

T.C
SELÇUK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İRİS DESENİNİN
YAPAY ZEKA YÖNTEMLERİ İLE TANINMASI

Hasan Erdinç KOÇER

DOKTORA TEZİ

ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Konya, 2007

ÖZET

Doktora Tezi

İRİS DESENİNİN YAPAY ZEKA YÖNTEMLERİ İLE TANINMASI

Hasan Erdinç KOÇER

Selçuk Üniversitesi Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman : Prof. Dr. Novruz ALLAHVERDİ

2007, 149 Sayfa

Jüri : Prof. Dr. Novruz ALLAHVERDİ

Prof. Dr. Ahmet ARSLAN

Prof. Dr. Bekir KARLIK

Prof. Dr. Şirzat KAHRAMANLI

Yrd. Doç. Dr. Yüksel ÖZBAY

Bu tez çalışmasında, kişilerden alınan göz resmi içerisinde ayrıştırılan iris deseninin yapay zeka yaklaşımı ile tanınması işlemi gerçekleştirilmiştir. Bu yaklaşım çerçevesinde iris görüntüleri, yapay zekanın sınıflandırmada kullanılan bir çeşidi olan Yapay Sinir Ağları ile sınıflandırılmıştır. İris tanıma amacıyla, Çin Bilim Akademisi ve Beira Interior Üniversitesi'nden alınan iki farklı veritabanı bu çalışmada kullanılmıştır.

İris bölgesinin tespiti için Hough dönüşümü ve Canny kenar bulma işlemleri uygulanmış ve gözbebeği ile iris bölgesinin dış kenar çizgileri tespit edilmiştir.

Tespit edilen iris bölgesi göz resmi içerisinde ayrıştırlarak Kartezyen – Polar koordinat dönüşümü ile dairesel halden dikdörtgensel hale dönüştürülmüştür. İris üzerinde yer alan desenlerin daha belirgin hale gelmesi amacıyla görüntüye histogram eşitleme uygulanmıştır.

İris görüntüsünün elde edilmesinin ardından öznitelik çıkarımı işlemine geçilmiştir. Bu aşamada iki farklı öznitelik vektörü çıkarımı uygulanmıştır. İlk yöntemde Gabor dalgacık dönüşümü yöntemi kullanılmış ve iris deseni ikili (binary – 0 ve 1 ile kodlama) olarak ifade edilmiştir. Buradan elde edilen öznitelik vektörü istatistiksel yaklaşımda kullanılmıştır. Diğer yöntemde ise, görüntü değişik boyutta (10*10, 14*14 v.b.) karesel pencereler kullanılarak alt görüntülere bölünmüş ve bu alt görüntülere ortalama mutlak sapma yöntemi uygulanarak çeşitli uzunlukta öznitelik vektörü elde edilmiştir. Bu çıkarım yöntemi ile elde edilen öznitelik vektörü ise yapay sinir ağı ile iris tanımda kullanılmıştır.

Çalışmanın son aşamasında ise karşılaştırma işlemi yapılmıştır. Karşılaştırma aşamasında iki farklı yol izlenmiştir. İlkinde, istatistiksel yöntemlerden Hamming uzaklığı yöntemi kullanılmıştır. Bu yöntemde tanıma işlemi iki görüntünün karşılaştırılması şeklinde olmaktadır ve bir sınıflandırma yapılmamaktadır. İkincisinde ise, yapay zeka yöntemlerinden çok katmanlı idrak sinir ağı, modüler sinir ağı ve Elman sinir ağı modelleri kullanılarak karşılaştırma işlemi gerçekleştirilmiştir. Genetik algoritmalar kullanılarak iris verileri azaltılmış ve karşılaştırma işlemi yeni iris verileri ile tekrar edilmiştir.

Çalışma sonucunda alınan doğrulama oranlarına göre, modüler sinir ağı modelinin diğer modellere oranla daha yüksek doğrulamaya sahip olduğu gözlenmiştir. CASIA iris veritabanından alınan iris görüntüleri için % 97,14, UBIRIS iris veritabanından alınan iris görüntüleri için en yüksek 100 % tanıma oranı elde edilmiştir. Ayrıca, sigmoid aktivasyon fonksiyonu ve eşleştirmeli eğim azaltımı öğrenme algoritması daha yüksek doğrulama gerçekleştirdiği gözlenmiştir. Genetik algoritmalar kullanılarak öznitelik seçimi yapılmış girişlerde iris tanıma oranında düşüş gözlenmiştir.

Anahtar Kelimeler: biyometrik sistemler, iris tanıma, görüntü işleme.

ABSTRACT

PhD Thesis

RECOGNITION OF IRIS TEXTURE BY USING ARTIFICIAL INTELLIGENCE METHODS

Hasan Erdinç KOÇER

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronical Engineering

Supervisor : Prof. Dr. Novruz ALLAHVERDİ

2007, 149 pages

Jury : Prof. Dr. Novruz ALLAHVERDİ

Prof. Dr. Ahmet ARSLAN

Prof. Dr. Bekir KARLIK

Prof. Dr. Şirzat KAHRAMANLI

Assist. Prof. Dr. Yüksel ÖZBAY

In this study, the process of recognition of iris texture that segmented from eye pictures taken from the people with artificial intelligence approach. In the frame of this approach, the iris images are classified by the Artificial Neural Networks (ANN) that the model of artificial intelligence used for classification. Two different iris databases obtained from Chinese Academy of Science and University of Beira Interior were used for iris recognition in this study.

Hough transform and Canny edge detection algorithms are applied to iris images for determining the boundary lines of iris region. This determined iris region

is reshaped from ring shaped to rectangular form by using Cartesian-Polar Coordinate transform. Then, histogram equalization is applied to this iris texture for becoming the iris features more clearly.

After getting the iris texture, feature extraction process is done. Two different feature extraction methods are used in this phase. In the first method, Gabor Wavelet transform is applied to iris images and obtained binary (0 and 1 coding) iris feature vectors. This iris feature vectors are used in statistical approach for matching. In the other extraction method, the iris images are divided into various squared dimensions (10*10, 14*14 etc.) then Average Absolute Deviation (AAD) method are applied to these sub-images for getting the iris feature vectors. These feature vectors are used in artificial neural network approach for classification.

In the last phase of this study, the matching or classification process is implemented. Two different ways are followed in recognition phase. In the first way, the kind of statistical matching method, Hamming Distance method is used. In this method, the identification process is implemented as matching between two iris templates. In the second way, three models of artificial intelligence; Multi-Layered Perceptron Neural Network, Modular Neural Network and Elman Neural Network are used for recognition of iris images. The genetic algorithms are used for reducing the iris features then the recognition process is repeated.

According to the correct classification rates, modular neural networks have the highest classification rates. The correct classification rates are 97,14 % for CASIA iris image database and 100 % for UBIRIS iris image database. Besides that, sigmoid activation function and conjugate gradient descent learning algorithm have the highest classification rates. It has been observed that the classification rates have been decreased for the inputs obtained from the genetic selection. The classification rates obtained from experimental results were presented as in tables in results part of this study.

Keywords: biometric systems, iris recognition, image processing.

TEŞEKKÜR

Biyometrik sistemler insanın fiziksel veya davranışsal özelliklerinin kullanılarak tanıma gerçekleştiren sistemlerdir. Çoğunlukla güvenlik amacıyla tasarlanan bu sistemlerde insan fizyolojisinin kullanılması sistemi çok daha güvenilir hale getirmektedir.

Bu tez çalışmasında, bir biyometrik sistem çeşidi olan iris tanıma sisteminin yüksek tanıma oranı ile gerçekleştirilmesi hedeflenmiştir. Bu amaçla, iris görüntüleri içerisinden iris deseni ayrıştırılarak öz nitelikleri çıkartılmış ve ardından tanıma işlemine geçilmiştir. Tanıma aşamasında, yapay sinir ağları kullanılmış ve yüksek doğrulama oranına sahip bir iris tanıma sistemi gerçekleştirilmiştir.

Çalışmamın her aşamasında yardımlarını esirgemeyen değerli hocam ve danışmanım Prof. Dr. Novruz ALLAHVERDİ'ye ve fikirleriyle bana yol gösteren tez izleme komitesi üyeleri Prof. Dr. Ahmet ARSLAN ve Yrd. Doç. Dr. Yüksel ÖZBAY'a sonsuz teşekkürlerimi iletiyorum.

Bunun yanında akademik çalışmalarımı ve yurtdışı akademik faaliyetlere katılımımı maddi anlamda destekleyen Selçuk Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğüne teşekkür ediyorum.

Ayrıca, bu tez çalışması süresince bana destek olan eşim Gülsün KOÇER'e ve biricik oğlum Hüsnü Tolga KOÇER'e de minnettarlığımı burada ifade etmek istiyorum.

İÇİNDEKİLER

	ÖZET	i
	ABSTRACT	iii
	TEŞEKKÜR	v
	İÇİNDEKİLER	vi
	ŞEKİLLER LİSTESİ	viii
	TABLolar LİSTESİ	ix
	SİMGELER ve KISALTMALAR	x
1.	GİRİŞ	1
1.1	Çalışmanın Amacı ve Önemi	6
1.2	Tezin Organizasyonu	7
2.	KAYNAK ARAŞTIRMASI	9
3.	BİYOMETRİK SİSTEMLER	16
3.1	Biyometrik Teknikler	16
3.2	Biyometrik Sistemin Seçimi	20
3.3	Biyometrik Çeşitleri	21
3.3.1	Yüz tanıma	21
3.3.2	Parmakizi tanıma	22
3.3.3	El geometrisi	23
3.3.4	Ses tanıma	24
3.3.5	El yazısı ve imza tanıma	25
3.3.6	Retina tanıma	25
3.3.7	Kulak şekli tanıma	26
3.3.8	DNA tanıma	26
3.3.9	Vücut ısı (termogram) tanıma	26
3.3.10	Yürüyüş tanıma	27
3.3.11	Dudak hareketi tanıma	27
3.3.12	İris tanıma	27
3.4	Çoklu-Biyometrikler	28
3.5	Biyometrik Sistemlerin Karşılaştırılması	28
3.6	Bölüm Sonuçları	30
4.	İRİS TANIMA SİSTEMLERİ	31
4.1	İrisin Yapısı	31
4.2	Teknik Özellikler	35
4.2.1	Görüntünün alınması	36
4.2.2	İrisin yerinin belirlenmesi	39
4.2.3	Öznitelik çıkarımı	41
4.2.4	Karşılaştırma	42
4.3	Bölüm Sonuçları	44
5.	İRİS GÖRÜNTÜSÜNÜN ÖN İŞLEMDEN GEÇİRİLMESİ	45
5.1	Görüntü Nedir?	45

5.2	Görüntü Formatları	46
5.3	Görüntü Ön İşleme Teknikleri	47
5.3.1	Görüntünün filtrelenmesi	47
5.4	Ayrıştırma (Segmentation) İşlemi	49
5.5	Histogram Dönüşümü	62
5.6	Bölüm Sonuçları	64
6.	İRİS GÖRÜNTÜSÜNÜN ÖZNİTELİKLERİNİN ÇIKARILMASI	66
6.2	Dalgacık (Wavelet) Kodlaması	66
6.3	Ortalama Mutlak Sapma	69
6.4	Bölüm Sonuçları	71
7.	İSTATİSTİKSEL YAKLAŞIM İLE İRİS TANIMA	72
7.1	Hamming Uzaklığı	72
7.2	Hamming Uzaklığı Yöntemi Uygulaması	73
7.3	Bölüm Sonuçları	76
8.	YAPAY SİNİR AĞLARI İLE İRİS TANIMA	77
8.1	Yapay Sinir Ağları (YSA)	77
8.1.1	YSA'nın genel özellikleri	78
8.1.2	YSA'nın dezavantajları	79
8.1.3	YSA'nın temel yapısı	80
8.1.4	Yapay sinir ağı hücresi	82
8.1.5	YSA öğrenme algoritmaları	85
8.1.6	Performans fonksiyonunun seçimi	86
8.1.7	YSA modelleri	87
8.2	Çok Katmanlı Perseptron (MLP) Modeli	88
8.2.1	MLP sinir ağı ile iris tanıma	96
8.3	Modüler Sinir Ağı (MNN) Modeli	100
8.3.1	MNN ile iris tanıma	102
8.4	Elman Sinir Ağı Modeli	105
8.4.1	Elman sinir ağı ile iris tanıma	107
8.5	Genetik Algoritmalar ile İris Öznitelik Vektörünün Azaltılması	109
8.5.1	GA ile iris öznitelik seçimi uygulaması	113
8.6	Bölüm Sonuçları	116
9.	SONUÇLAR ve ÖNERİLER	117
10.	TARTIŞMA	124
11.	KAYNAKLAR	127
	EKLER	137
	Ek-1: Uygulama Yazılımları	137

ŞEKİLLER LİSTESİ

Şekil 1.1	CASIA iris veritabanında yer alan iris görüntüsü	2
Şekil 1.2	UBIRIS veritabanında yer alan iris görüntüleri	3
Şekil 1.3	İris tanıma sistemi işlem adımları	5
Şekil 3.1	Biyometrik sistemin çalışma prensibi	18
Şekil 3.2	Biyometrik tanıma sisteminin genel yapısı	18
Şekil 3.4	Biyometrik sistem pazar oranları (2006)	30
Şekil 4.1	İrisin Fiziksel Yapısı	32
Şekil 4.2	İrisin üzerindeki bölgeler ve geometrik şekiller	33
Şekil 4.3	İris tanıma sistemlerinin aşamaları	36
Şekil 4.4	a) Daugman'ın Geliştirdiği Donanım b) Wildes'in Geliştirdiği Donanım	37
Şekil 4.5	İrisin yerinin belirlenmesi	40
Şekil 5.1	Orta değer (median) filtre	48
Şekil 5.2	Hough dönüşüm görüntü uzayı	57
Şekil 5.3	Kenarları tespit edilmiş iris görüntüsü a) CASIA b)UBIRIS	58
Şekil 5.4	Kenarları yanlış tespit edilmiş iris görüntüsü a) CASIA b)UBIRIS	59
Şekil 5.5	Alt ve üst kirpik görüntüleri atılmış iris görüntüsü a) CASIA b)UBIRIS	59
Şekil 5.6	Kartezyen – Polar koordinat dönüşümü	60
Şekil 5.7	Normalize edilmiş iris görüntüsü a) CASIA b)UBIRIS	61
Şekil 5.8	Hough dönüşüm noktaları eklenmiş iris görüntüsü a) CASIA b)UBIRIS	62
Şekil 5.9	Dönüşüm sonrası iris bölgesi görüntüsü a) CASIA b)UBIRIS	62
Şekil 5.10	Histogram eşitleme uygulanmış iris görüntüsü a) CASIA b)UBIRIS	64
Şekil 6.1	Gabor dalgacık dönüşümü sonrası elde edilen öznelik vektörü	69
Şekil 6.2	Ortalama mutlak sapma yöntemi ile öznelik çıkarımı	70
Şekil 7.1	Hamming uzaklığı yönteminde bit kaydırma işlemi	73
Şekil 7.2	Hamming uzaklığı değerleri (CASIA ve UBIRIS)	75
Şekil 8.1	Temel yapay sinir ağı hücresi	83
Şekil 8.2	Çok katmanlı perseptron ağı yapısı	88
Şekil 8.3	Eğitme işlemi	93
Şekil 8.4	CASIA 10*10 gizli katman hücre sayısı belirleme grafiği	97
Şekil 8.5	UBIRIS 10*10 eşleştirmeli eğitim algoritması MLP eğitim grafiği	100
Şekil 8.6	Paralel MLP modüllerinden oluşmuş MNN ağı yapısı	101
Şekil 8.7	İki veya daha fazla gizli katman içeren MNN ağı yapıları	102
Şekil 8.8	Uygulamada kullanılan MNN ağı yapısı	103
Şekil 8.9	MNN gizli katman hücre sayıları	104
Şekil 8.10	CASIA 14*14 eşleştirmeli eğitim algoritması MNN eğitim grafiği	105
Şekil 8.11	Elman sinir ağı yapısı	106
Şekil 8.12	UBIRIS 10*10 hızlı yayılım algoritması Elman ağı eğitim grafiği	108
Şekil 8.13	Genetik algoritmanın temel birimleri	109
Şekil 8.14	Genetik algoritma uygunluk değeri grafiği	114

TABLÖLAR LİSTESİ

[illegible]

SİMGELER ve KISALTMALAR

N	Giriş katman hücre sayısı
M	İçerik katmanı hücre sayısı
A^g	Giriş katmanındaki hücrelerin çıkışı aktivasyonu
A^i	İçerik katmanındaki hücrelerin çıkış aktivasyonu
$\eta(t)$	t . iterasyondaki adım büyüklüğü
$d(t)$	Azaltmanın yapılacağı doğrultuyu veren yön vektörü
δ	Hızlandırma katsayısı
a	Ölçekleme/yayılma katsayısı
b	Bias sabiti
ψ	Dalgacık fonksiyonu
$f(t)$	Dalgacık işareti
μ	Momentum büyüme faktörü
j	Çıkış birimlerinin indisi
y	Gerçek çıkış değeri
y'	İstenen çıkış değeri
d	Çıkış durumu
w	Ağırlık değeri
w_{ij}	ij düğümünün ağırlık değeri
k	Giriş-çıkış çiftleri
n	Görüntüde yer alan piksel sayısını
m	Görüntüde yer alan tüm piksel değerlerinin ortalaması
η	Öğrenme katsayısı
α	Momentum
ε	Kazanç terimi
β	Eğim sabiti
$N(q)$	Histogram sonrası elde edilen yeni görüntü piksel değeri
k	Piksel seviyesi
$c(k)$	k seviyesine kadar olan eski gri değerlerin toplam piksel sayısı
CCD	Charged Coupled Device
NIR	Near Infra-Red
CASIA	Chinese Academy of Science – Institute of Automation
UBIRIS	University of Beira Interior iris veritabanı
YSA	Yapay Sinir Ağları
MLP	Multi Layered Perceptron – Çok Katmanlı Perseptron
MNN	Modular Neural Network – Modüler Sinir Ağı
QP	Quick Propagation – Hızlı yayılım
CGD	Conjugate Gradient Descent – Eşleştirmeli Eğim Azaltımı
LVQ	Learning Vector Quantization – Kuantalamalı Vektör Öğrenme
FAR	False Accept Rate – Yanlış kabul etme oranı
FRR	False Reject Rate – Yanlış reddetme oranı

SOM	Self Organizing Map – Kendi kendine organize olabilen harita
NFL	Nearest Feature Line – En yakın öznitelik çizgisi
DNA	Deoksiribo Nükleik Asit
IBG	International Biometric Group – Uluslararası Biyometrik Grubu
RGB	Red – Green – Blue
ROI	Region of Interest – İlgili Bölge
AAD	Average Absolute Deviation
FCM	Fuzzy C-Means – Bulanık C-Ortalama
OMS	Ortalama Mutlak Sapma
HU	Hamming Uzaklığı
YZ	Yapay Zeka
AIC	Akaike Information Criteria – Akaike Bilgi Kriteri
MSE	Mean Square Error – Ortalama Karesel Hatası
SSE	Sum Square Error – Toplam Karesel Hata
RMS	Root Mean Square – Temel Ortalama Kare
GA	Genetik Algoritmalar

1. GİRİŞ

Çok hızlı bir şekilde değişen ve hayatımızın her alanına giren teknolojik gelişmeler, son yıllarda güvenlik alanında oldukça sık bir şekilde kullanılmaktadır. Özellikle binalar veya bina içerisindeki birimlerin girişlerinde ve askeri tesisler, havaalanları gibi yüksek seviyeli güvenlik gerektiren yerlerde ileri teknoloji ürünü güvenlik sistemleri tercih edilmektedir. Bu tür güvenlik sistemlerine en iyi örnek biyometrik sistemlerdir.

Biyometrik sistemler, el, yüz, parmak, iris, retina ve ses gibi insanın fizyolojik ve davranışsal özelliklerinin güvenlik alanında kullanılması prensibine dayanır (Wildes 1997). Her geçen gün daha fazla kartı yanında bulundurma gerekliliği, daha fazla şifrenin akılda tutulması gibi zorlukları ortadan kaldıran biyometrik sistemler, kartların ve şifrelerin unutulması veya çalınması olasılıklarına karşı mükemmel bir çözümdür.


Bu çalışmada, biyometrik sistemler içerisinde en güvenilirlerden biri olan ve insanın fiziksel bir özelliği olarak güvenlik ve tanıma alanında kullanılan iris tanıma üzerinde durulmuştur. Bu amaçla, mevcut tanıma sistemleri incelenmiş ve başarı oranı yüksek bir iris tanıma sistemi geliştirilmiştir. İris tanıma sistemi genel anlamda 4 aşamadan oluşmaktadır (Wildes 1997, Daugman 1993). Bunlar:

- Göz görüntüsünün alınması;
- Göz görüntüsü içerisinde iris bölgesinin ayrıştırılması;
- İris deseninin özniteliklerinin çıkarılması;
- Karşılaştırma işleminin yapılması.

Göz görüntüsünün alınması işlemi için genellikle CCD (Charge Coupled Device) kameralar kullanılmaktadır. Ancak görüntü elde edilirken bazı zorluklarla karşılaşmaktadır. Bunların başında yetersiz aydınlatmadan kaynaklanan

görüntülerin karanlık olarak algılanması gelmektedir. Karanlık görüntüler tanıma işlemlerinde başarı oranını oldukça düşürmektedir. Aydınlatmada çoğunlukla halojen ampuller kullanılmaktadır. Görüntü alınırken karşılaşılan bir diğer sorun ise iris üzerinde aydınlatma kaynaklarının oluşturduğu ışık yansımalarıdır. Bu yansımalar iris deseninin bozulmasına sebep olmaktadır. Bunun önüne geçebilmek için son yıllarda yakın kızılötesi (Near Infra-Red – NIR) aydınlatmalı kameralar tercih edilmektedir. Bu kameralardan alınan görüntüler oldukça sade, ışık yansıması olmayan görüntülerdir (Bolle 2004).


Tez çalışmasında kullanılan göz görüntüleri iki farklı veritabanından alınmıştır. İlki, Çin Bilim Akademisi Otomasyon Enstitüsü (Chinese Academy of Science – Institute of Automation) tarafından oluşturulan CASIA iris veritabanıdır (NLPR 2007). Bu veritabanında, 102 kişiye ait 714 iris görüntüsü yer almaktadır. Her bir kişiye ait 7 görüntü mevcuttur. Görüntü alınırken kullanılan CCD kamera, NIR aydınlatmalı ve yaklaşık 10-15 cm den görüntü alabilen bir kameradır. Bu cihaz Çin Ulusal Desen Tanıma laboratuvarlarında (National Laboratory of Pattern Recognition, China) geliştirilmiştir. CASIA veritabanında yer alan görüntüler 320*280 piksel boyutlarında gri seviyeli resimlerdir. Şekil 1.1 (a)'da, CASIA veritabanında yer alan normal bir iris görüntüsü örnek olarak gösterilmiştir. Bu veritabanında yer alan bazı görüntülerde göz kapağı ve kirpikler iris bölgesini oldukça fazla kapatmaktadır. Bu tip bir görüntü Şekil 1.1 (b)'de gösterilmiştir.



Şekil 1.1 CASIA iris veritabanında yer alan iris görüntüleri

Diğer iris veritabanı ise İspanya Beira Interior Üniversitesi Enformatik Bölümü (University of Beira Interior) tarafından oluşturulan veritabanıdır (Proenca 2005). Bu veritabanından alınan 120 kişiye ait toplam 600 iris görüntüsü bu tez çalışmasında kullanılmıştır. Bu veritabanında her bir kişiye ait 5 görüntü yer almaktadır. Görüntüler alınırken halojen ampul aydınlatmalı bir CCD kamera (71 mm odaksal uzunluk, 300*300 dpi çözünürlük, 1/30 saniye deklanşör hızı) kullanılmıştır. UBIRIS veritabanında yer alan görüntüler 200*150 piksel boyutlarında gri seviyeli resimlerdir. Şekil 1.2 (a)'da UBIRIS veritabanında yer alan normal bir iris görüntüsü gösterilmiştir.

Bu veritabanında yer alan bazı görüntülerde aydınlatma ve netlik tam olarak yapılamamıştır. Aydınlatması ve netlik ayarı tam olarak yapılmamış örnek görüntüler, sırasıyla Şekil 1.2 (b) ve Şekil 1.2 (c)'de gösterilmiştir.



Şekil 1.2 UBIRIS veritabanında yer alan iris görüntüleri

Genelde kameradan elde edilen göz görüntüleri iris tanıma için direkt olarak kullanılmazlar. Çünkü bu görüntüler, iris bölgesi dışında, gözbebeği, gözakı, alt ve üst kirpikler gibi gürültü olarak nitelendirebileceğimiz kısımları içermektedir. Bu kısımlar tanıma işlemi için gereksizdir ve tanımayı çok karmaşık bir duruma getirebilmektedir. Dolayısıyla bunların görüntüden atılması gereklidir. Bu amaçla, iris tanıma işleminde, öncelikle iris bölgesinin belirlenmesi işlemi yapılmalıdır. Iris bölgesi gözbebeği dış çizgisi ile iris dış çizgisi arasında kalan bölgedir. Bu çizgilerin bulunması amacıyla çalışmada, Hough Dönüşümü ve Canny kenar bulma algoritmaları kullanılmıştır. Bu algoritmalar sayısal görüntü işleme kısmında ayrıntılı olarak anlatılmıştır. Kenar çizgileri bulunduktan sonra Kartezyen – Polar Koordinat

dönüşümü kullanılarak dikdörtgensel halde iris görüntüsü göz resminden alınmıştır. Alınan bu iris görüntüsünün boyutları kullanılan veritabanına göre değişmektedir. Iris görüntüsü CASIA iris veritabanı için 140*70 piksel boyutlarında, UBIRIS iris veritabanı için 80*40 piksel boyutlarında elde edilmiştir. Iris üzerinde yer alan desenlerin daha belirgin hale gelmesi amacıyla görüntüye histogram eşitleme uygulanmıştır.


Iris deseninin göz görüntüsünden ayrıştırılmasının ardından sayısallaştırma işlemi yapılmalıdır. Sayısallaştırma işleminde, iris görüntüsünün öznitelikleri analiz edilerek vektörel bir bilgi oluşturulur. Öznitelik analizi aşaması sistemin en önemli aşamasıdır. Çünkü elde edilecek bilgi karşılaştırma işleminin başarısını doğrudan etkileyecektir. Öznitelik vektörü ne kadar küçük boyutlarda olursa karşılaştırma da o kadar hızlı gerçekleşir. Ancak boyutun azalması, görüntüyü niteleyen bazı özniteliklerin kaybolması anlamına gelmektedir. Dolayısıyla, öznitelik analizi yapılırken iris görüntüsünü en iyi şekilde ifade edebilecek en küçük vektör bulunmaya çalışılmaktadır.

Tez çalışmasında, öznitelik çıkarımı için iki farklı yol izlenmiştir. Birinci yöntemde, görüntüye Gabor filtresi uygulanmış ve ikili (0 ve 1) kodlama şeklinde değişik boyutlarda öznitelik vektörü elde edilmiştir. İkinci yöntemde ise görüntü karesel olarak çeşitli boyutlarda (14*14, 10*10 v.b.) pencereler kullanılarak giriş görüntüsü alt görüntülere bölünmüş ve her bir alt görüntüye ortalama mutlak sapma yöntemi uygulanarak sayısal öznitelik değerleri elde edilmiştir. Alt görüntülerin boyutları farklı olduğundan dolayı elde edilen öznitelik vektörlerinin uzunlukları da farklı olmuştur.

Çalışmanın son aşaması olan karşılaştırma işleminde hem istatistiksel, hem de yapay zekâ yöntemleri uygulanmış ve geliştirilmiş olan sistemin performansı test edilmiştir. İstatistiksel yöntemlerden Hamming uzaklığı yöntemi; yapay zekâ yöntemlerinden yapay sinir ağları (YSA) modeli karşılaştırma aşamasında kullanılmıştır. YSA'nın sınıflandırma problemlerinde sıkça tercih edilen çok katmanlı perseptron (Multi-Layered Perceptron - MLP) sinir ağı modeli, bu modelin geliştirilmiş olan modüler sinir ağı (Modular Neural Network - MNN) ve yinelemeli sinir ağı çeşidi olan Elman ağı modeli iris görüntülerinin sınıflandırılması işleminde

uygulanmıştır. YSA'nın eğitimi aşamasında geriye yayılım yöntemlerinden olan hızlı yayılım (Quick-Propagation – QP) ve eşleştirmeli eğim azaltımı (Conjugate Gradient Descent – CGD) seçilmiştir.

Yukarıda bahsedilen tüm işlem adımları, bir blok şema halinde Şekil 1.3'te gösterilmiştir.



Şekil 1.3 İris tanıma sistemi işlem adımları

YSA'nda eğitim süresinin nispeten uzun olmasından dolayı giriş sayısının azaltılması amacıyla Genetik Algoritmalar uygulanmıştır. Elde edilen yeni girişlerle sınıflandırma işlemi tekrarlanmıştır. Bu uygulamalar sonucunda doğrulama oranının biraz düştüğü gözlenmiştir. Alınan sonuçlar karşılıklı değerlendirilmiş ve yöntemlerin avantaj ve dezavantajları ortaya çıkarılmıştır. Bununla birlikte bu çalışmanın, giriş görüntüsündeki gürültülerden kaynaklanan doğrulama oranının düşmesi problemini ortadan kaldırdığı tespit edilmiştir.

1.1. Çalışmanın Amacı ve Önemi

Son yıllarda birçok alanda kişi tanıma ve kimlik sorgulama işlemleri ile sıkça karşılaşılmaktadır. Özellikle özel ofis girişleri, havaalanı, bankalar gibi yerlerde bu tür kişi tanıma işlemleri çok daha sıkı kontroller altında yapılmaktadır. Önceleri sadece kimlik bilgilerinin sorgulanması, şifre veya pin numarasının istenmesi şeklinde olan bu kontrollerin yeterli güvenlik seviyesinde olmaması kişileri daha güvenilir sistemlerin arayışına itmiştir. İnsanın kendisinin bir kontrol aracı olarak kullanılmasının en güvenilir yol olacağı düşüncesi ile biyometrik sistemler ortaya çıkmıştır. Biyometrik sistemler, iris, parmakizi, yüz, el gibi insanın fizyolojik özelliklerinin tanıma amaçlı olarak kullanılması demektir.

Tez çalışmasında, bir biyometrik özellik olan ve insanın doğumundan ölümüne kadar değişmeyen bir özelliğe sahip iris deseninin yapay zekâ yöntemleri kullanılarak tanımlanması amaçlanmıştır. Bu amaçla, mevcut uygulamalar incelenmiş ve hata oranı en düşük bir kişi doğrulama sistemi oluşturulmaya çalışılmıştır. Yapay zekânın, özellikle tanıma veya sınıflandırma alanında ne denli yüksek performans gösterdiği göz önünde bulundurulduğunda, iris tanıma sistemi içerisinde bu tür bir yaklaşımın değerlendirilmesi, sistemi çok daha güvenilir yapacağı düşünülmüştür.

Bu çalışmada temel olarak aşağıdaki çalışmalar amaçlanmıştır:

- Geleneksel iris tanıma sistemleri incelenerek, bu sistemlerin avantaj ve dezavantajlarının belirlenmesi;
- Kenar bulma algoritmaları kullanılarak giriş görüntüsü içerisinde iris bölgesinin yerinin tespit edilmesi;
- Tespit edilen dairesel iris bölgesinin dairesel halden dikdörtgensel hale getirilmesi;

- İris görüntüsünün görüntü işleme algoritmaları kullanılarak analiz edilmesi ve öznitelik vektörünün elde edilmesi;
- Giriş görüntülerinin tanınması için istatistiksel yöntemlerin uygulanması;
- Giriş görüntülerinin tanınması için yapay sinir ağları yönteminin uygulanması;
- Genetik algoritmalar kullanılarak giriş vektörünün azaltılarak yeniden sınıflandırma yapılması;
- Sonuçların analizi ve değerlendirilmesi.

1.2. Tezin Organizasyonu

Bu tez çalışması giriş, kaynak araştırması, sayısal görüntü işleme, biyometrik sistemler, iris tanıma sistemleri, iris görüntüsünün ön işleminden geçirilmesi, öznitelik çıkarımı, istatistiksel yaklaşımla iris tanıma, yapay sinir ağları ile iris tanıma, sonuçlar ve öneriler ve kaynaklar olmak üzere toplam on bir bölüm ve eklerden oluşmaktadır.

Birinci bölüm giriş bölümü olup konunun genel tanımı yapılmış, çalışmanın amacı ve önemi üzerinde durulmuştur.

İkinci bölümde, konu ile ilgili önceden yapılmış olan benzer çalışmalar hakkında kaynak araştırması yapılmış, bunlar hakkında bilgiler verilmiş ve bu çalışmaların özellikleri belirlenmiştir.

Üçüncü bölümde, çoğunlukla güvenlik uygulamalarında kullanılan ve kişinin kendine has özellikleri ile tanınabilmesini amaçlayan biyometrik sistemler hakkında bilgi verilmiştir. Biyometrik sistemlerin çalışma prensipleri, biyometrik çeşitleri,

biyometrik sistem seçimi, tanımda kullanılan algoritmalar, çoklu biyometrikler, karşılaşılan güçlükler ve yapılan uygulamalar anlatılmıştır.

Dördüncü bölümde, iris tanıma sistemi hakkında detaylı bilgi verilmiştir. Genel anlamda sistemin tanıtımı yapılmış, sistemin işleyişi aşamalarla anlatılmıştır. Ayrıca daha önce gerçekleştirilmiş olan iris tanıma sistemlerinden de bahsedilmiştir.

Beşinci bölümde, iris görüntüsünün ön işlemde geçirilmesi konusu anlatılmıştır. Görüntü içerisinde iris bölgesinin tespiti, görüntünün göz kapağı, kirpik gibi gürültülerden arındırılması işlemleri analiz edilmiştir.

Altıncı bölümde, elde edilen iris bölgesi görüntüsünden öznelik çıkarımı işleminden bahsedilmiştir. Kullanılan yöntemler anlatılmış ve uygulama sonuçları sunulmuştur.

Yedinci bölümde, istatistiksel yöntem kullanılarak iris görüntüsünün tanınması konusu irdelenmiştir. Bu bölümde, Hamming uzaklığı yönteminin sonuçları değerlendirilmiştir.

Sekizinci bölümde, yapay zekâ yöntemleri kısaca analiz edilerek, yapay sinir ağları yöntemi ayrıntılı olarak anlatılmıştır. Sınıflandırma problemlerinde sıkça tercih edilen çok katmanlı idrak, modüler sinir ağı ve Elman sinir ağı modellerinden bahsedilmiş, bu yöntemler kullanılarak gerçekleştirilen iris tanıma işlemi ve uygulama sonuçları verilmiştir. Ayrıca genetik algoritmalar ile iris verisi azaltılarak yeniden tanıma gerçekleştirilmiş ve uygulama sonuçları karşılaştırılmıştır.

Dokuzuncu bölümde, çalışmanın sonuçları üzerine genel bir değerlendirme yapılmıştır. Bu bölümde ayrıca çalışma ile ilgili öneriler yer almaktadır.

Onuncu bölümde tez çalışmasından alınan sonuçlar tartışılmıştır.

On birinci bölümde çalışma ile ilgili kaynaklar verilmiştir.

Ekler kısmında uygulama yazılımlarının ekran görüntüleri açıklanmıştır.

2. KAYNAK ARAŞTIRMASI

İris tanıma sistemlerini tanıma amaçlı olarak kullanılabileceği düşüncesini, 19 yüzyılın başlarında ilk ortaya atan kişi Fransız göz doktoru Alphonse Bertillon'dur. Ancak bu düşünce onun zamanında uygulamaya geçirilememiştir. Daha sonra, 1987 yılında Alan Safir ve Leonard Flom irisin biyometrik sistemde kullanılması düşüncesinin patentini almışlardır. Kişisel tanımlamada iris tanıma sisteminin ilk kullanımına Paris ceza sisteminde rastlanmıştır. Daha sonraları, Flom ve Safir tarafından otomatik iris tanıma fikri ortaya atılmıştır. Ancak, bu kişilerin çalışan bir sistem tasarladıkları görülmemiştir. Gerçek anlamda ilk otomatik iris tanıma sistemi Kaliforniya Los Alamos Ulusal laboratuvarında geliştirilmiştir. Bunu müteakiben iki araştırma grubu prototip bir iris tanıma sistemi geliştirmiş ve sistemi çalıştırıp test etmişlerdir. Bu sistemde, yüzlerce iris görüntüsü içeren farklı veritabanları üzerinde çalışmalar yapılmış ve umut verici sonuçlar elde edilmiştir. 1989 yılında John Daugman (Cambridge Üniversitesi) öncülüğündeki bir grup, iris tanıma sistemi için bir tanıma algoritması geliştirmişlerdir. 1992'de ilk başarılı uygulamalarını yapmışlar ve 1999 yılında bu sistemin patentini almıştır. Daha sonra bu sistem LG firması tarafından satın alınmış ve iris tanıma cihazlarında bu sistemi kullanmışlardır. Halen en başarılı uygulama sonuçlarını Daugman tarafından geliştirilen algoritma vermektedir (Tablo 2.1).

