

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

GÖRÜNÜM TEMELLİ YÖNTEMLERLE GERÇEK ZAMANLI GÖZ BAKIŞ
YÖNÜ KESTİRİMİ VE İNSAN BİLGİSAYAR ETKİLEŞİMİ

YÜKSEK LİSANS TEZİ

Bilgisayar Müh. Çağatay Murat YILMAZ

ARALIK 2014
TRABZON

KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

GÖRÜNÜM TEMELLİ YÖNTEMLERLE GERÇEK ZAMANLI GÖZ BAKIŞ
YÖNÜ KESTİRİMİ VE İNSAN BİLGİSAYAR ETKİLEŞİMİ

Bilgisayar Müh. Çağatay Murat YILMAZ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde
"BİLGİSAYAR YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 05.12.2014
Tezin Savunma Tarihi : 29.12.2014

Tez Danışmanı: Prof. Dr. Cemal KÖSE

Trabzon 2014

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalında
Çağatay Murat YILMAZ tarafından hazırlanan

GÖRÜNÜM TEMELLİ YÖNTEMLERLE GERÇEK ZAMANLI GÖZ BAKIŞ
YÖNÜ KESTİRİMİ VE İNSAN BİLGİSAYAR ETKİLEŞİMİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 09/12/2014 gün ve 1580 sayılı kararıyla
oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Cemal KÖSE

Üye : Prof. Dr. Ali GANGAL

Üye : Yrd. Doç. Dr. Bekir DİZDAROĞLU

Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü

ÖNSÖZ

Göz bakışının kestirimi kullanıcının bilgisayar ekranı üzerinde baktığı konum bilgisinin ölçülmesidir. Bu bilgi kullanıcının ekran üzerinde ilgilendiği noktaları ve gerçekleştirmek istediği etkileşim işlemlerini anlamada önemli bir etkindir. Ekran üzerine yapılan bu bakış bilgisi özellikle insan bilgisayar etkileşimi, sanal gerçeklik uygulamaları, kullanılabilirlik testleri, motor ve konuşma bozukluğu olan kişiler için göz bakışı ile yazı yazma, uykululuk tespiti ve psikoloji gibi alanlarda sıkça kullanılmaktadır.

Tez çalışmasında, görünüm temelli video-okulografi yöntemleri kullanılarak görüntü verileri ile kullanıcının etkileşimde olduğu ekranı koordinatları eşleştirilmiş ve kullanıcının ekran üzerinde sağ, sol, alt, üst ve merkez doğrultularında yaptığı bakışlar ile gözün kapalılık durumu kestirimi gerçekleştirilmiştir. Bakış yönü kestiriminin iyileştirilmesi amacıyla göz bölge modelleri üzerinde çeşitli öznitelik çıkarım ve sınıflandırma yöntemleri kullanılarak en iyi doğrulukta kestirimi gerçekleştirilen yaklaşımların tespiti gerçekleştirilmiştir. Geliştirilen sistemdeki bileşen ve yöntemler gerçek zamanlı çalışabilirliği destekleyecek şekilde seçilmiş ve önerilen yöntem bazı insan bilgisayar etkileşimi probleminde alternatif kullanıcı arabirimi olarak uygulanarak başarılı sonuçlar elde edilmiştir.

Çalışmalarım süresince bilgi, görüş ve önerileriyle bana yardımcı olan çok değerli danışman hocam Sayın Prof. Dr. Cemal KÖSE'ye teşekkürlerimi bir borç bilir ve şükranlarımı sunarım.

Yüksek lisans eğitimim süresince sabır, destek ve sevgileriyle hep yanımda olan aileme teşekkür eder şükranlarımı ve saygılarımı sunarım.

Çağatay Murat YILMAZ

Trabzon 2014

TEZ BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum “Görünüm Temelli Yöntemlerle Gerçek Zamanlı Göz Bakış Yönü Kestirimi ve İnsan Bilgisayar Etkileşimi” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Cemal KÖSE'nin sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 05/12/2014

Çağatay Murat YILMAZ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET.....	VIII
SUMMARY	IX
ŞEKİLLER DİZİNİ.....	X
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ.....	XIII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. İnsan Gözünün Yapısı.....	2
1.3. Göz Hareketleri.....	2
1.3.1. Sıçrama Hareketleri.....	3
1.3.2. Sabitlenme Hareketler.....	4
1.4. Renk Uzayları.....	4
1.4.1. RGB Renk Uzayı.....	4
1.4.2. HSV Renk Uzayı.....	5
1.4.3. HSL Renk Uzayı.....	6
1.4.4. YUV Renk Uzayı.....	6
1.4.5. YCbCr Renk Uzayı.....	7
1.4.6. Lab Renk Uzayı.....	7
1.4.7. Gri Renkli Görüntü.....	8
1.5. Görüntü İşleme Yöntemler.....	10
1.5.1. Görüntü Histogramı.....	10
1.5.2. Histogram Eşitleme.....	11
1.5.3. Çift Doğrusal Aradeğerleme.....	12
1.6. Haar Basamaklı Sınıflandırıcılar.....	13
1.6.1. Haar Benzeri Öznitelikler.....	14
1.6.2. İntegral Görüntü ve Hızlı Öznitelik Hesaplama.....	16

1.6.3.	Adaboost ile Sınıflandırıcının Eğitimi.....	17
1.6.4.	Basamaklı Sınıflandırıcı Yapısı.....	19
1.7.	Öznitelik Çıkarımı Yöntemleri.....	21
1.7.1.	Yerel İkili Örüntüler.....	21
1.7.1.1.	Düzenli Örüntüler.....	23
1.7.2.	Temel Bileşen Analizi.....	25
1.7.2.1.	Özyüzlerin Hesaplanması.....	25
1.8.	Sınıflandırma Yöntemleri.....	28
1.8.1.	K En Yakın Komşu Algoritması.....	28
1.8.2.	Destek Vektör Makineleri.....	30
1.8.2.1.	Doğrusal Destek Vektör Makineleri.....	32
1.8.2.1.1.	Doğrusal Ayrılabilir Veriler İçin İkili Sınıflandırma.....	32
1.8.2.1.2.	Doğrusal Ayrılamayan Veriler İçin İkili Sınıflandırma.....	36
1.8.2.2.	Doğrusal Olmayan Destek Vektör Makineleri.....	38
1.8.3.	Yapay Sinir Ağları.....	39
1.8.3.1.	Yapay Sinir Ağlarının Tarihi.....	40
1.8.3.2.	Biyolojik Sinir Hücresi.....	40
1.8.3.3.	Yapay Sinir Hücresi.....	41
1.8.3.4.	Yapay Sinir Ağlarının Yapısı.....	42
1.8.3.5.	Aktivasyon Fonksiyonları.....	43
1.8.3.6.	Çok Kategorili Tek Katmanlı Ayrık Perseptron.....	43
1.8.3.7.	Yapay Sinir Ağı Modelleri.....	45
1.8.3.8.	Öğrenme Metotları.....	46
1.8.3.8.1.	Danışmanlı Öğrenme Metodu.....	47
1.8.3.8.2.	Danışmansız Öğrenme Metodu.....	47
1.8.3.8.3.	Takviyeli Öğrenme Metodu.....	47
2.	YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME.....	48
2.1.	Giriş.....	48
2.2.	Literatür Taraması.....	49
2.2.1.	Elektrookülografi.....	49
2.2.2.	Arama Bobinleri.....	51
2.2.3.	Kızılötesi-Okulografi.....	52

2.2.4.	Video-Okulografi.....	53
2.2.4.1.	Özellik Temelli Göz Bakış Yönü Kestirimi.....	53
2.2.4.2.	Görünüm Temelli Göz Bakış Yönü Kestirimi.....	56
2.3.	Yüz Tespiti.....	58
2.4.	Sağ ve Sol Göz Tespiti.....	61
2.5.	Göz Bakış Özniteliklerinin Çıkarılması.....	64
2.5.1.	Özgöz ile Öznitelik Çıkarımı ve Boyut İndirgeme.....	64
2.5.2.	Yerel İkili Örüntü Histogramı ile Öznitelik Çıkarımı.....	66
2.6.	Göz Bakış Görüntülerinin Sınıflandırılması.....	67
2.6.1.	KEYK ile Sınıflandırma.....	67
2.6.2.	YSA ile Sınıflandırma.....	68
2.6.3.	DVM ile Sınıflandırma.....	69
2.7.	Bakış Yönü Veritabanı.....	71
2.8.	DeneySEL Sonuçlar ve Karşılaştırmalar.....	73
3.	SONUÇLAR VE TARTIŞMA.....	87
4.	ÖNERİLER.....	89
5.	KAYNAKLAR.....	90

ÖZGEÇMİŞ

Yüksek Lisans Tezi

ÖZET

GÖRÜNÜM TEMELLİ YÖNTEMLERLE GERÇEK ZAMANLI GÖZ BAKIŞ YÖNÜ
KESTİRİMİ VE İNSAN BİLGİSAYAR ETKİLEŞİMİ

Çağatay Murat YILMAZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Cemal KÖSE
2014, 96 Sayfa

Göz bakışının kestirimi kullanıcının ekran üzerinde baktığı konum bilgisinin ölçülmesidir. Ekran üzerine yapılan bu bakış bilgisi özellikle insan bilgisayar etkileşimi alanında klavye ve fare gibi geleneksel giriş birimlerine alternatif olması, sanal gerçeklik uygulamaları, kullanılabilirlik testleri, motor ve konuşma bozukluğu olan kişiler için göz bakışı ile yazı yazma ve uykululuk tespitine yönelik çalışmalarda sıkça kullanılmaktadır.

Tez çalışmasında, görünüm temelli video-okulografi yöntemleri kullanılarak bakış görüntü verileri ile kullanıcının etkileşimde olduğu ekran koordinatları eşleştirilmiş ve kullanıcının ekran üzerinde sağ, sol, alt, üst ve merkez doğrultularında yaptığı bakışlar ile gözün kapalılık durumu kestirimi gerçekleştirilmiştir. Bakış yönü kestiriminin iyileştirilmesi amacıyla önerilen göz bölge modelleri üzerinde çeşitli öznitelik çıkarım ve sınıflandırma yöntemleri kullanılarak en iyi doğrulukta kestirimi gerçekleştiren yaklaşımların tespiti gerçekleştirilmiştir.

Geliştirilen sistemde kullanılan bileşen ve yöntemler gerçek zamanlı çalışabilirliği destekleyecek şekilde seçilmiş ve önerilen yöntem bazı insan bilgisayar etkileşimi problemlerinde alternatif kullanıcı arabirimi olarak uygulanarak başarılı sonuçlar elde edilmiştir.

Anahtar Kelimeler: Göz Bakış Yönü Kestirimi, İnsan Bilgisayar Etkileşimi, Görünüm Temelli Video-Okulografi, Destek Vektör Makineleri, Yerel İkili Örüntü Histogramları, Özgöz Yaklaşımı, Haar Basamaklı Sınıflandırıcılar

Master Thesis

SUMMARY

REAL TIME EYE GAZE DIRECTION DETECTION USING APPEARANCE
BASED METHODS AND HUMAN COMPUTER INTERACTION

Çağatay Murat YILMAZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Cemal KÖSE
2014, 96 Pages

Eye-gaze direction detection is the process of measuring the position of user's gaze on computer screen. This gaze information is mostly used in the research areas like Human Computer Interaction (HCI), virtual reality applications, usability tests, eye typing for physically disabled people and drowsiness detection. In HCI, it is widely being employed as an alternative of traditional input devices such as mouse and keyboard.

In this thesis, gaze image data and screen which user has interaction are mapped using appearance based video-oculography approach and gazing directions of left, right, lower, upper, center and closed eye state are detected. Various feature extraction and classification methods are used on proposed eye models to improve the detection of gaze direction. Additionally, selection of the best approaches for gaze direction detection is performed by using the resulting classification accuracy of applied methods.

In the proposed system, all components and methods are selected according to real time applicability and the resulting system applied on a few HCI problems as an alternative of user interface problems which gives successful results.

Key Words: Eye Gaze Direction Detection, Human Computer Interaction, Appearance Based Video-Oculography, Support Vector Machines, Local Binary Pattern Histograms, Eigen-eye Approach, Haar Cascade Classifiers

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1.1.	İnsan gözünün görünür kısmının temel yapısı 2
Şekil 1.2.	Sıçrama hareketinin oluşum zaman safhası 3
Şekil 1.3.	RGB renk uzayı modeli 5
Şekil 1.4.	Gri seviye yoğunluk değerleri 9
Şekil 1.5.	Renkli (a) ve gri renkli (a) görüntü 10
Şekil 1.6.	Gri seviyeli görüntü (a), görüntü histogramı (b) 10
Şekil 1.7.	Zıtlığı bozuk görüntü (a) ve histogramı (b), histogram eşitleme uygulanmış görüntü (c) ve histogramı (d) 12
Şekil 1.8.	Aradeğerleme ile hedef piksel değerinin hesaplanması 13
Şekil 1.9.	Yatay (a), dikey (b) ve çeşitli açılarda (c, d) iki-dikdörtgen HBÖ'ler 15
Şekil 1.10.	Yatay (a, b), dikey (c, d) ve çeşitli açılarda (e, f, g, h) HBÖ'ler 15
Şekil 1.11.	(a, b) Merkezi çevreli ve (c) çapraz dört-dikdörtgen HBÖ'ler 15
Şekil 1.12.	İntegral görüntü hesaplanması 17
Şekil 1.13.	Adaboost sınıflandırıcı ile seçilmiş bazı HBÖ'ler 18
Şekil 1.14.	Basamaklı sınıflandırıcı yapısı 20
Şekil 1.15.	Pencereler ile çeşitli ölçeklerde hedef görüntü nesnesinin aranması 20
Şekil 1.16.	Farklı aydınlanma ortamlarındaki orijinal görüntüler (üstte), YİÖ ile ifade edilen görüntüler (altta) 21
Şekil 1.17.	Temel YİÖ operatörünün uygulanışı, 3x3'lük komşu pikseller (a), ikili kod ve ondalık değer elde edilmesi (b) 22
Şekil 1.18.	Farklı P ve R değer çiftleri için dairesel YİÖ operatörleri 23
Şekil 1.19.	Yerel histogramların birleştirilmesiyle genel YİÖH öznitelik vektörünün oluşturulması 24
Şekil 1.20.	KxL boyutunda yüz görüntüsünü TBA'da kullanımı için sütun vektörüne dönüşümü 26
Şekil 1.21.	K-EYK ile test verisinin sınıflandırılması 29
Şekil 1.22.	İki boyutlu uzayda 2 farklı sınıfı ayırıcı muhtemel küçük sınırlı doğrular 31
Şekil 1.23.	En geniş sınır aralığında en iyi ayırıcı doğrular 32
Şekil 1.24.	Doğrusal ayrılabilir veriler ve doğrusal ayırıcı hiperdüzlem yapısı 33
Şekil 1.25.	Doğrusal ayrılamayan veriler ve ayırıcı hiperdüzlem yapısı 36
Şekil 1.26.	Bir boyutta doğrusal ayrılama durumu (a), çekirdek fonksiyonları ile iki boyutta doğrusal ayrılabilirliğin sağlanması (b) 38

Şekil 1.27.	Biyolojik sinir hücresinin yapısı	41
Şekil 1.28.	Yapay sinir ağı hücresinin yapısı	42
Şekil 1.29.	Girdi, ara ve çıktı katmanlarından oluşan bir ağ yapısı.....	43
Şekil 1.30.	Çok kategorili tek katmanlı ayırık perseptron yapısı	44
Şekil 1.31.	Tek katmanlı ileri beslemeli YSA blok diyagramı, (b) Tek katmanlı ayırık zamanlı geri beslemeli YSA blok diyagramı	46
Şekil 2.1.	Elektrookülografi ile göz hareketlerinin ölçülmesi	50
Şekil 2.2.	Elektrotların yüz bölgesi üzerine yerleştirimi	50
Şekil 2.3.	Göz bölgesi üzerine yerleştirilmiş arama bobini (a),	51
Şekil 2.4.	IR-okulografi sistemlerin yapısı	52
Şekil 2.5.	Göz bebeği merkezi ve kornea yansımasının göreceli konumları.....	55
Şekil 2.6.	Yüz bölgesi tespiti akış diyagramı	59
Şekil 2.7.	Tespit edilen örnek yüz bölgesi örneği	61
Şekil 2.8.	Sağ (a) ve sol (b) göz arama bölgeleri.....	62
Şekil 2.9.	Tespit edilen sağ ve sol gözler	63
Şekil 2.10.	Sol ve sağ göz tespiti akış diyagramı	64
Şekil 2.11.	Ortalama göz görüntüsü	65
Şekil 2.12.	Eğitim veri kümesi üzerinde hesaplanan ilk 30 özgöz görüntüsü	66
Şekil 2.13.	Çeşitli R ve P parametre çiftleri ile hesaplanan YİÖ görüntüleri.....	67
Şekil 2.14.	Bakış veritabanı içeriği, ekran üzerinde sol (a), sağ (sağa), alt (c), üst (d) ve merkeze (e) yapılan bakış örnekleri ile kapalı göz görüntü örneği (f).....	73
Şekil 2.15.	Başarılı (a) ve başarısız (b) yüz tespiti sonuç görüntüleri	75
Şekil 2.16.	Başarılı (a) ve başarısız (b) göz tespiti sonuç görüntüleri	76
Şekil 2.17.	Farklı renk uzaylarındaki bakış görüntüleri	76
Şekil 2.18.	Örnek GözBölge#2 görüntüleri (a), Örnek GözBölge#1 görüntüleri (b).....	79
Şekil 2.19.	Örnek GözBölge#4 görüntüleri (a), Örnek GözBölge#3 görüntüleri (b).....	79

TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1.1. Çekirdek fonksiyonları, matematiksel ifadeleri ve aldıkları parametreler.....	39
Tablo 2.1. Çekirdek fonksiyon parametrelerinin ızgara tabanlı aramayla belirlenmesinde kullanılan değer aralıkları.....	70
Tablo 2.2. Radyal tabanlı çekirdek fonksiyonunda γ , C parametreleri için ızgara tabanlı arama ile elde edilen sınıflandırma sonuçları.....	70
Tablo 2.3. Bakış yönü veritabanındaki çeşitli yönlerde toplam görüntü sayıları	72
Tablo 2.4. Yüz tespiti başarımları sonuçları	74
Tablo 2.5. Göz tespiti başarımları sonuçları	75
Tablo 2.6. Farklı renk uzay ve kanallarının göz bakış yönü kestiriminde ölçülen başarımları	77
Tablo 2.7. Kullanılan sınıflandırma ve öznitelik çıkarma yöntemleri.....	80
Tablo 2.8. GözBölgesi#1 modeli üzerinde sınıflandırma doğrulukları	81
Tablo 2.9. GözBölgesi#2 modeli üzerinde sınıflandırma doğrulukları	82
Tablo 2.10. GözBölgesi#3 modeli üzerinde sınıflandırma doğrulukları	82
Tablo 2.11. GözBölgesi#4 modeli üzerinde sınıflandırma doğrulukları	83
Tablo 2.12. GözBölgesi#1 modeli üzerinde DVM ve YİÖH yöntem çifti ile çeşitli çözünürlüklerde sınıflandırma doğrulukları.....	84
Tablo 2.13. Yöntem çiftlerinin eğitim ve test süreleri.....	85
Tablo 2.14. Önerilen yöntemin mevcut çalışmalarla kıyaslanması.....	86

SEMBOLLER DİZİNİ

YSA	Yapay Sinir Ağları (Artificial Neural Network)
HBS	Haar Basamaklı Sınıflandırıcı (Haar Cascade Classifier)
HBÖ	Haar Benzeri Öznitelikler (Haar Like Features)
DVM	Destek Vektör Makineleri (Support Vector Machine)
K-EYK	K En Yakın Komşuluk (K-Nearest Neighbor Algorithm)
YİÖ	Yerel İkili Örüntüler (Local Binary Patterns)
YİÖH	Yerel İkili Örüntü Histogramı (Local Binary Pattern Histogram)
HSV	Hue, Saturation, Value
ÇKP	Çok Katmanlı Perseptron (Multi Layer Perceptron)
RGB	Red, Green, Blue (Kırmızı, Yeşil, Mavi)
OPENCV	Open Source Computer Vision Library

1. GENEL BİLGİLER

1.1. Giriş

Göz bakışının izlenmesi (eye-gaze tracking) temel olarak kullanıcının ekran üzerinde baktığı konumun ölçülmesidir. Göz bakış yönü kestirimi (eye-gaze direction detection) ise göz bakışının izlenmesinin daha özel bir halidir ve ekran üzerinde çeşitli konumlara bakan kullanıcının bakış yönünün tespiti işlemidir. Ekran üzerinde yapılan bakış bilgisi insan bilgisayar etkileşimi, tüketici elektroniği, oyun sistemleri, sanal gerçeklik uygulamaları, kullanılabilirlik testleri, psikoloji, motor ve konuşma bozukluğu olan kişilerin yaşam kalitesini arttırmaya yönelik görsel sistemler ve diğer birçok alanda sıkça kullanılmaktadır.

Göz bakış bilgisinin ölçülmesi kullanılan donanım türüne göre elektrookulografi, arama bobinleri, video-okulografi ve kızılötesi-okulografi olmak üzere 4 farklı yöntemle gerçekleştirilir. Bu yöntemlerden en sık kullanılan video-okulografi yönteminde ekran üzerinde çeşitli konumlara yerleştirilmiş normal veya kızıl ötesi sensörlü kameralar ile kullanıcı görüntüleri yakalanır. Yakalanan bu kullanıcı görüntü verilerine özellik veya görünüm temelli yöntemler uygulanarak kullanıcı bakış bilgisi tespiti gerçekleştirilir.

Tez çalışmasında video-okulografi ve görünüm temelli yöntemler kullanılarak görüntü verileri ile kullanıcının etkileşimde olduğu ekranı koordinatları eşleştirilmiş ve ekran üzerinde sağ, sol, alt, üst ve merkez doğrultularında yaptığı bakışlar ile gözün kapalılık durumu kestirimi gerçekleştirilmiştir. Geliştirilen sistemde kullanılan tüm bileşen ve yöntemler gerçek zamanlı çalışabilirliği destekleyecek şekilde seçilmiş ve önerilen yöntem bazı insan bilgisayar etkileşimi problemlerinde alternatif kullanıcı arabirimi olarak uygulanmış ve başarılı sonuçlar alınmıştır.

Çalışmada ilk aşama olan yüz bölgesi tespiti yüksek doğruluk, hız ve ölçeklendirmeden bağımsız çalışan HBS yapısı ile gerçekleştirilmiştir. Bu yöntemde öncelikle gri renkli görüntüler üzerinde hesaplama maliyeti düşük HBÖ'ler hesaplanır, daha sonra Adaboost ile ayırt ediciliği yüksek öznelik seçimi ve sınıflandırıcıların oluşturulması gerçekleştirilir. İkinci aşamada tespit edilen yüz bölgesi üzerinde hedef göz arama penceresi oluşturulmuş ve bu alan içerisinde HBS yaklaşımı ile ölçekten bağımsız ve gerçek zamanlı çalışabilen sağ ve sol göz bölge tespiti gerçekleştirilmiştir.


Görünüm temelli yöntemlerde eğitim verileri üzerinde istatistiksel analiz ve makine öğrenme yöntemleri kullanılarak öğrenme gerçekleştirilir ve öğrenme sonucu oluşan dağılım modelleri ve ayırıcı fonksiyonlar ile verilerin sınıflandırılması gerçekleştirilir. Çalışmada bu amaçla bir deney ortamı oluşturulmuştur ve göz yapıları birbirinden farklı kullanıcılardan alınan kalibrasyon ve test video görüntüleri kullanılarak bakış yönü veritabanı oluşturulmuştur. Bu veritabanı, ekran üzerinde sağa, sola, alta, üste ve merkeze yapılan bakış görüntüleri ile kapalı göz görüntülerini içermektedir. Bu görüntüler göz bakış yönü kestiriminde diğer renk uzaylarına göre başarılı olduğu ölçülen YUV renk uzayının parlaklığı ifade eden Y kanal görüntüsü formatındadır. Ayrıca, veritabanına kullanıcıdan alınan kalibrasyon görüntü verilerinin de eklenmesiyle görünüm temelli yöntemlerde çok sayıda eğitim verisine sahip olma problemi çözülmeye çalışılmıştır.

Çalışmada göz bakış yönü kestirimi sırasında kullanılacak bakış yönü görüntü verilerinin edinilmesinde önceki çalışmalardan farklı bazı yöntemler önerilmiştir. Göz çevresindeki gereksiz bölgeleri kullanılmayarak öznitelik çıkarım aşamasında oluşan işlem maliyeti azaltılmaya ve sınıflandırma doğruluğu arttırılmaya çalışılmıştır. Ekran üzerine yapılan bakışlarda kullanıcının her iki gözünün tamamen aynı doğrultuda bakmaması problemini çözmek amacıyla tek göz bölgesi yerine iki göz bölgesi kullanılmıştır.

Göz bakış görüntülerinden öznitelik çıkarımı aşamasında özellikle yüz tanıma ve tespiti çalışmalarında sıkça kullanılan ve başarılı sonuçlar üreten iki farklı yöntem kullanılmıştır. Bu yöntemlerden YİÖH gri yoğunluk seviyesinden bağımsız, göz çevresindeki aydınlanma değişimlerinden az etkilenen, ayırcılığı yüksek bir doku betimleyicisi ve öznitelik çıkarım yöntemidir. TBA ve özyüzler yaklaşımı ise hem öznitelik çıkarımı hemde yüksek öznitelik boyutlarının azaltılması amacıyla sıkça kullanılan bir yöntemdir. Göz bakış görüntülerinden sınıflandırılması aşamasında ise ızgara tabanlı arama yöntemi ile en iyi parametre değerleri seçilmiş, makineleri öğrenme ve örüntü sınıflandırma problemlerinde sıkça kullanılan DVM, YSA ve KEYK yöntemleri kullanılmıştır. Son olarak, önerilen göz bölge modelleri üzerinde öznitelik çıkarım ve sınıflandırma yöntem çiftleri uygulanarak her bir yöntemin göz bakış yönü kestirimindeki başarısı ölçülmüştür. Önerilen yöntem, gerçek zamanlı çalışan bazı insan bilgisayar etkileşimi problemlerinde alternatif kullanıcı arabirimi olarak uygulanmış ve başarılı sonuçlar alınmıştır.

1.2. İnsan Gözünün Yapısı

Göz çevreden aldığı ışık sayesinde görme olayını gerçekleştiren bir organdır ve insanlar çevreden aldıkları bilgilerin yaklaşık %80'ini bu organla elde ederler. Küre şeklinde olan göz ışık geçirebilme özelliğine sahip üç adet tabakadan oluşmaktadır. En dışta sert tabaka veya göz akı (sclera) olarak adlandırılan ve gözü koruyan beyaz renkte bir tabaka bulunur. Bu tabaka göz ön bölgesinde genişerek ışığı odaklamak ve gözü dış etkenlerden korumakla görevli korneada olarak adlandırılan saydam bir tabaka oluşturur. Göz akı ve kornea arasında yer alan sınır çizgisi ise limbus olarak adlandırılır. Sert tabakanın ardında gözün beslenmesini sağlayan damar tabaka yer alır. Bu tabaka gözün ön kısmında renk değiştirerek göze rengini veren iris ve irisin ortasında yer alan göz bebeğini oluşturur. Iris çevreden gelen ışık miktarına bağlı olarak göz bebeğini büyütür veya küçültür. En içte ise ışığa duyarlı almaçların yer aldığı retina olarak adlandırılan ağ tabaka yer alır (1, 2014). İnsan gözünün çalışmada kullanılan görülebilir temel kısımları Şekil 1.1'de verilmiştir.



Şekil 1.1. İnsan gözünün görünür kısmının temel yapısı


1.3. Göz Hareketleri

Göz hareketleri temel olarak iki ana kategoriye ayrılabilir. Bunlar; dikkati bir noktaya yoğunlaştırmak ve odaklanmak için dengeleme hareketleri ve görsel saha içerisinde gözü başka bir odak noktasına hareket ettirmek için gerçekleştirilen sıçrama (saccade) hareketleridir. Dengeleme hareketleri gözü sabitleme (fixation) ve düzgün takip hareketlerini (smooth pursuit movements) içerir. Sıçrama hareketleri ise gözün hedef odaklanma noktasına sıçrama ve bağlama hareketlerini (vergence movements) içermektedir. Göz ve göz bakış hareketleri temel olarak görüş açısının dereceleri cinsinden ölçülmektedir

ve ekrana 57 cm uzaklıkta gözün ekran üzerindeki 1 derecelik görüş açısı yaklaşık 1 cm'lik mesafe aralığını kapsamaktadır [2,3].

1.3.1. Sıçrama Hareketleri

Sıçrama hareketleri gözün sabitlendiği bir görsel sahneden/alandan diğerine çok hızlı ve ani hareketleridir. Gözler küçük bir görsel alana net olarak odaklanabilirler ve farklı görsel alanlara başarılı bir şekilde odaklanabilmeleri için sıçrama hareketlerinin kısa süre içerisinde ve sürekli olarak yapılması gerekmektedir. Göz üzerindeki sıçrama hareketleri kişinin odaklanmak istediği hedefe doğru bilinçlice başlayabilir, ancak gözün hedef bölgeye sıçrama hareketini gerçekleştirmesi bilinçsizce ve refleks olarak gerçekleştirilir. Ayrıca, gözler açık olduğunda ve bir noktaya sabit bir şekilde bakıldığında bile bu hareketler bilinçsizce meydana gelirler. Bir sıçrama hareketinin oluşum zaman safhası Şekil 1.2'de verilmiştir. Gözün sabitlendiği bir noktadan diğerine sıçrama hareketinin başlaması yaklaşık olarak 200 ms (milisaniye) sürmektedir. Bu gecikme süresi içerisinde gözün hangi yönde ne kadar hareket edeceği bilgisi hesaplanır ve hedef noktaya hareketi sağlayacak kaslara ilgili komutlar verilir. Yaklaşık 30-120 ms süre aralığında ise yeni odak noktasına sabitlenme işlemi gerçekleştirilir [4, 5]. Ayrıca, gözün sıçrama hareketinin genliğine göre 400-600 derece/saniye hızında sıçrama hareketleri gerçekleştirilebilir [2].



Şekil 1.2. Sıçrama hareketinin oluşum zaman safhası

1.3.2. Sabitlenme Hareketleri

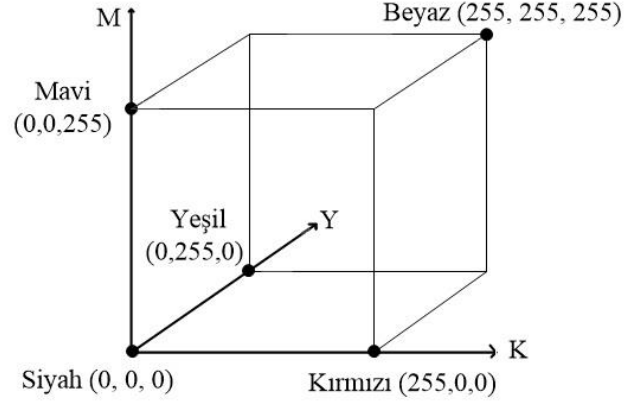
Sabitlenme hareketleri gözle odaklanılmak istenen noktanın retina üzerinde net olarak oluşabilmesi için gözün gerçekleştirdiği hareketlerdir. 100 ile 1000 ms süre aralığında gerçekleşen bu hareketler sırasında görüş açısında yaklaşık 1 derecelik alanında en net görme olayı gerçekleşir [2].

