

T.C.
MİLLÎ SAVUNMA ÜNİVERSİTESİ
ALPARSLAN SAVUNMA BİLİMLERİ VE MİLLÎ GÜVENLİK
ENSTİTÜSÜ
ASKERÎ ELEKTRONİK SİSTEMLER MÜHENDİSLİĞİ ANA
BİLİM DALI
ASKERÎ ELEKTRONİK SİSTEMLER MÜHENDİSLİĞİ
PROGRAMI

ELEKTROOKÜLOGRAM TABANLI SANAL
KLAVYE UYGULAMASINDA METASEZGİSEL
OPTİMİZASYON ALGORİTMASI KULLANIMI

YÜKSEK LİSANS TEZİ

ALİ ÇAĞRI BAYRAKTAR
2181151

TEZ DANIŞMANI: DR.ÖĞR. ÜYESİ SERKAN GÜRKAN

ANKARA
MAYIS 2024

T.C.
MİLLÎ SAVUNMA ÜNİVERSİTESİ
ALPARSLAN SAVUNMA BİLİMLERİ VE MİLLÎ GÜVENLİK
ENSTİTÜSÜ
ASKERÎ ELEKTRONİK SİSTEMLER MÜHENDİSLİĞİ ANA
BİLİM DALI
ASKERÎ ELEKTRONİK SİSTEMLER MÜHENDİSLİĞİ
PROGRAMI

ELEKTROOKÜLOGRAM TABANLI SANAL
KLAVYE UYGULAMASINDA METASEZGİSEL
OPTİMİZASYON ALGORİTMASI KULLANIMI

YÜKSEK LİSANS TEZİ

ALİ ÇAĞRI BAYRAKTAR
2181151

TEZ DANIŞMANI: DR.ÖĞR. ÜYESİ SERKAN GÜRKAN

ANKARA
MAYIS 2024

ÖZGÜNLÜK RAPORU

Tez çalışmamın a) Kapak sayfası, b) Giriş, c) Ana bölümler ve ç) Sonuç kısımlarından oluşan toplam 61 sayfalık kısmına ilişkin, 04/04/2024 tarihinde şahsım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan özgünlük raporuna göre, tezimin benzerlik oranı % 8'dir.

Uygulanan filtrelemeler:

- 1- Kaynakça hariç
- 2- Alıntılar hariç
- 3- 5 kelimedenden daha az örtüşme içeren metin kısımları hariç

Millî Savunma Üniversitesi Alparslan Savunma Bilimleri ve Millî Güvenlik Enstitüsü Lisansüstü Tez Çalışması Özgünlük Raporu Alınması ve Kullanılması Uygulama Usul ve Esasları'nı inceledim ve bu Uygulama Esasları'nda belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Ali Çağrı BAYRAKTAR

04/04/2024

ETİK BEYAN

Millî Savunma Üniversitesi Enstitüleri Lisansüstü Tez Hazırlama Kılavuzu'nda yer alan yazım kurallarına uygun olarak hazırladığım bu tez çalışmada; tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi, tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu, tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi, kullanılan verilerde herhangi bir değişiklik yapmadığımı, bu tezde sunduğum çalışmanın özgün olduğunu bildirir; aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim. Bu tezdeki düşünce, görüş, varsayım, sav veya tezler bana aittir; Millî Savunma Bakanlığı, Türk Silahlı Kuvvetleri, Kara Kuvvetleri Komutanlığı, Millî Savunma Üniversitesi ve Alparslan Savunma Bilimleri ve Millî Güvenlik Enstitüsü sorumlu tutulamaz.

Ali Çağrı BAYRAKTAR

04/04/2024

Aziz Şehitlerimiz, Kahraman Gazilerimiz ve Canım Aileme...



ÖNSÖZ ve TEŞEKKÜR

Bu tezde göz hareketlerine dayanan bir sanal klavye uygulamasında, öznitelik seçimi için metasezgisel bir optimizasyon tekniği olan gri kurt algoritmasının kullanılması ve sınıflandırma başarımının incelenmesi amaçlanmıştır.

Tüm bu çalışmalarımı gerçekleştirirken mesleki anlamda sahip olduğu tüm tecrübeleri ile birikimlerini benimle paylaşan değerli danışmanım ve aynı zamanda komutanım Dr.Öğr. Üyesi Serkan GÜRKAN'a, desteklerinden dolayı Millî Savunma Üniversitesi Kara Astsubay Meslek Yüksekokulunda görev yapan çok değerli mesai arkadaşlarıma, sadece yüksek lisans döneminde değil hayatımın her anında yanımda olan ve beni her zaman destekleyen canım aileme teşekkürlerimi sunarım.

Ankara; Mayıs 2024

Ali Çağrı BAYRAKTAR

İÇİNDEKİLER

Sayfa

ÖZGÜNLÜK RAPORU	
ETİK BEYAN	
İTHAF	
ÖNSÖZ ve TEŞEKKÜR	
İÇİNDEKİLER	vii
TABLO LİSTESİ	viii
ŞEKİL LİSTESİ	ix
SEMBOL LİSTESİ	x
KISALTMALAR	xi
TÜRKÇE ÖZ	xii
İNGİLİZCE ÖZ (ABSTRACT)	xiii
1. GİRİŞ	1
2. LİTERATÜR TARAMASI ve KURAMSAL TEMELLER	3
2.1. Elektrokülogram	7
2.2. EOG Elektrotları	9
2.3. EOG Veri Yakalama	10
2.4. Öznitelik Çıkarma	12
2.5. Metasezgisel Optimizasyon Algoritmaları	13
3. GRİ KURT OPTİMİZASYONU ALGORİTMASI	16
3.1. Avın Çevrelenmesi	18
3.2. Avlanma	19
3.3. Ava Saldırı	20
3.4. Av Arama	20
4. MATERYAL VE METOT	23
4.1. Veri Yakalama Sisteminin Tasarımı ve Üretimi	23
4.2. Veri Toplama	27
4.3. Öznitelik Çıkarımı	30
4.4. Öznitelik Seçimi	32
4.5. Sınıflandırma	37
4.6. Sanal Klavye	39
5. DENEYSEL ÇALIŞMALAR	41
5.1. Veri Toplama Sisteminin Test Edilmesi	41
5.2. Öznitelik Seçim Sürecinin İncelenmesi	42
5.3. Sınıflandırma Başarımının İncelenmesi	48
5.4. Göz Hareketlerine Dayalı Sanal Klavye Uygulamasının İncelenmesi	49
6. SONUÇ	52
KAYNAKÇA	54

TABLO LİSTESİ

	Sayfa
Tablo 2.1: Göz Hareketlerine Dayanan İBA ve Sanal Klavye Uygulamalarına İlişkin Literatüre Giren Bazı Önemli Çalışmalar.	4
Tablo 2.2: Sürü Zekâsından Esinlenen Başlıca Optimizasyon Algoritmaları.	15
Tablo 4.1: Kullanılan Öznitelikler ve Denklemleri.	31
Tablo 4.2: Aritmetik Ortalama Özniteliği İçin Uygunluk ve Başarım Değerleri.	34
Tablo 4.3: Standart Sapma Özniteliği İçin Uygunluk ve Başarım Değerleri.	34
Tablo 4.4: Medyan Özniteliği İçin Uygunluk ve Başarım Değerleri.	34
Tablo 4.5: %25 Kırpılmış Ortalama Özniteliği İçin Uygunluk ve Başarım Değerleri.	35
Tablo 4.6: %50 Kırpılmış Ortalama Özniteliği İçin Uygunluk ve Başarım Değerleri.	35
Tablo 4.7: Maksimum Özniteliği İçin Uygunluk ve Başarım Değerleri.	35
Tablo 4.8: Minimum Özniteliği İçin Uygunluk ve Başarım Değerleri.	36
Tablo 4.9: Çeyrekler Açıklığı Özniteliği İçin Uygunluk ve Başarım Değerleri.	36
Tablo 4.10: Ortalama Mutlak Sapma Özniteliği İçin Uygunluk ve Başarım Değerleri.	36
Tablo 4.11: Basıklık Özniteliği İçin Uygunluk ve Başarım Değerleri.	37
Tablo 5.1: Aritmetik Ortalama Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	43
Tablo 5.2: Standart Sapma Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	43
Tablo 5.3: Medyan Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	44
Tablo 5.4: %25 Kırpılmış Ortalama Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	44
Tablo 5.5: %50 Kırpılmış Ortalama Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	44
Tablo 5.6: Maksimum Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	45
Tablo 5.7: Minimum Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	45
Tablo 5.8: Çeyrekler Açıklığı Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	45
Tablo 5.9: Ortalama Mutlak Sapma Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	46
Tablo 5.10: Basıklık Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.	46
Tablo 5.11: YSA ile Sınıflandırmada Elde Edilen En İyi Başarı Değerleri.	46
Tablo 5.12: %25 Kırpılmış Ortalama Özniteliği ile Birlikte Farklı Özniteliklerin Kullanımının Sınıflandırma Başarımına Etkisi.	47
Tablo 5.13: %25 Kırpılmış Ortalama ve Basıklık Öznitelikleri ile Gerçekleştirilen Sınıflandırma için Elde Edilen Karşıtlık Matrisi.	48
Tablo 5.14: Metin Yazım Hızı Deney Sonuçları.	50
Tablo 5.15: Metin Yazım Hızı Ortalamaları ve Literatür Karşılaştırması.	51

ŞEKİL LİSTESİ

	Sayfa
Şekil 2.1: İnsan Gözüne Ait Görüntüler (a) Dikey Kesit (b) Karşıdan Görünüm.	8
Şekil 2.2: EOG Sinyalinin Gözün Yatay Hareketleri ile Değişimi ve Oküler Dipol Model.	8
Şekil 2.3: EOG Sinyallerinin Ölçümünde Kullanılan Ag/AgCl Elektrotlara Ait Görüntüler.	9
Şekil 2.4: Ag/AgCl Elektrotlarının İnsan Yüzüne Yerleşimine Ait Örnek Görüntüler.	10
Şekil 2.5: EOG Veri Yakalama Sistemlerine Örnekler (a) Örnek 1 (b) Örnek 2 (c) Örnek 3.	11
Şekil 2.6: EOG Kayıtları (a) Örnek 1 (b) Örnek 2 (c) Örnek 3 (ç) Örnek 4.	12
Şekil 3.1: Gri Kurt Hiyerarşisi.	16
Şekil 3.2: Gri Kurt Avlanma Davranışı (a) Takip, Kovalama, Yaklaşma (b-ç) Takip, Kuşatma, Taciz (d) Saldırı.	17
Şekil 3.3: Gri Kurtların Avlanma Stratejisi.	19
Şekil 3.4: Av Arama ve Saldırma Kriteri.	20
Şekil 3.5: GKO Algoritmasının Akış Şeması.	21
Şekil 4.1: Tasarım Aşamaları.	23
Şekil 4.2: Tasarlanan EOG Veri Yakalama Sisteminin Blok Şeması.	24
Şekil 4.3: Tasarlanan EOG Veri Yakalama Sisteminin Devre Şeması.	24
Şekil 4.4: Üretimi Yapılan EOG Veri Yakalama Devresinin Bileşenleri.	24
Şekil 4.5: Elektrotların Yüzdeki Yerleşimi.	25
Şekil 4.6: Hanning Filtreleme Algoritması.	26
Şekil 4.7: Tasarlanan Li-Po Batarya Şarj Devresi.	26
Şekil 4.8: Test Yüzeyinin Bileşenleri (a) Test Hedefi (b) Test Hedeflerinin Test Yüzeyinde Yerleşimi.	28
Şekil 4.9: Veri Toplamada Kullanılan Bilgisayar Arayüzü.	29
Şekil 4.10: Veri Toplama Safhasında Elde Edilen Örnek EOG Kayıtları.	29
Şekil 4.11: Elde Edilen Öznitelik Grafikleri.	30
Şekil 4.12: Sınırlar ve Av Koordinatları.	33
Şekil 4.13: Tasarlanan YSA Modeli.	39
Şekil 4.14: Tasarlanan P300 Sanal Klavye Grafik Arayüzü.	40
Şekil 5.1: Örnek Bir EOG Kaydı (a) Ham Veri (b) DC Seviye Bastırma İşlemi (c) Hanning Filtreleme İşlemi.	42

SEMBOL LİSTESİ

Ag/AgCl	: Gümüş/Gümüş Klorür
α	: Alfa
β	: Beta
δ	: Delta
ω	: Omega
t	: Mevcut İterasyon
\vec{A}	: A Katsayı Vektörleri
\vec{C}	: C Katsayı Vektörleri
\vec{X}_p	: Avın Konum Vektörü
\vec{X}	: Gri Kurdun Konum Vektörü
\vec{D}_α	: Alfa Kurdun Ava Olan Mesafe Vektörü
\vec{D}_β	: Beta Kurdun Ava Olan Mesafe Vektörü
\vec{D}_δ	: Delta Kurdun Ava Olan Mesafe Vektörü
\vec{X}_α	: Alfa Kurduna Göre Avın Konum Vektörü
\vec{X}_β	: Beta Kurduna Göre Avın Konum Vektörü
\vec{X}_δ	: Delta Kurduna Göre Avın Konum Vektörü
\vec{X}_1	: Alfa Kurt İçin Deneme Vektörü
\vec{X}_2	: Beta Kurt İçin Deneme Vektörü
\vec{X}_3	: Delta Kurt İçin Deneme Vektörü
\vec{r}_1	: Rastsal Vektör-1
\vec{r}_2	: Rastsal Vektör-2
kHz	: Kiloherz
μV	: Mikrovolt

KISALTMALAR

EOG	: Elektrokülografi
EKG	: Elektrokardiyogram
EMG	: Elektromiyogram
EEG	: Elektroensefalogram
İMA	: İnsan Makine Arabirimi
İBA	: İnsan Bilgisayar Arabirimi
ALS	: Amyotrofik Lateral Skleroz
GKO	: Gri Kurt Optimizasyonu
YSA	: Yapay Sinir Ağı
CNN	: Convolutional Neural Network
kNN	: k-Nearest Neighbour
DTW	: Dynamic Time Warping
FFNN	: Feed Forward Neural Network
SVM	: Support Vector Machine
LDA	: Linear Discriminant Analysis
CT	: Classification Tree
DNN	: Deep Neural Network
DPW	: Dynamic Positional Warping
BBA	: Beyin Bilgisayar Arabirimi
SZ	: Sürü Zekâsı
Li-Po	: Lityum Polimer
MCC	: Matthews Correlation Coefficient
ReLU	: Rectified Linear Unit
tanh	: Hiperbolik Tanjant
TP	: True Positive
TN	: True Negative
FP	: False Positive
FN	: False Negative

TÜRKÇE ÖZ

Elektrookülogram Tabanlı Sanal Klavye Uygulamasında Metasezgisel Optimizasyon Algoritması Kullanımı

Ali Çağrı BAYRAKTAR

Millî Savunma Üniversitesi, Alparslan Savunma Bilimleri ve Millî Güvenlik Enstitüsü

Ankara, Mayıs, 2024

Göz hareketlerine dayanan insan bilgisayar arabirimleri ve insan makine arabirimleri amyotrofik lateral skleroz gibi hastalıklara sahip bireylerin günlük yaşantılarına önemli katkılar sağlayan sistemlerdir. Bu sistemlere yenilikler kazandırmak ve mevcut kabiliyetlerini geliştirmek üzere çalışmalar devam etmektedir. Sözü geçen çalışmaların bir kısmı göz hareketlerini algılayan veri toplama sistemleri alanında yoğunlaşırken bir kısmı da toplanan kayıtların sınıflandırılması ve değerlendirilmesi alanlarına yoğunlaşmaktadır. Bu tez çalışması kapsamında, düşük maliyetli bir elektrookülogram veri yakalama sistemi geliştirilmiş ve prototip üretimi yapılmıştır. 20 farklı bireyden 9 sakkadik göz hareketi için veri toplama işleminin ardından istatistiksel hesaplamalara dayanan 10 öznitelik çıkarımı gerçekleştirilmiştir. Elde edilen özniteliklerden en uygununun belirlenmesi için metasezgisel bir yöntem olan gri kurt optimizasyon algoritması kullanılmıştır. Yürütülen çalışma neticesinde, %25 kırılmış ortalama ve basıklık özniteliklerinin birlikte kullanıldığı durumda en iyi özniteliklerin seçilmiş olacağı öngörülmüştür. Bu doğrultuda bir yapay sinir ağı modeli tasarlanmış ve belirlenen öznitelikler kullanılarak eğitilmiştir. Sınıflandırma çalışmaları neticesinde sakkadik göz hareketleri için %99,8 başarımla elde edilmiştir. Eğitilen yapay sinir ağı modelini içeren ve P300 sanal klavye arayüzünü kullanan bir MATLAB uygulaması geliştirilmiş, geliştirilen sanal klavye için 14,7 harf/dakika karakter yazım hızına ulaşılmıştır.

Anahtar Sözcükler: Makine Öğrenmesi, Elektrookülografi, Gömülü Sistemler, Sınıflandırma, Gri Kurt Optimizasyon Algoritması.

Bilim Kodu : 93437

Sayfa Sayısı : 61

Tez Danışmanı: Dr.Öğr.Üyesi Serkan GÜRKAN

ABSTRACT

Utilization of a Metaheuristic Optimization Algorithm in Electrooculogram Based Virtual Keyboard Application

Ali Çađrı BAYRAKTAR

Turkish National Defense University, Alparslan Defence Sciences and National Security Institute

Ankara, May, 2024

Eye movement-based human-computer interfaces and human-machine interfaces are systems that make significant contributions to the daily lives of individuals with diseases such as amyotrophic lateral sclerosis. Efforts are underway to innovate these systems and improve their existing capabilities. Some of these efforts focus on developing data collection systems that detect eye movements, while others concentrate on the classification and evaluation of collected records. Within the scope of this thesis, a low-cost electrooculogram data capture system has been developed and a prototype has been produced. Data collection for 9 saccadic eye movements from 20 different individuals was conducted, followed by the extraction of 10 different features based on statistical calculations. To determine the most suitable features, a metaheuristic method called grey wolf optimization algorithm was utilized. As a result of the conducted study, it is anticipated that the best features will be selected when the features of 25% trimmed mean kurtosis are used together. Accordingly, an artificial neural network model was designed and trained using the identified features. Classification studies resulted in a 99,8% success rate for saccadic eye movements. A MATLAB application incorporating the trained artificial neural network model and using the P300 virtual keyboard interface was developed, achieving a typing speed of 14,7 characters per minute for the developed virtual keyboard.

Keywords: Machine Learning, Electrooculography, Embedded Systems, Classification, Gray Wolf Optimization Algorithm.

Science Code : 93437

Pages : 61

Supervisor : Asst.Prof.Dr. Serkan GÜRKAN

1. GİRİŞ

Elektrokardiyogram (EKG), elektromiyogram (EMG) ve elektroensefalogram (EEG) gibi insan vücudunun aktiviteleri esnasında üretilen elektriksel sinyaller hastalıkların teşhis edilmesinde önemli destekleyici enstrümanlardır. Gerçek zamanlı kayıt altına alınan EEG ve EMG sinyallerinin değerlendirilmesi neticesinde hastalıkların teşhisinin yanı sıra insan bilgisayar arabirimleri (İBA) ve insan makine arabirimleri (İMA) geliştirilebilmektedir. İBA ve İMA'lar; bazı hasta gruplarının kullandıkları medikal destekleyici aygıtların kontrolü, hastaların çevre ile iletişimi, uyku apnesi gibi hastalıkların takibi, insan alışkanlıklarının belirlenmesi ve daha birçok alanda etkin bir şekilde kullanılmaktadır.

Son on beş yılda, İBA ve İMA uygulamaları alanında elektrookülogram (EOG) sinyallerinin kullanımı önemli bir artış göstermiştir. Özellikle motor nöron (Amyotrofik Lateral Skleroz: ALS) hastalarının çevre ile iletişim kurmalarını sağlamak ve felçli hastaların tekerlekli sandalyelerinin kontrol edilmesi gibi uygulamalarda EOG işaretlerinin sıklıkla kullanıldığı görülmektedir. Diğer taraftan pilotların ve askerlerin baskı altında davranışlarını incelemek için EOG işaretlerinden faydalanılarak gerçekleştirilen çalışmalar da bulunmaktadır.

EOG işaretlerinin kullanıldığı İMA ve İBA uygulamaları incelendiğinde çalışmaların; ölçüm elektrotları, sinyal ölçme sistemi, en uygun özneliklerin belirlenmesi ve sınıflandırma gibi başlıca alanlarda yoğunlaştığı görülmektedir. Bu alandaki gelişmeler sayesinde göz hareketleri başlangıçta %70-80 doğrulukta sınıflandırılabilirken, gelinen noktada %90'ı aşan sınıflandırma başarımları elde edilebilmektedir.

Literatür incelendiğinde; sinyal ölçme sistemi, en uygun özneliklerin belirlenmesi ve sınıflandırma gibi alanlardaki çalışmaların devam ettiği ve sınıflandırma başarımının artırılmasına yönelik gayretlerin sürdüğü görülmektedir.

Literatüre yeni giren sınıflandırma algoritmalarının ve uygun öznelik belirlemek için geliştirilen güncel tekniklerin EOG işaretleri için de uygulanması önem taşımaktadır.

Bu doğrultuda bir inceleme yapıldığında, literatürde EOG işaretleri için uygun özniteliklerin belirlenmesi ve sınıflandırılması için metasezgisel algoritmaların kullanıldığı çalışmalara yeterince yer verilmediği görülmüştür.

Tüm bu bilgilerden hareketle, “EOG işaretleri için en uygun özniteliklerin belirlenmesinde metasezgisel bir algoritma olan gri kurt optimizasyon (GKO) algoritması kullanılarak sınıflandırma başarımı artırılabilir” hipotezi oluşturulabilir.

Oluşturulan hipotezin doğrulanması maksadıyla bu çalışma kapsamında; EOG işaretlerinin toplanması için bir ölçme sistemi tasarlanmış, toplanan EOG verileri ön işlemden geçirilmiş, ön-işlenmiş veriler için 10 farklı öznitelik çıkarımı gerçekleştirilmiş, tüm özniteliklere GKO uygulanarak en uygun öznitelikler belirlenmiş, belirlenen en uygun öznitelikler ile MATLAB platformunda oluşturulan yapay sinir ağı (YSA) modeli eğitilmiş, oluşturulan modelin sınıflandırma başarımı yine MATLAB platformunda geliştirilen bir sanal klavye ile test edilmiştir.

Tez altı bölümden oluşmaktadır. Giriş bölümünün ardından ikinci bölümde literatür araştırması ve kavramsal temeller ele alınmıştır. Üçüncü bölümde GKO algoritması incelenmiştir. Dördüncü bölümde EOG tabanlı sanal klavye sistemini oluşturan donanımsal ve yazılımsal bileşenlerin tasarım ilkelerine yer verilmiştir. Beşinci bölümde deneysel çalışmalar, son bölüm olan altıncı bölümde ise sonuçlar irdelenmiştir.

2. LİTERATÜR TARAMASI ve KURAMSAL TEMELLER

Elektrookülografi (EOG), göz hareketlerini analiz etmek için kullanılan bir fizyolojik ölçüm yöntemidir. Bu yöntem ile gözün retinasındaki elektriksel aktiviteyi ölçerek göz hareketlerini incelemek amaçlanır. EOG, gözlerin istemsiz titremesi (nistagmus) gibi göz hareket bozukluklarının tanısında, göz hareketlerinin normalden sapması veya anormal aktivitelerin belirlenmesi gibi nörolojik ve oftalmolojik muayenelerde hekime kolaylık sağlayan bir ölçüm yöntemidir (Gulyás, 2016).