Daugman (1985, 1988, 1993, 1994, 2001, 2003), iris tanıma konusunda ilk uygulamaları gerçekleştirmiştir. Bu çalışmalarda, iris bölgesinin belirlenmesi amacıyla Hough dönüşümü ve bu dönüşümün bir çeşidi olarak bilinen integro-diferansiyel operatör kullanılmıştır. Alt ve üst kirpik yaylarının tespiti için parabolik Hough dönüşümü algoritması kullanılmıştır. Öznitelik çıkarımı gerçekleştirilirken iki boyutlu Gabor dalgacık dönüşümü uygulanmıştır. Bu uygulama sonucunda "iriscode" diye adlandırılan 2048 bit (256 byte) uzunluğunda bir iris vektörü elde edilmiştir. Karşılaştırma aşamasında ise XOR operatörü ile birlikte Hamming

uzaklığı yöntemi kullanılmıştır. Uygulamada alınan doğrulama oranları Tablo 2.1’de gösterilmiştir.

Wildes (1997), iris lokalizasyonu için kenar belirleme ve Hough dönüşümü yöntemlerini kullanmıştır. Öznitelik çıkarımı aşamasında, Laplas piramidi olarak adlandırılan ve görüntüye önce Gauss filtresi uygulanması, daha sonra yeni görüntünün laplas fonksiyonunun alınması şeklinde geliştirilen algoritmayı uygulamıştır. Karşılaştırma aşamasında öklid uzaklığı yöntemini kullanmıştır. Çalışmasında doğrulama oranları ile ilgili bilgi verilmemiştir.

Boles ve ark. (1998), irisin yerini belirlenmek için kenar bulma algoritmaları kullanmışlardır. Öznitelik çıkarımında sıfır geçişli dalgacık dönüşümü uygulamışlardır. Karşılaştırma için benzersizlik fonksiyonu kullanan Boles ve ark., yayınladıkları çalışmalarında, 4 iris görüntüsünün tümünün doğru olarak tanındığını belirtmişlerdir.

Sanchez-Reillo ve ark. (1999, 2000, 2002), histogram analizleri kullanarak irisin kenar bilgilerini bulmuşlardır. Öznitelik çıkarımı için sıfır geçişli dalgacık dönüşümü ve Gabor filtresi kullanmışlardır. Karşılaştırma aşamasında ise Hamming uzaklığı yöntemini uygulamışlardır. 2000 ve 2002 de yaptıkları çalışmalarda aldıkları doğrulama sonuçları Tablo 2.1’de verilmiştir.

Tisse ve ark. (2002), irisin yerinin belirlenmesi amacıyla Hough dönüşümü kullanmışlardır. Öznitelik çıkarımı aşamasında iki boyutlu Hilbert dönüşümü ve karşılaştırma aşamasında Hamming uzaklığı yöntemini uygulamışlardır. Yaptıkları uygulamada, 300 iris görüntüsü için % 1 (FAR – yanlış kabul etme) – % 3 (FRR – yanlış reddetme) sonuçlarını almışlardır.

Lim ve ark. (2001), kenar bulma algoritmaları kullanarak irisin iç ve dış kenarlarını bulmuşlardır. Daha sonra öznitelik çıkarımı aşamasında Haar dalgacık dönüşümü kullanan Lim ve ark., karşılaştırma aşamasında yarışmalı (competitive) öğrenme algoritmasına (learning vector quantization - LVQ) dayalı yapay sinir ağlarını kullanmışlardır. 200 kişi üzerinde yaptıkları çalışmada % 94,4 doğru sınıflandırma gerçekleştirmişlerdir.

Li Ma ve ark. (2002a, 2002b), iris lokalizasyonunda kenar bulma algoritmaları ve Hough dönüşümü kullanmışlardır. Öznitelik çıkarımı için Gabor filtresi ile birlikte ortalama mutlak sapma uygulamışlardır. Karşılaştırma aşamasında ise en yakın özellik çizgisi (nearest feature line – NFL) olarak adlandırdıkları bir algoritma ile sınıflandırma gerçekleştirmişlerdir. Bu araştırmacıların bir diğer çalışmalarında ise karşılaştırma aşamasında ağırlıklı öklid uzaklığı yöntemini uygulamışlardır. Aldıkları uygulama sonuçları Tablo 2.1’de verilmiştir.

Huang ve ark. (2002), iris lokalizasyonu aşamasında integro-diferansiyel operatör kullanmışlardır. Öznitelik çıkarımı için temel bileşen analizi yönteminin geliştirilmiş versiyonu olan bağımsız bileşen analizi yöntemini kullanmışlardır. Karşılaştırma aşamasında öklid uzaklığı yöntemini uygulamışlardır. 10 kişi üzerinde yaptıkları uygulamada % 100 doğru tanıma elde etmişlerdir.

Alim ve ark. (2002), irisin yerinin belirlenmesi amacıyla Hough dönüşümü uygulamışlardır. Öznitelik çıkarımı aşamasında iki boyutlu Gabor filtresi kullanan Alim ve ark., karşılaştırma aşamasında geri dönüşümlü çok katmanlı perseptron yapay sinir ağı kullanmışlardır. 159 kişi üzerinde yaptıkları çalışmada, % 96,1 doğru sınıflandırma oranı ile tanıma gerçekleştirmişlerdir.

Liam ve ark. (2002), kenar bulma algoritmaları kullanarak irisin iç ve dış kenar çizgilerini belirlemişlerdir. Öznitelik vektörünün çıkarımı için kullanılan algoritma tam olarak açıklanmamıştır. Karşılaştırma aşamasında ise yapay zeka yöntemlerinden SOM (Kendi kendine organize olabilen harita – Self Organizing Map) modelini kullanmışlardır. Yaptıkları çalışmada 30 kişiden alınan iris görüntülerini kullanmışlar ve % 83 oranında doğru sınıflandırma almışlardır. Bu oran oldukça düşüktür.

Yu ve ark. (2002), karşılaştırma aşamasında fraksiyonlu fourier dönüşümü kullanarak iki iris bilgisinin benzerliğine bakmıştır. Yapılan uygulama sonuçları Tablo 2.1’de verilmiştir.

Szewczyk ve ark. (2002), karşılaştırma aşamasında çok katmanlı perseptron sinir ağı modeli kullanarak bir iris tanıma gerçekleştirmiştir. Kullandığı model

sınıflandırma yerine sadece karşılaştırma yapmaktadır. Bir başka deyişle, gelen iris görüntüsünün veritabanında herhangi bir iris görüntüsü ile eşleşip eşleşmediğine bakmıştır.

Liu ve ark. (2003), temel iris yakalama sistemi ve hızlı kenar bulma algoritması içeren bir iris tanıma sistemi gerçekleştirmiştir. Sistemin hızı ile bilgiler verilmiştir ancak doğrulama oranı ile ilgili bir bilgi verilmemiştir.

Mira ve ark. (2003), histogram analizi ve kenar bulma algoritmaları kullanarak irisin yerini belirlemişlerdir. Daha sonra öznitelik analizi için morfolojik işlemler uygulamışlardır. Bu işlemler eşikleme üzerine kurulmuştur. Eşikleme algoritmaları sonucunda iris görüntüsü içerisinde eşikğin üzerinde kalan kısımlar iris desenini oluşturmaktadır. Çeşitli görüntü işleme filtreleri kullanarak desen içerisinde hat sonu ve çizgi uzunluklarını bulan Mira ve ark. bu bilgileri öznitelik vektörü oluşturmak için kullanmışlardır. Özniteliklerin benzerlik fonksiyonuna bakarak karşılaştırma gerçekleştirmişlerdir.

Chen ve ark. (2003), öznitelik analizi için tek boyutlu dalgacık dönüşümü yöntemini uygulamışlardır. Karşılaştırma aşamasında k-ortalaması ve sinir ağları yöntemlerini kullanmışlardır. Kullanılan sinir ağı modeli ile ilgili bir bilgi verilmemiştir. Uygulama sonuçlarına göre, % 3.67 (FAR) – % 8.82 (FRR) doğrulama oranları bulmuşlardır.

Noh ve ark. (2003), öznitelik çıkarımı için çok kanallı Gabor filtresi ve dalgacık dönüşümü kullanmışlardır. Karşılaştırma aşamasında ise ağırlıklı öklid uzaklığı yöntemini uygulamışlardır. 16 kişiden alınan iris görüntüleri üzerinde gerçekleştirdikleri uygulamada % 93,8 doğrulama elde etmişlerdir.

Masek (2003), yaptığı çalışmada iki farklı iris veritabanı ile iris tanıma gerçekleştirmiştir. Öznitelik çıkarımı için Gabor dalgacık dönüşümü, karşılaştırma aşamasında Hamming uzaklığı yöntemini uygulamıştır. Aldığı uygulama sonuçları Tablo 2.1’de gösterilmiştir.

Sun ve ark. (2005) iki farklı sınıflandırma algoritmasını iris verileri üzerinde denemiştir. Bu algoritmalar yerel öznitelik tabanlı sınıflandırma (LFC – Local

feature based classfier) ve genel öznitelik tabanlı sınıflandırma (GFC – Global feature based classifier) olarak alınmıştır. Yapılan testlere göre, iyi kalitede alınmış iris görüntüleri için önce LFC sonra GFC uygulanması daha iyi sonuç vermektedir. Buna karşılık kötü kalitede alınmış iris görüntüleri için önce GFC ardından LFC uygulanması daha iyi sonuç vermiştir. Yaptıkları uygulamadan aldıkları doğrulama sonuçları Tablo 2.1’de verilmiştir.

Miyazawa ve ark. (2006), karşılaştırma aşamasında faz tabanlı görüntü karşılaştırma algoritmasını kullanmışlardır. 108 kişiye ait iris görüntülerinin kullanıldığı uygulama sonuçlarına göre % 0.0032 (FAR / FRR) doğrulama oranları elde etmişlerdir.

El-Bakry (2001), hızlı modüler sinir ağı kullanarak bir resim içerisinde iris görüntüsü olup olmadığına bakmıştır.

Kong ve ark. (2001), iris lokalizasyonunun performansını artırmak amacıyla görüntüde ışık yansımaları ve kirpik gürültülerinin tespitini gerçekleştiren bir algoritma önermiştir.

Petrova (2002), biyometrik sistemlerde giriş ve doğrulama için biyometrik ölçümleri analiz etmiş ve sistemlerin güvenilirliği, kullanıcıya uygunluğu gibi parametreleri ortaya koymuştur.

Ko (2005), iris, parmakizi ve yüz öznitelik vektörlerinin bir arada kullanıldığı bir çoklu-biyometrik sistemi gerçekleştirmiştir. Biyometrik özelliklerin bir arada kullanılmasının sistemin başarı oranını yükselttiğini aldığı deneysel sonuçlarla ifade etmiştir.

Vatsa ve ark. (2004), 4 farklı iris tanıma algoritmasını karşılaştıran bir çalışma gerçekleştirmiştir. Bu algoritmalar Sanchez-Reillo ve ark., Li Ma ve ark., Tisse ve ark. ile Daugman ve ark. aittir. Aldığı deneysel sonuçlara göre Daugman (% 99,9) en güvenilir sisteme sahiptir. Daugman’ı sırasıyla Li Ma ve ark. (% 98), Sanchez-Reillo ve ark. (% 97,89) ve Tisse ve ark. (% 89,37) izlemektedir.

Aşağıdaki tabloda (Tablo 2.1) literatürde yer alan iris tanıma sistemlerinin tanıma performanslarına ilişkin bilgi verilmiştir.

Tablo 2.1 İris tanıma sistemleri ve tanıma performans sonuçları (FAR – Yanlış kabul etme oranı / FRR – Yanlış reddetme oranı)

Araştırmacı	Yıl	Tanıma Yöntemi	Veritabanı	Performans
Daugman	1993 2001 2003	Hamming Uzak. Hamming Uzak. Hamming Uzak.	592 iris gör. 2150 iris gör. 4258 iris gör.	<0.0001 (FAR) - <0.0001 (FRR) <0.0001(FAR) - <0.0001(FRR) <0.0001(FAR) - <0.0001(FRR)
Boles ve ark.	1998	Benzersizlik fonk.	4 iris gör.	% 100
Reillo ve ark.	2000 2002	Hamming Uzak. Hamming Uzak. Öklid Uzaklığı	10 kişi 10 kişi	% 98.3 % 98.7 % 96.7
Tisse ve ark.	2002	Hamming Uzak.	300 iris gör.	% 1 (FAR) – % 3 (FRR)
Lim ve ark.	2001	YSA (LVQ)	200 kişi	% 94.4 (Doğru sınıflandırma)
Li Ma ve ark.	2002	NFL Öklid Uzaklığı	109 kişi 25 kişi	% 0.1 (FAR) – % 0.83 (FRR) % 99.09
Huang ve ark.	2002	Öklid Uzaklığı	10 kişi	% 100 (Doğru sınıflandırma)
Liam ve ark.	2002	YSA (SOM)	30 kişi	% 83 (Doğru sınıflandırma)
Alim ve ark.	2002	YSA (MLP)	159 kişi	% 96.1 (Doğru sınıflandırma)
Yu ve ark.	2002	Fourier Dönüşümü	10 kişi	% 0.26 (FAR) – % 1.79 (FRR)
Chen ve ark.	2003	K-Means	40 kişi	% 3.67 (FAR) – % 8.82 (FRR)
Noh ve ark.	2003	Öklid Uzaklığı	16 kişi	% 93.8 (Doğru sınıflandırma)
Masek	2003	Hamming Uzak.	756 iris gör. 120 iris gör.	% 0.005 (FAR) – % 0.238 (FRR) % 0 (FAR) – % 0 (FRR)
Sun ve ark.	2005	Hamming Uzak.	306 kişi	% 0.01 (FAR) – % 0.01 (FRR)
Miyazawa ve ark.	2006	Faz tabanlı karş. (Phase Based)	108 kişi	% 0.0032 (FAR / FRR)

Kaynak araştırmasına göre, iris tanıma üzerine yapılan çalışmaların büyük bir kısmında istatistiksel karşılaştırma yöntemleri tercih edilmiştir. Son yıllarda yapılan çalışmalar ise yapay zeka yöntemlerine yönelik çalışmalar olmaktadır. Bunun nedeni, istatistiksel karşılaştırma yöntemlerinin bazı dezavantajlarının olmasından kaynaklanmaktadır. İstatistiksel karşılaştırma yönteminde görüntülerin birebir karşılaştırılması söz konusudur. Karşılaştırılan görüntülerden herhangi birisinin yüksek gürültü oranına (görüntü net olarak alınmamış olması, kirpik veya göz kapağının iris bölgesi üzerine gelmiş olması, iris üzerinde ışık yansımalarının olması v.b.) sahip olması karşılaştırmanın yanlış sonuç vermesine sebep olmaktadır.

İris tanıma sistemi içerisinde, görüntünün ön işleminden geçirilmesi ve öznetelik çıkarımı aşamalarında çeşitli yöntemler uygulanmıştır. İris bölgesinin

tespitinde Hough dönüşümü oldukça fazla tercih edilmiştir. Öznitelik çıkarımında ise çok farklı yöntemler kullanılmıştır. Karşılaştırma aşamasında, Hamming uzaklığı yöntemi birebir karşılaştırma için en iyi sonuçları vermiştir. Bu yöntemi tercih edenler içerisinde en yüksek performansı Daugman elde etmiştir. Ancak, bu yöntemde karşılaştırılan görüntülerin çok fazla gürültü içermesi performansı olumsuz etkilediği belirtilmiştir. Bu problemi yapay zeka yöntemleri ile aşmak mümkün olmaktadır. Yapay zeka yöntemlerinden alınan sonuçlar incelendiğinde, en yüksek performans % 96,1 ile Alim ve ark. ait olduğu gözlemlenmiştir. Bu oran bazı durumlarda yetersiz kalmaktadır. Bundan dolayı, yapay zeka yöntemleri kullanılarak gerçekleştirilen iris tanıma sisteminin daha yüksek performans elde edilmesi çalışmaları günümüzde güncelliğini korumaktadır. Bu çalışmada, iris tanıma problemine bu açıdan yaklaşmakta ve elde edilen sonuçlar ile literatürde karşılaşılan doğrulama oranlarından daha yüksek bir doğrulama oranları alındığı gözlemlenmektedir.

3. BİYOMETRİK SİSTEMLER

Biyometrik kelimesi ilk anda insana “yeni bir ileri teknoloji” hissi uyandırır da aslında uzun süredir kullanılan oldukça basit bir tekniktir. Biyometrik insan tanımlamadır. Daha teknik bir ifadeyle, biyometrik kişilerin kendilerine has fizyolojik özelliklerini ölçen ve bu özellikleri kullanarak teşhis ve doğrulama uygulamalarında kullanılan genel bir tekniktir (Wildes 1997).

Biyometrik sistemler, tıpkı insan beyni gibi karşısındakini tanıyıp ayırt edebilmektedir. Kart ve şifre gibi kaybolabilen, çalınabilen veya unutulabilen tanıtıcılar yerine direkt olarak insanın kendisinin kullanılması sistemi daha güvenilir ve daha kullanışlı hale getirmektedir. Biyometrik sistemlerde kullanılan cihazlar her insanda farklı olan fiziksel özellikleri analiz ederek şifre kullanılmaksızın veritabanı, bankalar ve bilgisayar sistemleri gibi ortamlara giriş için kimlik doğrulaması yaparlar.

Bu bölümde literatürde yer alan ve insan tanıma amacıyla kullanılan biyometrik çeşitleri, biyometrik sistemin seçiminde kullanılan etkenler, çoklu-biyometrikler ve biyometrik sistemlerin karşılaştırılmalı performans değerlendirmeleri verilmiştir.

3.1 Biyometrik Teknikler

Günümüzde çok çeşitli biyometrik tanıma teknikler kullanılmaktadır. Bunlar içerisinde en sık uygulananlar yüz tanıma, parmakizi tanıma, iris tanıma, el geometrisi tanıma, ses tanıma, el yazısı ve imza tanıma olarak sıralanabilir. Ayrıca retina tanıma, kulak şekli tanıma, DNA tanıma, koku tanıma, vücut ısısı (termogram)

tanıma, yürüyüş tanıma ve dudak hareketi tanıma teknikleri de uygulamada az da olsa biyometrik tanıma uygulamalarında kullanılmışlardır.

Biyometrik alanında kullanılan genel fizyolojik ve davranışsal özellikler aşağıdaki tabloda gösterilmiştir (Bolle ve ark. 2004).


Tablo 3.1 Biyometrik tanımda kullanılan özellikler

Sık Kullanılan Biyometrikler		Az Sıklıkta Kullanılan Biyometrikler	
<i>Fizyolojik</i>	<i>Davranışsal</i>	<i>Fizyolojik</i>	<i>Davranışsal</i>
El Geometrisi	Ses	Retina	Yürüyüş
Yüz	El Yazısı ve İmza	Kulak Şekli	Dudak Hareketi
Parmakizi		DNA	
İris		Termogram (Isı)	

Biyometrik teknikler içerisinde en popüler olanı parmakizi (fingerprint) tanımadır (Bolle ve ark. 2004). Bu teknikte parmak ucunda bulunan parmakizi, bir tarayıcı yardımıyla taranarak analiz edilmektedir. İlk geliştirildiğinde çok uzun zaman alan bu iş, bugünkü ileri teknolojik cihazlarla çok kısa sürelerde tamamlanmaktadır (Jain ve ark. 1999a).


Bununla birlikte yüz ve iris tanıma da son yıllarda üzerinde çok çalışılan biyometrik çeşidi durumuna gelmiştir. Biyometrik sistemlerin çalışma prensipleri hepsinde aynıdır. İlk olarak tarama yapılır. Tarama sonucunda elde edilen bilgiler görüntü işleme yöntemleri ile analiz edilir ve öznitelikleri çıkarılır. Öznitelikler sayısal ortamda kaydedilir. Gerekirse güvenlik amacıyla bu bilgiler şifrelenerek veritabanında tutulur. Sisteme giriş yapacak kişinin bilgileri ile veritabanına önceden kaydedilmiş olan bilgiler karşılaştırılarak giriş onaylanır veya reddedilir.

Genel anlamda bir biyometrik sistemin aşamaları Şekil 3.1 de gösterilmiştir (Bolle ve ark. 2004).



Şekil 3.1. Biyometrik sistemin çalışma prensibi

Biyometrik tanıma sistemlerinde karşılaştırma işlemi iki temel amaç için yapılır. Teşhis veya tanıma (identification) ve doğrulama (authentication or verification) (Bolle ve ark. 2004). Teşhis veya tanıma yönteminde sisteme kişinin bilgileri girilir ve sistem, veritabanında önceden kaydedilmiş kişi bilgilerini analiz ederek kişinin kim olduğunu teşhis eder. Doğrulama işleminde ise kişi sisteme kim olduğunu söyler (ID numarası, kart veya şifre ile) ve sistem kişinin gerçekten o kişi olup olmadığını kayıtları inceleyerek bulmaya çalışır. Bir başka deyişle teşhis veya tanıma işleminde birebir karşılaştırma yapılır ve sistem “senin kim olduğunu biliyor muyum?” sorusuna cevap arar. Doğrulama işleminde ise bire-birden çok karşılaştırma yapılıyor ve sistem “Sen gerçekten iddia ettiğin kişi misin?” sorusuna cevap arar. Şekil 3.2’de bu iki çeşit karşılaştırma işlemi gösterilmiştir.



Şekil 3.2. Biyometrik tanıma sisteminin genel yapısı

Havaalanı, askeri bölgeler, hastaneler, şirket binaları v.b. yerlerin girişinde gerekli olan güvenlik sistemi, biyometrik sistemler kullanılarak en üst seviyede sağlanmış olur. Çoğu binanın girişinde veya bir internet sitesinde anahtar, pin numarası veya şifre gibi çalınması, kaybolması, unutulması veya taklit edilmesi kolay yöntemler kullanılmaktadır. Ancak bu tür sistemlerin güvenlik seviyesi asla bir biyometrik sisteminki kadar olmamaktadır. Tablo 3.2’de giriş için kullanılan çeşitli yöntemlerin pozitif ve negatif yönleri gösterilmiştir (Bolle ve ark. 2004).

Tablo 3.2 Giriş izni gereken yerler için kullanılan yöntemler

Yöntem	Örnekleri	Özellikleri
Sahip olduklarınız	Kullanıcı ID si, Akıllı kart, Anahtar.	Paylaşılabilir, Çoğaltılabilir, Çalınabilir veya kaybolabilir.
Bildikleriniz	Şifre, PIN numarası, Kişisel bilgiler.	Paylaşılabilir, Tahmin edilebilir, Unutulabilir.
Hem sahip olup hem bildikleriniz	ID + Şifre, Akıllı kart + PIN	Paylaşılabilir, Kırılabilir.
Kişiye has fizyolojik veya davranışsal özellikler	Parmakizi, Yüz, İris v.b.	Paylaşılamaz, Taklit edilmesi çok güç, Çalınamaz veya kaybolamaz.

Biyometrik sistemler kullanılan metoda göre belirli bazı parametreleri analiz ederler. Bu parametrelerin sayısı taranacak fiziksel özelliğe göre değişir. Örneğin bir parmakizi için dikkat edilecek parametre sayısı 100 kadardır. İris için bu sayı çok daha fazla (250 ve üzeri) olmaktadır (Wildes 1997). Ayrıca sistemde kullanılacak yönteme ve oluşturulan algoritmaya göre de bu sayı değişir. Çok fazla parametre olan sistemler çok daha fazla güvenli olmaktadır. Ancak parametre sayısı arttıkça işlem süresi uzayacaktır. İşlem süresi ne kadar kısalsa güvenilirlik o kadar azalacaktır.

3.2 Biyometrik Sistemin Seçimi

Bir biyometrik sistem seçilmeden önce sistemin gereksinimleri dikkatli bir şekilde değerlendirilmelidir. Bu gereksinimler önem sırasına göre aşağıda listelenmiştir (Bolle ve ark. 2004):

- Gerekli güvenlik seviyesi
- Doğruluk
- Maliyet ve işlem zamanı
- Kullanıcıya uygunluk

Kişisel bilgisayar kullanılmayan sistemlerde genellikle ses ve imza tanıma teknikleri tercih edilmektedir. Ancak ses ve imza tanıma teknikleri, birçok kişisel bilgisayar ve ağ kullanıcı doğrulaması için iyi bir teknik olarak görülmemektedir. Fiziksel özelliklere göre çözümler sunan biyometrik teknikler daha kesin sonuç verir, bundan dolayı daha yüksek bir güvenlik seviyesine sahiptir.

Retinal tarama ve iris tanıma sistemleri, kişisel tanımlamanın en yüksek doğrulukta yapıldığı yollardan ikisidir. Ancak, bunların her ikisi de uygulama aşamasında çok fazla maliyetlidir ve çok fazla güvenlik gerektirmeyen sistemlerde bu sistemlerin kullanılması düşünülmemelidir. El, yüz ve parmakizi doğrulama teknikleri, daha az maliyetli donanımlara sahip tekniklerdir ve bir çok uygulamada yeterli doğrulama sunar. Kaza sonucu meydana gelen kesikler, çizikler, kirlenme, yara izleri ve yaşlanma gibi fiziksel değişiklikler biyometrik doğrulama tekniklerinden bazıları için sonucu etkileyebilmektedir. Bu yüzden, biyometrik sistemde kullanılan veritabanları, bu tür problemleri yok etmek için güncellenmelidir.

Bir biyometrik sistem tasarlanırken, sistemin maliyetini ve işlem zamanını belirli kriterlere uygun olarak değerlendiren bir uzmanla çalışılması, en uygun sistemi belirlemek ve gerçekleştirmek için gereklidir. Bu kriterler:

- Kişisel bilgisayar uyumlu donanım ve yazılımın araştırılması, satın alınması ve kurulması.
- Biyometrik görüntü yakalama donanımının belirlenmesi (okuyucular, kameralar, tarayıcılar v.b.) ve bu donanıma uygun yazılımın seçilmesi.
- Sistem için gerekli donanım ve yazılımı varolan ortamla bütünleştirmek için gerekli zamanın belirlenmesi.
- Kullanıcılara ait tanıma verilerinin bir veritabanında biriktirilmesi ve korunması.
- Gerektiğinde veritabanının güncellenmesi.

Kullanıcılar, parmakizi, yüz veya el tanınması gibi biyometrik teknikleri genellikle daha az zorlayıcı bulmaktadırlar. Ancak bazı kullanıcılar kendi parmak izlerinin bir veritabanında kayıtlı olmasından dolayı rahatsızlık duyabilirler. Sistem tasarlanırken, sistem çalışanlarına, seçilen biyometrik teknikle ilgili bilgi ve eğitim verilmelidir. Böylece sistem uygulanmadan önce sistem hakkında gerekli bilgileri önceden bilme şansına sahip olacaklardır.

3.3 Biyometrik Çeşitleri

Biyometrik sistemler kullanılan biyometrik özelliğe değişiklik arz etmektedir. Biyometrik özellikler iris, yüz, parmakizi, el geometrisi, ses, el yazısı ve imza, retina, kulak şekli, DNA, vücut ısısı, yürüyüş, dudak hareketi şeklinde sıralanabilir. Bu bölümde uygulama imkanı bulmuş biyometrik sistemlerden bahsedilecektir.

3.3.1 Yüz tanıma

Yüz tanıma sistemleri bir vesikalık fotoğraf incelemek yerine yüzde bulunan yaklaşık 50 kadar noktayı analiz eder. Yüz karakteristiği tanımlanırken göz çukurlarının saptanması, elmacık kemiğini çevreleyen bölgelerin taranması, ağız kenarlarının belirlenmesi, kulak memesinin analizi gibi çeşitli metodlar kullanılır (Hong ve Jain 1998). Birçok yüz tanıma sisteminde saç stili, saçın uzunluğu veya kısalığı gibi belirleyicilere dikkat edilmez. Örnek imaj oluşturulurken en genel yöntem, kişinin kamera karşısında sabit dururken çeşitli açılardan yüzün görüntülerinin alınmasıdır. Bunun yanı sıra, kızılötesi algılayıcılarla da yüzün farklı açılardan görüntüleri alınabilir. Alınan görüntü işlenerek daha önce alınmış olan görüntü bilgisiyle karşılaştırılır. Görüntünün öznitelikleri çıkarılırken göz çukuru, burun, kulak gibi organların konumuna, bunlar arasındaki çapraz ilişkilere ve yüzün genel durumuna dikkat edilir. Yüz tanıma sistemleri fiziksel bir temas gerektirmediğinden daha çok tercih edilirler. Ancak yüz tanımlama sistemleri uygulamalarda sınırlı başarı sağlamışlardır. Çünkü bıyık gelişimi, kilo alma-verme, ikizinin olması gibi bazı tanıma problemleri yüz tanıma sistemlerinde çok sık karşılaşılan durumlardır (Jain ve ark. 1999).

3.3.2 Parmakizi tanıma

Parmakizi tanıma sistemleri günümüzde en yaygın kullanılan biyometrik tanıma sistemidir. Oldukça uzun bir geçmişe sahip olan bu biyometrik çeşidi 20. yüzyılın başlarında özellikle kriminal uygulamalarda tercih edilmiştir. Parmakizi taranırken çoğunlukla optik algılayıcılar kullanılmaktadır. Ancak son yıllarda teknolojiye gelişmelerle birlikte termal ve kapasitif ölçüm yapan tarayıcı cihazlar kullanılmaya başlanmıştır. Optik tarayıcılar bir ışık kaynağından gönderilen ışınların tarayıcı yüzey üzerine yerleştirilmiş parmakta bulunan çukurlar ve çıkıntılara göre

yansıyarak CCD algılayıcılara gönderilmesi prensibine göre çalışır. Diğer tip tarayıcılar ise yalnızca parmaktaki izleri taramakla kalmaz aynı zamanda parmaktaki statik etkileri ölçerek taranan parmağın canlı bir parmak olup olmadığını tarar (Ingilis ve ark. 1998, Lee ve ark. 1999, Dickinson ve ark. 2000). Termal tarayıcılar ise parmakta bulunan girinti ve çıkıntıların arasındaki ısı farklılıklarını tespit ederek parmakizini oluşturur. Bir parmak izindeki tüm izler dikkate alınmaz. Bunun yerine izdeki bazı özel noktalar; bunlar, girinti ve çıkıntı arası uzaklıklar, hat sonları, çatallaşmalar, bazı kesişim bölgeleri v.b. işlenir ve daha sonra çeşitli görüntü işleme yöntemleriyle sayısal hale getirilir ve veritabanına kaydedilir. Parmakizi tanıma sistemleri kullanım kolaylığı, düşük fiyatı ve küçük ebatları nedeniyle ev, ofis gibi yerlerde daha çok tercih edilirler. Ancak tarama sırasında optik tarayıcıyla fiziksel temasın olması, parmağın kirli, yağlı veya ıslak olması gibi görüntü kalitesini düşürebilecek etkenlerin bulunması, çabuk kopyalanabilir olması ve aşırı sürtünmeden izlerin bozulması gibi faktörler parmakizi tanıma sistemlerini diğerlerinden daha az güvenli yapmaktadır (Uludağ ve ark. 2001).

3.3.3 El geometrisi

El geometrisi aynı zamanda el taraması olarak da bilinir. Bu sistemde el üç boyutlu olarak taranarak elin ve parmakların fiziksel karakteristikleri analiz edilir. Tarama sırasında parmakların uzunluğu ve genişliği, birleşme noktaları arasındaki uzaklıklar, parmaklardaki oynak yerlerinin geometrisi gibi noktalara dikkat edilir (Jain ve ark. 1999b). Bazı sistemlerde yalnızca üç parmak (baş, orta ve işaret parmağı) taranır. Bazılarında ise doksandan fazla ölçüm yapılır. El geometrisi ile çalışan biyometrik sistemler uygulaması oldukça kolay sistemlerdir. Tarayıcı cihaz olarak normal bir optik algılayıcı kamera kullanılabilir. El geometrisi biyometrik sistemleri parmakizi, yüz ve iris tanıma sistemleri kadar hassas ve güvenilir değildir. Veritabanında tutulan bilgiler, diğer biyometrik sistemlere oranla daha az yer kapladığından kullanıcı sayısının fazla olduğu sistemlerde daha çok tercih edilmektedir.

3.3.4 Ses tanıma

Ses tanıma, bazı kaynaklarda konuşma tanıma olarak da bilinir (Campbell 1999). Biyometrik sistemler içerisinde oldukça sık kullanılan bir davranışsal tanıma şeklidir. Diğer biyometrik sistemlere göre çok daha kolay uygulanır. Günlük yaşantımızda sesin ne kadar çok kullanıldığı düşünüldüğünde ilginç bir biyometrik yöntem olarak karşımıza çıkan ses tanıma teknolojisi güvenilirlik açısından çok tercih edilen bir teknoloji değildir. Buna rağmen insan sesi davranışsaldır ve bu bile tek başına belirleyici bir unsur olmaktadır. Sistem kişilerin seslerine ait akustik seslerin kaydedilip dijital ortama dönüştürür. Kullanıcı önce sistemin önceden belirlediği birkaç sözcükten oluşan metni okuyarak sesini sisteme tanıtır. Kaydedilen ses spektral analizler kullanılarak dijitalleştirilir. Kullanıcı daha sonra aynı metni kullanarak sisteme giriş yapar. Bazı ses tanıma sistemlerinde ise önceden belirlenmiş bir metin kullanılmaz. Bu tür sistemlerde kişinin ses görüntüsüne dikkat edilir. Diğer bir deyişle o kişiye ait ses frekans bilgileri kullanılır. Bu teknikte ses frekansları üç boyutlu görüntüleri oluşturmakta ve sesin en küçük birimleri, özel bir takım biçimlerde karakterize edilmektedir (Furui 1997). Ses tanıma sistemleri telefon üzerinden bir sisteme ulaşım için daha uygun bir yapıdadır. Ancak bu tür bir sistemde kişinin ses dalgaları telefonda iletilirken bozulmalara uğrayabilir. Bu da o sistemi daha az güvenilir kılacaktır. Ayrıca kaydedilen ses bilgisinin çok fazla yer kaplaması, sesin yaşlılık, hastalık veya psikolojik durumlardan dolayı değişmesi, kayıt sırasında arka plandaki gürültüler ve hem kayıt sırasında hem de sisteme giriş sırasında okunan metinde yanlış sözcük kullanılması gibi dezavantajlar ses tanıma sistemlerini daha kullanışsız ve güvensiz hale getirir.

3.3.5 El yazısı ve imza tanıma

El yazısı ve imza tanıma sistemleri diğerleri kadar geniş kullanım alanı olmayan bir biyometrik teknolojidir (Nalwa 1997). Genellikle belge kullanılan

güvenlik sistemlerinde tercih edilir. Kullanıcının el yazısı veya imzası taranarak yazının veya imzanın karakteristik özellikleri çıkarılır. Bu karakteristik özellikler kalem hızı ve basıncı, imzadaki bazı çizgilerin durumu, yazı karakterlerinin şekilleri gibi özelliklerdir (Srihari ve ark. 2002). Diğer biyometrik sistemlere göre çok daha az güvenlidir.

3.3.6 Retina tanıma

Retina göz yuvarlağının iç kısmında arka tarafta yer alan ince sinirlerin ve damarların bulunduğu ağ tabakadır. Bu tabakada yer alan ışığa duyarlı sinirler ışığı optik sinirler vasıtasıyla beyne iletir. Retina tarayıcı cihazlar gözbebeği içerisinden tarama yaparlar. Bir optik algılayıcı retinanın yapısını düşük yoğunluklu ışınlar kullanarak tarar. Bu işlem sırasında kullanıcı yaklaşık 1cm'lik bir delikten kımıldamadan bakar. Tarayıcı cihaz tarama sırasında yaklaşık altı tur döner ve her turda belirlenen noktaları kaydeder. Daha sonra bu bilgiler dijitalleştirilerek kaydedilir (Hill 1999). Ancak tarama sırasında gözün tarayıcıya fiziksel teması, gözde oluşabilecek ve retina yapısına zarar verebilecek travmaların olması, tarama işleminin oldukça zahmetli olması ve uzun sürmesi gibi faktörler retina tanıma sistemlerini daha az tercih edilir hale getirmiştir.

3.3.7 Kulak şekli tanıma

Kulak şeklinin biyometrik olarak kullanılması düşüncesi diğer biyometriklere göre çok daha yakın zamanda ortaya atılmıştır. Bir grup araştırmacı, kenar bulma teknikleri kullanarak, kulağın temel yapısını elde etmiş ve bu görüntünün özneliliklerini kullanarak tanıma işleminde kullanmıştır (Burge ve Burger 2000). Kulak şeklinin her insanda farklı olma olasılığı diğer biyometriklere oranla daha

düşüktür. Bu yüzden bu tür bir tanıma şekli güvenilir olmayacaktır. Zaten uygulamada kulak şeklinin kullanımı oldukça düşüktür.