1.4. Renk Uzayları

Renk uzayları 3 veya 4 boyutlu bir koordinat sistemi ile temsil edilen ve görünür bölgedeki renkleri ifade etmek için kullanılan matematiksel modelleridir. Farklı renk uzayları arasında doğrusal veya doğrusal olmayan yöntemlerle dönüşümler gerçekleştirilebilir. Özellikle görüntü işleme uygulamalarında çeşitli problemleri çözmek amacıyla çok sayıda renk uzayları tanımlanmıştır. Örneğin, HSV renk uzayı ortam aydınlatma değişimlerinden daha az etkilenmekte ve başarı sonuçlar üretmektedir. Bunun nedeni bu uzayda parlaklık ve rengi ifade eden parametrelerin birbirinden ayrı olmasıdır. Benzer bir yaklaşım RGB renk uzayında tanımlı olmadığından görüntü üzerindeki herhangi bir parlaklık değişimi tüm renk parametreleri etkilemekte ve sıklıkla parlaklık değişiminden etkilenen günlük hayat problemlerinin çözümünü zorlaştırmaktadır.

1.4.1. RGB Renk Uzayı

RGB renk modeli, renkleri kırmızı, yeşil ve mavi dalga boyları ve bu dalga boylarının çeşitli oranda karışımları ile 3 boyutlu Kartezyen koordinat sistemi ile ifade etmektedir. RGB renk modelinin Kartezyen uzayında tanımlanması ve çok bilinen bazı renk değerlerinin bu uzayda aldıkları değerler Şekil 1.3'te gösterilmiştir. Görüntü işleme ve diğer alanlarda en sık kullanılan renk modelidir. Ancak, gerçek dünya görüntüleri üzerinde çalışıldığında bu renk uzayında çeşitli problemler oluşabilmektedir. Örneğin, bir piksel değerinin renk veya yoğunluk bilgisi değiştirilmek istendiğinde tüm kanal değerleri okunmalı ve üzerinde işlem yapılmalıdır [6]. Bu ve benzeri nedenlerle diğer renk uzay modelleri önerilmiştir. Diğer renk uzaylarının anlatıldıkları bölümlerde görüntü işleme çalışmalarında RGB renk uzayına nazaran neden tercih edildikleri kısaca izah edilmiştir.



Şekil 1.3. RGB renk uzayı modeli

1.4.2. HSV Renk Uzayı

HSV renk uzayı, renkleri sırasıyla renk özü (hue), doygunluk (saturation) ve parlaklık (value) olarak tanımlar. Renk özü bir rengi diğerinde ayıran niteliklerdir. Doymunluk, bir rengin aynı renkteki bir renkten ayırım derecesini belirleyen niteliklerdir. Parlaklık ise rengin açıklığını veya koyuluğunu belirtir [7]. Bu renk uzayı RGB uzayına nazaran insan görüşüne daha yakın bir yapıdadır. Ayrıca, aydınlık değışimleri RGB renk uzayındaki bütün renk bileşenlerini etkilerken bu değışimler HSV renk uzayında sadece parlaklık parametresini etkiler [8]. Bu gibi avantajlarından dolayı sıklıkla ten rengine ile nesne tespitine yönelik çalışmalarda sıklıkla kullanılmaktadır [9].

RGB renk uzayından HSV renk uzayına doğrusal olmayan bir yolla yapılan dönüşüm ise (1.1), (1.2) ve (1.3) denklemlerinde ifade edilmektedir. Ancak, hesaplamalardan önce RGB renk uzayındaki görüntünün her bir kanalındaki 0 ve 255 arasındaki renk değerleri 0 ve 1 aralığına normalize edilmelidir [10].

$$H = \arccos \frac{\frac{1}{2}(2R - B - G)}{\sqrt{(R - G)^2 - (R - B) - (G - B)}} \quad (1.1)$$

$$S = \frac{\text{Maks}(R, G, B) - \text{Min}(R, G, B)}{\text{Maks}(R, G, B)} \quad (1.2)$$

$$V = \text{Maks}(R, G, B) \quad (1.3)$$

1.4.3. HSL Renk Uzayı

HSL renk uzayı da HSV gibi silindirik bir koordinat sistemi ile ifade edilir. Renk özü, aydınlık, doygunluk bileşenlerinden oluşmaktadır. HSV renk uzayına benzer bir yapı göstermektedir ancak bu renk uzayında parlaklık değil aydınlık bilgisi kullanılmıştır. Bu renk uzayında aydınlık parametre değeri düşük olursa koyu renkler, yüksek olursa açık renkler ifade edilir. Görüntü işleme alanında görüntü bölütleme ve kenar tespiti [11] gibi çalışmalarda kullanılmaktadır ancak HSV renk uzayı kadar popüler değildir.

RGB renk uzayından HSL renk uzayına dönüşüm (1.4), (1.5), (1.6) denklemleri ile hesaplanır. Burada, $C_{\text{Maks}} = \text{maks}(R, G, B)$, $C_{\text{Min}} = \text{min}(R, G, B)$ ve $\Delta = (C_{\text{maks}} - C_{\text{min}})$ denklemleri ile elde edilir [12].

$$H = \begin{cases} 60^\circ \times ((G' - B')/\Delta) \% 6, & C_{\text{max}} = R' \\ 60^\circ \times ((B' - R')/\Delta) + 2, & C_{\text{max}} = G' \\ 60^\circ \times ((R' - G')/\Delta) + 4, & C_{\text{max}} = B' \end{cases} \quad (1.4)$$

$$S = \begin{cases} 0, & \Delta = 0 \\ \frac{\Delta}{1 - |2L - 1|}, & \Delta <> 0 \end{cases} \quad (1.5)$$

$$L = (C_{\text{min}} + C_{\text{maks}})/2 \quad (1.6)$$

1.4.4. YUV Renk Uzayı

Özellikle görüntü taşınan sistemlerde bant genişliğinin azaltılması ve çeşitli video sıkıştırma yöntemlerinde olduğu gibi renk bilgisinden çok parlaklığın vurgulanmasına yönelik alanlarda kullanılır. Burada Y parametresi rengin parlaklık değerini yani renkli görüntünün gri seviye bilgisini, U ve V parametreleri ise renk bilgisini ifade etmektedir.

Görüntü işleme alanında stenografi, kenar belirleme, görüntü bölütlemeye sıkça [13] kullanılmaktadır. RGB renk uzayında YUV renk uzayına dönüşüm (1.7) ile ifade edildiği şekilde gerçekleştirilir.

$$\begin{bmatrix} [Y] \\ [U] \\ [V] \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.147 & -0.289 & 0.437 \\ 0.615 & -0.515 & -0.100 \end{bmatrix} * \begin{bmatrix} [R] \\ [G] \\ [B] \end{bmatrix} \quad (1.7)$$

1.4.5. YCbCr Renk Uzayı

Bu renk uzayı temel olarak sayısal video standardı oluşturmak amacıyla geliştirilmiştir. Burada, Y parlaklığı, Cb ve Cr ise sırasıyla mavi ve kırmızı renk bilgilerini ifade etmektedir. (1.8) ifadesinde RGB renk uzayından YCbCr renk uzayına dönüşüm denklemi verilmiştir [14]. Görüntü işleme alanında yüz tespiti gibi ten rengi tabanlı çalışmalarda kullanılmaktadır.

$$\begin{bmatrix} [Y] \\ [C_b] \\ [C_r] \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.1140 \\ -0.169 & 0.3316 & 0.5005 \\ 0.4998 & -0.4185 & -0.0812 \end{bmatrix} * \begin{bmatrix} [R] \\ [G] \\ [B] \end{bmatrix} \quad (1.8)$$

1.4.6. Lab Renk Uzayı

Lab renk uzayı ilk olarak görsel medya için tanımlanmış daha sonra birçok alanda standart olarak kullanılmaya başlanmıştır. Örneğin, gerçek boya renkleri ile basılı medyada kullanılan renk değerlerinin eşleştirilmesinde bu renk uzayı kullanılmaktadır. Cihaz bağımsız olması ve farklı cihazlar arasında renk taşınabilirliğine olanak sağlaması nedeniyle sık kullanılmaktadır. Ayrıca, insan gözünün algılayabileceği neredeyse tüm renk değerlerini tanımlayabilmektedir [15]. Renk uzayında, L kanalı 0 (siyah) - 100 (beyaz) arası değer alır ve rengin parlaklığını ifade eder. Rengi ifade eden a kanalı - 128 (yeşil) ile 128 (mavi) arası değer alır ve yine rengi ifade eden b kanalı ise -128 (mavi) ile 128 (sarı) arası değer alır [16]. RGB ve Lab renk uzayları arasında dönüşüm iki aşamalı yapılıdır.

Öncelikle, (1.9)'daki gibi RGB ve XYZ uzayları arası dönüşüm [17], daha sonra XYZ ile Lab arasında dönüşüm (1.10), (1.11), (1.12) ve (1.13) denklemleri ile gerçekleştirilir [18].

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.412453 & 0.357580 & 0.180423 \\ 0.212671 & 0.715160 & 0.072169 \\ 0.019334 & 0.119193 & 0.950227 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1.9)$$

$$L = \begin{cases} 116 \left(\frac{Y}{Y_n} \right)^{\frac{1}{3}} - 16, & \frac{Y}{Y_n} > 0.008856 \\ 903.3 \left(\frac{Y}{Y_n} \right), & \frac{Y}{Y_n} \leq 0.008856 \end{cases} \quad (1.10)$$

$$a = 500 * \left(f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right) \quad (1.11)$$


$$b = 200 * \left(f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right) \quad (1.12)$$

$$f(t) = \begin{cases} \frac{1}{t^3}, & t > 0.008856 \\ 7.787 * t + 16/116, & t \leq 0.008856 \end{cases} \quad (1.13)$$

1.4.7. Gri Renkli Görüntü

Bu görüntüler tek kanal bilgisi içerirler ve piksel değerleri gri rengin tonlarını ifade eder. Her bir piksel değeri 8 bit renk derinliğine sahiptir ve Şekil 1.4'teki gibi 0 (siyah) ile 255 (beyaz) arası bir değerle ifade edilir. Parlaklık bilgisi renk bilgisinden fazla ayırt edici özellik bilgi içerdiğinden ve bellek üzerinde daha az yer kapladığından işlemlerin hızlı yapılabilmesi için gri renkli görüntüler sıklıkla kullanılmaktadır.

Çeşitli avantajlarına rağmen ortam aydınlatması gibi faktörlerden etkilenir ve görüntü işleme alanında tek başına öznitelik vektörü olarak kullanılmaması tercih edilir.



Şekil 1.4. Gri seviye yoğunluk değerleri

RGB renk uzayındaki görüntülerden gri renkli görüntü elde etmenin birçok yolu mevcuttur. (1.14) ile ifade edilen yöntemde basitçe R, G, B değerlerinin ortalaması alınmıştır. (1.15) ile ifade edilen yöntemde ise ağırlıklı ortalamaları alınarak insan algısına daha yakın bir dönüşüm gerçekleştirilmiştir.

$$\text{Gri Piksel Değ.} = (R + G + B) / 3 \quad (1.14)$$

$$\text{Gri Piks. Değ.} = (0.299xR + 0.587xG + 0.114B) \quad (1.15)$$

RGB uzayındaki renkli bir görüntü ve bu görüntünün gri seviyedeki değerlerinden oluşan gri seviyeli görüntü Şekil 1.5'te verilmiştir.

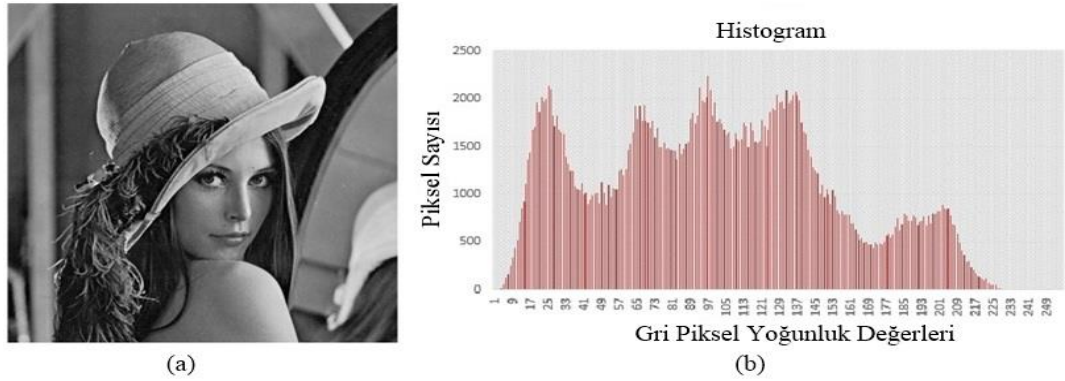


Şekil 1.5. Renkli (a) ve gri renkli (a) görüntü

1.5. Görüntü İşleme Yöntemleri

1.5.1. Görüntü Histogramı

Görüntü histogramı sayısal bir görüntü üzerinde her bir piksel renk değerlerinden toplam kaç tane olduğunu ifade eden bir fonksiyondur ve matematiksel olarak $h(r_k) = n_k$ ayrık fonksiyonu ile ifade edilir. Burada, r_k piksel yoğunluk değerlerini, n_k ise r_k piksel yoğunluk değerine sahip toplam piksel sayısını ifade eder. Uygulama işlemi sıklıkla gri seviyeli görüntüler üzerinde gerçekleştirilir ancak RGB vb. görüntülerde de her bir renk kanalı üzerine de uygulanarak iyileştirme yapılabilir. Örnek gri renkli bir görüntü ve bu görüntünün histogramı Şekil 1.6'da verilmiştir. Burada yatay eksen piksel yoğunluk değerlerini, dikey eksen ise görüntü üzerinde ilgili piksel yoğunluk değerine sahip toplam piksel sayısını ifade etmektedir.



Şekil 1.6. Gri seviyeli görüntü (a), görüntü histogramı (b)

1.5.2. Histogram Eşitleme

Histogram eşitleme çoğunlukla görüntüdeki renk değerlerinin belirli bir renk değeri aralığında toplanması sonucu oluşan renk dağılım ve zıtlık bozukluklarını gidermek amacıyla önışlem olarak uygulanır. Histogram eşitleme sonucunda temel histogram dağılım yapısı değişmez sadece belirli bir aralıktaki histogram tüm aralığa yayılır ve görüntü netleştirilerek daha ayırık ve düzgün dağılımlı bir histogram elde edilir. Görüntü üzerinde belirli bir bölgeye (yerel) veya tümüne (global) olarak uygulanabilir.

Histogram eşitleme işlemi şu şekilde gerçekleştirilir. Gri seviyede $N \times M$ boyutunda ve G (sıklıkla 256 seviye kullanılır) adet gri seviye yoğunluk bilgisine sahip görüntü olsun. Histogram bilgilerini tutmak için G boyutunda bir H dizisi tanımlansın ve dizinin tüm başlangıç değerleri sıfıra eşitlensin. Öncelikle görüntü üzerindeki tüm piksel verileri dolaşarak elde edilen her piksel yoğunluk değeri (pd) ile H dizisinde ilgili indisteki değeri 1 arttırılarak histogramı (1.16) şeklinde hesaplanır [19].

$$H[pd] = H[pd] + 1 \quad (1.16)$$

İkinci olarak kümülatif dağılım fonksiyonunu ifade eden histogram $H_k[0] = H[0]$ değer ataması yapıldıktan sonra (1.17) şeklinde hesaplanır.

$$H_k[p] = H_k[p - 1] + H[p], \quad p = 1, \dots, G - 1 \text{ için} \quad (1.17)$$

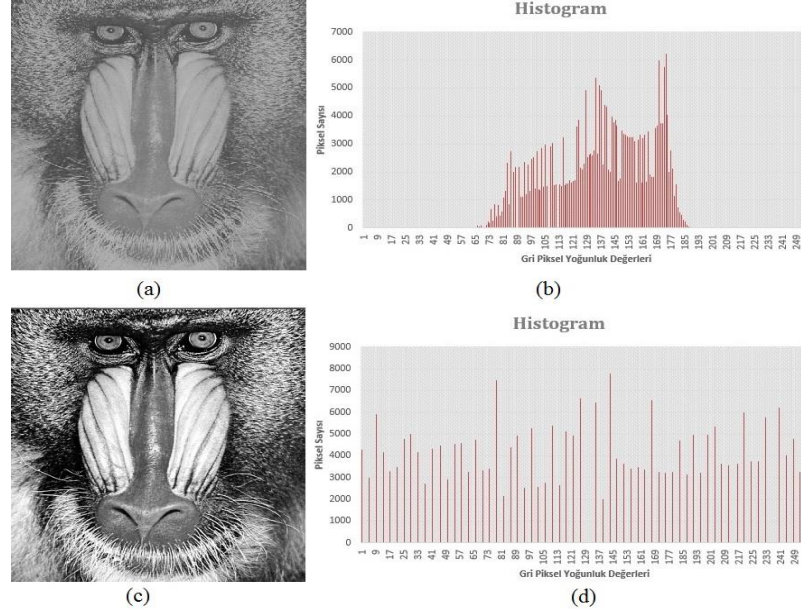
Üçüncü olarak H_k kümülatif histogramındaki her değeri hedef görüntüde olması istenen en büyük değer ile $(G - 1)$ çarpıp toplam piksel sayısına bölerek normalizasyon (1.18) şeklinde gerçekleştirilir.

$$T[p] = \text{DeğeriYuvarla} \left(\frac{G - 1}{N \times M} * H_k[p] \right) \quad (1.18)$$

Son olarak, giriş görüntüsü yeniden taranır ve hedef görüntüsüne normalize edilmiş gy piksel değerleri $qy = T[pd]$ ifadesi ile yerleştirilir.

Şekil 1.7'de görüldüğü gibi (a) görüntüsünün histogramı (b) ile ifade edilen histogramda görüldüğü gibi 73 ve 185 piksel yoğunluk değer aralığına sıkışmıştır.


Bu görüntü üzerinde histogram eşitleme yapıldığında görüntü zıtlığı belirgin şekilde artmış net (c) görüntüsü elde edilir. Yeni görüntünün (d) ile gösterilen histogramı ise 0 ve 255 yoğunluk değerleri arasında düzgün dağılıma sahip olmuştur.



Şekil 1.7. Zıtlığı bozuk görüntü (a) ve histogramı (b), histogram eşitleme uygulanmış görüntü (c) ve histogramı (d)

1.5.3. Çift Doğrusal Aradeğerleme

Çift doğrusal aradeğerleme yönteminde temel olarak hesaplanacak piksel değerine komşu olan dört piksel değerlerinin ortalaması alınır. İşlem sırasında yatay ve dikey yönlerde aradeğerleme gerçekleştirilir [28].



Şekil 1.8. Aradeğerleme ile hedef piksel değerinin hesaplanması

Örneğin, Şekil 1.8’de görüldüğü gibi P_{xy} noktasının piksel yoğunluk değeri $Q_{12}(x_1, y_2)$, $Q_{22}(x_2, y_2)$, $Q_{11}(x_1, y_1)$ ve $Q_{21}(x_2, y_1)$ konumlarındaki piksel değerleri ile hesaplanmak istenirse, öncelikle yatay eksende aradeğerleme yapılarak R_1 ve R_2 noktalarının piksel değerleri (1.19) ve (1.20) şeklinde hesaplanır [28].

$$f(R_1) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{11}) + \frac{x - x_1}{x_2 - x_1} f(Q_{21}) \quad (1.19)$$

$$f(R_2) \approx \frac{x_2 - x}{x_2 - x_1} f(Q_{21}) + \frac{x - x_1}{x_2 - x_1} f(Q_{12}) \quad (1.20)$$

Aradeğerleme ile elde edilen R_1 ve R_2 noktaları üzerinde dikey eksende aradeğerleme yapılarak hedef P_{xy} noktası piksel değeri ise (1.21) şeklinde hesaplanır.

$$f(P_{xy}) \approx \frac{y_2 - y}{y_2 - y_1} f(R_1) + \frac{y - y_1}{y_2 - y_1} f(R_2) \quad (1.21)$$

1.6. Haar Basamaklı Sınıflandırıcılar

Haar Basamaklı Sınıflandırıcılar (Haar Cascade Classifiers, HBS) görsel nesnelerin tespiti için hızlı ve aynı zamanda başarı oranı yüksek bir makine öğrenme yaklaşımıdır. İlk olarak Viola ve Jones [20] tarafından önerilmiştir. Önerilen yöntem yüz tespiti çalışmalarında uygulanmış ve yüksek derecede başarı göstermiştir.


Lienhart ve arkadaşları yaptıkları çalışmalarla [21] Viola ve Jones'un yaptıkları çalışmalara çeşitli yönlerden katkıda bulunmuşlardır. İlk olarak hesaplama maliyeti kolay ve döndürülmüş Haar Benzeri Öznitelikleri (HBÖ) önermişler ve yeni özniteliklerle tespit başarısını artırmışlardır. Daha sonra çeşitli boosting algoritmaları ve zayıf sınıflandırıcılar kullanarak diğer yöntemlere göre tespit performansını ve hesaplama karmaşıklığını karşılaştırmışlardır. Bu yöntem başarılı ve hızlı bir görsel nesne tespiti için şu üç önemli katkıyı sağlamaktadır.

- Özniteliklerin daha hızlı hesaplanmasını sağlayan ve yeni bir görüntü ifade tekniği olan integral görüntü (integral image) tekniği,
- Büyük veri kümeleri üzerinde ayırt ediciliği yüksek ve önemli özellikleri seçen ve bunları kullanarak yüksek seviyede başarılı sınıflandırıcıları oluşturmak için Adaboost temelli bir öğrenme algoritması,
- Karar ağaçlarına benzer ve her basamakta güçlü sınıflandırıcı barındıran ve hedef görüntü nesnesinin tespit başarı oranı atırıp, hesaplama ve tespit süresini önemli derecede azaltan yeni bir yöntem sınıflandırma yöntemi.


1.6.1. Haar Benzeri Öznitelikler

Haar Benzeri Öznitelikler (HBÖ) gri seviyede yoğunluk bilgisine sahip görüntülerde çeşitli boyut ve açıdaki dikdörtgensel bölgeler üzerinde toplam ve fark alma işlemleri ile gerçekleştirilir. Bu işlem, beyaz dörtgensel alan içinde yer alan toplam piksel yoğunluk değerlerinden siyah alan içerisindeki toplam piksel yoğunluk değerinin çıkartılması ile elde edilir. Örneğin, bir görüntü üzerinde (Şekil 1.11: a) ile ifade edilen herhangi bir konumdaki üç-dikdörtgen HBÖ, sol ve sağ beyaz alan ile örtüşen görüntü piksel yoğunluk değerleri toplamından ortadaki siyah alan ile örtüşen piksel yoğunluk değerleri toplamının çıkarılması ile elde edilir. Ayrıca, HBÖ'ler integral görüntü yaklaşımı kullanılarak hızlı bir şekilde gerçekleştirilir.


Şekil 1.9, 1.10 ve 1.11'de çeşitli tür ve açılardaki Haar Benzeri Öznitelik prototipleri gösterilmektedir. Örneğin, bu prototiplerden yatay ve dikey olanlar (Şekil 1.9: a, b ve Şekil 1.10: a, b, c, d) HBÖ prototipleri Viola ve Jones [20] tarafından, diğer prototipler (Şekil 1.9: c, d ve Şekil 1.10: e, f, g, h ve Şekil 1.11: a, b, c) ise Lienhart ve arkadaşları [21] tarafından önerilmiştir.



Şekil 1.9. Yatay (a), dikey (b) ve çeşitli açılarda (c, d) iki-dikdörtgen HBÖ'ler



Şekil 1.10. Yatay (a, b), dikey (c, d) ve çeşitli açılarda (e, f, g, h) HBÖ'ler



Şekil 1.11. (a, b) Merkezi çevreli ve (c) çapraz dört-dikdörtgen HBÖ'ler

1.6.2. İntegral Görüntü ve Hızlı Öznitelik Hesaplama

Frank Crow tarafından bilgisayar grafikleri alanında dikdörtgen şeklindeki alt alan toplamlarının hızlı ve etkili biçimde hesaplanması amacıyla geliştirilen Toplam Alan Tablosu yöntemi [22] Viola ve Jones [20] tarafından görüntü nesnelerinde HBÖ'nin hesaplanmasına uyarlanmış ve integral görüntü adını almıştır [23]. Bu yöntemle, her yeni ölçek ve türdeki HBÖ'ler teker teker hesaplanmaz. Bunu yerine tüm hesaplamalar başta yapılır ve gelecek hesaplamalarda kullanılmak amacıyla saklanır. Örneğin, x, y noktasındaki $ii(x, y)$ integral görüntü değeri (1.22) ifadesindeki gibi bu noktanın sol ve üstünde kalan alandaki tüm $i(x, y)$ piksel yoğunluk değerlerinin toplamını alınarak hesaplanır.


$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (1.22)$$

Ayrıca, (1.23) ve (1.24)'teki yineleme işlemlerinden faydalanarak görüntü üzerinden bir geçişle integral görüntü değerleri hesaplanabilir. Burada $s(x, y)$ kümülatif satır toplamını ifade etmektedir. Hesaplamalarda $s(x, -1) = 0$ ve $ii(-1, y) = 0$ eşitlikleri kullanılmaktadır.

$$s(x, y) = s(x, y - 1) + i(x, y) \quad (1.23)$$

$$ii(x, y) = ii(x - 1, y) + s(x, y) \quad (1.24)$$

Benzer şekilde görüntü üzerindeki tüm piksel noktaları için integral görüntü değerleri hesaplanır. Örneğin, Şekil 1.12 üzerinde A bölgesindeki piksel değerleri toplamı 1 noktasındaki integral görüntü değerine, A+B+C+D bölgelerinin toplam piksel değerleri toplamı ise integral görüntünün 4 noktasındaki değerine denk gelecektir. Ara D bölgesindeki piksel değerleri toplamı ise 4-2-3+1 integral görüntü işlemleri ile hesaplanabilir [20].



Şekil 1.12. İntegral görüntü hesaplanması

1.6.3. Adaboost ile Sınıflandırıcının Eğitimi

HBÖ seçiminin tespit edilecek nesneyi ayırt etmekte en faydalı olacak öznelikler arasından seçilmesi gerekmektedir. Örneğin, 24x24 boyutundaki bir pencere ile görüntüde hedef nesne yatay, dikey ve döndürülmüş HBÖ prototipleri kullanılarak tespit edilmek istenirse toplam 117,941 adet öznelik elde edilecektir. Yatay ve dikey özneliklerin toplam sayısı (1.25) ve 45° döndürülmüş özneliklerin toplam sayısı ise (1.26) ile hesaplanabilir. Burada $X = [W/w]$ ve $Y = [H/h]$ yatay ve dikeyde maksimum ölçeklendirme faktörünü ifade etmektedir.

$$XY \cdot \left(W + 1 - w \frac{X + 1}{2} \right) \cdot \left(H + 1 - h \frac{Y + 1}{2} \right) \quad (1.25)$$

$$XY \cdot \left(W + 1 - z \frac{X + 1}{2} \right) \cdot \left(H + 1 - z \frac{Y + 1}{2} \right) \text{ ve } z = w + h \quad (1.26)$$

Çok sayıda ve ayırt ediciliği düşük öznelik kullanımı problemini ortadan kaldırmak ve faydalı özneliklerin seçilmesi amacıyla Viola ve Jones [20] yaptıkları çalışmada Adaboost öğrenme [24] yaklaşımı üzerinde geliştirmeler yaparak büyük veri kümeleri üzerinde düşük sayıda ama önemli özellikleri seçen ve sınıflandırıcıyı eğiten bir yöntem önermişlerdir. Örneğin, Şekil 1.13'te üstte yüz bölgesi tespiti için ayırt ediciliği yüksek iki öznelik gösterilmektedir. Bu özneliklerden ilki göz bölgesinin burun ve yanak bölgelerinden daha koyu olması, ikincisi ise iki göz arasındaki burun uzantısının gözlerden daha açık renkte olmasından faydalanmaktadır.

Bu öznitelikler benzer şekilde alın ve yanaklar gibi diğer bölgelere uygulandıklarında ayırt edici olmayacaktır [20].



Şekil 1.13. Adaboost sınıflandırıcı ile seçilmiş bazı HBÖ'ler

Yukarıda bahsedilen gereksiz özniteliklerin elimine edilmesi problemi için AdaBoost ile en iyi HBÖ seçimi gerçekleştirilmektedir. Bu işlemde, tespit edilmek istenen nesneye ait pozitif örnekler ve tespit edilecek nesne içermeyen negatif örnekler kullanılır. Bu amaç doğrultusunda, AdaBoost algoritmasındaki zayıf sınıflandırıcılar (weak learners) bir öznitelikmiş gibi tasarlanır ve pozitif ve negatif eğitim örnekleri en iyi şekilde ayıran dikdörtgensel öznitelikler aranır. Her bir zayıf sınıflandırıcı $h_j(x)$; bir tane f_j özniteliği, θ_j eşik değeri ve eşitsizlik işaretinin yönünü ifade eden p_j içerir. Burada x tüm görüntü üzerinde hedef görüntü nesnesi yapılırken kullanılan pencerenin boyutudur [25].

$$h_j(x) = \begin{cases} 1, & p_j \cdot f_j(x) < p_j \theta_j \text{ ise} \\ 0, & \text{aksi takdirde} \end{cases} \quad (1.27)$$

Ancak, hesaplaması kolay bu zayıf sınıflandırıcılar eğitim verisinin çoğunu doğru sınıflandıramaz. Güçlü sınıflandırıcı ise zayıf sınıflandırıcıların doğrusal birleştirilmesi ile elde edilir. Bu amaçla her bir öznitelik için zayıf bir sınıflandırıcı eğitildikten sonra, eğitim kümesinde yanlış sınıflandırılan örneklerin ağırlıkları arttırılır, doğru sınıflandırılan örneklerin ağırlıkları ise azaltılır.

Örneklerin yeni ağırlık değerleri kullanılarak önceki zayıf sınıflandırıcıların az başarı ürettikleri örneklerin sınıflandırmasında daha başarılı sonuç veren yeni bir zayıf sınıflandırıcı (öznitelik) güçlü sınıflandırıcıya dâhil edilir. Bu şekilde her adımda yeni zayıf sınıflandırıcılar birleştirilerek güçlü bir sınıflandırıcı oluşturulur [26]. İstenen başarı/hata oranı veya yeterli sayıda öznitelik elde edilene kadar zayıf sınıflandırıcı eklemeye devam edilir. Adaboost algoritması adım adım şu şekilde ifade edilir [1]:

1) Eğitim veri kümesi $(x_1, y_1), \dots, (x_n, y_n)$ olan bir görüntü veri setinde x_i eğitim görüntülerini, $y_i \in \{0, 1\}$ negatif ve pozitif örnekliliği ifade eden etiket değerini, n ise toplam eğitim veri sayısı gösterebilir.

2) Öncelikle m adet negatif ve l adet pozitif görüntü verisi için başlangıç ağırlık değerleri $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$ hesaplanır.

3) Her döngüde yeni bir zayıf sınıflandırıcı seçimi şu şekilde gerçekleştirilir:
 $t = 1, \dots, T$ için

Ağırlık değerleri $w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}$ şeklinde normalize edilir.

