index: Tahmin edilmek istenen ile gerçek değer kümesinin birleşim kümesine oranıdır. 0 ile 1 arasında değer alır. En iyi sonuç 1, en kötü sonuç 0'dır.

F1-Score: Confusion matrix çıkarılırken üzerinde hesaplanan precision ve recall değerlerinden hesaplanır. Formülleri:

$$Pre = TP / (TP + FP) \tag{3.26.}$$

$$Rec = TP / (TP + FN) \quad F1\text{-Score} = 2 \cdot ((Pre \cdot Rec) / (Pre + Rec)) \tag{3.27.}$$

şeklinde. 0 ile 1 arasında değer alır. 0'dan 1'e doğru başarı oranı artmaktadır. En iyi sonuç 1'dir.

LogLoss: Logistic Regresyon uygulanması sonucunda tahminlerin olasılıkları üzerinden hesaplanır. 0 ile 1 arasında değer alır. En iyi sonuç 0, en kötü sonuç 1'dir.

Eğitim verilerindeki bağımsız değişkenler farklı birim oldukları durumlarda, mesafeyi hesaplamadan önce değişkenlerin standardize edilmesi gerekir. Örneğin bir değişken metre cinsinden iken diğer bir değişken kg cinsinden olabilir. Veriler üzerinde analiz yapmak için bu değerleri standartlaştırılması gerekmektedir. Bu çalışmada özniteliklerin bir formül ile bulunmasından dolayı farklı büyüklükte değerler ortaya çıkmaktadır. Karmaşıklığı azaltmak ve sonucu karşılaştırabilmek için standardizasyon işlemi yapılmıştır. Aşağıda formüllerle gösterilen farklı tipte standartlaştırma işlemi gösterilmiştir.


$$x_s = \frac{X - \text{mean}}{s.d.}$$

$$x_s = \frac{X - \text{mean}}{\text{max} - \text{min}}$$

$$x_s = \frac{X - \text{min}}{\text{max} - \text{min}}$$
(3.28.)

### 3.5.4 Rastgele orman (RandomForest) Algoritması

Rastgele orman (RO) algoritması denetimli bir sınıflandırma algoritmasıdır. RO, model toplama fikrine dayalı oldukça hassas olan sınıflandırma ve regresyon görevleri için kullanılan bir öğrenme algoritmasıdır (Acır, Mengü., Çınar, 2018). RO isminden de anlaşılacağı üzere her bir ağacın bir sınıf için oy kullandığı ve ormanın, ormandaki tüm ağaçlar arasında en çok oyu alan sınıflandırmayı seçen deneme yöntemiyle eğitim verilerden rastgele seçim ile çok sayıda karar ağacı üretmesine dayanır. Basitçe aktaracak olursak birden fazla karar ağacı oluşturulur ve daha doğru tahminler etmek için ağaçlar birleştirilir. RO en büyük avantajı hem sınıflandırma hemde regresyon problemlerinin çözümünde kullanılabilmesidir. Sınıflandırma öğreniminin yapı taşı kabul edilir. Şekil 3.17’de basitçe gösterilmiştir.



Şekil 3.16. RO iki ağaçlı basit gösterimi (DevHunter, 2018)

RO sınıflandırma problemlerinde diğer öğrenme yöntemleri ile karşılaştırıldığında eğitim aşamasına göre diğerlerinden çok daha hızlıdır. Yeterliliği ve doğruluğu kanıtlanmış çok kullanışlı bir sınıflandırıcıdır (Gislason vd, 2006). Boosting ve Bagging yöntemleri ile ağaçların sınıflandırılması da toplu öğrenme için

kullanılan iki yöntemden geliştirilmiştir. Bagging yönteminde eğitim verileri kullanılarak öznitelikler için birer ağaç inşa edilir. En büyük oy tahmin için alınır ve ardışık gelen ağaçlar bir öncekinden bağımsız çalışırlar. Boostingde yönteminde ise ardışık gelen ağaçlar bir öncekine bağlıdır. Tahminde yanlış bulunduğu zaman ise ekstra ağırlık verilerek problem çözülür. Sonrasında ağırlıklı oy tahmin için alınır (Liaw ve Wiener, 2002). RO, Bagging yöntemini kullanmaktadır (Breiman, 2001).

Toplu öğrenmede gerçekleirebilmek için RO algoritmasında öncelikli olarak her bir ağacı geliştirmek için rastgele vektörler oluşturulur. Her düğümde bulunan splitler, K en iyi olan splitler arasından seçilir. Oluşturulan  $\theta_K$ 'lar birbirinden bağımsızdır. Eğitim verisindeki örnek sayısı N kadardır. Rastgele seçilen vektörler N tane kutuya yerleştirilirler. Sonrasında split seçimleri randomize olacak şekilde seçim yapılır. K değeri 0 ile 1 arasında bir değer olur ve bağımsız integer bir sayıdır. Kapsamlı bir sayıda ağaçlar oluşturulur ve popüler sınıf için oylanırlar. Sınıflandırma formülü ;

$$\{h(x, \theta_k = 1, \dots)\} \text{ şeklindedir.} \quad (3.29.)$$

Formülde x değişkeni girdi verisini,  $\theta_K$  ise rastgele vektörü temsil eder. Her bir ağaç bir sınıf için atanır ve bu işleme Rastgele Orman denir.

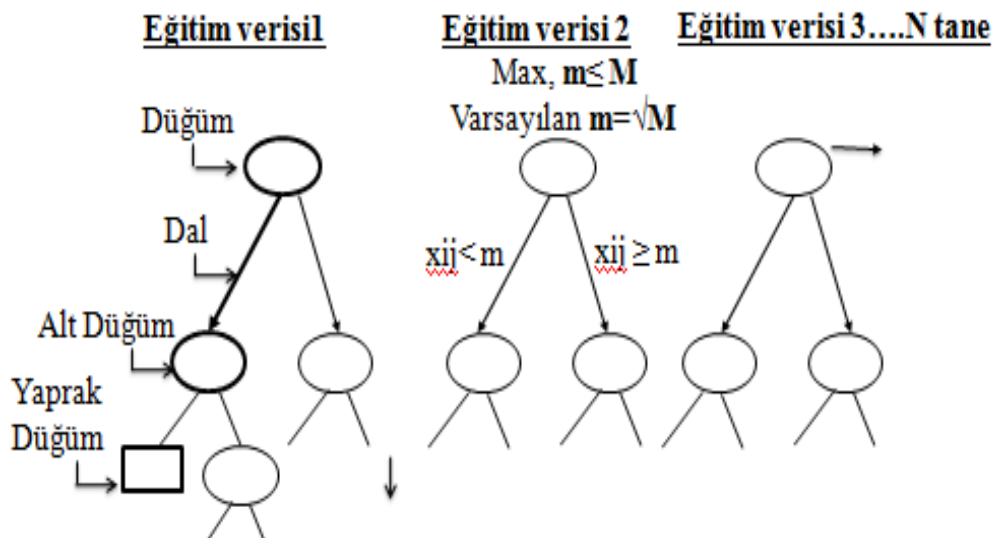
RO, kendi içersinde birçok sınıflandırılmış ağaç geliştirir. Girdi verileri yeni bir obje sınıflandırılması için ormandaki her bir ağaca yerleştirilir. Her bir ağaç her sınıflandırma demektir. Her ağaç için ağaç oyları belirlenir. RO en yüksek oya sahip sınıflandırmayı seçer.

RO sınıflandırıcı bir ağaç üretmek için 2 parametre gereklidir. Birinci parametre, en iyi bölümlenmeyi tespit etmek için her bir düğümde kullanılan değişkenlerin sayısı (m) ve ikinci parametre olarak ise ağaçların sayısı (N)'dir (Pal, 2005). m değeri kullanıcı tarafından rastgele seçilir ve alınan out-of-bag hatalarına karşı arttırılır yada azaltılırlar. En uygun m değeri bulunarak bu şekilde sınıflandırma duyarlılığı azaltılır yada arttırılır. Her bir yer değişiminde RO algoritması tahmin hatasının ne kadar olduğunu inceleyerek değişkenlerin önemini ve etkilerini hesaplarlar (Liaw ve Wiener, 2002). Değişkenlerin önem seviyeleri yerleri değiştirilerek yapılır ve sonuçlar değişkenin önemi ortaya koyar.

RO, ham ve budama olmadan ağaç geliştirmek için CART (Classification and Regression Tree) algoritmasını kullanmaktadır (Breiman, 2001). CART algoritması ağaç yapısı kurulurken bir metot belirlenerek bölünme işlemi ile gerçekleştirilir. Metodun gerçekleştirebilmek için öncelikle tüm öznelikler değerlendirilir ve eşleşmeler ile ikili bölünmeler seçme işlemi ile elde edilir. Bölünme işleminde dağılımı homojen olan sınıflar tercih edilir. Düğüm homejenliğinin tespiti için Gini İndeks, Entropy, Yanlış Sınıflama Hatası (Misclassification Error), Gain Oranı Kriteri (Gain Ratio Criteria). RO algoritması Gini indeksini kullanmaktadır. Gini indeksi formülü aşağıdaki gibidir.

$$Gini = 1 - \sum_{i=1}^n (p_i)^2 \quad (3.30.)$$

Burada  $p_i$ , bir nesnenin belirli bir sınıfa sınıflandırılma olasılığıdır. Gini değerinin ölçümüyle Gini indeksine sahip olan bölünme pozisyonu belirlenir (Takçı, 2008). Gini katsayısı büyüdükçe homojenlik azalır. Katsayı azaldıkça ise sınıfı homojenliği artmaktadır. Ağaçtaki dallanmalar incelenirken bir alt düğümün gini indeksi bir üst düğümdeki Gini indeksi küçük olduğu düğüm başarılı kabul edilir. Ağaçtaki dallanma işlemi gini indeksinin sıfıra ulaşması ile son bulur. Ağaç sayısını belirlemek için her düğüm için en iyi dal belirlenir ve o kadar ağaç üretilir (Liaw ve Wiener, 2002). Kısaca eğitim verileri kümesinde değerler kullanarak belirlenen ölçütlere göre düğümler dallara ayrılarak ağaç yapıları oluşturulmaktadır. RO sınıflandırmasına göre optimum bölünme pozisyonlarına bakılarak oluşturulan ağaç yapısı örneği Şekil 3.18’de gösterilmiştir.

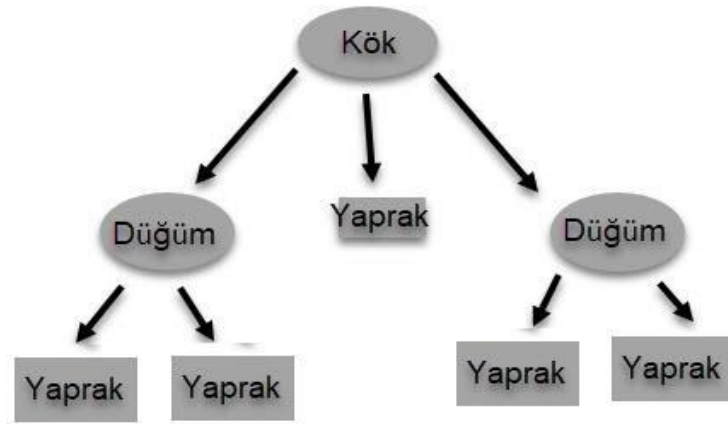


Şekil 3.17. RO yöntemine ait ağaç yapısı (Ok, Akar, Güngör, 2011)

Şekilde gösterilen Xij değerleri girdi verileri göstermektedir. Ağaç yapısı kurulduktan sonra girdi verisi ormandaki her ağaca yerleştirilir ve belirlenen ağaçlar arasında oylama yapılır en çok oyu alan ağaç sınıfa atanır. Çalışmada ağaçlandırma düğüm sayısı maksimum 10 seçilmiş eğitim verileri k-fold çaprazlama ile 5 defa veriler karıştırılarak aşırı öğrenme engellenmiştir.

### 3.5.5 Karar Ağacı (Decision Tree) Algoritması:

Ağaç tabanlı bir yöntem olan Karar ağacı (KA) algoritmaları denetimli bir öğrenme yöntemidir. KA, kararlılık, yüksek doğruluk ve yorumlanma kolaylığına sahiptir. Doğrusal olmayan ilişkileri oldukça iyi bir şekilde eşleyebilirler. Sınıflandırma ve regresyon ile her türlü veri bilimi problemlerinin çözümünde kullanılabilirler. Tümevarım yöntemiyle çalışan KA büyük miktarda verileri, çok küçük gruplara bölerek basit karar vermede başarılı bir şekilde uygulanabilirler. Tahmin edici ve tanımlayıcı özelliğe sahiptirler. KA oluşturulan kural yapısının basit ve anlaşılabilir olmasından dolayı sıklıkla tercih edilen makine öğrenmesi algoritmaları arasında yer almaktadır (Gök ve Fidan, 2019). Diğer yöntemlerle benzer olarak örnekler eğitilir ve model kullanarak farklı örneklerin sınıflandırılması şeklinde gerçekleşir. Eğitilen örnekler oluşturulan model test kümesine uygulanarak verilerin doğruluğu kontrol edilir. Çıkan başarımın sonucu KA algoritmasının uygulanabilirliği hakkında bilgi verir. Düşük çıkması KA doğruluğunu yansıtmadığını gösterir. KA algoritması gerçek bir ağaç yapısı tasarlanarak kök, düğüm ve yaprak kısımlarından oluşur. Şekil 3.19' de örnek bir karar ağacının yapısı verilmiştir.



Şekil 3.18. Örnek Karar Ağacı Yapısı (Çelik vd, 2022)

Kök kısmı aynı zamanda bir düğümdür ve düğümler dallamanın gerçekleştiği

yerlerdir. Dal kavramı ise düğümlerden çıkan kavramları göstermek için kullanılır. Yaprak kavramı ise ağaç yapının son elemanıdır ve çıktı verisini gösterir. Kök ilk düğümdür ve literatürde kök düğüm olarak ifade edilir. Veri setlerinde kullanılan her bir değişken öznitelik olarak kabul edilir ve kök dahil olmak üzere ağaç yapısı içerisindeki tüm düğümler öznitelikleri gösterirler. Sonucu değiştirmeyen öznitelikler ağaç yapısında gösterilmezler. Ağaç yapısına yerleştirirken başarıyı en yüksek yapan öznitelik ile başlanır. Sonrasında sıralama yapılarak algoritmaya göre sıralı şekilde düşük olan öznitelikler yerleştirilerek yeni bir düğüm yapısı oluşturulamayana kadar ağaç yapısı oluşturulur. KA en önemli adım dallanmalar için gerekli olan kriterlerin doğru belirlenmesidir. Bu kriterlerin belirlenmesi için literatürde birkaç yöntem vardır. Bilgi kazancı ve bilgi oranına göre Ki-kare tablo istatistiği, towing kuralı ve gini indeksi bunlardan birkaçıdır. Bu yöntemler ile oluşturularak gerçekleştirilen algoritmalarından bazıları ise ID3, C4.5, C5.0, J48 (Alan ve Yeşilyurt, 2018) ve CART algoritmaları olarak sayılabilmektedir (Kavzoğlu ve Çölkesen, 2010).

Kriterlerin belirlenmesi için kullanılan birkaç yöntem vardır. Bu kriterler bilgi kazancı ve bilgi kazancı oranı, gini-indeksi, Towing kuralı, Ki –Kare olasılık tablo istatistiği olarak sayılabilmektedir. Bu yöntemler kullanılarak geliştirilen algoritmalarından bazıları ise ID3, C4.5, C5.0, J48 (Alan ve Yeşilyurt, 2018) ve CART algoritmaları olarak sayılabilmektedir (Kavzoğlu ve Çölkesen, 2010). Bu çalışmada bilgi kazancı oranı yaklaşımı kullanılarak tasarlanan ID3 algoritması kullanılmıştır.