3.3.8 DNA tanıma

DNA tanıma biyometrik tanıma çeşitleri içerisinde en mükemmelidir. Her insanın farklı DNA yapısı olduğu düşünüldüğünde bu tür bir biyometrik sistemin güvenilirliği tartışılmaz. Ancak tek yumurta ikizlerinin DNA yapıları aynı olduğu da bir gerçektir. Bu da bu tarz bir sistemin eksik yönüdür (NRC 1996). DNA yapısının elde edilmesi oldukça güç ve günler, hatta haftalar alan uzun süren bir süreçtir. Bununla birlikte oldukça maliyetli ve karmaşık bir uygulamadır. Ayrıca hiç kimse biyometrik bir sisteme giriş için kendi DNA yapısını kolay kolay vermek istemez. Bütün bunlar, DNA yapısının biyometrik tanıma amacıyla kullanılmasının önünde önemli engellerdir.

3.3.9 Vücut ısısı (termogram) tanıma

Vücut ısısı (termogram) ölçüm görüntüleri kızılötesi spektrumun değişik bandında yer almaktadır. Bu alanda yapılan ilk çalışmalar el veya yüzün termal görüntülerini kullanmıştır (Prokoski ve Riedel 1999). Aslında termal görüntülerin yüz tanıma için kullanılması avantajlı bir durumdur. Yüzde bulunan oyukların ve çıkıntıların termal olarak daha belirgin alınacağı açıktır. Bununla birlikte vücut ısısının değişken olması bu tür bir tanıma sistemi için negatif bir durumdur.

3.3.10 Yürüyüş tanıma

Yürüyüş tanıma davranışsal bir biyometrik şeklidir. Genellikle video görüntüleri kullanılarak elde edilen yürüyüş şekli kişilerin tanınmasında kullanılabileceği düşüncesi yirminci yüzyılın sonlarında ortaya atılmıştır (Nixon ve ark. 1999). Yürüyüş şeklinin zamanla değişken olması bu tür bir tanıma sistemini oldukça güvensiz hale getirmektedir.

3.3.11 Dudak hareketi tanıma

Dudak hareketi davranışsal bir biyometrik şeklidir. Kişilerin konuşma sırasında yaptıkları dudak hareketlerinin video görüntüsü içerisinden alınarak tanıma amacıyla kullanılması prensibine göre çalışır (Nabiyev ve Yavuz 2005). Dudak hareketleri genellikle sabit bir metin okutularak alınır. Bu tarz bir tanıma sisteminde hem yüz şekli hem de dudak hareketleri birlikte kullanılarak sistemin güvenilirliği artırılabilir.

3.3.12 İris tanıma

İris gözün ön kısmında bulunan ve fibroz (lifli) dokudan oluşan renkli tabakadır. İriste yaklaşık 250 den fazla görsel karakteristik bulunmaktadır. Bunlar daireler, benekler, çizgiler gibi belirleyici şekillerdir (Wildes 1997). İrisin, bebek embriyo olarak anne karnındayken oluşması ve insanın ölümüne kadar değişmemesi iris tanıma sistemlerinin güvenilirliğini oldukça yükseltir.

İris görüntüsünün alınması işlemi biyometrik taramalar içerisinde en basit olanlarından biridir. Sıradan CCD kamera kullanılarak yaklaşık 15-20 cm uzaklıktan tarama yapılır. Bununla birlikte iris üzerinde ışık yansımalarının önüne geçmek amacıyla kızılötesi aydınlatmalı kameralar da kullanılmaktadır (NLPR 2007). Kullanıcı ile tarayıcı arasında fiziksel temas olmasına gerek yoktur. Bu da sistemin kullanıcı dostu olmasını sağlamaktadır. İris görüntüsü alınırken kişilerin gözlüklerini çıkarmasına bile gerek yoktur. İris deseninin zamanla değişmemesi, ayırt edici özelliklerinin çok olması ve iris görüntüsünün çok kolay elde edilmesi iris tarama sistemlerini daha çok tercih edilir hale getirmiştir (Wildes 1997).

3.4. Çoklu-biyometrikler

İki veya daha fazla biyometrik tekniğin bir araya getirilerek oluşturulan sistemlere çoklu-biyometrik sistemler denir. Bu tür sistemler, tek biyometrik teknoloji kullanılarak oluşturulmuş sistemlerden daha güvenli sistemler tasarımlamak için düşünülmüştür. Tek bir biyometrik sistem çok da güvenilir olmayabilir. Aslında bazı çoklu-biyometrik sistemlerde iki biyometrik özelliğin yerine bir biyometrik ve bir de şifre, pin, veya akıllı kart gibi kişinin kim olduğunu tanıttıcı bilgi girilir. Karşılaştırma sonucuna göre sistem kullanıcıya geçiş izni verir veya reddeder. Bu tür çoklu-biyometrik sistemler geliştirilme çalışmalarının henüz ilk aşamalarında. Ancak bu tür sistemler tam olarak geliştirildiğinde diğer sistemlere göre çok daha güvenilir ve etkili olacaktır.

3.5 Biyometrik Sistemlerin Karşılaştırılması


En sık kullanılan biyometrik sistemlerden bazıları; güvenlik seviyesi, kullanım kolaylığı, kullanıcıya uygunluk, dayanıklılık, sistemdeki hata oranı ve

maliyet açısından karşılaştırılmış ve değerlendirme sonuçları tablo halinde gösterilmiştir (Tablo 3.3).

Tablo 3.3 Biyometrik Sistemlerin Karşılaştırılması

	Yüz	Parmakizi	El	Ses	İris	El Yazısı (İmza)
Güvenlik Seviyesi	Orta	Yüksek	Orta	Orta	Çok Yüksek	Düşük
Kullanım Kolaylığı	Orta	Yüksek	Yüksek	Yüksek	Yüksek	Yüksek
Kullanıcıya Uygunluk	Orta	Yüksek	Orta	Yüksek	Orta	Yüksek
Dayanıklılık	Yüksek	Yüksek	Yüksek	Yüksek	Çok Yüksek	Yüksek
Hatayı artıran etkenler	Yaşlanma Saç, sakal Gözlük	Kirlilik Nemlilik Yaşlanma	Kaza Yaşlanma	Gürültü Hastalık Yaşlanma	Düşük aydınlatma	El yazısının değişmesi
Maliyet (tarayıcı)	< \$200	< \$100	< \$500	< \$5	< \$300	< \$300

Biyometrik sistem seçilirken bazı önemli hususlar dikkate alınmalıdır. Öncelikle biyometrik sistemle çözümlenecek olan problem iyi analiz edilmelidir. İhtiyaçlara göre sistemin seçimi yapılmalıdır. Örneğin güvenlik seviyesi ve biyometrik özelliğin dayanıklılığı çok yüksek olması gereken bir yere biyometrik sistem uygulanacaksa o halde iris tanıma sistemi kullanmak daha uygun olacaktır. Kullanım kolaylığı ve maliyet ön planda ise, o halde parmakizi tanıma sistemini seçmek daha doğru olacaktır. Ayrıca hatayı artırıcı etkenlere de dikkat edilmelidir. Kişinin yaşlanması ile biyometrik özellikleri de değişime uğrayacaktır. Dolayısıyla sistem kişiyi tanımakta güçlük çekecektir. İrisin bir ömür boyu değişmez bir özelliğe sahip olması iris tanıma sistemlerini daha cazip hale getirmektedir. Buna karşılık ses tanıma sisteminde kullanılan kişinin sesi hastalanma gibi bir sebepten dolayı çok kısa aralıklarda değişime uğrayabilir. Bu da sistemi güvensiz kılmaktadır. Uluslararası Biyometrik Grup (International Biometric Group – IBG) tarafından 2006 yılında biyometrik sistemlerin karşılaştırılması üzerine yapılan araştırma sonuçları aşağıdaki grafikte verilmiştir (Şekil 3.4) (IBG 2006).



Şekil 3.4 Biyometrik sistem pazar oranları (2006)

3.6 Bölüm Sonuçları

Bu bölümde, insan tanıma amacıyla geliştirilen biyometrik teknikler ve biyometrik sistemler anlatılmıştır. Biyometrik tanıma amacıyla kullanılan fiziksel ve davranışsal özellikler irdelenmiş ve biyometrik sistemin seçiminde etkili olan faktörler anlatılmıştır. Biyometrik çeşitlerinin tanımı ve kullanım yerleri incelenmiş ve avantaj ve dezavantajları ortaya konmuştur. Yapılan araştırmalar göstermiştir ki, parmakizi tanıma, en fazla rağbet gören biyometrik çeşididir. Bununla birlikte, kullanım amacına göre biyometrik sistemin seçimi çok önemli bir unsur haline gelmiştir. Bu durumda, yanlış yapılan bir seçimin sistemin performansını direkt olarak etkilediği görülmüştür. Son yıllarda, birden fazla biyometrik özelliğin (iris + parmakizi + yüz v.b.) bir arada kullanıldığı çoklu biyometrik sistemler daha çok tercih edilmeye başlandığı gözlenmiştir.

4. İRİS TANIMA SİSTEMLERİ


Biyometrik teknolojileri, koruma altındaki bölgelere ve materyallere ulaşımında, tanımlama ve doğrulunu kanıtlama kontrolü uygulamalarında oldukça etkilidir. Bu uygulamaları destekleyen çok çeşitli biyometrikler geliştirilmiştir. Biyometrik konusunda geliştirilen sistemler retina bölgesi damarların tanınması, parmakizi tanıma, el tanıma, imza tanıma ve ses tanıma gibi tanıma sistemlerini içermektedir. Bu yaklaşımların tümü kabul edilebilir performansla sahiptirler. Ancak insan faktörü göz önünde bulundurulduğunda bu metotların çoğu insan vücuduna zarar verebilecek özelliklere sahiptirler. Uygulamada tarama yapılacak kişinin tarama yüzeyi ile fiziksel temas halinde olması gerekmektedir. Yukarıda verilen biyometrik sistemlerin dışında vücuda zararı en az olan bir sistemde yüz tanıma sistemidir. Bunun yanı sıra iris tanıma sistemleri kişilerin tanınması ve doğruluğunun kanıtlanmasında vücuda zarar verebilecek herhangi bir fiziksel temas içermez. İlginçtir ki, iris bölgesindeki desenler diğerlerinden farklı olarak çok yüksek ayırt edici özelliklere sahiptir. İris de yüz gibi uzaktan değerlendirilebilen, görünen bir bölgedir. Bununla birlikte iris, diğerlerinin aksine birbiri ile kesinlikle aynı olmayan ve zamanla değişmeyen bir özelliğe sahiptir (Kronfeld 1962, Wildes 1997).

Bu bölümde irisin yapısı, iris tanıma sistemlerinin teknik özellikleri ve sistemin aşamaları (görüntünün alınması, irisin yerinin belirlenmesi, özneliliklerin çıkarılması ve karşılaştırma) anlatılmıştır.

4.1 İrisin Yapısı

Eski dilde gökkuşağı manasına gelen iris kelimesi oldukça eski zamanlardan (16. yüzyıl) gelmektedir. Gözün dış kısmını ele aldığımızda, iris gözün alacalı bulacalı görünen renkli kısmını ifade etmektedir (Vesalius 1543). Daha teknik olarak ifade edersek, iris gözün orta tabakasından ön kısmına doğru uzanan ve lens


tarafından desteklenen ince diyaframlı bir katmandır (Şekil 4.1). 3 boyutlu olarak düşünüldüğünde lensin bu desteği irise tepesi kesilmiş bir koni şeklini vermektedir. İris alt kısmından gözün ciliary gövdesi denilen bölgesine tutunmaktadır. Tam ters tarafından ise gözbebeğine ve geniz kısmına açılmaktadır. Kornea irisin ön kısmında yer alır ve saydam bir halde koruyucu tabaka görevi üstlenir.



Şekil 4.1 İrisin Fiziksel Yapısı

İrisin desen tanıma uygulamaları için ne kadar zengin özelliklere sahip olduğunu anlamak için irisi yapısal olarak daha detaylı incelemek gerekir. İris birçok katmandan oluşmuştur. İrisin arka yüzeyinde ışığa duyarlı yoğun pigmentli epitel hücreler bulunmaktadır. Bu kısım ışığın yoğunluğuna bağlı olarak, ışık arttığında daralıp azaldığında genişler. Bu katmanın hemen ön kısmında ise gözbebeğinin hareketlerini kontrol eden ve birlikte çalışan iki kas yer almaktadır. Daha sonra gövde (stroma) katmanı gelir. Bu katman kemer şeklinde kolajen bağlarla birbirine bağlı dokulardan oluşmuştur. Bu katmanın ortasında yarıçap şeklinde ve burgulu bir halde kan damarları bulunmaktadır. Daha ön kısımda ise ön kenar katmanı denilen ve gövdeden daha yoğun halde olan bir katman bulunur. Bu katmanda kromatofor (chromatophore) denilen özel pigment hücreleri bulunmaktadır. İris görsel olarak farklı görünümünü bu çok katmanlı yapısal özelliğinden almaktadır. İrisin ön yüzeyi iki ana bölgeden oluşmuştur. Bunlar; merkezi gözbebeği bölgesi ve bunu çevreleyen ciliary bölgesi. Bu iki bölgenin arasındaki sınıra kolaret (collarette) denir ve ön sınır

katmanının gözbebeğinin yakınında aniden sonlanması sonucu zigzaglı dairesel kabartmalar şeklinde görülür. Ciliary bölgesi gövde (stroma) desteğinden dolayı birçok iç içe geçmiş ağ şeklinde kabartmalar içerir. Bürgülü haldeki çizgiler gözbebeğinin durumuna göre değişiklik arz eder. İris üzerindeki diğer ayırt edici özellikleri şunlardır; cryptler (kenar katmanının düzensiz haldeki çukurları), neviler (kenar katmanının düzensiz haldeki tepecikleri) ve freckle'lar (kromatoforların yerel olarak toplu hali). Buna karşılık pupillary bölgesi oldukça sadedir. Bu bölgede genellikle sigara dumanı şekline yayılan tepeler bulunmaktadır (Şekil 4.2)(Wildes 1997). Pupillary bölgesinin gözbebeğine en yakın kısmında, tam sınırda pupillary frill denilen uç kısım yer alır. Bu uç kısmın alt tarafında yer alan yoğun pigmentli doku göz bebeği sınırını oluşturmaktadır.



Şekil 4.2 İrisin üzerindeki bölgeler ve geometrik şekiller

Işığın ön kenar katmanındaki pigmentli hücreler tarafından farklı seviyelerde emilimi sonucu irisin rengi oluşur. Ön kenar katmanında pigmentasyon az olduğunda ışık arka epitel dokudan yansıyarak açık bir renk oluşur. Pigmentasyonun fazla olması durumunda ışık daha az yansıyacak ve daha koyu bir renk oluşacaktır. Işığın az da olsa gövde kısmından geçerek yansımaları mavi bir görüntü oluşturur.

İrisin yapısal olarak her insanda farklı ve yaşa bağlı olarak zamanla değişmeyen bir özellikte olduğu iki farklı kaynak tarafından iddia edilmektedir. İlki

klirik gözlemlerdir. Çok fazla sayıda göz deseni üzerinde yapılan çalışmalarda, anatomist (Adler 1965) ve oftalmojistler (Flom ve Safir 1987), bir insanın sağ ve sol gözünün bile çok farklı yapıda olduğunu gözlemlemişlerdir. Ayrıca yine aynı gözlemlerde iris deseninin bebeklik döneminin ilk aylarında çok küçük değişimlere uğradığını görmüşlerdir. İrisin yapısal olarak her insanda farklı olduğu tezini savunan ikinci kaynak ise gelişimsel biyolojidir (Kronfeld 1968). İris genel yapısını genetik olarak elde etmektedir. Yapısal ayrıntılar embriyonun genel durumuna bağlı olarak gelişir. Bunun sonucunda olayların doğal gelişimi sonucu oluşan irisin aynı yapıya sahip olma olasılığı yok denecek kadar azdır. Nadiren de olsa gelişim sürecinde ters bir durum meydana gelebilir ve tam gelişmemiş iris (anindia), iz kayması (corectopia) ve gözbebeğinin biçimsel bozulması (coloblama) görülebilir.

Gelişimsel biyoloji aynı zamanda zamana bağlı değişmezlik olayını da kanıtlar. İrisin belirli kısımları (örneğin vasculature) bebeğin anne karnında gelişim sürecinde tamamen oluşmuş haldedir ve ölüme kadar aynı kalır. Bunun yanında bazı kısımlar (örneğin musculature) bebeğin iki yaşına erişmesine kadar değişebilmektedir (Adler 1965, Kronfeld 1968). Bununla birlikte ortalama gözbebeği genişliği delikanlılık çağına kadar çok az bir değişim gösterir. Bu tür küçük değişiklikler iris tanıma mekanizması için etkileyici faktör sayılmazlar. Çeşitli kazalar sonucu iriste meydana gelebilecek deformasyonlar ve çevresel atıklara yoğun bir şekilde maruz kalınması sonucu pigmentasyonlarda oluşabilecek değişiklikler nadiren de olsa yaşanmaktadır. Bu tip özel durumlar haricinde irisin yapısı herhangi bir değişime uğramaz (Olivier 1969, Wasserman 1974). Görüldüğü gibi iris değişmez bir yapıya sahiptir. Geniş kapsamlı araştırmalar göstermiştir ki, biyometrik alanında iris deseni değişmezlik ve sabitlik açısından yeterli kullanılabilirliğe sahiptir (Newell 1991). Biyometrik açıdan bakıldığında irisin bir diğer ilginç özelliği de dinamik bir yapıya sahip olmasıdır. İriste bulunan kasların karmaşık etkileşimi sayesinde gözbebeğinin çağı düşük seviyeli sabit osilasyonlar yapar. Bu hareketlilik bir canlılık örneğidir. Ayrıca irisin ışığın şiddetine çok hızlı bir şekilde cevap vermesi (birkaç yüz milisaniye civarında kasılma hızı) bu dinamikliliğin iyi bir göstergesidir.


4.2 Teknik Özellikler

Otomatik iris tanıma sistemlerinin tasarım özellikleri teknik olarak dört kısma ayrılabilir (Şekil 4.3) (Wildes 1997). İlk kısımda görüntü elde etme işlemi yapılır. Bunun için genellikle optik tarayıcılar veya kameralar kullanılır. İkinci kısım elde edilen görüntü üzerinde lokalizasyon (belirli bir bölgenin alınması) yapılması ile ilgilidir. Görüntü içerisinde iris bölgesi tespit edilerek resimden ayrıştırılır. Üçüncü kısımda ise elde edilen yeni iris deseninin öznelik çıkarımı işlemi yapılır ve elde edilen sayısal değer veritabanına kaydedilir. Son aşamada ise giriş iris bilgisi önceden kaydedilmiş olan iris bilgileriyle karşılaştırılır ve karar verme işlemi yapılır.

Son yıllarda irisin biyometrik tanıma amacıyla çok sık tercih edilmesinin birçok sebebi vardır. Bunlar;

1. İrisin kişinin doğumundan itibaren bir yaşında tam olarak belirgin hale gelmesi ve ölümüne kadar değişmemesi;
2. İris deseninin ayırt edici özellikleri diğer biyometrik tekniklere göre çok daha fazla olması (Aynı iris desenine sahip olma olasılığı 1/1078 dir.);
3. Gözün dış etkenlere karşı korunaklı bir yapıda olması;
4. İris tanıma sisteminde görüntü alınırken herhangi bir temas olmadan kolayca alınabilmesi;
5. Gözdeki iris tabakasının taklit edilmesinin imkansız olması;
6. Yapılan çalışmalarda iris tanıma sistemlerinin başarı oranlarının %100' çok yakın değerlere ulaşılması.

olarak sıralanabilir. Klinik deneyler ve geliştirilen iris tanıma sistemleri, irisin biyometrik alanında kullanım için çok uygun bir fiziksel özellik olduğunu ortaya koymuştur. İrisin yapılan çalışmalar sonucunda, her insanda farklı yapıda olduğu ve ilerleyen yaşlarda değişmediği görülmüştür.



Şekil 4.3 İris tanıma sistemlerinin aşamaları


4.2.1 Görüntünün alınması

Otomatik iris tanıma sistemlerinde karşılaşılan temel zorluklardan biri de irisin görüntüsünün kişiye zarar vermeden elde edilmesidir. Bilindiği gibi, iris oldukça küçük (yaklaşık 1 cm çapa sahip) ve karanlık bir nesnedir (Daugman 1993). Bununla birlikte insanlar gözleri konusunda oldukça hassastırlar. Bu nedenlerden dolayı iris görüntüsünün elde edilmesi oldukça dikkatli ve hassas bir teknik gerektirmektedir. Bu konu ile ilgili birçok endişe bulunmaktadır. İlk olarak, iris görüntüsünün tanımlama alanında kullanılabilmesi için yeterli çözünürlük ve keskinlikte olması istenir. İkinci olarak, kişiyi rahatsız edecek derecede yüksek seviyeli aydınlatmaya başvurulmadan iris deseninin yeterli netlikte ve kontrasta alınması önemli bir noktadır. Üçüncü husus ise kişiyi gereksiz yere zorlamadan iris görüntüsünün kamera karşısında en iyi şekilde çerçevelenmesinin gerekliliğidir. Tercihen kişinin gözünün, çenesinin veya diğer kısımlarının tarayıcı cihaza dokunmadan görüntünün yakalanması istenir. Bununla birlikte, merceksel yansımalar, optik yanılgılar gibi görüntünün net elde edilmesini engelleyen etkenler olabildiğince yok edilmelidir.

Yukarıda bahsedilen tüm zorluklara cevap verebilecek nitelikte geliştirilmiş iki farklı görüntü yakalama donanımı şematik olarak Şekil 4.4'te verilmiştir (Wildes 1997).

Mevcut iris tanıma sistemleri yeterli netlikte görüntü alabilecek donanımlara sahiptir. Bu sistemler içerisinde Daugman ve Wildes' in geliştirdiği sistemleri inceleyeceğiz (Daugman 1993, Wildes 1997). Daugman'ın geliştirdiği sistemde 330 mm lens kullanılarak 15-46 cm uzaklıktan 100 ve 200 piksel çözünürlüğe sahip bir görüntü elde edilebilmektedir. (Şekil 4.4.a)(Wildes 1997). Benzer şekilde Wildes'in geliştirdiği sistemde 80 mm lens kullanılarak yaklaşık 20 cm uzaklıktan 256 piksel çözünürlüğe sahip iris görüntüsü elde edilebilmektedir. (Şekil 4.4.b)(Wildes 1997). Aydınlatma seviyesinin kişiyi rahatsız etmeyecek şekilde düşük tutmak için optik aralığın çok az olması ($f:11$) gerekmektedir. Böylece her iki sistem de oldukça düşük alan derinliğine (yaklaşık 1 cm) sahip olacaktır.

Deneyimsel olarak, geliştirilen bu sistemlerin iris tanıma için yeterli keskinliğe ve çözünürlüğe sahip olduğu görülmüştür. Son araştırmalara göre, iris tanıma sistemini destekleyebilecek nitelikte iris görüntüsü farklı biçimlerde elde edilebilmektedir (Wildes 1997). Örneğin bazı sistemlerde standart video cihazı ve telefoto lens kullanılarak 1 metre uzaklıktan iris görüntüsü alınabilmektedir.



Şekil 4.4.a) Daugman'ın Geliştirdiği Donanım b) Wildes'in Geliştirdiği Donanım

İrisin aydınlatılması işleminde kişinin ışığa duyarlılığı ve düşük kontrastlarda detaylı görüntü elde edilmesi gibi zorluklarla karşılaşmaktadır. Daugman ve Wildes'in geliştirdiği sistemler bu tip zorluklara karşı değişik yaklaşımlar önermektedir.

Daugman'ın sisteminde standart bir video kamera ile bağlantılı LED tabanlı ışık kaynağı kullanılmıştır. Wildes'in sisteminde ise düşük aydınlatma seviyeli bir kamera ile bağlantılı polarizasyon ve ışık kaynağı kullanılmıştır. Daugman'ın geliştirdiği sistemin tasarımı oldukça basittir. Taraması yapılacak kişinin gözlük kullanması durumunda oluşabilecek yansımaları engellemek amacıyla ışık yan kısma dikkatlice yerleştirilmiştir.

Wildes'e ait sistemde aydınlatma donanımı daha karmaşık bir yapıdadır. Bu ise sisteme oldukça avantaj sağlamaktadır. Bu sistemde kullanılan dairesel polarizörler ışık kaynağından ileri gelen spekül yansımaların önüne geçilmesini sağlar. Böylece iris görüntüsü daha net ve ayrıntılı bir şekilde elde edilebilir. Yine Wildes'in geliştirdiği sistemde düşük ışık seviyeli kamera (silikon yoğunluklu kamera) kullanımı iris görüntüsü alınacak kişiyi rahatsız etmeden işlemin yapılmasına olanak verir. Spektral dağılıma göre her iki sistemde de kişi tarafından görülebilir ışık kaynağı kullanılmıştır. Bu tür sistemlerde kızılötesi (infrared) aydınlatmanın da yeterli aydınlatma sağladığı testlerde görülmüştür. Ayrıca her iki sistem de esas olarak 8-bit gri seviyeli monokrom kamera kullanmıştır. Böylece renk bilgisine gerek duyulmamıştır. Renk bilgisi ek ayırt edici güç sağlamasına rağmen saklanması için daha fazla kapasite ve zaman gerekir. Gri seviyeli bilgi şimdilik yeterli olmaktadır. Göz görüntüsünün kameranin görsel alanı içerisinde tam olarak çerçevelenebilmesi için irisin yerinin tam olarak belirlenmesi gerekir. Hem Daugman, hem de Wildes'in geliştirdiği sistemlerde iris görüntüsü alınacak kişi duracağı noktayı kendisi belirlemelidir. Kişinin durduğu yerle ilgili gereksiz sınırlamalara gidilmeden güvenilir bir görüntü elde etmek nerdeyse imkânsızdır.

Daugman'ın geliştirdiği sistemde görüntü, ışın ayırıcı (beam splitter) üzerinden minyatür bir likid kristal ekrana yansıyarak kişiye o an durduğu yerin doğru yer olup olmadığı konusunda bir fikir vermektedir. Böylece kişi kendi pozisyonunu doğru bir şekilde ayarlayabilir. Bu işlem sırasında sistem devamlı görüntü yakalar. Bu şekilde elde edilen görüntü serisi içerisinde en kaliteli olanı otomatik olarak veritabanına atılır. Görüntü kalitesi irisle gözaki arasındaki kontrast farkına bakılarak belirlenir.

Buna karşılık Wildes'in geliştirdiği sistemde kişiye duracağı yeri belirleme konusunda yardımcı olacak bir düzenek hazırlanmıştır. Kamera lensi etrafında kare şeklinde bir çerçeve kişinin görebileceği bir konumda yerleştirilmiştir. Bu çerçevenin hemen önünde havada asılı gibi duran daha küçük ikinci bir çerçeve yerleştirilmiştir. Bu çerçevelerin genişlikleri ve pozisyonları ayarlanmıştır. Kişi kamera önünde dururken bu iki çerçeveyi görsel olarak üst üste getirmek amacıyla manevralar yapar. Üst üste geldiği an doğru noktada durmaktadır. Bu noktada cihaz üzerine yerleştirilen bir butona basarak iris görüntüsünün alınmasını sağlar.


Bahsedilen her iki yer belirleme yaklaşımı da iris görüntüsü alınacak kişi için oldukça kolaydır. Gelecek araştırmaların birçoğu bu tür sorunları ortadan kaldıracak ve üç boyutlu modelleme yapabilecek sistemler geliştirmek amacıyla yapılmaktadır.

4.2.2 İrisin yerinin belirlenmesi

İris görüntüsü elde edilirken oldukça geniş bir bölgenin görüntüsü yakalanır. Bu görüntü içerisinde iris etrafındaki tüm nesneler (göz kapağı, kirpikler v.s.) yer almaktadır. Bundan dolayı, iris deseninin karşılaştırılması işleminde görüntü içerisinde irisin tam olarak yerinin belirlenmesi (lokalizasyon) oldukça önemlidir. Aslında, görüntü içerisinde iris ve göz akı arasındaki kenar çizgisi ile göz bebeğinin dış çizgisi arasında kalan bölgeyi sınırlandırmak gerekir. Göz kapakları irisin bazı bölgelerinin görünmesini engellemektedir. Bu yüzden, üst göz kapağının altındaki ve alt göz kapağının üst kısmındaki iris bölgesi alınmalıdır. Genellikle, yüksek kontrastlı görüntüdeki keskin ton farklılıkları belirlenerek kenar çizgileri işaretlenir. Bu kenar çizgilerinin alt ve üst kısımları göz kapağı tarafından engellenmiş haldedir. Göz bebeği kenar çizgileri daha zor tanımlanmaktadır. Göz bebeği ile pigmentli iris arasındaki kontrast farklılıkları çok az olduğundan dolayı ayrıştırma zor yapılır. Bunun yanında genellikle iristen daha koyu renkte olan göz bebeği, katarakt hastalığı oluşması durumunda tam ters şekilde açıklaşarak bulutlu bir hal alır. Göz bebeği

kenar çizgisi gibi göz kapağı derisinin renginin koyu olması da irisle gözkapağı arasındaki kontrast farklılığını azaltır. Göz kapağı sınır çizgisi, kirpiklerin yoğunluk durumuna göre düzensiz bir hal alabilir. Bütün bu etkenler göz önünde bulundurulduğunda, iris lokalizasyonunun oldukça dikkatli bir şekilde yapılması gerektiği görülmektedir (Daugman 1993, 2001, 2003).

İrisin yerinin belirlenmesi için yapılan geçmiş çalışmalara bakıldığında görülüyor ki, hemen hemen tüm çalışmalarda en çok tercih edilen yöntem Hough dönüşüm yöntemi olmuştur. Bu dönüşüm yönteminde temel fikir, görüntüdeki kontrast farklılıklarına göre lokal maksimumların bulunması ve kenar çizgilerin türev büyüklüklerinin elde edilmesidir. Bu yöntemde irisi sınırlayan çeşitli sınır çizgileri basit geometrik şekillerle modellenir. Bunun için Hough dönüşümünün geliştirilmiş hali olan Dairesel Hough Dönüşümü kullanılmıştır. Bu dönüşüm yönteminde göz bebeği ile iris kenarları dairesel konturlarla modellenir (Şekil 4.5) (Daugman 2003). Bunun yanında alt ve üst göz kapakları parabolik yaylar şeklinde modellenir. Bu yayların belirlenmesinde Daugman tarafından geliştirilmiş olan parabolik Hough dönüşümü oldukça etkilidir. İris kenarındaki dikey kenarlar filtreleme yapılarak daha seçici hale getirilir. Benzer şekilde, filtreleme yapılarak yatay bilgiler de seçici hale getirilir. İris lokalizasyonu yapıldıktan sonra kalan görüntü dijitalleştirilerek veritabanına aktarılır. Bununla birlikte, yapılan çalışmalarda, değişik kenar bulma algoritmaları ve histogram analizleri kullanılarak irisin kenar çizgileri bulunmuştur.



Şekil 4.5 İrisin yerinin belirlenmesi

4.2.3 Öznitelik çıkarımı

Öznitelik çıkarımı, iris tanıma sistemlerinde en önemli aşamadır. Çünkü bu aşamada elde edilecek öznitelik vektörü iris desenini ne kadar doğru ifade ederse, karşılaştırma aşamasında o kadar başarılı sonuçlar alınacaktır.

Öznitelik analizi için çeşitli algoritmalar geliştirilmiştir. Bunların birçoğu görüntüye filtre uygulanması şeklinde çalışmaktadır. Bazı çıkarımlarda ise görüntü alt görüntülere bölünerek her bir alt görüntünün sayısal olarak ifade edilmesi yöntemi uygulanmıştır. Aslında öznitelik çıkarımının amacı görüntüyü en doğru ve en az yer tutacak şekilde ifade etmeye yöneliktir. Bugüne kadar geliştirilmiş olan iris tanıma sistemleri içerisinde uygulanan öznitelik çıkarım yöntemleri Tablo 4.1’de verilmiştir.

Tablo 4.1 Iris tanıma için uygulanan öznitelik çıkarım yöntemleri

Araştırmacı	Yıl	Yöntem
Daugman	1993, 2001, 2003	2 boyutlu Gabor filtresi
Wildes	1997	Laplas piramidi
Boles ve ark.	1998	Sıfır geçişli dalgacık dönüşümü
Reillo ve ark.	2000, 2002	Sıfır geçişli dalgacık dönüşümü
Tisse ve ark.	2002	2 boyutlu Hilbert dönüşümü
Shinyoung	2001	Haar dalgacık dönüşümü
Li Ma ve ark.	2002	Gabor filtresi + Ort. Mutlak Sapma
Huang ve ark.	2002	Bağımsız bileşen analizi
Liam ve ark.	2002	Gri seviye piksel değerleri
Alim ve ark.	2002	2 boyutlu Gabor filtresi
Szewczyk ve ark.	2002	Yardımcı olay matrisi
Li Yu ve ark.	2002	Fourier Dönüşümü
Mira ve ark.	2003	Morfolojik eşikleme
Chen ve ark.	2003	Tek boyutlu dalgacık dönüşümü
Noh ve ark.	2003	Çok kanallı Gabor filtresi
Sun ve ark.	2005	Sıfır geçişli dalgacık dönüşümü
Miyazawa ve ark.	2006	2 boyutlu Fourier faz kodlama

Yukarıdaki tablo incelendiğinde, dalgacık dönüşüm yöntemlerinin öznelilik analizinde oldukça çok tercih edildiği görülmektedir. Bununla birlikte, tek veya 2 boyutlu Gabor filtresi de birden fazla uygulamada kullanılmıştır. Ayrıca fourier dönüşümü, Laplas piramidi, görüntünün morfolojik analizi, bağımsız bileşen analizi, yardımcı olay matrisi gibi yöntemler de uygulama aşamasında kendisine yer bulmuştur.

4.2.4 Karşılaştırma

İristen görüntüsünün öznelilik vektörünün elde edilmesinin ardından, son olarak karşılaştırılma işlemi yapılır. Desen karşılaştırılması işlemi 3 aşamada gerçekleşir (Wildes 1997).

- (a) Yeni iris deseninin veritabanındaki iris deseni ile hizalanması;
- (b) Hizalanmış iris desenlerini belirleyici yapan noktaların seçilmesi ve değerlendirilmesi;
- (c) Karşılaştırma sonucunda elimizdeki yeni iris deseni ile veritabanındaki iris deseninin aynı olup olmadığına karar verilmesi.

Hizalama İşlemi: İki görüntü arasında detaylı karşılaştırma yapmak için öncelikle desenlerdeki karakteristik yapıların benzerliklerini belirlemek gerekir. Hizalama işlemi sırasında görüntünün kaydırılması, skalalama ve döndürme gibi ayarlamalar yapılır. Kaydırma işlemi görüntüyü paralel olarak uygun hale getirir. Skalalama işlemi kameranın optik ekseninin uygunlaştırılması işlemidir. Döndürme işlemi ise optik eksene göre görüntünün açısal pozisyonunun uygunlaştırır. Günümüzde kullanılan sistemlerde, aydınlatma seviyesine bağlı olarak değişen gözbebeği genişliği, kritik bir sorun oluşturmamaktadır.

Karşılaştırma işlemi: İris tanıma sisteminde görüntünün elde edilmesi, elde edilen görüntünün iyi bir şekilde hizalanması ve uygun karşılaştırma ölçütlerinin

kullanılması sistemin doğru sonuç üretebilmesi için önemli bir etkidir. İyi bir karşılaştırma yapılabilmesi için elde edilen yeni görüntü ile veritabanından alınan görüntünün normalize edilmiş olması gerekir (Jayant and Noll 1984). Normalize edilmiş görüntüler standart korelasyona sahip benzer tipte bilgilere sahip olurlar. Bunun yanı sıra normalizasyon, lokal çeşitliliği değerlendirerek karşılaştırmayı güçlü hale getirir.

Karar verme işlemi: Elde edilen verinin veritabanından alınan iris deseni ile aynı bilgilere sahip olup olmadığını anlamak için yapılan son işlem karşılaştırma sonucunda elde edilen bilginin değerlendirilmesidir.

İris tanıma sistemlerinin karşılaştırma aşamasında istatistiksel yöntemler araştırmacılar tarafından daha çok tercih edilmiştir. Bunun sebebi bu yöntemlerin kolay uygulanabilir olmasıdır. Ayrıca birebir karşılaştırma işlemlerinde oldukça etkilidir. Ancak istatistiksel karşılaştırma yönteminin bazı dezavantajları bulunmaktadır. Bunların başında veritabanındaki görüntünün veya sisteme karşılaştırma için girilen görüntünün herhangi birinin tarayıcı cihazlarla alınması sırasında oluşabilecek hatalar için toleranslı olmaması gelmektedir. Ayrıca karşılaştırma için seçilecek parametrelerin çok hassas olması da karşılaştırma performansını etkileyen önemli bir faktördür. Örneğin Hamming uzaklığı yönteminde karşılaştırma sonucunun hangi değerden aşağı olacağı iyi tespit edilmelidir. Zira eşik değerinin üstünde alınan sonuç kişinin tanınamaması anlamına gelmektedir. Ayrıca yanlışlıkla bulanık olarak veya açısız anlamda dönmüş olarak alınmış bir görüntü veritabanına eklenmişse, bu tanıma aşamasında aynı kişi reddedilmesine sebep olacaktır. Bu açıdan bakıldığında yapay zeka yöntemleri biraz daha avantajlı bir konumdadır. Çünkü veritabanına birden fazla örnek girilmekte ve bunlarla eğitim yapılmaktadır. Bunların içerisinde bulanık olarak alınmış veya açısız olarak biraz dönmüş görüntüler de yer almaktadır. Bu da sistemin karşılaştırma aşamasında kararlı olmasını sağlamaktadır.