Her bir j özniteliği için bir h_j sınıflandırıcısı eğitilir ve sınıflandırıcının hata oranı $w_{t,e_j} = \sum_i w_i |h_j(x_i) - y_i|$ şeklinde hesaplanır.

En düşük h_t sınıflandırma hatasına sahip (en başarılı) zayıf sınıflandırıcı seçilir.

Ağırlık değerleri $w_{t+1,i} = w_{t,i} \beta_t^{1-e_i}$ şeklinde güncellenir. Burada x_i örneği doğru sınıflandırılmışsa $e_i = 0$, aksi takdirde $e_i = 1$ alınır ve $\beta_t = \frac{\epsilon_t}{1-\epsilon_t}$ 'dir.

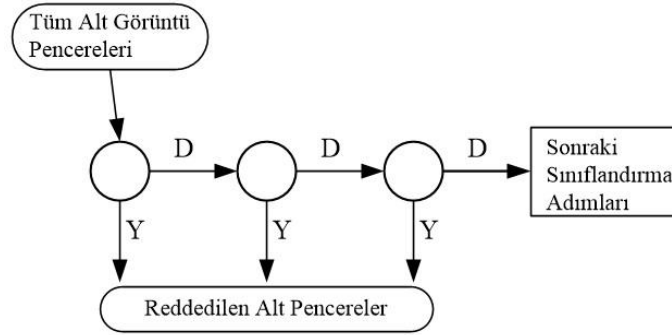
4) Her adımda yeni bir zayıf sınıflandırıcının seçilmesiyle güçlü bir sınıflandırıcı aşağıdaki şekilde ifade edilir.

$$h(x) = \begin{cases} 1, & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0, & \text{aksi takdirde} \end{cases}, \alpha_t = \log \frac{1}{\beta_t} \quad (1.28)$$

1.6.4. Basamaklı Sınıflandırıcı Yapısı


Basamaklı sınıflandırıcı yapısı karar ağaçlarına benzer bir yapıdadır ve basamak olarak nitelendirilen her adımda aranan nesneyi tespit etmek için bir güçlü sınıflandırıcı yer alır. Basamak yapısını kullanılarak tespit başarı oranı artırılırken tespit süresi azaltılır.

Bu yöntemde tespit işlemi temel olarak şu şekilde gerçekleştirilir: ilk sınıflandırıcıdan gelen pozitif bir sonuç, yine yüksek bir tespit oranıyla sınıflandırma için ayarlanmış ikinci sınıflandırıcıyı tetikler. İkinci sınıflandırıcıdan gelen pozitif bir sonuç ise üçüncü sınıflandırıcıyı tetikler ve bu şekilde adım adım ilerlenir. Herhangi bir sınıflandırıcıdan negatif bir sonuç gelmesi durumunda bu alt görüntü penceresinin aranan görüntü nesnesi olmadığına karar verilir ve bu alt görüntü penceresi hemen reddedilir. Ayrıca, görüntü nesnesi tespitinin hızlı bir şekilde gerçekleştirilmesi için ilk basamaklara az ve kolay hesaplanabilir öznelilikler eklenerek çoğu yanlış görüntü penceresi elimine edilir. Alt görüntü penceresi tüm basamakları pozitif bir sonuçla geçerse tespit edilmek istenen nesne bulunmuş olur. Basamaklı sınıflandırıcıların temel yapısı Şekil 1.14'deki gibidir.



Şekil 1.14. Basamaklı sınıflandırıcı yapısı

Örnek bir yüz görüntüsü üzerinde HBS yapısı ile çeşitli ölçeklerde görüntü nesnesi arama işlemi ise Şekil 1.15'de ifade edildiği gibi gerçekleştirilir.




Şekil 1.15. Pencere ile çeşitli ölçeklerde hedef görüntü nesnesinin aranması

1.7. Öznitelik Çıkarımı Yöntemleri

1.7.1. Yerel İkili Örüntüler

Yerel ikili örüntüler (YİÖ) [29] gri yoğunluk seviyesinden bağımsız ayırıcılığı yüksek bir doku betimleyicisi ve öznitelik çıkarım yöntemidir. Özellikle yüz tanıma/tespiti [30], yüz ifadelerin tanınması [31] ve diğer birçok görüntü analizi, görüntü işleme ve bilgisayarla görü uygulamalarında sıklıkla kullanılmaktadır. Şekil 1.16'de [34] ifade edildiği gibi ortam aydınlanma değişimlerine karşı toleranslı olması nedeniyle günlük hayat problemlerinde ve hesaplama maliyeti düşük olması nedeniyle de gerçek zamanlı uygulamalarda başarı göstermektedir.



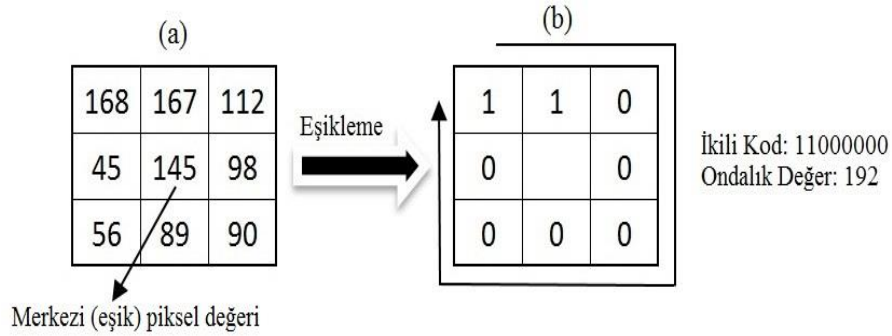
Şekil 1.16. Farklı aydınlanma ortamlarındaki orijinal görüntüler (üstte), YİÖ ile ifade edilen görüntüler (altta)

I ile ifade edilen gri seviyedeki bir görüntü üzerinde herhangi bir $p_m = (x_m, y_m)$ pikseli için YİÖ (1.29) ile ifade edildiği şekilde hesaplanır. Burada, K 3×3 'lük bir pencere içerisindeki komşu sayısını, n_p ise p_m merkez pikselinin saat yönündeki p . komşusunu ifade etmektedir. Komşu ile merkez piksel arasındaki farkı ifade eden s fonksiyonu ise (1.30) şeklinde tanımlanır [33].

$$YiÖ_K(p_m) = \sum_{p=0}^{K-1} s(n_p(p_m) - I(p_m)) \cdot 2^p \quad (1.29)$$

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1.30)$$

Yukarıda (1.29) ve (1.30) ile ifade edilen temel YİÖ operatörünün hesaplanması daha detaylı açıklanacak olursa, burada görüntü üzerindeki her bir piksel değeri için Şekil 1.17’de belirtildiği gibi bir etiket değeri oluşturulur. Bu etiket değeri, her bir merkez piksel ile bu pikseli çevreleyen 3x3’lük komşuları arasında piksel değerlerinin karşılaştırılması ile elde edilir. Karşılaştırma işleminde merkez piksel değeri eşik değer olarak seçilir ve sırasıyla tüm komşular ve bu eşik değer arasındaki farklar hesaplanır. Eğer komşu piksel değeri eşik değerinden büyük veya eşitse 1, küçükse 0 olarak ile işaretlenir. Tüm bu değerler yan yana yazılarak öncelikle 8 bitlik bir kod elde edilir, daha sonra ikilik tabandaki bu kod ondalık sayı düzenine çevrilerek merkez pikselin YİÖ etiket değeri elde edilir. Benzer şekilde görüntü üzerindeki tüm piksel değerleri için benzer şekilde YİÖ etiket değerleri hesaplanır.



Şekil 1.17. Temel YİÖ operatörünün uygulaması, 3x3’lük komşu pikseller (a), ikili kod ve ondalık değer elde edilmesi (b)


Ojala ve arkadaşları yaptıkları çalışmalarla [34] YİÖ operatörünü (1.31) ile ifade edildiği şekilde farklı boyutlarda ve dairesel komşu değerlerini kullanarak Şekil 1.18’de [34] gösterildiği şekilde geliştirmişlerdir. Bu dairesel komşuluk operatörü, R ile ifade edilen yarıçap bilgisi ve R ile tanımlanan daire üzerinde YİÖ hesaplamasında kullanılacak örnekleme sayısı olan P ile ifade edilir.

Örnekleme noktasının herhangi bir piksel üzerine denk gelmediği durumlarda çift doğrusal aradeğerleme vb. yöntemler kullanılarak piksel değerleri elde edilir.

$$YiÖ_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_m) \cdot 2^p \quad (1.31)$$

Burada $g_m = (x_m, y_m)$ merkezi piksel değerini, g_p ise g_m merkez pikselinin p . örnekleme noktasının değerini ifade etmektedir. Hesaplamalarda g_m noktasının koordinat değerleri $(0, 0)$ alınır ve g_i örnekleme noktasındaki (M_{xp}, M_{yp}) koordinatları (1.32) denklemi kullanılarak hesaplanır [32].

$$M_{xp} = x_m + R \cdot \cos \frac{2 \cdot \pi \cdot p}{P}, \quad M_{yp} = y_m - R \cdot \sin \frac{2 \cdot \pi \cdot p}{P} \quad (1.32)$$



Şekil 1.18. Farklı P ve R değer çiftleri için dairesel YİÖ operatörleri

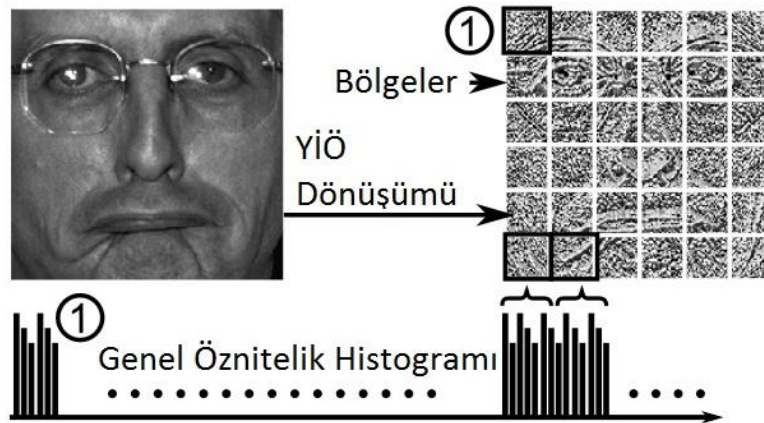
1.7.1.1. Düzenli Örüntüler

YİÖ'lerden öznitelik çıkarım işlemi bu örüntülerin histogramı (YİÖH) hesaplanarak gerçekleştirilir. Histogram hesaplama işleminde hem öznitelik vektörünün boyutunu azaltmak hem de ayırt ediciliği yüksek örüntülerin kullanılmasını sağlamak amacıyla düzenli örüntülerin seçilmesi yaklaşımı kullanılır. Örneğin, 8 komşuluklu bir YİÖ ele alındığında 256 (2^8) adet farklı kod yani örüntü oluşur ve histogram 256 adet bölmeden oluşur. Ancak, tanıma işlemlerinde tüm örüntüler önemli derecede ayırt ediciliğe sahip değildir ve bu nedenle düşük ayırtıcılığa sahip örüntülerin elenmesi gerekir.

Eleme işlemi düzenli örüntülerin seçilmesi ile gerçekleştirilir. Düzenli örüntüler ikili YİÖ kodunda 0 ile 1 veya 1 ile 0 arasındaki geçiş sayısı 2 veya daha az olanlardır.

Örneğin; 00000000, 00001111, 01110000 kodlarında geçiş sayıları sırasıyla 0, 1 ve 2 olması nedeniyle düzenli, 11001001 ve 01010011 kodları ise sırasıyla 4 ve 6 geçişe sahip olduklarından düzenli değildir [35]. YİÖH hesaplanırken her düzenli örüntü için bir bölme ayrılır ve düzenli olmayan diğer tüm örüntüler ise bir bölmede toplanır. 8 komşuluklu bir YİÖ için 256 yerinde 58 bölmeli bir histogram hesaplanır. Bu 58 adet düzenli kod ise 00000000, 00000001, 00000011, 00000111, 00001111, 00011111, 00111111, 01111111, 11111111 kodları ve bu örüntülerin döndürülmesi ile elde edilen kodlardır. Düzenli olmayan diğer tüm örüntülerde bir bölmede toplanarak 59 adet bölmeye sahip histogram elde edilir [36].

Sadece örüntü bilgisini değil aynı zamanda görüntüdeki konum bilgisinden de faydalanmak ve daha güvenilir sonuçlar elde etmek amacıyla tüm YİÖ görüntüsünün histogramını hesaplamak yerine bu işlem görüntü üzerinde yerel olarak uygulanır. Bu YİÖH'ları görüntünün belirli boyutlarda alt görüntülere ayrılması ve her birinden yerel YİÖH'larının hesaplanması ile gerçekleştirilir. Hesaplanan tüm histogram vektörleri yan yana yerleştirilerek genel YİÖH elde edilir. Şekil 1.19'de [37] örnek bir yüz görüntüsünün 7x7 oranında alt görüntülere ayrılması ve YİÖH'larının hesaplanması gösterilmektedir.



Şekil 1.19. Yerel histogramların birleştirilmesiyle genel YİÖH öznitelik vektörünün oluşturulması

1.7.2. Temel Bileşen Analizi

Temel Bileşen Analizi (TBA) çeşitli alanlarda (istatistik, örüntü tanıma, sinyal ve görüntü işleme, veri sıkıştırma) sıkça kullanılan değişken veya boyut azaltmaya yarayan kılavuzsuz istatistiksel bir yöntemdir. TBA sıklıkla istatistiksel analiz için kullanılsa da son zamanlarda örüntü tanıma problemlerinde sıkça kullanılmaya başlamıştır. Özellikle büyük boyuttaki ham verileri daha düşük boyuttaki özellik uzayına taşımak için kullanılır. TBA'nın temel olarak 3 kullanım amacı var. Bunlar;

- Veri boyutunu azaltılması ve öznelik çıkarımı
- Tahminde bulunma
- Veri setinin görüntülenmesi

Temel bileşen analizi çalışmalarda sıklıkla yüz tanıma problemleri için kullanılmış ve başarılı sonuçlar alınmıştır. Bu yöntemde, yüz bölgelerinin öznelik çıkarımı yüz üzerindeki göz, burun ve dudak konumları veya yüzün en boy bilgileri gibi geometrik temelli özellikler kullanılarak gerçekleştirilmez. Bunun yerine, eğitim verilerindeki dağılım ve değişim miktarlarını öznelik olarak kullanmayı sağlayan özvektörler (eigenvectors) ve özvektörlerden elde edilen özyüzlerin (eigenfaces) hesaplanması ile gerçekleştirilir.

1.7.2.1. Özyüzlerin Hesaplanması

Örneğin elimizde iki boyutlu ve gri seviye renk değerlerinden oluşan $K \times L$ boyutunda $I(x, y)$ görüntüsü olsun. Bu yüz görüntüsü $K \times L$ boyutundaki uzayda bir noktaya denk gelmektedir. Bu ve benzer boyuttaki gri seviyeli eğitim görüntüleri üzerinde özyüz hesaplanması adım adım aşağıdaki gibi gerçekleştirilir.

1) TBA'da öncelikle $K \times L$ (K : satır sayısı, L : sütun sayısı) boyutundaki $I(x, y)$ eğitim görüntülerinden Şekil 1.20'de ifade edildiği gibi yüz vektör uzayına dönüşüm yapılması gerekir. Bu vektör uzayında kullanılacak her bir Γ_i vektörel görüntüsü (1.33) denklemi ile ifade edildiği şekilde hesaplanır. Burada, p_j görüntü üzerindeki ilgili piksel değerlerini, N görüntüdeki toplam piksel sayısını ($K \times L$) ve M ise eğitim aşamasında kullanılacak toplam görüntü verisi sayısını ifade etmektedir.

$$\Gamma_i = [p_1 \dots p_N]^T, i = 1, \dots, M \quad (1.33)$$

$$I_1 = \begin{array}{c} \text{[Portrait of a man]} \\ \text{= } \end{array} = \begin{bmatrix} I_{111} & \dots & I_{11L} \\ \cdot & & \cdot \\ \cdot & & \cdot \\ I_{1K1} & \dots & I_{1KL} \end{bmatrix} = \begin{bmatrix} I_{111} \\ \cdot \\ I_{11L} \\ \cdot \\ I_{1K1} \\ \cdot \\ I_{1KL} \end{bmatrix}$$

Şekil 1.20. KxL boyutunda yüz görüntüsünü TBA'da kullanımı için sütun vektörüne dönüşümü

2) 1xN boyutundaki vektörel Γ_i görüntü verileri birleştirilerek NxM boyutundaki S eğitim matrisi (1.19) ile ifade edildiği şekilde oluşturulur.

$$S = \{\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M\} \quad (1.34)$$

3) Tüm yüz görüntü vektörlerinin Ψ ile ifade edilen ortalaması (1.35) ile ifade edildiği şekilde hesaplanır. Bu işlem kolon vektörü haline getirilen verilerin piksel değerlerinin toplanıp toplam görüntü sayısına bölünmesi ile elde edilir. Ortalama görüntü görüntülenmek istendiğinde elde edilen kolon matrisi KxL boyutundaki görüntü matrisine dönüştürülür.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (1.35)$$

4) Ortalama görüntü vektörünün, her bir görüntü vektöründen çıkarılması ile sıfır ortalamalı Φ eğitim matrisi (1.36) ile ifade edildiği şekilde elde edilir.

$$\Phi_i = \Gamma_i - \Psi \quad (1.36)$$

5) Sıfır ortalamalı vektörler üzerinden, verinin dağılımını en başarılı şekilde ifade edecek M adet ortonormal u_n vektörü (1.37) şeklinde seçilir. Bu u_n vektörlerinin her biri aşağıda tanımı verilen λ_k katsayılarını maksimum yapacak şekilde seçilmelidir [39].

$$\lambda_k = \frac{1}{M} \sum_{n=1}^M (u_k^T \Phi_n)^2 \quad (1.37)$$

Ayrıca, bu u_n vektörleri ortonormalik koşulu olan (1.38) formülünü sağlamalıdır.

$$u_1^T u_k = \delta_{1k} = \begin{cases} 1, & k = 1 \\ 0, & \text{Diğer} \end{cases} \quad (1.38)$$

6) u_k vektörleri ve λ_k sabitleri, aşağıda tanımı verilen kovaryans matrisi C 'nin sırasıyla özvektörleri ve özdeğerleridir. Bu matris temel olarak (1.39), (1.40) ve (1.41) şeklinde hesaplanır.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T \quad (1.39)$$

$$= AA^T \quad (1.40)$$

$$A = \{\Phi_1, \Phi_2, \Phi_3, \dots, \Phi_n\} \quad (1.41)$$

7) Yukarıda tanımı verilen C matrisinin özvektörleri ilgilenilen yüz uzayının özyüzlerini oluşturmaktadır. Dikkat edilirse, $N \times N$ boyutundaki yüz resimleri için C matrisi $N^2 \times N^2$ boyutundadır. Bu büyüklükteki bir matrisin özvektör ve özdeğerlerinin hesaplanması çalışmamızdaki gibi gerçek zamanlı olması istenen bir sistem için kullanışlı değildir. Bu sorunu çözmek için, eğitim kümesinde yer alan resimlerin sayısının resim uzayının boyutundan çok küçük olduğu durumlar için ($M \ll N$) formüldeki gibi matris boyutu $M \times M$ olacak şekilde (1.42) ile ifade edilen düzenleme yapılır [38].

$$L = A^T A \quad (1.42)$$

8) L matrisinin M adet v_1 özvektörleri hesaplanır ve bu özvektörler yardımıyla gerçek özvektörler için aşağıdaki yakınsama işlemi gerçekleştirilir [39].

$$u_l = \sum_{k=1}^M v_{lk} \Phi_k \quad l = 1, 2, \dots, M \quad (1.43)$$

9. Orijinal görüntülerin tümü elde edilen özyüz uzayına projekte edilir. Böylece eğitimde kullanılan herhangi bir yüz görüntüsünün sınıflandırma işlemlerinde kullanılacak öznitelik vektörü olan Ω^T (1.44) ifadesindeki formülde belirtildiği şekilde hesaplanır.

$$w_k = u_k^T (\Gamma - \Psi) \quad (1.44)$$

$$\Omega^T = [w_1 w_2 \dots w_M] \quad (1.45)$$

10) Herhangi bir yüz resmi, yüz uzayına yapılacak aşağıdaki izdüşüm ile yaklaşık bir görüntü ile elde edilebilir [38].

$$\Gamma = \Psi + \sum_{i=1}^M w_i u_i \quad (1.46)$$

11) Test aşamasında herhangi bir test görüntüsüne ait öznitelik vektörü test görüntüsünün eğitim işlemi sonunda elde edilen özyüz uzayına projekte edilmesi ile hesaplanır.


1.8. Sınıflandırma Yöntemleri

1.8.1. K En Yakın Komşu Algoritması

K en yakın komşusu algoritması (K-EYK) algoritması kolay anlaşılabilir ve uygulanabilir bir yöntemdir. Bu yöntemde öğrenme ve test sorgusu gerçekleştiriminin aynı anda gerçekleştirilmesi nedeniyle Tembel Öğrenme (Lazy Learning) veya Durum Temelli Öğrenme (Instance Based Learning) grubuna, veri ve verilerin sınıf bilgilerini kullanarak

bilgi sahibi olunan verilerde öğrenme işlemi gerçekleştirdiğinden dolayı Kılavuzlu Öğrenme algoritmaları grubuna dâhil edilmektedir [40]. K-EYK sınıflandırma, veri madenciliği ve regresyon problemlerinde sıklıkla kullanılmaktadır.

Örneğin; Şekil 1.21’de görüldüğü gibi üçgen şeklindeki veriler 1. sınıfı ve kare ile ifade edilenler ise 2. sınıfı ifade etsin. İki sınıfa ait bu veri uzayında merkezdeki test verisinin $k=2$ değeri ile hangi sınıfa ait olduğunun tespiti şu şekilde gerçekleştirilir. Öncelikle, test verisinin diğer tüm eğitim verilerine olan uzaklığı hesaplanır. Elde edilen mesafe bilgilerine göre test verisine en yakın $k=2$ eğitim verisinin hangi sınıfta olduklarına bakılarak sınıflandırma gerçekleştirilir. Örnek şekilde, test verisine en yakın 2 eğitim verisi 1. sınıfa dâhil olduğundan bu sınıf türü ile etiketlenecektir.



Şekil 1.21. K-EYK ile test verisinin sınıflandırılması

Benzer şekilde $k=3$ için test verisi sınıflandırılmaya çalışırsa, en yakın 3 komşudan 2 tanesi 1.sınıfa dâhil olduğundan yeni veri 1. sınıfa, $k=5$ için sınıflandırma yapıldığında ise test verisi 2. sınıfa dâhil edilecektir [41].

K-EYK algoritmasının çalışmada olduğu gibi gerçek hayat uygulamalarında kullanımında, öncelikle test verisinin özellikleri çıkarılarak öznitelik vektörü elde edilir. Daha sonra, elde edilen bu vektörün sınıflandırılmış tüm diğer özellik vektörleri ile aralarındaki mesafeler hesaplanır. Karar verme aşamasında, en yakın k adet komşu dikkate alınarak, test verisi çoğunluğun olduğu sınıfa dâhil edilir.

K-EYK algoritmasında özellik vektörlerinin birbirlerine olan uzaklıklarının hesaplanmasında çeşitli uzaklık ölçüleri kullanılabilir. En yaygın kullanılan ve bilinen uzaklık ölçütü öklid uzaklığıdır ve hesaplanması (1.47) ile ifade edildiği şekildedir. Burada p özellik vektörünün boyutunu, i ve j ise aralarındaki mesafe bilgisi hesaplanan vektör indekslerini ifade etmektedir [42].

$$d(i, j) = \sqrt{(x_{i1} - x_{j1})^2 + (x_{i2} - x_{j2})^2 + \dots + (x_{ip} - x_{jp})^2} \quad (1.47)$$

Sık kullanılan Manhattan ve Minkowski uzaklık ölçü denklemleri sırasıyla (1.48) ve (1.49) ile ifade edildiği şekildedir [42].

$$d(i, j) = (|x_{i1} - x_{j1}| + |x_{i2} - x_{j2}| + |x_{ip} - x_{jp}|) \quad (1.48)$$

$$d(i, j) = \left([|x_{i1} - x_{j1}|^m + |x_{i2} - x_{j2}|^m + \dots + |x_{ip} - x_{jp}|^m]^{1/m} \right) \quad (1.49)$$


1.8.2. Destek Vektör Makineleri

Destek vektör makineleri öğrenme, örüntü sınıflandırma, kümeleme, yoğunluk tahmini ve verilerden regresyon kuralları üretmek amacı ile kullanılan popüler bir öğrenme algoritmasıdır [43]. Temel olarak İstatistiksel Öğrenme Teorisi (Statistical Learning Theory) ve Yapısal Risk Minimizasyonu (Structural Risk Minimization) ilkelerine dayanmaktadır. 1995 yılında Cortes ve Vapnik tarafından üzerinde geliştirmeler yapılarak sınıflandırma amacı ile kullanılmaya başlanmıştır.

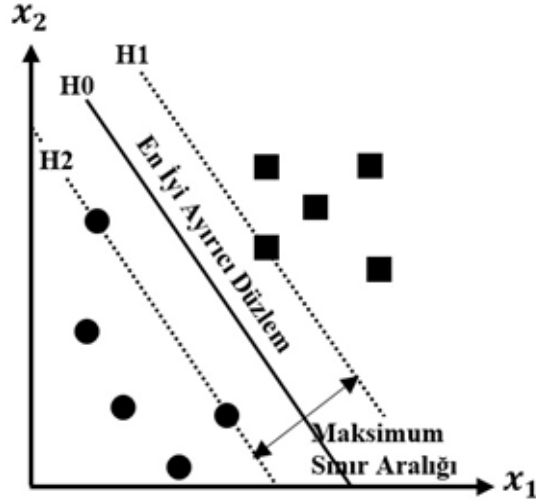
DVM çoğunlukla kılavuzlu öğrenme problemlerine uygulanmıştır ancak son zamanlarda kılavuzsuz öğrenme problemlerine uygulanmasına yönelik çalışmalar yapılmaktadır [44]. Kılavuzlu öğrenme problemlerine uygulanmasında veri ve verilerin sınıf bilgilerini (veri etiket değerleri) kullanarak bilgi sahibi olunan verilerde öğrenme işlemi gerçekleştirilmektedir. Kılavuzsuz öğrenme yöntemlerinde ise eğitim verilerinin sınıf bilgileri girişte verilmez, verinin özellik uzayındaki dağılımından faydalanarak sınıflandırma işlemini öğrenme algoritmasının gerçekleştirmesi beklenir.

Bu yöntemde temel olarak doğrusal ayrıştırılabilen veri yapıları için en iyi ayırıcı hiperdüzlem belirlenerek sınıflandırma gerçekleştirilir. Ancak, çoğu sınıflandırma probleminde veriler uzaya doğrusal olarak dağılmamakta ve ayrıştırılmamaktadır. Özellikle, bu çalışmada olduğu gibi yüksek boyutlu görüntü veri ve özelliklerinin sınıflandırılması problemlerinde bu durumla sıklıkla karşılaşmaktadır. Bu yöntemde öznitelik uzayında doğrusal ayrıştırılmayan veriler çeşitli dönüşümlerle farklı boyutta ve doğrusal ayrıştırmanın gerçekleştirilebileceği öznitelik uzaylarına taşınarak sınıflandırılmaya çalışılır [45].

Örneğin, Şekil 1.22’teki gibi 2 boyutlu kartezyen uzayında iki sınıfa ait doğrusal ayrıştırma problemi şekilde gösterildiği gibi birçok doğru ile kolayca çözülebilmektedir. Ancak, herhangi bir gruptaki sınıf verilerine yakın ayırıcı doğruların çoğu gürültülere duyarlı olacak ve ayrıştırma probleminde genelleştirilmeyi sağlamayacaktır [46]. DVM sınıflandırma yönteminde öncelikle destek vektörler (şekilde içi dolu olarak gösterilen sınıf verileri) ve bu vektörler arasında en geniş sınır aralığı bulunur. Daha sonra bu sınır bölgesinden geçen ve en iyi ayrıştırmayı sağlayacak doğru Şekil 1.23’de ifade edildiği şekilde belirlenir.



Şekil 1.22. İki boyutlu uzayda 2 farklı sınıfı ayırıcı muhtemel küçük sınırlı doğrular




Şekil 1.23. En geniş sınır aralığında en iyi ayırıcı doğrular

1.8.2.1. Doğrusal Destek Vektör Makineleri

1.8.2.1.1. Doğrusal Ayrılabilir Veriler İçin İkili Sınıflandırma

Örneğin, eğitim için $x_i \in \mathbb{R}^D$ giriş öznitelik vektörleri ve $y_i \in \{1, -1\}$ etiketleri ile ifade edilen L adet eğitim verisi $\{x_i, y_i\}$, $i = 1 \dots L$ şeklinde ifade edilsin. Burada D değeri eğitim için kullanılacak öznitelik sayısını yani boyutu ifade etmektedir.

Verilerin doğrusal ayrılabilir olması Şekil 1.24'te [46] görüldüğü gibi $D = 2$ durumunda farklı iki sınıfa ait verilerin bir doğru ile doğrusal olarak ayrılabilmesidir. $D > 2$ durumunda ise veriler hiperdüzlemler ile doğrusal olarak ayrıştırılabilirler. Bu hiperdüzlem $w \cdot x + b = 0$ denklemi ile tanımlanabilir. Burada, w ağırlık vektörü hiperdüzleme diktir ve $b/\|w\|$ hiperdüzlem ile orijin arasındaki dikey mesafedir. Destek vektörler hiperdüzleme en yakın verilerdir. DVM bu hiperdüzlem ile destek vektörleri arasındaki mesafenin maksimum olmasını sağlayacak şekilde yönlendirilmiş en iyi ayırıcı hiperdüzlemin bulunmasını amaçlamaktadır [46, 47].