### **3.6. Derin Öğrenme**

Derin öğrenme, yapay zekanın bir alt kümesi olan makine öğreniminin bir alt kümesidir. 1950'lerden beri bilgisayarların insanlara benzer şekilde düşünmesini ve akıl yürütmesini sağlamak amacıyla ortaya çıkmış olan yapay zekaların bir alt kümesi olarak makine öğrenmesi makinelerin açıkça programlanmadan nasıl öğreneceğine odaklanır. Derin öğrenme ile insanların yeni öğrenmeleri nasıl gerçekleştirdikleri taklit edilerek hiyerarşik modeller üzerinde çalışılır ve makine öğrenmesinin ötesine geçilir. Derin öğrenmede algoritmalar insan beyninin işleyişinden ilham alır. Derin öğrenme algoritmaları ile görüntü işleme tekniklerindeki hareketli nesne takibi konusunda pek çok karmaşık problem çözülebilir ve nesne takibinde doğruluk oranı artırılabilir (Daş, Polat, Tuna,2019). Algoritmalar denetimli veya denetimsiz olabilir. Derin öğrenme makinelerin yeni şeyler öğrenmesini sağlama sürecini iyileştirmeye odaklanır. Kural tabanlı yapay zeka ve makine öğrenmesi ile bir veri bilimcisi,

modellere dahil edilecek kuralları ve veri kümesi özelliklerini belirler ve bu modellerin nasıl çalıştığını yönlendirir. Derin öğrenme ile veri bilimcisi ham verileri bir algoritmayla besler. Sistem daha sonra, içine önceden programlanmış belirli kurallar veya özellikler olmadan bu verileri analiz eder. Sistem tahminlerini yaptıktan sonra, doğruluk için ayrı bir veri kümesine karşı kontrol edilir. Bu tahminlerin doğruluk düzeyi daha sonra sistemin yaptığı bir sonraki tahmin grubunu bilgilendirir. Derin öğrenmedeki "derin", sinir ağının zamanla biriktirdiği birçok katmanı ifade eder e ağ azaldıkça performans artar. Ağın her seviyesi, girdi verilerini belirli bir şekilde işler ve ardından bir sonraki katmana bilgi verir. Böylece bir katmanın çıktısı, bir sonrakinin girdisi olur. Derin öğrenme ağlarını eğitmek zaman alıcıdır ve sistem modelini kademeli olarak iyileştirdiği için büyük miktarda verinin alınmasını ve test edilmesini gerektirir.

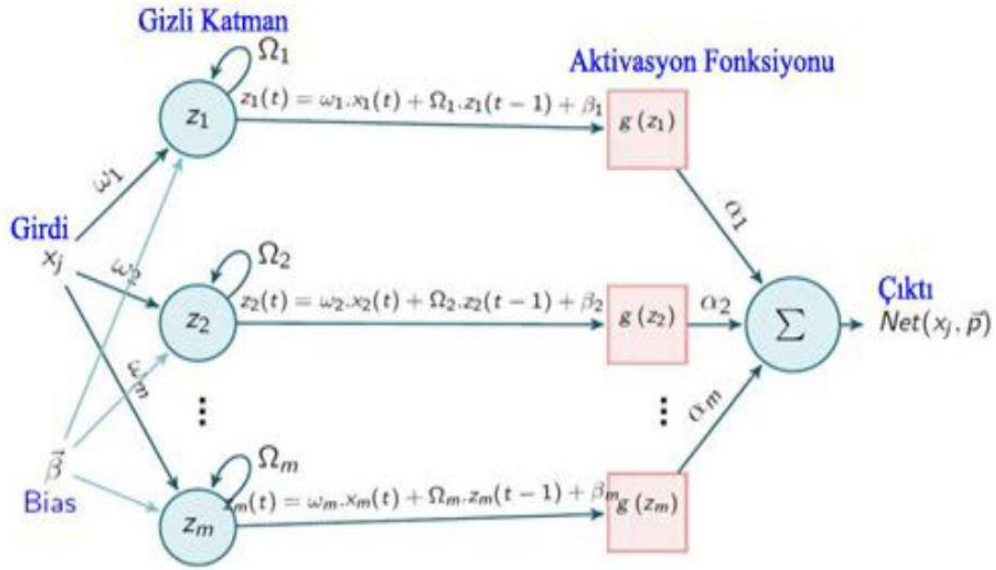
Makine öğrenmesi ile derin öğrenme ilişkisine bakıldığında tüm derin öğrenmenin makine öğrenimi olduğunu; ancak her makine öğreniminin derin öğrenme olmadığı söylenebilir. Her iki teknoloji de hangi modelin verilere en uygun olduğunu belirlemek için test verilerine karşı eğitim içerir. Ancak geleneksel makine öğrenimi yöntemleri, algoritmalar uygulanmadan önce verileri önceden işlemek için belirli bir düzeyde insan etkileşimi gerektirir. Makine öğrenimi, yapay zekanın bir alt kümesidir. Amacı, bilgisayarlara, hangi çıktının sağlanacağı konusunda özel olarak programlanmadan öğrenme yeteneği kazandırmaktır. Makine öğrenimi tarafından kullanılan algoritmalar, bilgisayarın nesnelere nasıl tanıyacağını öğrenmesine yardımcı olur. Tüm bunlar bir insan çabası gerektirebilir. Derin öğrenme algoritmaları, kendi beynimizin düşünce süreçlerini yansıtmayı amaçlayan hiyerarşik modeller oluşturarak bir adım daha ileri gider. Bir sonuç üretmek için giriş verilerinin ön işlenmesini gerektirmeyen çok katmanlı bir sinir ağı kullanır. Veri bilimcileri, ham verileri algoritmaya besler, sistem verileri önceden bildiklerine ve yeni verilerden çıkarabileceklerine göre analiz eder ve bir tahminde bulunur. Derin öğrenmenin avantajı, verileri basit kurallara dayalı yapay zekanın yapamayacağı şekilde işleyebilmesidir.

Günümüzde derin öğrenme büyük veri üreten pek çok alanda kullanılmaktadır. Tıp, imalat, finansal hizmetler ve pek çok kamu sektörü bu alanlara örnek verilebilir. Bu alanlarda hızlı ve doğru bir şekilde veri analizi yapabilmek ve sonuçları sağlıklı bir şekilde sunabilmek önemlidir.

Derin öğrenme modelleri oluştururken problemin çözümünde kullanılacak algoritmalar büyük önem taşır. Seçim yapılacak bu algoritmalar verinin türüne, boyutuna, hacmine ve yapısına, kullanılacak olan parametrelere göre farklılık gösterebilmektedir (Savaş, 2020). Litaratüde başlıca kullanılan derin öğrenme algoritmaları Evrişimsel Sinir Ağları (ESAConvolutional Neural Network — CNN), Tekrarlayan Sinir Ağı (Recurrent Neural Network-RNN) ve Kısıtlı Boltzmann Makineleri (Restricted Boltzmann Machines-RBM) ve Derin İnanç Ağları (Deep Belief Nets-DBN) bunlardan başlıcalarıdır.

CNN algoritması içlerinde en bilinen derin öğrenme algoritmasıdır. Algoritma görüntü sınıflandırma problemlerinde matris üzerinde genellikle 3x3, 5x5, 7x7 olan filtreler (çekirdekler) uygulanarak kullanılır. Sonrasında bu filtrelerin çıktıları üzerinde havuzlama (pooling) işlemi yapılarak çekirdekte bulunan veriler filtrelenir. Genel olarak bir CNN mimarisi; sırasıyla girdi, evrişim, havuzlama, aktivasyon ve sınıflama katmanlarından oluşmaktadır (Karakurt, İşeri, 2022). Makine öğrenmesinden farklı olarak öznitelik ham veriler üzerinden çıkarılmakta ve veriler işlenirken gerekli veriler farklı katmanlarda oluşturulan değişkenlerle temsil edilirler. Verilerin aynı boyutta katmanlara sahip olması CNN algoritmalarının daha az bağlantı ve parametre ile işlem yapılabilmesini bu durumda kolay eğitilmesini sağlar (Krizhevsky vd, 2012).


RNN algoritması ise girdi ve çıktı değerlerinin bağımsız olduğu varsayılır. Bu durum bazı problemlerde doğru sonucu engellemektedir. RNN algoritmasında girdi verilerinin tüm elemanlarının hesaplaması ayrı ayrı yapar ve her çıktı elemanı hesaplanan girdiye göre bağlı olarak işlem yapılır. Basit bir RNN algoritması Şekil 3.21’de gösterilmiştir.



Şekil 3.19. Basit RNN algoritması (Savaş, 2020)


RNN algoritması genellikle doğal dil işleme ses analizi yaparak konuşma tanıma alanlarında kullanılırlar. Uzun Kısa Süreli Bellek ağları, RNN'lerin uzun süreli hatırlama problemlerini çözmek geliştirilmiş ve kullanılmıştır (Savaş, 2020). Değişken uzunlukta verileri işleyebilme, hesaplamada geçmişten faydalanma, zamana bağlı paylaşımlı ağırlıkları kullanma gibi avantajları vardır. Değişken boyutlar ile işlem yaptığında yavaş hesaplama, geçmişteki veriler erişim zorluğu ve mevcut durumda gelecekteki girdi tahmin zorluğu gibi dezavantajları vardır.

RBM derin öğrenme algoritması ise, girdi veri seti üzerinde olasılık dağılımlarını öğrenebilen rastlantısal bir türdür. RBM iki katmanlı bir yapıya sahiptir. İlk katmanı giriş katmanı ikinci katmanı ise gizli katman olarak adlandırılırlar. Yapı olarak ağaç yapısına benzer olarak düğümlere sahiptirler. Düğümler katmanlar arasında birbirine bağlar fakat aynı katmandaki iki düğümler birbirine bağlı değildirler. Katmanlar arası iletişim yoktur. Bu yüzden kısıtlı olarak adlandırılırlar. Şekil 3.21'de bağlantı şeması gösterilmektedir.



Şekil 3.20. Kısıtlı Boltzman Makinesi (Krizhevsky vd., 2012)

DBN algoritması, denetimsiz sinir ağlarından oluşurlar. Katmanlar arasında bağlantılar vardır fakat ağın tek katmanları arasında birimler arasında bağlantılar yoktur. DBN, birden çok stokastik, gizli değişken katmanından oluşan olasılıksal üretken modellerdir (Yağın, 2022). Gizli katmandaki değişkenler ikili değerlere sahiptirler. Üstteki katman, yönsüz ve simetrik bağlantılıdır. Alttaki katman ise bir veri vektörü temsil eder. Katmanlar arasında aşağı ve yukarı doğru birbirine bağlayan bir prosedür vardır. Çok sayıda gizli katmana sahip ağlar, görüntüler gibi yüksek düzeyde yapılandırılmış girdi verilerine uygulandığında, gizli katmanlardaki özellik dedektörleri, girdi verilerindeki yapıyı modelleyen derin bir inanç ağı öğrenilerek başlatılırsa, geri yayılım çok daha iyi çalışır (Roder vd, 2021 ; Qiao, Yang vd, 2021). Şekil 3.22’de DBN bağlantı şeması gösterilmiştir.



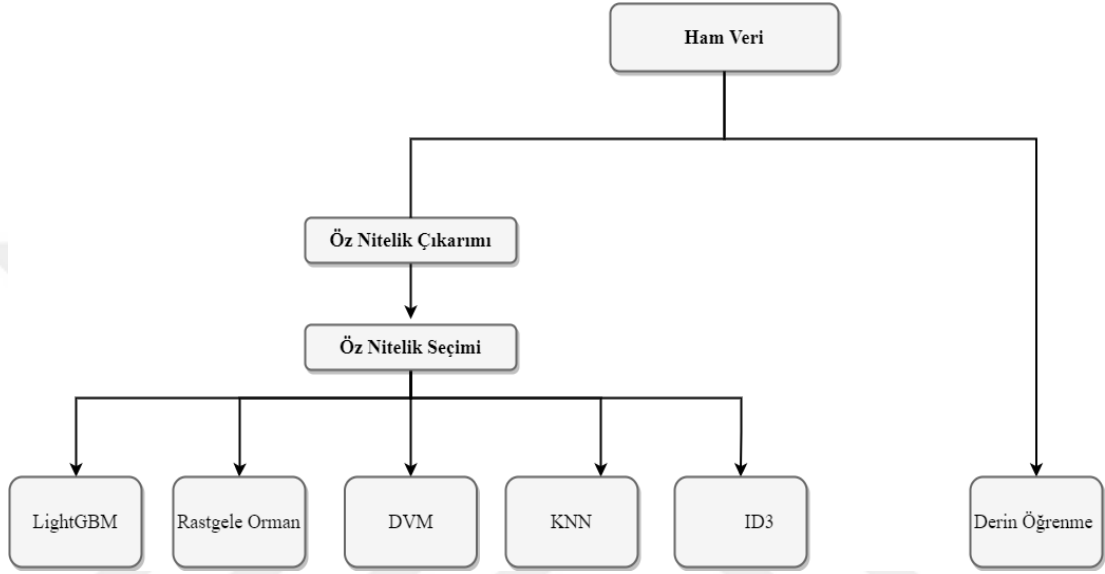
Şekil 3.21. Örnek DBN bağlantı şeması (Krizhevsky vd, 2012)

DBM’de her katmandaki gizli deęişkenlerin deęerleri, alt katmanda gözlenen bir veri vektörü ile başlayan ve üretici ağırlıkları ters yönde kullanan tek bir aşığıdan yukarıya geçişle çıkarılabilir.



#### 4. ANALİZ VE BULGULAR

EOG temelli İBA için uygun sınıflandırma yöntemleri geniş bir şekilde araştırılmıştır. Hem ham verileri hem de çıkarılan öznelikleri kullanarak klasik sınıflandırma yöntemlerinin yanı sıra derin öğrenme metotları ile de en yüksek başarımın araştırılması yapılmıştır. Bu araştırmanın özet bir akış şeması Şekil 4.1’de gösterilmektedir.



Şekil 4.1. Çalışmanın akış şeması

Örneklem çalışması 25 kişiden oluşmakta ve 20 sütun 7000 satırlık bir veri setinden oluşmaktadır. Ham özneliği çıkarılarak ve ham veri üzerinde analiz olarak iki aşamalı bir inceleme yapılmıştır.

Birinci aşamada çalışmamızda kullanılan öznelıklar EOG işaretlerine uygun olarak özellikle belirlenmiş ve klasik makine öğrenme metotları ile birlikte öznelik seçim yöntemi kullanılmıştır. Bu kısımda başlangıçta aşağıdaki öznelıklar hesaplanmıştır;

- $f_0$ : 1. Kanalın enerjisi
- $f_1$ : 2. Kanalın enerjisi
- $f_2$ : 1. Kanalın maksimum-minimum noktalarının eğimi
- $f_3$ : 2. Kanal maksimum-minimum noktalarının eğimi
- $f_4$ : 1. Kanal maksimum-minimum noktalarının genlik farkı

- $f_5$ : 2. Kanal maksimum-minimum noktalarının genlik farkı
- $f_6$ : 1. Kanal maksimum-minimum noktalarının arasında geçen süre
- $f_7$ : 2. Kanal maksimum-minimum noktalarının arasında geçen süre
- $f_8$ : 1. Kanalın çeyrekler açıklığı
- $f_9$ : 2. Kanalın çeyrekler açıklığı
- $f_{10}$ : 1. Kanalın standart sapma
- $f_{11}$ : 2. Kanalın standart sapma
- $f_{12}$ : 1. Kanalın varyansı
- $f_{13}$ : 2. Kanalın varyansı
- $f_{14}$ : 1. Kanalın etkinliği
- $f_{15}$ : 2. Kanalın etkinliği
- $f_{16}$ : 1. Kanalın maksimum genlik değeri
- $f_{17}$ : 2. Kanalın maksimum genlik değeri
- $f_{18}$ : 1. Kanalın minimum genlik değeri
- $f_{19}$ : 2. Kanalın minimum genlik değeri

Öznitelikler genellikle tek başına iyi sonuç vermezler. Bunun için farklı özniteliklerin bir araya getirilerek sınıflandırma başarımının artırılması yaygın bir yöntemdir. Ancak, özniteliklerin bir araya getirilmesi için belirli metotların kullanılması gerekmektedir. Rasgele yapılan seçimler rasgel sonuçlar doğurmaktadır. Bu nedenle öznitelik seçim algoritmalarının uygun şekilde kullanılması gerekmektedir.