EOG sinyalleri klinik tanılama yanı sıra uyku arařtırmaları, İMA, İBA, davranıř arařtırmaları, nörobilim, görsel protez, sürücü yorgunluk takibi gibi arařtırmalarda da kullanılmaktadır (Belkhiria & Peysakhovich, 2021; Huang vd., 2019; Murugan vd., 2023; Pratomo vd., 2020; Rezaei vd., 2017; Tao vd., 2023; Usakli & Gurkan, 2010).

Göz hareketlerine dayanan İBA ve sanal klavye uygulamalarına iliřkin literatüre giren bazı önemli çalıřmalar Tablo 1.1’de verilmiřtir.

Uřaklı ve Gürkan; 5 Ag/AgCl elektrodu kullanarak 20 katılımcıdan 5 farklı komut için topladıkları EOG verilerinin paternleri ile kNN sınıflandırması gerçekteřirmişler, tasarladıkları sanal klavye için %95,00 sınıflandırma başarıımı elde etmişlerdir (Usakli & Gurkan, 2010). Çalıřma grubu bu çalıřmalarında “WATER” kelimesini 24,5 saniyede yazdıklarını bildirmişlerdir.

Tangsuksant ve arkadaşları AD623 tabanlı bir enstrümantasyon yükseltici ile 10 bireyden 5 farklı göz hareketi için EOG sinyallerini toplamışlar, genlik eřik seviyelerini öznitelik olarak kullanan sınıflandırma için mikrodenetleyici tabanlı bir sistem geliřtirmişler, sonuçta dakikada 2,37 kelime yazmışlar ve %95,2 sınıflandırma başarıımı elde etmişlerdir (Tangsuksant vd., 2012).

Tablo 2.1: Göz Hareketlerine Dayanan İBA ve Sanal Klavye Uygulamalarına İlişkin Literatüre Giren Bazı Önemli Çalışmalar.

Çalışma	Sınıflandırma Metodu	Kullanılan Öznitelik	Katılımcı Sayısı	Yazım Hızı [k/d]	Komut Sayısı	Başarım [%]
(Usakli & Gurkan, 2010)	kNN	Patern	20	2,5	5	95,00
(Tangsuksant vd., 2012)	Eşik Algılama	Genlik Eşiği	10	2,37	5	95,20
(Ülkütaş, 2015)	Eşik Algılama	Genlik Eşiği	10	17,5	4	92,50
(Chang vd., 2017)	DPW, DTW, SVM	Wavelet Eşiği	21	X	X	95,93
(Usakli vd., 2018)	Eşik Algılama	Genlik Eşiği	2	X	10	100,00
(C. Zhang vd., 2018)	CNN	Patern	30	20	9	99,80
(Hou & Smitha, 2018)	Eşik Algılama	Genlik Eşiği	8	6,48	10	89,00
(Bastos vd., 2018)	Eşik Algılama	Genlik Eşiği	5	0,99	3	90,00
(Fang & Shinozaki, 2018)	DNN	Patern	6	X	9	95,00
(Findling vd., 2019a)	kNN, LDA, CT, SVM	Genlik Eşiği	15	X	9	88,30
(J. Zhang vd., 2019)	Eşik Algılama	Genlik Eşiği	6	X	3	94,23
(Ding & Lv, 2020)	DTW	Patern	12	3,36	7	94,52
(He vd., 2020)	SVM	Fark Fonksiyonu	10	2,99	5	99,33
(Saravanakumar & Reddy, 2020)	Eşik Algılama	Genlik Eşiği	10	X	5	94,16
(Ekim vd., 2021)	DTW	Moment	25	X	1	99,20
(Ramakrishnan vd., 2022)	FFNN	Periodogram	10	X	4	98,12
(Hossieny vd., 2023)	CNN	Patern	50	X	6	96,40
CNN : Convolutional Neural Network kNN : k-Nearest Neighbour DTW : Dynamic Time Warping FFNN : Feed Forward Neural Network SVM : Support Vector Machine			LDA : Linear Discriminant Analysis CT : Classification Tree DNN : Deep Neural Network DPW : Dynamic Positional Warping			

Ülkütaş; 6 elektrotlu ve 2 kanallı bir EOG veri toplama sistemi tasarlayarak üretmiş, toplanan verileri bilgisayara aktarmış, göz hareketlerine bağlı oluşan sinyallerin genlik eşik seviyelerini öznitelik olarak kullanmış, statik eşik seviyesi sınıflandırma yönteminin yürütülmesi için MATLAB ortamında bir kod geliştirmiş, Türkçe ile İngilizce dil desteği bulunan bir sanal klavye grafik arayüzü tasarlamıştır. Çalışmanın sonucunda dakikada 17,5 kelime yazım hızına ve %92,5'lik bir sınıflandırma başarımına ulaşıldığı bildirilmiştir (Ülkütaş, 2015) .

Chang ve arkadaşları çalışmalarında 18 sağlıklı, 3 ALS hastası bireyden EOG verilerini toplamışlar, Wavelet eşik değerini öznitelik olarak kullanmışlar, Arap harflerinin tanınması için önerdikleri DTW, DPW, SVM sınıflandırma algoritmalarının sınıflandırma performanslarını incelemişler, sonuç olarak ortalama %95,93 sınıflandırma başarımına ulaşmışlardır (Chang vd., 2017).

Uşaklı ve arkadaşlarının 2 ALS hastası ile yapılan deneysel çalışmaları kapsamında; EOG tabanlı kablosuz bir veri yakalama sistemi geliştirilmiş, göz hareketlerine ait genlik eşik seviyeleri öznitelik olarak kullanılmış, sınıflandırmada statik eşik seviyesi yöntemi tercih edilmiş, sistemde tanımlı 10 farklı komut için %100 sınıflandırma başarımı elde edilmiştir (Usakli vd., 2018).

Zhang ve arkadaşlarının çalışmalarında webcam, dijital kamera ve telefon kullanarak 30 kişiden 9 farklı göz hareketi için elde edilen görüntüler için paternler öznitelik olarak kullanılmış, sınıflandırıcı olarak CNN tercih edilmiş, önerilen sistemde dakikada 20 kelime yazma hızına ve %99,8 sınıflandırma başarımına ulaşıldığı bildirilmiştir (C. Zhang vd., 2018).

Hou ve Smitha'nın çalışmalarında 8 sağlıklı bireyden 5 Ag/AgCl elektrot ile 10 farklı göz hareketine ait EOG sinyalleri toplanmış, sinyallerin genlik eşik seviyelerini öznitelik olarak kullanan sınıflandırıcıyı tercih etmişlerdir. Geliştirdikleri sanal klavye için dakikada 6,48 yazım hızı ve ortalama %89,00 sınıflandırma başarımı elde etmişlerdir (Hou & Smitha, 2018).

Bastos ve arkadaşları çalışmalarında 5 sağlıklı bireyden 3 Ag/AgCl elektrot ile 3 farklı göz hareketine ait EOG sinyalleri toplanmış, sinyallerin genlik eşik seviyelerini öznitelik olarak kullanan sınıflandırıcıyı tercih etmişlerdir. Geliştirdikleri sanal klavye arayüzü için dakikada ortalama 0,99 yazım hızı ve %90,00 sınıflandırma başarımı elde etmişlerdir (Bastos vd., 2018).

Fang ve Shinozaki çalışmalarında 6 bireyden 6 Ag/AgCl elektrot ile 9 farklı göz hareketine ait EOG sinyallerini toplamışlar, sinyallerin paternlerini öznitelik olarak kullanmışlar, DNN sınıflandırma algoritmasını tercih etmişlerdir. Geliştirdikleri Japonca Katakana alfabesine ait sanal klavyede dakikada 27,9 karakter giriş hızına ve %95 sınıflandırma başarımına ulaşmışlardır (Fang & Shinozaki, 2018).

Findling ve arkadaşları “JINS MEME” adı verilen ve 3 adet burun pediyle EOG sinyallerinin algılanabildiği bir gözlük kullanarak göz hareketlerini algılamışlar, algılanan sinyallerin genlik eşik seviyelerini öznitelik olarak kullanmışlar, farklı sınıflandırma algoritmaları için (kNN, LDA, CT, SVM) sınıflandırma başarımlarını incelemişlerdir (Findling vd., 2019a). Önerilen yöntemin sanal klavye uygulamalarında kullanılabileceği ve farklı göz hareketlerinin algılanmasında %88,3'e kadar sınıflandırma başarımı elde edebildiklerini bildirmişlerdir.

Zhang ve arkadaşlarının EEG/EOG/EMG'nin kullanıldığı beyin bilgisayar arabirimi (BBA) çalışmaları kapsamında geliştirdikleri robot kolun bazı fonksiyolarını EOG ile yerine getirmişlerdir (J. Zhang vd., 2019). 6 sağlıklı bireyden alınan kayıtlar ile gerçekleştirilen çalışmada, sinyallerin genlik eşik seviyelerini öznitelik olarak kullanan sınıflandırıcıyı tercih etmişler ve EOG komutlarının sınıflandırılmasında %94,23 sınıflandırma başarımı elde ettiklerini bildirmişlerdir.

Ding ve Lv çalışmalarında EsCew sistemini kullanarak 12 bireyden göz kırpma sinyallerini toplamışlar, sinyallerin paternlerini DTW algoritması ile sınıflandırmışlar, Çin alfabesinde kullanılan bazı harfler için bir sanal klavye oluşturmuşlardır. Dakikada 3,36 kelime yazım hızına ulaştıklarını ve ortalama %94,52 sınıflandırma başarımına ulaştıklarını bildirmişlerdir (Ding & Lv, 2020).

He ve arkadaşları NuAmps aygıtı kullanarak 10 bireyden 5 farklı göz hareketi için EOG sinyallerini toplamışlar, öznitelik olarak 1. dereceden fark fonksiyonunu öznitelik olarak kullanmışlar, sınıflandırıcı olarak ise SVM tercih etmişlerdir (He vd., 2020). Çalışmanın sonucunda geliştirilen sanal klavye ile dakikada 2,99 kelimeye kadar yazım hızı ve ortalama %99,33'e kadar sınıflandırma başarımı elde edilmiştir.

Saravanakumar ve Reddy geliştirdikleri çalışmalarında Bio-Daq V01 sistemini kullanarak 4 adet Ag/AgCl elektrot ile 10 bireyden EOG sinyallerini toplamışlar, sinyallerin genlik eşik seviyelerini öznitelik olarak kullanan sınıflandırıcıyı tercih

etmişlerdir. Geliştirdikleri sanal klavye için komutların sınıflandırılmasında ortalama %94,16 başarımla elde ettiklerini bildirmişlerdir (Saravanakumar & Reddy, 2020).

Ekim ve arkadaşları NeuroSky MindWave Mobile aygıtını kullanarak 25 sağlıklı bireyden göz kırpmaya sinyallerini toplamışlar, bu sinyallerin momentlerini öznitelik olarak kullanmışlar, sınıflandırıcı olarak DTW yöntemini tercih etmişlerdir. Sonuç olarak “TEA” kelimesini 17 saniyede yazarak %99,2 sınıflandırma başarımla elde ettiklerini bildirmişlerdir (Ekim vd., 2021).

Ramakrishnan ve arkadaşlarının çalışmalarında ADT26 biyoyükselteç tabanlı bir sistem ile 10 bireyden 4 farklı göz hareketi için EOG verilerini toplamışlar, verilerin periodogram özniteliklerini kullanmışlar, sanal klavyelerde kullanılacak bir FFNN sınıflandırma algoritmasını önermişlerdir (Ramakrishnan vd., 2022). Ramakrishnan ve arkadaşları tarafından önerilen bu çalışmada %98,12’ye kadar sınıflandırma başarımları elde edilmiştir.

Hossieny ve arkadaşları çalışmalarında PSL-iEOG2 ile PSL-DAQ donanımlarını kullanarak 50 sağlıklı bireyden EOG verilerini toplamışlar, 6 farklı göz hareketi için sinyallerin paternlerini kullanmışlar, CNN sınıflandırıcıyı tercih ederek geliştirdikleri sanal klavye için performans testleri gerçekleştirmişlerdir (Hossieny vd., 2023). Çalışmanın sonucunda ortalama %96,4 sınıflandırma başarımla ulaştıklarını bildirmişlerdir.

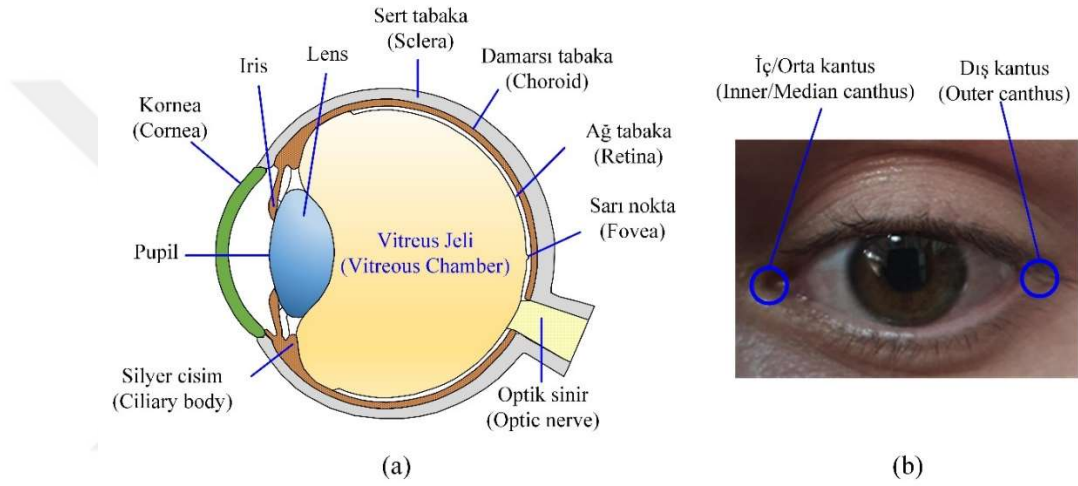
Göz hareketlerine dayanan bir kontrol sistemi genellikle dört başlıkta incelenebilir: veri yakalama, sinyal gürültüsü giderme ile öznitelik elde etmeyi de içeren ön işleme, sınıflandırma ve karar verme (López vd., 2023). Literatür taraması neticesinde; göz hareketlerine dayanan kontrol sistemleri ve sanal klavye uygulamalarını oluşturan birimlere ait vurgulanmasında fayda görülen temel kavramlar aşağıda ele alınmıştır.

2.1. Elektrookülogram

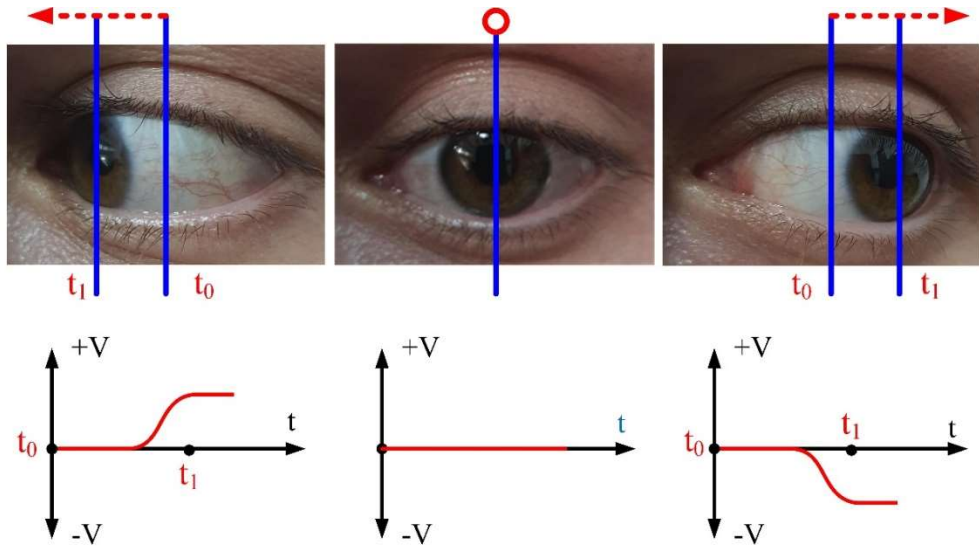
İnsan gözünde, lens sisteminin ışığı üzerine odakladığı alıcı (reseptör) katmanı bulunur. Alıcıların üzerlerine ışık düştüğünde; sinir sistemi vasıtasıyla alınan sinyal beyindeki görsel bölgeye (visual cortex) iletilir. Göz yuvarı, göz çukurundaki toplamda 6 kasın etkisi ile hareket eder. Bu hareketler; hızlı ve kısa hareketler (saccadic), yumuşak hareketler, baş hareketi ile gerçekleşen (vestibular) ve yakına odaklanma ile meydana gelen yakınsama hareketleridir. EOG, göz hareketlerinin

algılanmasına yönelik bir yöntemdir ve kornea ile retina arasında hiperpolarizasyon-depolarizasyonlardan kaynaklanan potansiyelin kaydedilmesine dayanır (Banerjee vd., 2013; Barea vd., 2002). Şekil 2.1’de insan gözüne ait bazı görüntüler verilmiştir.

Göz; ön kutbu pozitif, arka kutbu negatif polariteli bir dipol görevi görür. Sola bakışta kornea sol gözün dış kantusunun yakınına bağlı elektroda yaklaşır ve kaydedilen potansiyel farkta negatif eğilimli bir değişime neden olur. Sağa bakışta ise kornea sol gözün iç kantusunun yakınındaki algılayıcıya yaklaşır ve kaydedilen potansiyel farkta pozitif yönde bir değişime neden olur. Gözün sağa ve sola bakışı esnasında elde edilen potansiyel farkın değişimi Şekil 2.2’de verilmiştir.



Şekil 2.1: İnsan Gözüne Ait Görüntüler (a) Dikey Kesit (b) Karşıdan Görünüm.




Şekil 2.2: EOG Sinyalinin Gözün Yatay Hareketleri ile Değişimi ve Oküler Dipol Model.

Kaynaklarda farklılıklar olmasına karşın, gözün hareketleri ile yaklaşık 0-100 Hz frekans aralığında ve genliği 50~3500 μ V aralığında değişim gösteren sinyaller elde etmek mümkündür (Barea vd., 2002). Gözün 1°'lik hareketi ile yatay ve dikey eksenlerde 7 μ V gerilim değişimi meydana gelir (López vd., 2023; Ohya & Kawasumi, 2005; Öner, 2019).

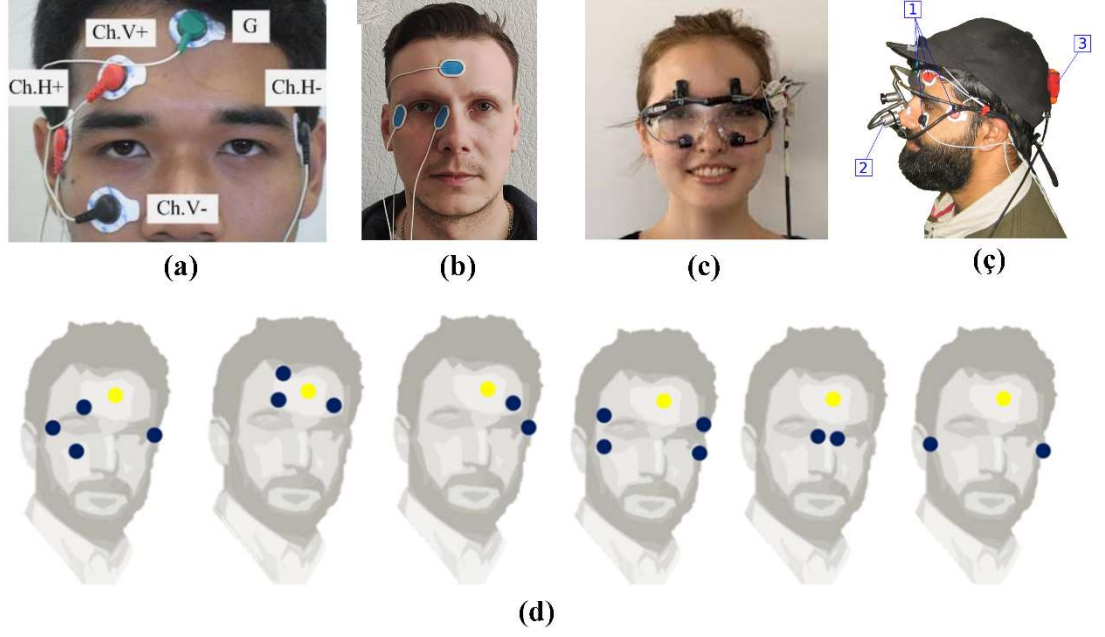
2.2. EOG Elektrotları

Biyosinyal ölçümlerinde, sinyalin kaynağından uygun şekilde alınması aşamasında elektrot seçimi önem kazanır. Biyosinyal ölçümlerinde en sık karşılaşılan elektrot tiplerini; Ag/AgCl, altın, polimer, metal, karbon, iğne elektrotlar şeklinde sıralamak mümkündür. Literatür incelendiğinde EOG sinyallerinin ölçümü için en yaygın kullanılan elektrot tipinin Ag/AgCl elektrotlar olduğu görülmüştür (Hou & Smitha, 2018; Ülkütaş, 2015; Usaklı vd., 2018). EOG ölçümlerinde kullanılan bazı Ag/AgCl elektrotların görüntüleri Şekil 2.3'te verilmiştir. Bu elektrotlar EOG veri kayıtları için özel olarak üretilmiş olmayıp, aslında EEG ve EKG kayıtlarında kullanılan elektrotlardır.



Şekil 2.3: EOG Sinyallerinin Ölçümünde Kullanılan Ag/AgCl Elektrotlara Ait Görüntüler.

Ag/AgCl elektrotlarının insan yüzünde farklı şekillerde yerleştirilmesiyle EOG kayıtları alınabilir. Şekil 2.4'te, literatürdeki farklı çalışmalarda Ag/AgCl elektrotlarının insan yüzüne ve giyilebilir teknolojilere yerleşimleri görülmektedir. Şekil 2.4 incelendiğinde genellikle bir adet referans elektrodu kullanıldığı, ölçülmek istenen her eksen (yatay ya da düşey) için bir çift elektrot kullanılması gerektiği ortaya çıkmaktadır.



Şekil 2.4: Ag/AgCl Elektrotlarının İnsan Yüzüne Yerleşimine Ait Örnek Görüntüler.