Şekil 1.24. Doğrusal ayrılabilir veriler ve doğrusal ayırıcı hiperdüzlem yapısı

Şekil 1.24'te ifade edildiği gibi en iyi ayırıcı hiperdüzlemin hesaplanmasında kullanılacak w ve b değişken değerlerinin hesaplanması için farklı sınıflara ait eğitim verileri (1.50) ve (1.51) eşitsizlikleri ifade edilir. Burada w ağırlık vektörünü, b ise sabit terimi ifade etmektedir.

$$x_i \cdot w + b \geq +1, y_i = +1 \text{ için} \quad (1.50)$$

$$x_i \cdot w + b \leq -1, y_i = -1 \text{ için} \quad (1.51)$$

(1.50) ve (1.51) eşitsizlikleri birleştirilerek (1.52) elde edilir.

$$y_i(x_i \cdot w + b) - 1 \geq 0, \forall_i \quad (1.52)$$

Hiperdüzleme en yakın olan ve destek vektörlerinin yer aldığı H_1 ve H_2 düzlemleri sırasıyla (1.53) ve (1.54) şeklinde ifade edilir.

$$x_i w + b = +1 \quad (1.53)$$

$$x_i w + b = -1 \quad (1.54)$$

Hiperdüzlem ile H1 ve H2 düzlemleri arasındaki uzaklıklar sırasıyla d_1 ve d_2 olarak tanımlandığında, hiperdüzlemin H1 ve H2 düzlemlerine eşit dik uzaklıkta olmasından faydalanarak $d_1 = d_2 - a$ ile ifade edilen ve DVM'nin sınır değeri elde edilir. Burada sınır değeri $1/\|w\|$ eşitlik değerine sahip olur ve sınırın en yüksek değere ulaşabilmesi için $\|w\|$ değerinin aşağıdaki koşulu sağlayacak şekilde minimum olarak seçilmesi gerekir [46].

$$\min \|w\| \text{ öyleki } y_i(x_i \cdot w + b) - 1 \geq 0 \forall_i \quad (1.55)$$

Bu ifade aşağıdaki şekilde düzenlenerek kuadratik programlama optimizasyonuna mümkün hale getirilir. Burada $\|w\|$ değeri $\frac{1}{2} \|w\|^2$ şeklinde düzenlenmiştir.

$$\min \frac{1}{2} \|w\|^2 \quad \text{s.t. } y_i(x_i \cdot w + b) - 1 \geq 0 \forall_i \quad (1.56)$$

Ortaya çıkan kısıtlamalı optimizasyon problemini çözmek için Lagrange Çarpanları yöntemi $\alpha_i \geq 0 \forall_i$ koşulunu sağlayacak şekilde uygulanır [47].

$$L_P \equiv \frac{1}{2} \|w\|^2 - \sum_{i=1}^L \alpha_i y_i(x_i \cdot w + b) + \sum_{i=1}^L \alpha_i \quad (1.57)$$

Denklemden w , b ve α değerlerinin hesaplanması gerekmektedir. Bu işlem L_P denkleminin w ve b 'ye göre aşağıdaki gibi türevlerinin alınması ve sıfıra eşitlenmesi ile gerçekleştirilir [46].

$$\frac{\partial L_P}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^L \alpha_i y_i x_i \quad (1.58)$$

$$\frac{\partial L_P}{\partial b} = 0 \Rightarrow \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.59)$$

(1.58) ve (1.59) denklemleri kullanılarak (1.57) denklemi kullanılarak düzenlenirse, maksimum değere çekilmesi gereken α değişkenine bağlı dual problem formuna sahip (1.60) ile ifade edilen L_D denklemi elde edilir. Denklem çözümünde elde edilecek $\alpha_i > 0$ çarpanlarına sahip x_i eğitim verileri destek vektörlerini ifade eder [46].

$$L_D \equiv \sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \quad \text{s. t.} \quad \alpha_i \geq 0 \quad \forall_i, \quad \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.60)$$

Burada Lagrange çarpanları (1.61) ile ifade edilen denklem ve koşulları sağlayacak şekilde hesaplanır [46].

$$\max_{\alpha} \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right] \quad \text{öyleki} \quad \alpha_i \geq 0 \quad \forall_i \quad (1.61)$$

Bu konveks kuadratik optimizasyon problemi kuadratik programlama ile çözümlenerek α değerleri, denklem (1.58) ise çözümlenerek w değerleri elde edilir. En iyi ayırıcı hiperdüzlemin hesaplanması için geriye sadece b değerinin hesaplanması kalır. (1.59) ifadesini sağlayan herhangi bir veri noktası (destek vektör) x_s (1.62) formunda olur [46].

$$y_s \left(\sum_{m \in S} \alpha_m y_m x_m \cdot x_s + b \right) = 1 \quad (1.62)$$

Burada S destek vektörlerinin indeks kümesini ifade eder ve bu küme $\alpha_i > 0$ şartı ile belirlenir. Elde edilen ifade y_s ile çarpılarak, formül (1.50) ve (1.51) kullanılarak ve $y_s^2 = 1$ eşitliğinden faydalanarak b değeri (1.63) denklemi ile elde edilir [46].

$$b = y_s - \sum_{m \in S} \alpha_m y_m x_m \cdot x_s \quad (1.63)$$

Gerekli w ve b değerlerinin hesaplanmasıyla en iyi yönelimdeki hiperdüzlem elde edilmiş olunur. Bu hiperdüzlem kullanılarak test verilerinin sınıflandırılması gerçekleştirilir.

1.8.2.1.2. Doğrusal Ayrılamayan Veriler İçin İkili Sınıflandırma


Birçok uygulama alanında olduğu gibi görüntü verilerinin sınıflandırılmasında veri setinin özellik uzayında doğrusal ayrılması mümkün değildir. Bu durum Şekil 1.25'ten de [46] görüleceği gibi bazı eğitim verilerinin hiperdüzlemin diğer sınıfa ait kısmında kalmasından kaynaklanmaktadır. Bu yanlış sınıflandırma problemi (1.64) ve (1.65) denklemlerine pozitif değere sahip $\xi_i, i = 1, \dots, L$ gevşek değişkenin (1.66) koşulu ile eklenmesiyle oluşan 1.67 denklemi ile çözülür [46]. Bu değişken yanlış sınıflandırılan bir veri örneğinin gerçekte ait olduğu karar sınırına olan uzaklığının ölçüsünü ifade etmektedir.

$$x_i \cdot w + b \geq +1 - \xi_i \quad y_i = +1 \text{ için} \quad (1.64)$$

$$x_i \cdot w + b \leq -1 + \xi_i \quad y_i = -1 \text{ için} \quad (1.65)$$

$$\xi_i \geq 0 \quad \forall_i \quad (1.66)$$

$$y_i(x_i \cdot w + b) - 1 + \xi_i \geq 0 \quad (1.67)$$



Şekil 1.25. Doğrusal ayrılamayan veriler ve ayırıcı hiperdüzlem yapısı

Ayrıca, yanlış sınıflandırma olasılığını düşürme ve sınır genişliğinin maksimum hale gelmesi amacıyla probleme aşağıdaki gibi C düzenleme parametresi eklenir [46].

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i \quad (1.68)$$

Lagrange fonksiyonu $\alpha_i \geq 0$ ve $\mu_i \geq 0 \forall_i$ koşulu ile aşağıdaki şekilde düzenlenir. Burada, μ_i , ξ_i gevşek değişkenlerinin değerlerini pozitif tutmak için kullanılmış Lagrange çarpanlarıdır [47].

$$L_P \equiv \frac{1}{2} \|w\|^2 + C \sum_{i=1}^L \xi_i - \sum_{i=1}^L \alpha_i [y_i(x_i \cdot w + b) - 1 + \xi_i] - \sum_{i=1}^L \mu_i \xi_i \quad (1.69)$$

(1.69) probleminin çözülmesi amacıyla L_P Lagrange fonksiyonunun w , b ve ξ_i değişkenlerine göre sırasıyla türevleri alınarak (1.58), (1.59) ve (1.70) eşitlikleri elde edilir [46].

$$\frac{\partial L_P}{\partial \xi_i} = 0 \Rightarrow C = \alpha_i + \mu_i \quad (1.70)$$

Bu eşitlikler (1.69) Lagrange fonksiyonuna yerleştirilerek maksimum değere çekilmesi gereken α değişkenine bağlı dual problem formundaki (1.71) denklemini elde edilir. Bu denklemin koşulları (1.72) şeklinde olur [46].


$$\max_{\alpha} \left[\sum_{i=1}^L \alpha_i - \frac{1}{2} \alpha^T H \alpha \right] \quad (1.71)$$

$$0 \leq \alpha_i \leq C \forall_i \text{ ve } \sum_{i=1}^L \alpha_i y_i = 0 \quad (1.72)$$

Yukarıdaki formülde $0 \leq \alpha_i \leq C$ koşulunu sağlayan Lagrange çarpanlarını ifade eden eğitim verileri destek vektörleri ifade eder.

1.8.2.2. Doğrusal Olmayan Destek Vektör Makineleri

Birçok uygulama alanında olduğu gibi görüntü verilerinin sınıflandırılmasında da veri setinin tam veya belirli bir hatayla doğrusal olarak ayrılması mümkün olmamaktadır. Bu durumda veriler üzerinde sınıflandırma işlemi çekirdek fonksiyonları kullanılarak verinin yüksek boyutlu başka bir uzaya taşınması ve bu uzayda doğrusal ayırıcı hiperdüzlemin aranması ile gerçekleştirilir. Doğrusal ayrılamayan bir veri seti örneği Şekil 1.26'da solda ve bu veri setinin radyal tabanlı çekirdek fonksiyonları kullanılarak doğrusal ayrıştırmanın gerçekleştirilebileceği daha yüksek boyutta bir uzaya taşınması sağda verilmiştir.



Şekil 1.26. 1 boyutta doğrusal ayrılma durumu (a), çekirdek fonksiyonları ile 2 boyutta doğrusal ayrılabilirliğin sağlanması (b)

Çekirdek fonksiyonlarının temel yapısı (1.73) şekilde ifade edilir. Burada, $\Phi()$ fonksiyonu eğitim verilerini daha yüksek boyuttaki bir uzaya taşımak amacı ile kullanılan fonksiyonu, K ise yeni uzaydaki verilerin iç çarpımları olan çekirdek fonksiyonunu temsil etmektedir [46].

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (1.73)$$

Literatürde kullanılan çok sayıda çekirdek fonksiyonu bulunmaktadır. Bu çekirdek fonksiyonlarının Merker teoremi koşullarını sağlaması gerekmektedir. Bu fonksiyonlardan bazıları ve matematiksel ifadeleri aşağıdaki gibidir [47].

Tablo 1.1. Çekirdek fonksiyonları, matematiksel ifadeleri ve aldıkları parametreler

Çekirdek Fonksiyonu	Matematiksel İfadesi	Parametreler
Doğrusal Çekirdek	$K(x_i, x_j) = x_i^T x_j$	-
Çokterimli Çekirdek	$K(x_i, x_j) = (\gamma(x_i^T x_j) + r)^d, \gamma > 0$	C, γ, r, d
Radyal Tabanlı Çekirdek	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$	C, γ
Sigmoid Çekirdek	$K(x_i, x_j) = \tanh(\gamma(x_i^T x_j) + r)$	C, γ, r

Tanımlanan bu çekirdek fonksiyonlarının uygulanması aşamasında en önemli adımlardan biri Tablo 1.1’de verilen uygun çekirdek fonksiyonu ve parametre değerlerinin seçilmesidir. Bu amaçla çekirdek fonksiyonları problem üzerinde alabilecekleri parametre değerleri ile birlikte uygulanmalıdır. Bu en iyi parametrelerin belirlenmesinde önceki çalışmalarda sıkça ızgara tabanlı arama (grid search) yöntemi kullanılmıştır. Bu yöntemde, her bir parametre için alt-üst sınır değerleri ve parametre değerinin değişimini ifade eden artış miktarı belirlenir. Herbir parametre çifti için sınıflandırma başarısı ölçülerek en iyi parametre seçimi gerçekleştirilir [48].

1.8.3. Yapay Sinir Ağları

Yapay Sinir Ağları - YSA (Artificial Neural Networks) son yıllarda çok sık ilgi gören ve mühendislik, tıp, finans, fizik, biyoloji, biyomedikal ve sosyal bilimler gibi çok çeşitli alanlarda sıklıkla kullanılan bir yöntemdir. İnsan beyninin çalışma prensiplerinden esinlenerek geliştirilmiştir ve beynin öğrenme ve tahmin etme gibi işlevlerini matematiksel olarak modelleyerek günlük hayat problemlerine uygulanmasını sağlayan sistemlerdir. Bu sistemler yapay olarak tanımlanan sinir hücrelerinin birbirlerine çeşitli şekil ve ağırlıklarda bağlanması ile oluşur.

1.8.3.1. Yapay Sinir Ağlarının Tarihi

YSA'nın oluşturulması için ilk hesaplama modelleri olan Eşik Mantık Birimi (Threshold Logic Unit) 1943 yılında McCulloch ve Piits tarafından [50] önerilmiştir. Çalışmada yapay sinir hücrelerinden oluşan bir ağın hesaplama yeteneğine sahip olabileceği ve tüm mantıksal ifadelerin yapay sinirler vasıtasıyla ifade edilebileceği gösterilmeye çalışılmıştır. 1949 yılında Hebb [51] sinirsel yolların her yeni kullanımında güçlendiğini göstermiş ve YSA'larının eğitiminde kullanılabilecek Hebb öğrenme kuralı geliştirmiştir. 1959 yılında Frank Rosenblatt [52] basit nöron modellerine ve hesaplama işlemlerinde dayanan ve örüntü tanımada kullanılabilen tek katmanlı perseptron adı ile bilinen modeli önermiş ve YSA üzerindeki çalışmalar hız kazanmıştır. Minsky ve Papert 1969 yılında yaptıkları çalışma [53] ile tek katmanlı ve doğrusal perseptronların doğrusal ayrılabilen basit problemlerde çalışabildiğini ancak doğrusal olmayan XOR problemini gibi zor bir problemi çözemediğini ve bilgisayarların büyük yapay sinir ağları etkili biçimde işleyecek kadar gelişmediklerini göstermişlerdir. Bu nedenle kısa süreliğine YSA alanında yapılan çalışmalar duraksama döneminde girmiştir.


Hopfield 1982 yılı ve sonrasında yaptığı çalışmalar [54] ile YSA'larında nöronların karşılıklı etkileşimlerine dayalı hesaplama modeli önermiştir. Ayrıca, basit bir analog devre modelini kurmuş, bu modeli kullanarak çeşitli zor problemler için çözümler önermiştir. YSA üzerindeki çalışmalar ile bu başarılı sonuçlar ile birlikte hız kazanmıştır ve 1984 yılı ve sonrasında Boltzman Makinası olarak bilinen yapay nöronlar arasında geri besleme döngülerinin de kullanılabildiği ilk YSA modelleri ortaya çıkmaya başlamıştır. Rumelhart ve arkadaşları 1986 yılı ve sonrası yaptıkları çalışmalarla [55] ileri beslemeli yapay sinir ağları için hatanın geriye yayılma algoritmasını geliştirmişler ve YSA'nın gelişmesinde önemli rol oynamışlardır.

1.8.3.2. Biyolojik Sinir Hücresi

İnsan benzeri düşünen, davranan ve öğrenen sistemlerin bilgisayarlar üzerinde gerçekleştirilmesi için insan beynini bu işlemleri nasıl meydana getirdiğinin incelenmesi gerekmektedir. Tüm beyin aktiviteleri ve insanın öğrenme vb. işlemleri nasıl gerçekleştirdiği günümüzde de büyük bir oranda bilinemediği için, bu alanda çalışmalar insan beynini oluşturan nöron hücrelerinin modellenmesi üzerinde geliştirilmeye başlanmıştır. Beyin

hakkında bilgi sahibi olduğu oranda bilgisayar vb. sistemler üzerinde daha başarılı sistemler geliştirilebileceklerdir.


Beyin nöron olarak bilinen sinir hücrelerinden oluşmaktadır. Bu sinir hücreleri Şekil 1.27’de görüldüğü gibi dentrit (dendrite), akson (axon), sinaps ve hücre gövdesi (soma) bileşenlerinden oluşmaktadır. Dentritler nöron gövdesi etrafında, hücreye girdilerin alınmasında görevlidir. Dentritlere hücre gövdesine getirilen elektriksel sinyaller, çekirdek içerisinde işlenir ve sinyalleri taşımakla görevli bir sinirsel bağlantı olan akson çıkışa aktarır. Çıkışa gelen ve diğer sinir hücresine iletilecek elektriksel sinyallerin geçişi temassız kimyasal yapıdaki bölgeler olan sinapslar ile gerçekleştirilir.



Şekil 1.27. Biyolojik sinir hücresinin yapısı

1.8.3.3. Yapay Sinir Hücresi

Yapay sinir hücreleri biyolojik sinir hücrelerinden esinlenilerek geliştirilse de bu hücrelere göre oldukça basit bir yapıdadır. Bu yapılar Şekil 1.28’de ifade edildiği gibi bir veya daha fazla sayıda giriş, bir adet çıkış, tüm giriş ve çıkışlar için ağırlık değerleri ve toplama ile aktivasyon fonksiyonlarından oluşan basit hesaplama birimleridir. Girdi olarak gelen veriler ağırlık değerleri yardımıyla etki dereceleri göz önüne alınarak ilgili nörona bağlanırlar. Girdi ve ağırlık değer çiftleri toplama fonksiyonuna sokularak net girdi değeri hesaplanır. Son olarak aktivasyon fonksiyonu kullanılarak net nöron çıkışı hesaplanır [56].



Şekil 1.28. Yapay sinir ağı hücresinin yapısı

Toplama fonksiyonu ile girdi ve ağırlık bilgileri kullanılarak net girdi değeri (1.74) şeklinde hesaplanır. Burada x_i dış ortamlardan veya önceki nöronun çıktısı olarak gelen i . girdi değerini, w_i ise önceki katmandaki nöronun bu işlem elemanı üzerindeki etkisini ifade eden ve ağırlık eğitimi sırasında en uygun değere çekilmeye çalışılan i . ağırlık değerini ifade etmektedir. Net girdi değeri, her girdi değeri ve ilgili ağırlık değerinin çarpımlarının toplanması ve bu değere bias değerinin eklenmesi ile elde edilir [56].

$$\text{net} = \sum_{i=1}^n w_i x_i + b \quad (1.74)$$

Toplam fonksiyonu ile elde edilen bu net girdi değeri doğrusal veya doğrusal olmayan aktivasyon fonksiyonuna sokularak nöronun asıl çıktı değeri (1.75) şeklinde hesaplanır [56].


$$Y = f(\text{net}) = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (1.75)$$

1.8.3.4. Yapay Sinir Ağlarının Yapısı

Yapay sinir hücreleri sıklıkla birkaç katman halinde dizilerek çeşitli yapılarıdaki YSA modellerini oluştururlar. Temel bir YSA'da bu katmanlar işlevlerine göre girdi, ara (gizli) ve çıktı katmanları olmak üzere Şekil 1.29'daki gibi üç gruba ayrılmaktadır.

Girdi katmanı dış dünyadan gelen veriler üzerinde çoğunlukla işlem yapılmadan ara katmanlara iletir. Ara katmanlar girdi katmanından gelen verileri işleyerek çıktı katmanına

iletir. Bazı YSA yapılarında ara katman bulunurken bazılarında ara katman bulunmaz. Ara katman sayısı arttıkça da ağ üzerindeki işlem maliyeti artar. Ayrıca, bu katmandaki nöron sayısı girdi ve çıktı katmandaki yapay sinir hücresi sayısından bağımsızdır. Çıktı katmanı ise girdi verileri için çıktı değerlerini üretir. Geri beslemeli modelindeki ağırlarda çıktı katmanı bilgileri kullanılarak ağ üzerinde yeni ağırlık değerleri hesaplanır [56].



Şekil 1.29. Girdi, ara ve çıktı katmanlarından oluşan bir ağ yapısı

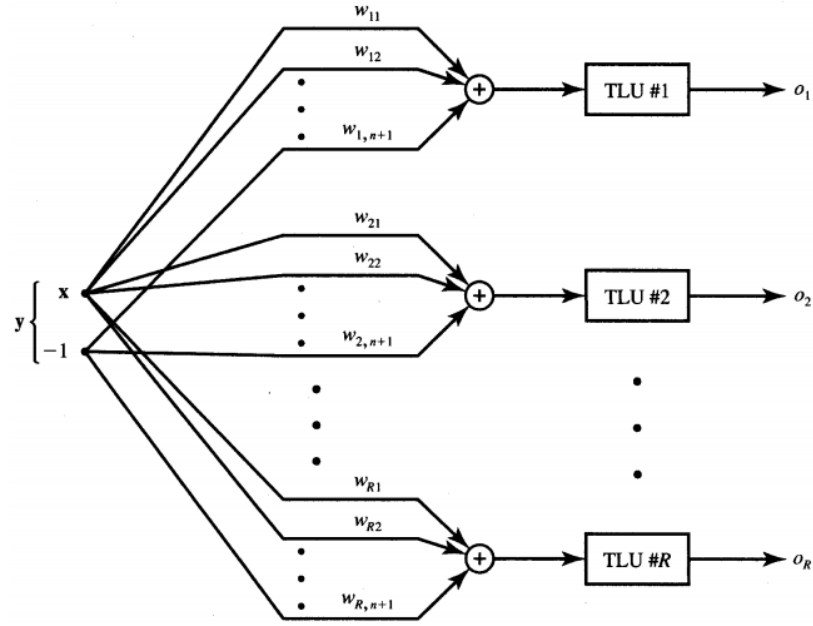
1.8.3.5. Aktivasyon Fonksiyonları

Modellenen bir yapay sinir hücresinde gelen girdiler üzerinde toplama fonksiyonları ile elde edilen net girdi değerini çıkışa aktarmadan önce istenen değerleri arasında sınırlandırmak amacıyla kullanılan fonksiyonlardır. Literatürde eşik veya transfer fonksiyonu olarak adlandırılırlar ve işlemlerde sıklıkla doğrusal olmayan aktivasyon fonksiyonları kullanılır. Keskin sınırlı, doğrusal, sigmoid ve hiperbolik aktivasyon fonksiyonları sıklıkla kullanılmaktadır.

1.8.3.6. Çok Kategorili Tek Katmanlı Ayrık Perseptron

YSA uygulamalarında önemli bir yeri olan perseptron yapısı özellikle çok katmanlı ve geri yayımlı modeli ile örüntü sınıflandırma problemlerinde sıkça kullanılmaktadır. Ayrıca, bu yapı YSA'nın temel yapısını anlamada basit yapısı nedeniyle kolaylık sağlamaktadır. Bu yöntemde ilk olarak eğitim verisi ve bu verilerin etiket değerlerini girdi olarak alınır.

Daha sonra her eğitim verisi için sırasıyla çıktı değerleri hesaplanır ve çıktı değeri ile girdi verisinin etiket değeri karşılaştırılarak sınıflandırma başarısına göre hata değeri hesaplanır. Son olarak hata değerine göre ağırlık bağlantı ağırlık değerleri güncellenerek belirli bir hata değeri veya eğitim adım sayısı kadar bu işlemlere devam edilir.



Şekil 1.30. Çok kategorili tek katmanlı ayrık perseptron yapısı

YSA'larının çalışma prensibini öğrenmek amacıyla Şekil 1.30 ile ifade edilen en basit YSA yapılarından biri olan çok kategorili ve tek katmanlı ayrık perseptronlarda ağ eğitimi şu şekilde gerçekleştirilir [57]. Örneğin, elimizde $\{x_1, d_1, x_2, d_2, \dots, x_p, d_p\}$ şeklinde eğitim veri ve etiket değer çiftleri bulunsun. Burada, $i = 1, 2, \dots, P$ değerleri için x_i vektörü ($n \times 1$) boyutunda herhangi bir eğitim verisini, d_i vektörü ise ($R \times 1$) boyutunda bu eğitim verisine ait etiket değerini ifade etsin. Öncelikle tüm eğitim verileri için eklemeli girdi değerleri (augmented input vector) $y_i = \begin{bmatrix} x_i \\ -1 \end{bmatrix}$ şekilde hesaplanır. Burada k herhangi bir eğitim adımını, p bir eğitim döngüsünde adım sayıcısını ve E güncel hata değerini ifade edecek şekilde eğitim işlemi adım adım şu şekilde gerçekleştirilir [57].

1) Küçük bir değere sahip c öğrenme sabit değeri seçilir.

2) Ağdaki tüm bağlantı ağırlıklarını ifade eden W matrisinde rastgele başlangıç değerleri verilir. Bu $W = w_{ij}$ matrisi $R \times (n + 1)$ boyutundadır. Diğer eğitim parametrelerine de (1.76) ile ifade edildiği şekilde başlangıç değer ataması yapılır.

$$k \leftarrow 1, p \leftarrow 1, E \leftarrow 0 \quad (1.76)$$

3) Eğitim verileri ağa verilerek o_i çıktı değerleri (1.78) ile ifade edildiği şekilde hesaplanır (Eğitim döngü aşaması burada başlar). Burada, w_i vektörü tüm bağlantı ağırlıklarının tutulduğu W matrisinin i . satırını ifade etmektedir.

$$y \leftarrow y_p, d \leftarrow d_p \quad (1.77)$$

$$o_i \leftarrow \text{sgn}(w_i^t y), \quad i = 1, 2, \dots, R \text{ için} \quad (1.78)$$

4) Mevcut ağırlık değerleri (1.79) şeklinde güncellenir.

$$w_i \leftarrow w_i + \frac{1}{2} c(d_i - o_i)y, \quad i = 1, 2, \dots, R \text{ için} \quad (1.79)$$

5) Döngü hatası (1.80) şeklinde hesaplanır.

$$E \leftarrow \frac{1}{2} (d_i - o_i)^2 + E, \quad i = 1, 2, \dots, R \text{ için} \quad (1.80)$$

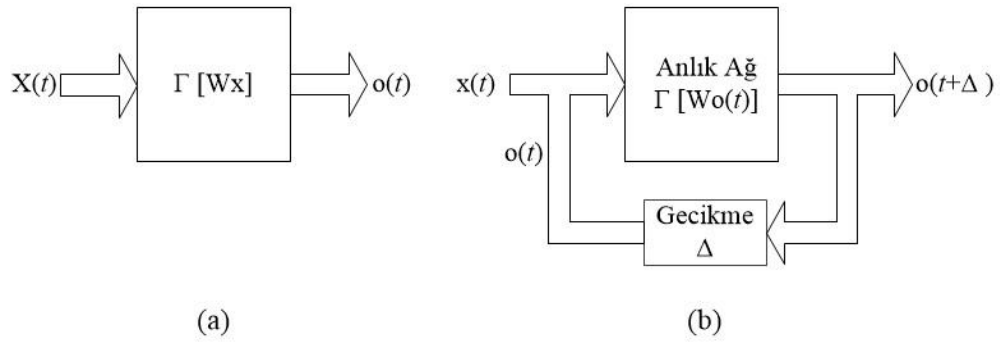
6) Eğer $p < P$ ise $p \leftarrow p + 1, k \leftarrow k + 1$ şeklinde yeni değer atamaları yapılır ve 3. adıma gidilir. Değilse, 7. adımdan devam edilir.

7) Bir eğitim döngüsü tamamlanmış demektir. $E = 0$ hata değeri için eğitim aşaması sonlandırılır ve test işlemlerinde kullanılacak w bağlantı ağırlık değerleri elde edilmiş olunur. $E > 0$ hata değeri durumunda $E \leftarrow 0, p \leftarrow 1$ değer atamaları yapılarak yeni bir eğitim döngüsüne başlamak için 3. adıma gidilir.

1.8.3.7. Yapay Sinir Ağı Modelleri

YSA temel olarak ileri beslemeli ve geri beslemeli YSA olarak ikiye ayrılmaktadır. İleri beslemeli YSA'da bağlantılar ve işlemler tek yönlü olarak girdi katmanından çıktı katmanına doğru olacak şekilde modellenir. İşlemler girdi katmanından çıktı katmanına doğru ilerlediğinden bu ağ modelinde gecikme olmaz.

Geri beslemeli yapay sinir ağı modellerinde herhangi bir katmandaki yapay sinir hücreleri kendi veya daha önceki katmandaki nöronlarla bağlantı kurarak geri besleme yapılıır ve ağ üzerinde bir hafıza yapısı oluşturulur. Bu yapı sayesinde herhangi bir iterasyondaki çıktı değerleri, hem o iterasyondaki hem de önceki iterasyonlardaki girdi ve çıktı değerleri kullanılarak hesaplanmaktadır. Önceki katmanlara bağlantı yapılması bu tür ağ modellerinde gecikmeye neden olmaktadır. Örnek ileri ve geri beslemeli YSA model yapıları Şekil 1.31'deki gibidir [57].



Şekil 1.31. Tek katmanlı ileri beslemeli YSA blok diyagramı, (b) Tek katmanlı ayırık zamanlı geri beslemeli YSA blok diyagramı

1.8.3.8. Öğrenme Metotları

YSA temel olarak insan beyninin çalışma prensiplerinden esinlenerek geliştirildiği için kullanılan öğrenme metotları da bu yapıya benzer şekilde geliştirilmeye çalışılmıştır. İnsanlar hayatları boyunca çevrelerinden duyu organları vasıtasıyla aldıkları bilgilerle öğrenir ve çıktı olarak nitelendirebileceğimiz tepkilerde bulunurlar. YSA'da da öğrenme sürecinde ağ yapısı girdileri alır, kurallarını çeşitli yöntemlerde oluşturur ve öğrendikleri ile çıktı üretir. YSA'da danışmanlı, danışmansız ve takviyeli olmak üzere üç öğrenme metodu kullanılır.

1.8.3.8.1. Danışmanlı Öğrenme Metodu

Bu yöntemde eğitim verileri ve bu verilerin ait oldukları sınıf bilgilerini kullanarak bilgi sahibi olunan verilerde öğrenme işlemi gerçekleştirilir. Ağ girdi değerlerini alır, ağın yapısı, ağırlık değerleri ve aktivasyon fonksiyonlarına bağlı olarak işler ve girdinin ait olduğu sınıf tipini ifade eden bir çıktı oluşturur. Girdi verisinin ait olduğu sınıf tipi ile ağ üzerinde hesaplamalar ile elde edilen çıktı değerlerinin uyuşmadığı yani ağın bu girdi verisini doğru sınıflandırmadığı durumlarda hata değerleri hesaplanır ve ilgili ağırlık değerleri güncellenir. Bu işlem belirli bir döngü sayısı veya minimum hata değerine ulaşıncaya kadar devam eder.

1.8.3.8.2. Danışmansız Öğrenme Metodu

Bu yöntemde eğitim verilerinin hangi sınıfa ait oldukları bilinmeden öğrenme işlemi gerçekleştirilir. YSA eğitim verilerini kullanarak yapay sinir hücreleri arasındaki bağlantı ağırlıklarını aynı sınıfa ait verileri sınıflandırabilecek şekilde gerçek sınıf bilgileri olmadan kendisi hesaplar ve kendi öğrenme kurallarını oluşturur.

1.8.3.8.3. Takviyeli Öğrenme Metodu

Danışmanlı öğrenmeye benzer bir yaklaşımdır ancak danışmansız öğrenmeye benzer şekilde bu yöntemde de eğitim verisinin ait oldukları sınıf bilgisi girdi olarak verilmez. Bunun yerine ağın eğitiminde her adımda elde edilen çıkış değerinin sınıflandırma açısından başarılı olup olmadığına yönelik bir bilgi verilir. YSA bu bilgiler ile gerekli ağırlık güncellemelerini gerçekleştirerek öğrenme işlemi gerçekleştirilmeye çalışır.

2. YAPILAN ÇALIŞMALAR, BULGULAR VE İRDELEME

2.1. Giriş

Bu bölümde, göz bakış yönü kestirimi amacıyla gerçek zamanlı ve görünüm temelli video-okulografi yöntemleri kullanılarak geliştirilen sistem, yapılan çalışmalar ve elde edilen sonuçlar detaylı bir şekilde anlatılmıştır.