4.3. Bölüm Sonuçları

Bu bölümde iris tanıma sistemlerinin teknik özellikleri ve uygulama aşamaları ayrıntılı olarak ele alınmıştır. İrisin yapısı ve iris görüntüsünün alınması için kullanılan yöntemler anlatılmıştır. Sistemin aşamaları iris bölgesinin tespiti, öznitelik analizi ve karşılaştırma başlıkları altında sunulmuştur. Bu işlemler sırasında karşılaşılabilecek sorunlardan bahsedilmiş ve birbirilerine olan üstünlükleri incelenmiştir. Yapılan çalışmalar incelendiğinde, irisin yerinin belirlenmesi aşamasında Hough dönüşümünün oldukça etkili olduğu gözlemlenmiştir. Öznitelik çıkarımı aşamasında ise bir çok yöntem mevcut olduğu görülmüş, ancak bunlar içerisinde özellikle dalgacık dönüşümü ve Gabor filtrelerinin oldukça fazla tercih edildiği tespit edilmiştir. Karşılaştırma aşamasında ise araştırmacıların istatistiksel yöntemleri oldukça fazla tercih ettikleri ve bu yaklaşımın birebir karşılaştırmada oldukça etkili olduğunu belirtmiş oldukları gözlemlenmiştir. Bununla birlikte, istatistiksel yaklaşımın sahip olduğu bazı dezavantajlarının yapay zeka yöntemleri ile giderilebildiği anlaşılmıştır. Bundan dolayı, çeşitli yapay zeka yöntemleri ile iris tanıma probleminin aktüel olduğu fikrine varılmıştır.

5. İRİS GÖRÜNTÜSÜNÜN ÖN İŞLEMDEN GEÇİRİLMESİ

Görüntünün analizi sırasında karşılaşılabilecek bazı zorlukları (örneğin görüntüde yer alan gürültüler, görüntünün bulanık, çok parlak veya çok karanlık olması v.b.) ortadan kaldırmak ve analizi kolaylaştıracak iyileştirmelerin yapılabilmesi için kullanılan tekniklere “Görüntü ön-işleme teknikleri” denmektedir. Bunun için seçilen bir operatörün görüntüde yer alan tüm piksellere uygulanması gerekmektedir (Leondes 1998). Şimdi görüntünün ön işlenmesi için kullanılan tekniklere değinelim.

Bu bölümde öncelikle görüntü ve görüntü formatları hakkında bilgi verilmiştir. Daha sonra sayısal görüntü işleme aşamalarından ön işlem aşaması anlatılmıştır. Ön-işlem aşamasında, görüntüye uygulanan genel filtreleme teknikleri ve ayrıştırma işlemleri anlatılmıştır. Genel filtreleme tekniklerinden ortalama, orta değer, gauss, laplas, wiener filtreleri ve histogram dönüşümleri irdelenmiştir. Daha sonra ayrıştırma işleminde kullanılan kenar bulma algoritmalarından (Roberts, Sobel, Prewitt ve Canny) bahsedilmiştir. Bu algoritmaların etkili olduğu noktalara göre iris tanıma sistemi içerisinde kullanılabilirlik oranları incelenmiştir.

5.1 Görüntü Nedir?

Görüntü ışığın cisimler üzerinde yansısıyla ortaya çıkan iki boyutlu resimdir. İnsan gözü bu görüntüleri üç boyutlu olarak algılar ancak makineler bunu gerçekleştiremezler. İnsan beyni bu görüntüleri analiz ederek insana gördüğünün ne olduğunu bildirir. Bu işlem görüntünün tanınması işlemidir. İnsan gördüğü nesnelerin ne olduğunu bebeklikten itibaren öğrenerek tanır. İşte insan gibi kamera sistemleri de görüntüyü objektifler vasıtasıyla alır ve bunları önceden belirlenmiş

veri alanlarına sayısal olarak kaydeder. Kaydedilen bu görüntülere sayısal görüntü adı verilmektedir (Umbaugh 1999). Aynı şekilde fotoğraf makineleri ile kâğıda basılan görüntüler tarayıcılar vasıtasıyla taranarak da sayısal olarak ifade edilebilirler. Daha sonra bu görüntüler insan beyninde olduğu gibi analiz edilirler ve cismin ne olduğu belirlenir. Buna makinenin öğrenmesi de denilebilir.

Günümüzde görüntüler CCD algılayıcılar kullanılarak elde edilmektedir. CCD algılayıcılarda görüntüdeki her bir noktayı renksel olarak algılayabilen ışığa duyarlı foto elemanlar yer alır. Her bir hücre bir piksel olarak ifade edilmektedir. Görüntüdeki piksel sayısı o görüntünün çözünürlüğünü, bir başka deyişle görüntünün kalitesini belirlemektedir. Yüksek çözünürlüklü görüntü daha kaliteli görüntüdür ancak veri alanı olarak daha fazla yer kaplar (Umbaugh 1999).

Sayısal görüntüler iki boyutlu matrisler şeklinde ifade edilirler. x ve y elemanlarından oluşan bu matrisin her bir elemanı görüntünün bir pikselini belirler.

5.2 Görüntü Formatları

Görüntü temel olarak 3 farklı formatta saklanabilir (Umbaugh 1999). Bunlar:

- Siyah-Beyaz görüntü,
- Gri seviyeli görüntü,
- Renkli görüntü.

Siyah-Beyaz (Binary) görüntü yalnızca siyah ve beyaz renklerden oluşan ve sayısal olarak 0 ve 1 değerleriyle ifade edilen görüntüdür.

Gri seviyeli görüntü ise siyah ve beyaz dışında bu iki renk arasında kalan gri renkleri de ihtiva eden görüntüdür. Görüntüdeki her bir piksel 0-255 arasında bir sayısal değere sahiptir. Dolayısıyla her bir piksel 8 bitle ($2^8=256$) ifade edilir.

Renkli görüntü ise 3 temel rengin birleşmesinden meydana gelen renk tayfindan oluşur. Her bir piksel 3 farklı renk değerine sahiptir. Bu renkler kırmızı-yeşil-mavi renklerdir. RGB (Red-Green-Blue) olarak adlandırılan bu renklerin her biri 8 bitle ifade edilir ve dolayısıyla her bir piksel 24 bitlik bilgi içermektedir.

5.3 Görüntü Ön-İşleme Teknikleri

Görüntünün analizi sırasında karşılaşılabilecek bazı zorlukları (örneğin görüntüde yer alan gürültüler, görüntünün bulanık, çok parlak veya çok karanlık olması v.b.) ortadan kaldırmak ve analizi kolaylaştıracak iyileştirmelerin yapılabilmesi için kullanılan tekniklere “Görüntü ön-işleme teknikleri” denmektedir. Bunun için seçilen bir operatörün görüntüde yer alan tüm piksellere uygulanması gerekmektedir (Leondes 1998). Görüntünün ön işlenmesinde çoğunlukla filtreler kullanılır. Bunlardan en temel kullanılan filtreleme tekniklere değinelim.

5.3.1 Görüntünün filtrelenmesi


Görüntü işlemede filtre kullanımının en temel amacı, giriş görüntüsünde yer alan çeşitli tipteki gürültülerin yok edilmesidir. Gürültüler, görüntü elde edilirken oluşan ve analiz sırasında hatalara neden olan istenmeyen kısımlardır. Bununla birlikte, görüntüdeki yüksek veya düşük frekansların bastırılarak kenar değerlerini ortaya çıkarmak amacıyla da filtreler kullanılmaktadır. Bir görüntüyü filtrelerken, görüntüdeki her bir piksel için konvolüsyon denilen $n*n$ boyutlu matrissel bir maske kullanılır. Bu maske merkezi pikselin komşuluk değerlerine bakarak yeni bir değer elde eder ve elde edilen bu değer önceki pikselin yerini alır. Uygulanan konvolüsyon

maskesinin boyutu deęiřkendir ve uygulanacak filtrenin amacına gre kullanıcı tarafından seilir (Umbaugh 1999). Bu alıřmada ortalama (mean) filtre, orta deęer (median) filtre ve gauss (gaussian) filtresi kullanılarak iris grntlerinin kenar haritalarının belirlenmesi amalanmıřtır.

Ortalama (mean) Filtre: Bu filtrede grntde yer alan her bir pikselin, kullanılan $n*n$ boyutundaki maskeye gre komřu piksel deęerlerinin ortalaması alınarak, ortada yer alan merkezi pikselin yeni deęeri bulunur. Bu iřlem ařaęıda verilen 3*3'lk konvolsyon maskesi kullanılarak yapılabilir.

1/9	1/9	1/9
1/9	1/9	1/9
1/9	1/9	1/9

Orta Deęer (median) Filtre: Bu filtre genellikle grntde yer alan beneklerin azaltılması veya yok edilmesi amacıyla kullanılır. Orta deęer filtresinde, nceden belirlenen $n*n$ boyutlu komřuluk maskesine gre grntde yer alan pikseller kkten byęe veya bykten kęe sıralanır ve ortada yer alan deęer, sz konusu alanın ortasındaki piksel yerine yazılır (řekil 5.1).



řekil 5.1 Orta deęer (median) filtre

Gauss (gaussian) Filtresi: Bu filtre daha ok grntde yer alan dairesel grltleri yok etmede kullanılır ve bunu gerekleřtirirken grntde yumuřatma

(smoothing) işlemi gerçekleştirir. $n*n$ boyutlu bir maske kullanıldığında, Gauss filtre katsayıları şu şekilde elde edilir (Karabörk 2002):

$$HG(i,j)=exp[-1/2(d/\sigma)^2] \quad (5.1)$$

Burada $d=(i^2+j^2)/2$ dir. σ ise standart sapmayı ifade eder ve literatürde değişik standart sapma değerlerine sahip pek çok Gauss maskesi yer almaktadır.

5.4 Ayırıştırma (segmentation) İşlemi

Görüntü işlemede kullanılan resimlerde gürültü olarak tanımlanan ve uygulamada gerekli olmayan birçok bilgi içermesi resmin bölgelere ayrıştırılmasını zorunlu kılmaktadır. Örneğin iris tanıma işleminde kullanılan orijinal görüntüde iris bölgesi dışında gözbebeği, gözakı, alt ve üst kirpikler, kaşlar gibi kullanılmayan bilgiler yer alır. Bu bilgilerin atılması veya uygulamada kullanılacak bölgenin tespitine ayırıştırma (bazı kaynaklarda segmentasyon olarak adlandırılır) işlemi denilmektedir. Ayırıştırma işlemi sonunda elde edilen anlamlı kısımlara ilgili alan (Region of Interest – ROI) denilmektedir (Umbaugh 1999).

Ayırıştırma işlemi için genellikle kenar bulma algoritmaları kullanılır. Bir resimdeki gri seviyelerin yoğunluğundaki farkın büyüklüğü bize kenar bilgisini verir. Piksel arasındaki yoğunluk değişimi ne kadar büyükse, değişim bölgesi o kadar kenar olarak ifade edilir. Kenar bulma işlemi için çeşitli operatörler geliştirilmiştir. Bunlardan en sık kullanılanları Roberts operatörü, Sobel operatörü, Prewitt operatörü ve Canny algoritmasıdır. Bununla birlikte çizgilerin trigonometrik olarak ifade edildiği yerlerde Hough Dönüşümü kullanılır.

Roberts Operatörü: Kenar bulmada kullanılan en eski operatörlerden biridir. Bu operatör yalnızca kenar noktalarını işaretleme işini yapar. Kenarların yönleriyle











ilgili herhangi bir bilgi vermez. Gri seviyeli resimlere oranla siyah-beyaz resimlerde daha iyi sonuç verir. Roberts operatörünün iki şekli vardır. İlki, çapraz komşulukların toplamının karekökünü verir. İkincisi ise çapraz komşulukların farklarının toplamı şeklindedir. Bu iki denklem aşağıdaki verilmiştir (Umbaugh 1999).








$$\sqrt{[I(r, c) - I(r-1, c-1)]^2 + [I(r, c-1) - I(r-1, c)]^2} \quad (5.2)$$

$$|I(r, c) - I(r-1, c-1)| + |I(r, c-1) - I(r-1, c)| \quad (5.3)$$

İkinci algoritma ilkinde oranla hesaplamada daha etkili sonuçlar vermektedir. Bu çalışmada normal ve filtreden geçirilen görüntülere Roberts kenar bulma operatörü uygulanmıştır. Uygulama sonrası alınan kenar görüntüleri Tablo 5.1’de gösterilmiştir.

Tablo 5.1 Roberts kenar bulma algoritması uygulama sonuçları

	Giriş Görüntüsü	Kenar Haritası (Roberts - Dikey)	Kenar Haritası (Roberts - Yatay)	Kenar Haritası (Roberts - Birleşik)
Filtre Uygulanmamış (Normal)				
Orta Değer Filtre				
Ortalama Filtre (3x3)				
Ortalama Filtre (5x5)				

Ortalama Filtre (7x7)				
Gauss Filtre (3x3)				
Gauss Filtre (5x5)				
Gauss Filtre (7x7)				

Sobel Operatörü: Bu operatör en iyi kenar bulma operatörlerinden biridir. Genellikle 3*3 boyutlu yatay ve dikey konvolüsyon maskesi uygulanır. Daha sonra elde edilen yatay ve dikey kenar bilgileri birleştirilerek geometrik şekillerin kenarları bulunur. Yatay ve dikey konvolüsyon maskeleri aşağıda verilmiştir (Umbaugh 1999).



























$$\begin{bmatrix} -1 & 2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

Kenar büyüklüğü ve kenarın yönü (5.4)'da verilen formüllerle tanımlanır.

$$\sqrt{S_1^2 + S_2^2} \text{ (Kenar büyüklüğü)} \quad \tan^{-1} \left[\frac{S_1}{S_2} \right] \text{ (Kenar yönü)} \quad (5.4)$$

Bu çalışmada normal ve filtreden geçirilen görüntülere Sobel kenar bulma operatörü uygulanmıştır. Uygulama sonrası alınan kenar görüntüleri Tablo 5.2'de gösterilmiştir.

Tablo 5.2 Sobel kenar bulma algoritması uygulama sonuçları

	Giriş Görüntüsü		Kenar Haritası (Sobel - Dikey)	Kenar Haritası (Sobel - Yatay)	Kenar Haritası (Sobel - Birleşik)
Filtre Uygulanmamış (Normal)					
Orta Değer Filtre					
Ortalama Filtre (3x3)					
Ortalama Filtre (5x5)					
Ortalama Filtre (7x7)					
Gauss Filtre (3x3)					
Gauss Filtre (5x5)					
Gauss Filtre (7x7)					










Prewitt Operatörü: Bu operatör Sobel operatörüne benzer şekilde işlem yapar. Yalnızca kullanılan konvolüsyon maskesindeki katsayılarda farklılıklar vardır. Prewitt operatörü olarak kullanılan maskeler aşağıda verilmiştir (Umbaugh 1999).













$$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$$

Görüntüde yer alan her bir piksel için iki farklı değer bulunur. Satır için bir değer (p_1) ve sütun için bir değer (p_2) bulunur. Bulunan bu değerler, kenar büyüklüğü ve kenar yönünün bulmak için kullanılır. Sobel operatörü ile aynı şekilde hesaplanır.

Bu çalışmada normal ve filtreden geçirilen görüntülere Prewitt kenar bulma operatörü uygulanmıştır. Uygulama sonrası alınan kenar görüntüleri Tablo 5.3’de gösterilmiştir.

Tablo 5.3 Prewitt kenar bulma algoritması uygulama sonuçları

	Giriş Görüntüsü	Kenar Haritası (Prewitt - Dikey)	Kenar Haritası (Prewitt - Yatay)	Kenar Haritası (Prewitt - Birleşik)
Filtre Uygulanmamış (Normal)				
Orta Değer Filtre				
Ortalama Filtre (3x3)				
Ortalama Filtre (5x5)				

Ortalama Filtre (7x7)				
Gauss Filtre (3x3)				
Gauss Filtre (5x5)				
Gauss Filtre (7x7)				

Canny Kenar Bulma Algoritması: Bu teknik çok aşamalı olarak işlem görür. İlk olarak Gauss filtresi ile görüntü yumuşatılır. Kenar tarayıcısı bir f konvolüsyon filtresidir ve görüntüdeki gürültüleri yumuşatarak kenarların yerinin belirlenmesine yardımcı olur. Aşağıdaki eşitlikte (5.5) G kenar bilgisi için uygulanan f konvolüsyon filtre cevabı verilmiştir (Parker 1997).

$$H = \int_{-W}^W G(-x)f(x)dx \quad (5.5)$$

Burada filtre $[-W, W]$ bölgesinin dışında kalan kısımları sıfır olarak almaktadır. Canny algoritması temelde kenar noktalarını maksimize eden f filtresini bulmaya çalışır. Bunun için Gauss fonksiyonunun türevinden faydalanılır. Gauss fonksiyonunu ($G(x)$) şu şekilde ifade edersek:

$$G(x) = e^{-\frac{x^2}{2\sigma^2}} \quad (5.6)$$

Fonksiyonun x 'e göre türevini aldığımızda:

$$G'(x) = \left(-\frac{x}{\sigma^2}\right)e^{-\left(\frac{x^2}{2\sigma^2}\right)} \quad (5.7)$$

İki boyutlu bir görüntüde Gauss fonksiyonu şu şekilde yazılır:

$$G(x, y) = \sigma^2 e^{-\left(\frac{x^2+y^2}{2\sigma^2}\right)} \quad (5.8)$$















Burada σ standart sapmadır. Canny kenar bulma algoritmasının çalışma aşamaları şu şekilde yazılabilir:

- Görüntüyü (I) oku;
- I görüntüsüne göre tek boyutlu Gauss maskesini (G)oluştur;
- Gauss fonksiyonunun türevini x ve y yönlerinde al ($G(x)$ ve $G(y)$);
- Görüntünün satır (I_x) ve sütunlarına (I_y) Gauss filtresi ile konvolüsyon uygula;
- Yerel maksimum noktalarını tespit et ve bunların dışında kalan bölgeleri ortadan kaldır.

Canny algoritması yerel maksimum yapmış kabartıların tepe noktalarını takip ederek, bu noktaların dışında tüm pikselleri sıfıra ayarlar. Bu işleme maksimum olmayan bölgelerin bastırılması (non-maksimum suppression) denmektedir (Parker 1997).

Bu çalışmada normal ve filtreden geçirilen görüntülere Canny kenar bulma operatörü uygulanmıştır. Uygulama sonrası alınan kenar görüntüleri Tablo 5.4'de gösterilmiştir.


Tablo 5.4 Canny kenar bulma algoritması uygulama sonuçları

	Giriş Görüntüsü		Kenar Haritası (Canny - Dikey)	Kenar Haritası (Canny - Yatay)	Kenar Haritası (Canny - Birleşik)
Filtre Uygulanmamış (Normal)					
Orta Değer Filtre					
Ortalama Filtre (3x3)					
Ortalama Filtre (5x5)					
Ortalama Filtre (7x7)					
Gauss Filtre (3x3)					
Gauss Filtre (5x5)					
Gauss Filtre (7x7)					

Hem CASIA hem de UBIRIS veritabanında yer alan tüm görüntülere uygulanan kenar bulma algoritmaları sonucunda, Gauss 7x7 filtre ve Canny kenar bulma algoritması uygulanmış görüntülerde irisin iç ve dış kenar çizgilerinin daha belirgin ve hatasız (çatallaşma veya kesik çizgi yok) olarak elde edildiği tespit edildiği gözlemlenmiştir. Kenar bulma algoritmalarından alınan tüm görüntülere Hough dönüşümü uygulanarak göz bebeği dış kenar çizgisi ile iris dış kenar çizgilerinin tespit edilmesi işlemi gerçekleştirilmiştir.

Hough Dönüşümü: Resim içerisindeki çizgi, daire gibi geometrik şekillerin tespiti amacıyla geliştirilen Hough dönüşümü aynı yönde ve aynı hat üzerinde yer alan kenar noktalarının birleşiminden oluşan çizgileri oldukça hızlı ve etkili bir şekilde belirler. Kenar bulma operatörleri gibi çalışmaktadır. Özellikle daire gibi geometrik şekillerin tespitinde Hough dönüşümü oldukça başarılıdır.

Hough dönüşümünü daha iyi anlamak için r - c tabanlı bir görüntü uzayında tanımlanan bir çizginin Şekil 5.2'deki gibi gösterildiğini varsayalım (Umbaugh 1999).



Şekil 5.2 Hough dönüşüm görüntü uzayı

Burada p , tanımlanan çizginin orijin noktasına olan uzaklığı, θ ise r aksisi ile çizgiye dik olan p uzaklığı arasındaki açıyı ifade etmektedir. θ açısı -90° ile $+90^\circ$ arasında bir değerdir. p ise 0 ile $n*1/2$ aralığında tanımlıdır. n ise görüntünün büyüklüğüdür.

Hough dönüşüm algoritması 3 aşamada gerçekleştirilmektedir.

- p ve θ ile Δp ve $\Delta \theta$ üzerinde istenen artış oranını belirle ve bunları nicelendir (quantization)


- Her bir nokta için (bu noktalar kenar bulma operatörleri ile belirlenmiştir) r ve c değerlerini aşağıda verilen çizgi denkleminde yerine koy. Daha sonra θ 'nın her bir değeri için p yi bul.
- Elde edilen her $p-\theta$ çifti için $r-c$ uzayında çizgi koordinatını kaydet.

Hough dönüşüm işlemi tamamlandığında sürekli hat şeklinde yer alan çizgiler elde edilmiş olur. Bununla birlikte dairesel çizgilerin belirlenmesinde dairesel Hough dönüşümü (circular Hough transform) kullanılmaktadır. Normal dönüşümden farklı olarak bu algorithmada dairenin merkez noktası (x,y) ve yarıçap (r) işleme girmektedir. Dairesel Hough dönüşümünün denklemi (5.9) ve (5.10)'deki gibidir (Daugman 1993, 2001, 2003).

$$X=Cx+ r \cos \theta \quad (5.9)$$

$$Y=Cy+ r \sin \theta \quad (5.10)$$


Hough dönüşümü işlemi sonrasında Şekil 5.3'de gösterildiği gibi kenarları tespit edilmiş CASIA ve UBIRIS iris görüntüleri elde edilmiştir.



Şekil 5.3 Kenarları tespit edilmiş iris görüntüsü a) CASIA b)UBIRIS


Uygulama sırasında bazı güçlüklerle karşılaşmıştır. Karşılaşılan en büyük zorluk, özellikle irisin dış kenarının bulunması sırasında yaşanmıştır. Veritabanından alınan bazı göz görüntülerinde iris bölgesi ile gözakı arasındaki kontrast farkının yeterli seviyede olmaması, görüntüde yer alan piksellerin açıklık-koyuluk ve komşuluk durumlarına göre işlem yapan kenar bulma algoritmalarının kenarları

yanlış tespitine neden olmaktadır. Bu güçlüğün aşılması için veritabanında yer alan görüntüler analiz edilmiş ve deneme-yanılma metoduyla uygun bir eşik değeri tespit edilmiştir. Bununla birlikte göz bebeği ve irisin göz bebeği merkez noktasına olan uzaklıkları (yarıçap) algoritma içerisinde birer parametre olarak girilerek kenar çizgisi tespitinin daha doğru olarak gerçekleştirilmesi sağlanmıştır. Şekil 5.4’de iris sınır çizgileri yanlış tespit edilmiş göz görüntüleri gösterilmiştir.




Şekil 5.4 Kenarları yanlış tespit edilmiş iris görüntüsü a) CASIA b)UBIRIS

Aynı iris görüntülerinin parametreleri (eşik değeri, göz bebeği ve iris yarıçapı) değiştirilerek yeniden işleme sokulmuş ve doğru olarak iris sınır çizgileri tespit edilmiştir. Şekil 5.5’de bu görüntüler verilmiştir.




Şekil 5.5 Kenarları doğru tespit edilmiş iris görüntüsü a) CASIA b)UBIRIS

Kartezyen – Polar dönüşüm işlemi yapılmadan önce görüntüler incelenmiş ve özellikle üst kirpik gürültülerinin iris bölgesi üzerine çok fazla gelmiş olduğu fark edilmiştir. Bunun tanıma aşamasında hatalara sebep olacağı düşünülmüştür. Dolayısıyla göz bebeği merkez noktası üzerinde yer alan bölge atılarak işleme konulmamıştır. Merkez noktanın altında kalan kısımda alt kirpik gürültülerinin atılması için bir sınır değeri (CASIA görüntüleri için 70 piksel, UBIRIS görüntüleri için 40 piksel) belirlenmiştir. Şekil 5.6’da alt ve üst kirpik gürültüleri atılmış iris görüntüleri gösterilmiştir.



Şekil 5.6 Alt ve üst kirpik gürültüleri atılmış iris görüntüsü a) CASIA b)UBIRIS

İris bölgesinin sınır çizgileri elde edildikten sonra iris bölgesinin ayrıştırılması işlemi gerçekleştirilmiştir. Bu amaçla, Kartezyen – Polar koordinat dönüşümü uygulanmıştır. Bunun için öncelikle göz bebeğinin merkez noktası tespit edilir. Daha sonra iç dairenin (göz bebeğinin dış kenar çizgisi) yarıçap bilgisi alınır. Dönüşüm sırasında kullanılacak başlangıç noktasının tespiti için açısai değeri ve alınacak iris piksellerinin yatay ve dikey örnek sayısı (bu bilgi alınan iris resminin boyutunu belirler) belirlenir. Tüm bu parametrelere uygun olarak iris bölgesinde bir noktadan başlayarak Kartezyen – Polar dönüşümü gerçekleştirilir. Bu dönüşümde, Daugman tarafından geliştirilmiş lastik tabaka (rubber sheet) yöntemi kullanılmıştır (Daugman 2003). Bu algoritma, göz bebeğinin merkezi referans noktası alınmak suretiyle, belirlenen açısai vektörler iris bölgesi üzerinden geçirilir. Her bir açısai vektörün üzerinde yer alan noktasal veriler alınır ve dikdörtgenin x ve y koordinatlarına yazılarak dönüşüm gerçekleştirilir. Dönüşüm işlemi Şekil 5.7’de şematik olarak gösterilmiştir.



Şekil 5.7 Kartezyen – Polar koordinat dönüşümü

Göz bebeği ile irisin aynı merkez noktasına sahip olmayabilir. Dolayısıyla dönüşüm işleminde alınan noktaların uygulanan açısal değere göre yeniden ölçütlenmesi gereklidir (Masek 2003). Bunun için aşağıdaki denklem (5.11) kullanılmıştır.


$$r' = \sqrt{\alpha} \beta \pm \sqrt{\alpha \beta^2 - \alpha - r_i^2} \quad (5.11)$$

Burada r_i irisin yarıçapıdır. α ve β şu şekilde bulunmaktadır.


$$\begin{aligned} \alpha &= \sqrt{c_x^2 + c_y^2} \\ \beta &= \cos(\pi - \arctan(c_y / c_x) - \theta) \end{aligned} \quad (5.12)$$

Bu denklemde c_x ve c_y göz bebeği ile irisin merkez noktalarını ifade etmektedir. r' ise irisin dış kenar çizgisi ile göz bebeği dış kenar çizgisi arasında kalan yarıçaptır.

Bu dönüşümün en büyük avantajı, görüntülerin alınması sırasında oluşabilecek hataları yok edebilmesidir. Örneğin, tek bir kişiden alınmış iki göz görüntüsünde, aydınlatma şiddetine bağlı olarak göz bebeğinin çapı farklı olabilir. Dolayısıyla, oransal anlamda bir farklılık meydana gelecektir. Bu da öznetelik çıkarımında hatalara sebep olabilir. Şekil 5.8'de dönüşüm öncesi iris görüntüsü üzerinde yer alan noktalar gösterilmiştir. Şekil 5.9'da ise dönüşüm işlemi sonrası elde edilen temiz iris görüntüleri gösterilmiştir.



Şekil 5.8 Hough dönüşüm noktaları eklenmiş iris görüntüsü a) CASIA b)UBIRIS



Şekil 5.9 Dönüşüm sonrası iris bölgesi görüntüsü a) CASIA b)UBIRIS

5.5 Histogram Dönüşümü

Histogram, bir görüntüyü oluşturan piksellerin gri seviyede kaç adet olduğunu gösteren grafikdir. Diğer bir ifadeyle, histogram bir veri setindeki verilerin dağılımını veya başka bir ifadeyle kullanım sıklığını ya da frekansını gösteren tablodur (Umbaugh 1999).

Örneğin gri seviyeli (0..255 arasında piksel değerlerine sahip) 200 elemanlı bir veri kümesi için histogram şu şekilde ifade edilebilir.

Renk Kodu	Tekrarlanma sayısı
0	23
1	18
2	65
...	...
255	3

Histogramlar, çoğunlukla grafiksel olarak gösterilirler. Yatay eksen de gri seviye deęerleri verilirken dikey eksen de bu deęerlerin resim ierisinde tekrarlanma sayısı izilir.

Orijinal bir grntde piksel deęerlerinin birbirine ok yakın olması resmin ok karanlık veya ok parlak olması eklinde yorumlanabilir. Bu, resmin gri seviye yoęunluęunun eřit daęılımının olmaması anlamına gelmektedir. İdeal bir grntde yoęunluk fonksiyonu dzgn daęılımlı olması istenir. Bu durumda resmin histogram deęerlerine bakılır ve ideal resim elde edilmesi amacıyla gri seviye deęerleri 0..255 arasına daęıtılır. Bu iřleme histogram eřitleme (histogram equalization) denir.

Histogram eřitlemenin amacı, parlaklık seviyesi eřit olarak daęıtılan bir grnt oluřturmaktır. Bylece grntdeki detaylar daha belirgin hale gelmiř olur. $n*m$ boyutlarında gri seviyeli bir grnt iin histogram eřitleme iřlemi (5.25)'de verilen denklemle gerekleřtirilir (Umbaugh 1999).


$$N(q) = \text{Max} \{0, \text{Round} [2^L \cdot c(k) / (m \cdot n)] - 1\} \quad (5.25)$$

Burada $N(q)$ histogram sonrası elde edilen yeni grnt piksel deęeri, $c(k)$ ise k seviyesine kadar olan eski gri deęerlerin toplam piksel sayısıdır. *Round* yuvarlama iřlemidir. Histogram eřitleme algoritması řu řekilde iřlem yapar (Umbaugh 1999):

- Resmin histogramı bulunur.
- Histogramdan yararlanılarak kmlatif histogram bulunur. Kmlatif histogram, histogramın her deęerinin kendisinden ncekiler ve kendisinin toplamı ile elde edilen deęerleri ieren grafikdir.

- Kümülatif histogram değerleri yeni resimde olmasını istediğimiz maksimum renk değerleri ile çarpılıp resimdeki toplam nokta sayısına bölünerek normalize edilir.
- Normalize olmuş histogram değerleri ile orijinal resmin renk değerleri güncellenir.

Bu çalışmada iris görüntüsüne öznitelik çıkarımı işlemi uygulanmadan önce histogram eşitleme işlemi uygulanmış ve iris desenindeki özellikler daha belirgin hale getirilmiştir (Şekil 5.10).



Şekil 5.10 Histogram eşitleme uygulanmış iris görüntüsü a) CASIA b)UBIRIS

Histogram eşitleme işlemi, özellikle görüntüde var olan kontrast farklılıklarını ortadan kaldırmakta ve aynı kişiye ait görüntülerin öznitelik vektörlerinin birbirine daha çok benzemesine yardımcı olmaktadır.

5.6 Bölüm Sonuçları

Bu bölümde, iris bölgesinin elde edilmesi amacıyla öncelikle göz bebeğinin dış kenar çizgisi ile irisin dış kenar çizgisi tespit edilmesine yönelik bir çalışma yapılmıştır. Bu amaçla görüntüye filtreler ve kenar bulma algoritmaları uygulanmıştır. uygulama sonucunda Gauss 7x7 filtre ile Canny kenar bulma algoritmasının en iyi sonuç verdiği gözlenmiştir. Kenar haritası belirlenmiş iris görüntülerine Hough dönüşüm algoritması uygulanarak iris sınır çizgileri elde edilmiştir. Yapılan uygulamaların sonucunda görülmüştür ki, bazı görüntülerin kenar

çizgileri doğru olarak tespit edilememektedir. Bunun sebebinin kenar bulma algoritmasında karşıtlık parametrelerinin tam olarak belirlenememesi olarak gözlemlenmiştir. Dolayısıyla giriş görüntülerinin kontrast durumlarının iyi bir şekilde tespit edilmesinin gerekli olduğu sonucuna varılmıştır. Ayrıca veritabanına bağlı olarak göz bebeği dış kenar çizgisi ile iris dış kenar çizgisinin merkeze olan uzaklıkları (yarıçap) algoritma içerisinde birer parametre olarak kullanılarak sınır çizgilerinin tam olarak tespit edilmesi sağlanmaya çalışılmıştır. Bununla birlikte, görüntülerde yer alan ışık kaynağı yansıması, göz kapağı, alt ve üst kirpik gibi gürültülerin atılması işleminin nasıl gerçekleştirileceği araştırılmıştır. Bu aşamada CASIA iris veritabanından alınan görüntülerde çok fazla üst kirpik gürültüsü olduğu tespit edilmiştir. UBIRIS iris veritabanından alınan görüntülerde ise çoğunlukla iris bölgesinin üst kısmında ışık yansımasından kaynaklanan gürültülerin mevcut olduğu gözlenmiştir. Her iki görüntü çeşidinde de, bu gürültülerin atılması için göz bebeği merkez noktası olmak üzere, iris bölgesinin üst kısmı görüntüden ayrıştırılarak atılması teklif edilmiştir. Bu amaçla, her iki veritabanı için farklı piksel sayıları belirlenmiş ve gözbebeği merkez noktasından itibaren belirlenen piksel uzunluğu boyunca aşağı yönde bir sınır çizgisinin çizilmesine karar verilmiştir. Belirlenen piksel uzunluğu CASIA veritabanı için 70, UBIRIS veritabanı için 40 pikseldir. Arada kalan bölge ise kartezyen – polar dönüşümü kullanılarak dairesel halden dikdörtgensel hale dönüştürülmüştür. İşlemin son aşamasında ise elde edilen iris görüntülerine histogram eşitleme uygulanmış ve iris desenlerinin daha belirgin hale gelmesi sağlanmıştır. Daha ilerde de görüleceği gibi bu işlem, iris görüntüsünün özniteliklerinin çıkarılmasında oldukça önemli bir rol oynamaktadır.

6. İRİS GÖRÜNTÜSÜNÜN ÖZİNİTELİKLERİNİN ÇIKARILMASI

Bir görüntüye ait öziniteliklerin analiz edilmesinin amacı görüntü tanıma uygulamaları için gerekli görüntü bilgilerinin elde edilmesidir. Elde edilen bu bilgi görüntü tanıma sistemlerinde karşılaştırma veya sınıflandırma amacıyla kullanılır.

Herhangi bir görüntünün belirgin ve ayırt edici özelliklerinin sayısal olarak ifade edilmesi işlemine özinitelik çıkarımı denilmektedir. Özinitelik çıkarımında görüntünün renk bilgilerine, görüntüde yer alan geometrik şekillere veya bunlar arasındaki ilişkilere bakılır. Bu işlemler yapılırken elde edilecek bilginin vektörel anlamda en az boyutta olması istenir. Böylece karşılaştırma veya sınıflandırma aşamasında çok daha hızlı sonuç alınabilecektir. Özinitelik çıkarımı yapılırken giriş verilerinin hangilerinin daha önemli olduğunu doğru bir şekilde analiz etmek gerekir. Analizin hatalı olarak yapılması verilerin hatalı alınmasına ve dolayısıyla karşılaştırmada yanlış sonuçların alınmasına neden olacaktır.

Özinitelik analizinde kullanılan birçok yöntem vardır. Bu yöntemlerden Gabor dalgacık dönüşümü (Gabor Wavelet Transform) ve ortalama mutlak sapma (Average Absolute Deviation – AAD) yöntemleri bu çalışmada özinitelik çıkarımı aşamasında kullanılmıştır. Bu bölümde, öncelikle bu yöntemler ayrıntılarıyla ele alınmıştır. Ardından, bu yöntemler kullanılarak iris görüntüsünün öziniteliklerinin elde edilmesi amacıyla yapılan çıkarım işlemleri ve alınan sonuçlar verilmiştir.