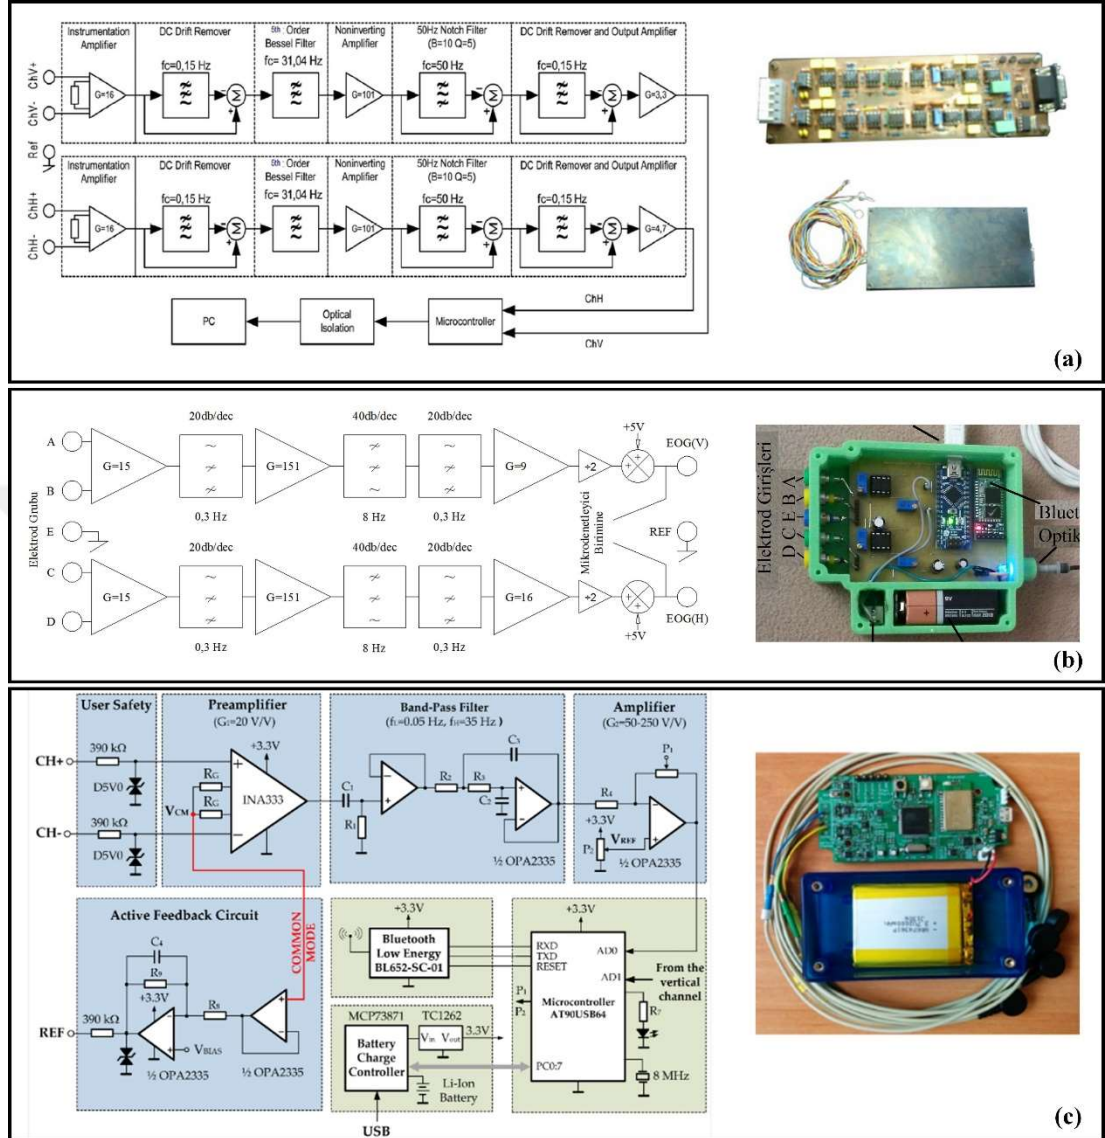
(Aungsakun vd., 2011; Belkhiria & Peysakhovich, 2020; Bulling vd., 2009; Pleshkov vd., 2022; Vidal vd., 2011).

2.3. EOG Veri Yakalama

Farklı kaynaklardan elde edilen veriler ışığında, EOG sinyallerinin 0-100 Hz frekans aralığında ve genliği 50~3500 μ V aralığında değişim gösteren sinyaller olduğundan yukarıda bahsedilmişti. Bu sinyallerin kaynağından alınarak karar verme sürecine doğru şekilde aktarılması için bir veri yakalama sistemine ihtiyaç duyulmaktadır. Literatürdeki EOG veri yakalama sistemleri incelendiğinde enstrümantasyon yükselteci, filtreler, seviye kaydırma devreleri, yükselteç gibi ünitelerden oluşan yaklaşımlar karşımıza çıkmaktadır. Bu yaklaşımlardan bazılarında ait blok şemalar ve sistem görünüşleri Şekil 2.5'te verilmiştir.

Şekil 2.5'te verilen örneklerin tamamında yüzün farklı noktalarına yerleştirilen Ag/AgCl elektrotlar ile EOG sinyalleri algılanmış ve sistemin girişinde bulunan enstrümantasyon yükseltecine uygulanmıştır. Belirli bir genlik seviyesine ulaşan bu noktadaki sinyal, gürültüler içermektedir. Devamındaki aşamalarda, içerisinde EOG sinyalini de barındıran gürültülü sinyal filtreleme işlemine tabi tutulur. Ardından tekrar yükseltilecek sinyale DC seviye kaydırma, 50 Hz çentik filtreleme, alçak geçiren filtreleme gibi işlemler uygulanır ve nihayetinde analogtan sayısala çevirme işlemi

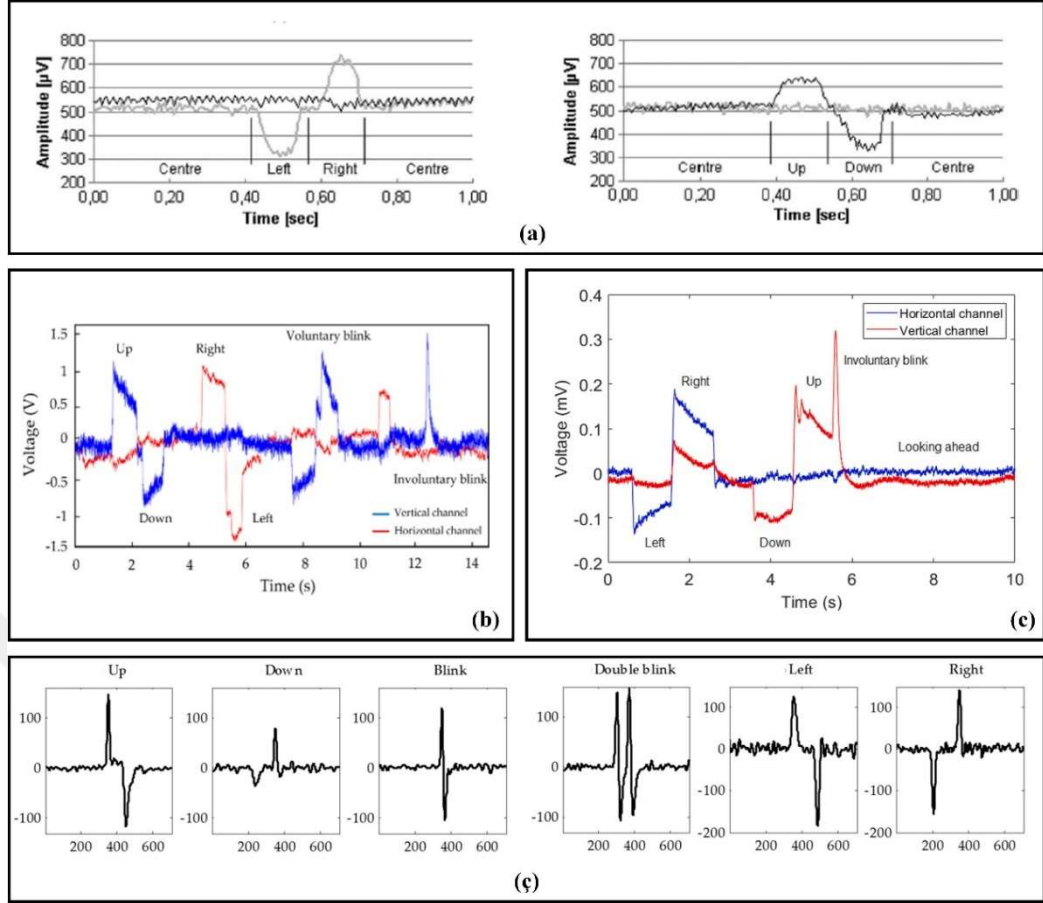
gerçekleştirilir. Elde edilen sayısal işaret İBA ve İMA gibi uygulamalarda kullanılabilir.



Şekil 2.5: EOG Veri Yakalama Sistemlerine Örnekler (a) Örnek 1 (b) Örnek 2 (c) Örnek 3.

(Gürkan vd., 2016; López vd., 2020; Usakli & Gurkan, 2010).

Farklı EOG veri yakalama sistemlerinden elde edilen analog sinyal kayıtlarına ilişkin bazı örnekler Şekil 2.6'da verilmiştir.



Şekil 2.6: EOG Kayıtları (a) Örnek 1 (b) Örnek 2 (c) Örnek 3 (ç) Örnek 4.

(Heo vd., 2017; López vd., 2020, 2023; Usakli & Gurkan, 2010).

2.4. Öznitelik Çıkarma

Sınıflandırma ve karar verme süreçlerinin önemli bileşenlerinden birisi de öznitelik çıkarmadır. Elde edilen analog ya da sayısal EOG verilerinin bir bütün halinde değerlendirilmesi ve sınıflandırılması oldukça zordur. Bu yüzden belirli bir boyuttaki EOG verisinin tek bir nicelik ile temsil edilmesi yani öznitelğe indirgenmesi sınıflandırma başarımını arttıracaktır.

Veri bilimi ve makine öğrenmesi gibi süreçlerde önemli bir yeri olan öznitelik çıkarma işlemi sahip olduğumuz ham verilerden değişken (öznitelik) üretmektir. Öznitelik üretme kavramı iki başlıkta incelenebilir. Yapısal veri kümesinden öznitelik üretmek; formal yapıdaki verilerden öznitelik üretmeyi kapsar. Yapısal olmayan verilerden öznitelik üretmek ise ses ve görüntü gibi düzgün değişmeyen veri kümelerinden öznitelik üretmeyi kapsar. Bu bilgiler ışığında EOG sinyaline ait veri kümesinden öznitelik üretmek yapısal olmayan bir öznitelik üretme işlemi olarak nitelendirilebilir.

Makine öğrenmesi algoritmaları eğitim kümesine tanımlanan öznitelik verilerini öğrenebilir ve eğitim kümesine dâhil edilmeyen veriler için tahminlerde bulunabilir. Doğrudan ham veri ile eğitmek yerine öznitelikler ile yapılan eğitim işlemi sınıflandırma hızını arttırıcı bir faktördür.

EOG kayıtlarına ait ham veriler patern olarak ele alınıp makine öğrenmesi aşamalarında eğitim kümesine doğrudan dâhil edilebildiği gibi, aritmetik ortalama, standart sapma, geometrik ortalama, medyan, moment, maksimum değer, minimum değer, varyans, eşik değeri, basıklık, çarpıklık vb. gibi istatistiksel hesaplamalar sonucunda ortaya çıkan öznitelikler de eğitim aşamasında tercih edilmektedir (Ding & Lv, 2020; Ekim vd., 2021; Findling vd., 2019b; Hossieny vd., 2023; Saravanakumar & Ramasubba Reddy, 2020) .

2.5. Metasezgisel Optimizasyon Algoritmaları

Metasezgisel optimizasyon teknikleri son otuz yılda popülerlik kazanmıştır. Bu tekniklerden bazıları sadece bilgisayar bilimleri alanında değil diğer uygulamalı bilimlerde de kullanım alanı bulmaktadır. Teorik çalışmaların yanında uygulamalı bilimlerde de iyi sonuçlar vermesi nedeniyle metasezgisel optimizasyon teknikleri tercih edilmektedir.

Metasezgisel optimizasyon teknikleri çoğunlukla fiziksel olaylardan ya da hayvan davranışlarından ilham alırlar ve teorik açıdan çoğunlukla gayet basite indirgenebilirler. Bu basitlik, araştırmacıların problemleri daha hızlı şekilde modelleyebilmesine, metasezgisel algoritmaların hibrit kullanımına ve geliştirilen modelin diğer araştırmacılar tarafından kolay anlaşılmasına olanak tanır (Mirjalili vd., 2014) .

Metasezgisel optimizasyon algoritmaları sahip oldukları esneklik sayesinde herhangi bir alana uygulanan teknik, çok fazla değişikliğe veya uyarlamaya gerek olmadan başka alanlara da uygulanabilir.

Metasezgisel optimizasyon algoritmalarında optimuma ulaşmak için arama uzaylarının türevlerini hesaplamaya gerek yoktur. Bu özelliği metasezgisel optimizasyon algoritmalarını, zaman maliyeti açısından türevselliğe dayanan optimizasyon yöntemlerine göre daha avantajlı hâle getirir (Mirjalili vd., 2014).

Doğada karşılaşılan problemlerin arama uzayı rastlantısaldır ve çok sayıda değişken nedeniyle çok karmaşıktır. Bu problemlere stokastik teknikler ile çözüm aramak doğrusal optimizasyon tekniklerine göre daha kullanışlıdır. Metasezgisel optimizasyon teknikleri stokastik doğası sayesinde, belirlenen sınırlar içerisinde arama uzayının belirlenen sınırlar içerisinde kapsamlı şekilde aranmasına olanak tanır ve doğrusal olmayan problemlerin optimizasyonunda avantajlar sağlar.

“Bedava Yemek Yok” teoremi; tüm problemlerin çözümü için en uygun olarak tanımlanabilecek bir metasezgisel tekniğin olmadığını, bir problem için çok iyi sonuçlar verebilen tekniğin başka problemde beklenen sonuçları vermeyebileceğini açıklamaktadır (Wolpert & Macready, 1997). Bu bilgi, mevcut yaklaşımların geliştirilmesi ve yeni metasezgisel optimizasyon tekniklerinin hâlen öneriliyor olmasının nedenini açıklamaktadır.

Metasezgisel optimizasyon teknikleri çözüm tabanlı ve popülasyon tabanlı olmak üzere iki başlık altında incelenebilir. Tek çözüm tabanlı tekniklerde arama süreci bir aday çözüm ile başlatılır ve bu çözüm yinelemeler ile en iyi sonuç elde edilinceye kadar yinelenir. Popülasyon tabanlı optimizasyon tekniklerinde ise çözüm için bir başlangıç dizisi tanımlanır ve bu rasgele başlangıç popülasyonu yinelenerek en iyi çözüme ulaşmak hedeflenir.

Popülasyon tabanlı metasezgisel optimizasyon tekniklerinin, tek çözüm tabanlı metasezgisel optimizasyon tekniklerine göre avantajları şu şekilde sıralanabilir: birden fazla aday çözüm sayesinde arama alanı hakkında bilgi paylaşımı gerçekleşir ve bu sayede alanın çözüme yakın kısmına ani sıçramalar meydana gelir, birden fazla aday çözüm sayesinde hatalara sebep olacak yerel en iyi sonuçlardan kaçınılır.

Popülasyon tabanlı metasezgiseller için 1993 yılında önerilen “Sürü Zekâsı (SZ)” önemli bir yer tutar. Bonebeau ve arkadaşları çalışmalarında SZ’yi “Basit ajanlardan oluşan grupların ortak zekâsı” olarak tanımlamıştır ve doğal koloniler ile sürülerden ilham aldıklarını bildirmişlerdir (Wolpert & Macready, 1997).

SZ algoritmalarının, evrimsel algoritmalara (EA) göre bazı avantajları şu şekilde sıralanabilir:

- SZ algoritmaları genellikle o ana kadar elde edilen en iyi çözümü kaydetmek için hafızayı kullanır. SZ algoritmalarında işlem yürütmek için daha az parametreye ihtiyaç duyulur.

- SZ algoritmaları daha az operatöre sahiptir. SZ algoritmalarının uygulanması daha kolaydır.

Literatürde karşılaşılan ve optimizasyon problemlerinin çözümünde sık tercih edilen bazı SZ algoritmaları Tablo 2.2’de verilmiştir.


Tablo 2.2: Sürü Zekâsından Esinlenen Başlıca Optimizasyon Algoritmaları.

Sıra No	Algoritmanın Adı	Örnek Uygulama Alanı
1	Karınca Kolonisi Optimizasyonu (Dorigo, 1992)	Lojistik (Eren Şenaras & İnanç, 2017)
2	Parçacık Sürü Optimizasyonu (Kennedy & Eberhart, 1995)	Emtia Piyasaları (Alagöz & Kutlu, 2012)
3	Balık Sürüsü Algoritması (X. Li vd., 2002)	Sensör Ağları (Zhou vd., 2021) Güç Sistemleri (Hua vd., 2021)
4	Bakteriyel Yemek Arama Algoritması (Passino, 2002)	Güç Elektroniği (Hernández-Ocaña vd., 2019)
5	Yapay Arı Kolonisi Algoritması (Basturk & Karaboga, 2006)	Sivil Havacılık (Çavuş & Tuncer, 2017)
6	İstilacı Ot Optimizasyonu (Mehrabian & Lucas, 2006)	Güç Sistemleri (Zheng vd., 2019)
7	Ateş Böceği Algoritması (Krishnanand & Ghose, 2009)	Lojistik (Marinaki & Marinakis, 2016)
8	Yerçekimsel Arama Algoritması (Rashedi vd., 2009)	Kaotik Haritalama (Özyön vd., 2020)
9	Yapay Bağışıklık Sistemi Algoritması (Timmis vd., 2010)	İmalat Teknolojileri (Pinto & Gonçalves, 2022)
10	Yarasa Algoritması (X.-S. S. Yang, 2010)	Lojistik (Srivastava & Sahana, 2019)
11	Meyve Sineği Optimizasyonu (Pan, 2012)	Rota Planlama (Shi vd., 2020)
12	Gri Kurt Optimizasyonu (Mirjalili vd., 2014)	Görüntü İşleme (Koc vd., 2018)
13	Güvercin Optimizasyonu (Duan & Qiao, 2014)	İnsansız Sistemler (Hao vd., 2015)
14	Salp Sürü Algoritması (Mirjalili vd., 2017)	Öznitelik Seçimi (Celal vd., 2021)
15	Benekli Sırtlan Algoritması (Dhiman & Kumar, 2017)	Metin Sınıflandırma (Maragheh vd., 2022)
16	Kel Kartal Arama Optimizasyonu (Alsattar vd., 2020)	Enerji Yönetimi (Youssef vd., 2023)
17	Ton Balığı Sürüsü Algoritması (Xie vd., 2021)	Hata Ayıklama (Tuerxun vd., 2022)

Farklı uygulama alanları bulunan SZ algoritmaları sistemlerin parametrelerinin optimizasyonunda, sınıflandırma aşamalarında ve uygun özniteliklerin belirlenmesi safhalarında kullanılabilir.

3. GRİ KURT OPTİMİZASYONU ALGORİTMASI

Gri kurtlar (canis lupus); Canidae ailesine ait olan, besin zincirinin en üstünde olması sebebiyle yırtıcı olarak kabul edilen ve genellikle 5~12 bireylik sürüler halinde dolaşmayı tercih eden canlılardır ve Şekil 3.1’de verilen hiyerarşiye sahiplerdir.



Şekil 3.1: Gri Kurt Hiyerarşisi.

Hiyerarşinin en tepesinde “*alfa*” denilen, bir erkek ve bir dişiden oluşan lider kurtlar bulunur. Alfa kurtlar avlanma, uyuma yeri belirleme, uyanma zamanı gibi konularda karar verirler ve bu kararlar sürüye dikte edilir. Alfa kurtlar sürünün en güçlü üyesi değil yönetimsel açıdan en yeteneklisidir. Bu bilgiden hareketle, bir sürünün organizasyonunun ve disiplininin gücünden daha önemli olduğu söylenebilir (Mirjalili vd., 2014).

Gri kurt hiyerarşisinin ikinci seviyesini “*beta*” kurtlar oluşturur. Beta kurtlar; alfa kurtlara karar verme ve diğer sürü faaliyetlerinde yardımcı olan ikincil kurtlardır. Beta kurtların cinsiyetine ilişkin bir belirleyicilik bulunmaz. Alfa kurtlardan birisinin ölmesi ya da yaşlanması durumunda beta kurtlar alfa adaydır. Hiyerarşi içerisinde betalar alfalara itaat etmek zorundayken, bir alt seviyedeki kurtlara da komuta etme sorumlulukları vardır. Beta, sürünün durumu hakkında sürekli veri toplayarak alfaya geribildirim sağlar ve komutlarını güçlendirir.

Hiyerarşinin üçüncü seviyesinde “*omega*” kurtlar bulunur. Omega kurtlar alfa ve beta kurtlara itaat etmek zorundadır. Sürü içerisinde beslenmelerine en son izin verilen kurtlardır. Omega kurtlar sürünün önemsizleri gibi görülmekte omeganın kaybedilmesi durumunda sürü iç kavgalarla ve anlaşmazlıklarla karşı karşıya kalabilir. Diğer taraftan omegalar sürünün yavru kurtlarının bakımından ve eğitiminden sorumludur.

Alfa, beta, omega sınıfına girmeyen tüm kurtlar “*delta*” olarak anılır. Delta kurtlar alfa ve beta kurtlara itaat etmek zorundadırlar. Ancak omega kurtlara komuta edebilirler. İzci, nöbetçi, yaşlı, avcı ve bakıcı kurtlar delta kurt olarak anılır. İzçiler, sürüye ait bölgenin sınırlarını izlemekle ve herhangi bir tehlike algılanması durumunda sürüyü ikaz etmekle yükümlüdürler. Nöbetçi kurtlar sürünün güvenliğini tesis eder ve garanti altına alır. Yaşlılar, öncesinde alfa ya da beta seviyesinde olan deneyimlerinden fayda sağlanan kurtlardır. Avcılar, av esnasında veya sürüye yiyecek sağlanırken alfa ve beta kurtlara yardım eder. Bakıcı kurtlar ise, sürüdeki hasta, zayıf ve yaralı durumdaki kurtların bakımından sorumludur.

Grup avcılığı gri kurtların sosyal davranışıdır. Bu davranışa ilişkin görsel Şekil 3.2’de verilmiştir. Gri kurtların avlanma aşamaları aşağıda verilmiştir (Muro vd., 2011):

- Avı takip etmek, kovalamak ve yaklaşmak,
- Avı durana kadar takip etmek, kuşatmak ve taciz etmek,
- Ava saldırmak.



Şekil 3.2: Gri Kurt Avlanma Davranışı (a) Takip, Kovalama, Yaklaşma (b-ç) Takip, Kuşatma, Taciz (d) Saldırı.

(Muro vd., 2011).

Gri kurtların sosyal hiyerarşisini ve avlanma davranışlarını esas alarak 2014 yılında Mirjalili ve arkadaşları tarafından “Gri Kurt Optimizasyonu” önerilmiştir. Bu

optimizasyon tekniđi problemlere yaklařımda sürü zekası prensiplerini kullanan matematiksel bir modeli içermektedir. Bu model avı takip etme, kuřatma ve saldırma gibi ařamaları ifade etmekte kullanılır.

GKO ile tasarımıda en iyi çözümler alfa (α), ikinci en iyi çözümler beta (β), üçüncü en iyi çözümler delta (δ) ve geri kalan tüm çözümler omega (ω) olarak adlandırılır. GKO algoritmasında avlanma stratejisi α , β , δ tarafından yönlendirilir. ω kurtları; α , β , δ kurtlarını takip eder.

3.1. Avın Çevrenmesi

Gri kurtların sosyal hiyerarřısı ve toplu avlanma davranıřları geređi tespit edilen avla doğrudan bir saldırı söz konusu deđildir. Yukarıda da bahsedildiđi gibi üç ařamalı bir avlanma stratejisi söz konusudur.

Bu kapsamda ilk ařama avın çevrenmesidir. t mevcut iterasyon, \vec{A} ve \vec{C} katsayı vektörleri, \vec{X}_p avın konum vektörü, \vec{X} bir gri kurdun konum vektörü olmak üzere avı çevrelemek için Denklem 3.1 ve Denklem 3.2 kullanılır.

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (3.1)$$

$$\vec{X}(t + 1) = \vec{X}(t) - \vec{A} \cdot \vec{D} \quad (3.2)$$

\vec{A} ve \vec{C} katsayı vektörleri Denklem 3.3 ve Denklem 3.4'te verildiđi gibi hesaplanır.