Analiz yapmak için python programlama dilinde bulunan keras kütüphanesi kullanılmıştır. Keras kütüphanesi tensorflow alt yapısını kullanır. Keras kütüphanesi tensorflow kütüphanesini özelleştirerek daha kullanıcı dostu bir kütüphanedir. Ham ve özniteliklere uygulanarak veri setimizde seçmiş olduğumuz özniteliklerin ham veriler üzerinde kendisi seçerek ileri seçilimli bir yöntem ile karşılaştırılma yapılmıştır.

Öznitelik seçilimi işleminde makine öğrenmesi süreci içerisinde hedef (target)

değişkene bağlı olarak girdi (input) değişkenleri seçim (feature selection) işlemi kullanılır. Kısaca veri setinde n adet olan özellik sayısını en iyi k adet seçme işlemidir (Budak, 2018). Değişken seçimi işlemlere basitlik, overfitting (aşırı öğrenme), bazı değişkenlerin arasında yüksek ilişkiyi (Multicollinearity) engelleme, eğitim sürecini hızlandırma ve doğru değişken seçimi amacıyla kullanılır. Üç tip ardışık arama yöntemi bulunmaktadır. Bunlar ileri yönlü, geri yönlü ve iki yönlü arama yöntemleridir. Bu çalışmada ardışık arama yöntemi olan ileri yönlü arama yöntemi kullanılmış ve yüksek başarımlar elde edilmiştir. İleri seçilimli yöntem ilk sütundan başlayarak en son sütuna kadar olan özellikleri kombinasyonlu olarak seçip ve test etmektedir.

Bu çalışmada sınıflandırma metodları ile birlikte ileri yönlü öznelik seçim algoritması kullanılmıştır. İleri seçim ile sütunların başarımlarını Şekil 4.2 gösterilmiştir.

Seçilen sütun sayısı	Seçilen Sütunlar																				
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	
Seçilen Öznitelikler	2	2	2	2	2	2	2	2	2	2	2	2	2	0	0	0	0	0	0	1	
		3	3	3	3	3	3	3	3	3	3	3	3	2	2	2	2	2	1	2	
			5	5	5	5	5	5	5	5	5	5	5	3	3	3	3	3	2	3	
				6	6	6	6	6	6	6	6	6	6	5	5	5	5	4	3	4	
					17	17	7	7	7	7	7	7	7	6	6	6	6	5	4	5	
						18	17	16	13	8	8	8	8	7	7	7	7	6	5	6	
							18	17	16	13	12	11	11	8	8	8	8	7	6	7	
								18	17	16	13	12	12	11	10	9	9	8	7	8	
									18	17	16	13	13	12	11	10	10	9	8	9	
										18	17	16	15	13	12	11	11	10	9	10	
											18	17	16	15	13	12	12	11	10	11	
												18	17	16	15	13	13	12	11	12	
													18	17	16	15	15	15	13	12	13
														18	17	16	16	15	13	14	
															18	17	17	16	15	15	
																18	18	17	16	16	
																	19	18	17	17	
																		19	18	18	
																			19	19	
																				19	20
Başarımlar Sonucu (%)	54,47	75,53	86,92	89,69	90,61	91,20	91,79	92,28	92,52	92,55	92,68	92,68	92,68	92,63	92,69	92,79	92,88	92,95	92,95	92,68	

Şekil 4.2. İleri öznelik seçim yöntemi ile elde edilen Lightgbm algoritması sonuçları

Kullanılan sınıflandırma yöntemleri, ileri öznelik seçim yöntemi ile elde edilen öznelikler ile bu modellerin eğitim kümesindeki başarıları Tablo-2’de verilmiştir. Eğitim ve test kümesi sırasıyla %70 ve %30 olarak bölünmüştür. Sınıflandırma sonuçları daha doğru ve güvenilir elde edebilmek için eğitim sürecinde 10 kat çapraz doğrulama tekniği kullanılmıştır. Tablodan da anlaşılacağı üzere sonuçların 88,65% ile 92,95% aralığında dağıldığı görülmektedir. Sonuçların birbirine yakın olması elde edilen veri setinin, seçilen özneliklerin ve sınıflandırıcıların kararlılığını göstermektedir.

Tablo 4.1. Eğitim kümesi sınıflandırma sonuçları


Sınıflandırma Sonuçları	Seçilen Öznitelik	Sonuç
Lightgbm	$f_0, f_1, f_2, f_3, f_5, f_6, f_7, f_8, f_9, f_{10}, f_{11}, f_{13}, f_{14}, f_{15}, f_{16}, f_{17}, f_{18}, f_{19}$	% 92,95
DVM	$f_1, f_2, f_3, f_4, f_5, f_7, f_8, f_{12}, f_{13}, f_{16}, f_{17}$	% 91.15
KNN	$f_0, f_2, f_4, f_5, f_6, f_7, f_8, f_9, f_{11}, f_{12}, f_{13}, f_{16}, f_{17}, f_{18}$	% 90.65
Random Forest	$f_1, f_2, f_3, f_5, f_6, f_7, f_8, f_{16}, f_{17}, f_{18}$	% 92,31
Decisin Tree	$f_0, f_1, f_2, f_3, f_4, f_5, f_6, f_7, f_8, f_9, f_{10}, f_{11}, f_{12}, f_{16}, f_{17}, f_{18}, f_{19}$	% 88,65

Eğitim kümesinde %92,95 başarımla en iyi sonucun  $f_0, f_1, f_2, f_3, f_5, f_6, f_7, f_8, f_9, f_{10}, f_{11}, f_{13}, f_{14}, f_{15}, f_{16}, f_{17}, f_{18}, f_{19}$  özniteliklerinin seçilmesi ve Lightgbm sınıflandırma algoritmasının kullanılması durumunda elde edildiği görülmektedir. Dolayısıyla eğitim kümesinden elde edilen modelimiz budur. Bu model test kümesinde % 95.66 olarak eğitim kümesine yakın bir sonuç vermiştir. Sonuç olarak sınıflandırma metotları ile en iyi başarımla % 95.66 olarak belirlenmiştir.

#### 4.1 Makine Öğrenmesi Analiz ve Bulgular


##### 4.1.1 LightGBM analiz ve bulgular

Sınıflandırmanın başarımında veri kümesinin güvenilirliğinin etkisinin olduğu kadar uygulanacak yöntemin parametrelerinin etkisi de önemlidir. Python dilinde sınıflandırma metotlarını uygularken standart parametre seçimi yapılabileceği gibi en uygun seçimi yapabilecek optimizasyon yöntemleri de denenebilir. Yukarıda Tablo-2'den de anlaşılacağı üzere en iyi başarımla veren LightGBM algoritması için çalışmada iki metot da denenmiş, random search parametre optimizasyon algoritması kullanılarak en yüksek başarımla bulunmuştur. Bulunan en uygun değerler  $earning\_rate=0.5, max\_depth=10, num\_leaves=31$  olarak seçilmiştir. Model eğitimi sırasında en çok kullanılan  $eval\_metric='logloss'$  değeri ise parametre olarak seçilmiştir. Çalışmanın İterasyon başına hata oranı grafiği Şekil 4.3'de gösterilmiştir.



Şekil 4.3. LightGBM İterasyon başına hata oranı

Eğitim verisi iterasyon başına eğitim ve test veri setlerinin hata oranlarını göstermektedir. Test verisi için 10. iterasyondan sonra hata oranı artmaya başlamıştır. Optimum iterasyon sayısı 10'dur. Modelin en performanslı eğitimi bu şekilde elde edilmiştir. Çalışmanın LightGBM kolonların önem sırası grafiği Şekil 4.4'de gösterilmiştir.



Şekil 4.4. LightGBM Kolonların Önem Sırası

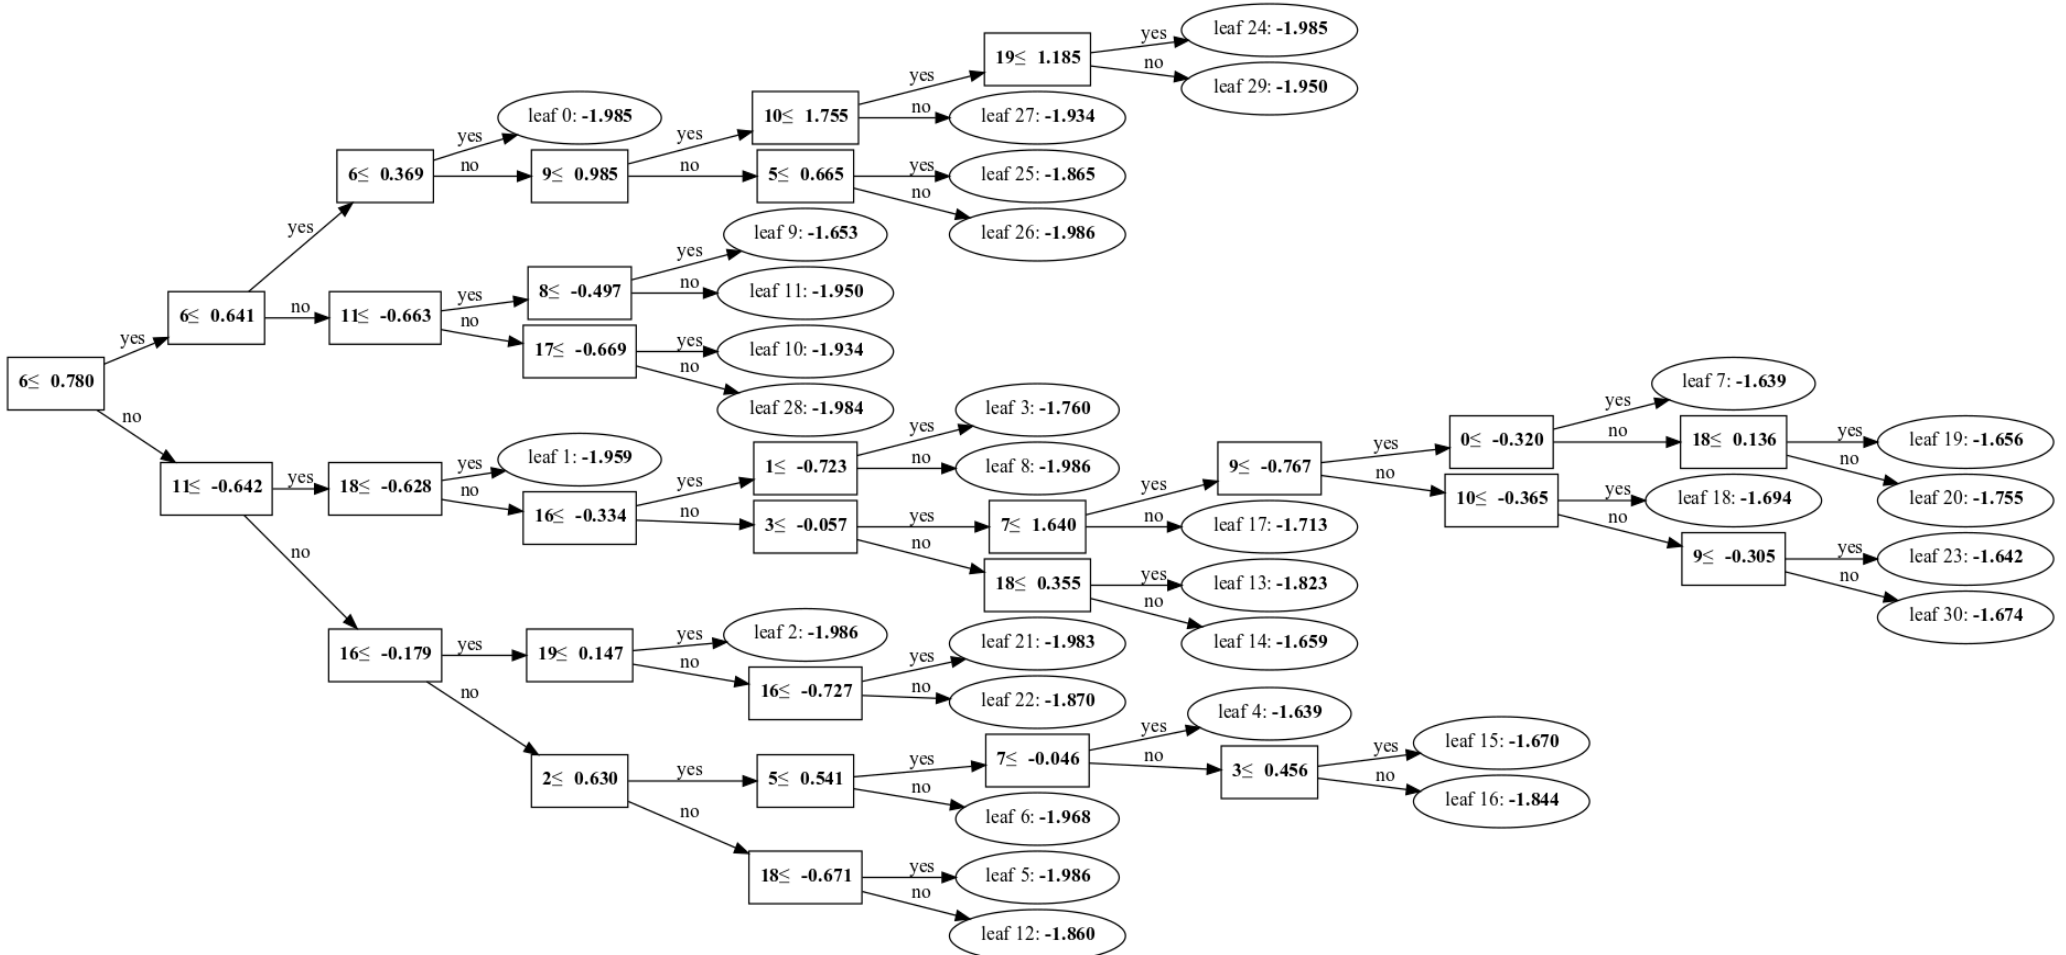
Grafik incelendiğinde modelin başarımını etkileyen en yüksek kolon, kolon 3., en düşük kolon ise 9. kolondur. Bu gösterge bize en değerli kolon 3 numaralı öznelik olan birinci kanalım max-min eğim noktası bulunmuştur. Önemi en az olan 9 numaralı kolon ise birinci kanalın sahip olduğu çeyrekler açıklığı özneliğidir.

LightGBM ağaç yapısı şeması, verilere görsellik katmak ve kullanıcıların kurduğu model yapısını anlaması için tasarlanmış bir grafik şeklidir. Şekil 4.5'e bakıldığında ileri seçilimli öznelik seçim yapıldığında toplamda olan 20 öznelikden bütün kombinasyonlar denenerek en yüksek başarımın 18 özneliğin kombinasyonu ile elde edildiği görülmektedir. Sonrasında başarımın değişmediği veya düştüğü görüldüğünden kalan diğer özneliklerin seçimine gerek duyulmadığı anlaşılmaktadır.



Şekil 4.5. LightGBM kolon seçim grafiği

Şekil 4.6'da LightGBM ağaç yapısı girilen değer veya öznelikleri ağırlıklandırılarak en yüksek ağırlıkta olan bir girdinin çıktığı alana kadarki geçen seçim aşamalarını göstermektedir. Kolonlar incelendiğinde sırası ile c0, c1, c2, c3, c5, c6, c7, c8, c9, c10, c11, c12, c13, c14, c15, c16, c17, c18 ve son olarak c19 kolonlarını seçtiği görülmektedir. Seçim işlemi kombinasyon ile en yüksek ağırlık oranı seçilerek ağaç yapısı kurulmuştur.