6.1 Dalgacık (Wavelet) Kodlaması

Özinitelik çıkarımı aşamasında en çok kullanılan yöntemlerden biri de dalgacık dönüşümü yöntemidir. Dalgacık dönüşümünde görüntünün frekans bilgisinin yanında uzaysal (spatial) bilgi de elde edilir. Dalgacık dönüşümü

geleneksel Fourier analizine göre daha etkilidir, çünkü dalgacık dönüşümü yönteminde frekans verisi bölgeselleştirilebilmektedir. Diğer bir deyişle Fourier Dönüşümü ile kıyaslandığında sadece frekans parametrelerine göre değil aynı zamanda skala parametrelerine göre de fonksiyonun dönüşümünü gerçekleştirir (Çankaya ve ark. 2002). İşlemleri frekans uzayının küçük bir bölgesine göre gerçekleştirebilir. Dalgacık dönüşümü matematiksel olarak;

$W(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \cdot \overline{\psi\left(\frac{t-b}{a}\right)} \cdot dt$	(6.4)
---	-------

şeklinde tanımlanır. Bu denklemlerde $a > 0$, $b \in \mathbb{R}$ olmak üzere a , ölçekleme/yayılma katsayısını; b dönüşüm/öteleme katsayısını; $f(t)$ işareti; ψ , dalgacık fonksiyonunu (ana dalgacığı); $W(a,b)$ ise işaretin sürekli dalgacık dönüşümünü belirtir (Wickerhauser 1994).

Eğer $f(t)$ işareti; iki boyutlu ise, dalgacık analizi için 1 tane iki boyutlu $\varphi(x,y)$ ölçekleme fonksiyonu ve 3 tane de iki boyutlu $\psi^y(x,y)$ (yatay), $\psi^D(x,y)$ (dikey) ve $\psi^K(x,y)$ (köşegensel) dalgacık fonksiyonları gereklidir. Bunların her biri, bir boyutlu φ ölçekleme fonksiyonu ve ilgili ψ dalgacık fonksiyonundan elde edilir

Dalgacık dönüşümü giriş görüntüsünü dört alt örneğe böler. Dönüşüm sonucunda elde edilen görüntü, dikey ve yatay yönde alçak geçiren ve yüksek geçiren filtre uygulanmış tek bir görüntüdür. Yüksek geçiren filtrenin sonuçları dalgacık katsayılarını, en son basamaktaki alçak geçiren filtrenin sonuçları ise ölçek katsayılarını oluşturmaktadır. Bu filtreler uygulanırken çoğunlukla tek boyutlu konvolüsyon haritası kullanılır. Ancak son yıllarda iki boyutlu konvolüsyon kullanılarak yapılan dönüşümlere daha sık rastlanmaktadır.

Gabor dalgacık dönüşümü, Gabor filtresini kullanan ve son yıllarda oldukça sık tercih edilen bir öznitelik çıkarım tekniğidir. Özellikle desen analizlerinde tercih edilen bu teknikte, sinüs ve kosinüs fonksiyonları tarafından modüle edilmiş Gauss elemanları fonksiyon olarak kullanılır. Sinüs dalgasının zaman uzayında frekans uzayında olduğu kadar mükemmel bir şekilde lokalize olamamasından dolayı, Gauss


filtresi ile modüle edilmiş bir sinüs dalgası kullanılarak bu dezavantaj ortadan kaldırılır.

Gabor filtresi boyutsal anlamda tek boyutlu veya iki boyutlu görüntülere uygulanabilir. Tek boyutlu bir Gabor filtresinde gerçek (real) ve zahiri (imaginary) özellikli değerler elde edilir. Gauss filtresi ile modüle edilmiş kosinüs sinyali gerçek kısmı, sinüs sinyali ise zahiri kısmı belirtir. Bahsedilen bu gerçek ve zahiri filtreler literatürde çift simetrik ve tek simetrik elemanlar olarak da bilinmektedir. Filtrenin merkez frekansı sinüs ve kosinüs dalgalarının frekansına göre belirlenir. İki boyutlu bir Gabor filtresi ise daha çok iki boyutlu görüntülerde uygulanır. Aşağıdaki denklemde (x,y) boyularındaki bir görüntüye uygulanabilecek iki boyutlu bir Gabor filtresinin denklemi verilmiştir (Masek 2003).

$G(x, y) = e^{-\pi[(x-x_0)^2 / \alpha^2 + (y-y_0)^2 / \beta^2]} e^{-2\pi i[u_0(x-x_0) + v_0(y-y_0)]}$	(6.8)
---	-------

Burada (x_0, y_0) görüntüde konumlanılan pozisyon, (α, β) genişlik ve uzunluk, (u_0, v_0) ise modülasyonu belirtmektedir.

Gabor dalgacık dönüşüm yönteminden elde edilecek vektörün ikili değerler içerecek olmasından dolayı bu vektörün istatistiksel karşılaştırma aşamasında kullanılması daha doğru olacağı tespit edilmiştir. Gabor dalgacık dönüşümü yönteminde, Gabor filtresi kullanılarak görüntüde yer alan her pikselin faz değeri iki bit şeklinde elde edilmiştir. Gabor filtresi sonrasında elde edilen çıkış bilgileri, faz niceleme (phase quantization) işlemi ile ikili (0 ve 1) değerlere dönüştürülmüştür (Daugman 1993). Faz niceleme işleminde tek ve çift simetrik fazör denilen açölçerler yardımıyla her bir giriş desen bilgisinin faz açısı belirlenir. Daha sonra bu faz açısının bulunduğu bölgeye karşılık gelen bitler öznitelik vektörüne eklenir. Şekil 6.1’de CASIA iris veritabanından alınan örnek bir iris görüntüsünün Gabor dalgacık dönüşümü uygulanmış hali gösterilmiştir.



Şekil 6.1 Gabor dalgacık dönüşümü uygulaması

Öznitelik vektörünün büyüklüğü fazör sayısı ile kartezyen – polar dönüşümünde belirlenen yatay ve dikey örnek sayısına göre değişmektedir. Dolayısıyla CASIA iris veritabanından alınan görüntü için öznitelik vektörü $70 \times 140 \times 2 = 19600$ bit uzunluğundadır. UBIRIS veritabanından alınan görüntü için öznitelik vektörü uzunluğu $80 \times 40 \times 2 = 6400$ bittir. Elde edilen bu öznitelik vektörleri karşılaştırma aşamasında Hamming uzaklığı yönteminde kullanılmıştır.


6.3 Ortalama Mutlak Sapma

Öznitelik vektörü elde etmede kullanılan ortalama mutlak sapma yönteminde görüntüde yer alan her bir pikselin, ortalama piksel değerine olan sapma değerinin hesaplanması işlemi gerçekleştirilir (Ma 2002a). Aşağıdaki denklem (6.16) ortalama mutlak sapma değerini hesaplamaktadır.

$$F = \frac{1}{N} \left(\sum_{i=1}^N |a(x, y) - m| \right) \quad (6.16)$$

Bu denklemde N görüntüde yer alan piksel sayısını, m ise görüntüde yer alan tüm piksel değerlerinin ortalamasını ifade etmektedir. $a(x, y)$, (x, y) noktasındaki piksel değeridir.

Ortalama mutlak sapma (OMS) yönteminde ise görüntüler karesel olarak çeşitli boyutlarda pencereler kullanılarak alt görüntülere ayrılmıştır. Her bir alt görüntüye uygulanan OMS işlemi ile her bir alt görüntü için bir öznitelik değeri hesaplanmıştır. Bu öznitelik değerleri artarda eklenerek tek boyutlu bir vektör elde edilmiştir. OMS işlemi Şekil 6.2’de şematik olarak gösterilmiştir.



Şekil 6.2 Ortalama mutlak sapma yöntemi ile öznitelik çıkarımı işlemi

CASIA veritabanından alınan iris görüntülerine 10*10 ve 14*14 boyutlarında pencere uygulanarak alt görüntüler elde edilmiştir. UBIRIS veritabanından alınan iris görüntülerine ise 20*20 ve 10*10 boyutlarında karesel pencere uygulanarak alt görüntülere bölünmüştür. Aşağıdaki tabloda (Tablo 6.1) seçilen alt görüntülerin pencere boyutları ve elde edilen öznitelik vektörlerinin uzunluğu gösterilmiştir.

Tablo 6.1 Alt görüntü ve öznitelik boyutları

Veritabanı	Görüntü Boyutu	Alt görüntü boyutu	Öznitelik vektörü uzunluğu
CASIA	140 x 70	10 x 10	98 byte
		14 x 14	50 byte
UBIRIS	80 x 40	20 x 20	8 byte
		10 x 10	32 byte

6.4 Bölüm Sonuçları

Bu bölümde, bir görüntünün öznitelik analizi için uygulanan yöntemler incelenmiştir. Bu yöntemlerden bir kısmında ikili sayılar içeren öznitelik vektörleri elde edilirken, diğer kısmında gerçek sayılar içeren öznitelik vektörleri elde edilmektedir. Bu çalışmada, karşılaştırma aşamasında hem istatistiksel, hem de yapay zeka yöntemleri kullanılmıştır. Dolayısıyla, hem ikili ve hem de gerçek sayılardan oluşmuş iki farklı öznitelik vektörü elde edilmiştir. İstatistiksel karşılaştırma için Gabor dalgacık dönüşümü iris görüntülerine uygulanmış ve CASIA veritabanından alınan görüntülerden $70 \times 140 \times 2 = 19600$ bit, UBIRIS veritabanından alınan görüntülerden $80 \times 40 \times 2 = 6400$ bit uzunluğunda vektörler elde edilmiştir. Yapay sinir ağları kullanılarak gerçekleştirilecek karşılaştırma için iris görüntüleri çeşitli boyutlarda alt görüntülere bölünmüş ve her bir alt görüntüye ortalama mutlak sapma yöntemi uygulanmıştır. CASIA veritabanından alınan görüntüler 10×10 ve 14×14 boyutlarında alt görüntülere bölünmüş ve 98 ve 50 öznitelik içeren vektörler elde edilmiştir. UBIRIS veritabanından alınan iris görüntüleri ise 10×10 ve 20×20 boyutlarında alt görüntülere bölünmüş, 32 ve 8 öznitelik içeren vektörler elde edilmiştir.

Öznitelik vektörünün boyutu tanıma aşamasında önemli rol oynamaktadır. Çok az eleman içeren bir öznitelik vektörü sınıflandırma işlemlerinde hızı artıracaktır, ancak öznitelik çıkarımı sırasında kaybolan bilgiler daha fazla olacaktır. Aslında öznitelik çıkarımında farklı boyutlarda alt görüntülere bölünmesinin sebebi hız ve kayıp bilgi dengesinin iyi bir şekilde sağlanmasıdır. Uygulama sonuçlarına bakılarak, en iyi alt görüntü pencere boyutu daha doğru tespit edilebilecektir.

7. İSTATİSTİKSEL YAKLAŞIM İLE İRİS TANIMA

Görüntü tanıma, özellikleri belirlenmiş görüntülerin tanıma algoritmaları kullanılarak analiz edilmesi, karşılaştırılması ve sınıflandırılması anlamına gelmektedir. İstatistiksel yaklaşımda tanıma işlemi iki görüntünün karşılaştırılması şeklinde olmaktadır ve bir sınıflandırma yapılmamaktadır. Bu yaklaşımda, tanıma amacıyla görüntülerin benzerlikleri analiz edilir ve benzerlik oranına göre görüntülerin aynı kişiye ait olup olmadığı belirlenir.

İstatistiksel tanıma yaklaşımında kullanılan birçok yöntem mevcuttur. Bunlardan, Hamming uzaklığı (Hamming distance) yöntemi en sık kullanılan tekniktir. Bu bölümde, Hamming uzaklığı yöntemi ayrıntılarıyla anlatılacak ve tez çalışmasında bu yöntemle alınan uygulama sonuçları sunulacaktır.

7.1 Hamming Uzaklığı


Hamming uzaklığı (HU) yöntemi iki görüntü verisi arasında hangi bitlerin aynı olduğunu ölçen istatistiksel bir karşılaştırma yöntemidir. Bu yöntemde giriş görüntülerinde yer alan bitlerin karşılaştırması yapılarak bu iki görüntünün aynı kişiye mi yoksa farklı kişilere mi ait olduğu belirlenir.

0 ile 1 arasında bir değer veren HU yönteminde sonuç değer 0'a yaklaştıkça benzerlik oranı artmaktadır. Yani birebir aynı iki görüntü karşılaştırıldığında sonuç 0 olmaktadır. X ve Y giriş görüntülerinin HU ile karşılaştırılması işlemi aşağıdaki denklemle gerçekleştirilebilir (Daugman 1993).

$HU = \frac{1}{N} \sum_{j=1}^N X_j (XOR) Y_j$	(7.1)
---	-------

Burada N görüntüdeki bit sayısı yani öznitelik vektörünün büyüklüğü, XOR ise lojik operatördür. Giriş görüntülerinde yönsel farklılıkların olması ihtimaline karşı karşılaştırma yapılırken bit kaydırma yöntemi uygulanır. Bu yönsel farklılıklar görüntü alınırken oluşabilmektedir.

Bit kaydırma işlemi yatay yönde yapılır ve genellikle 2-3 bit sağa ve sola kaydırma şeklinde gerçekleştirilir. Kaydırma işlemi sonrası bulunan HU değerleri içerisinde en küçük olanı alınarak yönsel farklılıklardan kaynaklanan hatalar giderilmiş olur. Şekil 7.1’de 2 bit sağa ve sola kaydırma işlemi ile elde edilen HU sonuçları verilmiştir (Masek 2003).



Şekil 7.1 Hamming uzaklığı yönteminde bit kaydırma işlemi

7.2 Hamming Uzaklığı Yöntemi Uygulaması

Bu çalışmada, CASIA ve UBIRIS veritabanlarından alınan iris görüntülerine HU yöntemi ile karşılaştırma işlemi uygulanmıştır. CASIA iris veritabanından alınan bir kişiye ait 7 görüntüden 1 tanesi sisteme tanıtılmış, diğer 6 tanesi ise tanıma aşamasında kullanılmıştır. UBIRIS veritabanından alınan bir kişiye ait 5 görüntüden 1 tanesi sisteme tanıtılmış, diğer 4 görüntü ise tanıma aşamasında test edilmiştir. Bu

karşılaştırma işleminde HU eşik değeri önceden belirlenmiş sınır değerler arasında değiştirilerek her veritabanı için en uygun eşik değerinin tespit edilmesi işlemi gerçekleştirilmiştir. Bu aşamada alınan karşılaştırma sonuçları Tablo 7.1’de gösterilmiştir. HU karşılaştırma aşamasında MATLAB programı kullanılmıştır. Geliştirilen yazılımın ekran görüntüleri Ekler kısmında verilmiştir.


Tablo 7.1 Hamming uzaklığı eşik değeri belirleme sonuçları

Veritabanı	Karşılaştırma Sayısı	HU Eşik Değeri	FAR		FRR	
			Adet	(%)	Adet	(%)
CASIA	612 (102*6)	0,30	9	1,47	85	13,88
		0,35	21	3,43	27	4,41
		0,40	28	4,58	3	0,50
		0,45	64	10,45	1	0,16
UBIRIS	480 (120*4)	0,20	24	5,00	98	20,41
		0,25	45	9,37	56	11,66
		0,30	63	13,13	11	3,30
		0,35	103	21,45	6	1,25

Uygulama sonuçları analiz edildiğinde (Tablo 7.1) CASIA veritabanı için en uygun eşik değerin 0.4, UBIRIS veritabanı için en uygun eşik değerin 0.3 olduğu belirlenmiştir. Sistemde, eğer HU değeri bu eşik değerin altına inememişse, bu durum karşılaştırmaya giren iris görüntüsünün veritabanında kayıtlı olmadığı anlamına gelmektedir. Bununla birlikte, iki veya daha fazla HU değeri belirtilen eşik değerin altında ise bu durumda en küçük olan değer giriş değeri ile eşleşmiş demektir.

Karşılaştırma sonucunda bulunan en küçük değer veritabanında kayıtlı başka birine ait iris görüntüsüne ait olduğu tespit edilmesi sistemin kişiyi yanlış kabul ettiği (False accept – FA) anlamına gelmektedir. Bunun tersine, giriş iris görüntüsünün eşik değerin altına inemediği tespit edilirse, bu durumda da kişi sistem tarafından

yanlış olarak reddedilmiş (False Reject – FR) demektir. Aşağıdaki grafiklerde (Şekil 7.2) çeşitli iris görüntüleri için alınan karşılaştırma sonuçları verilmiştir.



Şekil 7.2 Hamming uzaklığı değerleri (CASIA ve UBIRIS)

HU yöntemi CASIA ve UBIRIS verileri üzerinde uygulanmış ve sistemin performansı değerlendirilmiştir. Yukarıdaki grafikte CASIA veritabanında yer alan 70 numaralı kişinin HU değeri eşik değeri olan 0,4'ün altında (0,31) olduğu görülmektedir. Aynı şekilde UBIRIS veritabanında yer alan 22 numaralı kişinin HU değeri eşik değeri olan 0,3'ün altında (0,25) olduğu grafikten anlaşılmaktadır.

7.3 Bölüm Sonuçları

Bu bölümde istatistiksel karşılaştırma yöntemlerinden biri olan Hamming uzaklığı yöntemi kullanılarak iris tanıma işlemi gerçekleştirilmiştir. Bunun amacı yapay zeka yöntemleri ile doğrulama oranı karşılaştırması yapılmak istenmesidir. Doğrulama oranları incelendiğinde, UBIRIS veritabanından alınan iris görüntülerinin CASIA görüntülerine oranla tanımda daha yüksek hata oranı sahip olduğu görülmektedir. Bunun sebebinin veritabanında yer alan görüntülerin daha fazla gürültülü (yetersiz ışık, ışık yansımaları, net olmama v.b.) görüntü olmaları söylenebilir. Bununla birlikte, Hamming uzaklığı yönteminde kullanılan eşik değerinin tam olarak tespit edilmesinin güçlüğü de hata oranını artırdığı görülmüştür.

Alınan sonuçlara bakıldığında, çok fazla gürültü (kirpik, gözkapağı, ışık yansıması v.b.) içeren iris görüntülerinin tanınmadığı gözlenmiştir. Bu durumun sebebinin, daha önce de belirtildiği gibi istatistiksel yöntemin birebir karşılaştırma yapmasından kaynaklandığı tespit edilmiştir. İstatistiksel yöntemin tam ve net iris görüntüleri için daha uygun olduğu, gürültülü iris görüntüleri için farklı yöntemlerin aranması gerektiği öngörülmüştür. Gerçekte, tam ve net bir iris görüntüsünün alınmasının zor ve pahalı bir sistem gerektirdiği tespit edilmiştir. Dolayısıyla yapay zeka yöntemlerinin bu aşamada daha etkili olacağı düşünülmüştür. UBIRIS veritabanından alınan iris görüntülerinin CASIA görüntülerine oranla daha yüksek hata oranı ile tanındığı görülmektedir. Bunun sebebinin veritabanında yer alan görüntülerin daha fazla gürültülü (yetersiz ışık, ışık yansımaları, net olmama v.b.) görüntü olmaları söylenebilir. Ayrıca Hamming uzaklığı eşik değerinin tam olarak tespit edilmesinin güçlüğü de hata oranını yükseltmektedir.

8. YAPAY SINIR AĞLARI İLE İRİS TANIMA

Yapay zeka (YZ), bir bilgisayarın ya da bilgisayar denetimli bir makinenin, genellikle insana özgü nitelikler olduğu varsayılan akıl yürütme, anlam çıkartma, genelleme ve geçmiş deneyimlerden öğrenme gibi yüksek zihinsel süreçlere ilişkin görevleri yerine getirme yeteneği olarak tanımlanmaktadır (Nabiyev 2005).

YZ konusunda ilk çalışma McCulloch ve Pitts tarafından 1940'lı yıllarda yapılmıştır. Bu araştırmacılar 1943 yılında yapay sinir sisteminin ilk matematiksel modelini geliştirmişlerdir (McCulloch ve Pitts 1943). Çalışmalarında herhangi bir hesaplanabilir fonksiyonun sinir hücrelerinden oluşan ağlarla hesaplanabileceğini göstermişlerdir. İlerleyen yıllarda bir çok araştırmacı YZ üzerine çalışmalar yapmış ve çeşitli YZ teknikleri geliştirmişlerdir. YZ araştırmalarının temel amacı insan gibi düşünen ve davranan ideal sistemleri oluşturmaktır. Bunun zorluğu fark edilince çalışmalar daha çok rasyonel düşünen ve davranan sistemler üzerine yoğunlaşmıştır.

Bu bölümde, YZ teknikleri içerisinde özellikle sınıflandırma problemlerinde tercih edilen Yapay Sinir Ağları (YSA) irdelenerek, YSA yönteminin teknik özellikleri, yapısı, kullanım alanları, avantaj ve dezavantajları, öğrenme algoritmaları ve YSA modelleri anlatılmıştır. YSA modellerinden, Çok katmanlı perseptron (Multi Layered Perceptron - MLP), Modüler sinir ağı (Modular Neural Network – MNN) ve Elman sinir ağı modelinin iris tanıma amacıyla kullanılmıştır. Çalışmada alınan uygulama sonuçları tablo halinde sunulmuştur.

8.1 Yapay Sinir Ağları (YSA)

Yapay Sinir Ağları, insan beyninin işleyişini taklit ederek yeni sistem oluşturulmaya çalışılan yaklaşımlardır. Beynimizdeki biyolojik sinir hücrelerinin

yapısı temel alınarak YSA yapısı oluşturulur. YSA’nda aynen beynimizde olduğu gibi öğrenme ve öğrenilen bilgilere göre karar verme mekanizmaları bulunur (Elmas 2003, Öztemel 2003, Sağiroğlu ve ark. 2003, Allahverdi 2002).

YSA alanında yapılan ilk çalışmalar McCulloch ve Pitts tarafından yapılmıştır (McCulloch ve Pitts 1943). Bu araştırmacıların yayınladığı “Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap” başlıklı makalede YSA konusunda ilk adım atılmıştır. İlerleyen zamanlarda Hebb (1949), Rosenblatt (1958), Widrow ve Hoff (1960), Hopfield (1982), Kohonen (1982), Rumelhart ve ark. (1986) ve daha birçok araştırmacı farklı YSA öğrenme algoritmaları geliştirmişlerdir.

Yapay Sinir Ağları, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden (nöron) meydana gelmektedir. Temel olarak bir YSA’nın görevi, kendisine gösterilen giriş setine karşılık bir çıkış seti belirlemektir. Bunu gerçekleştirebilmek için ağ, ilgili problemin örnekleri ile eğitilerek (öğrenme), o problemle ilgili istenenleri çözebilme yeteneğine kavuşturulur. Literatürde birçok öğrenme algoritması ve sinir ağı modeli mevcuttur. Bu algoritmalar ve modeller bu bölümde ayrıntılı olarak anlatılacaktır.

8.1.1 YSA’nın genel özellikleri

YSA’nın karakteristik özellikleri uygulanan ağ modeline göre değişebilmektedir. Bu değişik ağ modelleri ilerleyen kısımlarda anlatılacaktır. Genel karakteristik özellikler şunlardır (Öztemel 2003, Sağiroğlu ve ark. 2003, Allahverdi 2002):

- YSA öğrenme gerçekleştirirler. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.

- Bilgi geleneksel yöntemlere göre farklı biçimde saklanır. Bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Bir veritabanı yoktur.
- Görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.
- Görüntü tanıma ve sınıflandırma yapabilirler. Kendisine örnekler halinde verilen görüntüleri işleyerek öğrenme yapar ve daha sonra gelen bir örneğin hangi sınıfa dahil olduğuna karar verebilir.
- Kendi kendine organize olma yetenekleri vardır. Örnekler ile kendisine gösterilen durumlara adapte olup yeni olayları sürekli olarak öğrenebilmektedir.
- Eksik bilgi ile çalışabilir. YSA eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmamasına rağmen sonuç üretebilir.
- Hata toleransına sahiptir. Eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmasını sağlar.
- Dağıtık belleğe sahiptirler. YSA'nda bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir.
- Sadece sayısal bilgi ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin sayısal bilgilere çevrilmesi gerekir.

8.1.2 YSA'nın dezavantajları

YSA'nın birçok önemli dezavantajı vardır (Sağıroğlu ve ark. 2003, Haykin 1999). Bunlar:

- Probleme uygun ağ yapısının belirlenmesi zor bir süreçtir. Genellikle ağ yapısı belirlenirken deneme-yanılma metodu kullanılır. Bu da bazen çok uzun zaman almaktadır. Eğer problem için uygun ağ yapısı belirlenemezse,

çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusu olmaktadır. Aynı zamanda bu durum bulunan çözümün en doğru çözüm olduğunun garantisini de vermez.

- Bazı ağlarda ağın parametre değerlerinin (örneğin öğrenme katsayısı, hücre sayısı v.b.) belirlenmesinde bir kural olmaması, çözümlere ulaşmada sorun oluşturur. Bu değerler kullanıcının tecrübesine bağlıdır ve her problem için farklı etkenlere dikkat etmek gerekir.
- Problemin ağa gösterimi çok önemli bir etkidir. YSA sadece sayısal bilgilerle çalışır ve problemin sayısal değerlere çevrilmesi gerekmektedir. Bu da kullanıcının becerisine bağlıdır. Uygun bir gösterim mekanizmasının kurulmamış olması problemin çözümünü engelleyebilir.
- Ağın eğitiminin ne zaman bitirileceğine dair kesin kurallar yoktur. Eğitimde hata toleransının belli bir değerin altına inmesi eğitimin tamamlanması için yeterli görülmektedir. Fakat neticede en iyi öğrenmenin gerçekleştiği söylenememektedir.

8.1.3 YSA'nın temel yapısı

YSA sinir hücrelerinin bir araya gelmesiyle oluşurlar. Tabi bu işlem rasgele olarak yapılmamaktadır. Genelde hücreler, 3 katman halindedir ve her katman içinde paralel halde ağ oluştururlar. Bu katmanlar;

- Giriş Katmanı: Bu katmandaki hücreler giriş bilgilerini gizli katmana ulaştırmakla görevlidir.
- Gizli Katman: Giriş katmanından gelen bilgiler işlenerek çıkış katmanına gönderilir. Bir ağda problemin durumuna göre, birden fazla gizli katman olabilmektedir.
- Çıkış Katmanı: Bu katmandaki hücreler gizli katmandan gelen bilgiyi çıkış katmanına gönderirler. Üretilen çıkışlar problemin çözümünü içermektedir.

Gizli katman sayısının ve hücre sayısının belirlenmesi: YSA'nın tasarımı sırasında ağdaki katman sayısına ve katmanlardaki hücre sayısına doğru bir şekilde karar vermek sistemin performansı açısından oldukça önemlidir. Birçok problemde iki veya üç katmanlı bir ağ istenen sonuçları üretebilmektedir (Haykin 1999). Katmanlar, hücrelerin aynı doğrultu üzerinde bir araya gelmeleriyle oluşmaktadır. Katmanların farklı şekilde birbirleriyle bağlanmaları ile farklı ağ yapıları oluşmaktadır. Giriş ve çıkış katmanlarının sayısı da, problemin yapısına göre değişmektedir (Freeman ve Skapura 1991).


Ağın bir diğer yapısal özelliği ise her bir katmandaki hücre sayısıdır. Gizli katmandaki hücre sayısının tespitinde de genellikle deneme-yanılma yöntemi kullanılır. Bunun için takip edilecek yöntem, başlangıçtaki rasgele olarak belirlenen hücre sayısını istenilen performansa ulaşıncaya kadar arttırmak veya tersi şekilde istenilen performansın altına inmeden azaltmaktır. Gizli katmanda kullanılacak hücre sayısı ne kadar az olursa eğitim işlemi de o kadar kısa sürmektedir. Çünkü hesaplama adım sayısı kısalmaktadır. Aynı zamanda hücre sayısının az olması sinir ağının “genelleme” yeteneğini arttırırken, gereğinden fazla olması ağın verileri ezberlemesine neden olmaktadır. Bununla birlikte hücre sayısının gereğinden az olması, ağın giriş verilerini öğrenememesi gibi bir sorun oluşturmaya neden olabilir.

Gizli katman hücre sayısının belirlenmesinde kullanılan bir diğer yöntem ise tecrübeye dayalı (heuristic) arama yöntemidir. Tecrübeye dayalı arama yönteminde arama doğruluğu, son arama adımında denenen mimari ile bir önceki arasındaki arama kriteri ile belirlenir (Breiman 1994). Bununla birlikte ağın genel hata oranına bakılarak da ağ yapısı belirlenmesi işlemi gerçekleştirilebilmektedir. Ağdaki gizli katman sayısı arttıkça ağırlık sayısı da artacağından dolayı ağ yapısı karmaşık bir hale gelecektir. Bu yöntemde, her bir modelin en uygun olabilirlik fonksiyonunu bulunur. Olabilirlik fonksiyonunun değeri en küçük olan model, en uygun model olarak seçilmektedir (Schwarz 1978).

Yapılan son çalışmalarda (Dodd 1990, Kitano 1990, Happel 1992, Nan ve ark. 2003, Boers ve Kuiper 1992) sinir ağı yapısının belirlenmesinde genetik algoritmaların oldukça etkili olduğu görülmüştür. Genetik algoritmaların optimizasyon problemlerinde ne denli iyi performans verdikleri bilinmektedir. Olasılıksal karakterleri ve çoklu mümkün çözümleri araştırma gibi özelliklere sahip olan GA'ların sinir ağının yapısının belirlenmesinde çok iyi performans vereceği beklenmektedir.

8.1.4 Yapay sinir ağı hücresi

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli Şekil 8.1'de görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlinear) bir fonksiyondur (Haykin 1999).



Şekil 8.1 Temel yapay sinir ağı hücresi

Burada b bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Nöronun matematiksel modeli şöyledir.

Çıkış,

$$y = f(w.x + b) \quad (8.2)$$

şeklinde nöron çıkışı hesaplanır. Buradaki w ağırlıklar matrisi, x ise girişler matrisidir. n giriş sayısı olmak üzere;

$$w = w_1, w_2, w_3, \dots, w_n \quad (8.3)$$

$$x = x_1, x_2, x_3, \dots, x_n \quad (8.4)$$

şeklinde yazılabilir. Buradan;

$$net = \sum_{i=1}^n w_i x_i + b \text{ ve } y = f(net) \quad (8.5)$$

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (8.6.)$$

şeklinde de yazılabilir. Yukarıdaki formülde görülen f aktivasyon fonksiyonudur. Genelde lineer olmayan olan aktivasyon fonksiyonunun çeşitli tipleri vardır. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse sıfır, sıfırdan daha büyük bir değer ise net çıkışında $+1$ değeri verir. Eşik aktivasyon fonksiyonunun -1 ile $+1$ arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse $+1$, sıfırdan küçükse -1 , sıfıra eşitse sıfır değerini verir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir (Bishop 1995).

$$f(x) = x \quad (8.7)$$

şeklinde ifade edilir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir. Böylece daha

sonraki bölümlerde görülecek olan geri yayımlı ağlarda kullanmak mümkün olabilmektedir (Bishop 1995).

Fonksiyonu tanımlarsak,

$$f(x) = \text{lojistik}(x) = \frac{1}{1 + \exp(-\beta x)} \quad (8.8)$$

şeklinde ifade edilir. Buradaki β eğim sabiti olup genelde bir olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir (Haykin 1999, Bishop 1995).

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (8.9)$$

Bu aktivasyon fonksiyonlarından başka fonksiyonlar da vardır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir (Haykin 1999, Bishop 1995).

8.1.5 YSA öğrenme algoritmaları

Bugüne kadar geliştirilmiş birçok öğrenme algoritması mevcuttur. Bunların büyük çoğunluğu matematik tabanlıdır ve ağırlıkların güncelleştirilmesi için kullanılırlar. Mevcut öğrenme algoritmaları Hebb (1949), Delta, Kohonen (1982) ve Hopfield (1982) olmak üzere 4 öğrenme algoritması temel alınarak geliştirilmiştir (Sağıroğlu ve ark. 2003, Haykin 1999, Bishop 1995).

Hebb Öğrenme Kuralı: Bilinen en eski öğrenme kuralıdır. Hebb'in (1949) geliştirdiği bu öğrenme algoritması, "bir nöron diğer bir nörondan giriş alıyorsa ve

her iki nöronunda aktif ise (matematiksel olarak aynı işarete sahip ise), nöronlar arasındaki ağırlık kuvvetlendirilir” esasına göre çalışır. Diğer bir deyişle, bir hücrenin kendisi aktif ise, bağlı olduğu hücreyi aktif yapmaya çalışır. Ters durumda pasif yapmaya çalışır. Diğer birçok öğrenme kuralı bu felsefeyi baz alarak geliştirilmiştir.

Delta Öğrenme Kuralı: Bu kural Hebb kuralının biraz daha geliştirilmiş şeklidir. Bu kurala göre, beklenen çıkış ile gerçekleşen çıkış arasındaki farklılığı azaltmak için ağırlık değerleri sürekli değiştirilmelidir. Ağın ürettiği çıkış ile üretilmesi beklenen çıkış arasındaki hatanın karelerinin ortalamasını en aza indirmek hedeflenmektedir. Hata aynı zamanda bir katmandan bir önceki katmanlara geriye yayılarak azaltılır. Bu kural geri yayılım, Widrow-Hoff (1960) veya en küçük ortalama karesel öğrenme kuralı olarak da bilinir.

Kohonen Öğrenme Kuralı: Kohonen (1982) tarafından geliştirilmiş olan bu kurala göre ağın hücreleri ağırlıklarını değiştirmek için birbirleriyle yarışır. En büyük çıkışı veren yani kazanan hücre ağırlığını değiştirir. Bu, o hücrenin diğer hücrelere karşı daha kuvvetli hale gelmesi anlamını taşır. Kohonen kuralı hedef çıkışa gereksinim duymaz ve dolayısıyla danışmansız bir öğrenme metodudur.

Hopfield Öğrenme Kuralı: Bu kural da Hebb kuralına benzer. Hopfield (1982) kuralında hücreler arası bağlantıların ne kadar kuvvetlendirilmesi veya zayıflatılması gerektiği belirlenir. Eğer beklenen çıkış ve girişlerin ikisi de aktif/pasif ise öğrenme katsayısı kadar ağırlık değerleri kuvvetlendirilir/zayıflatılır. Öğrenme katsayısı 0 ile 1 arasında bir değer alır.

8.1.6 Performans fonksiyonunun seçimi

Performans fonksiyonu YSA'nın öğrenme performansını ölçmede kullanılan bir ölçüttür. (Rumelhart ve ark. 1986). İleri beslemeli ağlarda genellikle ortalama

kareesel hata (Mean Square Error - MSE) performans fonksiyonu olarak kullanılır. MSE fonksiyonu istenen sonuç ile hesaplanan sistem çıkışı arasındaki farkın kareleri toplamının ortalaması olup aşağıdaki formülle hesaplanır:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i' - y_i)^2 \quad (8.10)$$

Burada y , istenen çıkış değerini; y' ise sistem tarafından hesaplanan çıkış değerini ifade eder. N ise çıkış sayısını belirtmektedir. Hatanın sıfıra yaklaşması istenen çıkış değerine yakın çıkış değeri elde edilmiş olması demektir.

İleri beslemeli ağlarda kullanılan bir diğer performans fonksiyonu toplam kareesel hata (Sum Square Error – SSE)'dir (Sağıroğlu ve ark. 2003). 8.11'de verilen denklem kullanılarak toplam kareesel hata hesaplanır:

$$SSE = \sum_{i=1}^N (y_i' - y_i)^2 \quad (8.11)$$

Bunlardan başka performans fonksiyonu olarak kullanılan bir diğer hata hesaplama yöntemi ortalama kareesel hatanın karekökü (Root Mean Square – RMS) fonksiyonudur ve aşağıdaki formül ile hesaplanır:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i' - y_i)^2} \quad (8.12)$$

Sağıroğlu ve ark. (2003) 'na göre performans fonksiyonuna ağırlık biaslarının ve ağırlıklarının kareleri toplamının ortalama değerini ifade eden bir terim eklenerek genelleştirme daha da iyileştirilebilir. Böylece ağ daha hassas hale getirilir ve ağırlık eğitimi kümesi haricindeki veriler için sağlıklı bir genelleme yapmasını engelleyebilir. Bunun yanı sıra genelleştirmeyi iyileştirmek için kullanılan yöntemlerden birisi de öğrenmeyi erken sonlandırmaktır (Sağıroğlu ve ark. 2003). Bu yöntemde, YSA'ya uygulanacak veri kümesi üç bölüme ayrılır. İlk küme YSA'nın eğitiminde kullanılarak ağırlıkların, biasın ve eğimin güncelleştirilmesinde kullanılır. İkinci bölüm veri kümesi ise doğrulama verisi olarak kullanılır. Eğitim

süresince, eğitim verilerinden hesaplanan hata oranı düştüğü gibi test veri kümesine ait hata da normal şartlarda düşer.

8.1.7 YSA modelleri


Yapay sinir ağları yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde modellenenebilir.