Bu denklemlerde \vec{a} , her iterasyonda 2'den 0'a doğru azalır. \vec{r}_1 ve \vec{r}_2 [0,1] aralıđında rastsal vektörlerdir.

$$\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a} \quad (3.3)$$

$$\vec{C} = 2 \cdot \vec{r}_2 \quad (3.4)$$

Burada \vec{a} , \vec{r}_1 , \vec{r}_2 vektörleri \vec{A} ve \vec{C} vektörlerinin deđerlerini deđiřtirerek kurtların arama uzayı içerisinde farklı noktalara ilerleyebilmelerine ve avla göre pozisyonlarını iyileřtirmelerine imkân tanır. Bu yapı sayesinde gri kurtlar üç boyutlu bir arama uzayında hareket ederler ve her yeni iterasyonda önceki iterasyonlara göre en iyi çözümler arayıřı devam eder.

3.2. Avlanma

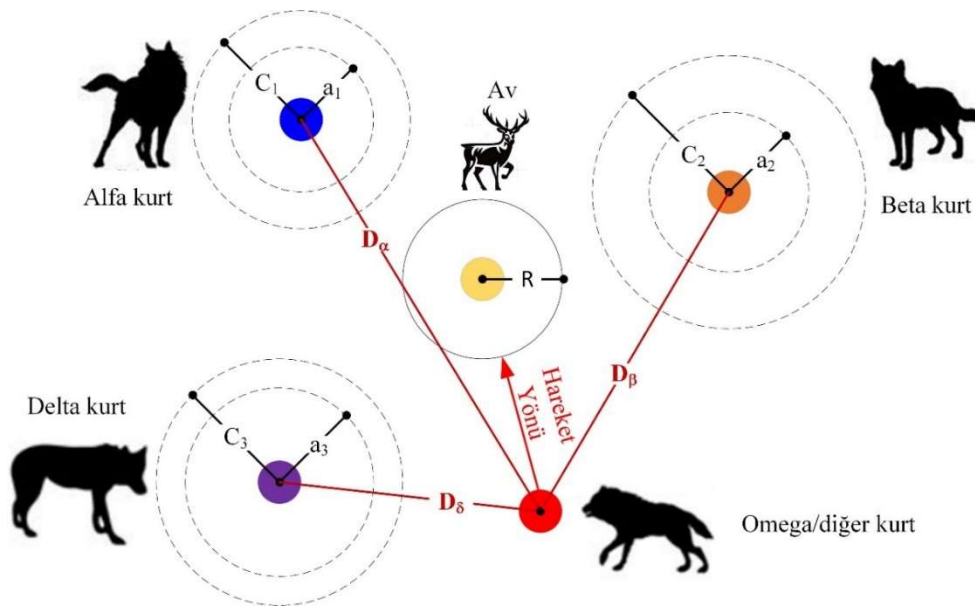
Gri kurt popülasyonları avlarının yerini tanıma ve kuşatma yeteneklerine sahiptirler. Avı yönlendiren baskın karakter çoğunlukla alfa kurtlardır. Beta ve delta kurtlar zaman zaman avlanmaya dâhil olabilir. Soyut bir arama uzayında konumun en iyi değeri hakkında bir bilgi sahibi olunması söz konusu değildir. Gri kurtların avlanma davranışlarının matematiksel modelinde alfa, beta ve delta kurtlar avın olası konumu hakkında daha iyi bilgiye sahiptir. Bu sebepten her iterasyonda hesaplanan çözümlerin en iyi değerdeki ilk üçü sonraki iterasyonlara çözüm olarak güncellenir. Bunun için Denklem 3.5, Denklem 3.6 ve Denklem 3.7 kullanılır (Karakaş, 2020; Mirjalili vd., 2014) . Bu denklemlerde \vec{D}_α , \vec{D}_β , \vec{D}_δ alfa, beta, delta kurtların ava olan mesafe vektörleri, \vec{X}_α , \vec{X}_β , \vec{X}_δ alfa, beta, delta kurtlarına göre avın konum vektörleri, \vec{X} t numaralı iterasyon anındaki gri kurt konum vektörü, \vec{X}_1 , \vec{X}_2 , \vec{X}_3 alfa, beta, delta kurtlar için deneme vektörleridir.

$$\vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}| \quad (3.5)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1 \cdot (\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_2 \cdot (\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3 \cdot (\vec{D}_\delta) \quad (3.6)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (3.7)$$

Şekil 3.3 gri kurtların iki boyutlu arama uzayındaki konumlarını nasıl güncellediklerini göstermektedir.



Şekil 3.3: Gri Kurtların Avlanma Stratejisi.

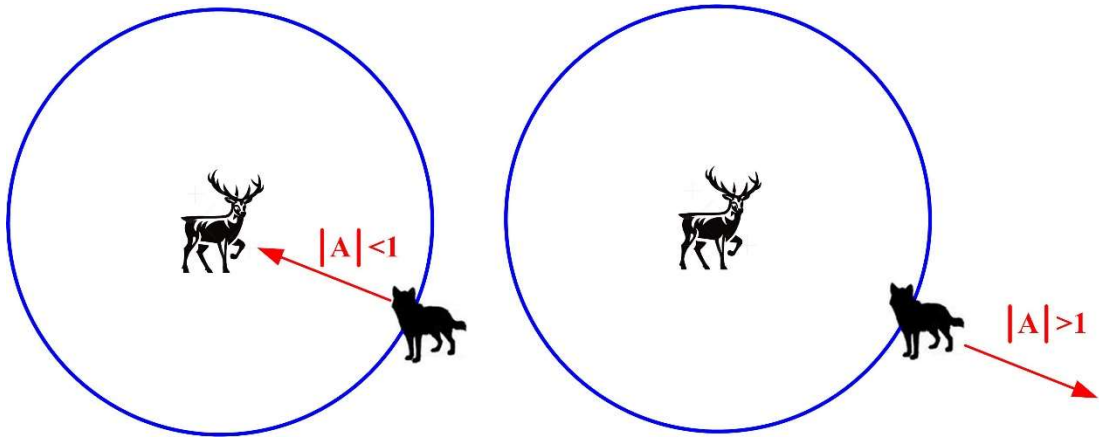
Şekil 3.3'te nihai konum arama uzayındaki alfa, beta ve delta konumları ile tanımlanan bir daire içerisinde rastsal bir yerde olacağı görülmektedir. Yani alfa, beta ve delta avın konumunu tahmin eder ve diğer kurtlar avın etrafındaki konumlarını rastsal güncellerler.

3.3. Ava Saldırı

Gri kurtlar avın hareket etmeyi bırakması ile birlikte ava saldırırlar ve avı sonlandırırılar. Matematiksel modelde \vec{a} 'nın her iterasyonda azaltılması ve daha dar bir aralıkta değişime zorlanması ava yaklaşmayı ifade eder. \vec{A} 'nın $[-1,1]$ aralığında rastsal değerler alması arama ajanının bir iterasyon sonrasındaki konumunun, mevcut iterasyondaki konumu ile avın mevcut konumu arasında rastsal bir konumda olmasına neden olur. $|\vec{A}|$ 'nın değeri saldırı yapılıp yapılmayacağını belirler. $|\vec{A}| < 1$ şartı sağlandığında kurtlar ava saldırmaya zorlanır.

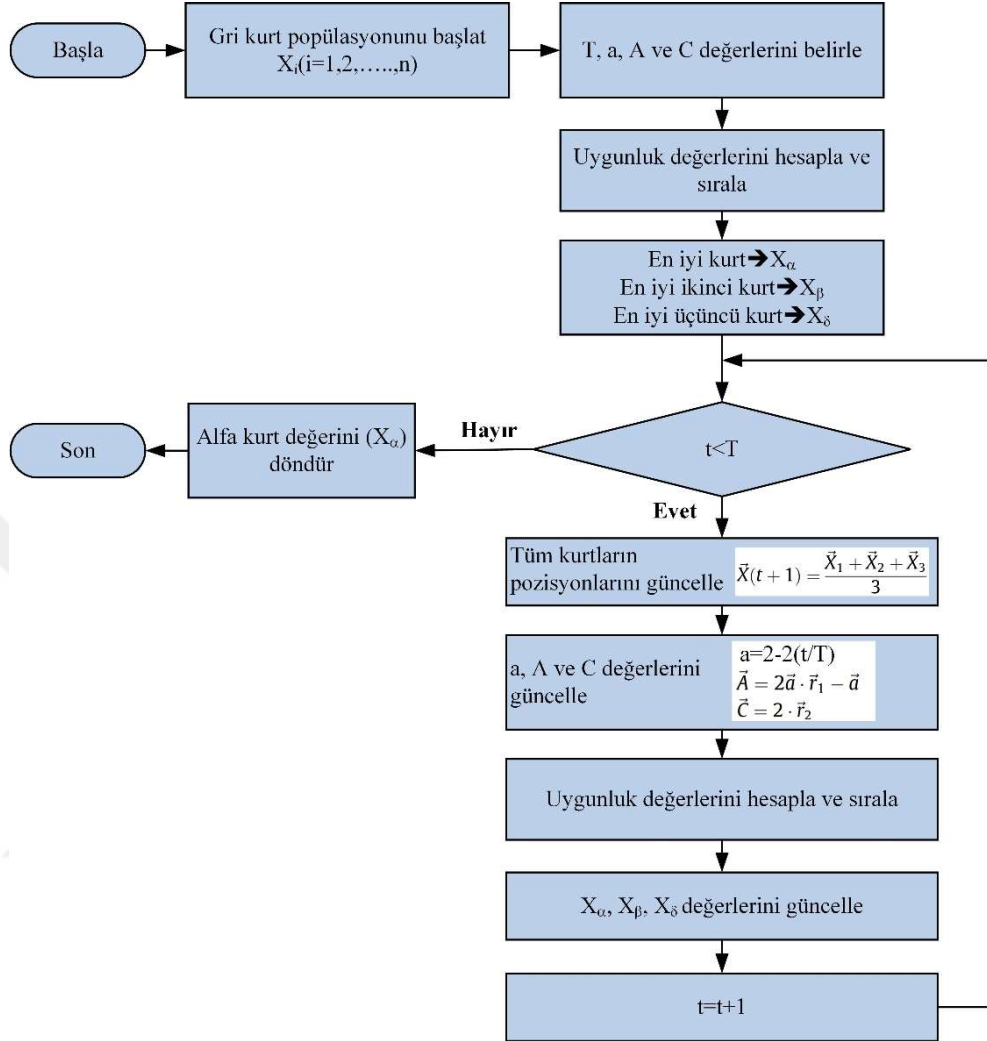
3.4. Av Arama

Gri kurtlar çoğunlukla alfa, beta, delta kurtların pozisyonlarını değerlendirerek arama gerçekleştirirler. Avlarını aramak ve saldırmak için ilk fırsatta bir araya gelmek şartıyla birbirlerinden uzaklaşırlar. Matematiksel modeldeki \vec{A} , arama sürecinde gri kurtların hareket tarzının ne olacağını belirler. $|\vec{A}| > 1$ şartı sağlanıyorsa gri kurtlar daha iyi avlar bulma amacıyla avdan uzaklaşırlar. Bu durumu açıklayan görsel Şekil 3.4'te verilmiştir.



Şekil 3.4: Av Arama ve Saldırma Kriteri.

Gri kurtların avlanma aşamalarını yazılımsal olarak gerçekleyen bir akış şeması Şekil 3.5'te verilmiştir.



Şekil 3.5: GKO Algoritmasının Akış Şeması.

GKO; kontrol sistemlerinin tasarımı ve ayarlanmasında (B. Yang vd., 2017), planlama uygulamalarında (Lu vd., 2016), robotik sistemlerde rota planlamasında (Jain vd., 2018; S. Zhang vd., 2016), optimum güç dağıtım problemlerinde (Pradhan vd., 2016), görüntü işleme uygulamalarında (Medjahed vd., 2016), makine öğrenmesi uygulamalarında (Q. Li vd., 2017), tıp ve biyoinformatik uygulamalarında (Mostafa vd., 2017; Sahoo & Chandra, 2017), kablosuz sensör ağlarında (Diwan, 2016) ve jeolojik araştırmalarda (Song vd., 2015) kullanım alanı bulmaktadır (Dada vd., 2022).

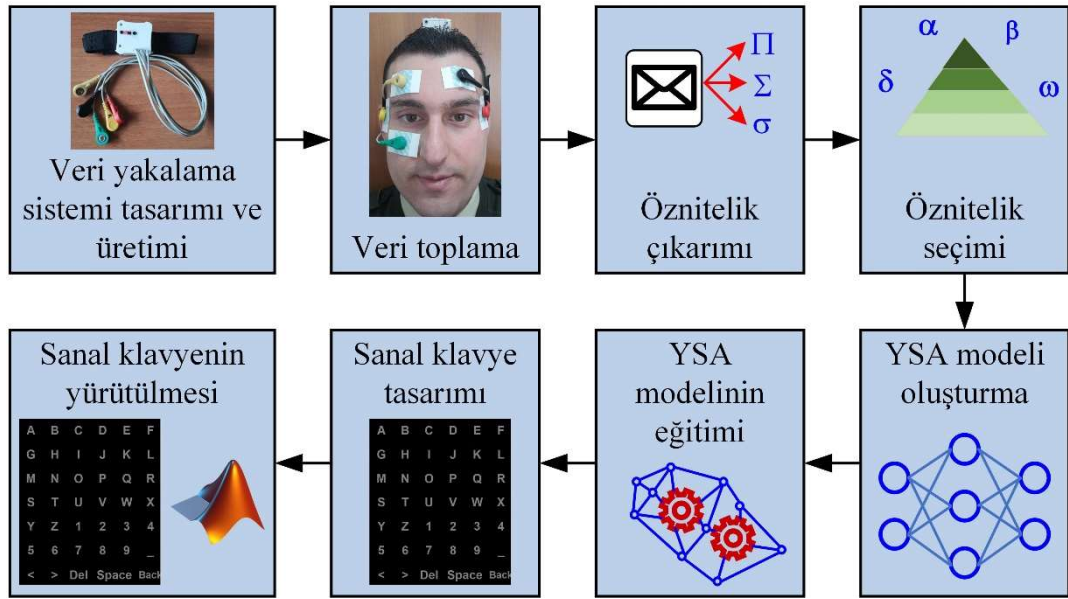
Literatürde, GKO'nun makine öğrenmesi süreçlerinden öznelik seçimi aşamasında kullanımına ilişkin çalışmalara da rastlanmıştır. Emary ve arkadaşları GKO'nun öznelik belirleme aşamasında sergilediği performansı parçacık sürü

optimizasyonu ve genetik algoritma gibi farklı yöntemlerin performanslarına göre değerlendirmiş ve GKO'nun öznitelik seçimindeki performansının daha iyi olduğu sonucuna ulaşmışlardır (Emary vd., 2015). Tu ve arkadaşları öznitelik seçiminde GKO'nun kullanımına ilişkin çalışmalarında CEC2014'ten çeşitli fonksiyonlara dayalı sayısal deneyler yapmış ve GKO'nun farklı varyantlarının kullanımının sınıflandırma başarımlarına olumlu yansıdığını bildirmişlerdir (Tu vd., 2019). Hu ve arkadaşları sahip oldukları veri seti üzerinde öznitelik belirleme aşamasında GKO kullanmışlar, önerdikleri yöntemin test edilmesi için Benchmark Kıyaslama Fonksiyonları'nı kullanmışlar ve öznitelik seçiminde GKO'nun katkısını göstermişlerdir (Hu vd., 2020). Sreedharan ve arkadaşları yüzdeki duyguların tanımlanması için bir duygu tanıma sistemi geliştirmişler, topladıkları verilerin öznitelik çıkarımını yapmışlar, öznitelik seçiminde GKO, sınıflandırma aşamasında YSA tercih etmişler, önerdikleri YSA-GKO tekniği ile %91,22 sınıflandırma başarımları elde etmişlerdir (Sreedharan vd., 2018). Mulam ve Mudigonda çalışmalarında GKO kullanarak en az hata fonksiyonuna sahip öznitelikleri seçmişler, YSA kullanarak göz hareketlerinin sınıflandırılmasını sağlamışlar ve yüksek sınıflandırma başarımları elde ettiklerini bildirmişlerdir (Mulam & Mudigonda, 2020).

Literatürdeki çalışmalar incelendiğinde; GKO'nun sakkadik göz hareketlerinin sınıflandırılmasında, EOG kayıtlarına ait özniteliklerin belirlenmesinde ve göz hareketlerine dayanan sanal klavye uygulamalarında kullanımına dair çalışmaların çok az olduğu, bu alandaki çalışmaların ilerleyen zamanlarda artış göstereceği öngörülmektedir.

4. MATERYAL VE METOT

Elektrookülogram tabanlı sanal klavye uygulamasında metasezgisel algoritma kullanımı çalışması kapsamında; EOG veri yakalama sistemi tasarlanarak üretilmiş, belirlenen bireylerden veri toplama işlemi gerçekleştirilmiş, toplanan verilerde öznitelik çıkarımı işlemi yapılmış, popülasyona dayalı metasezgisel bir algoritma olan GKO ile en uygun öznitelikler belirlenmiş, belirlenen öznitelikler oluşturulan YSA modeline eğitim kümesi olarak tanımlanmış, MATLAB platformu üzerinde geliştirilen sanal klavye uygulaması eğitilen YSA modeli kullanılarak yürütülmüştür. Bu tasarım aşamaları Şekil 4.1’de görsel olarak verilmiş ve tasarım aşamalarına ait ayrıntılar aşağıda ele alınmıştır.




Şekil 4.1: Tasarım Aşamaları.

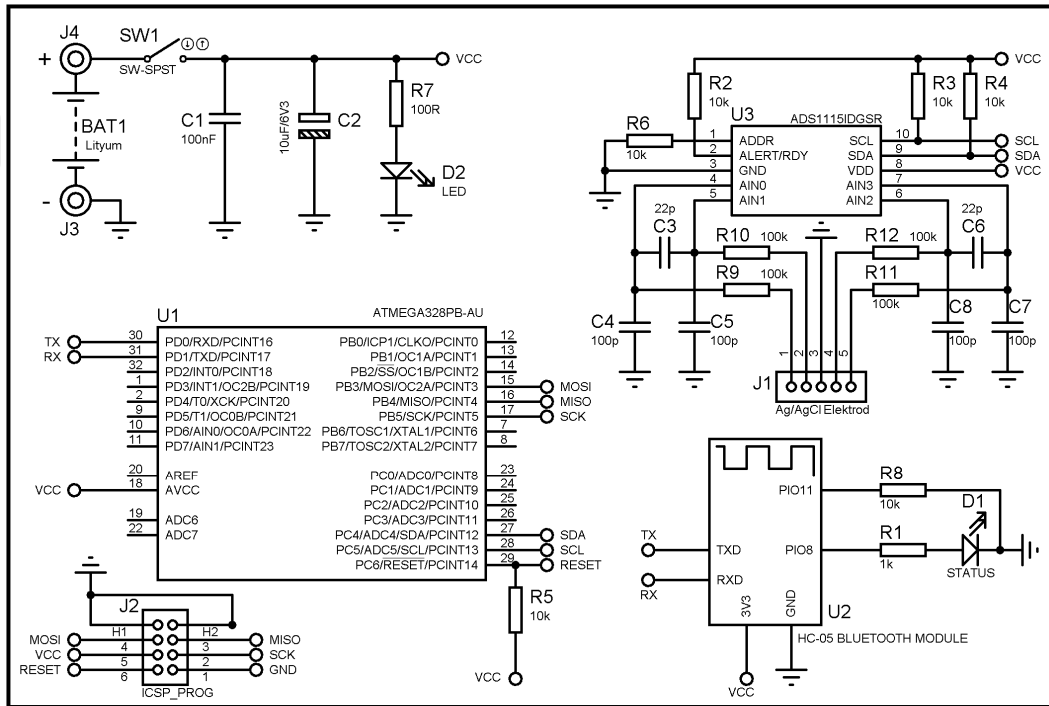
4.1. Veri Yakalama Sisteminin Tasarımı ve Üretimi

Daha önceki bölümlerde EOG veri yakalama sistemlerine ait bazı bilgiler ve görseller verilmişti. Verilen bu bilgi ve görsellerde veri yakalama işlemindeki yükseltme, filtreleme, DC seviye kaydırma gibi işlemlerin donanımsal olarak gerçekleştirildiğini ve bunun da hacim ve maliyet açısından yük getirdiği hatırlatılmalıdır. Bu çalışmada; EOG kayıtlarının düşük maliyetli ve küçük hacimli bir veri yakalama sistemi ile


toplanması hedeflenmiştir. Bu kapsamda, Şekil 4.2’de blok şeması verilen veri yakalama sisteminin tasarımı ve üretimi gerçekleştirilmiştir. Tasarıma ait devre şeması Şekil 4.3’te, sisteme ait bileşenler Şekil 4.4’te verilmiştir.



Şekil 4.2: Tasarlanan EOG Veri Yakalama Sisteminin Blok Şeması.




Şekil 4.3: Tasarlanan EOG Veri Yakalama Sisteminin Devre Şeması.



Şekil 4.4: Üretimi Yapılan EOG Veri Yakalama Devresinin Bileşenleri.

Veri yakalama sisteminde göz sinyalleri pediatrik Ag/AgCl EKG elektrotları ile devreye aktarılmıştır. Bu elektrotlar boyutlarının küçük olması ve tek kullanımlık olmaları sebebiyle tercih edilmiştir. Yüzün farklı noktalarına yerleştirilen 5 farklı elektrot ile algılanan sinyaller Şekil 4.3'te verilen devrenin J1 konnektöründen uygulanmaktadır. Elektrotların yüzdeki yerleşimi Şekil 4.5'te verilmiştir. R9-R10-C3-C4-C5 ile R11-R12-C6-C7-C8 devre elemanlarından oluşan bölüm kesim frekansı yaklaşık 13 kHz olan bir pasif alçak geçiren filtredir. Filtre çıkışı ADS1115'e uygulanır. ADS1115; 4 kanal ve 16 bit çözünürlüğe sahip bir analogtan sayısala çeviricidir. ADS1115'in besleme geriliminin 3,3 V olduğu düşünülürse, sayısal çıkışında 1 bitlik değişim meydana getirebilmek için analog girişinden 50,35 μ V'luk bir gerilim uygulamak gerekir. EOG sinyallerinin, 0-100 Hz frekans aralığında ve 50~3500 μ V genlik aralığında değişim gösterdiği düşünüldüğünde, ADS1115 ile EOG sinyallerinin doğrudan ölçülebileceği ve elde edilen sayısal verilerin filtrelenebileceği ortaya çıkar. Bu durumda donanımsal filtre, yükseltme ve diğer analog işlemler için eklentiler yapmaya gerek kalmaz, dolayısıyla hacim ve sistem maliyeti azalır.




Şekil 4.5: Elektrotların Yüzdeki Yerleşimi.

ADS1115; I2C protokolü ile haberleşen bir analogtan sayısala çeviricidir. Geliştirilen EOG veri yakalama sistemi ATMEGA-328 mikrodenetleyici tabanlı olarak geliştirilmiştir. Ayrıca sistemin bilgisayar haberleşmesi de HC-05 bluetooth modülü ile sağlanmaktadır. Mikrodenetleyici; analog EOG sinyallerine ait sayısal verileri I2C protokolü ile ADS1115'ten alır, gömülü yazılım ile filtreleme ve DC seviye kaydırma

işlemlerine tabî tutarak UART üzerinden bluetooth modülüne aktarır. Böylelikle elektrotlar ile algılanan EOG sinyalleri sayısallaştırılarak kablosuz olarak bilgisayara aktarılmış olur.

Geliştirilen veri yakalama sisteminin mikrodenetleyici ünitesinde filtreleme işlemi için Hanning filtre tercih edilmiştir. Kullanılan Hanning filtrenin algoritmasına ait blok şema Şekil 4.6’da, transfer fonksiyonu ise Denklem 4.1’de verilmiştir.