Şekil 4.6. LightGBM ağaç yapısı

Karmaşık matrisi bir test verisi üzerinde sınıflandırma performansı göstermesi için kullanılan bir tablo biçimidir. LightGBM sınıflandırıcı algoritması çıktığı sonucu oluşan karmaşık matrisi sonucu Şekil 4.7. 'da gösterilmiştir.



Şekil 4.7. LightGBM karmaşık matrisi

Karmaşık matrisi test veri setindeki doğru ve yanlış tahmin etme sayısını gösteren tablo çıktılarını açıklayalım.

Test setinde olan 293 adet 1.sınıf örneklerinden modelimiz 280 tanesini doğru olarak 1. sınıf olarak sınıflandırmıştır. (1,4,8) adet örneği sırası ile 2.sınıf, 3.sınıf ve 6.sınıf olarak tahmin etmiştir bu tahminler modelin hatalarıdır.

Test setinde olan 317 adet 2.sınıf örneklerinden modelimiz 311 tanesini doğru olarak 2. sınıf olarak sınıflandırmıştır. (3,3) adet örneği sırası ile 4.sınıf ve 7.sınıf olarak tahmin etmiştir bu tahminler modelin hatalarıdır.

Test setinde olan 284 adet 3.sınıf örneklerinden modelimiz 270 tanesini doğru olarak 3. sınıf olarak sınıflandırmıştır. (3,5,1,4) adet örneği sırası ile 1.sınıf, 4.sınıf, 5.sınıf, 6.sınıf ve 7.sınıf olarak tahmin etmiştir bu tahminler modelin hatalarıdır.

Test setinde olan 300 adet 4.sınıf örneklerinden modelimiz 285 tanesini doğru olarak 4. sınıf olarak sınıflandırmıştır. (1,2,4,3,4,1) adet örneği sırası ile 1.sınıf, 2.sınıf, 3.sınıf, 5.sınıf, 6.sınıf ve 7.sınıf olarak tahmin etmiştir bu tahminler modelin hatalarıdır.

Test setinde olan 309 adet 5.sınıf örneklerinden modelimiz 288 tanesini doğru

olarak 5. sınıf olarak sınıflandırmıştır. (2,5,8,6) adet örneği sırası ile 1.sınıf, 3.sınıf, 6.sınıf ve 7.sınıf olarak tahmin etmiştir bu tahminler modelin hatalarıdır.

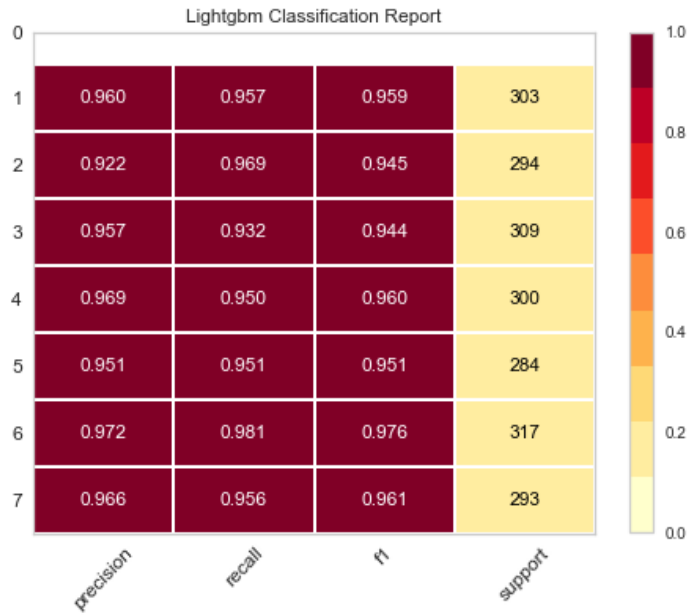
Test setinde olan 294 adet 6.sınıf örneklerinden modelimiz 195 tanesini doğru olarak 6. sınıf olarak sınıflandırmıştır. (4,4,1) adet örneği sırası ile 1.sınıf, 5.sınıf ve 7.sınıf olarak tahmin etmiştir bu tahminler modelin hatalarıdır.

Test setinde olan 303 adet 7.sınıf örneklerinden modelimiz 290 tanesini doğru olarak 7. sınıf olarak sınıflandırmıştır. (2,3,4,5) adet örneği sırası ile 2.sınıf, 3.sınıf, 4.sınıf ve 5.sınıf olarak tahmin etmiştir bu tahminler modelin hatalarıdır.

En yüksek başarıma sahip LightGBM karmaşıklık matrisinin etiket değerlerine bakıldığında en yüksek başarımın 2. etikete sahip sağa bakma hareketinde olduğu, en düşük başarımın ise 4. etikete sahip sağ göz kırpma hareketi olduğu görülmektedir. Diğer etiketlerde (1-Sola bakma, 3-Aşağı bakma, 4-Aşağı bakma, 6-Sol göz kırpma, 7-İki göz kırpma) hareketlerine bakıldığında birbirine yakın oranlar da başarıya sahip olduğu görülmektedir. LightGBM algoritmasının iki kanallı bir yapıda birinci kanalın sahip olduğu yatay hareketleri daha iyi algıyabildiği, dikey ve kırpma hareketlerinin sahip olduğu hareketlerde ise daha başarısız olduğu görülmektedir. Bunun sebebi olarak ise örnek alımında sırasında kişilerin dikey hareketlerde zorlandığı ve koordinasyon eksikliği gibi nedenlerden dolayı hareketlerde parazitlenme ve zayıf aksiyon neden olabileceği düşünülmektedir.

Sınıflandırma raporu, sınıf bazında ana sınıflandırma metriklerinin bir temsilini gösterir. Bu, çok sınıflı bir problemin bir sınıfındaki fonksiyonel zayıflıkları maskeleyebilen global doğruluk üzerinde sınıflandırıcı davranışına daha derin bir sezgi verir. Görsel sınıflandırma raporları, sınıflandırma modellerini "daha kırmızı", örneğin daha güçlü sınıflandırma ölçütlerine sahip veya daha dengeli olan seçili modellerle karşılaştırmak için kullanılır. Metrikler, doğru ve yanlış pozitifler ve doğru ve yanlış negatifler açısından tanımlanır. Bu durumda pozitif ve negatif, ikili sınıflandırma probleminin sınıfları için genel isimlerdir. Şekil. deki örnekte, doğru ve yanlışın işgal edildiğini ve doğru ve yanlışın işgal edilmediğini kabul edeceğiz. Bu nedenle, gerçek bir pozitif, gerçek sınıfın, tahmin edilen sınıf gibi pozitif olduğu zamandır. Yanlış pozitif, gerçek sınıfın negatif, ancak tahmin edilen sınıfın pozitif olmasıdır. Precision , recall, f1-Skor, Support gibi 4 göstergesi vardır. Precision bir sınıflandırmanın kesinliğinin bir ölçüsü olarak görülebilir. Her sınıf için, gerçek pozitiflerin, doğru ve yanlış pozitiflerin toplamına oranı olarak tanımlanır. Başka bir


deyişle, "Pozitif olarak sınıflandırılan tüm örnekler için yüzde kaç doğruyd?" sorusunun cevabını gösterir. "Recall" parametresi ise sınıflandırıcının eksiksizliğinin bir ölçüsüdür; bir sınıflandırıcının tüm pozitif örnekleri doğru bir şekilde bulma yeteneği. Her sınıf için, gerçek pozitiflerin, gerçek pozitiflerin ve yanlış negatiflerin toplamına oranı olarak tanımlanır. Başka bir deyişle, "gerçekten olumlu olan tüm durumlar için, yüzde kaç doğru sınıflandırıldı?" cevabını arar. "F1-Skor" ise F 1 skoru, hassaslığın ağırlıklı harmonik ortalamasıdır ve en iyi skor 1.0 ve en kötü 0.0 olacak şekilde hatırlamadır. Genel olarak konuşursak, F1 puanları kesinlik ve geri çağırma hesaplamalarına dahil ettikleri için doğruluk ölçümlerinden daha düşüktür. Genel bir kural olarak, sınıflandırıcı modellerini karşılaştırmak için global doğruluk yerine F1'in ağırlıklı ortalaması kullanılmalıdır. Son olarak "Support" ise belirtilen veri kümesindeki sınıfın gerçek oluşumlarının sayısıdır. Eğitim verilerindeki dengesiz destek, sınıflandırıcının rapor edilen puanlarındaki yapısal zayıflıkları gösterebilir ve tabakalı örnekleme veya yeniden dengeleme ihtiyacını gösterebilir. Destek, modeller arasında değişmez, bunun yerine değerlendirme sürecini teşhis eder.



Şekil 4.8. LightGBM Sınıflandırma Raporu


Şekil 4.8’de sınıflandırma sonucu çıkan rapor gösterilmiştir. Bu raporu kısaca açıklayacak olursak, precision yani kesinlik değerine bakacak olursak sınıflandırma yapılırken en yüksek ayrımı 6. etiketin temsil ettiği sahip sol göz kırpma hareketinin %97,2 ile en düşük ayrımın ise 2. numaralı etikete sahip %92,2 ile sağa bakma göz hareketinin yaptığı görülmektedir. Burada iki kanallı bir yapı kullanıldığı için ikinci

kanaldaki sinyalin iki gözün kırılması sonucu frekans değişiminin fazla olduğundan ayırt edici düşünülmektedir. Recall yani türkçe hatırlatmak kolonuna bakıldığında en yüksek değer olan %98,1 sahip 6. etiketin temsil ettiği sahip sol göz kırpma hareketinin en düşük değer ise %95,4 ile 3 numaralı etikete sahip yukarı bakma hareketinin sahip olduğu görülmektedir. Tüm pozitif örnekleri 6 numaralı etikette daha iyi bulduğu 3 numaralı etikette ise diğerlerine göre daha az bulduğu görülmektedir. F1-skor değerine sahip sütuna bakıldığında ise %97,6 ile 6 numaralı etiket, en düşük değere ise 3 numaralı etiket %94,4 sahip olduğu görülmektedir. Kesinlik (precision) ve duyarlık (recall) değerinin harmonik ortalaması alınarak bulunan F1-skorunda 6. etiketin daha kararlı 3. etiketin ise diğerlerine göre daha kararsız olduğu görülmektedir. Support sütunu ise model seçilirken hangi etiketten ne kadar örnek seçtiğini gösterir. Model rastgele olarak en yüksek seçimi 205 adet ile 2. etiket yani sağa bakma en düşük seçimi ise 1. etiket olan sola bakma hareketinden seçmiştir. Ayrıca model 1400 örnek içinden doğruluk (accuracy) değeri %95 bulunmuştur. LightGBM 0,5 öğrenme oranı ile modelin ağırlıklı ve mikro ortalama değeri de %95 bulunmuştur. Modelin mutlak hatası %14, ortalama kare hatası %56 ve karekök ortalama hatası ise %75 bulunmuştur.



Şekil 4.9. LightGBM doğruluk grafiği

Accuracy skoru makine öğrenmesi sınıflandırma algoritmalarının yorumlanmasında sıklıkla kullanılan bir grafikdir. Skor 0 ve 1 arasında değer alır. Değer 1'e yaklaştıkça model başarılı kabul edilir. Skor bulunurken kullanılan formül tüm doğru cevapların (TP,TN), tüm cevaplara (TP,TN,FP,FN) oranı ile bulunur.



Şekil 4.10. LightGBM kayıp grafiği

Accuracy'in bir dezavantajı dengesiz dağılımlı gruplarda anlamlı sonuçlar vermez. Grafikten de anlaşılacağı gibi model skoru 1'e yaklaşmış ve doğru bir model kurulduğu görülmüştür.

LightGBM ile yapılan sınıflandırma sonucunda %95,56 başarımla en yüksek skor elde edilmiştir. En iyi kolon olarak c0, c1, c2, c3, c5, c6, c7, c8, c9, c10, c11, c13, c14, c15, c16, c17, c18 ve c19 kolonları bulunmuştur. Bu kolonlar sırası ile 1. Kanalın enerjisi, 2. Kanalın enerjisi, 1. kanalın max-min zaman farkı, 1. Kanalın maksimum-minimum noktalarının eğimi, 1. Kanal maksimum-minimum noktalarının genlik farkı, 1. Kanal maksimum-minimum noktalarının arasında geçen süre, 2. Kanal maksimum-minimum noktalarının arasında geçen süre, 1. Kanalın çeyrekler açıklığı, 2. Kanalın çeyrekler açıklığı, 1. Kanalın standart sapma, 2. Kanalın standart sapma, 2. Kanalın varyansı, 1. Kanalın etkinliği, 2. Kanalın etkinliği, 1. Kanalın maksimum genlik değeri, 2. Kanalın maksimum genlik değeri, 1. Kanalın minimum genlik değeri ve 2. Kanalın minimum genlik değeri bulunmuştur. Göz hareketlerinde birinci kanal gözün yatay hareketlerini ikinci kanal ise gözün dikey hareketlerini ve göz kırpma hareketlerini tespit etmek amacıyla kullanılmıştır. Algoritmaya göre göz hareketlerinin


tespitinde kanalların eğimi, zaman farkı, genlik farkı gibi sinyallerin hareketine bağlı olarak değişim ve öznitelikler ön plana çıktığı görülmektedir. İstatistiksel olarak sadece standart sapmalarının önemli olduğu ortaya çıkmaktadır. 2. kanalın sinyaldeki değişimde etkili olduğu ortaya çıkmaktadır. En yüksek başarımlı çıkması ile LightGBM sınıflandırma algoritmasının kullanılabilirliği düşünülmektedir.

#### 4.1.2 Random Forest Algoritması Analiz ve Bulgular

İsabetli bir sınıflandırma için birden fazla karar ağacı kullanarak daha uyumlu model üretmeye dayalı olan random forest algoritması çalışmada öznitelikler üzerinde kullanılarak denemiştir. Veri seti yedi farklı göz hareketi etiketlenerek hareket sonucunda oluşan sinyallerin öznitelikleri üzerinde Visual Studio Kod uygulaması ile Python programlama dili kütüphanesi içinde bulunan scikit-learn kütüphanesi ensemble modülü RandomForestClassifier sınıflandırma algoritması ile uygulanmıştır. Eğitim kümesi yüzde %70 test kümesi %30 olarak seçilmiştir. Farklı oranlar denenmiş fakat başarımlı sonucu daha düşük çıkmıştır. Veri setinin daha doğru sonuçlar verebilmesi için veri ön işleme aşamasında standardizasyon işlemi yapılmıştır. Random forest algoritması farklı pariteleri içinde bulundurur. Problemin çözümüne göre farklı pariteler değiştirilerek optimizasyon işlemi yapılır. Çalışmada RandomForestClassifier içinde bulunan random\_state, max\_depth, criterion , bootstrap pariteleri üzerinde yapılan optimum seçim ile en yüksek başarımlı sonucu elde edilmiştir. Diğer pariteler problemin çözümünde etkisi olmamasından dolayı tercih edilmemiştir. Bunlardan ilk parite olan max\_depth paritesi oluşturulan modelde maksimum ağaç derinliğini belirtmek için kullanılır düşük veya yüksek seçilmesi sınıflandırma başarımlı üzerinde etki yapmaktadır. Random Forest algoritması içinde en önemli paritedir. Elle deneme sonucunda 10 değeri en iyi değer olarak seçilmiştir. İkinci parite random\_state ise hem ağaç oluştururken kullanılan kullanılan örneklerin önyüklemesinin rastgeleliğinin hem de her düğümde en iyi bölünmeyi ararken dikkate alınacak özelliklerin örneklemesini (if ) kontrol eder. Diğer sınıflandırma algoritmalar ile karşılaştırabilmek için değer 0 seçilmiş bu sayede her seferinde eğitim ve test kümesi seçimi içinde değişmesi engellenerek karşılaştırma işlemi daha doğru sonuç elde edilmesi sağlanmıştır. Diğer bir kriter olan “criterion” paritesi ise bir bölünmenin kalitesini ölçmek için kullanılır. Desteklediği kriterler gini, entropi ve log\_loss'dur. Bu üç kriter denenmiş ve en yüksek başarımlı, S, bir sitemin girebileceği mikroskobik durumların sayısının W, yoluyla bulunması metoduyla bulunan entropy seçilmiştir.