İleri beslemeli modelde, bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir (Özbay ve Karlık 2001). Katmanlardaki hücrelerin sayısı tamamen uygulanan probleme bağlıdır. Hücreler bir katmandan diğer bir katmana bağlantı kurarlarken, aynı katman içerisinde bağlantıları bulunmaz. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan gizli katmandaki hücrelere iletir. Giriş bilgileri, gizli ve çıkış katmanında işlenerek ağ çıkışı belirlenir (Türkoğlu ve Arslan 1996). İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcı (Multi Layer Perseptron – MLP), modüler sinir ağları (Modular Neural Networks – MNN), vektör kuantalamalı öğrenme (Learning Vector Quantization – LVQ), radyal tabanlı fonksiyon (Radial Basis Function – RBF) ve olasılık tabanlı (Probabilistic Neural Network – PNN) sinir ağları verilebilir.

Geri beslemeli sinir ağı modelinde ise çıkış katmanındaki ve gizli katmandaki çıkışlar, giriş katmanındaki hücrelere veya bir önceki gizli katmanlara geri besleme şeklinde iletilir (Öztemel 2003). Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu tip sinir ağlarının hafızaları dinamiktir ve çıkış hem anlık hem de önceki girişleri yansıtır. Bundan dolayı, bu tip sinir ağı modeli önceden tahmin uygulamaları için daha uygundur (Haykin 1999). Geri beslemeli ağ modeline örnek olarak Hopfield, adaptif rezonans teori (ART), kendi kendine organize olabilen harita (Self Organizing Map – SOM) ağları, Elman ve Jordan ağları verilebilir.

8.2 Çok Katmanlı Perseptron (MLP) Modeli

Çok katmanlı perseptron (MLP), giriş, gizli ve çıkış katmanından oluşmuş ileri beslemeli bir ağıdır (Şekil 8.2) (Haykin 1999). Katmanlardaki nöronlar arasında ve bir katmandan önceki katmana geriye doğru bağlantı yoktur.



Şekil 8.2 Çok katmanlı perseptron ağ yapısı

Herhangi bir katmandaki j . birime gelen toplam giriş, önce k_i katmandaki birimlerin y_i çıkışlarının (1. katman için girişlerin) bağlantılar üzerindeki w_{ij} ağırlıkları ile hesaplanmış bir ağırlıklı toplamıdır.

$$x_j = \sum w_{ij} \cdot y_i \quad (8.13)$$

Birimin çıkışı, bu toplam girişi bir lineer olmayan fonksiyondan geçirerek belirlenir. Bunun için birçok fonksiyon teklif edilmiştir. Ancak en çok kullanım göreni aşağıdaki sigmoid fonksiyondur.

$$y_j = \frac{1}{1 + e^{-x_j}} \quad (8.14)$$

Bu fonksiyon yakınsama şartını, yani “her birimin çıkışı, toplam girişin devamlı artan, türevi sınırlı bir fonksiyonu olmalıdır” şartını sağlar. Bu fonksiyon y_j çıkışını 0 ve 1 değerleri arasına sınırlar.

MLP’de, ilk katmana bir giriş vektör uygulanır. Daha sonra giriş ve 1. katman arasındaki ağırlıklar yardımıyla 1. katmandaki her birimin aldığı toplam giriş belirlenir. Her birim girişini bir lineer olmayan fonksiyondan geçirerek bir sonraki katmana göndereceği çıkış işaretini belirler. Bir katmandaki tüm birimlerin durumları paralel olarak belirlenir. Bu işlem çıkış katmanındaki birimlerin durumları belirleninceye kadar sırayla tekrar edilir.

MLP ağıнын eğitilmesi danışmanlı öğrenmeye bir örnek oluşturabilir. Bu ağda girişe bir giriş vektörü uygular ve bir çıkış vektörü elde eder. Daha sonra bu çıkış vektörünü istenilen bir “hedef” vektörü ile karşılaştırır ve bu iki vektör arasındaki fark en küçük olacak şekilde ağ ağırlıklarını ayarlar. Amaç her giriş vektörü için, ağın üreteceği cevabın istenilen çıkış vektörünün aynısı (veya yeterince yakını) olmasını sağlayan bir ağırlık kümesi bulmaktır.

Eğitme iki adımlı bir işlemdir. İlk adımda bir giriş vektörü uygulanır, ağ içindeki her birim için toplam giriş ve çıkış hesaplanır ve her birimin çıkışı daha sonra ağırlık ayarlamasında kullanılmak üzere saklanır. Çıkış vektörü oluşturulduktan sonra, eğitme işlemi çıkış hatasını hesaplar ve bu hatanın geriye doğru yayılımını sağlar. Birimlerin ağırlıkları bu hata işaretine göre ayarlanır. Bu iki adımlı işlem ağ istenilen cevapları üretinceye kadar, eğitme vektör çiftleri ile tekrar edilir (Bishop 1995, Haykin 1999).

Çıkış katmanını eğitmek bağıl olarak daha basittir. Sorun bir hedef vektörünün olmadığı ara katman ağırlıklarını eğitirken ortaya çıkar. Bunun çözümü, hata işaretinin çıkıştan daha iç katmanlar doğru yayılımını sağlamakla bulunur. Yani bir iç veya ara katman birimi, kendisinden sonraki katmanın hata işaretlerinin ağırlaştırmış toplamı olan bir hata işareti alır. Bu hata işareti her birim ağırlıklarını eğitmek için kullanıldıktan sonra; eğitme işlemi, oluşturulan yeni hata işaretinin daha önceki katmanlara doğru yayılımını sağlar.

Önceden belli, sonlu sayıda giriş-çıkış çifti için, belli bir ağırlık kümesine sahip ağın davranışındaki hata, her çift gerçek ve istenilen çıkış vektörlerini karşılaştırarak hesaplanabilir. E toplam hatası aşağıdaki şekilde tanımlanabilir.

$$E = \frac{1}{2} \cdot \sum_j \sum_k (y_{j,k} - d_{j,k})^2 \quad (8.15)$$

Burada k giriş-çıkış çiftlerinin, j çıkış birimlerinin indisi y bir çıkış biriminin gerçek durumunu, d ise istenen durumunu göstermektedir. Verilen bir giriş-çıkış çifti için hata her ağırlığa göre iki adımda hesaplanır.

Geri yön adımı, her çıkış birimi için $\partial E / \partial y$ büyüklüğünü hesaplayarak başlar. Belli bir k çifti için denklem (8.16) türetilirse ve k indisi yazılmazsa,

$$\frac{\partial E}{\partial y_j} = y_j - d_j \quad (8.16)$$

elde edilir. Daha sonra $\partial E / \partial x_j$ 'yi hesaplamak için aşağıdaki zincir kuralı kullanılabilir.

$$\frac{\partial E}{\partial y_j} = \frac{\partial E}{\partial y_j} \cdot \frac{dy_j}{dx_j} \quad (8.17)$$

dy/dx 'nin değerini bulmak için 8.15 denklemi türetilerek yukarıda yerine konursa,

$$\frac{\partial E}{\partial x_j} = \frac{\partial E}{\partial y_j} \cdot y_j \cdot (1 - y_j) = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \quad (8.18)$$

ifadesi elde edilir. Bu da, j . çıkış birimine toplam giriş büyüklüğündeki (X_j) bir değişimin hatayı nasıl etkilediğini bildiğiniz anlamına gelir. Bu ifade çıkış katmanından bir birimden geriye doğru yayılımı yapılacak hata işaretidir. Bu toplam giriş, alçak katman birimlerinin y_i çıkışlarının bir lineer fonksiyonudur. x_j girişi aynı zamandaki ağırlıkların da bir lineer fonksiyonudur. Dolayısıyla ara katman çıkışlarındaki veya ağırlardaki bir değişimin hatayı nasıl etkileyeceğini hesaplamak kolaydır. i . birimden, j . birime bir w_{ij} ağırlığındaki değişimin hataya etkisi,

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dw_{ij}} = \frac{\partial E}{\partial x_j} \cdot y_i = (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot y_i \quad (8.19)$$

ifadesinden bulunabilir. Sondan bir önceki katmandaki i . birimin çıkışı için, i 'nin J üzerindeki etkisi nedeniyle ortaya çıkan $\partial E / \partial y_i$ katkısı,

$$\frac{\partial E}{\partial y_i} = \frac{\partial E}{\partial x_j} \cdot \frac{dx_j}{dy_i} = \frac{\partial E}{\partial x_j} \cdot w_{ij} \quad (8.20)$$

şeklindedir. Bu şekilde i . birimden çıkan tüm bağlantıları göz önüne alarak,

$$\frac{\partial E}{\partial y_i} = \sum_j \frac{\partial E}{\partial x_j} \cdot w_{ij} = \sum_j (y_j - d_j) \cdot y_j \cdot (1 - y_j) \cdot w_{ij} \quad (8.21)$$

elde edilir. Bu şekilde son katmandaki bu birimler için $\partial E / \partial y$ verildiğinde, sondan bir önceki katmandaki herhangi bir birim için $\partial E / \partial y$ 'nin nasıl hesaplanacağı gösterilmiş olmaktadır. Bu ifade sondan bir önceki katmandaki i . birime gelen hata işaretidir. Daha önceki katmanlarda bu terimi hesaplamak için burada yapılan işlem tekrar edilebilir. Bu olay şematik olarak Şekil 8.8 ve 8.9'da gösterilmiştir.

Ağırlıkları ayarlamak için $\partial E / \partial w_{ij}$ türevsel bilgisi kullanılır. Bu bilgiyi kullanmanın bir yolu ağırlıkları her giriş çıkış çiftinin uygulanmasından sonra değiştirmektir. Bu yöntemin $\partial E / \partial w_{ij}$ türevlerini saklamak için hiç ayrı bellek ihtiyacı göstermemesi gibi bir avantajı vardır. Öte yandan ağırlıkları ayarlamanın bir başka yolu, tüm giriş-çıkış çiftlerinin uygulanması ile elde edilen $\partial E / \partial w_{ij}$ değerlerini toplamak ve daha sonra bu bilgiyi w_{ij} ağırlığının değişiminde kullanmaktır. Eğim azalmasının en basit şekli, her w_{ij} ağırlığını $\partial E / \partial w_{ij}$ değerine orantılı olacak şekilde değiştirmektir.


$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} \quad (8.22)$$

Burada $w_{ij}(n)$ i . birimden j . birime olan ağırlığın hesaplamanın n .adımındaki değerini göstermektedir. ε ise 0 ile 1 arasında (tipik olarak 0,1'ler mertebesinde) değer alan bir kazanç terimidir.

Ağırlık değişimindeki bu yöntem, ikinci türevleri kullanan yöntemler gibi hızlı yakınsamaz, fakat daha basittir ve paralel donanımda lokal hesaplamalar ile kolayca gerçekleştirilebilir. Bu yöntem aşağıdaki şekilde geliştirilebilir.

$$w_{ij} \cdot (n+1) = w_{ij} \cdot (n) - \varepsilon \cdot \frac{\partial E}{\partial w_{ij}} + \alpha \cdot (w_{ij}(n) - w_{ij}(n-1)) \quad (8.23)$$

Burada α ağırlıktaki değişimi önceki değişimin değerine bağlayan bir katsayıdır ($0 < \alpha < 1$). Bu yeni öğrenme denklemi, ε 'nin daha büyük değerlerine imkan sağlayarak yakınsamayı hızlandırır. Geri yayılım algoritmasında çıkışın hesaplanması işlemi ileri yönde gerçekleşir. Ancak eğitim sırasında hatanın bulunması ve değiştirilmesi geri doğru gerçekleştirilir (Şekil 8.3).



Şekil 8.3 Eğitim işlemi

Geri yayılım algoritması uygulamada oldukça sık rastlanan bir algoritmadır. Bu algoritmada, hataların çıkıştan girişe geriye doğru azaltılmaya çalışılmasından dolayı geri yayılım ismini almıştır (Parker 1985).

MLP sinir ağında eğitim aşamasında en sık kullanılan algoritmalar Hızlı Yayılım (Quick-Propagation) ve Eşleştirmeli Eğitim Algoritması (Conjugate Gradient Descent) aşağıda açıklanmıştır. Bu algoritmalar bu çalışmada da kullanılmıştır.

Hızlı yayılım algoritması (Quick-Propagation): Hızlı yayılım algoritması, Newton metoduna dayanan, çok katlı algılayıcıların eğitilmesi için kullanılan ve Newton metoduna dayanan sezgisel bir öğretme algoritmasıdır. Bu algoritmalar optimum çözümü garanti edemeyip sadece ona yakın çözümü bulmaktadırlar. Ayrıca bu algoritmada tecrübeye ve eğitilmiş tahmine dayalı kurallar bulunmaktadır (Fahlman 1988).

Hızlı yayılım algoritmasının sağladığı bazı önemli avantajlar şöyledir (Sağıroğlu ve ark. 2003):

- Herhangi bir tam yöntemin parçası olarak öğrenme amacıyla kullanılabilir.
- Gerçek dünya problemleri için her zaman matematiksel formülasyon kurmak çok kolay olmayabilir. Bu basitleştirme sonucu oluşan hata, bir hızlı yayılım algoritmasının sağladığı en iyi çözümün sahip olduğu hatadan daha büyük olabilir.

Hızlı yayılım algoritmasında çözümden fazla uzaklaşmaksızın mümkün olan en büyük adımlarla kısa sürede çözüme ulaşmak arzu edilir (Fausett 1994). Bu algoritmada iki geleneksel yaklaşım birleştirilerek çözülmüştür (Sağıroğlu ve ark. 2003). İlk yaklaşımda, hesaplamanın geçmişteki durumu ile bağlantılı genel veya her bir ağırlık için ayrı sezgilere dayanan dinamik olarak ağırlıkların ayarlanır. Diğer yaklaşımda ise her bir ağırlığa göre hatanın ikinci türevi kullanılır. Bunun yanı sıra bu algoritmada her bir ağırlık için hata eğrisi kolları yukarı doğru açık bir parabole yaklaştırılır. Hata eğrisinin açılma değişimi, diğer tüm ağırlıkların değişiminden etkilenmez (Sağıroğlu ve ark. 2003). Bahsedilen bu parabol, birbirinden bağımsız her bir ağırlık için mevcut ve önceki hata eğimleri ve bu eğimlerin ölçüldüğü noktalar arasındaki değişim kullanılarak belirlenir. Bu işlemin ardından algoritma doğrudan bu parabolün minimum noktasına dallanır. Hızlı yayılım algoritması üzerinde yapılan performans testlerine bakıldığında diğer tekniklere oranla, genelde daha iyi olduğu gözlenmektedir (Sağıroğlu ve ark. 1999). Bu algoritma giriş verilerinde mevcut olan gürültülerin fazla olduğu durumlarda çok daha iyi çalışmaktadır.

Bu algoritmada ağırlık hızlandırma ve kırılması ihmal edilerek $t-1$ den t 'ye kadar ağırlıklardaki değişim eşitlik (8.24) ile ifade edilir (Fausett 1994).

$$\Delta w(t) = \varepsilon L(t) + \alpha Q(t) \quad (8.24)$$

Burada ε , öğrenme katsayısıdır.

$$L(t) = \begin{cases} h(t) & \text{eğer } h(t)h(t-1) \geq 0 \\ 0 & \text{diğer durumlarda} \end{cases} \quad (8.25)$$

ve

$$Q(t) = \begin{cases} \mu \Delta w(t-1) & \text{eğer } h(t) \left(h(t) - \left(\frac{\mu}{\mu+1} \right) h(t-1) \right) \geq 0 \\ \Delta q(t) & \text{diğer durumlarda} \end{cases} \quad (8.26)$$

eşitlikleri ile verilir. Bu eşitliklerde μ , momentum büyüme faktörünü; $h(t) = \frac{\partial E}{\partial w(t)}$,

eğimi ve $\Delta q(t) = \frac{\Delta w(t)h(t)}{h(t-1)h(t)}$ ise minimum adım miktarını göstermektedir (Haykin

1999). Buradan ağırlık fonksiyonunu güncelleştirmek için, delta ağırlık fonksiyonu ve ağırlık hızlandırma katsayısı işleme dahil edilirse;

$$w(t) = (1 - \delta)w(t-1) + \Delta w(t) \quad (8.27)$$

eşitliği elde edilir. Burada δ , hızlandırma katsayısıdır. Son olarak ağırlık çok küçük ise, 0 alınarak kırılır (Haykin 1999). Yani, $|w(t)| < \kappa$ ise $w(t)=0$ alınır. Burada, κ , ağırlık kırma faktörüdür.

Eşleştirmeli eğim algoritması: Bu algoritma, çok katmanlı perseptron modelinin gelişmiş bir metodudur. Geri yayılım algoritmasından daha iyi performans gösterir ve bu algoritmanın kullanıldığı tüm problemlere uygulanabilir. Çok büyük sayıda ağırlık içeren, çok çıkış düğümlü ağlar için daha uygun bir tekniğe sahiptir (Bishop 1995). Eşleştirmeli eğim algoritmasında öğrenme ve momentum oranı parametreleri olmadığından dolayı kullanımı geri yayılım algoritmasından daha kolaydır. Bununla birlikte, bu algoritma da geri yayılım algoritmaları gibi ağırlık değerlerini eğimin negatifi yönünde dengelemeye çalışır. Bu doğrultu eğimin hızla düştüğü doğrultu

olup performans fonksiyonu da bu doğrultuda düşer. Geriye yayılım algoritmasında performans fonksiyonundaki hızlı düşüş, ağırlık hızlı yakınsamasına izin vermez. Eşleştirmeli eğim algoritmasında ise eğim azaltım yöntemindeki doğrultulardan genellikle daha hızlı yakınsayan eşleştirme doğrultularında bir arama işlemi yapılır (Sağıroğlu ve ark. 2003).

Eşleştirmeli eğim algoritması aslında, bir yığın güncelleştirme algoritmasıdır. Geri yayılım algoritmasında ağırlık ayarlaması işlemi her bir giriş için ayrı yapılır. Buna karşın eşleştirmeli eğim algoritmasında, epokun sonunda ağırlıkları güncellemeden önce tüm durumlardaki ortalama hata eğimi hesaplanır (Luenberger 2003). Başlangıç arama yönü $d_0 = -g_0$ şeklindedir. Daha sonra arama yönü Polak-Rebiere formülü kullanılarak güncellenir (Ellsworth ve Moran 2003):

$$D_{j+1} = -g_{j+1} + \beta_j d_j \quad (8.28)$$

$$\text{Burada, } \beta_j = \frac{g_{j+1}^T (g_{j+1} - g_j)}{g_j^T g_j}, \text{ dir.} \quad (8.29)$$

Eşleştirmeli eğim YSA eğitim algoritması diğer eğim azaltma algoritmalarıyla karşılaştırıldığında ölçüt işlevinin en küçük değerine daha çabuk ve daha kararlı ulaşmasıyla tanınır (Fine 1999). YSA üzerinde bulunan düğümler arasındaki bağlantıların t . iterasyondaki ağırlıklarına $w(t)$ dersek, ağırlıkların $(t+1)$. iterasyondaki değerine şu eşitlikle ulaşırız:

$$w(t+1) = w(t) + \eta(t)d(t) \quad (8.30)$$

Burada $\eta(t)$, t . iterasyondaki adım büyüklüğü, $d(t)$ ise azaltmanın yapılacağı doğrultuyu veren yön vektörüdür. $\eta(t)$ 'nin değerine $d(t)$ yönünde çizgi azaltma (line minimization) işlemi yapılarak ulaşılır. $d(t)$ ve $d(t+1)$ Hessian matrisine göre birbirine dik yön vektörleridir (Bishop 1992).


8.2.1 MLP sinir ağı ile iris tanıma

Bu çalışmada, çok katmanlı perseptron sinir ağı kullanılarak CASIA ve UBIRIS iris görüntüleri sınıflandırılmıştır. Bu amaçla, iris görüntülerinin öncelikle eğitim işlemi gerçekleştirilmiş, daha sonra test aşamasına geçilmiştir. Eğitim aşamasında hızlı yayılım ve eşleştirmeli eğim azalımı öğrenme algoritmaları uygulanmıştır.

Ağın giriş ve çıkış set sayıları veritabanına ve vektörün boyutlarına bağlı olarak değişmektedir. CASIA ve UBIRIS iris veritabanlarından alınan her bir kişiye ait görüntülerden sadece bir tanesi test aşamasında kullanılmış, diğerleri eğitim aşamasına katılmıştır. Dolayısıyla, eğitim aşamasında her bir sınıf için örnek sayısı; CASIA veritabanında 6, UBIRIS veritabanında 4'tür. Ağa verilen iris görüntülerinin giriş örnek sayılarının az olması nedeniyle, çıkış sınıf sayısı sınırlandırılmıştır. CASIA iris veritabanı için çıkış sınıf sayısı 70, UBIRIS iris veritabanı için çıkış sınıf sayısı 60 olarak belirlenmiştir.

Her giriş seti için en fazla 10000 iterasyon çalıştırılması hedeflenmiştir. Eğitim doğrulama oranı 100 % olduğunda iterasyonlar durdurulmuş ve iterasyon sayısı not edilmiştir.

MLP sinir ağı modelinde gizli katman hücre sayısı belirlenirken tecrübeye dayalı yöntem kullanılmıştır. Bu yöntemde her bir giriş seti için önceden belirlenen hücre sayısı aralıklarında 100 iterasyon eğitim yapılmış ve ortalama karesel hata (MSE) değerlerine göre en uygun gizli katman hücre sayısı belirlenmeye çalışılmıştır. Gizli katman hücre sayısı belirleme aşamasında kaydedilen örnek bir MSE – hücre sayısı grafiği Şekil 8.4'de gösterilmiştir.



Şekil 8.4 CASIA 10*10 gizli katman hücre sayısı belirleme grafiği

Sistemin genel doğrulama oranının belirlenmesi amacıyla yine MSE fonksiyonu kullanılmıştır. Tablo 8.1’de, belirlenen giriş, gizli ve çıkış katman hücre sayısına göre MLP ağ yapısı gösterilmiştir.

Tablo 8.1 MLP sinir ağının katman yapısı

Veritabanı	Öznitelik vektörü / (pencere boyutu)	Giriş – Gizli – Çıkış katmanı hücre sayıları
CASIA	98 byte / (10x10)	98 : 35 : 70
	50 byte / (14x14)	50 : 56 : 70
UBIRIS	8 byte / (20x20)	8 : 23 : 60
	32 byte / (10x10)	32 : 31 : 60

Eğitim aşamasında öğrenme metoduna bağlı olarak öğrenme oranı ve momentum parametreleri belirlenmelidir. Bu parametreler ağın öğrenme hızını ve performansını etkilemektedir. Öğrenme oranı ağırlıkların değişim miktarını

belirlemektedir. Eğer büyük değerler seçilirse o zaman yerel çözümler arasında ağı dolaşması ve osilasyon yaşaması söz konusu olmaktadır. Küçük değerler seçilmesi ise öğrenme zamanını artırmaktadır. Tecrübeler genellikle 0,1 - 0,4 arasındaki değerlerin kullanıldığını göstermektedir. Fakat bu tamamen ilgili probleme bağlıdır. Bu değerler iyidir demek de doğru olmaz. Bazı uygulamalarda öğrenme katsayısının 0.6 değerini aldığı zaman en başarılı sonuçları verdiği görülmektedir. Benzer şekilde momentum katsayısı da öğrenmenin performansını etkiler (Sağıroğlu ve ark. 2003).

Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesi olarak görülmektedir. Bu özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacı ile önerilmiştir. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler için ise tek bir çözüme ulaşmada sorunlar yaşanabilir. Tecrübeler bu değer 0,6–0,8 arasında seçilmesinin uygun olacağını göstermektedir. Fakat bu da kesin denilemez. Problemin niteliğine göre kullanıcının belirlemesinde fayda vardır. Daha küçük değerler ile başarılı sonuçların alındığını gösteren örnekleri görmek de mümkündür (Sağıroğlu ve ark. 2003).

Aşağıdaki tabloda (Tablo 8.2), bu çalışmada ağ için gözlemlenen en uygun parametreler gösterilmiştir.

Tablo 8.2. MLP sinir ağı için parametreler

Öğrenme Metodu	Parametreler ve değerleri
Hızlı yayılım	Transfer Fonksiyonu = Tanjant Hiperbolik ve Sigmoid Momentum katsayısı $[0..1] = 0.7$ Öğrenme oranı $[0..1] = 0.3$
Eşleştirmeli Eğitim	Transfer Fonksiyonu = Tanjant Hiperbolik ve Sigmoid -


MLP sinir ağı uygulamasında performans değerlendirmesi yaparken MSE değeri, eğitim ve test doğrulama oranlarına bakılmıştır. Bununla birlikte eğitim süresi hem sigmoid hem de tanjant hiperbolik aktivasyon fonksiyonları için not edilmiştir. Test aşamasında geçen süre saniyenin altında bir değer olduğu için bu süre kayıt

edilmemiştir. Eğitimin tamamlandığı noktada iterasyon sayıları not edilmiştir. YSA yöntemi ile gerçekleştirilen tüm sınıflandırma işlemleri NeuroSolutions programı kullanılarak gerçekleştirilmiştir. Programın ekran görüntüleri Ekler kısmında verilmiştir. Tablo 8.3’de MLP sinir ağı tanıma oranları gösterilmiştir.

Tablo 8.3 MLP sinir ağı tanıma oranı değerlendirmesi

	Alt görüntü boyutu	Öğrenme metodu	Süre (dk:sn)		İterasyon		Doğrulama Oranı (%)			
			tanh	Sigm.	tanh	Sigm.	Eğitim		Test	
							tanh	Sigm.	tanh	Sigm.
CASIA	10x10	Hızlı Yayılım	12:05	14:32	4719	7110	100	100	84,28	94,28
		Eşleşt. Eğitim	13:08	05:51	1264	1421	100	100	91,42	95,71
	14x14	Hızlı Yayılım	09:04	11:28	6517	7385	100	100	88,57	94,28
		Eşleşt. Eğitim	11:13	13:44	3688	5921	100	100	90,00	91,42
UBIRIS	20x20	Hızlı Yayılım	04:25	07:37	6986	9687	100	100	88,33	88,33
		Eşleşt. Eğitim	05:48	09:48	6267	9259	100	100	85,00	86,66
	10x10	Hızlı Yayılım	02:36	03:47	3464	7015	100	100	98,33	98,33
		Eşleşt. Eğitim	02:48	02:12	1625	1587	100	100	100	100

Tablodan da görüldüğü üzere, tüm girişlerin eğitim aşamasında 100 % eğitim tamamlanmıştır. Eğitim süreleri incelendiğinde, eşleştirmeli eğitim öğrenme metodunun genellikle daha uzun sürede, ancak daha az iterasyon sayısında eğitimi tamamladığı görülmüştür. Genel anlamda, sigmoid fonksiyonu kullanılarak gerçekleştirilen işlemlerde daha yüksek doğrulama elde edilmiştir. Şekil 8.5’de MLP ağı ile yapılan eğitim aşamasında alınan örnek bir MSE-İterasyon grafiği verilmiştir.




Şekil 8.5 UBIRIS 10*10 eşleştirmeli eğitim algoritması MLP eğitim grafiği

8.3 Modüler Sinir Ağı (MNN) Modeli


1990'lı yılların başında uygulanmaya başlanan modüler sinir ağı, çok katmanlı perseptron sinir ağı modelinin geliştirilmiş özel bir sınıfıdır (Patterson 1996). En temel MNN modeli, 2 veya daha fazla gizli katmandan oluşan ileri beslemeli sinir ağı yapısındadır. Yapılan araştırmalar bu tür bir MNN modelinin standart tek gizli katmanlı bir sinir ağının verdiği performansa göre çok daha iyi sonuç verdiğini kanıtlamıştır (Happel ve Murre 1994, Anand ve ark. 1995, Belotti ve ark. 1995, Blonda ve ark. 1993).

Bununla birlikte, birçok paralel MLP sinir ağının birer modül olarak birleşmiş şekli de MNN olarak tanımlanır (Farrugia ve ark. 1993, Anand ve ark. 1995, Chiang ve Fu 1994). Bu tip bir sinir ağında her bir MLP sinir ağı modülleri halinde girişler üzerinde ayrı ayrı işlem yapar ve daha sonra sonuçları tekrar birleştirir. Yapısal anlamda bir veya daha fazla gizli katman kullanılabilir. Ancak burada girişlerin durumu ayırt edici bir özelliktir. Bazı modellerde tüm girişler her bir modüle ayrı ayrı uygulanırken, bazılarında yalnızca seçilen girişler seçilen modüle giriş olarak verilir. Bu iki tip MNN modeli Şekil 8.6'da gösterilmiştir (Boers ve Kuiper 1992).



Şekil 8.6 Paralel MLP modüllerinden oluşmuş MNN ağ yapısı

Modüler sinir ağının en gelişmiş olanları girişlerin ve gizli katmanların ayrı ayrı modüllere ayrılmasıyla elde edilen sinir ağıdır. Yapılan son araştırmalar bu tip bir modüler sinir ağının oldukça etkili sonuçlar verdiğini göstermektedir (Happel ve Murre 1994). Böyle yapıya sahip bir MNN modelinde girişler bir modüldür ve bunların hangi gizli katmana ve gizli katmandaki hangi modüle seçileceğinin belirlenmesi gerekir. Bununla birlikte, bazı MNN yapılarında girişten veya gizli katmanlardan çıkış katmanına da bağlantı olmaktadır. Şekil 8.7’de bu tip MNN yapısına örnekler verilmiştir.



Şekil 8.7 İki veya daha fazla gizli katman içeren MNN ağ yapıları

MNN modelinde gizli katmanların hücre sayısının doğru bir şekilde belirlenmesi ağın performansı açısından çok önemlidir. Bu amaçla tecrübeye dayalı yöntem kullanılarak gizli katman hücre sayısı belirlenmiştir. Gizli katman hücre sayıları önceden belirlenmiş sınır değerleri arasında değiştirilerek kısa eğitimlere tabi tutulur ve alınan en küçük MSE değerlerine bakılarak en iyi ağ yapısı belirlenmiştir.

8.3.1 Modüler sinir ağı ile iris tanıma


Bu çalışmada iki gizli katmana sahip MNN modeli tercih edilmiştir. Gizli katmanların hücre sayısı, en küçük MSE değeri bulma algoritması kullanılarak seçilmiştir. Elde edilen bu ilk yapıya göre sistem eğitim ve test aşamalarından

geçirilmiştir. Daha sonra genetik algoritmalar kullanılarak bu sayılar yeniden belirlenmiş ve yeni yapıya göre tekrar eğitim ve test işlemleri gerçekleştirilmiştir. Öğrenme parametreleri olan öğrenme katsayısı ve momentum, MLP sinir ağı yönteminde olduğu gibi belirlenmiştir. Aşağıdaki tabloda (Tablo 8.4), bu çalışmada ağ için gözlemlenen en uygun parametreler gösterilmiştir.

Tablo 8.4 MNN için parametreler


Öğrenme Metodu	Parametreler ve değerleri
Hızlı yayılım	Transfer Fonksiyonu = Tanjant Hiperbolik ve Sigmoid Momentum katsayısı $[0..1] = 0.7$ Öğrenme oranı $[0..1] = 0.3$
Eşleştirmeli Eğitim	Transfer Fonksiyonu = Tanjant Hiperbolik ve Sigmoid -

Kullanılan MNN bağlantı modeli Şekil 8.8’de gösterilmiştir. Bu modelde, girişlerin tümü 1. gizli katmandaki hücelere ayrı ayrı bağlanmıştır. 1. gizli katmanda yer alan modüllerin çıkışları ise 2. gizli katmandaki modüllere bağlantılıdır.



Şekil 8.8 Uygulamada kullanılan MNN ağ yapısı

MNN gizli katman hücre sayıları aşağıdaki şekilde (Şekil 8.9) gösterilmiştir. Gizli katmandaki blokların içerisinde yazılmış olan rakamlar hücre sayılarını vermektedir. Tablo 8.5’de modüler sinir ağı doğrulama sonuçları verilmiştir. Eğitim ve test aşamasında uygulanan tüm işlem basamakları MLP ile benzerdir.




Şekil 8.9 MNN gizli katman hücre sayıları

Tablo 8.5 MNN tanıma oranı değerlendirmesi

	Alt görüntü boyutu	Öğrenme metodu	Süre (dk:sn)		İterasyon		Doğrulama Oranı (%)			
			tanh	Sigm.	tanh	Sigm.	Eğitim		Test	
							tanh	Sigm.	tanh	Sigm.
CASIA	10x10	Hızlı Yayılım	10:25	11:09	4929	6052	100	100	91,42	97,14
		Eşleşt. Eğitim	13:49	10:52	4315	1435	100	100	92,85	97,14
	14x14	Hızlı Yayılım	08:52	04:17	1051	3725	100	100	88,57	97,14
		Eşleşt. Eğitim	09:18	07:11	2948	4425	100	100	97,14	94,28
UBIRIS	20x20	Hızlı Yayılım	04:31	03:49	6340	5107	100	100	91,66	90,00
		Eşleşt. Eğitim	03:29	03:58	1679	2047	100	100	86,66	83,33
	10x10	Hızlı Yayılım	04:08	08:45	3694	7321	100	100	98,33	100
		Eşleşt. Eğitim	02:42	05:24	2899	1787	100	100	100	100

Tablo 8.5’den görüldüğü gibi, tüm girişlerde eğitim 100 % tamamlanmıştır. Eğitim süreleri incelendiğinde, eşleştirmeli eğitim öğrenme metodunun daha uzun sürede, ancak daha az iterasyon ile eğitimi tamamladığı görülmüştür. Genel anlamda, sigmoid transfer fonksiyonunun tanjant hiperbolik fonksiyonuna göre biraz daha iyi sonuçlar verdiği gözlemlenmiştir. MNN modelinin MLP’ye oranla daha yüksek doğrulamaya sahip olduğu tespit edilmiştir. Ancak eğitim, MLP sinir ağına oranla daha uzun sürede gerçekleşmektedir. Bunun sebebi, MNN modelinin birden fazla gizli katmana sahip olmasından kaynaklandığı tespit edilmiştir. Şekil 8.10’da MNN ağı ile yapılan eğitim aşamasında alınan örnek bir MSE-İterasyon grafiği verilmiştir.




Şekil 8.10 CASIA 14*14 eşleştirmeli eğitim algoritması MNN eğitim grafiği

8.4 Elman Sinir Ağı Modeli

Elman sinir ağı, yinelemeli (recurrent) sinir ağları grubuna girmektedir. MLP sinir ağına benzer bir yapıdadır. Giriş, gizli ve çıkış katmanına ek olarak içerik (context) katmanına sahiptir. İçerik katmanı gizli katmandan gelen çıktıları giriş olarak almaktadır. Bunun amacı, gizli katman hücrelerinin geçmiş durumlarını hatırlamaktır. Ağın çıkışı, hem önceki durumlara, hem de ağın o andaki durumuna

bağlı olarak oluşturulmaktadır. Geçmiş durumları hatırlayabilmeleri bu ağlara dinamik hafızaya sahip olma özelliği kazandırmaktadır (Öztemel 2003).

Yinelemeli sinir ağları içerisinde en basit yapıya sahip ve kullanımı en kolay ağ Elman ağıdır (Elman 1990). Şekil 8.11’de Elman sinir ağının yapısı gösterilmiştir.



Şekil 8.11 Elman sinir ağı yapısı

Şekilden de görüldüğü üzere içerik katmanı, gizli katmandan gelen çıktıları giriş olarak almakta ve bunları eğitime tabi tutarak yine gizli katmana göndermektedir. İçerik katmanı hücre sayısı gizli katman hücre sayısı ile aynıdır. Gizli katmandan gelip içerik katmanına giren bağlantının ağırlıkları sabittir ve eğitim sırasında değişmemektedir. Ancak içerik katmanından çıkan ve gizli katmana giren bağlantıların ağırlıkları eğitim sırasında hesaplanarak değiştirilirler. Dolayısıyla Elman ağında, herhangi bir k zamanında gizli katmana giren değerler, hem k zamanındaki değerleri, hem de $k-1$ (bir önceki) zamanındaki değerleri içermektedirler. Böylece ağ geçmiş durum hatırlanmakta ve ağırlık değişimleri daha dinamik olmaktadır.

Elman ağında, içerik katmanındaki hücrelerin başlangıç giriş değerleri kullanılan aktivasyon fonksiyonuna göre belirlenmektedir. Eğer sigmoid fonksiyonu kullanılacaksa genellikle bu değer 0,5 olarak alınır. Hiperbolik tanjant fonksiyonu için başlangıç değeri genellikle 0 olarak atanmaktadır (Öztemel 2003).

Elman ağıının öğrenmesi, MLP ağıının öğrenmesi ile aynı şekilde gerçekleşir. Ancak Elman ağıında, gizli katmandaki hücrelerin çıkışı bulunurken hem giriş, hem de içerik katmanından gelen girişler hesaplama katılır. Yapılan hesaplama aşağıdaki denklemde (8.31) gösterilmiştir.

$$Net(k) = \sum_{j=1}^N A_{ji}^g u(k) + \sum_{i=1}^M A_{ij}^i x(k-1) \quad (8.31)$$

Burada N giriş katmanı hücre sayısı, M ise içerik katmanı hücre sayısını ifade etmektedir. A^g giriş katmanındaki hücrelerin çıkışı aktivasyonu, A^i ise içerik katmanındaki hücrelerin çıkış aktivasyonudur. Yapılan işlemler k zaman diliminde gerçekleşmektedir.