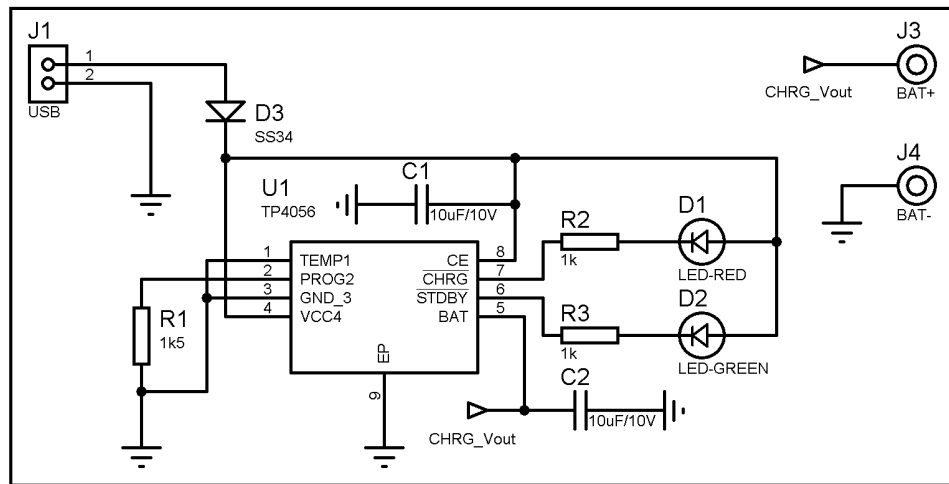


Şekil 4.6: Hanning Filtreleme Algoritması.

$$y(n) = \frac{1}{4} [x(n) + 2x(n - 1) + x(n - 2)] \quad (4.1)$$

EOG kayıtlarına ait veri dizisindeki son 20 verinin aritmetik ortalaması hesaplanarak dizideki her bir güncel elemandan çıkarılmış, böylelikle DC seviye bastırma işlemi gerçekleştirilmiştir.

Tasarlanan veri yakalama sistemi, enerjisini bir adet dâhili Lityum-Polimer (Li-Po) bataryadan almaktadır. Bu bataryayı şarj edebilmek için TP4056 destekli harici bir şarj ünitesi tasarlanmıştır. Tasarlanan şarj ünitesinin devre şeması Şekil 4.7’de verilmiştir.



Şekil 4.7: Tasarlanan Li-Po Batarya Şarj Devresi.

TP4056; 4,2 V ~ 3,6 V aralığında gerilim üretebilen Lityum (Li) ve Li-Po bataryaları şarj etmek üzere tasarlanmış bir entegre devredir. Şarj gerilimi 4,2 V olacak şekilde

sabit olarak belirlenmiş, şarj akımı değeri harici şekilde kullanılan bir direnç ile programlanabilmektedir. Bu direnç Şekil 4.7'deki devrede R1 direncidir. Şarj esnasındaki akım değeri programlanan değerin onda birine düştüğünde şarj döngüsü sonlanır. Bunların yanı sıra TP4056; akım takip, düşük gerilim, otomatik şarj, şarj sonlandırma ve giriş gerilimi varlığını bildiren 2 adet durum portuna sahiptir.


4.2. Veri Toplama

İlerleyen bölümlerde tasarım ilkeleri ayrıntılı şekilde açıklanacak olan YSA'nın eğitiminde veri toplama sistemi ile toplanan EOG kayıtları kullanılacaktır. Veri toplama çalışmaları kapsamında 20 sağlıklı bireyden veriler toplanmıştır. Bireylerden 10'u kadın, 10'u erkektir. Yaşları 27~50 arasında değişmektedir ve yaşların standart sapması 5,99'dur. Veri toplama işlemi 450~1950 lux ışık şiddetinde, 23~26 °C sıcaklıkta, kapalı ortamda gerçekleştirilmiştir.

Veri toplanan tüm bireylerin yüzlerine Şekil 4.5'teki gibi Ag/AgCl elektrotlar yerleştirilmiş, veri toplama sistemi başlarının üzerine sabitlenmiş ve hazırlanan test yüzeyinin karşısına konumlandırılmışlardır. Test yüzeyi; çapı 100 mm olan 9 adet test hedefinin 300 mm aralıklarla düz düşey beyaz bir zemine yerleştirilmesiyle oluşturulmuştur. Bir test hedefinin görünümü Şekil 4.8 (a)'da, hedeflerin test yüzeyinde yerleşimi Şekil 4.8 (b)'de verilmiştir. 5 numaralı test hedefi, merkezi yerden 1600 mm yükseklikte olacak şekilde yerleştirilmiştir. Veri toplama esnasında bireylerin, test yüzeyinden 500 mm uzaklıkta durmaları sağlanmıştır.

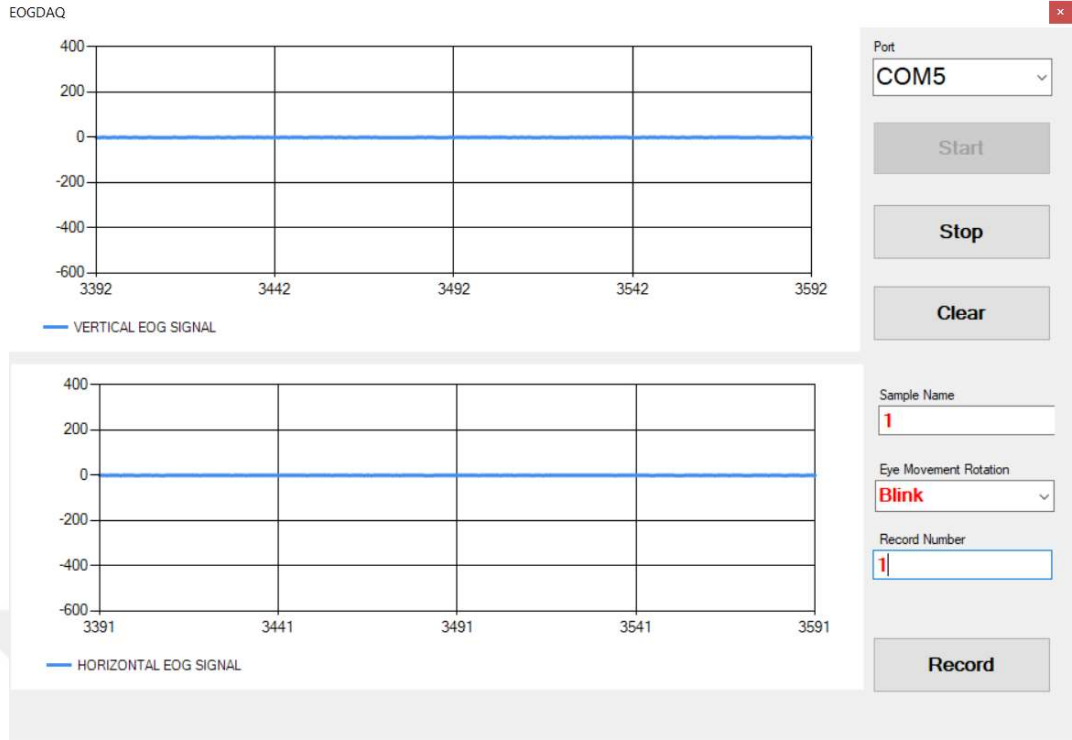
EOG verilerinin toplanmasına başlamadan önce tüm bireyler 7 dakikalık bir eğitime tabî tutulmuşlardır. Bu eğitimde, yapılacak işlemin amacı açıklanmış ve örnek kayıtlar alınmıştır. Alınan örnek kayıtlar YSA modelinin eğitiminde kullanılmamıştır. Bireylere verilen eğitiminin ardından YSA modelinin eğitiminde kullanılacak verilerin toplanması safhasına geçilmiştir. Tüm bireylerden gözlerini 5 numaralı hedefte sabit tutmaları ve verilen sesli komut ile gözlerini kırpmaları istenmiştir. 20 farklı göz kırpma eylemi için veriler kayıt altına alınmıştır. Ardından bireylerin gözlerini test zemini üzerinde 5→2, 5→8, 5→4, 5→6, 5→1, 5→3, 5→7, 5→9 doğrultularında hareket ettirmeleri istenmiştir. Sıralanan bu hareketler gözün yukarı, aşağı, sol, sağ, sol-yukarı, sağ-yukarı, sol-aşağı, sağ-aşağı hareketlerine karşılık gelmektedir. Her göz hareketi için 20 kayıt alınmıştır. Bireylerin göz hareketlerinin takibi ve verilerin kaydı için Şekil 4.9'da verilen veri toplama arayüzü tasarlanmıştır. Veri toplama arayüzü

tasarımında C# kullanılmıştır. Herhangi bir sakkadik göz hareketine ait kayıt oluşturulurken, veri toplama sisteminin dişey ve yatay kanalından alınan veriler eş zamanlı olarak bir txt dosyasına kaydedilmiştir. Veri kayıt işlemi tamamlandığında, 20 bireyin 9 farklı sakkadik göz hareketi için toplamda 7200 txt dosyasından oluşan EOG kayıtları elde edilmiştir. Öznitelik çıkarım, öznitelik seçme ve YSA modelinin eğitiminde bu EOG kayıtları kullanılmıştır.

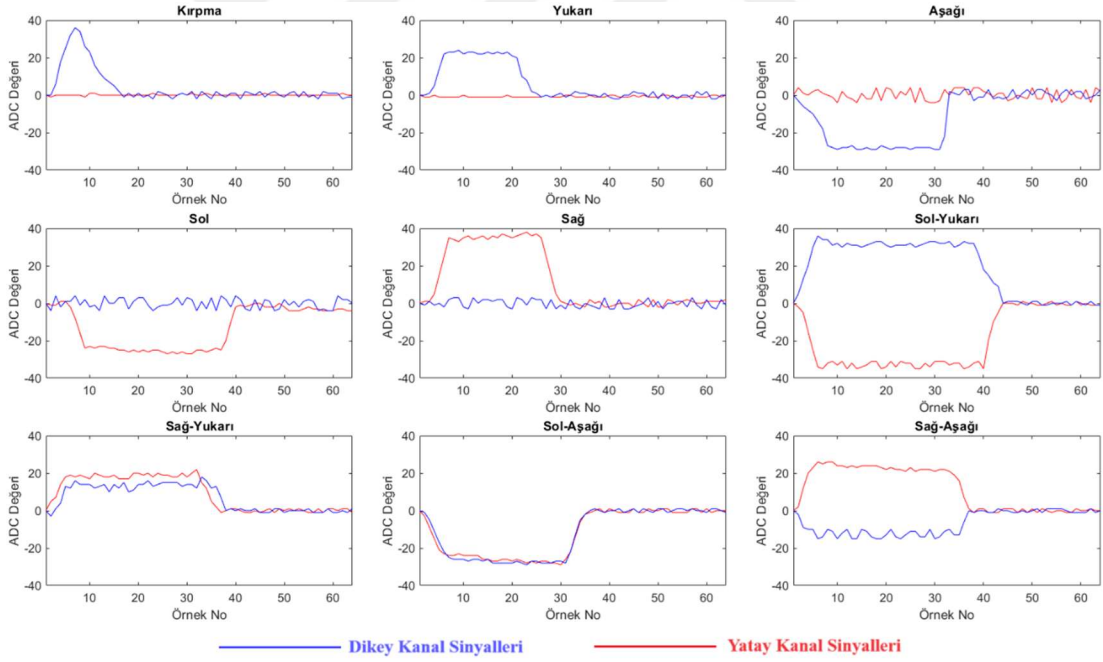


Şekil 4.8: Test Yüzeyinin Bileşenleri (a) Test Hedefi (b) Test Hedeflerinin Test Yüzeyinde Yerleşimi.

Veri toplama safhasının bitmesini takiben tüm verilerde bir ön işleme gerçekleştirilmiştir. Ön işleme aşamasında farklı boyutlardaki EOG kayıtları eşit uzunluklarda olacak şekilde düzenlenmiştir. Bu kapsamda tüm kayıtlarda sakkadik hareketin başladığı nokta tespit edilmiş ve bu noktadan itibaren 64 veri alınarak yeni dosyalar oluşturulmuştur. Ön işleme safhasının ardından EOG kayıtlarına ilişkin 7200X64 boyutunda bir veri matrisi elde edilmiştir. Bu matristen alınan ve bir bireye ait toplanan 9 farklı sakkadik göz hareketine ait verilerin oluşturduğu grafikler Şekil 4.10'da verilmiştir.



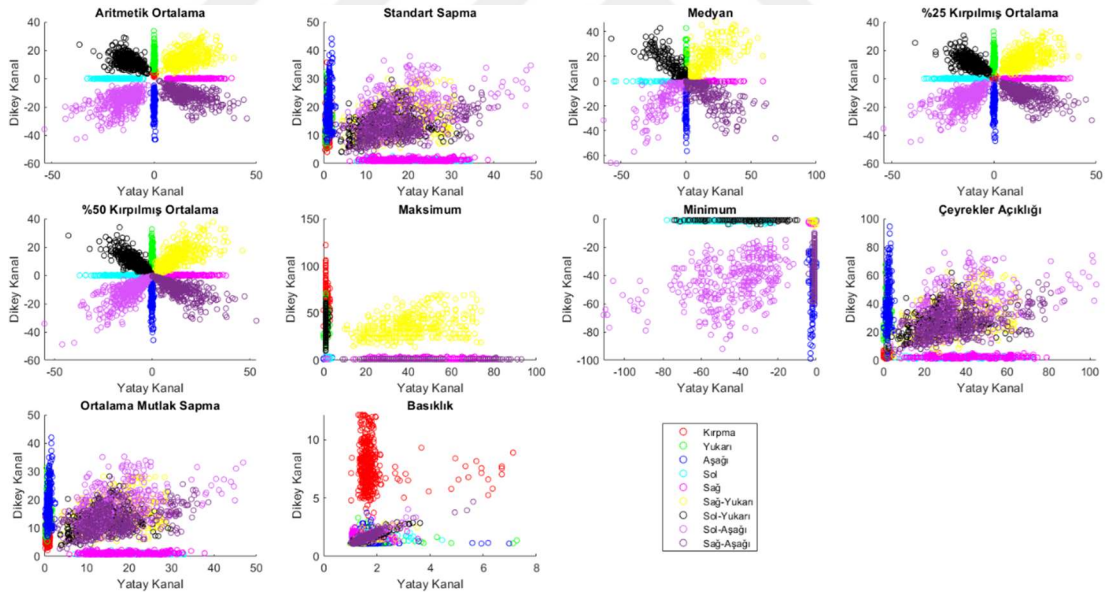
Şekil 4.9: Veri Toplamada Kullanılan Bilgisayar Arayüzü.



Şekil 4.10: Veri Toplama Safhasında Elde Edilen Örnek EOG Kayıtları.

4.3. Öznitelik Çıkarımı

Veri toplama işlemi neticesinde elde edilen verileri bir bütün olarak ele alarak sınıflandırmaya tabî tutmanın sınıflandırma hızını ve sınıflandırma başarımını düşürdüğü bilinmektedir. Bir sınıfa ait verilerin, o sınıfın özelliklerini niteleyen özniteliklere dönüştürülmesi ve indirgeme yapılması sınıflandırma hızını ve başarımını olumlu yönde etkilemektedir. Literatürde EOG verileri için aritmetik ortalama, standart sapma, medyan, kırılmış ortalama, maksimum, minimum, çeyrekler açıklığı, ortalama mutlak sapma ve basıklık gibi özniteliklerin kullanıldığı görülmüştür (Zengin vd., 2019). Bu bilgilerden hareketle, bu çalışma kapsamında, veri toplama safhasında elde edilen EOG kayıtları kullanılarak oluşturulan 7200X64 boyutlu veri matrisi kullanılmış ve sakkadik göz hareketlerini niteleyen, istatistiksel hesaplamalara dayalı özniteliklerin çıkarımı gerçekleştirilmiştir. Öznitelik çıkarımı neticesinde elde edilen grafikler Şekil 4.11’de, kullanılan öznitelikler ve denklemleri Tablo 4.1’de verilmiştir.



Şekil 4.11: Elde Edilen Öznitelik Grafikleri.

Tablo 4.1: Kullanılan Öznitelikler ve Denklemleri.

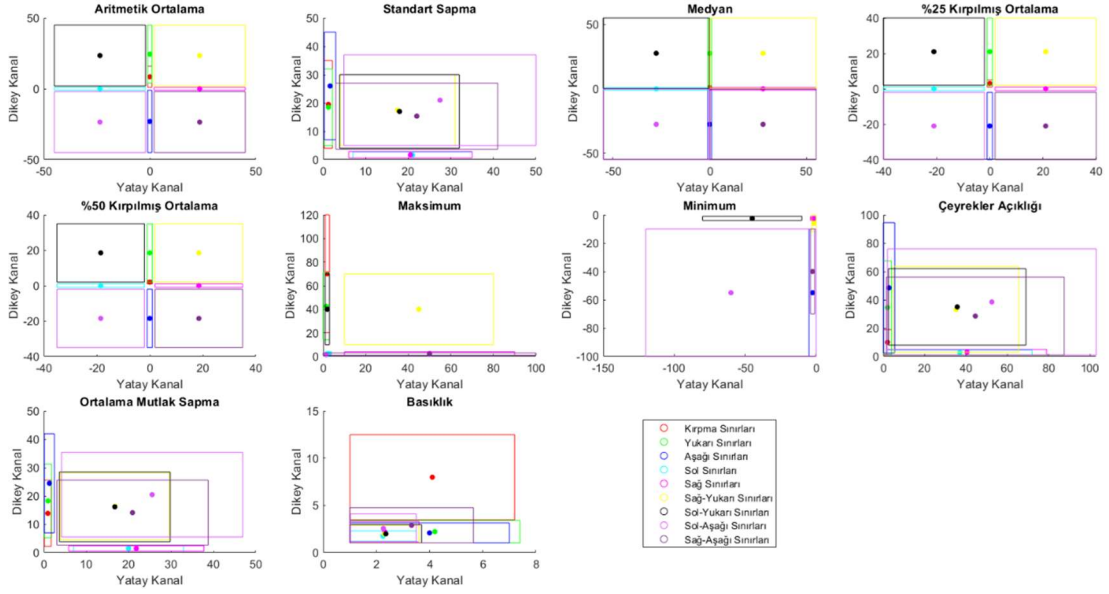
Sıra No	Öznitelik	Denklemler
1	Aritmetik Ortalama (\bar{x})	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{1}{n} (x_1 + \dots + x_n)$
2	Standart Sapma (S)	$\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$
3	Medyan (\tilde{x})	$\begin{cases} \frac{x_{n+1}}{2} & : x \text{ tek} \\ \frac{x_n}{2} + \frac{x_{n+1}}{2} & : x \text{ çift} \end{cases}$
4	%25 Kırpılmış Ortalama (T_{25})	<p>Büyükten küçüğe doğru sıralanmış n boyutlu bir veri dizisinde:</p> $T_{25} = \frac{\sum_{i=n/8}^{n-1/8} x_i}{3n/4}$
5	%50 Kırpılmış Ortalama (T_{50})	<p>Büyükten küçüğe doğru sıralanmış n boyutlu bir veri dizisinde:</p> $T_{50} = \frac{\sum_{i=n/4}^{3n/4} x_i}{n/2}$
6	Maksimum (x_{max})	$\max(x)$
7	Minimum (x_{min})	$\min(x)$
8	Çeyrekler Açıklığı (IQR)	$IQR = Q_3 - Q_1$ $Q_1 = \left(\frac{n+1}{4}\right)^{nci} \text{ terim}$ $Q_3 = \left(\frac{3(n+1)}{4}\right)^{nci} \text{ terim}$
9	Ortalama Mutlak Sapma (MAD)	$\frac{\sum_{i=1}^n x_i - \bar{x} }{n}$
10	Basıklık (x_{kur})	$\frac{\sum_{i=1}^n (x_i - \bar{x})^4}{(n-1)S^4}$

4.4. Öznitelik Seçimi

Sınıflandırma problemlerinde, eğitim safhasında kullanılabilir özniteliklerin belirlenmesinde farklı teknikler kullanılabilir. Aday öznitelik ya da öznitelikler arasından uygun olanın seçimi safhasında öngörüler ve geçmiş tecrübeler önemli olsa da bir modele dayalı öznitelik seçmek daha çok tercih edilir. Bu noktada, çözüm tabanlı ve popülasyona dayalı optimizasyon teknikleri ile öznitelik seçiminin son zamanlarda sıklıkla tercih edildiği görülmektedir (Adam vd., 2014; Hu vd., 2020; Perez Reynoso vd., 2020). Ancak literatür incelendiğinde, göz hareketlerine dayanan sanal klavye uygulamalarında öznitelik seçimi için GKO kullanımı nadiren görülmüştür. Literatürde bu alanda bir boşluk olduğu kıymetlendirilmektedir. Bu kapsamda, göz hareketlerine dayanan sanal klavye uygulamalarında öznitelik seçiminde GKO kullanımına yönelik bir hipotez kurulmuş ve bu doğrultuda çalışmalar gerçekleştirilmiştir.

GKO tekniğinde, kurtların konumlarının avın pozisyonuna göre sürekli olarak güncellendiğinden önceki bölümlerde bahsedilmiştir. 9 farklı sakkadik göz hareketi için elde edilen ve grafikleri Şekil 4.11’de verilen farklı özniteliklerde, her göz hareketi için bir sınır tanımlanabilir. Bu sınırlar içerisinde, her göz hareketinin sınırları içerisinde kalan öznitelik noktaları bir kurt sürüsü olarak nitelendirilebilir. Uygunluğu araştırılacak sınırlar içerisinde ya da kritik noktalarda belirlenecek koordinatlar av olarak tanımlanabilir. Dolayısıyla herhangi bir öznitelik grubunun her üyesinin, bir sakkadik göz hareketi sınırları içerisinde kalan ve av olarak nitelendirilen noktaya uygunluğunun ölçüsü hesaplanabilir. Elde edilen tüm uygunluk değerleri incelenerek uygun öznitelikler belirlenebilir. Bu çalışmada GKO algoritmasının yürütülmesi için MATLAB platformunda bir kod geliştirilmiş ve uygunluk ölçüsünün hesaplanabilmesi için CEC 2005 test fonksiyonlarının arasında yer alan f_{10} fonksiyonu kullanılmıştır. Bu fonksiyona ait eşitlik Denklem 4.2’de verilmiştir. Geliştirilen kod içerisinde popülasyon büyüklüğü 7 ve iterasyon sayısı 100 olacak şekilde atanmıştır. Tüm öznitelikler için belirlenen sınırlar ve her sakkadik göz hareket bölgesi için av olarak belirlenen noktalar Şekil 4.12’de görülmektedir.

$$f_{10}(x) = -20 \exp - \left(0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e \quad (4.2)$$



Şekil 4.12: Sınırlar ve Av Koordinatları.

Şekil 4.12’de her öznitelikte göz hareketlerine tanımlanan sınırlar açıkça görülmektedir. Tanımlanan dikdörtgensel sınırların köşeleri ile orta noktaları av olarak tanımlanmış, öznitelik kümesinde bulunan diğer noktaların ava yaklaşımında uygunluk ölçüleri hesaplanmıştır. Tablo 4.2~Tablo 4.11’de, çalışma kapsamında kullanılan öznitelikler için uygunluk ve başarımların değerleri verilmiştir. Tablolarda “□” kırpma, “↑” yukarı, “↓” aşağı, “←” sol, “→” sağ, “↖” sol-yukarı, “↗” sağ-yukarı, “↙” sol-aşağı, “↘” sağ-aşağı sakkadik göz hareketlerini sembolize etmektedir.