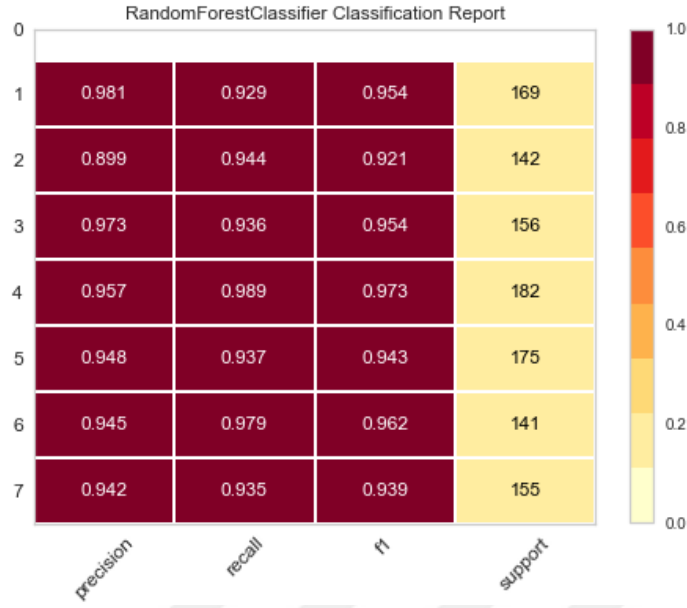
Ağaç oluştururken önyükleme örneklerinin kullanılıp kullanılmadığını belirten parite olan bootstrap ise bool değer olan True ve False değişkenleri alır. Herhangi bir değer olmadığından False seçilmiştir.

Random Forest çıktıları görüntüleri ekranda göstermek için kullanılan ListedColormap değerlerin üst üste gelmesi ve anlamlı çıktı vermesi için ikili seçimli kombinasyonlar seçilerek gösterim yapılması gerektiğini ayrıca en yüksek ikinci başarımlardan dolayı çalışmada çıktıları verilmemiştir. Bunun yerine diğer algoritmalarda da anlatacağımız karmaşıklık matrisi anlatılmıştır. Şekil 4.10'de gösterilen random forest sınıflandırma işlemi ile çıktı olan karmaşıklık matrisi sonucunun çıktıları açıklayalım.



Şekil 4.11. RF karmaşıklık matrisi

En yüksek başarıma sahip 2. sınıflandırma algoritması karmaşıklık matrisi incelendiğinde değerlerin oransal olarak farklı seçim olmasına rağmen başarımların birbirine yakın olduğu görülmektedir. En yüksek başarımların oranına 2 numaralı etikete sahip sağa bakma hareketinin sahip olduğu en düşük orana ise 6 numara etiketine sahip sol göz kırpma hareketinin olduğu görülmektedir. Diğer göz hareketlerinin ise birbirine yakın sonuçlar verdiği görülmektedir. Sinyalin grafiksel görünümü ve deney sırasında aksiyonlar incelendiğinde, algoritmanın sağa bakma hareketini kullanıcıların daha başarılı yaptığı sol göz hareketini zayıf yaptıklarından dolayı en iyi sonucun sağa bakma en düşük başarımların ise sol göz kırpma hareketi olduğu sonucu ortaya çıkmaktadır.



Şekil 4.12. RF sınıflandırma raporu


Şekil 4.12’de sınıflandırma sonucu çıkan rapor gösterilmiştir. Bu raporu kısaca açıklayacak olursak, precision yani kesinlik değerine bakacak olursak sınıflandırma yapılırken en yüksek ayrımı 1. etiket temsil ettiği sahip sola bakma hareketinin %98,1 ile en düşük ayrımın ise 2 numaralı etikete sahip %89,9 ile sağ tarafa bakma hareketinin yaptığı görülmektedir. Random Forest algoritmasının, LightGBM algoritması ile 7. etiketi aynı tespit ettiği fakat en düşük ayrım yapmada ise 3. etikete sahip yukarı bakma göz hareketi dışında 2. numaralı sağa bakma göz hareketini bulduğu görülmektedir. Recall sütununa bakıldığında ise 4 numaralı etikete sahip yukarı bakma göz hareketinin en yüksek değer olan %98.9 olduğu en düşük değer ise 1 numaralı etikete sahip sağ tarafa bakma hareketi olduğu görülmektedir. LightGBM algoritması seçmiş olduğu en yüksek 4 etiketi ve en düşük 1 etiketi dışında bir seçim olduğu görülmektedir. Pozitif örnek sayısının 4 numaralı etikette olduğu ve değerlerin birbirine yakın değerler çıktığı görülmektedir. F1-Skore sütunu incelendiğinde ise LightGBM algoritması gibi en yüksek değer 4 numaralı etiket olduğu görülmektedir. Yukarı bakma hareketinin her iki algoritmada da dengeli değerlere sahip olduğu görülmektedir. En düşük ve kararsız dağılıma sahip değer ise 2 numaralı etikete sahip göz hareketi sağa bakma hareketi olduğu görülmektedir. Algoritmalar arası seçimlerin karşılaştırılması için başlangıçta yapılan feature\_selection ile support küme değerlerinin aynı olduğu görülmektedir. K-fold çaprazlama yapılarak aşırı öğrenme engellenmiştir. 10 ağaçla, hatanın ortalama karesi %67.93, ortalama kare hatası %45

ve ortalama mutlak hata %12 bulunmuştur. 1400 örnek içinden doğruluk (accuracy) değeri %95 bulunmuştur. Modelin ağırlıklı ve mikro ortalama değeri de %96 bulunmuştur. Random Forest algoritmasının sınıflandırılması score sonucu %95.5 bulunmuştur.

#### **4.1.3 Destek Vektör Makineleri (DVM) Algoritması Analiz ve Bulgular**


İstatistiksel bir analiz yöntemine dayalı bir gözetimli algoritma olan DVM algoritması çıkarılan öznitelikler üzerinde diğer algoritmalar ile karşılaştırılma amacı ile denemiştir. Analog sinyaller üzerinde başarılı analizler yapabilen DVM algoritması python dilinde bulunan sklearn kütüphanesi içinde “svm” adıyla import edilmiştir. Eğitim ve test kümesi diğer algoritma türleri ile karşılaştırma yapabilmek için aynı şekilde ayrılmış ve pariteler elle denenerek gerekli optimizasyon işlemi yapılmıştır. DVM kendi içinde birçok parite bulunması birlikte bizim için sonuca etki eden kernel, C ve gamma değeri ile “fit” yani eğitime işlemi yapılmıştır. Kernel paritesi algoritmada kullanılacak çekirdek türünü belirtir. ‘linear’, ‘poly’, ‘rbf’, ‘sigmoid’, ‘precomputed’ gibi değerler alabilir. Rbf çekirdek SVM'sinin etkisini gösterir. Diğer pariteler denemiş en yüksek ve varsayılan değer olan rbf değeri seçilmiştir. “C” paritesi ise karar fonksiyonunun marjının maksimizasyonuna karşı eğitim örneklerinin doğru sınıflandırmasını değiştirir. C değeri 100 olarak belirlenmiştir. Bir diğer değer olan gama değeri ise ‘rbf’, ‘poli’ ve ‘sigmoid’ için çekirdek katsayısı belirlemek için kullanılır. Denemeler sonucuda en yüksek başarımlı değeri 0.7 olarak bulunmuştur.

Karmaşıklık matrisi diyagonal değerleri ne kadar yüksek olursa, o kadar iyidir, bu da birçok doğru tahmini gösterir. DVM algoritmasını diğer algoritmalarda kullandığımız karmaşıklık matrisi Şekil 4.13’de gösterilmiştir.



Şekil 4.13. DVM karmaşıklık matrisi

DVM analizinde karmaşıklık matrisi sonucunun çıktılarını açıklayalım. Çalışmada karmaşıklık matrisi incelendiğinde en yüksek başarımların dört tanesinin birbirine yakın en düşük 2 başarımlarının ise birbirine yakın çıktığı görülmektedir. Az bir farkla en yüksek başarımın 2. numaralı etikete sahip sağa bakma hareketi olduğu en düşük başarım sonucunun ise 6 numaralı etikete sahip sol gözü kırpma hareketi olduğu görülmektedir. DVM algoritmasının birinci kanaldan gelen sinyalleri iyi ayırt edebildiği, iki kanallı harekete sahip sinyallerde ise parazitlenmeyi daha az ayırt edebildiği görülmektedir.




Şekil 4.14. DVM Sınıflandırma Raporu

Şekil 4.14’de DVM makine algoritması sonucunda çıkan rapor gösterilmektedir. Raporda birinci sütunda kesinlik (precision) değerine bakıldığında LightGBM ve Random Forest algoritmalarında en yüksek değer 1. etikete sahip %94,2 oranla sola bakma hareketidir. En düşük değeri ise 5. etiket olan %86,7 ile sağ gözü kırpma hareketi diğer iki algoritmaya göre farklı çıkmıştır. Sınıflandırıcının tüm pozitif örnekleri doğru bir şekilde bulma yeteneği olarak kabul edilen recall sütununda ise değerler birbirine çok yakın çıkmış en yüksek değer %95 ile 5. etiket olan sağ gözü kırpma hareketi çıkmıştır. En düşük değer ise %86.1 ile 1. etikete sahip sol tarafa bakma hareketi olmuştur. F1 sütununda ise en yüksek doğruluğa sahip değer %92,3 ile 6. etiket olan sol gözü kırpma hareketi çıkmıştır. Support sütunu ise diğerleri ile aynı değere sahiptir. 1400 örnek doğruluk (accuracy), modelin ağırlık (macro avg) ve mikro ortalama (weighted avg) değerleri ise %95 bulunmuştur. Ortalama Mutlak Hata %14,21, Ortalama Kare Hatası % 56,64 ve Karekök ortalama hatası ise % 75.26 bulunmuştur. Sınıflandırma sonucu ise %95.21 bulunmuştur.

#### **4.1.4 KNN Aloritması Analiz Ve Bulgular**


Sınıflandırma ve regresyon problemlerin çözümünde kullanılan gözetimli bir algoritma olan KNN algoritması öznitelikler üzerinde uygulanmıştır. Sklean kütüphanesi içinde neighbors modülü altında KNeighborsClassifier sınıfı içinde bulunur. Ptyhon dili ve sklearn kütüphanesi içinde bulunan esnek pariteler ile hazır yazılımlardan daha başarılı sonuçlar elde edilebilmektedir. KNN algoritması içinde farklı birçok parite bulunmaktadır. Uygulamada hepsi denenmiş ve sonucu değiştiren iki parite olan n\_neighbors ve metric değerleri üzerinde yapılan değişiklikler sonucu maksimum çıkarmıştır. Sorgular için varsayılan olarak kullanılacak komşu sayısını gösteren n\_neighbors değeri 1 seçilmiştir. Ağaç için kullanılacak mesafe metriği olan metric ise “manhattan” uzaklık ölçüm yöntemi seçilmiştir. KNN algoritmasını diğer algoritmalarda kullandığımız karmaşıklık matrisi Şekil 4.15’de gösterilmiştir.



Şekil 4.15. KNN Karmaşıklık Matrisi

Sınıflandırma algoritmaları içerisinde en fazla kullanılan algoritmalarından bir olan KNN algoritmasının analiz sonuçları incelendiğinde çalışmada 4. sırada yer almaktadır. Karmaşıklık matrisi incelendiğinde en yüksek başarımın kendisini diğer hareketlerden ayıran 2. etikete sahip sağa bakma hareketi olduğu en düşük başarımın ise 3 numaralı harekete sahip yukarı bakma hareketi olduğu görülmektedir. Bakma hareketinin yapmış olduğu sinyal hareketlerine bakıldığında sağa bakma hareketinin birinci kanaldan gelen sinyalde hareketli ikinci kanalın ise hareketsiz olduğu ve gözün yatay hareketlerini temsil ettiği görülmektedir. KNN algoritmasının birinci kanaldan gelen hareketleri daha iyi algıladığı ikinci kanaldan gelen sinyaller ile oluşan göz hareketlerini ise daha az algıladığı görülmektedir. En düşük başarımın birbirine yakın olmasının iki sağ göz üzerine dikey hareketleri yerleştiren elektrotlar ile birleşen birinci kanaldan gelen sinyallerin birbirine yaklaşan değerleri ayırt etmekte zorlandığı görülmektedir. Farklı birçok çalışmada yüksek çıkan KNN algoritmasının bu çalışmada özneliliklerde daha az başarım sergilediği görülmektedir.

Şekil 4.16. KNN sınıflandırma raporu




Şekil 4.16. KNN sınıflandırma raporu

Şekil 4.16' da KNN makine algoritması sonucunda çıkan rapor gösterilmektedir. Raporda birinci sütunda kesinlik (precision) değerine bakıldığında LightGBM, Random Forest ve DVM algoritmalarında en yüksek değer 1. etikete sahip değer dışında çıkmış 2. etiket sahip %94,8 oranla sağa bakma hareketidir. En düşük değeri ise 5. etiket olan %92,7 ile sağa göz kırpmaya hareketi diğer üç algoritmaya göre farklı çıkmıştır. Recall sütununa bakıldığında ise en yüksek skor 6. etiketin sahip olduğu %96.2 ile sol göz kırpmaya hareketidir. En düşük değer ise 1 numaralı göz hareketi %92.7 ile sol tarafa bakma hareketidir. F1-Skor değerine bakıldığında ise değerler birbirine çok yakın olup en yüksek değer %95.3 ile 4. etiketin sahip olduğu sahip olduğu aşağı bakma hareketine aittir. En düşük skor ise 5 etiket numaralı olan yukarı bakma hareketine aittir. 1400 örnek doğruluk (accuracy), modelin ağırlık (macro avg) ve mikro ortalama (weighted avg) değerleri ise %95 bulunmuştur. Bu değerler DVM makine algoritması ile aynı orandadır. Algoritmaların paralel sonuçlar elde ettiği görülmektedir. Ortalama Mutlak Hata %14,21, Ortalama Kare Hatası % 56,64 ve Karekök ortalama hatası ise % 75.26 bulunmuştur. Sınıflandırma sonucu ise %94.85 bulunmuştur.

#### 4.1.5 Karar Ağacı Algoritması (ID3-Decision Tree) analiz ve bulgular

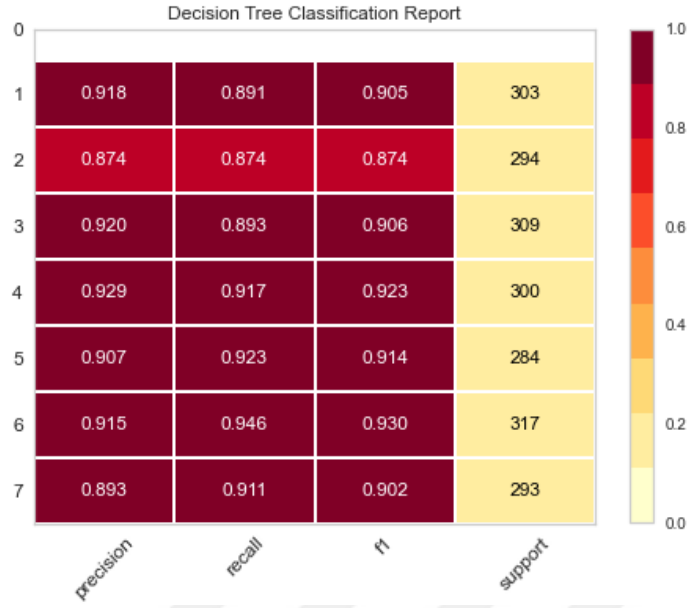
Birbirini izleyen şansa bağlı olaylarla ilgili olarak çıkan çeşitli karar noktalarını incelemek için kullanılan bir teknik olan Karar ağacı (Decision Tree) algoritması çalışmada bulunan öznelilikler üzerine uygulanmıştır. Sklearn kütüphanesi içinde tree

modülü içinde DecisionTreeClassifier sınıfında bulunur. Karar ağacı diğer benzer ağaç algoritmaları gibi benzer paritelere sahiptir. Birçok parite içinde maksimum ağaç derinliğini gösteren max\_depth değeri 10 seçilmiş ve diğer algoritmalar ile karşılaştırmak için eğitim kümesi değişmemesi için random\_state değeri sıfır seçilmiştir. Karar seçeneklerini ayrı ayrı karşılaştırdığımız karmaşıklık matrisi Şekil 4.17’de gösterilmiştir.