8.4.1 Elman sinir ağı ile iris tanıma


Bu çalışmada Elman sinir ağı kullanılarak CASIA ve UBIRIS iris görüntüleri sınıflandırılmıştır. Ağıın içerik katmanının hücre sayısı gizli katman hücre sayısı ile aynıdır. Gizli katman hücre sayılarının belirlenmesinde tecrübeye dayalı yöntem kullanılmıştır.

Diğer modellerde olduğu gibi, Elman sinir ağı modelinde de eğitim aşamasında en fazla 10000 iterasyon çalıştırılması hedeflenmiştir. Eğitim 100 % ulaşmışsa o anki iterasyon sayısı not edilmiştir. Öğrenme yöntemlerinden hızlı yayılım ve eşleştirmeli eğim azalımı kullanılmıştır. Hızlı yayılım algoritmasında momentum katsayısı 0,7 ve öğrenme oranı 0,4 olarak tespit edilmiştir. Sistemin performansının değerlendirilmesinde MLP ve MNN ağlarında olduğu gibi, MSE fonksiyonu kullanılmıştır. Tablo 8.6'da Elman ağı doğrulama sonuçları verilmiştir.

Tablo 8.6 Elman sinir ağı tanıma oranı değerlendirilmesi

	Alt görüntü boyutu	Öğrenme metodu	Süre (dk:sn)		İterasyon		Doğrulama Oranı (%)			
			tanh	Sigm.	tanh	Sigm.	Eğitim		Test	
							tanh	Sigm.	tanh	Sigm.
CASIA	10x10	Hızlı Yayılım	06:22	06:09	2919	3052	100	100	88,57	96,66
		Eşleşt. Eğitim	06:19	05:52	1715	1258	100	100	87,14	95,71
	14x14	Hızlı Yayılım	05:32	04:47	2951	2750	100	100	91,42	96,66
		Eşleşt. Eğitim	11:48	05:51	5048	3159	100	100	87,14	95,71
UBIRIS	20x20	Hızlı Yayılım	04:11	04:49	4699	4874	100	100	66,66	80,00
		Eşleşt. Eğitim	03:59	05:18	1696	3497	100	100	61,66	75,00
	10x10	Hızlı Yayılım	02:22	02:45	2490	3381	100	100	100	98,33
		Eşleşt. Eğitim	02:35	03:24	1246	1447	100	100	95,00	98,33


Tablodan da görüldüğü gibi, tüm girişler için eğitim tamamlanmıştır. Doğrulama oranlarına bakıldığında, sigmoid fonksiyonu kullanan girişlerde daha yüksek doğrulama oranına sahip olduğunu görmekteyiz. Şekil 8.12’de Elman ağı ile yapılan eğitim aşamasında alınan örnek bir MSE-İterasyon grafiği verilmiştir.



Şekil 8.12 UBIRIS 10*10 hızlı yayılım algoritması Elman ağı eğitim grafiği

8.5 Genetik Algoritmalar ile İris Öznitelik Vektörünün Azaltılması

Genetik algoritmalar (GA), yönlendirilmiş rasgele araştırma algoritmalarının bir türü olup, canlılardaki doğal gelişim prensibine dayanmaktadır. Daha çok karmaşık optimizasyon problemlerinin çözümünde kullanılmaktadır. Bir problemi çözebilmek için öncelikle rasgele başlangıç çözümleri belirlenir. Daha sonra bu çözümler birbiri ile eşleştirilerek performansı daha iyi çözümler üretilmeye çalışılmaktadır. Olaslıksal karakterleri ve çoklu mümkün çözümleri araştırma gibi özelliklere sahip olmaları en önemli üstünlüklerindendir. Bir GA'nın temel birimleri Şekil 8.13'de gösterilmiştir.



Şekil 8.13 Genetik algoritmanın temel birimleri

GA'da araştırma uzayında bulunan bazı çözümlerin oluşturduğu bir başlangıç yoğunluğu kullanılır. Bu başlangıç yoğunluğu her kuşakta, doğal seleksiyon ve tekrar üreme işlemleri yoluyla geliştirilir. Son kuşağın en uygun bireyi, problem için en iyi çözüm olmaktadır.

Başlangıç yoğunluğunun üretilmesini takiben, her çözümün uygunluğu veya iyiliği, seçilen uygunluk fonksiyonuna göre değerlendirilir. Uygunluk fonksiyonu, eldeki verileri dikkate alarak sonuçları değerlendirir. Seçme, çaprazlama ve mutasyon gibi genetik operatörler, elde edilen iyi çözümlerden denenmiş yeni çözümler üretmek için kullanılırlar.

Birçok seçme operatörü vardır. Bu operatörlerden ekilmiş (seeded) seçme, daha iyi çözümlere, daha fazla yaşama şansı veren yeni bir yoğunluk için çözüm anındaki yoğunluktan seçme işlemini gerçekleştirir (MMO 2007). Rasgele (random) seçme, o andaki elde edilen çözümlerden tamamen rasgele olarak yeni bir yoğunluk oluşturur. Seçkin (elite) seçme operatörü ise, her zaman en iyi çözümü bir kuşaktan diğerine kopyalar.

GA'da bir problem için birçok çözüm olabilir. GA bunlar içerisinde en iyisini bulmaya çalışır. Kromozomlar bu çözümleri gösterirler. Bir kromozomun elemanlarından her birisi çözümün bir özelliğini göstermektedir. Bunlara da gen denilir. Bir kromozomun ikili sayılarla temsil edilmesi şu şekildedir:


Kromozom 1 1101100100110110

Kromozom2 1101111000011110


Kromozom, temsil ettiği çözümle ilgili bilgi içermelidir. Her kromozom ikili (binary) bir diziden oluşur. Bu dizi içindeki bit adı verilen her bir sayı çözümün bir karakteristiğini temsil edebilir veya bir dizi bütünüyle bir sayıya işaret edebilir. Kromozomu ikili düzendeki sayılar dizisiyle ifade etmek çok tercih edilen bir temsil şeklidir, ancak bunun yerine tamsayı veya reel sayılar da kullanılabilir. İkili düzenin tercih edilmesinin sebebi basit olması ve bilgisayar tarafından daha kolay ve hızlı bir biçimde işlenebilmesidir.

Bir problemin en iyi çözümünü aramak için kullanılan ve rasgele belirlenmiş başlangıç çözüm setine çözüm havuzu denilmektedir. Problem çözüm havuzunda bulunan çözümleri (kromozomları) ikişer ikişer birleştirerek yeni çözümler üretmektir. İki kromozomdan iki adet yeni kromozom üretilir. Bir problem çözüm uzayından kaç adet kromozomun çaprazlanacağı çaprazlama oranına göre belirlenir.

Kromozomların nasıl temsil edileceğine karar verildikten sonra çaprazlama yapılabilir. Çaprazlama ebeveynlerden bazı genleri alarak yeni bireyler oluşturma işlemidir.



Çaprazlama yapılacak konum rasgele seçilir (|). Oluşan yeni birey ebeveynlerin bazı özelliklerini almış ve bir bakıma ikisinin kopyası olmuştur. Çaprazlama işlemi başka şekillerde de yapılabilir. Mesela birden fazla çaprazlama noktası seçilebilir. Daha iyi performans almak amacıyla değişik çaprazlamalar kullanılabilir. Çaprazlama neticesinde farklı çözümlere ulaşmak bazen zor olmaktadır. Yeni çözüm aramanın kolaylaştırılması ve aramanın yönünü değiştirmek amacı ile bir kromozomun bir elemanının (bir geninin) değiştirilmesi işlemidir. Bir problem havuzu içinden kaç kromozomun mutasyona uğratılacağı mutasyon oranına göre belirlenir. Mutasyon oluşan yeni bireyin bir bitini (eğer ikili düzende ifade edilmiş ise) rasgele değiştirir.



Belirlenen çözümlerin uygunluk derecelerinin ölçülmesini sağlayan fonksiyondur. Her problem için bir uygunluk fonksiyonunun belirlenmesi gerekir. Bu fonksiyon probleme göre değişmektedir. Birçok problemde uygunluk fonksiyonu elde edilen sonuç ile tahmin edilen sonuç arasındaki hatadan bulunmaktadır. Örneğin, bir iş sıralanması probleminde belirlenen sıraya göre işlerin tamamının bitirilmesi zamanı uygunluk fonksiyonu ölçütü olarak belirlenebilir. En kısa zamanda

işi bitiren iş sırasının belirlenmesi istenir. İşlerin toplam bitirilme zamanı azaltıldığı sürece daha farklı iş sıralarının aranmasına devam eder. Sürenin en aza indirildiği noktada en iyi çözüm bulunmuş olacaktır. Sınıflandırma problemlerinde ise uyguluk fonksiyonu, sisteme verilen giriş değerlerinden elde edilen çıkış değerinin istenen çıkış değerine ne kadar yakınsadığına bakılarak belirlenebilir. İstenen değerlere en yakın değerler üreten genetik parametreler uygunluk fonksiyonunu oluşturmaktadır.

Çözüm havuzundaki kromozomlar çaprazlama ve mutasyon neticesinde üretilen yeni kromozomlar nedeni ile çoğalacaktır. Bunların arasından problem havuz büyüklüğüne göre kromozomlar seçilerek diğerleri atılır. Seçilenler ise bir sonraki nesil için yeniden çaprazlanarak gelecek çözümleri üretirler. Seçim işleminde bireylerin uygunluklarına bakılarak en iyi bireyler bir sonraki üretime dahil edilirler. En kötü bireyler ise atılırlar. Yeniden üretim için kullanılan en yaygın yöntem Rus Ruleti yöntemidir. Bu yöntemde yeni havuz üyeleri rulet mantığı ile seçilirler. Rulet tekerleğinin rasgele döndürülmesinden sonra, bireyin bir sonraki nesil için seçilmesi, tekerlek üzerinde kapladığı alana bağlı olarak değişir (Engin 2001). Bu yöntemde düşük uygunluğa sahip bireylere de seçilme hakkı verilir. Bir diğer seçim yöntemi olan sıralama (rank) yönteminde ise popülasyonun sıralanmasının ardından kromozomların uygunluğuna bakılır. Bu yöntemde en uygun kromozomlarda değişiklik yapılmadığından seçme işlemi daha yavaş olmaktadır.

Popülasyon büyüklüğünün seçimi, GA'nın performansını etkileyen en önemli rollerden birisidir. Popülasyon büyüklüğünün çok küçük seçilmesi algoritmanın bir eşikte takılıp kalmasına yol açabilmektedir. Bunun tersine popülasyon büyüklüğü çok büyük değerde seçilirse en iyi çözüme ulaşmak çok fazla süre alacaktır. Bu konuda yalnızca kromozom uzunluğuna bağlı bir popülasyon büyüklüğü hesaplama yönteminin daha uygun olduğu önerilmektedir (Goldberg 1985). Bunun yanı sıra test fonksiyonları üzerine yapılan araştırmalar sonucunda, 10-30 arası bir popülasyon büyüklüğünün iyi sonuçlar verdiği belirtilmiştir (Schaffer ve ark. 1989).

GA içerisinde kromozomlar birbirine benzemeye başlıyorsa ve çözüm noktalarına hala ulaşamıyorsa o halde mutasyon işlemi uygulanır. Böylece hesaplama süreci takıldığı yerden kurtulabilir. Ancak, yüksek değerde bir mutasyon olasılığı algoritmanın daha az kararlı olmasına sebep olabilir. Bir diğer deyişle


mutasyon olasılığı artarsa, genetik arama rastsal bir aramaya dönüşür. Mutasyon olasılığı genellikle 0 ile 1 arasında bir değerde seçilir (Janikow 1993). Mutasyon işlemi popülasyondaki genetik çeşitliliğin korunmasına yardımcı olmaktadır. Mevcut kromozomların özelliklerini birleştirerek daha uygun kromozomların elde edilmesi işlemine çaprazlama denmektedir. Kromozom çiftleri, belirli bir olasılık değeriyle çaprazlamaya uğramak üzere seçilirler. Ancak çok fazla çaprazlamanın yapılması bazı iyi kromozomların bozulma olasılığını arttırmaktadır. Çaprazlama olasılığı genellikle 0 ile 1 arasında seçilmektedir (Emel ve Taşkın 2002).

8.5.1 GA ile iris öznitelik seçimi uygulaması

Çalışmamızda iris öznitelik vektörlerinin azaltılması için GA kullanılmıştır. Bu uygulamanın temel amacı doğrulama oranından ödün vermeden giriş sayısının azaltılması ve böylece eğitim süresinin kısaltılmasıdır.

GA uygunluk fonksiyonu olarak en küçük MSE değeri alınmıştır. Öznitelik seçimi sırasında ağ girişleri 200 iterasyonluk eğitim yapılmış ve en küçük MSE değerinin bulunduğu noktada giriş verileri tespit edilmiştir. GA parametrelerinden popülasyon büyüklüğü 10 ve jenerasyon sayısı 50 olarak belirlenmiştir. Ayrıca, mutasyon olasılığının 0,01 ve çaprazlama olasılığının 0,9 olduğu durumlarda en iyi sonuç alındığı gözlemlenmiştir.

Genetik algoritmalar kullanılarak YSA yapısının belirlenmesi işleminde CASIA 10*10 iris görüntüsü için kaydedilen örnek bir eğitim grafiği Şekil 8.14'de verilmiştir. Diğer tüm grafikler Ekler kısmında verilmiştir.



Şekil 8.14 Genetik algoritma uygunluk değeri grafiği

GA kullanılarak yapılan öznitelik seçimi işlemi sonucunda giriş sayılarının bir hayli düştüğü gözlenmiştir. Uygulama aşamasında giriş sayısının belli bir değerin altına düşmemesi amacıyla sadece rasgele belirlenen girişlerin GA ile seçim işlemine tabi tutulmasına karar verilmiştir. Bu amaçla önce tüm girişlerin seçimi (GA1), daha sonra toplam giriş sayısının, rasgele olarak seçilen yarısı ile seçim işlemi (GA2) tekrar gerçekleştirilmiştir. Daha sonra her iki GA uygulamasından alınan sonuçlara göre eğitim ve test işlemleri tekrarlanmış ve doğrulama oranlarına bakılmıştır. GA seçim işlemleri sonucunda belirlenen ağ yapısı Tablo 8.7’de verilmiştir.

Tablo 8.7 GA uygulama sonuçları

	CASIA 10*10	CASIA 14*14	UBIRIS 10*10	UBIRIS 20*20
GA1 sonrası yapı (tüm girişler)	41:45:70	21:35:70	25:27:60	3:10:60
Süre	9 dk. 17 sn.	8 dk. 45 sn.	6 dk. 14 sn	4 dk.54 sn.
GA2 sonrası yapı (50 %)	73:45:70	38:35:70	29:27:60	6:10:60
Süre	5 dk. 37 sn.	5 dk. 23 sn.	4 dk. 44 sn	2 dk.48 sn.

Elde edilen bu yeni giriş vektörleri MLP, MNN ve Elman sinir ağları ile yeniden eğitime tabi tutulmuştur. Eğitim aşamasında hem tanjant hiperbolik hem de sigmoid aktivasyon fonksiyonları için ayrı ayrı sonuçlar alınmıştır. GA uygulamadan önceki ve sonraki giriş vektörleri ile yapılan YSA test sonuçlarının genel bir değerlendirmesi Tablo 8.8’de verilmiştir.

Tablo 8.8 Normal ve GA ile azaltılmış özellik vektörleri doğrulama oranları

		CASIA 10*10 Doğrulama (%)		CASIA 14*14 Doğrulama (%)		UBIRIS 10*10 Doğrulama (%)		UBIRIS 20*20 Doğrulama (%)	
		<i>Tanh.</i>	<i>Sigm.</i>	<i>Tanh.</i>	<i>Sigm.</i>	<i>Tanh.</i>	<i>Sigm.</i>	<i>Tanh.</i>	<i>Sigm.</i>
Hızlı Yayılım	MLP	84,28	94,28	88,57	94,28	98,33	98,33	88,33	88,33
	MNN	91,42	97,14	88,57	97,14	98,33	98,33	91,66	90,00
	Elman	88,57	97,14	91,42	97,14	100	98,33	66,66	80,00
	<i>GA1-MLP</i>	77,14	80,00	82,85	85,71	95,00	96,66	75,00	66,66
	<i>GA1-MNN</i>	90,00	92,85	87,14	90,00	96,66	95,00	58,33	80,00
	<i>GA1-Elman</i>	85,71	87,14	74,28	77,14	100	98,33	61,66	73,33
	<i>GA2-MLP</i>	82,85	91,42	85,71	88,57	96,66	96,66	86,66	76,66
	<i>GA2-MNN</i>	91,42	95,71	88,57	92,85	98,33	98,33	91,66	86,66
	<i>GA2-Elman</i>	87,14	92,85	88,57	91,42	100	96,66	63,33	73,33
Eşleştirmeli Eğim Azalımı	MLP	91,42	95,71	90,00	91,42	100	100	85,00	86,66
	MNN	92,85	97,14	97,14	94,28	100	100	86,66	83,33
	Elman	87,14	95,71	87,14	95,71	95,00	98,33	61,66	75,00
	<i>GA1-MLP</i>	82,85	82,85	75,71	81,42	86,66	90,00	66,66	61,66
	<i>GA1-MNN</i>	90,00	81,42	72,85	80,00	95,00	91,66	76,66	60,00
	<i>GA1-Elman</i>	78,57	71,42	75,71	77,14	93,33	95,00	60,00	63,33
	<i>GA2-MLP</i>	87,14	91,42	87,14	88,57	96,66	96,66	83,33	80,00
	<i>GA2-MNN</i>	91,42	91,42	94,28	90,00	95,00	98,33	80,00	80,00
	<i>GA2-Elman</i>	87,14	78,57	85,71	90,00	95,00	95,00	61,66	73,33

Yukarıdaki tablodan görüldüğü üzere, GA uygulanarak öznelik seçimi yapılmış girişlerin doğrulama test sonuçları tüm girişlerden alınan doğrulama sonuçlarına oranla düşüş göstermiştir. GA1 ve GA2 doğrulama sonuçları karşılaştırıldığında ise GA2'nin GA1'e oranla daha yüksek doğrulamaya sahip olduğu gözlemlenmektedir. Bu durumda öznelik seçiminde elenen öznelik sayısı

ne kadar az ise doğrulama oranı o kadar artmaktadır sonucunu çıkarmak mümkün olmaktadır.

8.6 Bölüm Sonuçları

Çalışmanın bu bölümünde yapay sinir ağları ile tanıma aşamasında alınan doğrulama sonuçları verilmiştir. Yapay sinir ağlarının çok katmanlı perseptron (MLP), modüler sinir ağı (MNN) ve Elman sinir ağı modelleri kullanılarak CASIA ve UBIRIS görüntüleri sınıflandırılmıştır. Alınan sonuçlar incelendiğinde, hem CASIA hem de UBIRIS görüntülerinin sınıflandırılmasında sigmoid transfer fonksiyonunun daha yüksek doğrulama oranına sahip olduğu görülmektedir. Genel performansa bakıldığında MNN modelinin MLP ve Elman sinir ağına oranla daha yüksek doğrulama gösterdiği tespit edilmiştir.

GA ile öznitelik seçimi yapılmış girişlerde iris tanıma oranında düşüş gözlenmiştir. Bu durum, giriş verilerinin azaltılmasının performansı olumsuz etkilemesi şeklinde açıklanabilir. Örneğin, 98 girişli bir vektöre GA uygulandıktan sonra 41 girişli bir vektör; 8 girişli bir vektöre GA uygulandıktan sonra 3 girişli bir vektör elde edilmiştir. Dolayısıyla giriş sayısı yarıdan daha az bir sayıya düşürülmüştür. Bu azaltım, iris görüntüsündeki bir çok belirleyici özneliğin kaybolması anlamına gelmektedir. Bununla birlikte iki farklı GA seçim işlemi gerçekleştirilmiştir. İlkinde tüm girişlere GA uygulanmış (GA1) ve elde edilen yeni girişler eğitime tabi tutulmuştur. İkincisinde ise girişlerin yarısı GA işlemine uygulanmış (GA2) ve elde edilen yeni giriş vektörü eğitim ve test aşamalarından geçirilmiştir. Uygulama sonuçlarından görülmüştür ki, GA sonrası elde edilen yeni öznitelik vektörünün eleman sayısı ne kadar azalmış ise doğrulama oranında da o kadar düşüş yaşanmıştır. Yine bu sonuç da bize, GA ile seçim işlemi sırasında iris desenini tanımlayıcı birçok özneliğin kaybolmuş olduğunu göstermektedir.

9. SONUÇLAR VE ÖNERİLER

9.1 Sonuçlar

Bu çalışmada, yapay sinir ağları temeline dayanan sınıflandırma algoritmaları kullanılarak, kişilerin iris görüntülerinin mümkün olduğunca yüksek doğrulama oranı ile tanınması amaçlanmıştır. Bu amaçla iki farklı iris veritabanından (CASIA ve UBIRIS) alınan iris görüntüleri ön işleme tabi tutularak göz bebeği, göz kapağı, alt ve üst kirpikler gibi gürültülerden arındırılmıştır. Elde edilen iris bölgesinin öz nitelikleri çeşitli görüntü analiz yöntemleri kullanılarak belirlenmiştir. Bu öz nitelikler kullanılarak karşılaştırma yapılmış ve sistemin iris görüntüsü ile ilgili karar vermesi sağlanmıştır. Genel olarak bakıldığında, doğrulama oranı çok yüksek bir iris tanıma sistemi gerçekleştirilmiştir. Çalışmada alınan önemli sonuçlardan bazıları şunlardır:

1. İris deseninin ayırt edici özelliklerinin çok fazla olduğu ve aynı iris desenine sahip olma olasılığının çok düşük olduğu göz önünde bulundurulduğunda, bu tip bir iris doğrulama veya tanıma sisteminin önemi daha iyi anlaşılmaktadır. Bununla birlikte iris deseninin insanın doğumundan ölümüne kadar değişmemesi, taklit edilememesi ve iris görüntüsünün alınmasında herhangi bir cihazla temas gerektirmemesi de iris tanıma sistemlerinin son yıllarda çok fazla tercih edilmesinin sebebini açıklamaktadır.
2. Çalışmamızda, performans ölçütlerinin güvenilirliği sağlanması amacıyla iki farklı veritabanı kullanılmıştır. Öyle ki, CASIA iris veritabanı yakın kızılötesi aydınlatma kullanırken, UBIRIS iris veritabanı halojen aydınlatma kullanmıştır. Bilindiği üzere, iris görüntüleri alınırken ışık kaynağının iris üzerinde yansımaları sebep olması ihtimali bulunmaktadır. Bu da iris deseninin farklılaşmasına ve dolayısıyla öz niteliklerinin yanlış bir şekilde bulunmasına yol açar. Bu açıdan bakıldığında, CASIA iris görüntülerinin daha güvenilir olduğu gözlemlenmiştir. Çünkü kızılötesi

aydınlatma ile görüntüler alınmış ve görüntülerin üzerinde ışıktan kaynaklanan yansımaların bulunmadığı görülmüştür. Ancak, CASIA iris görüntülerinde denek olarak Çinli kişilerin kullanılması ve Çinlilerin çekik gözlü olmaları alt ve üst kirpiklerin iris bölgesi üzerine çok fazla gelmesine sebep olmaktadır. Dolayısıyla bu durum, hem iris bölgesinin tespitini, hem de öznitelik çıkarımını zorlaştırmaktadır. Ayrıca, göz kapağı ve kirpik gibi gürültülerin fazlalığı, tanıma performansını da etkilemektedir. UBIRIS veritabanının dezavantajı ise görüntülerde halojen aydınlatmadan kaynaklanan ışık yansımalarının mevcut olmasıdır. Ayrıca bu veritabanında olan bazı görüntülerde netlik tam olarak sağlanamamıştır. Dolayısıyla bu görüntüler net değildir. Buna karşılık, alt ve üst göz kapakları ile kirpiklerin iris bölgesi üzerine düşmediği gözlenmiştir. Böylece çalışmada, her iki veritabanını kullanarak yukarıda bahsedilen dezavantajların ortadan kaldırılması problemi üzerinde de durulmuştur.

3. Iris tanıma sistemlerinde karşılaşılan temel sorunlardan birisi iris bölgesinin tespitidir. Yapılan çalışmada görülmüştür ki, sistem içerisinde iris bölgesinin tespit edilmesi aşaması sistemin en zor aşamalarından biridir. Özellikle CASIA veritabanında alt ve üst göz kapaklarının iris bölgesini kapatması kenarların tespitini oldukça güçleştirmektedir. Bu çalışmada aynı zamanda, göz bebeğinin dış kenar çizgilerinin tespiti, irisin dış kenar çizgilerinin tespitine nazaran daha kolay olduğu görülmüştür. Bunun sebebi kenarların tespitinde kontrast farklılıklarına bakılmasıdır. Bilindiği üzere göz bebeği, göz görüntüsü içerisinde yer alan en koyu bölgedir. Dolayısıyla kontrast farklılığı, diğer kısımlara göre daha fazladır. Kenar çizgilerinin tespit edilmesi işleminde karşılaşılan güçlükleri aşmak için algoritma içerisinde kullanılan eşik değerinin değiştirilmesi çalışmamız dahilinde önerilmektedir. Her veritabanı için farklı eşik değerleri kullanılması teklif edilmiş ve böylece irisin iç ve dış kenar çizgileri doğru bir şekilde elde edilmesi sağlanmıştır.

4. Iris tanıma sistemlerinde, öznitelik çıkarımı aşamasında kullanılan birçok yöntem mevcuttur. Bunların içerisinde en çok tercih edileni dalgacık dönüşümü yöntemidir. Haar, Gabor, Hilbert, sıfır geçişli dalgacık dönüşümü yöntemleri bunlardan en önemlileridir. Bunun yanı sıra, Fourier dönüşümü, Laplas piramidi, temel bileşen analizi, bağımsız bileşen analizi yöntemleri de uygulamada yer almıştır. Tez

çalışmasında iki farklı öznitelik çıkarımı gerçekleştirilmiştir. İlk yöntem, uygulamalarda sıklıkla tercih edilen Gabor dalgacık dönüşümü yöntemidir. Bu yöntemde öznitelikler ikili sistemde elde edilmektedir. Diğer öznitelik çıkarımı yönteminde ise, iris görüntüsünü çeşitli boyutlarda karesel alt görüntülere bölmek suretiyle farklı boyutlarda öznitelikler elde edilmiştir. Bölünmüş haldeki alt görüntülerin her biri ortalama mutlak sapma yöntemi kullanarak sayısal hale dönüştürülmüştür. Bu yöntemde temel amaç özniteliklerin boyutunun azaltılmasıdır. Çünkü bu işlem tanıma aşamasında sürenin kısılmasını sağlayacaktır. Çok fazla sayıda eleman içeren giriş vektörü hem tanıma performansını etkileyecek, hem de işlemlerin uzamasına yol açacaktır. Ancak bilindiği gibi veri azaltımı işlemi bazı özniteliklerin kaybolmasına sebep olmaktadır. Burada önemli olan özniteliklerin görüntüyü tam olarak niteleyebilmesidir. Aslında, farklı boyutlarda alt görüntülere bölme işlemi, bunun ortaya çıkarılmasına yöneliktir. Yapılan çalışmada bunlar, ayrı ayrı denenmiş ve her bir veritabanı için hangi pencere boyutunun daha iyi performans gösterdiği kaydedilmiştir.

5. Yapay zeka tekniklerinin iris tanıma performansını ölçmeye yönelik olan bu çalışmada, iris görüntülerinin sınıflandırılması amacıyla yapay sinir ağları (YSA) tercih edilmiştir. Literatürde bir çok YSA modeli mevcuttur. Bu modellerden sınıflandırma problemlerinde sıklıkla tercih edilen çok katmanlı perseptron (MLP), bu modelin biraz daha geliştirilmiş olan modüler sinir ağı (MNN) ile yinelemeli (recurrent) sinir ağı modeli olan Elman sinir ağı iris görüntülerinin tanınması için kullanılmıştır. CASIA ve UBIRIS iris veritabanından alınan görüntülerin yalnızca bir tanesi test aşaması için ayrılmış, diğerleri eğitim aşamasında sisteme dahil edilmiştir. Yukarıda bahsedilen YSA modelleri ile iris görüntüleri hatanın geriye yayılması metodu ile eğitime tabi tutulmuş ve tüm girişlerde eğitim 100 % oranında gerçekleşmiştir. Öğrenme aşamasında hızlı geri yayılım ve eşleştirmeli eğitim azaltımı yöntemleri uygulanmıştır. Test aşamasında alınan performans sonuçlarına göre, MNN modelinin diğerlerine oranla daha yüksek başarı oranlarıyla (100 %) sınıflandırma yaptığı gözlenmiştir. Bununla birlikte eşleştirmeli eğitim azaltımı öğrenme algoritması hızlı geri yayılım algoritmasına oranla daha iyi performans gösterdiği tespit edilmiştir.

6. Tanıma aşamasında kullanılan istatistiksel yaklaşımla yapay zeka yaklaşımının verdiği doğrulama performansları karşılıklı olarak değerlendirilmiştir. İstatistiksel yaklaşımda kullanılan Hamming uzaklığı yönteminde tanıma oranı CASIA veritabanı için ortalama 97,46 %, UBIRIS veritabanı için ortalama 92,28 % olarak gerçekleşmiştir. Alınan test sonuçları incelendiğinde, yapay zeka yaklaşımının istatistiksel yaklaşıma oranla daha yüksek doğrulama oranı ile tanıma gerçekleştirdiği görülmüştür. Buna karşılık, yapay sinir ağı ile tanımda süreç, istatistiksel yaklaşıma göre oldukça fazla vakit almaktadır. Bunun temel sebebi, yapay zeka yaklaşımında giriş görüntülerinin eğitim aşamasından geçmesinin gerekliliğidir. Ancak, eğitim süreci bir kere yapılacağından dolayı tanıma süresi olarak test süresinin alınmasının daha uygun olacağı düşünülmüştür. Dolayısıyla istatistiksel yaklaşım ile yapay sinir ağı yaklaşımı tanıma anlamında birbirine yakın sürede işlemi gerçekleştirmektedir.

YSA’nda eğitim süresi, uygulamada kullanılan bilgisayarın konfigürasyonuna göre değişiklik arz etmektedir. YSA ile yapılan eğitim süreleri Pentium 4 3.0 Ghz işlemci (ön bellek 1 Mb) ve 2x512 Mb DDR2 400 Mhz RAM belleğe sahip bir bilgisayardan (Bilgisayar 1) alınmış sürelerdir. Donanımın performansa olan etkisinin gösterilmesi amacıyla, CASIA veritabanından alınan ve 14*14 boyutlarında alt görüntülere bölünen 70 kişiye ait 490 adet iris görüntüsüne MNN sinir ağı modeli ile Pentium 4 Duo (çift çekirdek) 2x2.8 Ghz işlemci (ön bellek 2 Mb) ve 2x512 Mb DDR2 400 Mhz RAM belleğe sahip bir bilgisayarda (Bilgisayar 2) eğitilmiş ve iki örnek giriş üzerinde doğrulama performansı değerlendirmesi yapılmıştır (Tablo 9.1).

Tablo 9.1 Donanım karşılaştırmalı eğitim süreleri ve doğrulama oranları

Veritabanı ve Eğitim Modeli	Bilgisayar 1			Bilgisayar 2		
	Eğitim süresi (dk:sn)	İterasyon sayısı	Doğrulama Oranı (%)	Eğitim süresi (dk:sn)	İterasyon sayısı	Doğrulama Oranı (%)
CASIA 14*14 MNN - Eşleştirmeli Eğim öğrenme alg.	09:18	3948	97,14	08:35	3227	97,14
UBIRIS 10*10 MLP - Eşleştirmeli Eğim öğrenme alg.	02:48	1625	100	02:05	1287	100

Tablo 9.1’den de görüldüğü gibi, doğrulama oranları değişmeden iterasyon sayılarında bazı küçük farklılıklar oluşmuştur. İterasyon sayısında meydana gelen azalmaya paralel olarak, eğitim süresinde de azalma görülmüştür. Dolayısıyla, her iki bilgisayar konfigürasyonunda da hızın çok fazla değişmediği gözlemlenmiştir. Bunun sebebi, YSA eğitiminde kullanılan Neurosolutions programının konfigürasyondan fazla etkilenmemesi olarak söylenebilir.

7. CASIA ve UBIRIS veritabanlarından alınan iris görüntülerine uygulanan istatistiksel tanıma yaklaşımında tanıma oranını düşüren bazı dezavantajların olduğu görülmüştür. Bunların başında, karşılaştırılan görüntülerden herhangi birisinin net olmaması veya çok fazla gürültü (ışık yansımaları, kirpik, göz kapağı v.b.) içermesi ve dolayısıyla yanlış tanıma gerçekleşmesine sebep olması gelmektedir. Ayrıca, benzerlik oranını belirlemek için gerekli olan eşik değerinin hatalı belirlenmesinin de tanıma performansını doğrudan etkilediği görülmüştür. Çalışmada, bazı bozuk görüntüler (yetersiz ışık, netlik ayarı tam yapılmamış, kirpiklerin iris üzerine çok fazla gelmesi v.b.) her iki tanıma metoduna da giriş verisi olarak özellikle verilmiştir. Alınan sonuçlar analiz edildiğinde görülmüştür ki, istatistiksel karşılaştırmada bu tür giriş görüntüleri ya yanlış sınıflandırılmış, ya da reddedilmiştir. Buna karşılık, yapay zeka yöntemi ile tanıma işleminde bu görüntüler doğru olarak sınıflandırılmıştır. Bunun sebebi, bu tür bozuk görüntülerin de eğitim aşamasına katılmış olmasından ileri gelmektedir. Bu durum, yapay zekanın çok önemli bir avantajıdır.

Bu tez çalışmasından alınan uygulama sonuçları ile literatürde daha önce bu konuda yapılmış diğer çalışmalarla karşılaştırılmasına ilişkin tablo “tartışma” bölümünde verilmiştir.

Yapılan bu çalışmanın, gerçek bir sistemde online olarak kullanılması da mümkündür. Öncelikle kişilerin iris resimlerinin alınarak sisteme tanıtılması işlemi yapılmalıdır. Bu aşamada, göz resmi CCD kameralar kullanılarak yakalanır ve göz resmi içerisinden iris deseni çıkarılarak sayısal hale dönüştürülür. Tanıtım için her bir kişiden birden fazla görüntü yakalanması gerekir. Kişilere ait iris desenleri ayrı ayrı sınıflara dahil edilerek eğitim işlemi gerçekleştirilir. Bu noktaya kadar olan kısım, canlı sistemin çalışmasından önce yalnızca bir kez yapılması gereken bir işlemdir. Bu aşamadan sonra sistem tanıma aşamasına geçebilir. Tanıma aşaması çok

kısa sürede (milisaniye uzunluğunda) gerçekleşmektedir. Sisteme yeni bir kişi dahil edileceğinde, o kişiye ait göz resimleri alınarak sayısallaştırılır ve eğitim aşaması tekrar edilir.

Bu çalışmanın göz resmi içerisinde iris bölgesinin tespiti ve iris deseninin sayısallaştırılması aşamaları MATLAB programı kullanılarak gerçekleştirilmiştir. Sayısal iris bilgilerinin YSA kullanılarak sınıflandırılması işlemi ise NeuroSolutions programında yapılmıştır.

Genetik algoritmalar kullanılarak iris verisinin azaltılması işlemi gerçekleştirilmiş ve yeni giriş verileri ile YSA eğitimleri tekrarlanmıştır. Test sonuçlarına bakıldığında doğrulama performanslarının düştüğü gözlemlenmiştir. Bu durumun, iris özniteliklerinin azaltılmasında bazı ayırt edici özniteliklerin kaybolmasına sebep olması şeklinde açıklanması uygun görülmüştür.

9.2 Öneriler

Böylece çalışmada iris tanıma probleminin yapay zeka yöntemleri kullanılarak yüksek doğrulama oranı ile çözümlenebildiği gözlemlenmiştir. Ayrıca bozuk iris görüntülerinin istatistiksel tanıma ile doğru olarak tespit edilemediğini, bu sorunun yapay zeka yöntemleri ile aşılabildiği görülmüştür.

Bu tez çalışmasının bir aşaması olarak;

- Online bir iris tanıma sisteminin tasarlanarak, sistemin test edilmesi ve sonuçların değerlendirilmesi,

- Farklı yöntemlerle alınmış ve fazla sayıda iris görüntüsü içeren veritabanları üzerinde bu uygulamaların gerçekleştirilmesi ve doğrulama sonuçlarının analiz edilmesi,
- Eğitime girilen örnek sayısının artırılarak tanıma oranlarının gözlenmesi,
- Değişik öznitelik çıkarımlarının iris görüntüleri üzerinde uygulanarak elde edilecek öznitelik vektörlerinin doğrulama oranlarının incelenmesi,
- YSA'nın farklı modellerinin iris görüntüleri üzerinde uygulanarak deneysel sonuçların alınması,

gibi bazı önemli çalışmaların ileriye yönelik birer çalışmalar olarak önerilmesinde fayda görülmüştür.