“TP (True Positive)” gerçekte doğru olan ve doğru tahmin edilen eylemleri ifade eder. “TN (True Negative)” gerçekte doğru olmayan ve doğru tahmin edilmeyen eylemleri ifade eder. “FP (False Positive)” gerçekte doğru olmayan ve doğru tahmin edilen eylemleri ifade eder. “FN (False Negative)” gerçekte doğru olan ve doğru tahmin edilmeyen eylemleri ifade eder. En uygun öznitelik belirlenmesinde Denklem 4.3’te verilen “Matthews Korelasyon Katsayısı (MCC)” kullanılmıştır.

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}} \quad (4.3)$$

Tablolarda uygunluk değerinin 5’in altında olması “doğru”, 5’in üstünde olması “yanlış” olarak değerlendirilmiştir.

Tablo 4.2: Aritmetik Ortalama Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef											
		□	↑	↓	↶	↷	↺	↻	↹	↸	↷		
Test	□	1,60	1,58	12,10	11,12	11,39	4,37	4,37	12,82	12,39	TP:	9	
	↑	10,69	1,64	18,76	18,46	18,54	4,38	4,38	18,96	18,78	TN:	71	
	↓	18,31	18,97	1,62	18,04	18,04	18,64	18,59	4,38	4,37	FP:	0	
	↶	18,04	18,22	18,04	1,58	18,76	4,37	18,76	4,37	18,76	FN:	11	
	↷	18,04	18,30	18,30	18,76	1,71	18,76	4,37	18,76	4,37	MCC		
	↺	18,54	18,04	20,03	18,04	20,14	1,59	18,76	18,76	20,33	0,62		
	↻	18,54	18,04	20,03	20,14	18,04	18,76	1,60	20,34	18,76			
	↹	20,03	20,27	18,04	18,04	20,14	18,76	20,34	1,63	18,76			
	↸	20,03	20,25	18,04	20,14	18,04	20,34	18,76	18,76	1,60			

Tablo 4.3: Standart Sapma Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef											
		□	↑	↓	↶	↷	↺	↻	↹	↸	↷		
Test	□	1,75	1,68	1,66	17,15	16,95	7,84	7,74	7,72	9,69	TP:	9	
	↑	1,83	1,95	1,71	16,80	16,73	8,12	6,94	7,57	8,77	TN:	53	
	↓	2,87	2,84	2,13	18,76	18,54	9,53	11,40	10,49	13,46	FP:	0	
	↶	17,15	17,56	17,36	1,79	1,84	9,64	7,80	9,71	8,44	FN:	19	
	↷	17,15	17,23	17,22	2,11	1,95	9,30	7,69	9,89	8,55	MCC		
	↺	15,58	15,58	15,58	15,15	15,11	2,59	2,80	2,39	2,88	0,49		
	↻	15,59	15,60	15,11	15,11	15,14	2,37	2,41	2,77	3,95			
	↹	18,76	18,76	18,57	17,27	16,80	6,65	2,49	2,83	4,44			
	↸	17,15	17,15	17,08	14,06	14,05	2,42	2,28	2,75	2,23			

Tablo 4.4: Medyan Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef											
		□	↑	↓	↶	↷	↺	↻	↹	↸	↷		
Test	□	1,56	1,56	3,02	3,02	3,02	1,56	1,56	3,02	3,02	TP:	8	
	↑	18,76	4,00	19,35	18,97	19,16	11,40	7,59	19,35	19,35	TN:	63	
	↓	19,34	19,34	2,42	19,03	19,12	19,34	19,22	11,40	13,64	FP:	1	
	↶	19,02	19,03	18,99	1,75	19,21	14,11	19,22	9,69	19,21	FN:	9	
	↷	19,02	19,03	19,03	19,34	3,84	19,34	12,85	19,21	5,85	MCC		
	↺	20,43	19,20	20,52	19,22	20,52	5,03	19,33	19,50	20,52	0,59		
	↻	20,43	19,10	20,52	20,52	19,21	19,86	4,06	20,52	19,59			
	↹	20,68	20,52	18,98	18,98	20,52	20,26	20,73	2,45	19,66			
	↸	20,52	20,52	19,23	20,52	19,10	20,52	20,22	20,08	2,80			

Tablo 4.5: %25 Kırpılmış Ortalama Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef									
		□	↑	↓	↶	↷	↸	↹	↺	↻	
Test	□	1,64	2,51	8,93	6,49	7,32	5,46	4,52	9,70	6,26	TP: 9
	↑	14,10	1,83	18,33	17,60	17,80	8,70	8,82	18,33	17,77	TN: 70
	↓	17,47	18,69	1,67	17,47	17,52	18,44	18,05	9,98	10,80	FP: 0
	↶	17,17	17,55	17,53	1,82	18,30	8,36	18,09	7,82	17,84	FN: 2
	↷	17,19	17,64	17,77	18,20	1,76	18,37	9,68	18,15	9,34	MCC
	↸	18,59	17,47	19,81	17,48	19,79	4,21	18,96	18,87	19,66	
	↹	18,62	17,49	19,78	19,65	17,43	18,85	2,77	20,17	18,96	
	↺	19,48	20,00	17,29	17,53	19,88	18,80	19,97	4,68	18,95	0,89
	↻	19,65	19,89	17,50	19,74	17,56	20,02	18,75	18,97	2,42	

Tablo 4.6: %50 Kırpılmış Ortalama Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef									
		□	↑	↓	↶	↷	↸	↹	↺	↻	
Test	□	1,83	1,72	5,21	4,26	4,41	2,32	2,90	5,25	4,45	TP: 9
	↑	16,02	1,73	16,80	16,54	16,78	7,99	8,56	16,80	16,80	TN: 66
	↓	16,83	16,80	1,80	16,54	16,56	17,14	16,81	8,88	9,02	FP: 0
	↶	16,37	16,53	16,44	2,00	16,80	8,58	16,81	7,80	16,81	FN: 6
	↷	16,43	16,79	16,48	16,80	1,74	16,80	9,67	16,80	6,63	MCC
	↸	18,54	16,65	19,04	16,54	19,01	2,59	17,84	17,81	19,03	
	↹	18,54	16,42	18,99	19,10	16,42	17,89	2,65	18,98	17,77	
	↺	18,76	18,97	16,42	16,44	19,06	18,18	19,05	2,97	18,24	0,74
	↻	18,76	19,00	16,43	18,87	16,43	19,05	18,32	18,47	3,59	

Tablo 4.7: Maksimum Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef									
		□	↑	↓	↶	↷	↸	↹	↺	↻	
Test	□	1,56	3,86	21,44	21,43	21,46	7,99	19,36	21,45	21,59	TP: 9
	↑	2,80	2,80	20,84	20,76	20,86	2,80	12,84	20,92	20,82	TN: 59
	↓	16,07	13,58	2,59	2,59	13,49	10,81	16,42	2,59	9,67	FP: 0
	↶	16,12	13,51	2,80	2,80	13,51	10,58	16,03	2,80	9,71	FN: 13
	↷	21,18	21,18	20,95	20,95	2,59	21,15	14,62	21,03	2,59	MCC
	↸	1,56	1,56	20,34	20,25	20,74	1,56	12,09	20,43	20,68	
	↹	20,74	20,77	21,28	21,28	20,26	20,79	3,02	21,32	20,52	
	↺	16,53	14,08	2,80	2,80	14,08	11,34	16,85	2,80	10,52	0,58
	↻	21,22	21,15	20,95	20,95	1,56	21,19	14,60	21,03	1,56	

Tablo 4.8: Minimum Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef											
		□	↑	↓	↔	⇒	↖	↗	↘	↙			
Test	□	2,80	2,80	15,66	16,12	2,80	11,40	2,80	16,92	10,52	TP:	9	
	↑	2,80	2,80	15,66	16,12	2,80	11,40	2,80	16,92	10,52	TN:	55	
	↓	21,14	21,14	2,59	21,31	21,14	21,38	20,79	15,12	4,00	FP:	0	
	↔	20,73	20,73	21,01	2,59	20,66	4,00	20,73	16,82	20,90	FN:	17	
	⇒	2,59	2,59	15,67	15,64	2,59	10,81	2,59	18,86	10,55	MCC		
	↖	20,73	20,73	21,01	2,59	20,66	4,00	20,73	16,82	20,90			
	↗	4,46	4,46	13,50	16,28	4,46	12,13	3,23	16,07	6,82	0,51		
	↘	21,58	21,58	21,30	21,20	21,54	21,21	21,48	3,02	21,32			
	↙	20,25	20,26	2,59	20,73	20,25	20,59	19,17	14,01	4,00			

Tablo 4.9:Çeyrekler Açıklığı Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef											
		□	↑	↓	↔	⇒	↖	↗	↘	↙			
Test	□	4,22	3,02	4,00	10,64	10,64	2,59	9,62	4,00	7,31	TP:	9	
	↑	15,67	1,56	1,56	19,99	20,08	12,11	9,86	11,58	12,13	TN:	53	
	↓	19,70	2,91	2,67	20,96	21,01	12,00	15,16	15,17	17,56	FP:	0	
	↔	19,91	20,15	20,15	2,82	2,09	14,56	8,77	13,88	12,66	FN:	19	
	⇒	20,34	20,52	20,60	1,56	2,59	14,73	9,71	14,20	12,42	MCC		
	↖	20,61	19,89	19,66	19,65	19,65	2,91	2,09	3,52	4,32			
	↗	20,35	19,84	19,65	19,42	19,50	2,33	2,33	2,33	4,20	0,49		
	↘	21,27	21,25	21,05	20,30	20,15	4,00	4,46	4,00	4,09			
	↙	20,85	20,67	20,66	18,52	18,31	5,35	3,23	2,80	2,80			

Tablo 4.10: Ortalama Mutlak Sapma Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef											
		□	↑	↓	↔	⇒	↖	↗	↘	↙			
Test	□	2,00	2,04	1,85	15,12	14,64	7,74	5,84	6,70	5,82	TP:	9	
	↑	2,36	1,78	1,68	16,82	16,61	7,85	7,26	7,67	8,81	TN:	54	
	↓	3,32	2,72	1,63	18,44	18,32	8,82	10,81	10,21	13,26	FP:	0	
	↔	16,80	17,25	17,15	1,88	1,86	9,71	7,78	9,30	8,75	FN:	18	
	⇒	17,48	17,78	17,78	1,92	2,05	9,85	7,55	8,63	7,77	MCC		
	↖	15,32	15,11	15,12	14,60	14,60	2,56	2,14	3,08	3,08			
	↗	15,44	15,12	15,15	14,81	14,77	2,68	2,39	2,88	2,98	0,50		
	↘	18,57	18,34	18,09	16,89	16,56	6,09	2,47	2,99	5,47			
	↙	17,00	16,86	16,80	13,46	13,46	2,71	1,83	2,92	2,72			

Tablo 4.11: Basıklık Özniteliği İçin Uygunluk ve Başarım Değerleri.

		Hedef									
		□	↑	↓	←	→	↖	↗	↘	↙	
Test	□	2,95	8,61	7,79	8,90	8,19	8,09	8,48	6,86	6,61	TP: 9
	↑	5,48	2,68	3,22	2,88	2,98	2,88	2,81	3,28	3,70	TN: 10
	↓	5,45	2,61	2,92	2,82	2,82	2,88	2,73	3,04	3,33	FP: 0
	←	4,23	1,97	1,86	1,62	1,67	1,73	1,88	2,09	2,06	FN: 62
	→	3,87	2,36	2,52	2,01	2,10	1,66	1,89	1,64	1,63	
	↖	4,15	2,08	2,34	1,77	1,81	1,65	1,87	1,77	2,03	
	↗	4,15	1,92	2,20	1,68	1,78	1,63	1,90	1,74	2,11	
	↘	3,19	2,51	2,58	2,61	2,56	1,77	1,76	1,76	1,80	
	↙	4,16	4,05	4,05	2,89	2,84	1,62	2,53	2,33	2,42	
			MCC								
		0,13									

Tablo 4.2~Tablo 4.11 incelendiğinde, 9 farklı sakkadik göz hareketine ait özniteliklerden, en iyi MCC değeri 0,89 ile %25 kırılmış ortalama özniteliği için elde edilmiştir. Bu sonuç, göz hareketlerine dayanan sanal klavye uygulamasının sınıflandırma ve karar verme sürecinde %25 kırılmış ortalama özniteliğinin tercih edilmesinin daha faydalı olacağını göstermektedir. %25 kırılmış ortalama özniteliği, kullanılan 10 farklı öznitelik arasından en iyi uygunluk başarımını vermiş olsa da, gözün yukarı ve kırpma sakkadik hareketlerine ait uygunluk değerlerinin iyileştirilmesine yönelik bir değerlendirme daha yapılması uygun olacaktır. Tablo 4.2~Tablo 4.11’de yalnızca gözün yukarı ve kırpma sakkadik hareketleri için elde edilen uygunluk değerleri incelendiğinde en iyi uygunluk sonucunun basıklık özniteliğine ait olduğu görülmektedir. Bu noktadan hareketle %25 kırılmış ortalama özniteliği ile beraber basıklık özniteliğinin de sınıflandırma ve karar verme süreçlerinde kullanılmasının toplam başarımı arttıracığı öngörülmüştür. Bu öngörüye ilişkin deneysel sonuçlar ilerleyen bölümlerde verilmiştir.

4.5. Sınıflandırma

Son yıllarda gerçekleştirilen göz hareketlerine dayalı İBA ve İMA uygulamaları incelendiğinde eşik algılama, kNN, DPW, DTW, SVM, CNN, DNN, LDA, CT, FFNN gibi tekniklerin kullanıldığı görülmektedir. Bu çalışmada, sınıflandırma için YSA tercih edilmiştir. YSA, insan beyninin işleyişinden esinlenilerek oluşturulan matematiksel bir modelleme tekniğidir. Bu ağlar; karmaşık veri setlerindeki desenleri tanımak, sınıflandırmak, tahmin etmek ve diğer çeşitli görevleri yerine getirmek için

kullanılır. YSA, sinir hücrelerinin (nöronlar) birbirine bağlanmasıyla oluşan bir ağ yapısına sahiptir. Bu yapının temel birimi “nöron” olarak adlandırılır.

YSA’lar genellikle giriş katmanı, gizli katmanlar (isteğe bağlı) ve çıkış katmanı olmak üzere 3 katmandan oluşur. Gizli katmanlar, verinin işlendiği ve temsil edildiği katmanlardır.

YSA’lar veri setleri üzerinden öğrenme süreçlerini gerçekleştirirler. Bu öğrenme sürecindeki amaç, gerçek sonuçlar ile tahminler arasındaki farkı en aza indirmektir. Bu süreç “geri yayılım (backpropagation)” algoritması ile gerçekleştirilmektedir.

YSA’daki her nöron; girişleri alır, ağırlıklarla çarpar, bir aktivasyon fonksiyonu uygular ve bir çıktı üretir. Yaygın olarak kullanılan aktivasyon fonksiyonları sigmoid, ReLU (Rectified Linear Unit), Hiperbolik Tanjant (tanh) şeklinde sıralanabilir.

Sigmoid aktivasyon fonksiyonu; en çok kullanılan ve doğrusal olmayan fonksiyonlardan bir tanesidir. Olasılıksal bir yaklaşım ile karar verir ve 0 ile 1 arasında çıktılar üretir. Elde edilen çıktının hangi sınıfa ait olduğunu belirlemek için olasılıksal bir sonuç verir. Sigmoid fonksiyonu sürekli yani türevlenebilir bir fonksiyondur ve bu yüzden öğrenme süreçlerinde kullanılabilir. Sigmoid aktivasyon fonksiyonu Denklem 4.4’te verilmiştir.

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (4.4)$$

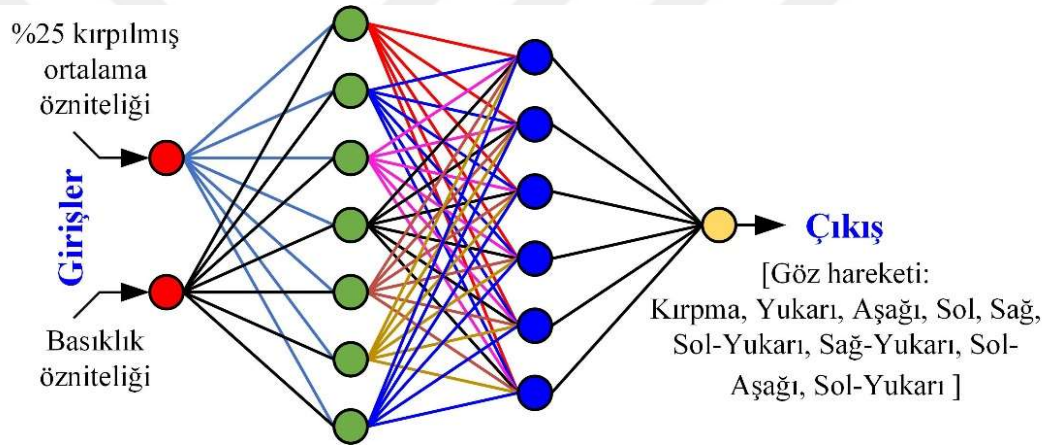
tanh aktivasyon fonksiyonu; sigmoid fonksiyonu ile benzer özellikler gösteren, giriş değerlerini alarak -1 ile 1 arasında değerler üreten, doğrusal olmayan bir fonksiyondur. tanh fonksiyonunun grafiği, x eksenine simetrik olan ve “S” şeklini andıran bir eğriye benzer. Bu fonksiyon özellikle çıkış katmanlarında ve bazı durumlarda gizli katmanlarda kullanılabilir. tanh aktivasyon fonksiyonu Denklem 4.5’te verilmiştir.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.5)$$

ReLU aktivasyon fonksiyonu derin öğrenme ve yapay sinir ağlarında kullanılan ve giriş değeri negatif ise 0, pozitif ise giriş değerini çıkış olarak veren bir fonksiyondur. Matematiksel olarak Denklem 4.6’daki gibi ifade edilir. ReLU fonksiyonunun grafiği x eksenini boyunca 0’dan başlayan ve pozitif yönde doğrusal artış gösteren bir fonksiyondur. Giriş değeri pozitif olduğunda ReLU fonksiyonunun türevi her zaman 1’dir. Bu, geriye yayılım esnasında gradyentin sabit kalmasına ve gradyent kaybolma probleminin azalmasına yardımcı olur.

$$ReLU(x) = \max(0, x) \quad (4.6)$$

Bu çalışmada; birinci katmanında 7, ikinci katmanında 6 nöron bulunan bir YSA modeli oluşturulmuş ve aktivasyon fonksiyonu olarak sigmoid fonksiyonu tercih edilmiştir. Tasarlanan YSA modeli Şekil 4.13'te verilmiştir. YSA modelinin giriş katmanında %25 kırılmış ortalama ve basıklık öznitelikleri yer almaktadır. Çıkış katmanı ise gözün dokuz farklı sakkadik hareketine karşılık tek bir çıktı üretmektedir. YSA'nın eğitimi aşamasında INTEL® Core™ i7-10750H CPU @2,6 GHz işlemciye ve 16 GB RAM'e sahip bir bilgisayar kullanılmıştır. Öznitelikler MATLAB platformuna aktarılmış ve "Classification Learner" bileşeni kullanılarak eğitim gerçekleştirilmiştir. Verilerin %70'i eğitim için, %30'u test için kullanılmıştır. Veri kümesinin eğitimi 7,8158 saniyede tamamlanmıştır.




Şekil 4.13: Tasarlanan YSA Modeli.

4.6. Sanal Klavye

Sanal klavye, çalışmanın karar sürecini oluşturmaktadır. Literatürdeki göz hareketine dayanan sanal klavye uygulamalarında kullanılan bir standart bulunmamaktadır. Araştırmacılardan bazıları özgün sanal klavyelerini tasarlayarak bunların ergonomisini araştırırken, bazı araştırmacılar da beyin bilgisayar arabirimi (BBA) uygulamalarında neredeyse standart haline gelmiş sanal klavye arayüzlerini tercih etmişlerdir.

Bu çalışmada beyin aktivitelerine dayalı sanal klavye uygulamalarında sıklıkla kullanılan P300 sanal klavye arayüzü tercih edilmiştir. Çalışma kapsamında; sakkadik göz hareketleri ile kontrol edilebilecek bir P300 sanal klavye için MATLAB platformunda bir grafik arayüzü tasarlanmıştır. Tasarlanan grafik arayüzüne ait görsel Şekil 4.14'te verilmiştir.



Şekil 4.14: Tasarlanan P300 Sanal Klavye Grafik Arayüzü.

5. DENEYSEL ÇALIŞMALAR

Tasarım aşamaları tamamlanan sistemin hedeflenen işlevleri gerçekleştirip gerçekleştirmediğine ve performansının test edilmesine yönelik olarak bazı deneysel çalışmalar gerçekleştirilmiştir. Deneysel çalışmalar 4 ana başlık altında irdelenmiştir. İlk olarak tasarlanan veri yakalama sisteminin performans testi gerçekleştirilmiş ve literatürdeki benzer çalışmalarda elde edilen kayıtlar ile karşılaştırmalar yapılmıştır. İkinci aşamada, GKO algoritması ile öznitelik seçimi için önerilen yöntemin geçerliliği test edilmiştir. Üçüncü aşamada, tasarlanan YSA modelinin sınıflandırma başarımına yönelik testler gerçekleştirilmiştir. Son bölümde ise geliştirilen göz hareketlerine dayalı sanal klavye ile metin oluşturmaya yönelik performans testleri uygulanmıştır. Dört aşamada ele alınan deneysel çalışmalar ve bu çalışmalar sonucu elde edilen veriler aşağıda sıralanmıştır.

5.1. Veri Toplama Sisteminin Test Edilmesi

Tasarlanarak prototip üretimi gerçekleştirilen veri toplama sisteminin giriş filtresi, analogtan sayısala çevirici, mikrodenetleyici ve kablosuz veri aktarma birimlerinden oluştuğundan daha önceki bölümlerde bahsedilmişti. Bu bölümde veri toplama sistemini oluşturan birimlerin fonksiyon testleri ve elde edilen kayıtların literatürde yer alan kayıtlar ile uyumluluğunun testi gerçekleştirilmiştir. Bu kapsamda ön test amacıyla 3 sağlıklı bireyin yüzüne Ag/AgCl elektrotlar Şekil 4.5'teki gibi yerleştirilmiş ve bireylere sakkadik göz hareketlerini yapmaları komutu verilmiştir. Ardından veri toplama sisteminden, veri toplama arayüzüne aktarılan veriler incelenmiştir.


Şekil 5.1 örnek bir test kaydını içermektedir. Şekil 5.1 (a)'da Hanning filtre ve DC seviye bastırma uygulanmayan örnek bir ham EOG verisi görülmektedir. Bu sinyal bir DC offset seviyesine ve gürültülere sahiptir.

Şekil 5.1 (b)'de DC seviye bastırma işlemi uygulanan, EOG kaydı görülmektedir. Şekil 5.1 (a)'daki yaklaşık 710 seviyelerindeki DC seviyenin bastırılarak referansın 0 seviyesine çekildiği görülmektedir. Ham verideki DC offset seviyesi ortamın ışık

şiddetine ve bireye göre değişiklik göstermektedir. Uygulanan DC offset bastırma ile bireyden ve ortam ışık şiddetinden bağımsız olarak 0 referans seviyesinde EOG işaretleri elde edilebilmektedir.

Şekil 5.1 (c)'de ise Hanning filtreleme işlemi uygulanan EOG kaydı görülmektedir. Şekil 5.1 (a) ve Şekil 5.1 (b)'de yoğun halde görülen gürültüler, uygulanan Hanning filtreleme işlemi sayesinde bastırılmış ve arzu edilen sinyal şekli elde edilmiştir.