Şekil 4.17. Karar ağacı karmaşıklık matrisi

Bir başka ağaç algoritması olan Karar Ağacı analizi karmaşıklık matrisi sonucunun çıktılarına bakacak olursak az bir farkla en yüksek başarıma 2. etikete sahip sağa bakma hareketinin olduğu görülmektedir. En düşük başarıma sahip göz hareketinin ise 6 numaralı etikete sahip sol göz kırpma hareketine sahip olduğu görülmektedir. Karar ağacı algoritmasının ikinci etiketin sahip olduğu sağa bakma hareketinin ters grafik görünümüne sahip sola bakma hareketini daha iyi seçebilmesi, birinci kanaldan gelen artı yöndeki sinyalleri daha iyi algılayabildiği görülmektedir. En düşük çıkan 6 numaralı harekette ise eksi yöndeki daha az tespit edebildiğinden ve ikinci kanaldan gelen parazitlenmelerden dolayı daha düşük başarı gösterdiği görülmektedir. Ağaç algoritmalarının öznelikleri çıkarılan göz hareketlerini daha diğer sınıflandırma algoritmalarına göre düşük başarıyla gerçekleştirdiği görülmektedir.



Şekil 4.18. Karar Ağacı (Decision Tree) Sınıflandırma Raporu

Şekil 4.18’de Karar Ağacı (Decision Tree) makine algoritması sonucunda çıkan rapor gösterilmektedir. LightGBM, Random Forest ve DVM algoritmalarından farklı olarak keskinlik (precision) değeri en yüksek değer %92,9 ile 4. numaralı etiket olan aşağı bakma hareketi olmuştur. En düşük değer ise %89,3 ile iki göz kırpma hareketi olan 7 numaralı etiket olmuştur. Maliyet değeri de denilen recall sütununda ise değerler birbirine yakın olup en yüksek değer %94,6 ile sol göz kırpma hareketi olmuştur. En düşük değer ise %87,4 ile sağa bakma hareketinin sahip olduğu 2 numaralı etiket olmuştur. F1- Skor sütununda ise en yüksek değer %93 ile 6 numaralı etiket olan sol göz kırpma hareketi olmuştur. En düşük değer ise %87,4 ile 2 etiketine sahip sağa bakma hareketi olmuştur. 1400 örnek doğruluk (accuracy), modelin ağırlık (macro avg) ve mikro ortalama (weighted avg) değerleri ise %93 bulunmuştur. Ortalama Mutlak Hata %19,71, Ortalama Kare Hatası %71,42 ve Karekök ortalama hatası ise %84,51 bulunmuştur. Sınıflandırma sonucu ise %92,71 bulunmuştur.

## 4.2 Ham Veri Analiz Bulgular


### 4.2.1 Derin Öğrenme Analiz ve Bulguları

Bir makine öğrenme yöntemi olan derin öğrenme, veriler büyüdükçe karmaşıklık artmakta ve çıktıları anlamı şekilde yorumlamak zorlaştığı durumlarda kullanılır. Çalışma 25 kişi üzerinden alınmış, sonraki aşamalarda gerçek zamanlı ve daha çok kişiden örneklem alındığı zaman karmaşıklığın artacağı düşünüldüğünden en iyi çalışan klasik sınıflandırma algoritmaları ile test edilerek karşılaştırma yapabilmek için ilk önce öznitelikler üzerinde test edilmiştir. Daha sonra ham veri üzerine de analiz yapılarak çıkan sonuçlar üzerinde performans değerlendirmesi amaçlanmıştır. Modelin ağ yapısı Yapay sinir ağları üzerine oluşturulmuş CNN ve RNN algoritmaları da denenmiştir. YSA ile anlamlı sonuçlar bulunmuş diğer derin öğrenme modellerinde düşük değerler elde edildiğinden sonuçlar verilmemiştir. Veriler analiz edilirken katmanlar öğrenme oranını artırma, bilgi kaybını önleme, aşırı ezberleme gibi durumları önlemek için bazı düzenleme yöntemleri kullanılmıştır (Özkan vd, 2022). Veriler arasında konvolüsyon katmanlarının giriş ve çıkış kısımları dışında istenilen katmanlar arasında normalizasyon işlemleri yapılmıştır. Ayrıca maksimum havuzlama yapılarak aşırı ezberleme ve gereksiz detaylara takılma gibi overfitting problemlerinden kaynaklanabilecek problemler engellemeye çalışılmıştır. Öznitelikler ve ham veriler üzerinde uygulanan analiz sonuçları inceleyelim.


### 4.2.2 Derin Öğrenme Bulguları

Sistemin gerçek zamanlı çalıştığına gelen ham verilere karşı nasıl bir başarımla cevap verdiğini öğrenmek için ham veriler üzerinde YSA algoritmaları ile analiz yapılmıştır. Ham halde olan veriler csv formatında import edildikten sonra verilerin farklı aralıklarda değer olmasından dolayı sklearn kütüphanesi içinde bulunan StandardScaler metodu yardımıyla veriler üzerinde standardizasyon işlemi yapılmıştır. Transform edilen veriler eğitim kümesi %70 ve test kümesi %30 olmak üzere bölünmüştür. Standardize edilmiş veri giriş katmanı 3602 nörondan oluşan modele beslenmiş ve 3 ara katmandan oluşturulmuştur. Dropout katman değeri 0.5 seçilerek modelin ezberlenmesi engellenmiştir. Ara katmanlar sırası ile 1801, 900, 405 nörondan oluşturulmuştur. Çıktı katmanı 8 sınıf olduğundan 8 nörondan oluşturulmuştur. Giriş katmanlarında hesaplama yükünün sigmoid ve tanh fonksiyonlarına göre az olması ve doğrusal bir fonksiyon olmayan hızlı bir algoritma olan RELU fonksiyonu seçilmiştir. Çıktı katmanının yorumlanması için activation

değeri softmax kullanılmıştır. Model optimizeri olarak ise parite olarak ‘adam’ ve ‘rmsprop’ denenmiş ve başarıyı yüksek çıkan ‘rmsprop’ paritesi seçilmiştir. Loss metriği olarak ‘categorical\_crossentropy’ kullanılmıştır. Çoklu sınıflandırma işlemi yapıldığı için bu metrik seçilmiştir. Model 150 epoch ile eğitilmiştir. Modelin başarı metriğini gösteren accuracy grafiği Şekil 4.20’de ve modelin başarısızlık grafiğini gösteren model loss grafiği ise Şekil 4.19’da gösterilmiştir.



Şekil 4.19. Ham veri derin öğrenme hata oran grafiği



Şekil 4.20. Ham veri derin öğrenme doğruluk grafiği

Grafikler incelendiğinde doğruluk ve hata oran dağılımının başarı yüzdesinin yüksek olduğu ve paralel hareket etmediği görülmektedir. Bunun sebebinin model için kullanılan ham verilerin içinde parazitten kaynaklanabilecek hatalı veriler olduğu veya ön işleme basamakları sırasında eksik verilerden kaynaklanabileceği düşünülmektedir.

Modele genel bakıldığında ise accuary değeri %94,20 ve loss değeri ise %58.62 çıkması orta derecede başarılı olduğunu göstermektedir.

True label	1	288	0	1	1	0	10	0
	2	0	290	5	0	1	0	4
	3	0	0	288	3	8	1	0
	4	1	2	2	293	0	0	2
	5	1	0	11	0	284	1	3
	6	14	0	1	0	1	284	0
	7	0	6	5	3	3	0	283
		1	2	3	4	5	6	7
		Predicted label						

Şekil 4.21. Derin Öğrenme karmaşıklık matrisi

Derin öğrenme karmaşıklık matrisi Şekil 4.21’de gösterilmiştir. Başarım sonuçları incelendiğinde göz hareketleri içerisinde en iyi tespit edebildiği hareketin 4. Etikete sahip aşağı bakma hareketi olduğu görülmektedir. En düşük oran ile göz hareketinin tespitinin 7 numaralı göz hareketi olan iki göz kırpma hareketi olduğu görülmektedir. Uygulanan analiz sonucuna göre grafik üzerinde incelendiğinde ikinci kanaldan gelen sinyalleri daha iyi ayırt edebildiği ve her iki kanaldan gelen sinyallerin oluşturduğu verilerde ise daha az başarım sağladığı görülmektedir.

Tablo 4.2. Derin öğrenme eğitim başarım sonuçları

Bölüm No	Başarım oranı(%)
1. Bölüm	95,10
2. Bölüm	96,53
3. Bölüm	96,73
4. Bölüm	95,51
5. Bölüm	95,71
6. Bölüm	96,33
7. Bölüm	94,90
8. Bölüm	91,63
9. Bölüm	95,71
10. Bölüm	95,92
<b>Ortalama Başarım</b>	<b>95,41</b>

Tablo 1.3. Derin öğrenme test başarıml sonuçları

<b>Bölüm No</b>	<b>Başarım oranı(%)</b>
1. Bölüm	96,10
2. Bölüm	96,38
3. Bölüm	95,43
4. Bölüm	95,76
5. Bölüm	96,19
6. Bölüm	95,67
7. Bölüm	95,33
8. Bölüm	94,29
9. Bölüm	96,71
10. Bölüm	96,33
<b>Ortalama Başarım</b>	<b>95,82</b>

Eğitim veri setininin sinir ağıları üzerinde gidip gelmesi ile oluşan epoch bölümlerinin her bir başarıml sonucu Tablo 3. 'de gösterilmiştir. Bölümler rastgele alınan verilerden oluştuğundan oransal olarak farklı değerler olduğu tablodada görülmektedir. Çalışmanın genel başarıml oranı değerlendirilmesi için değerlerin genel ortalaması alınarak sonuç %95.41 bulunmuştur. Derin öğrenmenin test sonuçları Tablo 4.'de verilmiştir. Test kümesinin derin öğrenme ile eğitilmesi sonucunda ortalama %95.82 sonucu bulunmuştur.

## 5. SONUÇ VE ÖNERİLER

Dünyada binlerce insan geçirdikleri kaza ya da farklı nedenlerle yatağa bağlı kalmakta ve hayatlarını başkasına muhtaç olarak geçirmek zorunda kalmaktadır. Bu çalışmada elde edilen veriler; göz ve yüz kasları dışında bütün hareket kabiliyetini kaybetmiş ALS ve benzeri hastaların iletişim yeteneklerini ve yaşam konforlarını artırmalarına, kişi ile iletişim kuran tarafların ise anlaşılır bilgiler ile doğru teşhis, tedavi ve bakım gibi hizmetleri daha kolay sunmasına katkı sağlamaktadır. Bu amaçla çalışmada bir insan bilgisayar arabirimi tasarlanarak elde edilen deneysel bulgular anlatılmıştır. Çalışmada bir göz hareketi komutu için yatay ve dikey olmak üzere iki kanaldan veri alınmıştır. Dolayısıyla kanalların öznitelikleri iki kanal için ayrı ayrı hesaplanmış, daha sonra ise tek bir işareti temsil etmek üzere vektör olarak birleştirilmiştir. Tasarlanan sistem ile asenkron veriler üzerinde yapılan analiz sonucunda sol, sağ, aşağı ve yukarı bakma, sol ve sağ göz kırpma ile iki gözü kırpma işleminden öznitelik çıkarılmış, çıkarılan verilerin analizi sonucunda lightgbm algoritması ile %95,56 başarımla elde edilmiştir. Ayrıca sistem ham veri üzerinde yapılan derin öğrenme analizi sonucunda 7 farklı göz hareketini %95,82 başarımla algılayabilmiştir.

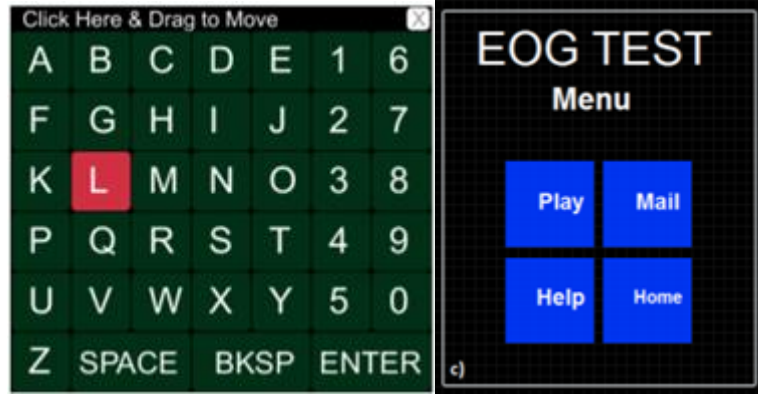
Çalışmada literatür taraması ile öncelikli olarak 50 farklı öznitelik bulunmuş ve sonrasında çalışma ile alakalı olan farklı öznitelik belirlenmiştir. MATLAB programında 50 farklı öznitelik ham veri üzerinde uygulanarak anlamlı sonuç veren 10 farklı öznitelik çalışmada kullanılmak üzere ayırt edilmiştir. Eğitim ve test kümesi ayrıldıktan sonra eğitim kümesi kfold çaprazlama yapılmıştır. İki kanallı bir yapı kurulduğundan belirlenen bu öznitelikler kanallara ayrı ayrı çapraz doğrulama yapılarak test kümesi başarımları elde edilmiştir. Sınıflandırma sonucunda başarımları en yüksek kılan  $f_0, f_1, f_2, f_3, f_5, f_6, f_7, f_8, f_9, f_{10}, f_{11}, f_{13}, f_{14}, f_{15}, f_{16}, f_{17}, f_{18}, f_{19}$  kod numaralı özniteliklerdir. Öznitelikleri çıkarıldıktan sonra en yüksek sınıflandırma başarımları sonucu %95,56 ile Microsoft'un çıkarmış olduğu LightGBM algoritması olmuştur.

Gürkan ve arkadaşları (2012) çalışmalarında 5 farklı göz hareketi kullanmış ve kullandıkları iki farklı sınıflandırma yönteminde %100 başarımları elde etmişlerdir. Zengin, Bozkurt, Uçar (2019) çalışmalarında ise yaş grubunu daha sınırlı tutarak 5 farklı göz hareketinden öznitelik çıkarmıştır. Bu çalışmada farklı yaş gruplarının kullanılması, örneklem sayısının fazla olması ve daha fazla göz hareketinin

kullanılması verilerin daha güvenilir olmasına katkı sağlamaktadır. Ayrıca sınıflandırma algoritmaları içinde lightgbm gibi ekran kartı performansını destekleyen, yüksek başarılar sunan algoritmanın kullanılması ve ham veriler üzerinde derin öğrenme analizinin kullanılması gerçek zamanlı bir sistem kurulmasını sağlamıştır. Yine bu çalışmada aynı eğitim ve test kümesinin diğer sınıflandırma algoritmalarına verilmesi ile sınıflandırma algoritmalarının performans karşılaştırmalarından daha doğru sonuçlar elde edilmesi sağlanmıştır.

Çalışmanın başarı ve kullanılabilirliğini arttırmak için daha fazla kişiden ve farklı yaş gruplarından örnekler alınarak zengin bir veri kümesi olabilirdi. Bu sayede gerçek kullanım sırasında kullanım sırasında meydana gelebilecek parazitlenmeler ve sinyallerde oluşan değişimler analiz edilebilecek ve başarıya etki eden kavramlar ortaya konulabilecekti. Gerçek zamanlı çalışmada bilgisayarların işlemci güçleri düşük performans vermekte onun yerine yüksek performanslı grafik kartları kullanılmaktadır. Çalışmada LightGBM algoritması ile farklı derin öğrenme algoritmaları ile maliyetlerin yüksek olması ve yeterli bir zaman olmadığından testler yapılamamıştır. Ayrıca daha fazla göz hareketi yapılmamıştır. Daha fazla göz hareketi daha yüksek ve hızlı etkileşim ile daha düşük performans gerektiren sistemler kullanılabilmesini sağlamaktadır.