Bölüm 2.2’de detaylı bir literatür araştırması yapılmıştır. Bu bölümde öncelikle göz bakışı ve göz bakış yönü kestirimi amacıyla önerilen tüm yöntemlerin işleyiş prensipleri verilmiş daha sonra herbir yöntemin kullanım avantaj ve dezavantajları incelenmiştir. Bölüm 2.3 ve 2.4’ te sırasıyla yüz ve göz bölgesi tespiti amacıyla kullanılan yöntemler verilmiştir. Bu bölümlerde ayrıca yüz ve göz tespiti aşamasında gerçek zamanlı çalışabilirliği sağlamak amacıyla kullanılan yöntemlere yer verilmiştir. Bölüm 2.5’te bakış görüntü verilerinden öznitelik çıkarımı amacıyla kullanılan yöntemlere, Bölüm 2.6’da ise bakış yönünün kestiriminde kullanılan sınıflandırma yöntemlerine ve bu yöntemlerin bakış görüntüleri üzerinde nasıl uygulandıklarına yer verilmiştir. Bölüm 2.7’de hem geliştirilecek sistemin eğitimi hemde kestirim doğruluğunun ölçülmesi amacıyla oluşturulan bakış yönü veritabanına yer verilmiştir. Bölüm 2.8’de sırasıyla yüz ve göz tespitindeki başarımları, göz görüntülerinde bakış yönünü bilgisini en iyi şekilde temsil eden renk uzayının belirlenmesi, önerilen göz bölge modelleri, uygulanan öznitelik çıkarım ve sınıflandırma yöntem çiftleri verilmiştir. Ayrıca, herbir sınıflandırma ve öznitelik çıkarım yönteminde, ızgara tabanlı arama veya deneme yanılma yoluyla elde edilen ve sınıflandırma başarısını arttıran en iyi parametre seçimi değerleri ile birlikte detaylı bir şekilde açıklanmıştır. Bu bölümde son olarak, herbir göz bölgesi modelinde önerilen yöntem çiftlerinin uygulanması sonucu tüm yönler ve göz kapalılığı durumu, sağ ve sol yönlerinde ve alt ile üst yönlerde elde edilen sınıflandırma doğrulukları verilmiş. Elde edilen sonuçlar hem kendi aralarında hemde literatürdeki benzer çalışmalarla karşılaştırılarak önerilen yöntemlerin avantaj ve dezavantajları irdelenmiştir.

2.2. Literatür Taraması

Literatürde göz bakış yönü kestirimi ile ilgili çalışma sayısı oldukça azdır. Yapılan çalışmalar daha çok ekran üzerinde kullanıcının baktığı noktanın tespiti şeklinde gerçekleştirilmiştir. Göz bakış yönü kestirimi, ekran üzerinde bakılan noktanın tespiti işleminin daha genel bir biçimini ifade ettiğinden bu yönde yapılan çalışmalarda göz bakış yönü kestirimi için kaynak oluşmaktadır. Ekran üzerine yapılan gözle bakış bilgisinin ölçülmesi kullanılan ekipmanlara göre sınıflandırıldığında 4 ana kategoride incelenebilir [58]. Bu yöntemler şu şekildedir:

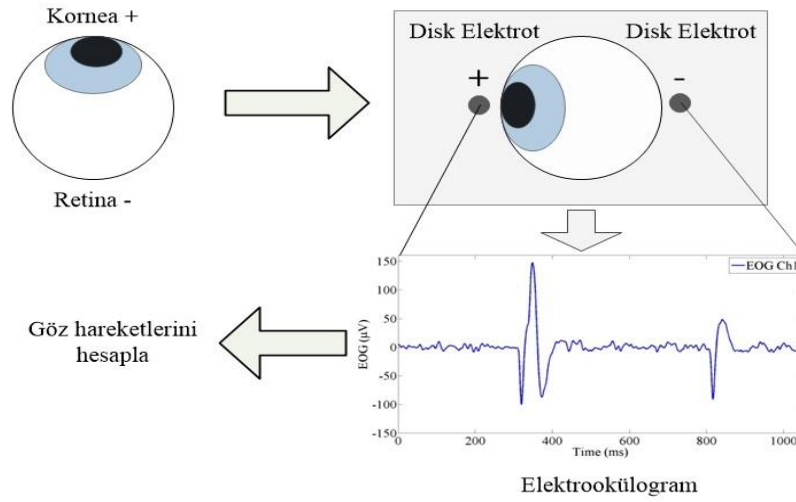
- Elektrokülografi (Electro-OculoGraphy, EOG)
- Arama bobinleri (Search Coils)
- Video - okulografi (Video-OculoGraphy, VOG)
- Kızılötesi - okulografi, (Infrared oculography, IROG)

Belirtilen yöntemlerden en sık kullanılanı video-okulografi yöntemidir. Bu yöntemle yapılan çalışmalar ise özellik temelli ve görünüm temelli olarak ikiye ayrılmaktadır. Göz görüntülerinin kamera ile yakalanması aşamasında kameranın yerleştirilme konumuna göre iki farklı yaklaşım kullanılmaktadır [58]. Bu yaklaşımlar şu şekildedir:

- Göz veya kafa üzerine yerleştirilen bir aparata monte edilen kamera sistemleri
- Ekran üzerinde veya çevresinde çeşitli konumlara yerleştirilen çeşitli sayıdaki kamera sistemleri


2.2.1. Elektrokülografi

Elektrokülografi göz küresinin hareketlerini tespit etmek için sıkça kullanılan bir yöntemdir. [59] ve [60] çalışmalarında EOG yaklaşımı ile göz bakışı kestirimine yönelik çeşitli sistemler geliştirilmiştir. EOG yönteminde temel olarak, korneanın pozitif kutbu ve retinanın ise negatif kutbu temsil ettiği iki kutuplu bir yapı olarak temsil edilen göz bölgesinde kornea ile retina arasındaki potansiyel farkın elde edilmesinden yararlanılır. Şekil 2.1'de örnek bir EOG sisteminin yapısı görülmektedir.



Şekil 2.1. Elektrokülografi ile göz hareketlerinin ölçülmesi

Oküler kürenin dönüşü yani farklı yönlerde gözle bakış bu iki kutup arasındaki potansiyel fark üzerinde orantılı bir değişikliğe neden olur. Bu potansiyel fark ve değişimlerin algılanması amacıyla ön yüz bölgesi üzerinde Şekil 2.2.'deki gibi 5 adet kuru düz elektrot yerleştirilir. Dikey göz hareketleri göz bölgesinin alt ve üst kısımlarına yerleştirilen DÜ ve DA elektrotları ile tespit edilir. Benzer şekilde, yatay göz hareketleri göz bölgesinin sağ ve sol uçlarına yerleştirilen YSG ve YSL elektrotları ile tespit edilir [61].



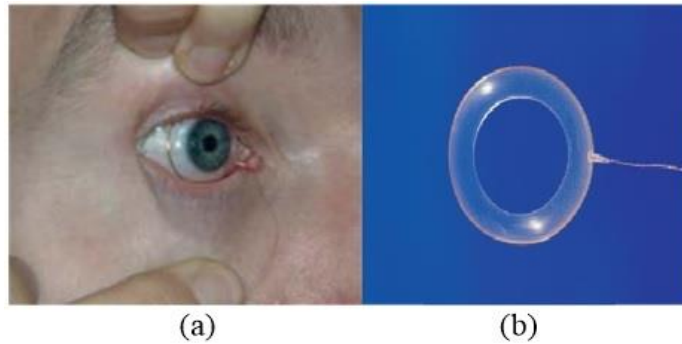
Şekil 2.2. Elektrotların yüz bölgesi üzerine yerleştirimi

Elektrookülografi yöntemleri kullanılarak "EOG Pointer" ve "EOG Switch" olarak adlandırılan göz bakış arayüz sistemi geliştirilmiştir. EOG Pointer arayüzü, sinyal sapmaları veya göz kırpma nedeni ile oluşan sinyal bozuklarına gibi durumlarda dahi belirli ölçülerde imleci hareket ettirme ve bilgisayarı kontrol etmeye olanak sağlamaktadır. EOG Switch arayüzü ise sadece açma veya kapama sinyali üretir. Örneğin, kişisel bir bilgisayara yüksek güvenilirlikte ve istikrarda bir bit sinyal göndermek için bu tip sistemler kullanılabilir [60].

Bu yöntemin avantajı olarak kullanıcının görüşünü engellememesi, gözlük üzerine yerleştirilen kameralara sistemlerine kıyasla kullanıcıyı yormaması ele alınabilir. Ancak, göz kırpma ve yüz kasları hareketleri ölçülen sinyaller üzerinde ciddi oranda gürültüye neden olabilmektedir. Bu gibi nedenlerden dolayı özellikle göz bakışı yönü kestirimi probleminde bu yöntem yeterli ilgiyi görmemiştir [60].

2.2.2. Arama Bobinleri

Bu yöntem, manyetik alan içerisinde hareket eden bir tel bobin üzerinde manyetik alanın indüksiyon voltajı oluşturması prensibine dayanmaktadır. Kontakt lensler içerisine yerleştirilmiş bobinler göz üzerine yerleştirilirse gözle bakış pozisyon bilgisi ve göz hareketlerini veren sinyaller elde edilebilir. Arama bobinleri çeşitli şekillerde yerleştirilerek 2 veya 3 boyutta yatay ve dikey göz hareketleri tespit edilebilir. Şekil 2.3'te göz üzerine yerleştirilmiş örnek bir arama bobini ve 2 boyuttaki bir arama bobininin temel yapısı gösterilmektedir [62].




Şekil 2.3. Göz bölgesi üzerine yerleştirilmiş arama bobini (a), 2 boyutta ölçüm yapan arama bobin yapısı (b)

Bu yöntemin en büyük avantajı iyi bir kesinlik oranı vermesi ve görüntü üzerinde çalışılmadığından çözünürlük ve ortam aydınlatması gibi etmenler etkilenmemesidir. Ayrıca, göz üzerinde gerçekleşen çok ani sıçrama hareketlerinde bile başarı göstermektedir. Ancak, göz üzerine kontakt lens içerisinde tel bobin ve hareketleri ölçen bir cihazın yerleştirilmesi kullanıcı açısından rahatsız edici bir durumdur. Bu nedenlerle klinik çalışmalarda nadiren kullanılmaktadır ancak başarı oranı nedeni ile değerli bir yöntemdir [62].

2.2.3. Kızılötesi-Okulografi

Bu yöntemde göz üzerinden yansıyan kızıl ötesi ışık yoğunluğundan faydalanılmaktadır. Göz bölgesi kızıl ötesi ışık kaynakları ile aydınlatılır ve göz bölgesi yüzeyi üzerinden geri yansıyan ışık miktarı göz konum değişiklikleri hakkında bilgi verir. Işık kaynağı ve geriye yansıyan ışık bilgisini toplayan sensörler göze takılan bir aparat üzerine (gözlük vb.) veya ekran üzerine yerleştirilebilir. Video-okulografi yöntemlerinde olduğu gibi bir aparatla kullanıldığında daha başarılı sonuçlar alınır. Elektro-okulografi yöntemleri ile karşılaştırıldığında bu yöntem daha az gürültüden etkilenecektir [63]. Ayrıca, kızıl ötesi ışığın kullanıcı tarafından görünür olmaması ve görünür ortam ışıklandırmasındaki değişimlerin kızıl ötesi ışık algılayıcıları etkilememesi bu yöntemin avantajlarından. [64] ve [65] çalışmalarında bu yöntemi kullanarak göz hareketlerini ölçme ve günlük problemlerin çözümüne yönelik çalışmalarda bulunmuşlardır. Ayrıca, bu yöntem kullanılarak geliştirilen diğer birçok ticari uygulama [66, 67, 68] geliştirilmiştir. IR-okulografi yöntemi kullanılarak gerçekleştirilen sistemlerin genel yapısı [66] Şekil 2.4'te verilmiştir.



Şekil 2.4. IR-okulografi sistemlerin yapısı

2.2.4. Video-Okulografi

Video tabanlı yöntemlerde ekran üzerinde çeşitli konumlara çeşitli açılarda yerleştirilmiş normal sensörlü veya kızıl ötesi kameralardan alınan görüntü verisi üzerinde işlem yapılır. Yöntemde sıklıkla görüntüler üzerinde ilk adım olarak yüz ve göz bölgesi tespiti yapılır. Elde edilen göz bölgeleri üzerinde görüntü işleme teknikleri vb. yöntemler kullanılarak göz bakış tespiti gerçekleştirilir. Video/görüntü verisi analizi yapılarak gözle bakış bilgisinin elde ediniminde çeşitli yöntemler kullanılmaktadır. Bu metotlar temel olarak özellik temelli (feature based) ve görünüm temelli (appearance based) olarak ikiye ayrılmaktadır.

2.2.4.1. Özellik Temelli Göz Bakış Yönü Kestirimi

Bu yöntemde insan gözündeki ayırıcı yerel karakteristik özelliklerinden faydalanılarak göz bakış yönü kestirimi yapılmaya çalışılır. Literatürde sıkça kullanılan bu karakteristik özelliklerden bazıları şunlardır:

- Kornea ve göz akı arasındaki sınır çizgisi (limbus [69])
- Göz bebeği merkezi ve çevresi
- Göz iç ve dış köşe bilgileri [70]
- Göz bebeği üzerindeki kornea yansımaları
- Göz akının göz bölgesi üzerindeki dağılım oranları
- Purkinje görüntüleri

Özellik temelli yöntemlerin kullanılmasının temel nedeni göz bebeği (pupil) ve üzerindeki yansımanın (glint) görüntü işleme teknikleri ile kolayca elde edilebilir olması ve bu geometrik konum özelliklerinin göz bakışı ile ilgili doğrudan bilgi içermesidir [71]. Bu yöntemde dikkat edilmesi gereken hususlardan biri göz geometrik özelliklerinin tespit edilebilmesi için yüksek çözünürlüklü görüntülerin kullanılması gerektiğidir. Bu nedenle kafaya takılan (head mounted) ve yakın bir uzaklıktan göz görüntüsü alan sistemlerde kullanım açısından daha uygundur. Özellik temelli yöntemler göz bakışı kestirimi alanında sıkça kullanılmaktadır. İlgili çalışmalardan bazıları şu şekildedir.

Cuong ve arkadaşları yaptıkları çalışmada [72] göz bölgesinin geometrik özelliklerinden faydalanarak göz bakışı tespiti gerçekleştirmişlerdir. Öncelikle, dinamik bir

eşikleme değeri ile ikili görüntü elde edilmiş, elde edilen görüntü üzerinde Harris köşe tespiti algoritması ile köşe noktaları çıkarılmıştır. Elde edilen köşe noktaları vasıtasıyla gözün geometrik yapısı, daha özel göz alanı ve irisin sınırlarını içeren konturları çıkartmışlardır. Elde edilen iris sınırları kullanılarak merkezi (X_r, X_c) ve yarıçapı ($r_{\min} < r < r_{\max}$) olan bir çembere benzer şekilde gözün yapısı modellenmiştir. Göz bakış kestirimi ise belirlenen göz bebeği ve gözün sağ ve sol kısımlarındaki kenar noktalarının birbirlerine konumlarından faydalanarak gerçekleştirilmiştir. Ayrıca, göz geometrik özelliklerinin tespit edilmesi için yüksek çözünürlüklü görüntülerin kullanılmıştır.

Sigut ve arkadaşları yaptıkları çalışmada [73] IR ışık kaynakları yerine görünür ışık kaynaklarını kullanarak göz bakışının izlenmesine yönelik bir model geliştirmişlerdir. Kornea yansımının elde edilmesi için kızıl ötesi ışık kaynağı yerine görünür ışık kaynağı ve göz bebeği yerine irisin merkezi kullanılmıştır. Çalışma sonucunda serbest kafa hareketlerine izin veren ve başarılı bir sistem geliştirmişlerdir. Çalışmada, görünür ışık kaynakları kullanılarak kullanıcıyı rahatsız edeceği ve başarısız sonuçlar vereceği düşünülen bu yöntemle aslında başarılı ve güçlü bir sistem geliştirilebileceği gösterilmiştir.

Arı ve arkadaşları yaptıkları çalışmada [74] göz hareketlerinin tespiti amacıyla kızıl ötesi kornea yansıma yönteminden faydalanarak bir sistem geliştirmişlerdir. Geliştirilen sistemde, göz bölgesi kızıl ötesi ışık kaynakları ile aydınlatılmış ve göz hareket görüntüleri kızıl ötesi süzgeç içeren bir kamera ile alınmıştır. Daha sonra görüntüler üzerinde adaptif eşik seviyesi belirleme ve çeşitli görüntü işleme yöntemleri kullanılarak Şekil 2.5'te ifade edildiği şekilde göz bebeği ve kornea yansımalarının merkezlerinin tespiti gerçekleştirilmiştir. Kalibrasyon görüntüsü ile göz bebeği merkezi ve kornea yansımalarının birbirlerine göre göreceli konumlarından faydalanarak ekran üzerinde gözle bakılan noktanın kestirimi gerçekleştirilmiştir. Geliştirilen sistem ekran üzerinde yatay yönde 38.5° düşey yönde ise 29.1° açısında görsel kullanıma izin vermektedir. Çeşitli denekler üzerinde yapılan testler sonucunda sistemin açısal doğruluğunun yatay ekseninde 0.33° ve düşey ekseninde ise 0.45° değerlerinin altında olduğu tespit edilmiştir. Bu başarı oranının elde edilmesinin temel nedeni göz görüntülerinin göz çevresine yerleştirilen bir aparat ve kamera sistemiyle göze çok yakından alınmış olmasıdır. Çalışmada denegin ekrana bakma mesafesi 50 cm olarak alınmıştır ve denek 35 cm x 26 cm boyutundaki ekrana üzerinde göz hareketlerini gerçekleştirmiştir.



Şekil 2.5. Göz bebeği merkezi ve kornea yansımasının göreceli konumları

Ebisawa ve arkadaşları [75] yaptıkları çalışmayla geniş kafa hareketlerinde çalışabilen ve kolay bir kalibrasyon aşaması içeren göz bebeği ve kornea yansımalarına dayalı göz bakış tespiti sistemi geliştirmişlerdir. Geliştirilen sistemde kızıl ötesi ışık kaynakları ve kamera sistemleri kullanmışlardır ve üç farklı ölçümleme yöntemi önerilerek göz bakış tespiti duyarlılığı artırılmıştır. Kullanıcının 7 farklı kafa hareketinin kullanıldığı test ortamında ortalama gözle bakış hatası görüş açısında %1'den düşük olarak hesaplanmıştır.

Ebisawa ve arkadaşları yaptıkları diğer bir çalışmada [76] değişen oda ışıklandırma koşullarında göz bebeği tespiti problemini aşmak amacıyla çeşitli yöntemler önermişlerdir ve göz bebeği tespitini başarılı şekilde gerçekleştirmek için iki ışık kaynağı ve görüntü farklılıkları yöntemini geliştirmişlerdir. Ayrıca, gözlük kullanıcıları için gözlük lensi üzerine yansıyan ışık kaynağı yansımalarını problemini elimine etme ve göz bakış hareketlerinin tespitini kolaylaştırmak amacıyla yönelik çalışmalar yapmışlardır.

Yukarıda ifade edilen özellik temelli yöntemlere dayalı çalışmalar başarı sonuçlar üretmektedirler. Ancak, bu yöntemde sıklıkla kullanıcı kafası veya göz bölgesine yerleştirilen özelleştirilmiş kameralar gibi kullanıcıyı rahatsız eden ek donanımsal ekipmanlar bu yöntemin uygulanmasında dezavantaj oluşturmaktadır. Ayrıca, bu yöntemlerin başarılı olabilmesi için ortam aydınlatması ve kullanıcının bakış açısı ve kafa hareketleri gibi çevresel etmenlerden az etkilenen göz bakış bilgisi taşıyan çeşitli özelliklerin kullanılması gerekmektedir [77]. Böyle olmadığı takdirde bu sistemler açık hava veya güçlü çevre ışıklarının bulunduğu ortamlarda performans ve başarı sorunlarına neden olurlar. Bunun nedeni ise sıklıkla bu sistemlerin değişmeyen veya belirli ışıklandırma ortamlarında çalışacak şekilde görüntü işleme teknikleri ile geliştirilmiş olmasındandır. Benzer şekilde iris, göz bebeği ve kenar bilgileri net olarak tespit edilmezse gözle bakış tespiti başarıyı da düşük olmaktadır.

2.2.4.2. Görünüm Temelli Göz Bakış Yönü Kestirimi

Görünüm temelli yöntemlerde eğitim verileri üzerinde istatistiksel analiz ve makine öğrenmesi yöntemleri kullanılarak öğrenme gerçekleştirilir. Öğrenme sonucu oluşan dağılım modelleri ve ayırıcı fonksiyonları ile verilerin sınıflandırılması gerçekleştirilir. Ayrıca yüksek işlem kapasitesine sahip görüntülerde performans problemlerinin üstesinden gelmek için boyut azaltma gerçekleştirilir [78]. Bu yöntem özellikle yüz/göz tespiti problemlerinde sıkça kullanılmakta ve başarılı sonuçlar elde edilmektedir. Özyüzler, fisher yüzler, DVM, YSA, Naive Bayes sınıflandırıcılar ve Saklı Markov modeli literatürde sıkça kullanılan görünüm temelli yöntemlerden bazılarıdır.

Bu yöntemlerde, göz görüntü verisi ile kullanıcının etkileşimde olduğu ekran arasında koordinat eşleştirmesi yapılarak göz bakış yönü kestirimi gerçekleştirilir [79]. Bu nedenle sıklıkla kalibrasyon aşamasına ihtiyaç duymazlar ve gözün geometrik özellikleri bu yöntemlerde kullanılmaz. Böylece kullanıcı daha az kısıtlanır ve daha ucuz ekipmanlar ile gözle bakış tespiti gerçekleştirilir [80]. Ancak, daha az kullanıcıyı kısıtlayıcı olması bu yöntemlerde kafaya vb. konumlara takılan kamera veya ışık kaynağı olmayacak anlamına gelmemektedir. Özellik temelli yöntemlerde olduğu gibi bu yöntemde de ortam aydınlatması, serbest kafa hareketleri ve göz yapısının kullanıcılar arasında fark göstermesi gibi faktörler göz önünde bulundurulmalıdır.

Bu yöntemlerde karşılaşılan diğer önemli bir sorun çok sayıda eğitim görüntüsüne ihtiyaç duymalarıdır. Örneğin, geliştirilecek sistemin ortam aydınlatmasından bağımsız olması isteniyorsa bu ortamlardan alınan görüntülerinde eğitim aşamasında kullanılması gerekmektedir. Ayrıca, kullanılan görüntü kalitesi arttıkça işlem maliyeti artmakta, tam tersi yönde düşük çözünürlüklü görüntüler kullanıldığında sistem başarısı azalmaktadır. Ayrıca, kafa duruşundan bağımsızlık sağlanması amacı ile kafa duruş özellikleri de girdi olarak verilmelidir. Literatürde bu yöntem kullanılarak yapılan bazı çalışmalar şu şekilde özetlenebilir.

Pomerleau ve Baluja yaptıkları çalışmada [81] yüz bölgesinden çıkartılan 15 x 30 boyutundaki göz görüntü verilerini geri beslemeli ve çok katmanlı YSA kullanarak sınıflandırmışlar ve ekran koordinatları ile eşleştirmişlerdir. Çalışmada, eğitim verilerinin alınması kullanıcının ekran üzerinde belirlenen noktaya bakması ve bu noktaya bakışın görüntüsünün kaydedilmesi şeklinde gerçekleştirilmiştir. Geliştirilen sistem herhangi bir özel donanıma ihtiyaç duymamakta, kalibrasyon gerektirmemekte ve çeşitli seviyelerde kafa

hareketlerine izin vermektedir. [82] ve [83] çalışmalarında da benzer şekilde YSA ve çeşitli öznitelik çıkarım yöntemleri kullanarak kullanıcı göz bakış bilgisi ile ekran koordinatları eşleştirmiş ve başarılı sonuçlar alınmıştır.

Thai yaptığı çalışmada [84] düşük çözünürlüklü görüntüler üzerinde TBA ve yinelenen sinir ağları kullanarak göz bakış kestirimi yapmıştır. Çalışmada, öncelikle insan yüz bölgesi üzerinde Adaboost sınıflandırıcısı ve HBÖ kullanarak göz bölgeleri çıkarılmıştır. Farklı aydınlatma koşullarında elde edilen örnek görüntülerle özgöz uzayı oluşturulmuş ve bu özniteliklerle üç katmanlı yinelenen sinir ağı eğitilmiştir. Yapılan çalışma ile değişen aydınlatma değişimlerine duyarlı yüksek doğrulukta göz bakış yönü kestirimi gerçekleştirmişlerdir.

Zhang ve arkadaşları yaptıkları çalışmada [85] değişen aydınlanma koşulları, serbest kafa hareketlerinde başarılı ve daha az hesaplama maliyeti getiren bir sistem önermişlerdir. 17 deneğin yer aldığı ve kafa üzerine yerleştirilen standart bir kamera ile gerçekleştirilen çalışmada ve 13 farklı yönde gözle bakış görüntüleri kaydedilmiş ve bu görüntüler üzerinde renk, yoğunluk ve dağılım bilgilerinden faydalanarak 50 adet öznitelik çıkarılmıştır. MRMR (Minimum Redundancy Maximum Relevance) özellik seçme yöntemi ve KEYK sınıflandırıcısı kullanılan bu yönlerde ortalama %86 oranında göz bakış yönü kestirimi gerçekleştirilmiştir.

Martinez ve arkadaşları yaptıkları çalışmada [86] kafaya takılabilen göz izleyici kamera sistemiyle göz bakış kestirimi yapan sistem geliştirmişlerdir. Çalışmada aydınlanma değişimlerine karşı başarılı sonuçlar veren çok seviyeli HOG (Histogram of Oriented Gradients) yapısı görünüm tanımlayıcı öznitelikler olarak kullanılmıştır. Göz ve ekran arasındaki koordinat eşleştirmesini sağlamak için DVM ve RVR (Relevance Vector Regression) öğrenme yaklaşımları kullanılmıştır. Görüntü üzerindeki güçlü düşük seviyeli gradyan bilgisinin göz görünümündeki değişimleri ifade etmede başarılı olduğunu ifade etmişlerdir. Önerilen yöntem yüksek boyutta öznitelik içermesine rağmen iyi çalışmakta ve başarılı sonuçlar üretmektedir.

Noris ve arkadaşları yaptıkları [87] çalışmada, 6 ve 18 aylık çocuklarda otizm spektrum bozukluğu gibi hastalıkların teşhisi ve gelişimini izlemek amacıyla bir sistem geliştirmişlerdir. Bu gibi hastalıklara yaşamın ilk yıllarında ortaya çıkmakta ve çocuklarda göz teması kurmama gibi belirtileri olmaktadır. Daha önce kafa yön bilgisi kullanılarak yapılan çalışmalar tatmin edici sonuçlar alınamadığında göz bölgesi ile bu hastalığın teşhisine yönelik çalışmaların yapılması gerekmektedir. Çalışmada bu amaçla göz bölgesi

üzerinde TBA ile öznitelik çıkarımı ve boyut azaltma gerçekleştirilmiş, DVM ve Gaussian Regresyon (Gaussian Process Regression) ile sınıflandırma yapılmıştır. Sistemin testi sonucunda DVM'nin daha başarılı sonuçlar verdiği gözlemlenmiştir.

Lu ve arkadaşları yaptıkları çalışmada [88] sıkça karşılaşılan eğitim veri sayısının fazlalığı, serbest kafa hareketlerinin getirdiği yanlış kestirimler, görüntü çözünürlüğündeki değişmeler ve göz kırpmasının getirdiği hatayı telafi etmeye çalışmışlardır. Çalışmada, Uyarlanabilir Doğrusal Regresyon (Adaptive linear regression) yöntemi ile adaptif bir şekilde en iyi eğitim veri kümesi seçilmiş, böylece eğitim için gerekli olan örnek sayısı kestirim başarımı korunacak şekilde önemli ölçüde azaltılmıştır. Çalışmanın geçerliliğini değerlendirmek amacıyla çok sayıda kullanıcı ve değişen koşullar altında sistem test edilmiş ve başarılı sonuçlar alınmıştır.

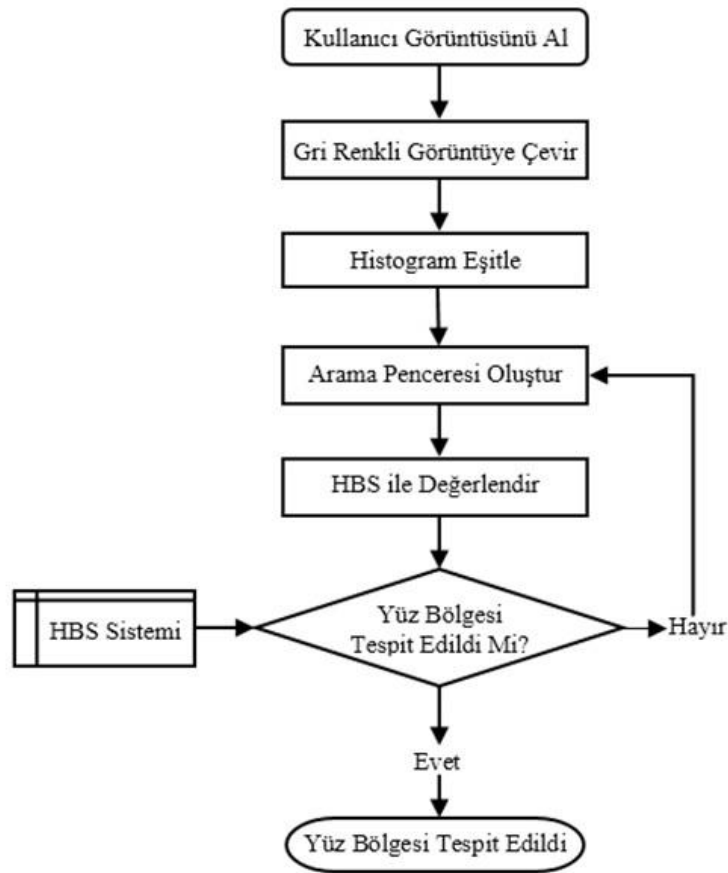
Wu ve arkadaşları yaptıkları çalışmada [89] gözle bakılan noktanın tespitinde etkili bir yöntem önermişlerdir. Öncelikle Aktif Görünüm Modeli (AGM) ile göz bölgesi tespiti yapılmış, elde edilen göz bölgeleri DVM ile sınıflandırarak beş farklı yönde gözle bakış yönü kestirimi yapmışlardır. Öznitelik olarak göz bölgesi üzerindeki sınırlar, iris boyutu, irisin konumu ve göz bebeğinin konumu gibi 36 adet işaret noktası kullanılmıştır. Ayrıca kullanılan kamera çözünürlüğünün etkisinin azaltılması yönünde çalışmalar yapmışlardır. Çalışma sonucunda daha az sınıflandırma hatası içeren ve belirtilen yönlerde daha kesin göz bakış kestirimi yapan bir sistem geliştirilmiştir.

Tan ve arkadaşları yaptıkları çalışmada [90] gri seviyeli göz görüntüleri üzerinde TBA ile boyut azaltma ve öznitelik çıkartma işlemini gerçekleştirmişlerdir. Eğitilen TBA öznitelik uzayı ile sınıflandırma ve test işlemlerini gerçekleştirmişlerdir.

2.3. Yüz Tespiti

Göz-bakış yönünün tespitindeki ilk adım doğruluk oranı yüksek yüz bölgesi tespittir. Ayrıca, geliştirilen sistemin gerçek zamanlı çalışabilmesi için yüz bölgesi tespiti gereksinimleri karşılayacak oranda hızlı bir şekilde yapılması gerekmektedir. PCA, LDA gibi görünüm temelli yöntemlerle geliştirilen sistemler başarılıdır ancak gerçek zamanlı çalışma açısından yeterli olmamaktadır. Bu nedenle, çalışmada yüz bölgesi tespiti yüksek doğruluk ve hızda çalışan HBS yöntemi ile gerçekleştirildi. HBS'nin yüz tespitine uygulanmasında öncelikle gri renkli görüntülerden HBÖ'ler hesaplandı ve Adaboost ile ayırt ediciliği yüksek öznitelik seçimi ve sınıflandırıcıların oluşturulması gerçekleştirildi.