3 sağlıklı bireyden elde edilen tüm kayıtlar birlikte değerlendirildiğinde, elde edilen kayıtların literatürdeki benzer çalışmalarda elde edilen kayıtlar ile uyumlu olduğu sonucuna ulaşılmıştır (Gürkan vd., 2016; López vd., 2023; Öner, 2019; Usakli vd., 2018; Usakli & Gurkan, 2010).



Şekil 5.1: Örnek Bir EOG Kaydı (a) Ham Veri (b) DC Seviye Bastırma İşlemi (c) Hanning Filtreleme İşlemi.

5.2. Öznitelik Seçim Sürecinin İncelenmesi

Bu bölümde, göz hareketine dayanan sanal klavye uygulamalarında öznitelik seçimi için önerilen GKO algoritmasının geçerliliği irdelenmiştir. Bu kapsamda Tablo 4.2 ~ Tablo 4.11 referans alınmış ve çalışmalara yön verilmiştir. Farklı öznitelikler için ortaya çıkan uygunluk değerlerinin incelenmesi neticesinde elde edilen en uygun MCC değerine %25 kırılmış ortalama özniteliğinin sahip olduğu, sınıflandırma başarımını arttırmak için bu özniteliğe ek olarak basıklık özniteliğinin de kullanımının faydalı olacağına dair tespit daha önceki bölümlerde aktarılmıştır. Bu önermenin doğruluğunu

test etmek için tasarlanan ve elde edilen öznitelikler ile eğitilen YSA modeli üzerinde bazı sınıflandırma çalışmaları gerçekleştirilmiştir.

Gerçekleştirilen ilk sınıflandırma çalışmasında öznitelik grupları tek tek sınıflandırma işlemine tabi tutulmuştur. Bu şekilde gerçekleştirilen bir sınıflandırma çalışmasında elde edilen karşıtlık matrisleri Tablo 5.1~Tablo 5.10'da verilmiştir. Elde edilen en iyi başarımların değerleri ise Tablo 5.11'de verilmiştir.

Tablo 5.1: Aritmetik Ortalama Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.

		Tahmin Edilen								
		□	↑	↓	↔	⇄	↖	↗	↘	↙
Doğru Sınıf	□	354	46							
	↑	51	349							
	↓			399						1
	↔				400					
	⇄					400				
	↖		1				399			
	↗							400		
	↘			1					399	
	↙									400

Tablo 5.2: Standart Sapma Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.

		Tahmin Edilen								
		□	↑	↓	↔	⇄	↖	↗	↘	↙
Doğru Sınıf	□	195	179	26						
	↑	91	261	48						
	↓	49	212	139						
	↔				308	92				
	⇄				236	164				
	↖						273	26	16	85
	↗						189	25	68	118
	↘						154	26	132	88
	↙			1		1	152	31	24	191

Tablo 5.3: Medyan Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.

		Tahmin Edilen								
		□	↑	↓	←	→	↖	↗	↘	↙
Doğru Sınıf	□	252	128		6	2	5	7		
	↑	12	372				6	10		
	↓	7		384					4	5
	←	13			374		6		7	
	→	9				373		10		8
	↖	4	6		9		381			
	↗	2	10			10		378		
	↘	1		8	9				382	
	↙	3		5		6				386

Tablo 5.4: %25 Kırpılmış Ortalama Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.

		Tahmin Edilen								
		□	↑	↓	←	→	↖	↗	↘	↙
Doğru Sınıf	□	382	17	1						
	↑	22	377					1		
	↓			399			1			
	←				399		1			
	→					399				1
	↖	2	1				397			
	↗					1		398		1
	↘	1					1		398	
	↙					1				399

Tablo 5.5: %50 Kırpılmış Ortalama Özniteliği ile Sınıflandırmada Karşıtlık Matrisi.

		Tahmin Edilen								
		□	↑	↓	←	→	↖	↗	↘	↙
Doğru Sınıf	□	384	11		3		2			
	↑	24	357	14			1	1	1	2
	↓		12	386					1	1
	←	6			394					
	→					400				
	↖	2	2				396			
	↗	1	2					397		
	↘		1	1	1				397	
	↙		3			1				396

Tablo 5.6: Maksimum Özniteliği ile Sınıflandırmada Karşılıklı Matrisi.

		Tahmin Edilen								
		□	↑	↓	←	→	↖	↗	↘	↙
Doğru Sınıf	□	277	76				47			
	↑	74	218				108			
	↓			141	93					166
	←			126	72					202
	→					276				124
	↖	35	104				261			
	↗					1		399		
	↘			3	2				395	
	↙					16				384

Tablo 5.7: Minimum Özniteliği ile Sınıflandırmada Karşılıklı Matrisi.

		Tahmin Edilen								
		□	↑	↓	←	→	↖	↗	↘	↙
Doğru Sınıf	□	22				139		239		
	↑	23	1			143		233		
	↓			283						117
	←				276		124			
	→	8				222		170		
	↖				90		310			
	↗	6	1			8		384		1
	↘								400	
	↙			70						330

Tablo 5.8: Çeyrekler Açıklığı Özniteliği ile Sınıflandırmada Karşılıklı Matrisi.

		Tahmin Edilen								
		□	↑	↓	←	→	↖	↗	↘	↙
Doğru Sınıf	□	396	3				1			
	↑	2	275	123						
	↓	3	187	210						
	←	4			281	113				2
	→	1			225	173		1		
	↖	1	1	1			223	36	54	84
	↗				1	1	148	50	92	108
	↘	1			1		114	40	162	82
	↙	3					115	41	45	196

Tablo 5.9: Ortalama Mutlak Sapma Özniteliği ile Sınıflandırmada Karşılık Matrisi.

		Tahmin Edilen								
		□	↑	↓	↔	⇒	↖	↗	↘	↙
Doğru Sınıf	□	301	88	11						
	↑	71	285	44						
	↓	41	223	135				1		
	↔				298	102				
	⇒				226	174				
	↖						280	24	16	80
	↗						199	40	68	93
	↘						161	33	144	62
	↙				1	1	172	24	27	175

Tablo 5.10: Basıklık Özniteliği ile Sınıflandırmada Karşılık Matrisi.

		Tahmin Edilen								
		□	↑	↓	↔	⇒	↖	↗	↘	↙
Doğru Sınıf	□	396	2	1	1					
	↑	1	199	109	21	11	8	8	41	2
	↓		181	124	31	13	7		44	
	↔		16	47	97	169	6	1	64	
	⇒		16	47	91	176	5	3	60	2
	↖		24	31	18	9	26	116	102	74
	↗		15	33	20	11	21	124	97	79
	↘		7	20	13	18	17	75	167	83
	↙	1	12	23	15	15	8	107	137	82

Tablo 5.11: YSA ile Sınıflandırmada Elde Edilen En İyi Başarı Değerleri.

Sınıflandırma Başarımı [%]									
Aritmetik Ortalama	Standart Sapma	Medyan	%25 Kırpılmış Ortalama	%50 Kırpılmış Ortalama	Maksimum	Minimum	Çeyrekler Açıklığı	Ortalama Mutlak Sapma	Basıklık
97,2	46,9	91,2	98,6	97,4	67,3	61,9	54,6	50,9	38,6

Tablo 5.1~Tablo 5.11 incelendiğinde en iyi başarımın %98,6 ile %25 kırılmış ortalama özniteliği için elde edildiği görülmektedir. %25 kırılmış ortalama özniteliğine ait karşıtlık matrisi incelendiğinde, %1,4'lük sınıflandırma başarısızlığındaki en önemli ağırlığın kırpma ve yukarı sakkadik göz hareketlerine ait olduğu ortaya çıkmaktadır. Bu noktada; sınıflandırma aşamasında %25 kırılmış ortalama özniteliğinin kullanımının daha uygun olacağı, ancak kırpma ve yukarı sakkadik göz hareketlerinin sınıflandırılmasında başarımı arttırmak için ilave bir özniteliğin daha kullanımının faydalı olacağı söylenebilir. Tablo 5.1~Tablo 5.10'daki karşıtlık matrislerinde yalnızca kırpma ve yukarı sakkadik göz hareketlerine ait başarımın incelendiğinde en iyi başarımın basıklık özniteliğine ait olduğu görülmektedir. Dolayısıyla %25 kırılmış ortalama ile basıklık özniteliklerinin birlikte kullanımının sınıflandırma başarımını arttıracığı öngörülmüştür. Bu öngörünün doğruluğunu desteklemek amacıyla, %25 kırılmış ortalama özniteliği ile birlikte kullanımında en iyi başarımın elde edildiği özniteliğin tespit edilmesi için bir çalışma gerçekleştirilmiştir. Çalışma kapsamında %25 kırılmış ortalama özniteliği, geriye kalan 9 farklı öznitelik ile ayrı ayrı YSA modelinin eğitiminde kullanılmış ve elde edilen sınıflandırma başarımaları irdelenmiştir. Elde edilen sonuçlar Tablo 5.12'de verilmiştir. Sonuç olarak en iyi sınıflandırma başarımı %25 kırılmış ortalama özniteliği ile basıklık özniteliğinin birlikte kullanıldığı durum için elde edilmiştir. Elde edilen bu sonuç çalışma öncesindeki öznitelik seçimindeki öngörüğü doğrular niteliktedir.

Tablo 5.12: %25 Kırılmış Ortalama Özniteliği ile Birlikte Farklı Özniteliklerin Kullanımının Sınıflandırma Başarımına Etkisi.

Sınıflandırma Başarımı [%]								
Aritmetik Ortalama	Standart Sapma	Medyan	%50 Kırılmış Ortalama	Maksimum	Minimum	Çeyrekler Açıklığı	Ortalama Mutlak Sapma	Basıklık
92,7	99,0	98,4	99,2	97,1	98,5	99,1	98,8	99,8

5.3. Sınıflandırma Başarımının İncelenmesi

Önceki bölümlerde, GKO algoritması kullanılarak seçilen özniteliklerin sınıflandırma başarımına yansıtıkları etkiler incelenmiştir. Bu bölümde ise sınıflandırma için belirlenen en uygun öznitelikler ile elde edilen %99,8'lik başarımın ayrıntıları ele alınmıştır.

Sınıflandırma aşamasında, tasarlanan YSA modeli %25 kırılmış ortalama ve basıklık öznitelikleri ile eğitilmiştir. Eğitim sonrasında gerçekleştirilen sınıflandırma çalışmalarında Tablo 5.13'te verilen karşılık matrisi elde edilmiştir. Tablo 5.13 incelendiğinde 3600 sakkadik göz hareketinden 3592 adedinin doğru, 8 adedinin hatalı sınıflandırıldığı görülmektedir. Yalnız başına %25 kırılmış ortalama özniteliği kullanılması ile elde edilen %98,6'lık sınıflandırma başarımının basıklık özniteliğinin sürece dâhil edilmesi ile %99,8'e çıkarılması önemli bir sonuçtur. Ayrıca basıklık özniteliğinin sürece dâhil edilmesi ile yukarı ve kırma sakkadik göz hareketlerinin tespit başarımı önemli bir artış göstermiştir. Elde edilen bu sonuçlar, çalışmanın "Giriş" bölümünde oluşturulan "EOG işaretleri için en uygun özniteliklerin belirlenmesi için metasezgisel bir algoritma olan gri kurt optimizasyon (GKO) algoritması kullanılarak sınıflandırma başarımı artırılabilir" hipotezini doğrulamaktadır.

Tablo 5.13: %25 Kırılmış Ortalama ve Basıklık Öznitelikleri ile Gerçekleştirilen Sınıflandırma için Elde Edilen Karşılık Matrisi.

		Tahmin Edilen								
		□	↑	↓	←	→	↖	↗	↘	↙
Doğru Sınıf	□	398					2			
	↑		399			1				
	↓			399					1	
	←				399				1	
	→					400				
	↖						400			
	↗							400		
	↘				1				399	
	↙	1				1				398

5.4. Gz Hareketlerine Dayalı Sanal Klavye Uygulamasının İncelenmesi

Gz hareketlerine dayalı sanal klavye uygulaması deneyleri kapsamında, eđitilen YSA modelinin yrtldđ ve MATLAB platformunda tasarlanan bir grafik arayz kullanılmıř ve literatrde sıklıkla kullanılan karakter komutlarının yazımı ile ilgili alıřmalar gerekleřtirilmiřtir. Geliřtirilen arayze iliřkin grsel daha nce Őekil 4.14'te verilmiřti.

Gerekleřtirilen ilk deneysel alıřmada YSA modelinin eđitiminde kullanılmayan ve gerek zamanlı elde edilen sakkadik gz hareketleri ile sanal klavyenin bařarım testi gerekleřtirilmiřtir. Bu kapsamda sanal klavye grafik arayznn alıřtıđı bilgisayar ekranı karřısına konumlandırılan bireylerden istenilen karakterleri gz hareketleri ile semeleri istenmiřtir. Gerek zamanlı gerekleřtirilen bu deneyde, 5 bireye verilen 500 farklı komutun %99,6 bařarım ile seilebildiđi sonucuna ulařılmıřtır. Bu deneyde ve ařađıdaki deneylerde kullanılan 5 bireyin yařları 24 ile 28 arasında deđiřmektedir ve daha nce kayıtları alınan bireylerden farklı kiřilerdir.

Diđer bir deneysel alıřmada sanal klavye grafik arayznn alıřtıđı bilgisayar ekranı karřısına konumlandırılan bireylerden gz hareketleri ile bir metin yazmaları istenmiřtir. Seilmek istenen karakter iin 3 defa art arda gz kırpması onay komutu olarak algılanmaktadır. Sanal klavye zerinde istenilen karaktere gz hareketleri ile ulařıldıktan sonra gzn 3 defa kırılması ile karakter seimi gerekleřmektedir. Bu deney sonucunda literatrde sıklıkla karřılařılan bazı İngilizce ve Trke metinlerin yazımına iliřkin elde edilen yazım sreleri birey bazında Tablo 5.14'te verilmiřtir. Yazım srelerinin ortalama deđerleri ile literatrde yer alan yazım srelerinin karřılařtırılması ise Tablo 5.15'te verilmiřtir. Tablo 5.15 incelendiđinde bu alıřma ile nerilen yntem ile belirlenen kelimelerin yazımında literatr ortalamalarına gre daha iyi yazım sreleri elde edildiđi grlmektedir. Yine Tablo 5.14'te yer alan yazım sreleri ve kelimeleri oluřturan harf sayıları gz nnde bulundurulduđunda geliřtirilen sanal klavye ile 14,7 harf/dakika yazım hızı elde edilmiřtir.

Tablo 5.14: Metin Yazım Hızı Deney Sonuçları.

Metin Komutu	Yazım Süreleri [saniye]														
	Birey 1			Birey 2			Birey 3			Birey 4			Birey 5		
WATER	18,8	20,2	19,2	23,4	20,8	19,9	24,4	24,4	23,2	25,2	22,9	24,9	28,3	28,7	28,1
HELLO	15,2	14,8	16,7	18,3	16,3	17,1	18,1	19,4	18,3	18,7	20,8	18,1	21,4	18,1	20,5
HELLO WORLD	35,4	35,8	36,8	38,4	40,2	38,9	41,3	39,9	41,0	46,5	46,0	42,6	48,2	43,9	50,2
GOOD	11,4	11,4	12,3	13,3	12,6	14,0	13,0	12,8	11,9	14,6	14,2	14,0	14,6	16,4	15,7
HAYIR	18,2	16,6	15,8	17,8	17,3	18,4	19,1	18,5	18,0	23,7	21,5	22,3	20,6	23,9	25,0
UYKU	14,7	13,6	15,1	15,4	14,7	15,9	15,9	17,4	16,0	18,4	16,5	18,3	19,6	19,3	18,3
GOOD MORNING	43,2	43,1	42,7	42,5	42,0	44,3	46,7	45,6	47,0	50,1	47,1	52,4	52,5	53,7	51,7
WELCOME	25,0	27,3	27,8	27,7	28,9	26,4	26,6	30,9	29,8	30,2	35,5	33,8	33,2	31,4	34,0
GOOD DAY	31,3	31,5	32,2	34,6	32,3	31,2	37,0	37,5	39,0	38,7	39,1	38,6	47,5	47,8	41,7
ORANGE_JUICE	45,3	44,0	41,3	45,3	46,4	46,7	49,7	52,7	50,7	55,3	53,4	53,8	57,5	55,1	56,0

Tablo 5.15: Metin Yazım Hızı Ortalamaları ve Literatür Karşılaştırması.

Metin Komutu	Yazım Süresi [saniye]	
	Literatürde	Bu Çalışmada
WATER	25 (Usakli & Gurkan, 2010) 32 (Hou & Smitha, 2018)	23,5
HELLO	72,2 (Tangsuksant vd., 2012) 52 (Bastos vd., 2018) 25,2 (Barbara vd., 2019)	18,1
HELLO WORLD	98 (Hou & Smitha, 2018)	41,7
GOOD	110 (Hou & Smitha, 2018)	13,5
HAYIR	53,3 (Ekim vd., 2023)	19,8
UYKU	43,8 (Ekim vd., 2023)	16,6
GOOD MORNING	175 (Bastos vd., 2018)	47,0
WELCOME	110 (Bastos vd., 2018)	29,9
GOOD DAY	40,3 (Barbara vd., 2019)	37,3
ORANGE_JUICE	66,5 (Buchwald & Jukiewicz, 2017)	50,2

6. SONUÇ

Göz hareketlerine dayanan bir sanal klavye uygulamasının gerçekleştirildiği bu çalışmada düşük maliyetli bir EOG veri toplama sistemi tasarlanarak prototip üretimi gerçekleştirilmiş, 20 bireyden toplanan kayıtlar ile 10 farklı özniteliğin çıkarımı yapılmıştır. Elde edilen özniteliklerden en uygun olanın belirlenmesi için GKO algoritmasından faydalanılmıştır. En iyi uygunluk değerinin elde edildiği öznitelikler ile tasarlanan bir YSA'nın eğitimi gerçekleştirilmiştir. Eğitilen YSA modeli, P300 sanal klavye arayüzü içeren bir MATLAB grafik arayüz uygulamasında kullanılmıştır. Bütün bu çalışmalar neticesinde elde edilen en önemli sonuçlar aşağıda maddeler halinde sıralanmıştır.

- Tasarlanarak üretimi gerçekleştirilen EOG veri toplama sisteminden elde edilen kayıtlar, literatürde aynı amaç için gerçekleştirilen benzer sistemlerin kayıtları ile uyumludur.
- Elde edilen EOG kayıtları sınıflandırılabilir ve bir karar verme sisteminde kullanılabilir. Bu sayede göz hareketlerine dayanan yeni İBA ve İMA uygulamaları geliştirilebilir.
- EOG kayıtlarından elde edilen ve istatistiksel hesaplamalara dayanan özniteliklerden hangisinin sınıflandırma performansının daha iyi olacağı doğrudan tespit edilememektedir. Bu çalışmada en uygun özniteliğin belirlenmesi için GKO algoritması kullanılmış ve %25 kırılmış ortalama özniteliği en uygun sonucu vermiştir. Bu aşamada elde edilen sınıflandırma başarımları %98,6 elde edilmiştir.
- GKO algoritması ile elde edilen uygunluk değerleri tekrar incelendiğinde yukarı ve kırpma sınıflarına ait başarımları arttırmak için basıklık özniteliğinin de sınıflandırmaya dâhil edilmesinin uygun olacağı tespit edilmiştir. %25 kırılmış ortalama ve basıklık özniteliklerinin birlikte kullanıldığı YSA'na dayalı sınıflandırmada %99,8 sınıflandırma başarımları elde edilmiştir.

- Göz hareketine dayanan sınıflandırma problemlerinin öznitelik seçimi aşamasında GKO algoritmasının verimli şekilde kullanılabileceği sonucuna ulaşılmıştır.
- Belirlenen öznitelikler ile eğitilen YSA modeli P300 sanal klavye arayüzü içeren bir MATLAB uygulamasında çalıştırıldığında göz hareketleri ile kelimeler oluşturmak mümkün olmaktadır.
- Kullanılan veri kümesi, öznitelikler, sınıflandırma metodu ve sanal klavye ile 14,7 harf/dakika karakter yazım hızına ulaşılmıştır.



KAYNAKÇA

- Adam, A., Shapiyai, M. I., Mohd Tumari, M. Z., Mohamad, M. S., & Mubin, M. (2014). Feature selection and classifier parameters estimation for EEG signals peak detection using particle swarm optimization. *Scientific World Journal*, 2014. <https://doi.org/10.1155/2014/973063>
- Alagöz, A., & Kutlu, M. (2012). Parçacık Sürü Optimizasyonu Yaklaşımı ile Emtia Piyasasında Portföy Optimizasyonu. *Sosyal Ekonomik Araştırmalar Dergisi*, 12(23), 35–50. <https://dergipark.org.tr/tr/pub/susead/issue/28412/302329>
- Alsattar, H. A., Zaidan, A. A., & Zaidan, B. B. (2020). Novel meta-heuristic bald eagle search optimisation algorithm. *Artificial Intelligence Review*, 53(3), 2237–2264. <https://doi.org/10.1007/S10462-019-09732-5/METRICS>
- Aungsakun, S., Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2011). Robust eye movement recognition using EOG signal for human-computer interface. *Communications in Computer and Information Science*, 180 CCIS(PART 2), 714–723. https://doi.org/10.1007/978-3-642-22191-0_63/COVER
- Banerjee, A., Datta, S., Pal, M., Konar, A., Tibarewala, D. N., & Janarthanan, R. (2013). Classifying Electrooculogram to Detect Directional Eye Movements. *Procedia Technology*, 10, 67–75. <https://doi.org/10.1016/J.PROTCY.2013.12.338>
- Barbara, N., Camilleri, T. A., & Camilleri, K. P. (2019). EOG-based eye movement detection and gaze estimation for an asynchronous virtual keyboard. *Biomedical Signal Processing and Control*, 47, 159–167. <https://doi.org/10.1016/J.BSPC.2018.07.005>
- Barea, R., Boquete, L., Mazo, M., & López, E. (2002). System for assisted mobility using eye movements based on electrooculography. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 10(4), 209–218. <https://doi.org/10.1109/TNSRE.2002.806829>
- Bastos, A., Alhat, S., & Panse, M. S. (2018). Speech Assistive Communication System Using EOG. *Proceedings of the 2nd International Conference on Intelligent Computing and Control Systems, ICICCS 2018*, 504–510. <https://doi.org/10.1109/ICCONS.2018.8663158>
- Basturk, B., & Karaboga, D. (2006). *An artificial bee colony (ABC) algorithm for numeric function optimization*.
- Belkhiria, C., & Peysakhovich, V. (2020). Electro-Encephalography and Electro-Oculography in Aeronautics: A Review Over the Last Decade (2010–2020). *Frontiers in Neuroergonomics*, 1, 606719. <https://doi.org/10.3389/FNRGO.2020.606719>
- Belkhiria, C., & Peysakhovich, V. (2021). EOG metrics for cognitive workload detection. *Procedia Computer Science*, 192, 1875–1884.