EOG sinyal tabanlı geliştirdiğimiz insan bilgisayar arabiriminin gözlerini hareket ettirme yetisine sahip tüm engelli bireylerde kullanılması bu çalışmanın beklentileri arasındadır. Barea, Boquete, Mazo, López (2002) çalışmalarında bu çalışmadakine benzer bir arabirim bir tekerlekli sandalye kontrolünde kullanılmıştır. Belirtilen çalışma sınıflandırma aşamasında kalmış öznitelik çıkarma yöntemleri kullanılmamıştır. Başka bir çalışmada bu sinyallerin sınıflandırılması için öznitelik çıkarma yöntemleri tespit edilmeye çalışılmıştır (Zengin, Bozkurt, Uçar, 2019). Çalışmamızda geliştirdiğimiz yöntem ile Şekil 5.1'deki Taja, Surya ve arkadaşlarının çalışmasındaki gibi bir klavye ekranı (Teja, Embrandiri, Chandrachoodan, Ramasubba, 2015) veya hastanın temel ihtiyaçlarını seçebileceği, Lopez ve arkadaşlarının yaptığı gibi bir kullanıcı arabirimi de (López, Arévalo, Valledor, Campo, 2014) oluşturulabilir.



a)

b)

Şekil 5.1. Arayüz tasarım a) Klavye tasarımı b) Menü tasarımı

İlerleyen süreçlerde bu çalışmanın kapsamı yaş grubu bakımından çeşitlilik gösteren ve ulaşılmak istenen hedef kitlenin özelliklerine sahip bireylerden alınan verilerle genişletilebilir. Ayrıca bu çalışmanın analizlerinde asenkron verilerin aksine senkron verilerin kullanılması performansı gerçeğe en yakın oranda görmemizi sağlayabilir.

Bu çalışmada kullanılan algoritmalar kullanılırken bilgisayarın işlemci gücüne dayalı analizler yapması verilerin analiz edilirken bilgisayarın hesaplama süresinin uzun olmasına neden olmuştur. Bu işlem gerçek zamanlı yapıldığında sistemin tepki süresinde gecikmeye neden olacağından verimlilik oranını düşürecektir.

Bu çalışmada 7 farklı göz hareketi alınmıştır. İlerleyen çalışmalarda hareket sayısının artırılması bireylerin kendini ifade etme ve iletişim becerilerini artırmalarını sağlayacaktır.

## KAYNAKLAR

- Acır, N., Mengüç, E. C., Çınar, S. (2018). EEG Sinyallerinden EOG Gürültülerini Yok Etmek için Lineer ve Geniş Lineer Kompleks Değerli En Küçük Ortalama Kare Algoritmaları Tabanlı Bir Adaptif Gürültü Yok Etme Sistemi. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 6(1), 205-219.
- Afandi, J. (2019). *EOG kontrollü çok yönlü tekerlekli sandalye*. Basılmamış Yüksek Lisans Tezi. İzmir Katip Çelebi Üniversitesi Fen Bilimleri Enstitüsü Biyomedikal Teknolojiler Ana Bilim Dalı, 55, İzmir.
- Akay, E. Ç. (2018). Ekonometride yeni bir ufuk: Büyük veri ve makine öğrenmesi. *Sosyal Bilimler Araştırma Dergisi*, 7(2), 41-53.
- Akca, M. F. (2020). Nedir Bu Destek Vektör Makineleri? (Makine Öğrenmesi Serisi-2). 15 Ocak 2022 tarihinde <https://medium.com/deep-learning-turkiye/nedir-bu-destek-vekt%C3%B6r-makineleri-makine-%C3%B6%C4%9Frenmesi-serisi-2-94e576e4223e> adresinden erişilmiştir.
- Aras, S. (2021). İnsan Bilgisayar Arabirimi. *Dijital Gelecek Dijital Dönüşüm-2*, 7.
- Arif, M., Malagore, I. A., and Afsar, F. A., 2012. Detection and localization of myocardial infarction using k-nearest neighbor classifier. *Journal of Medical Systems*, 36(1): 279-289.
- Ayaz, F. (2019). *EMG sinyallerinin sınıflandırılması*, Basılmamış Yüksek Lisans Tezi. İnönü Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, 67, Malatya.
- Aytekin, H. *İnsan ilişkileri ve iletişim*. Pegem Akademi, Ankara, 2018.
- Bağcı, D. (2016). *Biyonik el kontrolü için EMG işaretlerinin makine öğrenmesi yöntemiyle sınıflandırılması*, Basılmamış Yüksek Lisans Tezi. Yalova Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı, 91, Yalova.
- Banerjee, A., Datta, S., Pal, M., Konar, A., Tibarewala, D. N., and Janarthanan, R. (2013). Classifying electrooculogram to detect directional eye movements. *Procedia Technology*, 10, 67-75.
- Baran, M. (2020). *Makine öğrenmesi yöntemleriyle çoklu etiketli verilerin sınıflandırılması*, Basılmamış Yüksek Lisans Tezi. Sivas Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Yönetim Bilişim Sistemleri Ana Bilim Dalı, 113, Sivas.
- Bhuyain, F., Shawon, A.K., Sakib, N., Faruk, T., Islam, K. (2019). Design and Development of an EOG-based System to Control Electric Wheelchair for People Suffering from Quadriplegia or Quadriparesis, 2019 International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST), 460-465.
- Bilen, A., Özer, A. B. (2022). Siber Saldırıları için Rastgele Orman Algoritması Kullanılarak Öznitelik Seçimi. *Fırat Üniversitesi Fen Bilimleri Dergisi*, 34(1), 31-37.
- Biswal, S., J. Kulas, H. Sun, B. Goparaju, M. B. Westover, M. T. Bianchi, and J. Sun. (2017). "SLEEPNET: automated sleep staging system via deep learning," CoRR, vol. abs/1707.08262.
- Bolt, R. A. (1982). Eyes at the interface. In Proceedings of the 1982 conference on Human factors in computing systems (pp. 360-362).
- Brahmaiah, V. P., Sai, Y. P., and Prasad, M. G. (2017, January). Data Acquisition System of Electrooculogram. In *2017 IEEE 7th International Advance Computing Conference (IACC)* (pp. 716-721). IEEE.

- Breiman, L. (2001). Random Forests, Machine learning, 2001 Kluwer Academic Publishers, 45(1), 5-32
- Bronzino, J. D. (2000). The Biomedical Engineering Handbook, Second Edition, Volume I, CRC Press LLC.
- Bronzino, J. D. (2006). Biomedical Engineering Fundamentals, CRC Press.
- Budak, H. (2018). Özellik seçim yöntemleri ve yeni bir yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22, 21-31.
- Bulut, H. F. (2006). *Körler İçin İnsan Makina Arabirimi*, Basılmamış Doktora Tezi. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, 46, İstanbul.
- Cai, J., Luo, J., Wang, S., and Yang, S. (2018). Feature selection in machine learning: A new perspective. *Neurocomputing*, 300, 70-79.
- Calp, M. H., Butuner, R., Kose, U., Alamri, A., and Camacho, D. (2022). IoHT-based deep learning controlled robot vehicle for paralyzed patients of smart cities. *The Journal of Supercomputing*, 1-36.
- Cheng H. (2009) Classification of Software Behaviors for Failure Detection: A Discriminative Pattern Mining Approach, ACM 978-1-60558-495- 9/09/06.
- Choi, J. W., Rho, E., Huh, S., and Jo, S. (2018). An EOG/EEG-Based Hybrid Brain-Computer Interface for Chess. In 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC) (pp. 129-134). IEEE.
- Coşkun, A. (2017). *Elektrookulografi (Eog) Sinyalleri ile Uyku Evreleme*. Basılmamış Yüksek Tezi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, 97, Konya.
- Cömert, B. (2016). *Alın bölgesinden alınan elektrookulogram (EOG) işaretleri için ölçüm devresi tasarımı ve sınıflandırılması*. Basılmamış Yüksek Tezi. Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı, 97, Balıkesir.
- Çakır Gündoğan, F. (2021). Gözün Yapısı. 21 Şubat tarihinde <https://gozdoktor.net/gozun-yapisi/> adresinden erişilmiştir.
- Çelik, S., Bozkurt, Ö. Ç., Ekşili, N. (2022). Çalışan Performansı Ölçeğindeki İfadelerin Karar Ağacı Algoritması İle Belirlenmesi. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 9(1), 561-584.
- Çınar, A. (2019). Veri Madenciliğinde Sınıflandırma Algoritmalarının Performans Değerlendirmesi ve R Dili ile Bir Uygulama. *Öneri dergisi*, 14(51), 90-111
- Derdiyok, A. D., Ay, A. N., ve Yıldız, M. Z. (2021). Birbirine Benzer El Hareketlerinin EMG Sinyalleri Kullanılarak Sınıflandırılması. *Academic Perspective Procedia*, 4(1), 360-371.
- DevHunter (2018). Rastgelle Orman Algoritması. 15 Aralık 2021 tarihinde <https://devhunteryz.wordpress.com/2018/09/20/rastgele-ormanrandom-forest-algoritmasi/comment-page-1/> adresinden erişilmiştir.
- Dilki, G., Başar, Ö. D. (2020). İşletmelerin iflas tahmininde k-en yakın komşu algoritması üzerinden uzaklık ölçütlerinin karşılaştırılması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 19(38), 224-233.
- DTA Mühendislik (2020). Filtrelere Giriş – FIR ve IIR Filtreleri. 15 Aralık 2021 tarihinde <https://blog.dta.com.tr/filtrelere-giris-fir-ve-iir-filtreleri/> adresinden erişilmiştir.

- Duchowski, A. (2007). *Eye tracking techniques*. In Eye tracking methodology (pp. 51-59). Springer, London.
- Erdal, M. (2022). Sistem Analizi ve Planlama. 28 Mart 2022 tarihinde <https://kontrolotomasyon.files.wordpress.com/2015/02/sistem-analizi-4.pdf> adresinden alınmıştır.
- Erciyes (2016). Elektronik Filtre Devreleri. 15 aralık 2021 tarihinde [https://biomed.erciyes.edu.tr/acaliskan/12.Hafta\\_0\\_Filtreler.pdf](https://biomed.erciyes.edu.tr/acaliskan/12.Hafta_0_Filtreler.pdf) adresinden erişilmiştir.
- Erginöz, S. (2004). Elektroretinogram (ERG), ERG bileşenlerinin incelenmesi ve ERG'nin klinik elektrofizyolojisi.
- Ergün, E., ve Aydemir, Ö. (2018). Etkin epoklar ile motor hayaline dayalı EEG işaretlerinin sınıflandırma doğruluğunun artırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(5), 817-823.
- Erin, K., ve Boru, B. (2020). EMG tabanlı insan robot etkileşimi. *Journal of Smart Systems Research*, 1(1), 11-17.
- Erkaymaz, H. (2014). Elektrokulogram (EOG) Sinyallerinin İncelenmesi ve Yapay Zeka Teknikleri İle Modellenmesi. (Doktora Tezi). Ulusal Tez Merkezi (373666)
- Eyder (2021). Engelsiz Yaşama Derneği. 23 Mart 2022 tarihinde <https://ey-der.com/ana-sayfa/turkiye-ve-dunyada-engelliler/> adresinden erişilmiştir.
- Gislason, P. O., Benediktsson, J. A., and Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern recognition letters*, 27(4), 294-300.
- Gök, B., ve Fidan, Ü. (2019). Kurumsal itibar algısının satın alma niyetine etkisinin karar ağacı ile haritalandırılması. *Business and Economics Research Journal*, 10(3), 723-734.
- Gürkan, G., Gürkan, S., ve Uşaklı, A. B. (2012). EOG Sinyalleri için Sınıflandırma Algoritmalarının Karşılaştırılması.
- Han, J., Kamber, M., Pei J. 2011. Data Mining: Concepts and Techniques. Third edition. The Morgan Kaufmann Series in Data Management Systems, 5(4), 83-124.
- Hırokı T. (2010). Mouse Cursor Control System Using Electrooculogram Signals, World Automation Congress,
- Hossain, Z., Shuvo, M.H., Sarker, P. (2017). Hardware and software implementation of real time electrooculogram (EOG) acquisition system to control computer cursor with eyeball movement, 2017 4th International Conference on Advances in Electrical Engineering (ICAEE), 1. Cilt, 132-137.
- Hu, L. Y., Huang, M. W., Ke, S. W., and Tsai, C. F. (2016). The distance function effect on k-nearest neighbor classification for medical datasets. *SpringerPlus*, 5(1), 1-9.
- İleri, R. (2020). *Disleksi Tanılı Çocuklarda Eğitimlerinde Kullanılmak Üzere En Uygun Yazı Karakterlerinin EOG Sinyallerini Kullanılarak Tespit Edilmesi*. Basılmamış Yüksek Tezi. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Ana Bilim Dalı, 121, Kayseri.
- JeyaJothi, E. S., Anitha, J., Rani, S., and Tiwari, B. (2022). A comprehensive review: computational models for obstructive sleep apnea detection in biomedical applications. *BioMed research international*, 2022.
- Kadefors, R., Kaiser, E., Petersen, I. (1968). Dynamic spectrum analysis of myo- potentials and with special reference to muscle fatigue. *Electromyography*, 8(1), 39.
- Kahneman, D. (1973). *Attention and effort* (Vol. 1063, pp. 218-226). Englewood Cliffs, NJ: Prentice-Hall

- Karacan I, Koyuncu H , Pekel O, Sümbüloğlu G, Kirnap M, ve Dursun H. (2014). Traumatic spinal cord injuries in Turkey: a nation-wide epidemiological study,
- Karagöz, Y. (2019). *Elektrookülogram Tabanlı İnsan-Makine Arayüz Uygulaması*. (Yüksek Lisans Tezi). Ulusal Tez Merkezi (591126).
- Karakurt, M., ve İşeri, İ. (2022). Patoloji Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (33), 192-206.
- Karpov, A. A., and Yusupov, R. M. (2018). Multimodal interfaces of human– computer interaction. *Herald of the Russian Academy of Sciences*, 88(1).
- Kavzoğlu, T., ve Çölkesen, İ. (2010). Karar ağaçları ile uydu görüntülerinin sınıflandırılması: *Kocaeli Örneği. Harita Teknolojileri Elektronik Dergisi*, 2(1), 36-45.
- Kavzoğlu, T., ve Çölkesen, İ. (2010). Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, 144(7), 73-82.
- Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., and Liu, T. Y. (2017). Lightgbm: A highly efficient gradient boosting decision tree. *Advances in Neural Information Processing Systems* (s. 3146-3154).
- Kemal Dağ, O. (2013). Dijital Filtre Tasarımı Giriş (Digital Filter Design) | Elektrikport Akademi. 15 Aralık 2021 tarihinde [https://www.elektrikport.com/universite/dijital-filtre-tasarimi-giris-\(digital-filter-design\)-elektrikport-akademi/8232#ad-image-0](https://www.elektrikport.com/universite/dijital-filtre-tasarimi-giris-(digital-filter-design)-elektrikport-akademi/8232#ad-image-0) adresinden erişilmiştir
- Kim, D., Lee, J., Woo, Y., Jeong, J., Kim, C., and Kim, D. K. (2022). Deep Learning Application to Clinical Decision Support System in Sleep Stage Classification. *Journal of Personalized Medicine*, 12(2), 136.
- Koca İ., Işık M., Karakuş V., Altındağ Ö., Madenci Ö., Bülbül F. (2014). The Burden on Caregivers Affecting Factors in Patients with Spinal Cord Injuries. *Türkiye Klinikleri Tıp Bilimleri Dergisi*. s. 9 (1 ) : 15-21.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks.
- Lazar, J., Feng, J. H., and Hochheiser, H. (2017). *Research methods in human-computer interaction*. Morgan Kaufmann.
- Lee, J. S., and Pottier, E. (2009). Polarimetric radar imaging: from basics to applications. CRC press.
- Li, L., Wu, X. (2011). Design and Implementation of Multimedia Control System Based on Bluetooth and Electrooculogram (EOG), 2011 5th International Conference on Bioinformatics and Biomedical Engineering, 1-4.
- Li, W., Ding, S., Chen, Y., Wang, H., and Yang, S. (2019). Transfer learning-based default prediction model for consumer credit in China. *The Journal of Supercomputing*, 75(2), 862-884.
- Liaw, A., and Wiener, M. (2002). Classification and regression by randomForest. *R news*, 2(3), 18-22.
- López Celani, N. M., Orosco, E. C., Pérez Berenguer, M. E., Bajinay, S., Zanetti, R., Valentinuzzi, M. (2015). Hybrid Human-Machine Interface to Mouse Control for Severely Disabled People.
- López, A., Fernández, D., Ferrero, F. J., Valledor, M., and Postolache, O. (2016). EOG signal processing module for medical assistive systems. In *2016 IEEE International Symposium on Medical Measurements and Applications (MeMeA)* (pp. 1-5). IEEE.