Basamaklı sınıflandırıcı yapısı ve AdaBoost makine öğrenme algoritması kullanılarak çeşitli ölçeklerde, görüntü farkı ve ten renginden bağımsız gerçek zamanlı çalışabilen yüz bölge tespit sistemi geliştirildi. Sistemde gerçek zamanlı olarak alınan görüntüler üzerinde kayan pencereler ve HBS makine öğrenme algoritması ile yüz tespiti gerçekleştirildi. Ayrıca, yöntemde yüz tespiti ölçeklendirmeden bağımsız yapılmaktadır, yani kullanıcının z ekseninde yaptığı hareketler sonucunda yüz bölgesi tespiti yapılabilmektedir. Çalışmada kullanılan yüz bölgesi tespiti yönteminin akış diyagramı Şekil 2.6'daki gibidir.



Şekil 2.6. Yüz bölgesi tespiti akış diyagramı

Uygulanan adımlar detaylı şekilde açıklanacak olursa, ilk adım olarak yüz tespiti amacıyla bir sınıflandırıcı yapısı oluşturuldu. Yapı oluşturulurken, öncelikle eğitim verileri üzerinde yatay, dikey, çeşitli açılardaki ve üç-dikdörtgen HBÖ prototipleri kullanılarak öznitelik çıkarımı ve bu özniteliklerden Adaboost yaklaşımı ile en iyi HBÖ'lerin seçimi

gerçekleştirildi. Son olarak, basamaklı sınıflandırıcı yapısı ile yüz bölgelerini sınıflandıran HBS sistemi oluşturuldu. Oluşturulan HBS sistemi her bir adımda yüz bölgesi olmayan görüntülerin yarısını elimine etmekte ve toplam 20 adet sınıflandırıcı basamağı içermektedir. Sınıflandırıcı eğitimi farklı ten rengi ve aydınlatma koşullarında kaydedilen veriler üzerinde gerçekleştirildiğinden bu tür değişikliklerde de başarılı şekilde çalışmaktadır. Ayrıca, gerçek zamanlı çalışabilme ve test işlemlerinde sistem eğitiminin tekrar tekrar yapılmaması için HBS sınıflandırma sistemi yapısı dosya içerisine kaydedildi ve test verileri bu yapı üzerinde sınıflandırıldı.

Sistemin gerçek zamanlı çalışmasında kullanıcıdan alınan görüntü verileri üzerinde ilk adım olarak yumuşatma işlemi gerçekleştirildikten sonra, çeşitli oranlarda aydınlatma ve renk değişimlerinden etkilenmenin azaltılması ve görüntünün parlaklık bilgisinden daha fazla faydalanmak amacıyla RGB giriş görüntüsü gri seviyede görüntüye çevrildi. Son olarak elde edilen bu görüntüde zıtlık dağılımının düzenlenmesi için histogram eşitleme işlemi gerçekleştirildi.

Kullanıcı görüntüleri üzerinde bu ön görüntü işleme adımları gerçekleştirildikten sonra tespit işleminin hızlı yapılması ve arkaplanda yüz olarak algılanabilecek görüntü nesnelere elimine etmek için HBS ile aranacak minimum ve maksimum arama pencere boyutları aşağıdaki şekilde belirlendi.

$$\text{MinimumPencereGenişliği} = \text{GirisGoruntuGenisligi} * 0,20;$$

$$\text{MinimumPencereYüksekliği} = \text{GirisGoruntuYuksekligi} * 0.20;$$

$$\text{MaksimumPencereGenişliği} = \text{GirisGoruntuGenisligi} * 0,80;$$

$$\text{MaksimumPencereYüksekliği} = \text{GirisGoruntuYuksekligi} * 0.80;$$

Kullanıcı görüntüsü üzerinde yüz bölgesinin aranması işleminde girdi görüntüsü üzerinde yatay ve dikey yönlerde tarama ile elde edilen ve yukarıdaki şekilde boyut sınır değerleri belirlenen arama penceresi içerisindeki görüntüler eğitilen ve dosya içerisine kaydedilen HBS sınıflandırma sistemine girdi olarak verildi. Bu işlemde sınıflandırıcı pozitif bir çıktı üretiyorsa girdi görüntüsü yüz bölgesini ifade etmektedir. Sınıflandırıcı negatif bir sonuç üretiyorsa arama penceresi yatay ve dikey yönlerde kaydırılarak tekrar arama yapılır. Belirli bir boyuttaki arama sonucunda yüz bölgesi tespit edilemezse yeni pencere boyutu 1,2 oranında ölçeklendirilerek yeni arama penceresi ile sınıflandırma işlemi pozitif sonuç elde edilinceye kadar devam eder. Ayrıca, yanlış tespitleri elimine etmek için girdi görüntüsü üzerinde art arda beş adet arama penceresinin pozitif sonuç vermesi koşulu eklendi. Bu şartlarda yüz bölgesi tespit edilmişse yüz aday bölgelerinin koordinat ortalamaları alınarak

yüz bölgesi belirlendi. Gerçek zamanlı sistem üzerinde tespit edilen örnek bir yüz bölgesi Şekil 2.7' deki gibidir.



Şekil 2.7. Tespit edilen örnek yüz bölgesi örneği

2.4. Sağ ve Sol Göz Tespiti

Göz tespiti, bir önceki aşamada elde edilen yüz bölgesi üzerinde gerçekleştirilmektedir ve bu işlemde yüz bölgesi tespitinde olduğu gibi HBS yaklaşımı kullanılmaktadır. Çalışmada öncelikle yüz bölgesi üzerinde insan yüzünün temel yapısından faydalanarak herhangi bir görüntü işleme algoritması kullanmadan sadece yüz bölgesi üzerinde hedef göz arama bölgesinin çıkarılması gerçekleştirilmiştir. Bu oranlar deneysel gözlemler sonucunda elde edilmiştir. Hedef göz arama bölgesinin belirlenme işlemi Şekil 2.8'de ifade edildiği gibi yüz bölgesi üzerinde soldan ve sağdan %10'luk kısım, üstten %25 ve alttan ise %50'lik kısım kırılarak gerçekleştirilmiştir.

$$\text{GözBölgesiSolSınır} = \text{YüzBölgesiGenişlik} * 0,10;$$

$$\text{GözBölgesiSağSınır} = \text{YüzBölgesiGenişlik} * 0,90;$$


$$\text{GözBölgesiUstSınır} = \text{YüzBölgesiYükseklik} * 0,25;$$

$$\text{GözBölgesiAltSınır} = \text{YüzBölgesiYükseklik} * 0,50;$$

Tüm yüz görüntüsü üzerinde aramanın değilde daraltılan bu hedef göz arama bölgesinde göz tespit işleminin gerçekleştirilmesinin gerçek zamanlı çalışması istenen sisteme katkıları şu şekildedir:

- 1) %80 oranında gereksiz yüz bölgeleri üzerinde arama yapılması engellenir

2) Çeşitli görsel açılardan göze benzeyen ve HBS ile yanlış tespite neden olacak ağız bölgesi ve kaşlar gibi alanların yanlış tespiti engellenir



Şekil 2.8. Sağ (a) ve sol (b) göz arama bölgeleri

Çalışmada, sağ ve sol göz bölgeleri ayrı ayrı veya beraber kullanılarak göz bakış yönü kestirimi yapılacağından, sol ve sağ göz bölgelerinin ayrı ayrı elde edilmesi gerekmektedir. Bu nedenle, Şekil 2.8’de ifade edildiği gibi iki gözü kapsayacak şekilde elde edilen alan tam ortasından ikiye ayrılarak sağ ve sol gözler için ayrı ayrı arama yapılacak özel göz alanları (sırasıyla a ve b bölgeleri) elde edilmiştir.

Elde edilen göz arama bölgelerinde gözlerin tespit edilmesi yüz tespitinde olduğu gibi şu şekilde gerçekleştirilmiştir. Sağ ve sol gözler için göz eğitim verileri kullanılarak HBS sınıflandırma sistemi oluşturulmuştur. Sınıflandırıcı sistemin öznetelik çıkarımında yatay, dikey, çeşitli açılardaki ve üç-dikdörtgen HBÖ prototipleri kullanılmıştır. Adaboost ile eğitilen sınıflandırıcı sistem her bir adımda göz bölgesi olmayan görüntülerin yarısını elimine etmekte ve toplam 20 adet sınıflandırma basamağından oluşmaktadır.

Her bir gözün ilgili aday göz bölgesinden çıkarılması işleminin hızlı yapılması için HBS ile aranacak minimum ve maksimum arama pencere boyutları şu şekildedir:


$$\text{MinimumPencereGenişliđi} = \text{AdayGozBolgeGenisligi} * 0,25;$$

$$\text{MinimumPencereYüksekliđi} = \text{AdayGozBolgeYuksekligi} * 0.25;$$

$$\text{MaksimumPencereGenişliđi} = \text{AdayGozBolgeGenisligi};$$

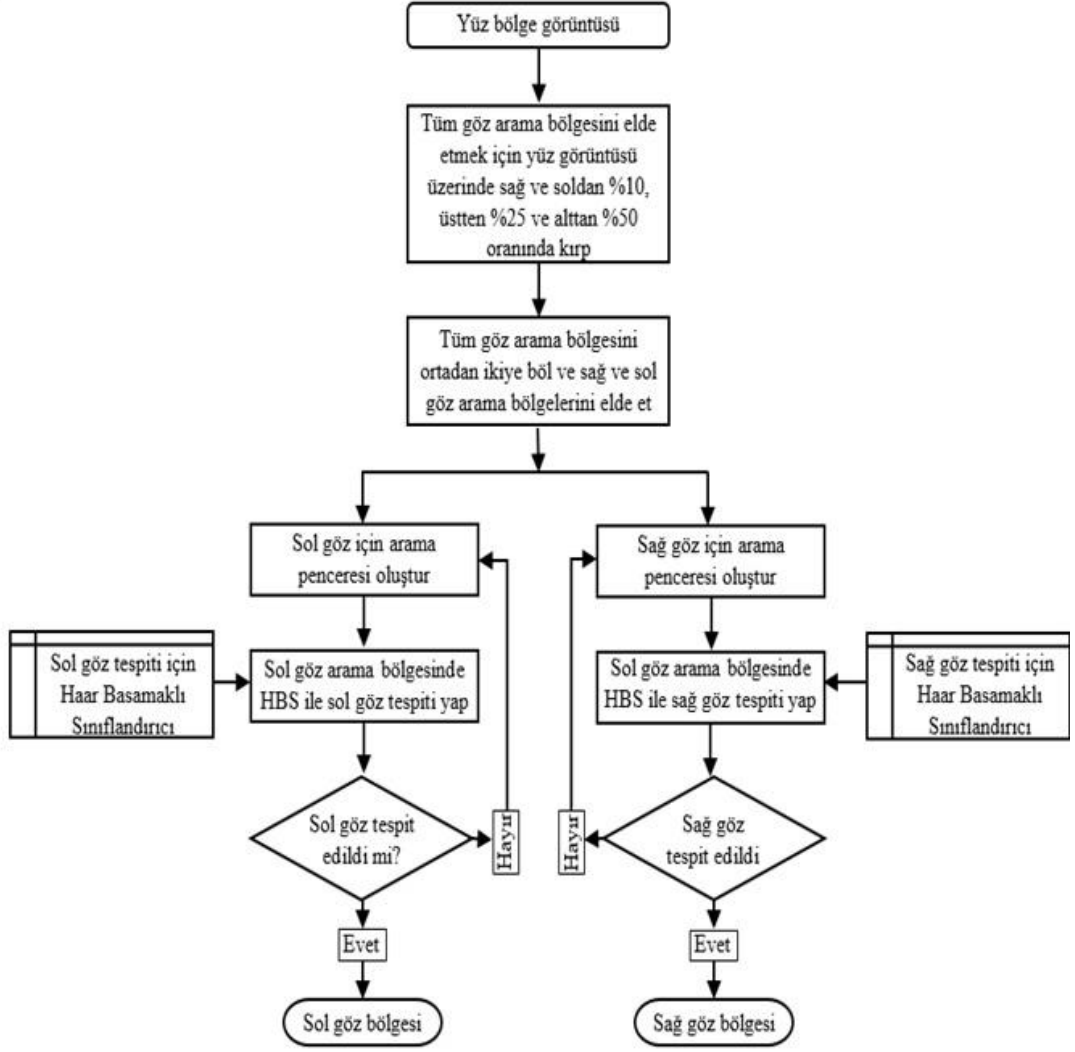
$$\text{MaksimumPencereYüksekliđi} = \text{AdayGozBolgeYuksekligi};$$

Göz tespiti, herbir aday göz bölgesi içerisinde yatay ve dikey yönlerde yukarıda belirlenen sınırlar içerisinde 1,1 ölçeklendirme oranı ile tarama yapılarak gerçekleştirilmiştir. Yanlış tespitleri elimine etmek için girdi görüntüsü üzerinde art arda en az beş adet arama penceresinin pozitif sonuç vermesi şartı eklenerek ve başarılı sonuç arama pencerelerinin koordinatlarının ortalaması alınarak göz tespiti gerçekleştirilmiştir. Sağ ve sol göz arama bölgeleri içerisinde örnek bir göz bölgesi tespiti Şekil 2.9'daki gibidir.



Şekil 2.9. Tespit edilen sağ ve sol gözler

Sağ ve sol göz tespitinde kullanılan yöntemleri ifade eden akış diyagramı ise Şekil 2.10'daki gibidir.



Şekil 2.10. Sol ve sağ göz tespiti akış diyagramı

2.5. Göz Bakış Özniteliklerinin Çıkarılması

2.5.1. Özgöz ile Öznitelik Çıkarımı ve Boyut İndirgeme

Temel bileşen analizi çalışmalarda sıklıkla yüz tanıma problemleri için kullanılmış ve başarılı sonuçlar alınmıştır. Akalın yaptığı [93] çalışmasında yüz tanıma için çok önemli olan yüz görünüşlerinin elde edilmesi amacıyla TBA'yı kullanmışlardır. Yüzleri özvektörler ile hesaplanmış uzaya yansıtılmışlar ve elde edilen ağırlık vektörleri yardımıyla özellik çıkarımı ve boyut azaltma işlemini gerçekleştirmişleridir. Elde edilen ağırlıklar ve YSA kullanarak eğitim ve tanıma işlemlerini gerçekleştirmişleridir. Benzer şekilde Faruqe ve arkadaşları yaptıkları çalışmada [94] TBA'yı yüz görüntülerinden özellik çıkarımı için

kullanmışlar ve DVM ile de sınıflandırma ve tanıma işlemini gerçekleştirmişlerdir. [95], [38] ve [96] çalışmalarında da TBA benzer şekilde yüz tanıma problemlerinde çeşitli sınıflandırıcılar ile kullanılmıştır.

Bu çalışmada da literatürdeki çalışmalarda olduğu gibi TBA hem öznelik çıkarımı hem de boyut azaltma amacıyla kullanılmıştır. Yüz tanıma problemlerinde kullanılan özyüz terimi bu çalışmada göz bölgeleri üzerinde işlem yapıldığından özgöz olarak adlandırılmıştır. Eğitim verileri üzerinde TBA ile özgöz görüntülerinin hesaplanması Bölüm 1.7.2.1’de anlatıldığı gibi kısaca şu şekilde gerçekleştirilmektedir:

1) Eğitim veritabanındaki her bir göz görüntüsü sütun vektörüne çevrilir ve tüm sütun vektörleri birleştirilerek eğitim veri matrisi oluşturulur.


2) Göz görüntü vektörlerinin ortalaması alınarak ortalama görüntü elde edilir.



Şekil 2.11. Ortalama göz görüntüsü

3) Ortalama görüntü vektörü her bir görüntü vektöründen çıkarılarak sıfır ortalamalı eğitim matrisi elde edilir.

4) Boyutu azaltılan kovaryans matrisi üzerinde istenilen sayıda veri dağılımını en başarılı şekilde ifade edecek K adet özvektör seçimi gerçekleştirilir. Bu düşük boyuttaki özvektörler orijinal göz boyutuna dönüştürülerek özgözler elde edilir. Çalışmada eğitim verileri üzerinde hesaplanan ilk 30 özgöz görüntüsü Şekil 2.12’deki gibidir.



Şekil 2.12. Eğitim veri kümesi üzerinde hesaplanan ilk 30 özgül görüntüsü

5) Eğitim veri görüntülerinin tümü elde edilen özgül uzayına projekte edilerek eğitimde kullanılan göz görüntülerinin sınıflandırma işlemlerinde kullanılacak boyutu azaltılmış öznelik vektörleri elde edilir. Herhangi bir test görüntüsüne ait öznelik vektörü de eğitim işlemi sonucunda elde edilen bu özgül uzayına projekte edilerek hesaplanır. Ayrıca, herhangi bir göz görüntüsü, göz uzayına yapılacak bir izdüşüm ile yaklaşık olarak elde edilebilir

2.5.2. Yerel İkili Örüntü Histogramı ile Öznelik Çıkarımı


Yerel ikili örüntü histogramları gri yoğunluk seviyesinden bağımsız ayıricılığı yüksek bir doku betimleyicisi ve öznelik çıkarım yöntemidir. Çalışmalarda sıklıkla yüz ve yüz ifadelerinin tanınması [30, 31] ve diğer birçok görüntü analizi, görüntü işleme ve bilgisayarla görü uygulamalarında kullanılmaktadır. Çalışmada olduğu gibi gerçek zamanlı günlük hayat problemlerinde kullanım avantajları şu şekildedir:

- Ortam aydınlatma değişimlerine karşı toleranslıdır
- Hesaplama maliyeti düşük olması nedeniyle gerçek zamanlı problemlerde sıklıkla kullanılmaktadır
- Gri yoğunluk seviyesinden bağımsızdır

Çalışmada çok ölçekli YİÖ histogramları öznelik olarak kullanılmıştır. Bu yöntemde farklı R ve P parametreleri kullanılarak örüntü oluşturulur. Komşu örnekleme sayısını ifade eden P parametresinin büyük değerleri hem YİÖ histogram boyutunu hem de işlem maliyetini artırır. P değerinin küçük seçilmesi ise komşulardan elde edilen bilginin kaybedilmesine neden olabilmektedir. Merkez piksel ile komşular arasındaki yarıçapı ifade

eden R parametresi ile farklı ölçekteki desenler tanınabilmektedir [97]. Farklı P ve R parametre çiftleri kullanılarak farklı ölçek ve başarı oranında çalışan örüntüler oluşturulabilmektedir. Çalışmada, eğitim verileri üzerinde YİÖH öznitelik çıkarımı Bölüm 1.7.1’de anlatıldığı gibi kısaca şu şekilde gerçekleştirilmektedir.

1) Seçilen P ve R parametreleri kullanılarak gri seviyeli görüntü üzerinde tüm piksel değerleri için ikili kod değerleri hesaplanır. Şekil 2.13’te örnek göz görüntüleri üzerinde çeşitli R ve P parametreleri çiftleri ile elde edilen YİÖ görüntüleri gösterilmektedir.



Şekil 2.13. Çeşitli R ve P parametre çiftleri ile hesaplanan YİÖ görüntüleri

2) Düzenli örüntüler kullanılarak ayırt ediciliği yüksek ve boyutu azaltılmış örüntüler seçilir.

3) Tüm görüntü yerine çeşitli sayıda yatay ve dikey alt bölmelere (örneğin 6x6) ayrılan YİÖ görüntüleri üzerinde yerel YİÖ histogramları çıkarılır. Böylece sadece örüntü bilgisi değil konum bilgisi de kullanılmış olur ve daha başarılı sonuçlar elde edilir.

4) Tüm alt görüntüler üzerinde hesaplanan histogramları birleştirilerek nihai YİÖ öznitelik histogramı vektörel olarak elde edilir.

2.6. Göz Bakış Görüntülerinin Sınıflandırılması

2.6.1. KEYK ile Sınıflandırma

K en yakın komşusu algoritması (K-EYK) algoritması kolay anlaşılabilir ve uygulanabilir bir algoritmadır ve sınıflandırma problemlerinde sıklıkla kullanılmaktadır. Yöntemde öğrenme işlemi ve test sorgusunun aynı anda gerçekleştirilmesi nedeniyle Tembel Öğrenme veya Durum Temelli Öğrenme grubuna dâhil edilen bir öğrenme yöntemidir [40].

Bu nedenle çalışmada olduğu gibi özellikle yüksek boyutta öznitelik vektörü içeren problemlerde gerçek zamanlı uygulanması problem teşkil edebilmektedir. Çalışmada da DVM ve YSA gibi sınıflandırıcılarla bu yöntemin başarı oranını kıyaslamak için kullanılmıştır.

K-EYK algoritmasının çalışmada kullanımı ise şu şekilde gerçekleştirilmiştir. Öncelikle TBA veya YİÖ histogramları kullanılarak test verisinin öznitelik vektörü elde edilmiş, elde edilen bu öznitelik vektörünün etiket değerleri bilinen (ait olduğu sınıf bilgisi bilinen) diğer tüm öznitelik vektörleri ile aralarındaki uzaklık bilgisi öklid uzaklığı kullanılarak hesaplanmıştır. Sınıflandırma işlemi en yakın k adet komşu dikkate alınarak ve test verisinin çoğunluğun olduğu sınıfa dâhil edilmesi şeklinde gerçekleştirilmiştir. Ayrıca, çalışmada çeşitli k değerleri kullanılarak en başarılı sonucu üreten k değeri belirlenmiştir.

2.6.2. YSA ile Sınıflandırma

YSA son yıllarda özellikle sınıflandırma problemlerine sıkça kullanılan ve başarılı sonuçlar üreten bir yöntemdir. [81], [82] ve [83] yaptıkları görünüm temelli göz bakış kestirimi çalışmalarda bu yöntemi göz bölgeleri ile ekran koordinatı ile eşleştirmek amacıyla kullanmışlar ve başarılı sonuçlar almışlardır.

Bu çalışmada örüntü sınıflandırma problemlerinde sıkça kullanılan ve başarılı sonuçlar veren geri beslemeli Çok Katmanlı Perseptron (ÇKP) modeli kullanılarak oluşturulan YSA ile göz bakış yönü kestirimi gerçekleştirilmiştir. Geri beslemeli YSA modeli herhangi bir katmandaki nöronların kendi veya daha önceki katmandaki nöronlarla bağlantı kurmasına ve böylelikle ağ üzerinde bir hafıza yapısının oluşturulmasına olanak tanır. Bu sayede herhangi bir iterasyondaki çıktı değerleri, hem o iterasyondaki hem de tüm önceki iterasyonlardaki girdi ve çıktı değerleri kullanılarak hesaplanmış olmaktadır. Önceki katmanlara bağlantı yapılması sistemin eğitimi sırasında gecikmeye neden olmaktadır. Ancak, çalışmada eğitilen YSA ağ bilgileri bir dosyada kaydedildiğinden ve test verisi ağa girdi olarak verilip çıktı bilgisi hesaplandığından geri beslemeli ağ modeli gerçek zamanlı çalışan sistem üzerinde olumsuz bir etki oluşturmamaktadır.

Çalışmada eğitim ve test işlemlerinde kullanılan YSA modelindeki katman ve her katmandaki nöron sayıları ve diğer bazı ağ parametreleri şu şekilde belirlenmiştir:

Girdi Katmanı: Öznitelik vektörü girdi olarak alınacağından girdi katmanında bu vektör boyutu ile aynı sayıda nöron yerleştirilmiştir. Çalışmada TBA veya YİÖ histogramları kullanılarak elde edilen öznitelik vektörleri girdi olarak verilecektir.

Ara Katmanlar: Ara katman sayısı ve her katmanda yer alacak nöron sayısı deneme yanılma yöntemi ile bulunmuştur. Herhangi bir ara katmanda nöron sayısı girdi katmanından az çıktı katmanından ise fazla olacak şekilde seçilmiştir.

Çıktı Katmanı: Sınıflandırılacak 6 farklı göz bakış bilgisi bulunduğundan 6 adet çıktı nöronu kullanılmıştır.

Aktivasyon Fonksiyonu: Göz bakış bilgisi içeren örnek eğitim ve test verileri üzerinde farklı aktivasyon fonksiyonları ile sınıflandırma başarısı ölçülerek aktivasyon fonksiyonu seçimi gerçekleştirilmiştir. Sınıflandırma sonucunda sigmoid, gauss ve doğrusal aktivasyon fonksiyonları kullanılarak sırasıyla %96.93, %95.95 ve %28.10 oranında başarı elde edilmiş ve YSA yapısında sigmoid fonksiyonun kullanılmasına karar verilmiştir.

Ağ Hata Değeri ve Toplam Adım Sayısı: Ağ hata değeri küçüldükçe ve maksimum adım sayısı arttıkça sınıflandırma başarısı önemli derecede artabileceğinden deneme yanılma yoluyla en uygun değer seçimi gerçekleştirmiştir.

2.6.3. DVM ile Sınıflandırma

Birçok uygulama alanında olduğu gibi görüntü verilerinin sınıflandırılmasında da veri seti uzayında belirli bir hatayla doğrusal olarak ayrılması mümkün olmamaktadır. Bu çalışmada da, görüntü verilerinden TBA ve YİÖH'ları ile öznitelik çıkarımı sonucunda yüksek boyutta ve doğrusal ayrışması mümkün olmayan öznitelik vektörleri oluşmaktadır. Çalışmada çekirdek fonksiyonları kullanılarak öznitelik vektörleri yüksek boyutlu başka bir uzaya taşınmış ve Doğrusal Olmayan DVM'ler kullanılarak bu uzayda en iyi ayırıcı düzlem ile sınıflandırma işlemi gerçekleştirilmiştir. Verilerin başka bir uzaya taşınmasında çokterimli, radyal tabanlı ve sigmoid çekirdek fonksiyonları kullanılmıştır.

Tanımlanan bu çekirdek fonksiyonlarının uygulanması aşamasında en önemli adımlardan biri uygun çekirdek fonksiyonu ve parametre değerlerinin seçilmesidir. Bu amaçla çekirdek fonksiyonları en başarılı sonuçlar üreten parametrelerle birlikte uygulanmalıdır. Çalışmada, en iyi hiperdüzlem parametrelerinin belirlenmesinde önceki çalışmalarda sıkça kullanılan ızgara tabanlı arama yöntemi kullanılmıştır. Bu yöntemde, her bir parametre için alt ve üst sınır değerleri ve her adımda parametre değerinin değişimini

ifade eden aralık değeri belirlenir. Sınıflandırma algoritma başarısı alt ve üst sınır değerleri içerisindeki tüm aralık değerleri ile değerlendirilerek uygun parametre seçilir [48]. Ayrıca, farklı parametrelerinde birbirlerine göre en uygun değerde olması sınıflandırma başarısını arttıracaktır. Çalışmada kullanılan çekirdek fonksiyonlarına ait değer aralıkları aşağıda Tablo 2.1’de verilmiştir.

Tablo 2.1. Çekirdek fonksiyon parametrelerinin ızgara tabanlı aramayla belirlenmesinde kullanılan değer aralıkları

Parametre	Alt Sınır Değeri	Üst Sınır Değeri	Artım Miktarı
C	2^{-15}	2^{15}	2^1
γ	2^{-13}	2^{13}	2^1
α	2^{-13}	2^6	2^1
d	1	4	1

Çalışmada, yukarıda belirtilen çekirdek fonksiyonları ve bağlı oldukları parametreler üzerinde ızgara tabanlı arama ile en iyi parametre seçimi gerçekleştirilmiştir. Bu amaçla, göz görüntülerinden YUV renk uzayında rengin parlaklığını ifade eden Y kanal bilgisi çıkarılmış, YİÖH’ları ile öznelilik çıkarımı gerçekleştirmiş ve yukarıda belirtilen parametre değer aralıklarında ızgara tabanlı en iyi parametre seçimi gerçekleştirmiştir.

Örneğin, bu radyal temelli çekirdek fonksiyonu üzerinde C ve γ parametre için ızgara tabanlı arama yapıldığında elde edilen sınıflandırma sonuçları Tablo 2.2’deki gibidir. Tabloda sınıflandırma başarısı yüksek değer çiftleri için sonuçlar gösterilmiştir.

Tablo 2.2. Radyal tabanlı çekirdek fonksiyonunda γ , C parametreleri için ızgara tabanlı arama ile elde edilen sınıflandırma sonuçları

$\gamma \setminus C$	2^{-15}	2^{-13}	2^{+1}	2^{+13}	2^{+15}
2^{-15}	61,44	92,77	97,59	97,59	97,59
2^{-13}	95,18	95,18	95,18	95,18	95,18
2^{+13}	24,09	24,09	24,09	24,09	24,09
2^{+15}	24,09	24,09	24,09	24,09	24,09

Benzer şekilde diğer çekirdek fonksiyonları ve parametreleri üzerinde ızgara tabanlı arama ile sınıflandırma yapıldığında başarı oranı daha düşük çıkmıştır. Bu nedenle, DVM ile sınıflandırma işleminin radyal tabanlı çekirdek fonksiyonu ve $\gamma = 15$ ve $C > 1$ parametre çiftleri ile gerçekleştirilmesine karar verilmiştir.

DVM'leri Bölüm 1.8.2'de anlatıldığı gibi farklı iki sınıfa ait verileri en iyi ayırıcı düzlemi bularak ayırmak üzerine geliştirilmiştir. Bu problemin çözümü için Çok Sınıflı DVM modelleri önerilmiştir. Bu yöntem, DVM'nin farklı sınıflara ait veriler üzerinde ikili sınıflandırma yapmasına dayanmaktadır ve bire karşı bir (one against one) [91], bire karşı hepsi (one against all) gibi çeşitli yaklaşımları bulunmaktadır [92]. Çalışmada bu yöntemin bire karşı bir yaklaşımı kullanılmıştır. Bu yaklaşımda herbir sınıf verisi bir diğer sınıf verileri ile ayrı ayrı olacak şekilde eğitilir. Yani n farklı sınıf için $n \cdot (n - 1) / 2$ adet ikili sınıflandırma yapılır. Karar verme işlemi test verisinin herbir ikili sınıflandırıcıya uygulanması ve oylanması ile gerçekleştirilir. Test verisi en çok oy alan sınıf etiket değeri ile etiketlenir.