- Buchwald, M., & Jukiewicz, M. (2017). Project and evaluation EMG/EOG human-computer interface. *Przeglad Elektrotechniczny*, 93(7), 128–131. <https://doi.org/10.15199/48.2017.07.28>
- Bulling, A., Roggen, D., & Tröster, G. (2009). Wearable EOG goggles: Seamless sensing and context-awareness in everyday environments. *Journal of Ambient Intelligence and Smart Environments*, 1(2), 157–171. <https://doi.org/10.3233/AIS-2009-0020>
- Çavuş, V., & Tuncer, A. (2017). İnsansız Hava Araçları İçin Yapay Arı Kolonisi Algoritması Kullanarak Rota Planlama. *Karaelmas Fen ve Mühendislik Dergisi*, 7(1), 259–265. <http://fbd.beun.edu.tr>
- Celal, C., Kaya, Y., & Kılıç, F. (2021). Salp Sürü Algoritması ile Öznitelik Seçimi ve Sınıflandırıcı Performans Değerlendirmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 30(30), 12–16. <https://doi.org/10.31590/EJOSAT.1005417>
- Chang, W. Du, Cha, H. S., Kim, D. Y., Kim, S. H., & Im, C. H. (2017). Development of an electrooculogram-based eye-computer interface for communication of individuals with amyotrophic lateral sclerosis. *Journal of NeuroEngineering and Rehabilitation*, 14(1), 1–13. <https://doi.org/10.1186/S12984-017-0303-5/TABLES/2>
- Dada, E. G., Joseph, S. B., Oyewola, D. O., Fadele, A. A., Chiroma, H., & Abdulhamid, S. M. (2022). Application of Grey Wolf Optimization Algorithm: Recent Trends, Issues, and Possible Horizons. *Gazi University Journal of Science*, 35(2), 485–504. <https://doi.org/10.35378/GUJS.820885>
- Dhiman, G., & Kumar, V. (2017). Spotted hyena optimizer: A novel bio-inspired based metaheuristic technique for engineering applications. *Advances in Engineering Software*, 114, 48–70. <https://doi.org/10.1016/J.ADVENGSOFT.2017.05.014>
- Ding, X. J., & Lv, Z. (2020). Design and development of an EOG-based simplified Chinese eye-writing system. *Biomedical Signal Processing and Control*, 57, 101767. <https://doi.org/10.1016/J.BSPC.2019.101767>
- Diwan, P. (2016). Energy Efficient Communication for WSNs using Grey-Wolf Optimization Algorithm. *International Journal Of Engineering And Computer Science*, 5(12).
- Dorigo, M. (1992). *Optimization, learning and natural algorithms*. Politecnico di Milano.
- Duan, H., & Qiao, P. (2014). Pigeon-inspired optimization: A new swarm intelligence optimizer for air robot path planning. *International Journal of Intelligent Computing and Cybernetics*, 7(1), 24–37. <https://doi.org/10.1108/IJICC-02-2014-0005/FULL/XML>
- Ekim, G., Atasoy, A., & İkizler, N. (2021). A new approach for eye-blink to speech conversion by dynamic time warping. *Traitement Du Signal*, 38(2), 369–377. <https://doi.org/10.18280/TS.380214>
- Ekim, G., İkizler, N., & Atasoy, A. (2023). A Study on Eye-Blink Detection-Based Communication System by Using K-Nearest Neighbors Classifier. *Advances in Electrical and Computer Engineering*, 23(1), 71–78. <https://doi.org/10.4316/AECE.2023.01008>
- Emary, E., Yamany, W., Hassanien, A. E., & Snel, V. (2015). Multi-Objective Gray-

- Wolf Optimization for Attribute Reduction. *Procedia Computer Science*, 65, 623–632. <https://doi.org/10.1016/J.PROCS.2015.09.006>
- Eren Şenaras, A., & İnanç, Ş. (2017). GSP Çözümü İçin Karınca Kolonisi Optimizasyonu. *Sosyal Bilimler Metinleri*, 2017(2), 58–67. <https://dergipark.org.tr/tr/pub/sbm/issue/47253/595285>
- Fang, F., & Shinozaki, T. (2018). Electrooculography-based continuous eye-writing recognition system for efficient assistive communication systems. *PLOS ONE*, 13(2), e0192684. <https://doi.org/10.1371/JOURNAL.PONE.0192684>
- Findling, R. D., Quddus, T., & Sigg, S. (2019a). Hide my Gaze with EOG!: Towards Closed-Eye Gaze Gesture Passwords that Resist Observation-Attacks with Electrooculography in Smart Glasses. *ACM International Conference Proceeding Series*, 107–116. <https://doi.org/10.1145/3365921.3365922>
- Findling, R. D., Quddus, T., & Sigg, S. (2019b). Hide my Gaze with EOG!: Towards Closed-Eye Gaze Gesture Passwords that Resist Observation-Attacks with Electrooculography in Smart Glasses. *ACM International Conference Proceeding Series*, 107–116. <https://doi.org/10.1145/3365921.3365922>
- Gulyás, S. (2016). Electro-oculography (EOG) examination of eye movements. *Neuro-Ophthalmology*, 287–293.
- Gürkan, S., Öner, P. A., Istanbulu, A., & Doğan, S. (2016). İnsan Bilgisayar Arabirim Uygulamaları için Taşınabilir Elektrokülogram Veri Yakalama Sistemi Tasarımı. *2015 Medical Technologies National Conference, TIPTEKNO 2015*. <https://doi.org/10.1109/TIPTEKNO.2015.7374106>
- Hao, R., Luo, D., & Duan, H. (2015). Multiple UAVs mission assignment based on modified Pigeon-inspired optimization algorithm. *2014 IEEE Chinese Guidance, Navigation and Control Conference, CGNCC 2014*, 2692–2697.
- He, S., Tan, H., Li, Y., Zhou, Y., Yu, T., Zhang, R., Huang, Q., Chuai, L., Mustafa, M. U., Gu, Z., & Yu, Z. L. (2020). EEG- And EOG-Based Asynchronous Hybrid BCI: A System Integrating a Speller, a Web Browser, an E-Mail Client, and a File Explorer. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(2), 519–530. <https://doi.org/10.1109/TNSRE.2019.2961309>
- Heo, J., Yoon, H., & Park, K. S. (2017). A Novel Wearable Forehead EOG Measurement System for Human Computer Interfaces. *Sensors 2017, Vol. 17, Page 1485*, 17(7), 1485. <https://doi.org/10.3390/S17071485>
- Hernández-Ocaña, B., Hernández-Torruco, J., Chávez-Bosquez, O., Calva-Yáñez, M. B., & Portilla-Flores, E. A. (2019). Bacterial Foraging-Based Algorithm for Optimizing the Power Generation of an Isolated Microgrid. *Applied Sciences 2019, Vol. 9, Page 1261*, 9(6), 1261. <https://doi.org/10.3390/APP9061261>
- Hossieny, R. R., Tantawi, M., Shedeed, H., & Tolba, M. F. (2023). Development of electrooculogram based human computer interface system using deep learning. *Bulletin of Electrical Engineering and Informatics*, 12(4), 2410–2420. <https://doi.org/10.11591/EEI.V12I4.5591>
- Hou, H. K., & Smitha, K. G. (2018). Low-Cost Wireless Electrooculography Speller. *Proceedings - 2018 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2018*, 123–128. <https://doi.org/10.1109/SMC.2018.00032>
- Hu, P., Pan, J. S., & Chu, S. C. (2020). Improved Binary Grey Wolf Optimizer and Its

- application for feature selection. *Knowledge-Based Systems*, 195, 105746. <https://doi.org/10.1016/J.KNOSYS.2020.105746>
- Hua, Z., Xiao, Y., & Cao, J. (2021). Misalignment Fault Prediction of Wind Turbines Based on Improved Artificial Fish Swarm Algorithm. *Entropy* 2021, Vol. 23, Page 692, 23(6), 692. <https://doi.org/10.3390/E23060692>
- Huang, Q., Zhang, Z., Yu, T., He, S., & Li, Y. (2019). An EEG-/EOG-Based Hybrid Brain-Computer Interface: Application on Controlling an Integrated Wheelchair Robotic Arm System. *Frontiers in Neuroscience*, 13, 459140. <https://doi.org/10.3389/FNINS.2019.01243/BIBTEX>
- Jain, U., Tiwari, R., & Godfrey, W. W. (2018). Odor source localization by concatenating particle swarm optimization and grey wolf optimizer. *Advances in Intelligent Systems and Computing*, 706, 145–153. https://doi.org/10.1007/978-981-10-8237-5_14/COVER
- Karakaş, M. (2020). *Sınıflandırma Problemlerine Özellik Seçimi İçin Karşıtlık Tabanlı Gri Kurt Optimizasyon Algoritması*. Bilecik Şeyh Edebali Üniversitesi.
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, 4, 1942–1948. <https://doi.org/10.1109/ICNN.1995.488968>
- Koc, I., Kaan Baykan, O., & Babaoglu, I. (2018). Gri kurt optimizasyon algoritmasına dayanan çok seviyeli imge eşik seçimi. *POLİTEKNİK DERGİSİ JOURNAL*, 21(4), 841–847. <https://doi.org/10.2339/politeknik.389613>
- Krishnanand, K. N., & Ghose, D. (2009). Glowworm swarm optimization for simultaneous capture of multiple local optima of multimodal functions. *Swarm Intelligence*, 3(2), 87–124. <https://doi.org/10.1007/S11721-008-0021-5/METRICS>
- Li, Q., Chen, H., Huang, H., Zhao, X., Cai, Z. N., Tong, C., Liu, W., & Tian, X. (2017). An Enhanced Grey Wolf Optimization Based Feature Selection Wrapped Kernel Extreme Learning Machine for Medical Diagnosis. *Computational and Mathematical Methods in Medicine*, 2017. <https://doi.org/10.1155/2017/9512741>
- Li, X., Shao, Z., Qian, J., & Li, X. (2002). An Optimizing Method Based on Autonomous Animats: Fish-swarm Algorithm. *Systems Engineering - Theory & Practice*, 22(11), 32–38. [https://doi.org/10.12011/1000-6788\(2002\)11-32](https://doi.org/10.12011/1000-6788(2002)11-32)
- López, A., Ferrero, F., Villar, J. R., & Postolache, O. (2020). High-Performance Analog Front-End (AFE) for EOG Systems. *Electronics* 2020, Vol. 9, Page 970, 9(6), 970. <https://doi.org/10.3390/ELECTRONICS9060970>
- López, A., Villar, J. R., Fernández, M., & Ferrero, F. J. (2023). Comparison of classification techniques for the control of EOG-based HCIs. *Biomedical Signal Processing and Control*, 80, 104263. <https://doi.org/10.1016/J.BSPC.2022.104263>
- Lu, C., Xiao, S., Li, X., & Gao, L. (2016). An effective multi-objective discrete grey wolf optimizer for a real-world scheduling problem in welding production. *Advances in Engineering Software*, 99, 161–176. <https://doi.org/10.1016/J.ADVENGSOFT.2016.06.004>
- Maragheh, H. K., Gharehchopogh, F. S., Majidzadeh, K., & Sangar, A. B. (2022). A New Hybrid Based on Long Short-Term Memory Network with Spotted Hyena

- Optimization Algorithm for Multi-Label Text Classification. *Mathematics* 2022, Vol. 10, Page 488, 10(3), 488. <https://doi.org/10.3390/MATH10030488>
- Marinaki, M., & Marinakis, Y. (2016). A Glowworm Swarm Optimization algorithm for the Vehicle Routing Problem with Stochastic Demands. *Expert Systems with Applications*, 46, 145–163. <https://doi.org/10.1016/J.ESWA.2015.10.012>
- Medjahed, S. A., Ait Saadi, T., Benyettou, A., & Ouali, M. (2016). Gray Wolf Optimizer for hyperspectral band selection. *Applied Soft Computing*, 40, 178–186. <https://doi.org/10.1016/J.ASOC.2015.09.045>
- Mehrabian, A. R., & Lucas, C. (2006). A novel numerical optimization algorithm inspired from weed colonization. *Ecological Informatics*, 1(4), 355–366. <https://doi.org/10.1016/J.ECOINF.2006.07.003>
- Mirjalili, S., Gandomi, A. H., Mirjalili, S. Z., Saremi, S., Faris, H., & Mirjalili, S. M. (2017). Salp Swarm Algorithm: A bio-inspired optimizer for engineering design problems. *Advances in Engineering Software*, 114, 163–191. <https://doi.org/10.1016/J.ADVENGSOFT.2017.07.002>
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46–61. <https://doi.org/10.1016/J.ADVENGSOFT.2013.12.007>
- Mostafa, A., Fouad, A., Houseni, M., Allam, N., Hassanien, A. E., Hefny, H., & Aslanishvili, I. (2017). A hybrid grey wolf based segmentation with statistical image for CT liver images. *Advances in Intelligent Systems and Computing*, 533, 846–855. https://doi.org/10.1007/978-3-319-48308-5_81/COVER
- Mulam, H., & Mudigonda, M. (2020). EOG-based eye movement recognition using GWO-NN optimization. *Biomedizinische Technik*, 65(1), 11–22. <https://doi.org/10.1515/BMT-2018-0109/MACHINEREADABLECITATION/RIS>
- Muro, C., Escobedo, R., Spector, L., & Coppinger, R. P. (2011). Wolf-pack (*Canis lupus*) hunting strategies emerge from simple rules in computational simulations. *Behavioural Processes*, 88(3), 192–197. <https://doi.org/10.1016/J.BEPROC.2011.09.006>
- Murugan, S., Sivakumar, P. K., Kavitha, C., Harichandran, A., & Lai, W. C. (2023). An Electro-Oculogram (EOG) Sensor's Ability to Detect Driver Hypovigilance Using Machine Learning. *Sensors* 2023, Vol. 23, Page 2944, 23(6), 2944. <https://doi.org/10.3390/S23062944>
- Ohya, T., & Kawasumi, M. (2005). Development of an Input Operation for the Amyotrophic Lateral Sclerosis Communication Tool Utilizing EOG. *Transactions of Japanese Society for Medical and Biological Engineering*, 43(1), 172–178. <https://doi.org/doi.org/10.11239/jsmbe.43.172>
- Öner, P. A. (2019). *İnsan-Makine Arabirimi Uygulamaları İçin Çok Kanallı Bir Biyosinyal Ölçüm Sisteminin Geliştirilmesi*. Balıkesir Üniversitesi.
- Özyön, S., Yaşar, C., & Temurtaş, H. (2020). Test Fonksiyonları için Kaos Tabanlı Yerçekimsel Arama Algoritmaları (CbGSA-X). *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 8(3), 1771–1793.
- Pan, W. T. (2012). A new Fruit Fly Optimization Algorithm: Taking the financial distress model as an example. *Knowledge-Based Systems*, 26, 69–74.

<https://doi.org/10.1016/J.KNOSYS.2011.07.001>

- Passino, K. M. (2002). Biomimicry of Bacterial Foraging for Distributed Optimization and Control. *IEEE Control Systems*, 22(3), 52–67. <https://doi.org/10.1109/MCS.2002.1004010>
- Perez Reynoso, F. D., Niño Suarez, P. A., Aviles Sanchez, O. F., Calva Yañez, M. B., Vega Alvarado, E., & Portilla Flores, E. A. (2020). A Custom EOG-Based HMI Using Neural Network Modeling to Real-Time for the Trajectory Tracking of a Manipulator Robot. *Frontiers in Neurorobotics*, 14, 578834. <https://doi.org/10.3389/FNBOT.2020.578834/BIBTEX>
- Pinto, R., & Gonçalves, G. (2022). Application of Artificial Immune Systems in Advanced Manufacturing. *Array*, 15, 100238.
- Pleshkov, M., Zaitsev, V., Starkov, D., Demkin, V., Kingma, H., & van de Berg, R. (2022). Comparison of EOG and VOG obtained eye movements during horizontal head impulse testing. *Frontiers in Neurology*, 13, 917413. <https://doi.org/10.3389/FNEUR.2022.917413/BIBTEX>
- Pradhan, M., Roy, P. K., & Pal, T. (2016). Grey wolf optimization applied to economic load dispatch problems. *International Journal of Electrical Power & Energy Systems*, 83, 325–334. <https://doi.org/10.1016/J.IJEPES.2016.04.034>
- Pratomo, M. R., Irianto, B. G., Triwiyanto, T., Utomo, B., Setioningsih, E. D., & Titisari, D. (2020). Prosthetic hand with 2-dimensional motion based EOG signal control. *IOP Conference Series: Materials Science and Engineering*, 850(1), 012024. <https://doi.org/10.1088/1757-899X/850/1/012024>
- Ramakrishnan, J., Doss, R., Palaniswamy, T., Faqihi, R., Fathima, D., & Srinivasan, K. (2022). High performance computation of human computer interface for neurodegenerative individuals using eye movements and deep learning technique. *Journal of Supercomputing*, 78(2), 2772–2792. <https://doi.org/10.1007/S11227-021-03932-Z/METRICS>
- Rashedi, E., Nezamabadi-pour, H., & Saryazdi, S. (2009). GSA: A Gravitational Search Algorithm. *Information Sciences*, 179(13), 2232–2248. <https://doi.org/10.1016/J.INS.2009.03.004>
- Rezaei, M., Mohammadi, H., & Khazaie, H. (2017). EEG/EOG/EMG data from a cross sectional study on psychophysiological insomnia and normal sleep subjects. *Data in Brief*, 15, 314–319. <https://doi.org/10.1016/J.DIB.2017.09.033>
- Sahoo, A., & Chandra, S. (2017). Multi-objective Grey Wolf Optimizer for improved cervix lesion classification. *Applied Soft Computing*, 52, 64–80. <https://doi.org/10.1016/J.ASOC.2016.12.022>
- Saravanakumar, D., & Ramasubba Reddy, M. (2020). A virtual speller system using SSVEP and electrooculogram. *Advanced Engineering Informatics*, 44, 101059.
- Saravanakumar, D., & Reddy, M. R. (2020). A virtual speller system using SSVEP and electrooculogram. *Advanced Engineering Informatics*, 44, 101059.
- Shi, K., Zhang, X., & Xia, S. (2020). Multiple Swarm Fruit Fly Optimization Algorithm Based Path Planning Method for Multi-UAVs. *Applied Sciences* 2020, Vol. 10, Page 2822, 10(8), 2822. <https://doi.org/10.3390/APP10082822>
- Song, X., Tang, L., Zhao, S., Zhang, X., Li, L., Huang, J., & Cai, W. (2015). Grey

- Wolf Optimizer for parameter estimation in surface waves. *Soil Dynamics and Earthquake Engineering*, 75, 147–157. <https://doi.org/10.1016/J.SOILDYN.2015.04.004>
- Sreedharan, N. P. N., Ganesan, B., Raveendran, R., Sarala, P., Dennis, B., & Rajakumar Boothalingam, R. (2018). Grey Wolf optimisation-based feature selection and classification for facial emotion recognition. *IET Biometrics*, 7(5), 490–499. <https://doi.org/10.1049/IET-BMT.2017.0160>
- Srivastava, S., & Sahana, S. K. (2019). Application of Bat Algorithm for Transport Network Design Problem. *Applied Computational Intelligence and Soft Computing*, 2019. <https://doi.org/10.1155/2019/9864090>
- Tangsuksant, W., Aekmunkhongpaisal, C., Cambua, P., Charoenpong, T., & Chanwimalueang, T. (2012). Directional eye movement detection system for virtual keyboard controller. *5th 2012 Biomedical Engineering International Conference, BMEiCON 2012*. <https://doi.org/10.1109/BMEiCON.2012.6465432>
- Tao, L., Huang, H., Chen, C., Feijs, L., Hu, J., & Chen, W. (2023). Review of electrooculography-based human-computer interaction: recent technologies, challenges and future trends. *Connected Health And Telemedicine*, 2(3), null-null. <https://doi.org/10.20517/CHATMED.2023.05>
- Timmis, J., Andrews, P., & Hart, E. (2010). On artificial immune systems and swarm intelligence. *Swarm Intelligence*, 4(4), 247–273. <https://doi.org/10.1007/S11721-010-0045-5/METRICS>
- Tu, Q., Chen, X., & Liu, X. (2019). Multi-strategy ensemble grey wolf optimizer and its application to feature selection. *Applied Soft Computing*, 76, 16–30. <https://doi.org/10.1016/J.ASOC.2018.11.047>
- Tuerxun, W., Xu, C., Guo, H., Guo, L., & Yin, L. (2022). Fault classification in wind turbine based on deep belief network optimized by modified tuna swarm optimization algorithm. *Journal of Renewable and Sustainable Energy*, 14(3). <https://doi.org/10.1063/5.0092379/2845495>
- Ülkütaş, H. Ö. (2015). *EOG'nin Kodlanmasına Dayanan Bilgisayar Tabanlı Gözle Yazı Yazma Sistemi Geliştirilmesi*. Başkent Üniversitesi.
- Usakli, A. B., & Gurkan, S. (2010). Design of a novel efficient humancomputer interface: An electrooculagram based virtual keyboard. *IEEE Transactions on Instrumentation and Measurement*, 59(8), 2099–2108. <https://doi.org/10.1109/TIM.2009.2030923>
- Usakli, A. B., Gurkan, S., Gurkan, G., & Kaya, A. (2018). A novel EOG-based wireless rapid communication device for people with motor neuron diseases. *Journal of Medical Engineering & Technology*, 42(6), 420–425.
- Vidal, M., Bulling, A., & Gellersen, H. (2011). Analysing EOG signal features for the discrimination of eye movements with wearable devices. *PETMEI'11 - Proceedings of the 1st International Workshop on Pervasive Eye Tracking and Mobile Eye-Based Interaction*, 15–20. <https://doi.org/10.1145/2029956.2029962>
- Wolpert, D. H., & Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1), 67–82.
- Xie, L., Han, T., Zhou, H., Zhang, Z. R., Han, B., & Tang, A. (2021). Tuna Swarm Optimization: A Novel Swarm-Based Metaheuristic Algorithm for Global

- Optimization. *Computational Intelligence and Neuroscience*, 2021. <https://doi.org/10.1155/2021/9210050>
- Yang, B., Zhang, X., Yu, T., Shu, H., & Fang, Z. (2017). Grouped grey wolf optimizer for maximum power point tracking of doubly-fed induction generator based wind turbine. *Energy Conversion and Management*, 133, 427–443. <https://doi.org/10.1016/J.ENCONMAN.2016.10.062>
- Yang, X.-S. S. (2010). A New Metaheuristic Bat-Inspired Algorithm BT - Nature Inspired Cooperative Strategies for Optimization (NICSO 2010). *Studies in Computational Intelligence*, 284, 65–74. <http://arxiv.org/abs/1004.4170>
- Youssef, H., Kamel, S., Hassan, M. H., Nasrat, L., & Jurado, F. (2023). An improved bald eagle search optimization algorithm for optimal home energy management systems. *Soft Computing*, 28(2), 1367–1390. <https://doi.org/10.1007/S00500-023-08328-0/FIGURES/18>
- Zengin, İ., Bozkurt, M. R., & 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. <https://doi.org/10.35377/SAUCIS.02.03.649002>
- Zhang, C., Yao, R., & Cai, J. (2018). Efficient eye typing with 9-direction gaze estimation. *Multimedia Tools and Applications*, 77(15), 19679–19696. <https://doi.org/10.1007/S11042-017-5426-Y/METRICS>
- Zhang, J., Wang, B., Zhang, C., Xiao, Y., & Wang, M. Y. (2019). An EEG/EMG/EOG-based multimodal human-machine interface to real-time control of a soft robot hand. *Frontiers in Neurorobotics*, 13, 420002. <https://doi.org/10.3389/FNBOT.2019.00007/BIBTEX>
- Zhang, S., Zhou, Y., Li, Z., & Pan, W. (2016). Grey wolf optimizer for unmanned combat aerial vehicle path planning. *Advances in Engineering Software*, 99, 121–136. <https://doi.org/10.1016/J.ADVENGSOFT.2016.05.015>
- Zheng, Z., Li, J., Sang, H., Zheng, Z., Li, J., & Sang, H. (2019). A hybrid invasive weed optimization algorithm for the economic load dispatch problem in power systems. *Mathematical Biosciences and Engineering* 2019 4:2775, 16(4), 2775–2794. <https://doi.org/10.3934/MBE.2019138>
- Zhou, J., Qi, G., & Liu, C. (2021). A Chaotic Parallel Artificial Fish Swarm Algorithm for Water Quality Monitoring Sensor Networks 3D Coverage Optimization. *Sensors, Signal, and Artificial Intelligent Processing*, 2021. <https://doi.org/https://doi.org/10.1155/2021/5529527>