- López A., Ferrero F.J., Valledor M. (2016). A Study On Electrode Placement in EOG Systems for Medical Applications, IEEE, 978-1-4673-9172-6/16.
- MacKenzie, I. S. (2012). Human-computer interaction: An empirical research perspective.
- MEB (2012). Göz Sinyal İzleyicilerde Kurulum.12 Mart 2022 tarihinde [http://megep.meb.gov.tr/mte\\_program\\_modul/moduller\\_pdf/G%C3%B6z%20Sinyal%20İzleyicilerde%20Kurulum.pdf](http://megep.meb.gov.tr/mte_program_modul/moduller_pdf/G%C3%B6z%20Sinyal%20İzleyicilerde%20Kurulum.pdf) adresinden erişilmiştir.
- Menteş, M. M., Güven, M. M., Özcan, Ş. N., ve Akşahin, M. F. (2020). Göz Hareketlerinin Takibi ile Bilgisayar Kontrolü. *Avrupa Bilim ve Teknoloji Dergisi*, 204-210.
- Mishchenko, Y., Kaya, M., ve Cömert, M. (2017). Beyin Bilgisayar Arayüzü İçin Dvm Makine Öğrenme Yöntemi Kullanılarak Eeg Verilerinden Sağ Ve Sol El Hareket Düşüncelerinin Tespiti. *Tübbav Bilim Dergisi*, 10(3), 1-20.
- Microsoft (2022). Light Gradient Boosting Machine. 21 Kasım 2021 tarihinde <https://github.com/Microsoft/lightGBM> adresinden erişilmiştir. “
- Mitchell, Tom (1997). *Machine Learning*. New York: McGraw Hill. ISBN 0-07-042807-7. OCLC 36417892
- Mohd Noor, N. S. E., Ibrahim, H., Che Lah, M. H., and Abdullah, J. M. (2022). Prediction of Recovery from Traumatic Brain Injury with EEG Power Spectrum in Combination of Independent Component Analysis and RUSBoost Model. *BioMedInformatics*, 2(1), 106-123.
- Mutlu İpek, B. (2018). EEG sinyallerinin epileptik rahatsızlıkların teşhisi için konvolüsyonel sinir ağları ve destek vektör makineleri ile tasnif edilmesi (Master's thesis, Fen Bilimleri Enstitüsü).
- O'Bard, Bryce, and Kiran George. "Classification of eye gestures using machine learning for use in embedded switch controller." 2018 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). IEEE, 2018.
- Ok, A. Ö., Akar, Ö., Güngör, O. (2011). Rastgele Orman Sınıflandırma Yöntemi Yardımıyla Tarım Alanlarındaki Ürün Çeşitliliğinin Sınıflandırılması.
- Öner, P. A., Gürkan, S., İstanbullu, A., Doğan, S. (2015). Digital signal processing and classification study for electrooculogram signals. In *2015 Medical Technologies National Conference (TIPTEKNO)* (pp. 1-4). IEEE.
- Öner, P.A., Gürkan, S. (2015). İstanbullu, A., Doğan, S., Digital signal processing and classification study for electrooculogram signals, 2015 Medical Technologies National Conference (TIPTEKNO), 1-4.
- Özkan, N. F., Ulutaş, B. H., Yetkin, B. N. (2022). Derin Öğrenme Yöntemleriyle Sürücü Yorgunluk Tespiti: Bir Uygulama.
- Paisarnsrisomsuk, S., Ruiz, C., Alvarez, S. (2020, July). Improved deep learning classification of human sleep stages. In *2020 IEEE 33rd international symposium on computer-based medical systems (CBMS)* (pp. 338-343). IEEE.
- Pal, M. (2005). Random forest classifier for remote sensing classification. *International journal of remote sensing*, 26(1), 217-222.
- Pfurtscheller, G., Da Silva, F. L. (1999). Event-related EEG/MEG synchronization and desynchronization: basic principles. *Clinical neurophysiology*, 110(11), 1842-1857.
- Prasath, V. B., Alfeilat, H. A. A., Hassanat, A., Lasassmeh, O., Tarawneh, A. S., Alhasanat, M. B., and Salman, H. S. E. (2017). Distance and Similarity Measures Effect on the Performance of K-Nearest Neighbor Classifier--A Review. *arXiv preprint arXiv:1708.04321*.

- Ravichandran, T., Kamel, N., Al-Ezzi, A. A., Alsaih, K., and Yahya, N. (2021). Electrooculography-based Eye Movement Classification using Deep Learning Models. In *2020 IEEE-EMBS Conference on Biomedical Engineering and Sciences (IECBES)* (pp. 57-61). IEEE.
- Rechichi, I., Iadarola, A., Zibetti, M., Cicolin, A., and Olmo, G. (2021). Assessing REM Sleep Behaviour Disorder: From Machine Learning Classification to the Definition of a Continuous Dissociation Index. *International Journal of Environmental Research and Public Health*, 19(1), 248.
- Roder, M., Passos, L. A., de Rosa, G. H., de Albuquerque, V. H. C., and Papa, J. P. (2021). Reinforcing Learning in Deep Belief Networks through nature-inspired optimization. *Applied Soft Computing*, 108, 107466.
- Roux, N. L., and Bengio, Y. (2008). Representational Power of Restricted Boltzmann Machines and Deep Belief Networks. *Neural Computation*, 20(6), 1631-1649. doi:10.1162/neco.2008.04-07-510.
- Roy, R., Kumar, A., Mahadevappa, M., and Kumar, C. S. (2018). Deep learning based object shape identification from EOG controlled vision system. In *2018 IEEE SENSORS* (pp. 1-4). IEEE.
- Sanei S., Chambers, J.A. (2007). EEG Signal Processing, Wiley, England.
- Saner, C. B., Kesici, M., Mahdı, M., Yaslan, Y., ve Genç, V. İ. (2019). Güç Sistemlerinde Geçici Hal Kararsızlığının Arıza Öncesi Fazör Ölçümleri Kullanarak Karar Ağacı Tabanlı Kestirimi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 23(1), 6-14.
- Savaş, S. (2020). Derin Öğrenme Algoritmaları. 15 Kasım 2021 tarihinde <https://medium.com/yapay-zeka-makine-%C3%B6%C4%9Frenmesi-derin-%C3%B6%C4%9Frenme/derin-%C3%B6%C4%9Frenme-algoritmalar%C4%B1-8dea99d9b41f> adresinden erişilmiştir.
- Sharma, M., Kumbhani, D., Yadav, A., and Acharya, U. R. (2022). Automated Sleep apnea detection using optimal duration-frequency concentrated wavelet-based features of pulse oximetry signals. *Applied Intelligence*, 52(2), 1325-1337.
- Tabak, Z. (2015). *Kalp ve solunum seslerinden uyku apnesi tespitinin yapılabilirliğinin incelenmesi*. Basılmamış Yüksek Tezi. Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Ana Bilim Dalı, 61, Ankara.
- Tabkara, M., Latifoğlu, F., Ceran, K., Çavga, S. H., Yaprak, M., ve Altıntop, Ç. G. (2017). Electrooculography based font and punto analysis. In *2017 Medical Technologies National Congress (TIPTEKNO)* (pp. 1-4). IEEE.
- Takçı, H. (2008). Veri Madenciliği Dersi Notları, (Veri Madenciliği Dersi – GYTE – Dr. Hidayet Takçı 10/05/2008)
- Tsiouris, K M, Pezoulas, V. C., Zervakis, M., Konitsiotis, S., Koutsouris, D. D., and Fotiadis, D. I. (2018). A Long Short-Term Memory deep learning network for the prediction of epileptic seizures using EEG signals. *Computers in Biology and Medicine*, 99, 24-37. doi:10.1016/j.combiomed.2018.05.019.
- Turan, B. İ. (2021). Design-engineering relation in yacht design process. *IDA: International Design and Art Journal*, 3(2), 210-223.
- Turkau Araştırma (2021). Sistem Tasarımı Nedir?. 5 Nisan 2022 tarihinde <https://turkau.com/sistem-tasarimi/> adresinden alınmıştır.
- Türker, G. F., Tarımer, İ. (2016). Kablosuz algılayıcı ağ tabanlı taşınabilir EKG tasarımı ve uygulaması, *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, c.22, s. 2, ss. 78-84.

- Tüylek, Z. (2021). Biyolojik Sistemlerde Gelecekteki Nano/biyosensör Ürünlerine Hazırlık. *Uluslararası Biyosistem Mühendisliği Dergisi*, 2(1), 17-39.-
- Ursula H., Pierre P., Sylvie B. (2010). Facial reactions to emotional facial expressions: Affect or cognition? *Cognition and Emotion* 1998:12(4), 509–531.
- Uşaklı, A. B., ve Gürkan, S. (2009). Elektrokülogram Tabanlı Yeni Bir İnsan Bilgisayar Arabirimi ve Sanal Klavye Olarak Uygulaması (A Novel Electrooculogram-Based Human Computer Interface and Its Application as a Virtual Keyboard), 14. *Biyomedikal Mühendisliği Ulusal Toplantısı*, 20-22.
- Uşaklı A.B., Gürkan, S. (2010). Design of a Novel Efficient Human–Computer Interface: An Electrooculogram Based Virtual Keyboard, *IEEE Transactions on Instrumentation and Measurement*, 70: 2099-2108.
- Uyulan, Ç., Ergüzel, T. T., ve Tarhan, N. (2019). Elektroensefalografi Tabanlı Sinyallerin Analizinde Derin Öğrenme Algoritmalarının Kullanılması. *JNBS*, 108.
- Ünal, Y. (2015). Makine öğrenmesi yöntemleriyle bel bölgesi rahatsızlıklarının tanısı.
- Üstüner, M., ve Şanlı, F. B. (2019). Çok zamanlı polarimetrik SAR verileri ile tarımsal ürünlerin sınıflandırılması. *Jeodezi Ve Jeoinformasyon Dergisi*, 7(1), 1-10.
- Valkenburg, M.E.V. (1982). *Analog Filter Design*: Cbs College College Publishing Company, New York.
- Vapnik, V.N. (1995), *The Nature of Statistical Learning Theory*, Springer-Verlag, New York.
- Vapnik, V. N. (2000), *The Nature of Statistical Learning Theory*, 2. Baskı, Springer-Verlag, New York.
- Venkataramanan, S., Prabhat, P., Choudhury, S. R., Nemade, H. B., and Sahambi, J. S. (2005). Biomedical instrumentation based on electrooculogram (EOG) signal processing and application to a hospital alarm system. In *Proceedings of 2005 International Conference on Intelligent Sensing and Information Processing, 2005*. (pp. 535-540). IEEE.
- Yağın, B. (2022). *Yapay zekâ tabanlı görüntü işleme yöntemleri ile COVID-19 tahmini*. Basılmamış Yüksek Tezi. İnönü Üniversitesi, Sağlık Bilimleri Enstitüsü, Biyoistatistik ve Tıp Bilişimi Ana Bilim Dalı, 47, Malatya.
- Yakut O., Solak S., ve Bolat E.D. (2014). Measuring EKG signal using e-health sensor platform”, *International Conference on Chemistry, Biomedical and Environment Engineering*, Antalya, 65-69.
- Yang, L., Jiang, H., Ding, X., Liao, Z., Wei, M., Li, J., and Fang, Y. (2022). Modulation of Sleep Architecture by Whole-Body Static Magnetic Exposure: A Study Based on EEG-Based Automatic Sleep Staging. *International Journal of Environmental Research and Public Health*, 19(2), 741.
- Yarbus, A. L. (1967). Eye movements during perception of complex objects. In *Eye movements and vision* (pp. 171-211). Springer, Boston, MA.
- Yavuz, O., Bayram, M. C., ve Yıldırım, T. (2007). Chebyshev Filtre Parametrelerinin Yapay Sinir Ağları Kullanılarak Hesaplanması. *EMO 2007 Elektrik-Elektronik-Bilgisayar Mühendisliği 12. Ulusal Kongresi*.
- Zander, T. O., Ihme, K., Gärtner, M., Rötting, M. (2011). A public data hub for benchmarking common brain–computer interface algorithms. *Journal of neural engineering*, 8(2), 025021.
- Zengin, İ., Bozkurt, M. R., ve Uçar, M. K. (2019). EOG İşaretini Kaynak İşaret Olarak Kullanmak Üzere Etkin Özelliklerin Belirlenmesi. *Sakarya University Journal of Computer and Information Sciences*, 2(3), 134-144.

- Zhang, Y., Gao, X., Zhu, J., Zheng, W., Lu, B. (2015). A novel approach to driving fatigue detection using forehead EOG, 2015 7th International IEEE/EMBS Conference on Neural Engineering (NER), 707-710.
- Zou, J., and Zhang, Q. (2021, January). eyeSay: Eye Electrooculography Decoding with Deep Learning. In *2021 IEEE International Conference on Consumer Electronics (ICCE)* (pp. 1-3). IEEE.
- Qiao C, Yang L, Shi Y, Fang H, and Kang Y. (2021). Deep belief networks with self-adaptive sparsity. *Appl. Intell*, 1-17.
- Wang, D., Miao, D., and Xie, C. (2011). Best basis-based wavelet packet entropy feature extraction and hierarchical EEG classification for epileptic detection. *Expert Systems with Applications*, 38(11): 14314-14320.
- Webster, J. G. (1998). *Medical Instrumentation*, 3rd Ed., John Wiley and Sons.



## ÖZ GEÇMİŞ

Recep ARSLAN, Samsun Atakum Teknik Lisesi'ni bitirdikten sonra Gaziantep Üniversitesi Mühendislik Fakültesi, Bilgisayar Mühendisliği bölümünden 01.09.2016 tarihinde mezun oldu. 2019 yılında OMÜ LEE Akıllı Sistemler Ana Bilim Dalı Yüksek Lisans programına girdi. Mezuniyetinden bu yana kamu da olarak görev yapan A. B., iyi/orta derecede İngilizce/orta bilmektedir. Temel ilgi alanları, oyun programlama, android programlama, IOT cihazlar, görüntü işleme, makine ve derin öğrenme, (09.18.2022).

### İletişim Bilgileri

ORCID ID: 0000-0002-8572-4635

### Yayınlar:

1. Kola, A. F., Arslan, R., Aras, S. (2021, Şubat). EOG Cihazı ile Arayüz Kontrolü. International Symposium of Scientific Research and Innovative Studies, Bandırma.
2. Arslan, R., Aras, S. (2021, Şubat), Göz Hareketleri Temelli İnsan Bilgisayar Arabirimi, has participated in 3rd International Conference on Applied Engineering and Natural Sciences on 20-23 July in 2022 at Konya/Turkey