2.7. Bakış Yönü Veritabanı

Görünüm temelli yöntemlerde Bölüm 2.2.4.2'de anlatıldığı gibi eğitim verileri üzerinde istatistiksel analiz veya makine öğrenmesi yöntemleri kullanılarak öğrenme gerçekleştirilir. Bu nedenle geliştirilecek sistemin eğitimi için sınıflandırılması istenen türdeki görüntülerle bir eğitim veritabanının oluşturulması gerekmektedir. Çalışmada bu amaçla 32 farklı kullanıcıdan alınan kalibrasyon ve test video görüntüleri kullanılarak bakış yönü veritabanı oluşturulmuştur. Bu veritabanı ekran üzerinde sağa, sola, alta, üste, merkeze bakış görüntülerini ve kapalı göz görüntülerini içermektedir. Eğitim veritabanının oluşturulmasında önceki çalışmalardan farklı olarak kullanıcıdan alınan kalibrasyon görüntü verileri de eklenmesiyle görünüm temelli yöntemlerde çok sayıda eğitim verisine sahip olma problemi çözülmeye çalışılmıştır. Veri örneklerinin alınması amacıyla öncelikle bir deney ortamı oluşturulmuştur. Oluşturulan bu deney ortamı ve kullanılan kamera sistemine ait bazı özellikleri şu şekildedir:

- Ekran genişliği 48 cm, ekran yüksekliği 27 cm, ekran çapraz genişliği yaklaşık 54,5 cm
- Ekran tabanının yerden yüksekliği 95 cm,


- Ekran ile kullanıcı yüz bölgesi arası mesafe yaklaşık olarak 90 -100 cm
- Kullanıcı görüş açısı yatayda 170°, dikeyde 160°
- Deney ortamı aydınlatma açısından uygun, ek ışık kaynağı bulunmamakta
- USB 2.0 bağlantı noktalı, 1280 x 720 çözünürlükte görüntü yakalayabilen, ekran üst orta kısmına yerleştirilen bir web kamerası
- x64 tabanlı 4 çekirdekli 3.40 GHz Intel Core i7-3770 işlemci, 8 GB DDR3 rastgele erişimli bellek, 8 GB cache, 64 bit Windows işletim sistemi

Veritabanının oluşturulması sırasında öncelikle deney ortamından alınan kullanıcı başına yaklaşık 15 saniyelik video görüntüleri üzerinde FFmpeg Kütüphanesi kullanılarak saniyede 1 adet olacak şekilde görüntü çıkartma işlemi gerçekleştirilmiştir. Daha sonra, elde edilen bu görüntüler üzerinde Bölüm 2.3 ve Bölüm 2.4'te anlatıldığı gibi yüz ve göz bölgesi tespiti yapılmış ve elde edilen sağ ve sol göz bölgeleri YUV renk uzayına dönüştürülerek sınıflandırmada başarılı olduğu görülen Y kanal bilgisi çıkartılarak kaydedilmiştir. Son olarak birbirine benzeyen ve hatalı olan görüntüler veritabanından çıkarılmış ve Tablo 2.3'te görüntü sayıları belirtilen bakış yönü veritabanı oluşturulmuştur.

Tablo 2.3. Bakış yönü veritabanındaki çeşitli yönlerde toplam görüntü sayıları

Bakış Yönü ve Bilgisi	Görüntü Sayısı
Alt	57
Sağ	64
Üst	61
Sol	67
Merkez	62
Kapalı	97
Toplam	408

Oluşturulan bakış yönü veritabanı içeriğinin bir kısmı Şekil 2.14'deki gibidir.



Şekil 2.14. Bakış veritabanı içeriği, ekran üzerinde sol (a), sağ (sağa), alt (c), üst (d) ve merkeze (e) yapılan bakış örnekleri ile kapalı göz görüntü örneği (f)

Ayrıca, mevcut veritabanını genişletmek amacıyla literatürdeki bu amaca yönelik veritabanları da detaylı biçimde incelenmiştir. Göz bakış yönü kestirimi amacıyla oluşturulan çok az sayıda veritabanı bulunduğu görülmüştür. Bu veritabanlarının çoğu çalışmada olduğu gibi ekran üzerine yapılan bakışlar için değil çevreye yapılan bakışların tespiti için oluşturulmuştur. Diğer bir kısmında ise kullanıcı görüntüsü alımı çok farklı kamera konumu, sayısı, türü vb. deney ortamları ile gerçekleştirildiğinden çalışmada kullanılmamıştır.

2.8. Deneysel Sonuçlar ve Karşılaştırmalar

Çalışmada sırasıyla yüz ve göz tespiti yapıldıktan sonra elde edilen göz bölgeleri üzerinde görünüm temelli yöntemler kullanılarak görüntü verileri ile kullanıcının etkileşimde olduğu ekranı koordinatlarının eşleştirilmiş ve kullanıcının ekran üzerinde baktığı yön kestirimi gerçekleştirilmiştir. Geliştirilen sistemde kullanılan bileşen ve yöntemler gerçek zamanlı çalışabilirliği destekleyecek şekilde seçilmiştir. Ayrıca, göz bakış yönünün kestirimi sırasında kullanılacak olan YİÖH, TBA öznelik çıkarım yöntemleri ve DVM, YSA ve KEYK öğrenme ve sınıflandırma algoritmaları için en uygun parametre

değerlerinin seçimi ızgara tabanlı arama ve çapraz doğrulama yöntemi ile gerçekleştirilerek maksimum başarı ve doğrulukta bir sistem geliştirilmesi amaçlanmıştır.

Göz bakış yönü kestirim sisteminin ilk aşaması Bölüm 2.3'te detaylı olarak anlatılan gerçek zamanlı çalışabilen bir yüz tespitin gerçekleştirilmesidir. Çalışmada bu amaçla HBÖ'ler, Basamaklı Sınıflandırıcı yapısı ve AdaBoost makine öğrenme algoritması kullanılarak çeşitli ölçeklerde, görüntü farkı ve ten renginden bağımsız gerçek zamanlı çalışabilen yüz bölge tespiti gerçekleştirilmiştir. Yöntemin çalışmaya kazandırdığı avantajlardan bazıları şu şekildedir:


- HBÖ ve integral görüntü ile matematiksel hesaplaması kolay öznitelik çıkarımı
- Adaboost ile ayırt ediciliği yüksek HBÖ özniteliklerin seçilmesi, gereksiz özniteliklerin elimine edilmesi
- Karar ağaçlarına benzer Basamaklı Sınıflandırıcı yapısı ile başarı oranı yüksek, işlem maliyeti az ve ölçeklendirmeden bağımsız yüz tespiti

Yüz tespiti için kullanılan bu yöntemle çalışmada kullanılan 16 fps'lik kullanıcı görüntüleri üzerinde yüz tespitini gerçek zamanlı olarak kolaylıkla gerçekleştirmektedir. Çalışmada kullanılan 417 kullanıcı görüntüsü üzerinde yüz tespiti gerçekleştirildiğinde bu yöntemle %98.32 oranında başarı sağlanmıştır. Tespit işleminde kullanılan görüntülerle ilgili diğer bilgiler Tablo 2.4'teki gibidir.

Tablo 2.4. Yüz tespiti başarımları sonuçları

Görüntü Sayısı	417
Doğru Tespit	410
Hatalı Tespit	7
Başarı Oranı	%98.32

Tespit edilemeyen yüz bölgeleri ise çoğunlukla kullanıcı kafasının tümünün kameranın görüş açısı içerisinde bulunmamasından kaynaklanmıştır. Başarılı ve başarısız yüz tespiti görüntü örnekleri Şekil 2.15'de verilmiştir.




Şekil 2.15. Başarılı (a) ve başarısız (b) yüz tespiti sonuç görüntüleri

Çalışmada ikinci aşama olarak Haar Basamaklı Sınıflandırıcı yaklaşımı ile sağ ve sol göz bölgelerini tespiti gerçekleştirilmiştir. Bu işlemde tüm yüz bölgesi üzerinde arama yapmak yerine Bölüm 2.4'te detaylı olarak anlatılan hedef göz arama penceresi içerisinde arama yaklaşımı kullanılarak %80 oranında gereksiz yüz bölgeleri üzerinde arama yapılması engellenmiştir. Ayrıca, göz tespitinde HBS yöntemi kullanılarak yukarıda yüz tespiti aşamasında belirtilen gerçek zamanlı çalışabilme ve ölçekten bağımsız çalışabilme avantajları sisteme kazandırılmıştır. Bu yöntemle, kullanılan 417 kullanıcı görüntüsü üzerinde %97.84 oranında göz tespiti başarıları sağlanmıştır. Tespit işleminde kullanılan görüntülerle ilgili diğer bilgiler Tablo 2.5'teki gibidir.

Tablo 2.5. Göz tespiti başarımları sonuçları


	Sol Göz	Sağ Göz
Görüntü Sayısı	417	417
Doğru Tespit	408	408
Hatalı Tespit	9	9
Başarı Oranı	%97.84	%97.84

Şekil 2.16’da bir kısmı verilen hatalı göz tespitlerinin çoğu gözlerin kapalı olduğu kullanıcı görüntüleri üzerinde gerçekleşmiştir.



Şekil 2.16. Başarılı (a) ve başarısız (b) göz tespiti sonuç görüntüleri

Göz bakış yön kestirimi görünüm temelli yöntemler ile gerçekleştirileceğinden sistemin eğitimi ve testi sırasında kullanılan göz görüntülerinde bakış yönünü bilgisini en iyi şekilde temsil eden renk uzaylarını tercih edilmesi önemlidir. Bu amaçla göz bakış görüntüleri RGB, HSL, HSV, Lab, YCbCr, YUV renk uzaylarına ve gri seviyeli görüntüye dönüştürülerek sınıflandırma başarımlarını ölçümü gerçekleştirilmiştir. Örnek bir bakış görüntüsünün farklı renk uzayları ve her uzaydaki farklı kanal bilgileri çıkarıldığında elde edilen görüntüler Şekil 2.17’de verilmiştir. Burada ilk satır ilgili renk uzayındaki tüm kanal bilgilerinin birleşmesi ile oluşan görüntüyü, diğer sütunlar ise sırasıyla ilgili renk uzayının farklı herbir kanal bilgisini ifade etmektedir.



Şekil 2.17. Farklı renk uzaylarındaki bakış görüntüleri

Uygun renk uzayının seçiminde HLS renk uzayının H, HSV renk uzayının V, Lab renk uzayının L, YCbCr renk uzayının Y, YUV renk uzayının Y ve RGB renk uzayının R, G, B kanalları ile gri seviyede görüntüleri kullanılmıştır. Renk uzaylarında parlaklık bilgisini ifade eden bu kanalları kullanılarak aydınlanma vb. değişimlerinden daha az etkilenmek amaçlanmıştır. Uygun renk bilgisinin seçimi bakış yön bilgisi bilinen görüntüler üzerinde YİÖH ve DVM ile eğitim ve test işlemi uygulanarak gerçekleştirilmiştir ve YUV renk uzayında parlaklığı ifade eden Y kanal bilgisinin diğerlerine oranla göz bakış yönü kestiriminde daha başarılı sonuçlar verdiği görülmüştür. Sınanan renk uzay ve kanal bilgilerinin göz bakış yönü kestiriminde elde edilen başarı oranları Tablo 2.6'daki gibidir.

Tablo 2.6. Farklı renk uzay ve kanallarının göz bakış yönü kestiriminde ölçülen başarı oranları

Renk Uzayı	Kanal Bilgisi	Başarı Oranı
RGB	R (renk)	%92.96
RGB	G (renk)	%94.85
RGB	B (renk)	%92.97
HSL	L (parlaklık)	%95.82
HSV	V (parlaklık)	%93.06
Lab	L (parlaklık)	%93.89
YCbCr	Y (parlaklık)	%94.74
YUV	Y (parlaklık)	%96.93
Gri	Gri (yoğunluk)	%94.30

Çalışmada göz bakış yönü kestirimi sırasında kullanılacak bakış yönü görüntü verilerinin edinilmesi farklı yöntemler kullanılarak gerçekleştirilmiştir. Literatürdeki görünüm temelli çalışmalar incelendiğinde göz tespiti aşaması sonrasında elde edilen sağ veya sol göz görüntülerinin bütününün yani göz kısmı ve çevresindeki göz bakış yönü kestirime katkısı olmayan kısımlarında sistemin eğitimi ve testinde kullanıldığı görülmektedir. Bu işlem gereksiz göz çevresi bölgelerinin hem öznelik çıkarım ve sınıflandırma aşamalarında işlem maliyetini arttırmakta hem de sınıflandırma doğruluğu başarısını azaltmaktadır. Çalışmada bu amaçla göz görüntüleri üzerinde gereksiz kısımları kırma işlemi gerçekleştirilmiştir. Önceki çalışmalarda karşılaşılan diğer bir problemde sadece tek göz bölgesine ait görüntülerin kullanılmasıdır. Yapılan deneysel çalışmalar sırasında kullanıcının ekran üzerinde belirli bir konuma bakarken her iki gözünün de

tamamen aynı doğrultuda bakmadığı gözlemlenmiştir. Bu nedenle sağ ve sol göz bilgilerinin birleştirilerek de kullanılmasına karar verilmiştir.

Çalışmada yukarıda belirtilen sorunları aşmak amacıyla aşağıda belirtilen GözBölge#1 ve GözBölge#3 görüntü yöntemleri önerilmiştir. Önceki çalışmalarla başarısını kıyaslamak amacıyla GözBölge#2 ve GözBölge#4 görüntü yöntemleri de denenmiştir. Bu modellerde üzerinde kırpma gerçekleştirilen veya gerçekleştirilmeyen herbir göz görüntüsü göz boyutlarının farklılığı, kullanıcı ekran arası mesafe vb. problemleri ortadan kaldırmak amacıyla çift doğrusal aradeğerleme yöntemiyle 90x60 boyutuna ölçeklendirilmiştir. Çift göz bölgesinden oluşan görüntüler ise 180x60 boyutunda ölçeklendirilmiştir. Kullanılan bu boyuttaki görüntüler literatürdeki çalışmalara göre oldukça yüksektir. Ancak çalışmada orijinal göz en/boy oranını korumakla birlikte sınıflandırma başarısını arttırmak amacıyla bu boyutlar kullanılmıştır. Bu şekilde yüksek boyutlu görüntü kullanılmasının dezavantajı işlem maliyetini arttırmasıdır ancak deneysel gözlemler sırasında sistemin gerçek zamanlı çalışmasını engellemediği gözlemlenmiştir.

Çalışmada kullanılan ve herbiri üzerinde eğitim ve test işlemleri ile başarıları ölçülen göz bölge modelleri şu şekildedirler:


GözBölge#1: Şekil 2.18 b'de görüldüğü gibi tek göz görüntüleri (sol veya sağ) göz akının sol ve sağ uç sınırları görüntünün yatay sınırları içinde kalacak şekilde alınarak gereksiz göz bölgeleri elimine edilmiş ve başarıları arttırılmaya çalışılmıştır.

GözBölge#2: Şekil 2.18 a' da görüldüğü gibi tek göz görüntüsü üzerinde herhangi bir kırpma işlemi gerçekleştirilmemiştir. Bu yöntemle GözBölge#1'in kullanılması sonucu elimine edilen göz bölgelerinin sistemin başarısında etkisinin olup olmadığı ölçülmüştür.

GözBölge#3: Şekil 2.19 b'de görüldüğü gibi sol ve sağ göz görüntüsü üzerinde GözBölge#1'de belirtildiği şekilde kırpma gerçekleştirilmiştir. Kırpılan ve herbiri 90x60 boyutuna ölçeklendirilen görüntüler yatay şekilde birleştirilerek iki göz bilgisi beraber kullanılmıştır. Deneyler sırasında bazı deneklerin her iki gözünün aynı doğrultuda bakmadığının gözlemlenmesi sonucu tek göz bilgisinin değil bu şekilde çift göz bilgisinin kullanılmasına karar verilmiştir.


GözBölge#4: Şekil 2.19 a'da görüldüğü gibi 90x60 boyutunda ölçeklendirilen sağ ve sol göz bölgeleri üzerinde herhangi bir kırpma işlemi gerçekleştirilmeden ve GözBölge#3 ile belirtildiği şekilde her iki göz bilgisi birleştirilerek kullanılmıştır. Bu yöntemle GözBölge#3'ün kullanılması sonucu elimine edilen göz bölgelerinin sistemin başarısında etkisinin olup olmadığı ölçülmüştür.

Yukarıda belirtilen GözBölge#1 ve GözBölge#2 modellerine ait örnek bakış görüntüleri Şekil 2.18'deki gibidir.



Şekil 2.18. Örnek GözBölge#2 görüntüleri (a), Örnek GözBölge#1 görüntüleri (b)

Yukarıda belirtilen GözBölge#3 ve GözBölge#4 modellerine ait örnek bakış görüntüleri Şekil 2.19'deki gibidir.



Şekil 2.19. Örnek GözBölge#4 görüntüleri (a), Örnek GözBölge#3 görüntüleri (b)

Çalışmada yukarıda belirtilen göz bölge modelleri ile görünüm temelli göz bakış yönü kestirimi için kullanılan öznitelik çıkarım ve sınıflandırma algoritma çiftleri Tablo 2.7'deki gibidir. Burada gri yoğunluk seviyesinden bağımsız ayıricılığı yüksek bir doku betimleyicisi ve öznitelik çıkarım yöntemi olan YİÖH ile göz bölgesi çevresinde oluşan aydınlanma değişimlerinden etkilenme oranı düşürülmeye çalışılmıştır. TBA yönteminde öz gözler hesaplanarak hem öznitelik çıkarımı hem de yüksek boyutlardaki görüntü verileri üzerinde boyut azaltma işlemi gerçekleştirilmiştir. Sınıflandırma işleminde başarılı sonuçlar verdiği bilinen DVM, YSA ve KEYK yöntemleri kullanılmıştır.

Tablo 2.7. Kullanılan sınıflandırma ve öznitelik çıkarma yöntemleri

Sınıflandırma Yöntemi	Öznitelik Çıkarım Yöntemi
DVM	YİÖH
DVM	TBA
YSA	YİÖH
YSA	TBA
KEYK	YİÖH
KEYK	TBA

Kullanılan herbir sınıflandırma ve öznitelik çıkarma yönteminde ızgara tabanlı arama veya deneme yanılma yoluyla elde edilen ve sınıflandırma başarısını arttıran en iyi parametre değerleri ise şu şekildedir:

DVM + YİÖH: Öznitelik çıkarımında YİÖH R=2, P=16 parametre değerleri ile hesaplanmış, örüntü 6x6 adet alt örüntü bölmesine bölünmüş ve herbiri üzerinde düzenli örüntüler kullanılarak 59 seviyeli YİÖH hesaplanmıştır. Sınıflandırma işlemi radyal tabanlı çekirdek fonksiyonlu DVM ile gerçekleştirilmiştir. Çekirdek fonksiyonunun ilgili parametreleri $\gamma = 2^{-15}$ ve $C = 2^{15}$ şeklindedir.

DVM + TBA: Öznitelik çıkarımında bileşen sayısı 30 alınarak TBA ile özyüz uzayı hesaplanmıştır. Sınıflandırma ise herhangi bir parametre almayan doğrusal çekirdek fonksiyonlu DVM ile gerçekleştirilmiştir. Beklenenin aksine radyal tabanlı DVM bu yöntemde başarılı sonuç üretmemiştir.

YSA + YİÖH: Öznitelik çıkarımında YİÖH R=2, P=16 değerleri ile hesaplanmış, örüntü 6x6 adet alt örüntü bölmesine bölünmüş ve herbiri üzerinde düzenli örüntüler kullanılarak 59 seviyeli YİÖH hesaplanmıştır. Sınıflandırma aşamasında ise 59 x 6 x 6 adet giriş, YİÖH öznitelik vektörü / 50 adet ara ve 6 çıkış katmanından oluşan ve sigmoid aktivasyon fonksiyonu kullanan, belirli bir hata değeri ve adım sayısı ölçütü ile ağ eğitimini gerçekleştiren geri beslemeli ÇKP yapısı kullanılmıştır.

YSA + TBA: Öznitelik çıkarımında bileşen sayısı 30 alınarak TBA ile özyüz uzayı hesaplanmıştır. Sınıflandırma aşamasında ise 30 giriş, 30 ara ve 6 çıkış katmanından oluşan sigmoid aktivasyon fonksiyonu kullanan, belirli bir hata değeri ve adım sayısı ölçütü ile ağ eğitimini gerçekleştiren geri beslemeli ÇKP yapısı kullanılmıştır.

KEYK + YİÖH: Öznitelik çıkarımında YİÖH R=2, P=16 değerleri ile hesaplanmış, örüntü 6x6 adet alt örüntü bölmesine bölünerek ve herbiri üzerinde düzenli örüntüler

kullanılarak 59 seviyeli YİÖH hesaplanmıştır. Sınıflandırma ise en yakın komşu sayısı $k=1$ değeri ile gerçekleştirilmiştir.

KEYK + TBA: Öznitelik çıkarımında bileşen sayısı 30 alınarak TBA ile özyüz uzayı hesaplanmıştır. Sınıflandırma ise en yakın komşu sayısı $k=1$ değeri ile gerçekleştirilmiştir.

Geliştirilen sistemin testi için Bölüm 3.9'da belirtilen deney ortamı ve kamera sistemi özellikleri ve 32 farklı kullanıcıdan alınan eğitim ve kalibrasyon verilerinin birleştirilmesiyle oluşan veritabanı kullanılarak gerçekleştirilmiştir. Bu veritabanı YUV renk uzayının Y kanal bilgisi ile ifade edilen ekran üzerinde sağa, sol, üste, alta ve merkeze yapılan bakışlar ile kapalı göz görüntüleri olmak üzere 6 farklı gözle bakışı bilgisini içermektedir. Test işlemleri yukarıda verilen tüm göz bölgesi modelleri üzerinde herbir öznitelik çıkarım ve sınıflandırma yöntem çiftleri uygulanarak gerçekleştirilmiştir. Sistemin başarı değerleri ise tüm yönde yapılan bakışların, sağ ve sol yönlerde yapılan bakışların ve alt ve üst yönlerde yapılan bakışların doğruluklarının ölçülmesi şeklinde ayrı ayrı 3 farklı şekilde gerçekleştirilmiştir. Ayrıca, sistemde eğitim ve test verilerinin seçilmesi 5 kat çapraz doğrulama yöntemi kullanılmıştır.

GözBölgesi#1 bakış görüntüleri üzerinde Tablo 2.7'de verilen yöntem çiftlerinin uygulanması sonucu sırasıyla tüm yönlerde, sağ-sol yönlerinde ve alt-üst yönlerinde elde edilen sınıflandırma doğruluk sonuçları Tablo 2.8'deki gibidir.

Tablo 2.8. GözBölgesi#1 modeli üzerinde sınıflandırma doğrulukları

Yöntemler	Tüm Yönler + Kapalı Göz Sınıflandırma Doğrulukları	Sağ ve Sol Yönlerde Sınıflandırma Doğrulukları	Alt ve Üst Yönlerde Sınıflandırma Doğrulukları
DVM + YİÖH	%96,93	%97,25	%98,40
DVM + TBA	%91,72	%98,00	%98,40
YSA + YİÖH	%84,43	%98,00	%94,06
YSA + TBA	%95,36	%98,00	%98,60
KEYK + YİÖH	%94,76	%96,51	%95,93
KEYK + TBA	%93,90	%98,00	%97,56

GözBölgesi#2 bakış görüntüleri üzerinde Tablo 2.7'de verilen yöntem çiftlerinin uygulanması sonucu sırasıyla tüm yönlerde, sağ-sol yönlerinde ve alt-üst yönlerinde elde edilen sınıflandırma doğruluk sonuçları Tablo 2.9'daki gibidir.

Tablo 2.9. GözBölgesi#2 modeli üzerinde sınıflandırma doğrulukları

Yöntemler	Tüm Yönler + Kapalı Göz Sınıflandırma Doğrulukları	Sağ ve Sol Yönlerde Sınıflandırma Doğrulukları	Alt ve Üst Yönlerde Sınıflandırma Doğrulukları
DVM + YİÖH	%95,36	%96,51	%98,40
DVM + TBA	%90,73	%98,00	%98,40
YSA + YİÖH	%79,08	%96,51	%98,40
YSA + TBA	%92,67	%98,00	%98,40
KEYK + YİÖH	%91,96	%96,51	%98,40
KEYK + TBA	%92,44	%97,25	%97,56

GözBölgesi#3 bakış görüntüleri üzerinde Tablo 2.7’de verilen yöntem çiftlerinin uygulanması sonucu sırasıyla tüm yönlerde, sağ-sol yönlerinde ve alt-üst yönlerinde elde edilen sınıflandırma doğruluk sonuçları Tablo 2.10’deki gibidir.

Tablo 2.10. GözBölgesi#3 modeli üzerinde sınıflandırma doğrulukları

Yöntemler	Tüm Yönler + Kapalı Göz Sınıflandırma Doğrulukları	Sağ ve Sol Yönlerde Sınıflandırma Doğrulukları	Alt ve Üst Yönlerde Sınıflandırma Doğrulukları
DVM + YİÖH	%91,05	%97,25	%98,40
DVM + TBA	%93,03	%98,00	%98,40
YSA + YİÖH	%82,16	%98,00	%98,40
YSA + TBA	%94,77	%98,00	%98,40
KEYK + YİÖH	%91,55	%98,00	%98,91
KEYK + TBA	%91,54	%98,00	%98,40

GözBölgesi#4 bakış görüntüleri üzerinde Tablo 2.7’de verilen yöntem çiftlerinin uygulanması sonucu sırasıyla tüm yönlerde, sağ-sol yönlerinde ve alt-üst yönlerinde elde edilen sınıflandırma doğruluk sonuçları Tablo 2.11’deki gibidir.

Tablo 2.11. GözBölgesi#4 modeli üzerinde sınıflandırma doğrulukları

Yöntemler	Tüm Yönler + Kapalı Göz Sınıflandırma Doğrulukları	Sağ ve Sol Yönlerde Sınıflandırma Doğrulukları	Alt ve Üst Yönlerde Sınıflandırma Doğrulukları
DVM + YİÖH	%92,16	%97,25	%98,40
DVM + TBA	%94,36	%98,00	%98,40
YSA + YİÖH	%83,14	%98,00	%98,40
YSA + TBA	%93,63	%98,00	%98,40
KEYK + YİÖH	%91,43	%96,51	%98,40
KEYK + TBA	%91,92	%97,25	%96,76

Elde edilen sonuçlar incelendiğinde, tüm yönler ve göz kapalılığı durumundaki tüm verilerin sınıflandırılmasında en başarılı sonuçların önerilen tek göz görüntüsü üzerinde sol ve sağ uçlardan gereksiz göz bölgeleri elimine edildiği GözBölge#1 görüntü modeli üzerinde DVM ve YİÖH kullanılarak elde edilmiştir.

Sağ ve sol yönlerdeki göz bakış verilerini sınıflandırılmasında neredeyse tüm göz bölge modelleri ve yöntem çiftleri uygulandığına yaklaşık %98 oranına başarı elde edilmiştir. Tüm yönlerde benzer oranda başarı elde edilmesi sağ ve sol göz bakış verilerinin görünüm temelli yöntemlerle iyi ayrıştırılabildiğini göstermektedir. Bu başarının elde edilmesi, ayrıca ayırt edilecek sınıf sayısının düşük olmasından da kaynaklanmaktadır. Uygulanan yöntemlerin çoğunda en fazla %2 oranında başarısız sınıflandırma sonuçlarının bulunması ise test verilerinin bir kısmının hiçbir yöntemle ayrıştırılamadığının göstergesidir.

Üst ve alt yönlerdeki göz bakış verilerini sınıflandırılmasında neredeyse tüm göz bölge modelleri ve yöntem çiftleri uygulandığına yaklaşık %98,4 oranına başarı elde edilmiştir. Elde edilen bu başarı oranı alt ve üst yönlerdeki göz bakış verilerinin sağ ve sol yönlere göre görünüm temelli yöntemler ile daha kolay ayrıştırılabildiğini göstermektedir. Bu yönlerdeki verilerin sınıflandırılmasında yüksek başarı elde edilmesinde ayırt edilecek sınıf sayısının düşük olmasının etkisi bulunmaktadır. Benzer şekilde bu yöntemde de test verilerinin bir kısmı hiçbir yöntemle başarılı bir şekilde sınıflandırılmamıştır.

Dikkat edilmesi gereken diğer bir sonuçta, GözBölge#3 ve GözBölge#4 modelleri ile sınıflandırılan göz bölgelerinin, tüm yönler ve göz kapalılığı durumunun kestiriminde diğer göz modellerine göre düşük oranda başarı göstermesidir. Sağ-sol ve alt-üst yönlerdeki göz bakış verilerinin sınıflandırılmasında ise bu yöntem diğer göz modellerine yakın başarı elde etmiştir.

Ayrıca, bakış görüntüleri çeşitli çözünürlüklerde eğitim ve test işlemine tabi tutularak görünüm temelli yöntemlerde çözünürlüğün etkisi incelenmiştir. Sonuçlar bakış yönü kestiriminde en iyi sonuçlar veren GözBölgesi#1 modeli, DVM ve YİÖH kullanılarak gerçekleştirilmiştir. İşlem sonucunda sırasıyla tüm yönlerde, sağ-sol yönlerinde ve alt-üst yönlerinde elde edilen sınıflandırma doğruluk sonuçları Tablo 2.12'deki gibidir.

Tablo 2.12. GözBölgesi#1 modeli üzerinde DVM ve YİÖH yöntem çifti ile çeşitli çözünürlüklerde sınıflandırma doğrulukları

Görüntü Çözünürlüğü	Tüm Yönler + Kapalı Göz Sınıflandırma Doğrulukları	Sağ ve Sol Yönlerde Sınıflandırma Doğrulukları	Alt ve Üst Yönlerde Sınıflandırma Doğrulukları
15x10	%87,37	%96,50	%94,83
30x20	%92,69	%96,12	%96,36
60x40	%96,20	%97,25	%98,40
90x60	%96,93	%97,25	%98,40

Elde edilen sonuçlar incelendiğinde, tüm yönler ve göz kapalılığı durumundaki bakış verilerinin sınıflandırılmasında çözünürlük arttıkça başarı artmış ve 90x60 boyutundaki görüntülerde maksimum başarı elde edilmiştir. Sağ ve sol ile alt ve üst yönlerdeki verilerin sınıflandırılmasında ise çözünürlüğün etkisinin daha az olduğu görülmektedir. 15x20 boyutundaki görüntülerde az bir hata değeri ile en başarısız sonuçlar elde edilmiş, diğer çözünürlüklerde ise ortalama %98 oranında başarı elde edilmiştir.

Çalışmada gerçek zamanlı çalışan bir sistemin geliştirilmesi istendiğinden kullanılan yöntemlerin yeterli performansta çalışması gerekmektedir. Kullanılan tüm yöntem çiftlerinin verilen parametrelerle hesaplanması sonucu elde edilen eğitim ve test süreleri Tablo 2.13'deki gibidir. Her bir yöntem çiftinin test süreleri incelendiğinde tüm yöntem çiftlerinin gerçek zamanlı çalışmayı desteklediği görülmektedir. Eğitim süreci sonucunda oluşan ayırıcı düzlem ve sinir ağı yapıları bir dosya içerisinde kaydedildiğinden eğitim sürelerinin uzun olmasının herhangi bir dezavantajı bulunmamaktadır.

Dikkat edilmesi gereken diğer bir hususta, öznetelik çıkarımı aşamasında YİÖH kullanıldığında öznetelik vektör boyutunun büyük olması nedeniyle test süresinin arttığı ve sınıflandırma işleminde YSA kullanıldığında eğitim süresinin arttığıdır.

Tablo 2.13. Yöntem çiftlerinin eğitim ve test süreleri

Yöntemler	Eğitim Süresi	Test Süresi
DVM + YİÖH	953 ms	1,132 ms
DVM + TBA	2297 ms	0,378 ms
YSA + YİÖH	82093 ms	1,524 ms
YSA + TBA	15578 ms	0,195 ms
KEYK + YİÖH	-	1,146 ms
KEYK + TBA	-	0,182 ms

Literatüdeki çalışmaların çoğu göz bakışının izlenerek kullanıcının ekran üzerinde baktığı noktasal konumun ölçülmesi şeklinde gerçekleştirilmiştir ve sistemin doğruluk değerlerinin hesaplanmasında yatay ve dikey eksenlerdeki açısal doğruluk değeri kullanılmıştır. Ancak, çalışmada olduğu gibi, göz bakışının izlenmesinin daha özel bir hali olan göz bakış yönü kestirimine yönelik çalışmaların sayısı ve dolayısıyla karşılaştırılacak sonuç sayısı ise azdır. Yapılan çalışmanın ayrıca bu yönden de literatüre katkısı olacaktır.

Benzer çalışmalar ve bu çalışmalarla elde edilen sonuçlar şu şekildedir:

Zhang ve arkadaşları yaptıkları çalışmada [85] bakış görüntüleri üzerinde renk, yoğunluk ve dağılım bilgilerinden faydalanarak 50 adet öznitelik çıkarmışlar ve MRMR yöntemi ile öznitelik seçimi gerçekleştirmişlerdir. Çalışmada, KEYK sınıflandırma yöntemini kullanarak 17 deneğe ait 13 farklı yönde gözle bakış görüntülerini sınıflandırmışlardır ve %86 oranına başarı elde etmişlerdir. Elde edilen bu başarı oranı, daha fazla denek üzerinde gerçekleştirilen ve daha gerçekçi sonuçlar üreteceği düşünülen çalışmamızda elde ettiğimiz başarı oranlarına göre düşüktür. Ancak, ilgili çalışmada önerilen yöntemle 13 farklı göz bakış verisinin sınıflandırılması ve belirli seviyede serbest kafa hareketlerine izin vermesi başarı oranının yaptığımız çalışmaya göre düşük olmasına neden olduğu düşünülebilir. Diğer taraftan, bu çalışmada kafa üzerine yerleştirilen standart bir kamera ile göze yakın bakış görüntüleri kullanıldığından başarı oranının daha yüksek olması beklenirdi.

Wu ve arkadaşları yaptıkları çalışmada [89] AAM (Active Appearance Model) ile elde ettikleri göz bölgeleri üzerinde göz sınır bilgileri, iris boyutu, irisin konumu ve göz bebeğinin konumu gibi 36 adet işaret noktası öznitelik olarak kullanmışlardır. Ekran üzerinde merkez, sol alt, sol üst, sağ alt ve sağ üst göz bakışlarının sınıflandırılması ise DVM ile gerçekleştirilmiştir. Bu çalışmada herbir yönde ortalama %95,66 ile ifade edilen bir başarı elde edilmiştir. Bu çalışmada da bakış yönü verileri çalışmamızda olduğu gibi belirli

mesafedeki kamera ile alınmıştır. Ancak, elde edilen sonuçlar incelendiğinde, daha az sayıda türde bakış verileri sınıflandırılmasına ve herbir göz bakışının diğerlerine göre sınıflandırma doğrulukları hesaplanmasına rağmen, çalışmamızda olduğu gibi 6 farklı türdeki bakış verilerinin sınıflandırılması göre daha az başarılı sonuçlar elde edilmiştir. Ayrıca, önerilen sistem gerçek zamanlı çalışmayı desteklememektedir.

Literatürdeki çalışmalarda elde edilen ve yukarıda detaylı bir şekilde açıklanan yöntemler ile bu çalışmada 6 farklı yönde elde edilen göz bakış yönü kestirimlerinin başarı oranlarının karşılaştırılması Tablo 2.14'deki gibidir.

Tablo 2.14. Önerilen yöntemin mevcut çalışmalarla kıyaslanması

Merkez	Kestirim Sınıf Sayısı	Sınıflandırma Doğruluğu
Tez çalışması	6	%96,93
Zhang ve ark. [85]	13	%86,00
Wu ve ark. [89]	5	%95,66

Göz bakış yönü tespiti gerçekleştirildikten sonra insan bilgisayar etkileşimini sağlamak amacıyla Windows uygulama programlama arayüzleri kullanılarak ve çeşitli kullanıcı kontrolleri eklenerek gerçek zamanlı çalışması istenen sistemin başarısı gözlemlenmiştir. Bu amaçla ilk olarak, kullanıcının ekran üzerinde sağ, sol, alt ve üst yönlerde bakışlarında örnek bir coğrafi harita üzerinde ilgili yöne yönlendirmeler yapıldı. Merkeze bakışlarda duraklatılma, göz kapama hareketlerinde ise harita üzerinde yakınlaştırma işlemleri gerçekleştirildi. İkinci olarak, ekran üzerinde 4 farklı yönde yapılan bakışlarda imlecin ilgili doğrultuda yönlendirilmesi yapılarak sağ veya sol göz kırpma durumlarında ilgili tıklama kullanıcı kontrolleri gerçekleştirildi. Gerçekleştirilen bu işlemler sistem üzerinde gerçek zamanlı olarak kabul edilebilir bir başarı ile yerine getirilmiştir. Ancak bu işlemlerin hassaslıklarını ve başarılarını arttırmaya yönelik ek çalışmaların yapılması gerekmektedir.

3. SONUÇLAR VE TARTIŞMA

Tez çalışmasında video-okulografi ve görünüm temelli yöntemler kullanılarak görüntü verileri ile kullanıcının etkileşimde olduğu ekranı koordinatları eşleştirilmiş ve ekran üzerinde sağ, sol, alt, üst ve merkez doğrultularında yaptığı bakışlar ile gözün kapalılık durumu kestirimi gerçekleştirilmiştir. Geliştirilen sistemde kullanılan tüm bileşen ve yöntemler gerçek zamanlı çalışabilirliği destekleyecek şekilde seçilmiş ve önerilen yöntem birkaç insan bilgisayar etkileşimi probleminde alternatif kullanıcı arayüzü olarak uygulanmış ve başarılı sonuçlar alınmıştır.

Çalışmada öncelikle HBS yöntemi ile yüksek doğrulukta, ölçeklendirmeden bağımsız ve gerçek zamanlı çalışabilen yüz bölgesi tespiti yapılmıştır. Elde edilen yüz bölgesi üzerinde hesaplama maliyetini azaltmak amacıyla hedef göz arama penceresi oluşturulmuş ve bu alan içerisinde HBS yaklaşımı ile ölçekten bağımsız ve gerçek zamanlı çalışabilen sağ ve sol göz bölge tespiti gerçekleştirilmiştir. Görünüm temelli bir yöntemle göz bakış yönü kestirimi yapıldığından bir deney ortamı oluşturulmuş ve göz yapıları birbirinden farklı 47 adet kullanıcıdan alınan kalibrasyon ve test video görüntüleri kullanılarak bakış yönü veritabanı oluşturulmuştur. Bakış yönü kestiriminin iyileştirilmesi amacıyla önerilen göz bölge modelleri üzerinde çeşitli öznetelik çıkarım ve sınıflandırma yöntemleri kullanılarak en iyi doğrulukta kestirimi gerçekleştirilen yaklaşımın tespiti gerçekleştirilmiştir. Son olarak, elde edilen bakış yönü bilgisi gerçek zamanlı insan bilgisayar etkileşimi problemlerine uygulanmıştır.

Literatürde kullanılan görünüm temelli yöntemlerin en büyük problemi çok sayıda eğitim görüntü verisine ihtiyaç duymasıdır. Çalışmada, eğitim veritabanına kullanıcıdan alınan kalibrasyon görüntü verileri de eklenerek bu problem önemli ölçüde aşılmıştır. Ayrıca, literatürdeki çalışmaların çoğunda göz bakış görüntüleri düşük çözünürlüklü görüntülerdir. Çalışmada daha başarılı sonuçlar vereceği düşünülen yüksek çözünürlüklü ve net görüntüler kullanılarak sınıflandırma başarısı arttırılmaya çalışılmıştır. Bu aşamadaki yüksek işlem maliyeti, yüz ve göz bölgesi tespitinde en az hesaplama maliyeti içeren yöntemler ve arama parametreleri seçilerek telafi edilmeye çalışılmıştır.

Ayrıca, göz tespiti aşamasında çıktı olarak elde edilen göz bölgeleri üzerinde deneysel sonuçlar ile elde edilen oranlarda kırpma gerçekleştirilerek, elde edilen bu daha özel göz bölgeleri üzerinde bakış yönü kestirimi gerçekleştirilmiş ve kestirim doğruluk oranı arttırılmaya çalışılmıştır.

Çalışmada kullanılan görünüm temelli video-okulografi yöntemi elektrookulografi ve arama bobinleri gibi diğer yöntemlerde sıkça karşılaşılan kullanıcıyı kısıtlama ve rahatsız etme problemini ortadan kaldırmıştır. Bu kullanıcıyı rahatsız etme problemi video-okulografi yönteminde bakış görüntüsünün kafa veya göz üzerine yerleştirilen kamera sistemleri ile edinilmesi durumunda da karşılaşılmaktadır. Çalışmada ekran üzerine yerleştirilen kamera düzeneğinin kullanılması ile bu problemde ortadan kaldırılmaya çalışılmıştır ancak elde edilen başarı oranında bu yöntemlere göre miktar düşüş yaşanmıştır.

Literatürde özellikle özellik temelli yöntemlerde sıkça karşılaşılan ortam aydınlatma değişimlerinden etkilenme problemi öznitelik çıkarımı aşamasında YİÖH kullanılarak göz bölgesi üzerinde düzgün dağılan aydınlanma değişimlerinden etkilenmeyi azaltacak şekilde ortadan kaldırılmaya çalışılmıştır. Ancak göz bölgesi çevresinde düzgün olmayan gölgelerin oluşumu problemi çözülememiştir. Ayrıca, oluşturulan sistemde göz bakış verileri tamamen sabit bir kafa duruşu ile alınmamış ve düşük oranlarda da olsa çeşitli açılardaki kafa hareketlerine izin verilmiştir. Ancak, geliştirilen sistem tamamen serbest kafa hareketlerine izin vermemektedir.

Çalışmada ayrıca göz bakış yönü kestirimi farklı öznitelik çıkarım ve sınıflandırma algoritmaları ile aynı veritabanı üzerinde test edilerek bu yöntemlerin karşılaştırması yapılmıştır. Literatürdeki çalışmaların çoğunda tek öznitelik çıkarım ve sınıflandırma yöntemi kullanılmıştır. Çalışmada kullanılan veritabanının literatürdeki çalışmalara göre daha fazla sayıda örnek içermesi ve farklı göz yapısına sahip kullanıcılar ile gerçekleştirilmesi çalışmanın diğer bir katkısını oluşturmaktadır.

4. ÖNERİLER

Sadece göz bölgesine ait görünüm bilgileri kullanılarak bakış yönü kestirimi yerine kullanıcı kafasının kameraya göre 3 boyutlu yön ve pozisyon bilgisi de eklenerek serbest kafa hareketlerinde çalışabilen ve kalibrasyon gerektirmeyen yöntemler önerilebilir.

Göz görüntüsünün alınmasında kullanılan kamera ekran üzerine değilde göz önüne monte edilecek şekilde tasarlanarak serbest kafa hareketinden bağımsızlık ve değişen ortam koşullarına daha dayanıklı bir sistem geliştirilebilir. Göz üzerine monte edilen kamera sistemi ile elde edilen yüksek çözünürlükteki göz görüntüleri ile göz bakış yönü kestirimindeki doğruluk oranı arttırılabilir.

Çalışmada kullanılan YİÖH öznitelik çıkarma yöntemi görüntü üzerinde homojen dağılan aydınlatma değişimlerinden etkilenmeyerek başarılı sonuçlar üretmektedir, ancak gerçek hayat uygulamalarında göz çevresinde yer alan kavisli bölgeler gölgeler oluşmaktadır. Bu sorunu çözmek sınıflandırma işleminden önce göz çevresindeki gölgelenmeler kaldırılarak ve aydınlanma değişimleri normalize edilerek ortam aydınlatma değişimlerinden bağımsızlık sağlanabilir.

Kamera ile alınan kullanıcı görüntüleri üzerinde kafa ve vücut hareketlerinden kaynaklanan görüntü bozuklukları oluşabilmektedir. Benzer bozukluklar göz üzerindeki ani sıçrama hareketleri, göz durumunu değişmesi, göz kırpma ve ortam aydınlatmasının değiştiği durumlarda da ortaya çıkmaktadır. Gözle bakışının tespitinden önce bu görüntü bozuklukları giderilerek daha başarılı yöntemler önerilebilir.

5. KAYNAKLAR

1. <http://lasikblog.net/human-eye-structure-the-basics/> İnsan Gözünün Genel Yapısı. 10 Aralık 2014.
2. Singh, H. ve Singh, J., Human Eye Tracking and Related Issues: A Review, International Journal of Scientific and Research Publications (IJSRP), 2, 9 (2012) 1-9.
3. http://www.eubam.ege.edu.tr/kandel/kandel_39.htm Gözle Bakışın Kontrolü. 10 Aralık 2014.
4. Purves, D., Augustine, G., J. ve Fitzpatrick D, Neuroscience 2nd edition, Sinauer Associates Inc., USA, 2001.
5. Bedny, G. ve Karwowski, W., A Systemic-Structural Theory of Activity: Applications to Human Performance and Work Design, CRC Press, USA, 2007.
6. http://www.compression.ru/download/articles/color_space/ch03.pdf Renk Uzayları. 10 Kasım 2014.
7. Yılmaz, İ., Güllü, M., Baybura, T. ve Erdoğan, A. O., Renk Uzayları ve Renk Dönüşüm Programı (RDP), Fen ve Mühendislik Bilimleri Dergisi, 2, 2 (2000) 19-35.
8. Kuncan, M., Ertunç, H.M., Küçük yıldız, G., Hızarcı, B., Ocak, H. ve Öztürk, S., Görüntü İşleme Tabanlı Zeytin Ayıklama Makinesi, Otomatik Kontrol Ulusal Toplantısı, Eylül 2013, Malatya, Bildiriler Kitabı: 459-464.
9. Vandana, S. ve Jagadeesh, D., Face Detection System Using HSV Color Model and Morphing Operations, Proceedings of National Conference on Women in Science and Engineering, 2013, Bildiriler Kitabı: 200-204.
10. Krzywinski, M., Image Color Summarizer. http://mkweb.bcgsc.ca/color_summarizer/? 1 Ekim 2014.
11. Weeks, A. R., Felix, C.E, ve Myler, H.R., Edge Detection of Color Images Using the HSL Color Space, Nonlinear Image Processing VI, 2424 (1995) 1-11.
12. <http://www.rapidtables.com/convert/color/rgb-to-hsl.htm> RGB HSL Renk Uzay Dönüşümü. 9 Kasım 2014.
13. Stanescu, D., Stratulat, M., Groza, V., Ghergulescu, I. ve Borca, D., Steganography in YUV color space, IEEE International workshop on Robotic and Sensors Environments, Ekim 2007, Ottawa, Bildiriler Kitabı: 1-4.
14. http://www.compression.ru/download/articles/color_space/ch03.pdf Renk Uzayları. 10 Kasım 2014

15. <http://hidefcolor.com/color-management/what-is-lab-color-space/> Lab Renk Uzayı. 10 Kasım 2014.
16. <http://www.darktable.org/2012/02/mastering-color-with-lab-tone-curves/> Lab Renk Uzayı. 10 Kasım 2014.
17. http://www.cs.rit.edu/~ncs/color/t_convert.html Renk Dönüşüm Algoritmaları. 2 Kasım 2014.
18. Ford, A. ve Roberts, A., Colour Space Conversions. <http://www.poynton.com/PDFs/colo-ureq.pdf> 1 Kasım 2014.
19. Jain, P. ve Bansal, A., Histogram equalization of images. <http://www.cse.iitd.ernet.in/~neeraj/TA/cs316/2005-2006/project/final/pavan.pdf> 10 Kasım 2014.
20. Viola, P. ve Jones, M., Rapid object detection using a boosted cascade of simple features, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 1, (2001) I511-I518.
21. Lienhart, R., Kuranov, A. ve Pisarevsky, V., Empirical Analysis of Detection Cascades of Boosted Classifiers for Rapid Object Detection, DAGM 25th Pattern Recognition Symposium, Eylül 2013, Magdeburg, Bilgisayar Bilimleri Ders Notları: 297-304.
22. Crow, F., C., Summed-area tables for texture mapping, SIGGRAPH: International Conference on Computer Graphics & Interactive Techniques, 18, 3 (1984) 207-212.
23. http://en.wikipedia.org/wiki/Summed_area_table Toplam Alan Tablosu. 3 Eylül 2014.
24. Freund, Y. ve Schapire, R., E., A decision-theoretic generalization of on-line learning and an application to boosting, Journal of Computer and System Sciences, 55, 1 (1997) 119-139.
25. Bediz, Y., Automatic Eye Tracking and Intermediate View Reconstruction for 3D Imaging Systems, Yüksek Lisans Tezi, METU, Fen Bilimleri Enstitüsü, Ankara, 2007.
26. Karaimer, H., C. ve Baştanlar, Y., Haar-benzeri Öznitelikler ve Basamaklı Hızlandırma Kullanarak Tümyönlü Kameralar ile Binek Araç Tespiti, IEEE Conference on Signal Processing and Applications (SIU), Nisan 2014, Trabzon, Bildiriler Kitabı: 301 – 304.
27. <http://www.mathworks.com/help/vision/ref/vision.cascadeobjectdetector-class.html> Çok Ölçekli Görüntü Nesnesi Tespiti. 1 Eylül 2014.
28. Oflamaz, C., U., FPGA tabanlı video görüntü çerçevelerini iyileştirme cihazı geliştirimi, Yüksek Lisans Tezi, Hacettepe Üniversitesi, Fen Bilimleri Üniversitesi, Ankara, 2013.
29. Ojala, T., Pietikainen, M. ve Harwood, D., A comparative study of texture measures with classification based on featured distributions, Pattern Recognition, 29, 1 (1996) 51–59.

30. Ahonen, T. Hadid, A. ve Pietikainen, M., Face Description with Local Binary Patterns: Application to Face Recognition, Pattern Analysis and Machine Intelligence, 28, 12 (2006) 2037-2041.
31. Shan, C., Gong, S. ve McOwan, P., W., Facial expression recognition based on Local Binary Patterns: A comprehensive study, Image and Vision Computing, 27, 6 (2009) 803-816.
32. Sivri, E., Shape Descriptors Based on Intersection Consistency and Global Binary Patterns, Yüksek Lisans Tezi, METU, Fen Bilimleri Enstitüsü, Ankara, 2012.
33. http://docs.opencv.org/modules/contrib/doc/facerec_tutorial.html Komşu ile merkez piksel arasındaki farkı veren S fonksiyonu. 11 Aralık 2014.
34. Ojala, T., Pietikainen, M. ve Maenpaa, T., Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, IEEE Transactions on Pattern Analysis and Machine Intelligence , 24, 7 (2002) 971-987.
35. Pietikäinen, M., Hadid, A., Zhao, G. ve Ahonen, T., Computer Vision Using Local Binary Patterns, Springer, USA, 212, 2011.
36. Nabiyev, V., V. ve Günay, A., LBP Yardımıyla Görüntüdeki Kişinin Yaşının Belirlenmesi, Çankaya University Journal of Science and Engineering, 8, 1 (2011) 27-41.
37. Da., B. ve Sang, N., Local binary pattern based face recognition by estimation of facial distinctive information distribution, Machine vision and Pattern Recognition, 48, 11 (2009).
38. Atalay, İ., Özyüz Yöntemi ile Yüz Tanıma, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2006.
39. Turk, M.A., Face recognition using eigenfaces, Computer Vision and Pattern Recognition, Proceedings CVPR '91., IEEE Computer Society Conference on, Haziran 1991, Maui, Bildiriler Kitabı: 586 – 591.
40. http://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm K En Yakın Komşu Algoritması. 5 Aralık 2014.
41. Akkoca, B., S., Durgun Görüntülerden Yüz İfadelerin Tanınması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2014.
42. www.ist.yildiz.edu.tr/dersler/dersnotu/Kum-Analiz.doc Uzaklık Ölçütleri. 4 Eylül 2014.
43. Çomak, E., Destek Vektör Makineleri Çoklu Sınıflandırma Problemleri için Çözüm Önerileri, Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya, 2014.

44. Zhao,K., Tian, Y. ve Deng,Y., New Unsupervised Support Vector Machines, Cutting-Edge Research Topics on Multiple Criteria Decision Making Communications in Computer and Information Science, 35, (2009) 606-613.
45. Yilmaz, C.M., Kose, C., Computer Control and Interaction Using Eye Gaze Direction Detection, Signal Processing and Communications Applications Conference (SIU), Nisan 2014, Trabzon, Bildiriler Kitabı: 1658 – 1661.
46. Fletcher, T., Support Vector Machines Explained, <http://www.tristanfletcher.co.uk/> 10 Aralık 2014.
47. Tayyar, N. ve Tekin, S., İMKB 100 Endeksinin Destek Vektör Makineleri ile Günlük, Haftalık ve Aylık Veriler Kullanarak Tahmin Edilmesi, AİBÜ Sosyal Bilimler Enstitüsü Dergisi,13, 1 (2013) 189-217.
48. Ayhan, S. ve Erdoğan, Ş., DVM ile Sınıflandırma Problemlerinin Çözümü, Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 9, 1 (2014) 175-198.
49. Hsu, C., Chang, C. ve Lin, C., A Practical Guide to Support Vector Classification, Technical report, Department of Computer Science and Information Engineering, National Taiwan University, Taipei, 2003.
50. McCulloch, W., S. ve Pitts, W., A Logical Calculus of Ideas Immanent in Nervous Activity, The Bulletin of Mathematical Biophysics, 5, 4 (1943) 115-133.
51. Hebb, D., O., The Organization of Behavior, Journal of Clinical Psychology, 6, 3 (1950) 307.
52. Rosenblatt, F., The Perceptron: A Probabilistic Model for Information Storage and Organization In The Brain, Psychological Review, 65, 6 (1958) 386-408.
53. Minsky, M. ve Papert, S. An Introduction to Computational Geometry, M.I.T. Press, Cambridge, 258, 1969.
54. Hopfield, J., J., Neural networks and physical systems with emergent collective computational abilities, Proceedings of the National Academy of Sciences, 79, 8 (1982) 2554–2558.
55. Rumelhart, D., E. ve McClelland, J., L, Parallel Distributed Processing, 1, 1986.
56. Taşova, O., Yapay Sinir Ağları ile Yüz Tanıma, Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, 2011.
57. Zurada, J., M., Introduction to Artificial Neural Systems, 759, 1992.
58. Huynh, T., H., A new eye gaze detection algorithm using PCA features and recurrent neural networks, Computational Intelligence in Control and Automation (CICA), Nisan 2013, Singapore, Bildiriler Kitabı: 24-29.

59. Simini F., Touya A., Senatore A. ve Pereira J., Gaze tracker by electrooculography (EOG) on a head-band, 10th International Workshop on Biomedical Engineering, Ekim 2011, Kos, Bildiriler Kitabı: 1-4.
60. Yagi, T., Eye-gaze interfaces using electro-oculography, International Conference on Intelligent User Interfaces, Şubat 2010, Hong Kong, Bildiriler Kitabı: 28-32.
61. Ianez, E., Azorin, J. ve Vidal, C., Using Eye Movement to Control a Computer: A Design for a Lightweight Electro-Oculogram Electrode Array and Computer Interface, PLOS ONE, 8, 7 (2013) 1-10.
62. Singh, H. ve Singh, J., Human Eye Tracking and Related Issues: A Review, International Journal of Scientific and Research Publications, 2, 9 (2012) 1-9.
63. H.R. Chennamma, Xiaohui Yuan, A Survey on Eye-Gaze Tracking Techniques, Indian Journal of Computer Science and Engineering, 4, 5 (2013), 388-393.
64. Johns, Murray W., Tucker, A., Chapman, R., J., Crowley, Kate E. ve Michael, N., Monitoring eye and eyelid movements by infrared reflectance oculography to measure drowsiness in drivers, *Somnology - Sleep Research and Sleep Medicine*, 11, 4 (2007) 234-242.
65. Terrin, M., Berardinis, M., Boccuzzi, D., Terrin, G. ve Magli, A., Infrared Oculography as a Non Invasive Methods to Measure Visual Acuity before and after Surgery in Children with Congenital Nystagmus, *Pediatric Research* (2011), 424–424.
66. Carpenter, R., H., S., *Movements of the Eyes*, 1988.
67. <http://www.ober-consulting.com/main/lang/1/> Kızılötesi-Okulografi Yöntemi ile Ticari Uygulama. 4 Eylül 2014.
68. <http://www.alea-technologies.de/pages/en/home.php> Kızılötesi-Okulografi Yöntemi ile Ticari Uygulama. 4 Eylül 2014.
69. <http://lasikblog.net/the-eye-and-its-parts-limbus/> Kornea ve Göz Akı Arasındaki Sınır Çizgisi. 4 Eylül 2014.
70. http://www.lamasbeauty.com/beauty/custom_eyes_print.htm Göz İç ve Dış Bölgeleri. 4 Eylül 2014.
71. Hansen, D., W. ve Ji, Q., In the eye of the beholder: A survey of models for eyes and gaze, IEEE Trans. Pattern Anal. Mach. Intell., 32, 3 (2010) 478-500.
72. Nguyen, H. C. ve Huynh, T. H., Eye-gaze detection with a single WebCAM based on geometry features extraction, 11th International Conference on Control Automation Robotics & Vision (ICARCV), Aralık 2010, Singapore, Bildiriler Kitabı: 2507 – 2512.
73. Sigut, J. ve Sidha, S., Iris center corneal reflection method for gaze tracking using visible light, IEEE Trans. Biomed. Eng., 58, 2 (2011) 411-419.

74. Ari, F. ve Telatar, Z., Finding target fixation point based on pupil center and corneal reflection, *Signal Processing and Communications Applications (SIU)*, Nisan 2011, Antalya, *Bildiriler Kitabı*: 150-153.
75. Ebisawa, Y. ve Fukumoto, K., Head-Free, Remote Eye-Gaze Detection System Based on Pupil-Corneal Reflection Method with Easy Calibration Using Two Stereo-Calibrated Video Cameras, *IEEE Transactions on Biomedical Engineering*, 60, 10 (2013) 2952-2960.
76. Ebisawa, Y., Improved Video-Based Eye-Gaze Detection Method, *IEEE Trans. on Instrument and Measurement*, 47, 4 (1998) 948-955.
77. Iannizzotto, L. ve Rosa, F., Competitive combination of Multiple Eye detection and Tracking Techniques, *IEEE Transactions on Industrial Electronics*, 58 ,8 (2011) 3151-3159.
78. Orman, Z., Battal, A. ve Kemer, E., A Study on Face, Eye Detection and Gaze Estimation, *International Journal of Computer Science and Engineering Survey (IJCSSES)*, 2, 3 (2011) 29-46.
79. Orozco, J., Roca, F. ve Gonzalez, J., Real time gaze tracking with appearance based models, *Machine Vision and Applications*, 20, 6 (2009) 353-364.
80. Zhang, Y., Bulling, A. ve Gellersen, H., Discrimination of Gaze Directions Using Low-Level Eye Image Features, *Proc. of the 1st International Workshop on Pervasive Eye Tracking and Mobile Eye-Based Interaction (PETMEI 2011)*, Eylül 2011, Beijing, *Bildiriler Kitabı*: 9-13.
81. Baluja, S. ve Pomerleau, D., Non-Intrusive Gaze Tracking Using Artificial Neural Networks, *Working Notes: AAAI Fall Symposium Series, Machine Learning in Computer Vision: What, Why and How*, 53-156, 1994.
82. Huynh, T., H., A new eye gaze detection algorithm using PCA features and recurrent neural networks, *Computational Intelligence in Control and Automation (CICA)*, 2013 IEEE Symposium on, Nisan 2013, Singapore, *Bildiriler Kitabı*: 24-29.
83. Sesin, A., Adjouadi, M., Cabrerizo, M., Ayala, M. ve Barreto A., Adaptive eye-gaze tracking using neural-network-based user profiles to assist people with motor disability, *Journal of Rehabilitation Research and Development*, 45, 6 (2008) 801-818.
84. Huynh, T., H., A new eye gaze detection algorithm using PCA features and recurrent neural networks, *Computational Intelligence in Control and Automation (CICA)*, Nisan 2013, Singapore, *Bildiriler Kitabı*: 24 - 29.
85. Zhang, Y., Bulling, A. ve Gellersen, H., Discrimination of Gaze Directions Using Low-Level Eye Image Features, *Proc. of the 1st International Workshop on Pervasive Eye Tracking and Mobile Eye-Based Interaction (PETMEI 2011)*, Eylül 2011, Beijing, *Bildiriler Kitabı*: 9-13.

86. Martinez, F., Carbone, A. ve Pissaloux, E., Gaze estimation using local features and non-linear regression, Proc. 19th IEEE Int. Conf., Eylül 2012, Orlando, Bildiriler Kitabı: 1961 -1964.
87. Noris, B., Benmachiche, K. ve Billard, A., G., Calibration-free eye gaze direction detection with gaussian processes, VISAPP 2008: Proceedings of the Third International Conference on Computer Vision Theory and Applications, August 2008, Bildiriler Kitabı: 611-616.
88. Lu, F., Sugano, Y., Okabe, T. ve Sato, Y., “Adaptive Linear Regression for Appearance Based Gaze Estimation”, IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI), 36, 10 (2014) 2033-2046.
89. Wu, Y., L., Yeh, C., T., Hung, W., C. ve Tang, C., Y., Gaze direction estimation using support vector machine with active appearance model, Multimedia Tools and Applications, 70, 3 (2014) 2037-2062.
90. Tan, K., Kriegman, D., J. ve Ahuja, N., Appearance-based Eye Gaze Estimation, Proceedings of the Sixth IEEE Workshop on Applications of Computer Vision, (2002) 191.
91. Knerr, S., Personnaz, L. ve Dreyfus, G., Neurocomputing, 68 (1990), 41-50.
92. M. Pal, “Multiclass approaches for support vector machine based land cover classification,” in Proceedings of the 8th Annual International Conference, Map India, 2005, <http://arxiv.org/ftp/arxiv/papers/0802/0802.2411.pdf>.
93. Akalın, V., Face Recognition Using EigenFaces and Neural Networks, Yüksek Lisans Tezi, METU, Fen Bilimleri Enstitüsü, Ankara, 2003.
94. Faruqe, M., O. ve Hasan, M., A., M., Face Recognition Using PCA and SVM, Anti-Counterfeiting, Security, and Identification in Communication, Ağustos 2009, Hong Kong, Bildiriler Kitabı: 97-101.
95. Mazanec, Z., Melisek, M., Oravec, M. ve Pavlovicova, J., Support Vector Machines, PCA and LDA in Face Recognition, Journal of Electrical Engineering, 59, 4 (2008) 203-209.
96. Li, J., Zhao, B., Zhang, H. ve Jiao, J., Face Recognition System Using SVM Classifier and Feature Extraction by PCA and LDA Combination, Computational Intelligence and Software Engineering (CiSE 2009), Aralık 2009, Wuhan, Bildiriler Kitabı: 1-4.
97. Kaya, Y., Kaycı, L. ve Sezgin, N., Çok Ölçekli Yerel İkili Örüntüler ile Kelebek Görüntülerin Sınıflandırılması, Signal Processing and Communications Applications Conference (SIU), Nisan 2013, Girne, Bildiriler Kitabı: 24-26.

ÖZGEÇMİŞ

1988 yılında Giresun'da doğdu. İlk ve orta öğrenimini Yunus Emre İlköğretim Okulu, lise öğrenimini Bulancak Anadolu Lisesi'nde tamamladı. 2007 yılında Kocaeli Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü'nde lisans programına başladı ve 2011 yılında bu bölümden mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans öğrenimine başladı. 2011 yılı güz döneminden itibaren Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaktadır. Yabancı dil olarak iyi seviyede İngilizce bilmektedir.