10. TARTIŞMA

Bu çalışmada, yapay sinir ağları temeline dayanan bir iris tanıma sistemi geliştirilmiştir. Elde edilen sonuçların literatürde yer alan diğer iris tanıma sistemlerinden alınan sonuçlar ile karşılaştırılması yapılmıştır.

Bu çalışmada, iris tanıma sistemi aşamalarından görüntünün alınması, iris bölgesinin tespiti ve öznitelik çıkarımı işlemlerinde literatürde yer alan metotlar uygulanmıştır. görüntünün alınması aşamasında hazır iris görüntüleri içeren iki farklı veritabanı kullanılmıştır. Hazır iris görüntüleri içeren veritabanının kullanılması özellikle alınan test sonuçlarının literatürdekilerle karşılaştırılmasının yapılabilmesi açısından önemli bir avantaj sağlamaktadır. Ancak, bu tür veritabanlarında bir kişiye ait sınırlı sayıda iris görüntüsünün yer alması bir dezavantaj olarak söylenebilir. Iris bölgesinin tespiti aşamasında literatürde yer alan en etkili yöntemler tercih edilmiştir. Iris bölgesinin doğru bir şekilde tespit edilmesi işlemi bilinen yöntemler kullanılarak gerçekleştirilmiş, iris bölgesi üzerine gelen gürültülerin yok edilmesi amacıyla iris merkez noktasından itibaren aşağı yönde belirli bir kısmın alınması yöntemi bu çalışmada bir yenilik olarak uygulanmıştır. Bu da, bu çalışmada önemli bir avantaj olarak ön plana çıkmaktadır. Öznitelik çıkarımı aşamasında ise yine literatürde bilinen yöntemlerden etkili olanları tercih edilmiş, özellikle öznitelik vektörünün boyutunun küçültülmesi amacıyla görüntülerin alt görüntülere bölünmesi yöntemi yine bir yenilik olarak bu çalışmada kullanılmıştır.

Literatürde yer alan iris tanıma uygulamalarında karşılaştırma aşamasında genel anlamda istatistiksel, yani bire-bir karşılaştırma işlemi sıkça tercih edilmiştir. Yapılan son çalışmalarda özellikle yapay sinir ağları kullanılarak iris görüntülerinin sınıflandırılması işlemlerini görmekteyiz. Bu açıdan bakıldığında, bu çalışmanın karşılaştırma aşamasında izlediği yol, istatistiksel karşılaştırmanın dışında yer almaktadır. Dolayısıyla test aşamasında alınan sonuçların yapay sinir ağı kullanan iris tanıma çalışmalarıyla karşılaştırılması daha doğru olacaktır. Yapay sinir ağları

kullanarak gerçekleştirilen iris tanıma çalışmalarından alınan tanıma sonuçları ile bu tez çalışmasından alınan tanıma sonuçları Tablo 10.1’de verilmiştir.

Tablo 10.1 Yapay zeka yöntemleri ile iris tanıma üzerine yapılan önceki çalışmalar

Araştırmacı	Kullanılan Yöntemler			Kullanılan Veritabanı	Doğrulama Oranı
	Ön İşlem	Öznitelik Çıkarımı	Karşılaştırma		
Lim ve ark. (2001)	Hough Dönüşüm	Haar Dalgacık Dönüşümü	LVQ	200 kişiden alınan 6000 iris resmi	% 94,4
Liam ve ark. (2002)	Hough Dönüşüm	Gri seviye değeri	SOM	5 kişiden alınan 150 iris resmi	% 83
Alim ve ark. (2002)	Hough Dönüşüm	Gabor Dalgacık Dönüşümü	MLP	159 kişiden alınan iris resmi	% 96,1
Tez çalışması	Hough Dönüşüm	Ortalama Mutlak Sapma	MLP MNN Elman	70 kişiden alınan 490 iris resmi (CASIA) 60 kişiden alınan 300 iris resmi (UBIRIS)	% 97,14 (MNN) ----- % 100 (MNN)

Tablo 9.2’den de görüleceği üzere, Lim ve ark. (2001), karşılaştırma aşamasında yarışmalı (competitive) öğrenme algoritmasına (LVQ – Learning vector quantization) dayalı yapay sinir ağlarını uygulamışlardır. Çalışmalarında 200 kişiye ait toplam 6000 görüntü (her bir kişiye ait 30 örnek görüntü) kullanmışlar ve test verilerinde en yüksek % 94,4 doğrulama oranı elde etmişlerdir. Liam ve ark. (2002), iris görüntülerinin sınıflandırılmasında SOM (self organizing map) yöntemini kullanmışlardır. Çalışmalarında 5 kişiye ait toplam 150 iris görüntüsü (bir kişiye ait örnek sayısı 30) uygulamışlar ve % 83 doğrulama oranı bulmuşlardır. Alim ve ark. (2002), iris görüntülerini MLP kullanarak sınıflandırma gerçekleştirmişlerdir. 159 kişiden alınan iris görüntüleri üzerinde yapılan uygulama sonuçlarına göre en yüksek % 96,1 doğrulama oranı elde etmişlerdir. Oysa, bu tez çalışmasında geliştirilmiş olan

ve uygulanan yöntemlerle daha yüksek tanıma oranı elde edilmiştir. YSA modellerinden MLP, Elman ve MNN kullanılarak gerçekleştirilen sınıflandırma uygulamalarından alınan sonuçlara göre; CASIA iris veritabanından alınan 70 kişiye ait iris görüntüleri için en yüksek % 97,14 tanıma oranı, UBIRIS iris veritabanından alınan 60 kişiye ait iris görüntüleri için en yüksek % 100 tanıma oranı elde edilmiştir. Bu sonuçlar MNN modelinde sigmoid aktivasyon fonksiyonu kullanılarak alınmış sonuçlardır. Dolayısıyla, modüler sinir ağının diğerlerine göre daha iyi performans gösterdiği görülmüştür. Bunun nedeni, MNN modelinin yapısal anlamda modüllerden meydana gelmesi şeklinde söylenebilir. Yapılan araştırmalar, insan beyninin modüllerden oluştuğunu ve işlemleri bu modülleri kullanarak daha hızlı ve etkin yaptığını göstermektedir (Blonda ve ark. 1993, Belotti ve ark. 1995, Anand ve ark. 1995, Boers ve Kuiper 1992). Dolayısıyla, tanıma problemlerinde bu tip bir YSA modelinin daha iyi performans göstermesi beklenen bir sonuç olarak değerlendirilmiştir.

11. KAYNAKLAR

- Adler, F. H. 1965. Physiology of the Eye. St. Louis, MO: Mosby.
- Akaike, H. 1974. A new look at the statistical model identification. IEEE Trans. on Automatic Control, 19(6):716-723.
- Alim, O. ve Sharkas M. 2002. Texture classification of the human iris recognition using artificial neural Networks. Proc. of IEEE Melecon 2002, Cairo.
- Allahverdi, N. 2002. Uzman Sistemler Bir Yapay Zeka Uygulaması, Atlas Yayın Dağıtım, İstanbul.
- Anand, R., Mehrotra, K., Mohan, C.K. and Ranka, S. 1995. Efficient classification for multiclass problems using modular neural networks. In: IEEE Transactions on Neural Networks, Vol. 6, No. 1. pp. 117-124.
- Belotti, R., Castellano, M., De Marzo, C. and Satalino, G. 1995. Signal/Background classification in a cosmic ray space experiment by a modular neural system. In: Proc. of the SPIE - The International Society for Optical Engineering, Vol. 2492, No. pt.2. pp. 1153-1161.
- Bishop, C.M. 1995. Neural Network for Pattern Recognition, Oxford University Pres, England.
- Blonda, P. Laforgia, V., Pasquariello, G. and Satalino, G. 1993. Multispectral classification by modular neural network architecture. In: IGARSS '94. International Geoscience and Remote Sensing Technologies, Data Analysis and Interpretation, Vol. 4. pp. 1873-1876. New York, USA.
- Boers, E.J.W. and Kuiper, H. 1992. Biological metaphors and the design of modular artificial neural networks, Master thesis, Departments of Computer Science and Experimental and Theoretical Psychology at Leiden University, the Netherlands.
- Boles, W.W. and Boashah B. 1998. A human identification Technique Using Images of the Iris and Wavelet Transform, IEEE Tr. on Signal Proces., Vol. 46, pp. 1185-1188.
- Bolle, R. M., Connell J. H., Pankanti S., Ratha N. K. and Andrew W. S. 2004. Guide To Biometrics, Springer-Verlag New York, Inc.

- Breiman, L. 1994. Heuristics of instability in model selection. Technical Report Statistics Department, University of California at Berkeley.
- Burge, M.J. and Burger, W. 2000. Ear biometrics in computer vision. Proceedings of the International Conference on Pattern Recognition, pp. 826-830.
- Burnham, K. P., and D. R. Anderson. 2002. Model selection and multimodel inference: a practical information-theoretic approach. 2nd Edition. Springer-Verlag, New York, USA. 488 pp.
- Campbell, J. 1999. Speaker Recognition. Biometrics: Personal Identification in Networked Society, pp. 165-190, Kluwer Academic Pres, Boston, MA.
- Chen, W. and Yuan S. 2003. A Novel Personal Biometric Authentication Technique Using Human Iris based on Fractal Dimension Features, Proc. Of Int. Conf. On Acoustics, Speech and Signal Processing, Vol. 3, 2003, pp. 201-204.
- Chiang, C-C. and Fu, H-C. 1994. Divide-and-conquer methodology for modular supervised neural network design. In: Proceedings of the 1994 IEEE International Conference on Neural Networks. Part 1 (of 7). pp. 119-124. Orlando, FL, USA.
- Çankaya, İ. ve Vatansever, F. 2002. Fourier ve Dalgacık Dönüşümünün Karşılaştırılması, SDÜ Fen Bil. Ens. Dergisi, Cilt 6, Sayı 3, sayfa 14-24.
- Darter, M.O. and Gordon, V. 2005. Vehicle Steering Control Using Modular Neural Networks. IEEE International Conference on Information Reuse and Integration (IRI-2005), Las Vegas, NV, pp 374-379.
- Daugman, J. 1985. Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. Journal of the Optical Society of America A 2(7): 1160-1169.
- Daugman, J. 1988. Complete discrete 2D Gabor transforms by neural networks for image analysis and compression. Trans. Acous. Sp. Sig. Proc. 36(7): 1169-1179.
- Daugman, J. 1993. High confidence visual recognition of persons by a test of statistical independence. IEEE Trans. Pattern Anal. Machine Intell., vol. 15, no. 11, pp. 1148–1161.
- Daugman, J. 1994. U.S. Patent No. 5,291,560: Biometric Personal Identification System Based on Iris Analysis. Issue Date: 1 March 1994.

- Daugman, J. 2001. Statistical Richness of Visual Phase Information: Update on Recognizing Persons by Iris Patterns, *Int. Journal of Computer Vision* 45 (1), Kluwer Academic, pp. 25-38.
- Daugman, J. 2003. The importance of being random: statistical principles of iris recognition. *Journal of Pattern Recognition Society*, Elsevier, pp 279-291.
- Dell Magazine, Şubat 2000
- Dickinson, A., McPherson, R., Mendis, S., and Ross, P.C. 2000. Capacitive Fingerprint Sensor with Adjustable Gain, US Patent 6049620.
- Dodd, N. 1990. Optimization of network structure using genetic algorithms. *Proceedings of the International Neural Network Conference, INNC-90-Paris*, 693-696, B. Widrow and B. Angeniol (Eds.), Kluwer, Dordrecht.
- ED 2007. <http://www.dtek.chalmers.se/~d95danb/ocr/eucl.html>. Son erişim tarihi: 13.03.2007
- El-Bakry H. M.2001. Human iris detection using fast cooperative modular neural networks. *Int. Joint Conf. on Neural Networks*, Washington, Dc., USA, 14-19 July, 577-582.
- Ellsworth, D. and Moran, P. 2003. Accelerating Large Data Analysis By Exploiting Regularities. *Proceedings of IEEE Visualization 2003*, WA, pp. 561-568.
- Elman, J.L. 1990, Finding structure in time, *Cognitive Science*, Vol. 14, pp. 179-211.
- Emel, G.G. ve Taşkın, Ç. 2002. Genetik Algoritmalar ve Uygulama Alanları, *U.Ü. İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt XXI, Sayı 1, sayfa 129-152.
- Fahlman, S.E. 1988. An empirical study of learning speed in back-propagation networks. Technical report, Carnegie Mellon University.
- Farrugia, S., Yee, H. and Nickolls, P. 1993. Modular connectionist architectures for multi-patient ECG recognition. In: *3rd International Conference on Artificial Neural Networks*, IEE Conference Publication No. 372. pp. 272-276. Brighton, England.
- Fausett, L.V. 1994. *Fundamentals of Neural Networks: Architectures, Algorithms And Applications*, Prentice Hall Publ.
- FCM 2007.
- http://www.elet.polimi.it/upload/matteucc/Clustering/tutorial_html/cmeans.htm
1. Son erişim tarihi: 13.03.2007

- Fine, T. L. 1999. Feedforward Neural Network Methodology. Springer, New York.
- Fisher, R.A. 1936. The use of multiple measurements in taxonomic problems, *Annals of Eugenics*, 7, 179-188.
- Flom, L. and Safir, A. 1987. Iris recognition system. U.S. Patent 4 641 349.
- Freeman, J., and Skapura, D. 1991. Neural Networks. Reading MA: Addison-Wesley Publ.
- Furui, S. 1997. Recent advances in speaker recognition. Audio and video- based Biometric Person Authentication, LNCS volume 1206, pp. 237-252, Germany.
- Han, J. and Kamber, M. 2000. Data Mining: Concepts and Techniques, Morgan Kaufmann Publishers.
- Happel, B.L.M. 1992. Architecture and function of neural networks: designing modular architectures. In prep.
- Happel, B.L.M. and Murre, J.M. 1994. Design and Evolution of Modular Neural Architectures. *Neural Networks*, Vol. 7, No. 6/7, pp. 985-1004.
- Haykin, S. 1999. Neural Networks A Comprehensive Foundation, Prentice Hall publishing, New Jersey.
- Hebb, D.O. 1949. The Organization of Behaviour: A Neuropsychological Theory, New York: Wiley.
- Hill, R. 1999. Retina Identification. *Biometrics: Personal Identification in Networked Society*, pp. 123-142, Kluwer Academic Pres, Boston.
- HIPR 2007. <http://homepages.inf.ed.ac.uk/rbf/HIPR2/wksheets.htm>. Son erişim tarihi: 13.03.2007
- Hong, L. and Jain A.K. 1998. Integrating Faces and Fingerprints for Personal Identification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 12, pp. 1295-1307.
- Hopfield, J.J. 1982. Neural Networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences, USA*, vol. 79, pp. 2254-2258.
- Huang, Y.P., Luo, S.W. and Chen, E.Y. 2002. An efficient iris recognition system. *Proc.1st Int. Conf. Mach. Learning and Cybernetics*, Beijing.
- IBG 2006. <http://www.biometricgroup.com/index.html> , son erişim tarihi 13.03.2007.

- Inglis, C., Manchanda, L., Comizzoll, R., Dickinson, A., Martin, E., Mandis, S., Silveman, P., Weber, G., Ackland, B., and O'Gorman, L. 1998. A Robust, 1.8 V, 250 mW, Direct Contact 500 dpi Fingerprint Sensor. Proc. of IEEE Solid-State Circuits Conf, pp. 284-285.
- Jain, L.C., Halici U., Hayashi I., and Lee S.B. 1999a. Intelligent Biometric Techniques in Fingerprint and Face Recognition, CRC Press, Boca Raton, FL.
- Jain, A. K., Ross, A., and Pankanti, S. 1999b. A Prototype Hand Geometry-Based Verification System. 2nd International Conference on Audio- and Video-based Biometric Person Authentication, Washington D.C., pp. 166-171, March 22-24.
- Jayant, N. S. and Noll, P. 1984. Digital Coding of Waveforms. Englewood Cliffs, NJ: Prentice-Hall.
- Johnson, R. G. 1991. Can iris patterns be used to identify people. Los Alamos National Laboratory, CA, Chemical and Laser Sciences Division, LA-12331-PR.
- Kitano, H. 1990. Designing neural networks using genetic algorithms with graph generation system. Complex Systems, 4, 461-476, Champaign, IL.
- Ko, T. 2005. Multimodal Biometric Identification for Large User Population Using Fingerprint, Face and Iris Recognition. Proc. of 34rd Applied Imagery and Pattern Recognition Workshop.
- Kohonen, T. 1982. Self-organized formation of topologically correct feature maps. Biological Cybernetics, vol. 43, pp. 59-69.
- Kong, W.K. and Zhang, D. 2001. Acurate iris segmentation based on novel reflection and eyelash detection model, in Proceedings of Int. Symp. Ov Intelligent Multimedia, Video and Speech Processing, Honk Kong, pp. 263-266.
- Kronfeld, P. C. 1962. Gross anatomy and embryology of the eye. In: The Eye, H. Davson, Ed.) Academic Press: London.
- Kronfeld, P. C. 1968. The gross anatomy and embryology of the eye. In: The Eye, vol. 1, H. Davson, Ed. London: Academic, pp. 1-66.
- Lee, J.W., Min, P.I., Kim, I. and Kim, W. 1999. A 600 dpi Capacitive Fingerprint Sensor Chip and Image Synthesis Technique. IEEE Journal of Solid-State Circuits, vol. 34, no. 4, pp. 469-475.

- Liam, L., Chekima, A., Fan, L. and Dargham, J. 2002. Iris recognition using self-organizing neural network. In IEEE, 2002 Student Conference on Research and Developing Systems, pp. 169–172, Malaysia.
- Lim, S., Lee, K., Byeon, O. and Kim, t. 2001. Efficient Iris Recognition through Improvement of Feature Vector and Classifier, ETRI J., Vol. 23, No. 2, PP. 61-70.
- Liu, W., Wang, Y., Li, S.Z., Tan, T. 2004. Null Space Approach of Fisher Discriminant Analysis for Face Recognition, ECCV workshop on Biometric Authentication.
- Liu, Y., Yuan, S., Zhu, X. and Ciu, Q. 2003. A practical acquisition system and a fast edges locating algorithm in iris recognition. Instruments and Measurement Technology Conference, USA.
- Luenberger, D. G. 2003. Linear and nonlinear programming, second edition. Springer.
- Ma, L., Wang Y. and Tan T. 2002a. Iris recognition based on Multichannel Gabor Filtering, The 5th Asian Conference on Computer Vision, Australia.
- Ma, L., Wang, Y. And Tan, T. 2002b. Iris recognition using circular symmetric filters, 16th International Conf. on Pattern Recognition, vol. II, pp. 414-417.
- Masek, L. 2003. Recognition of Human Iris Patterns for Biometric Identification, Bachelor of Eng. Thesis, The University of Western Australia.
- McCulloch, W. S. and Pitts, W. H. 1943. A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 5:115-133.
- McPherson, S.R. 2001. A study of a personal iris recognition system for biometric identification. Master of Engineering, University of Louisville.
- Mira, J. and Mayer, J. 2003. Image Feature Extraction for Application of Biometric Identification of Iris – A morphological Approach. Proc. of 16rd Brazilian Symposium on Computer Graphics and Image Processing, Brasil.
- Miyazawa, K., Ito, K., Aoki, T., Kobayashi, K. and Nakajima, H. 2006. An implementation-oriented iris recognition algorithm using phase-based image matching. Int. Symposium on Intelligent Signal Processing and Communication Systems, Japan, pp. 231-234.

MMO 2007

http://www.mmo.org.tr/muhendismakina/arsiv/2001/ekim/Genetik_Algoritma.htm , son erişim tarihi: 13.03.2007

- Nabiyev, V. 2005. Yapay Zeka Problemler – Yöntemler – Algoritma, Seçkin Yay.
- Nabiyev, V. ve Yavuz, Z. 2005. Vucut Dilinin Bilgisayarda Yorumlanması ve Bilgisayarlı Dudak Okuma. 4. Uluslar arası İleri Teknolojiler Sempozyumu, Konya.
- Nalwa, V.S. 1997. Automatic on-line signature verification. Proc. of IEEE, 85 (2): 215-239.
- Nan, J., Zhiye, Z. and Liqun, R. 2003. Design of structural modular neural networks with genetic algorithm, Advances in Engineering Software, 34:17-24.
- National Research Council (NRC) 1996. The evaluation of forensic DNA evidence. Technical report, National Academy Press, Washington D.C.
- Newell, F. W. 1991. Ophthalmology Principles and Practice, 7th ed. St. Louis, MO: Mosby.
- Nixon, M.S., Carter, J.N., Cunado, D., Huang, P.S, and Stevenage, S.V. 1999. Automatic gait recognition. Biometrics: Personal Identification in Networked Society, pp. 231-248. Kluwer Academic Press, Boston, MA.
- NLPR 2007, <http://www.nlpr.ia.ac.cn/english/irids/irisdatabase.htm>, Son erişim tarihi: 13.03.2007
- Noh, S., Bae, K. and Kim, J. 2003. A novel method to extract features for iris recognition system, in Proc. 4th Int. Conf. Audio- and Video-Based Biometric Person Authentication, pp. 838-844.
- Olivier, G. 1969. Practical Anthropology. Springfield, IL: Charles C. Thomas.
- Öztemel, E. 2003. Yapay Sinir Ağları, Papatya Yayınevi, İstanbul.
- Özbay, Y., Karlık B. 2001. A Recognition of ECG Arrhythmia Using Artificial Neural Networks. 23rd Annual International Conference IEEE Engineering in Medicine and Biology Society, Istanbul, Turkey.
- Patterson, D.W. 1996. Artificial Neural Networks. Theory and Applications. Prentice Hall. Singapore.
- Petrova, K. 2002. Biometric Security Systems: Finally, a Friend?, 1st International Conference on Information Tech & Appl., Sydney.

- Proenca, H. and Alexandre L. 2005. UBIRIS: A noisy iris image database, Proc. Of Int. Conf. on Image Analysis and Processing, Vol. 1, pp. 970-977.
- Prokoski, F.J. and Riedel, R. 1999. Infrared identification of faces and body parts. Biometrics: Personal Identification in Networked Society, pp. 191-212, Kluwer Academic Pres, Boston.
- Rosenblatt, F. 1958. The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review, 65:386-408.
- Rumelhart, D. E., Hinton, G. E., and Williams, R. J. 1986. Learning representations by back-propagating errors. Nature, 323:533—536.
- Sağıroğlu, Ş., Beşdok, E. ve Erler, M. 2003. Mühendislikte Yapay Zeka Uygulamaları-1 Yapay Sinir Ağları, Ufuk Yayıncılık, Kayseri.
- Sanchez-Avila, C. and Sanchez-Reillo R. 2002. Multiscale Analysis for Iris Biometrics. Proc. of Int. Carnahan Conference on Security Technology, pp 35-38.
- Sanchez-Reillo, R., Sanchez-Avila C. and Martin-Pereda J.A. 1999. Minimal template size for iris recognition, Proc. of BMES/EBMS Conf., IEEE Publ., Atlanta.
- Sanchez-Reillo, R. and Sanchez-Avila C. 2000. Processing of the human iris pattern for biometric identification. Proc. of IPMU, pp 653-656.
- Schwarz, G. 1978. Estimating the Dimension of a Model. The Annals of Statistics, 6, 2, 461-464.
- Sinha, P. 1992. A head mounted display. Bachelor's thesis, Department of Electrical Engineering and Computer Science, Massachusetts Institute of Technology, Cambridge.
- Srihari, S.N., Cha, S., Arora, H. and Lee, S. 2002. Individuality of handwriting. Journal of Forensic Sciences, 47(4): 1-17.
- Sun, Z., Wang, Y., Tan, T. and Cui, J. 2005. Improving iris recognition accuracy via cascaded classifiers. IEEE Trans. on Systems, Man. and Cybernetics, vol. 35, no. 3, pp. 435-441.
- Szewczyk, R., Jablonski, P. Kulesza, Z., Napieralski, A., Cabestany, J. and Moreno, M. 2002. Automatic people identification on the basis of the iris pattern-

- extraction features and classification. Proc. of 23rd Int. Conf. on Microelectronics, vol. 2, Yugoslavia.
- Tisse, C.-L., Martin, L., Torres, L. and Robert, M. 2002. Person identification technique using human iris recognition. The 15th International Conference on Vision Interface, pp.294–299.
- Türkoğlu, İ., Arslan, A. 1996. Yapay Sinir Ağları ile Bozuk Örüntü Tanıma, F.Ü. Fen ve Mühendislik Bilimleri Dergisi, 8, 147 – 158.
- Uludag, U., Gunsel, B., and Ballan M. 2001. A spatial method for watermarking of fingerprint images. Proc. First Intl. Workshop on Pattern Recognition in Information Systems, Setúbal, Portugal, pp. 26-33.
- Umbaugh, S.E. 1999. Computer Vision and Image Processing A Practical Approach using CVIP tools, Prentice Hall, New Jersey.
- Vatsa, M., Singh, R. and Gupta, P. 2004. Comparison of iris recognition algorithms. International Conference on Intelligent Sensing and Information Processing India, pp.354-358.
- Vesalius, 1543. De Humani Corporis Fabrica.
- Wasserman, P. 1974. Ethnic Pigmentation. New York: Elsevier.
- Wickerhauser, M.V. 1994. Adapted Wavelet Analysis from Theory to Software, 1 st ed.
- Widrow, B. And Hoff, M.E. 1960. Adaptive switching circuits. IRE WESCON Convention record, pp. 96-104.
- Wildes, R.P. 1997. Iris Recognition: An Emerging Bionetric Technology. Proceedings of the IEEE Vol. 85 No. 9.
- Wildes, R. P., Asmuth J. C., Green G. L., Hsu S. C., Kolczynski R. J., Matey J. R., Matey J. R. and McBride S. E. 1992. Iris recognition for security access control: Final report. National Information Display Laboratory, Princeton, NJ.
- Wildes, R., Asmuth, J., Green, G., Hsu, S., Kolczynski, R., Matey, J., McBride. S. 1994. A system for automated iris recognition. Proceedings IEEE Workshop on Applications of Computer Vision, Sarasota, FL, pp. 121-128.
- Wildes, R. P., Asmuth J. C., Green G. L., Hsu S. C., Kolczynski R. J., Matey J. R., and McBride S. E. 1996. A machine vision system for iris recognition. Mach. Vision Applicat., vol. 9, pp. 1–8.

- Yu, L., Wang, K., Wang, C. And Zhang, D. 2002. Iris verification based on fractional fourier transform. Proc. of 1st Int. Conf. on Machine Learning and Cybernetics, Beijing.
- Zadeh, L.A. 1965. Fuzzy sets. Information and Control, 8(3):338-353.
- Zhu, Y., Tan, T., Wang, Y. 2000. Biometric personal identification based on iris patterns. Proceedings of the 15th International Conference on Pattern Recognition, Spain, Vol. 2.

EKLER


EK-1: UYGULAMA YAZILIMLARI

Bu Ek bölümünde, tez çalışmasında kullanılan uygulama yazılımlarından ekran görüntüleri detaylı olarak gösterilmiştir. Bu uygulamalar, Mathworks firmasının geliştirdiği MATLAB ve NeuroDimension firmasının geliştirdiği NeuroSolutions programları kullanılarak gerçekleştirilmiştir. MATLAB, sayısal ve sembolik hesaplamalar, veri çözümlemesi, gerçek ortamda test ve ölçüm yapabilme, çok gelişmiş çizim işlemleri, algoritma geliştirme, ileri seviye programlama, C/C++ ile tümleşik çalışabilmesi, mühendislik ve bilimsel uygulamaları ile tüm dünyada bir çok alanda yaygın olarak kullanılan yazılımdır. NeuroSolutions ise verilerin analizi, sınıflandırılması gibi işlemlerin kolayca gerçekleştirilebileceği yapay sinir ağı modelleri oluşturabilen grafik arayüze sahip bir uygulama yazılımıdır.

İlk aşamada, Hamming uzaklığı ile karşılaştırma amacıyla MATLAB programında geliştirilen yazılımının ekran görüntüleri verilmiştir (Şekil 1-6). Bu kısım, görüntünün alınması, öznitelik çıkarımı, özniteliklerin veritabanına eklenmesi ve karşılaştırmanın sonucu görüntülerini içermektedir.


İkinci aşamada ise, NeuroSolutions programı kullanılarak YSA metodu ile iris tanıma işlemi ekran görüntüleri verilmiştir (Şekil 7-11). Bu kısım, iris öznitelik veri kümesi, eğitim aşaması ve test sonuçları ekran görüntülerini içermektedir.

Hamming uzaklığı ile iris tanıma aşaması için geliştirilen MATLAB yazılımında ana menü, “Görüntü Seç”, “Seçilen görüntüyü veritabanına ekle”, “Veritabanı Bilgisi”, “Tanıma işlemi”, “Veritabanı Sil”, “Video Görüntüsü Al”, “Görüntü Yakala” ve “Çıkış” seçeneklerini içermektedir (Şekil 1).




Şekil 1. Hamming Uzaklığı ile tanıma yazılımı - Ana menü

“Görüntü Seç” butonuna basıldığında dosya seçme penceresi gelmektedir (Şekil 2). Bu pencereden seçilen iris görüntüsü üzerinde işlemler gerçekleştirilmektedir.




Şekil 2. Hamming Uzaklığı ile tanıma yazılımı – İris görüntüsü seçme ekranı

İris görüntüsü seçme ekranından seçilen iris görüntüsü, ayrı bir şekil penceresinde gösterilir (Şekil 3).




Şekil 3. Hamming Uzaklığı ile tanıma yazılımı - Seçilmiş iris görüntüsü

Seçilen iris görüntüsünün veritabanına eklenmesi işleminde, sınıf sayısının belirtildiği metin giriş kutusu ekrana gösterilir (Şekil 4).




Şekil 4. Hamming Uzaklığı ile tanıma yazılımı - Veritabanına ekleme

İris tanıma seçeneğinde, öznitelikleri çıkarılan iris görüntüsünün hangi sınıfa dahil olduğu belirlenir ve ekrana bir mesaj kutusu ile gösterilir (Şekil 5).



Şekil 5. Hamming Uzaklığı ile tanıma yazılımı - Tanımlanan iris görüntüsü

Eğer giriş iris görüntüsü herhangi bir sınıfa dahil değilse, bir başka deyişle daha önceden veritabanına eklenmediyse iris görüntüsünün tanımlanamadığı mesajı ekrana yansıtılır (Şekil 6).



Şekil 6. Hamming Uzaklığı ile tanıma yazılımı – Tanımlanamayan iris görüntüsü

YSA ile iris tanıma aşamasında NeuroSolutions programı kullanılmıştır. Bu program Microsoft Excel programı ile tümleşik olarak çalışmaktadır. Excel programı sınıflandırılacak iris bilgisini içermektedir. NeuroSolutions programı Excel içerisinde yer alan üst menülere “NeuroSolutions” seçeneğini ekler. Bu menü yardımıyla Excel’de açılmış olan iris veri kümelerinin özellikleri belirlenir. Örneğin, hangi sütunların giriş bilgisi veya çıkış sınıf bilgisi olduğu, hangi satırların eğitim veya test aşamasında kullanılacağı belirlenir (Şekil 7).

Microsoft Excel - casia_1414_70.csv

Yardımcı işlevler: Yarıdan itibaren yazın

Arad tür

	AA	AB	AC	AD	AE	AF	AG	AH	AI	AJ	AK	AL	AM	AN	AO	AP	AQ	AR	AS
2	1.695	1.2572	1.0369	0.83937	1.2212	1.1888	1.3591	0.57219	0.78719	1.3859	0.73344	0.71937	1.1991	1.3544	1.0719	1.6403	1.655	0.96344	A1
3	1.5004	1.0153	1.0191	0.91469	1.2501	0.99375	0.91600	0.35656	0.73969	1.4737	0.94375	0.7725	0.96100	1.3359	0.06701	1.4497	1.1244	0.76563	A1
4	1.2084	0.90875	1.0063	0.82375	1.3159	0.8525	1.0991	0.3025	0.55937	1.1472	0.7975	0.70531	1.1291	1.1969	1.0181	1.7831	1.6091	1.0134	A1
5	1.4181	0.96375	1.2309	0.75	1.1475	0.8975	1.0263	0.18489	0.57406	1.3225	0.84084	0.825	1.125	1.0731	1.1075	1.6191	1.2041	0.87031	A1
6	1.5116	1.0556	0.09125	0.05719	0.99219	0.85094	0.94344	0.066075	0.42201	0.99607	0.405	0.67094	0.07813	0.96531	0.79075	1.0209	1.2047	0.70107	A1
7	1.5219	1.1141	0.91312	0.705	1.2872	0.70281	1.0125	0.064062	0.39	1.0806	0.64344	0.74594	0.96437	0.95219	0.72625	1.4866	1.7456	1.2156	A1
8	1.0088	0.83375	0.76663	0.69531	0.58813	0.70813	1.4394	0.26313	1.14156	1.2128	0.63687	0.54125	0.69063	1.1216	1.1366	0.47687	1.0659	0.79125	A2
9	1.3069	0.82437	0.005	0.70563	0.57906	0.67108	1.1309	0.35944	0.004600	0.79201	0.53075	0.605	0.62594	0.04125	0.0725	0.51906	1.0697	0.96084	A2
10	1.5384	0.64344	0.025	0.83437	0.87375	0.88969	1.5806	0.40219	0.1875	0.98719	0.44781	0.38875	0.93406	1.3769	1.2888	0.80875	0.40875	0.51906	A2
11	0.77489	0.88219	0.8775	0.47166	0.585	0.51594	1.4463	0.26188	0.071963	1.0972	0.58344	0.48375	0.44031	0.98987	1.2953	0.69888	1.4797	1.0786	A2
12	1.4719	0.76594	0.91656	0.55969	0.61201	0.75201	1.2022	0.305	0.01075	1.2756	0.65594	0.54312	0.60625	0.01625	1.1603	0.03437	1.0131	0.87013	A2
13	1.0372	0.85313	0.99813	0.43156	0.65094	0.64094	1.4434	0.20313	0.064062	1.1256	0.85219	0.50656	0.65406	0.87531	1.5688	0.69594	1.2138	0.91312	A2
14	2.0831	2.1603	1.9815	1.7081	0.90312	0.7825	0.93806	0.21313	0.20281	1.4038	0.74438	0.86631	0.92663	1.0628	0.97625	0.83	1.2231	0.96084	A3
15	1.9006	2.1901	1.815	1.6775	0.9	0.93437	1.0506	0.10125	0.29125	1.3744	0.73930	0.93375	0.81469	0.02531	0.76107	0.93531	1.0994	0.94906	A3
16	2.2147	2.2859	1.7347	1.9087	0.97125	0.82188	0.98125	0.16594	0.25031	1.5622	0.88656	0.69125	0.77438	0.83313	0.96031	0.875	0.91	0.84031	A3
17	2.1862	2.1131	1.8806	1.6863	0.88406	0.70489	1.0953	0.22625	0.21375	1.565	0.79694	0.73666	0.78969	0.92688	0.96219	0.96688	0.88938	0.72406	A3
18	2.0347	2.1309	1.0372	1.0416	0.06607	0.72313	1.0625	0.14656	0.25600	1.5572	0.08107	0.76594	0.81031	0.94156	1.0131	1.1253	1.0120	0.70031	A3
19	1.8563	2.1659	1.8131	1.7962	0.85344	0.875	1.1781	0.48281	0.48188	1.6241	1.0256	0.78969	0.93031	1.2028	0.90844	1.6853	0.705	0.7725	A3
20	0.98489	1.965	2.1086	0.86489	1.8322	0.96781	1.2384	0.16475	0.03830	0.89719	1.5403	1.1086	1.2534	1.5987	1.5884	0.79438	1.3075	1.9109	A4
21	1.2420	1.7172	2.0353	0.87562	1.4566	1.7184	1.6430	0.075	0.04625	1.2487	1.0356	1.1397	1.0330	2.0403	1.6019	0.00075	1.5719	1.4901	A4
22	1.0769	1.2959	1.8675	1.1094	1.0519	1.7997	1.3681	0.38094	0.00375	1.0256	1.9181	1.3634	2.2686	2.1053	1.2663	0.8525	1.6447	1.9363	A4
23	1.2913	1.3281	1.9191	0.8375	1.4503	1.3444	1.01	0.48938	0.16625	1.0106	1.2909	0.69666	1.6156	1.4753	1.1881	0.91406	1.3653	2.0291	A4
24	1.1741	1.4630	1.9159	0.96531	1.5544	1.2069	0.9575	0.64219	0.1725	1.2069	0.6675	0.9975	1.2591	1.5600	1.4531	1.065	1.3391	1.9694	A4
25	1.1819	1.2972	1.8603	1.035	1.4741	0.64344	0.82969	0.53312	0.19031	1.0306	1.87	0.31625	1.3884	1.0722	1.0497	0.96562	1.6159	1.18	A4
26	0.79688	0.88813	1.3125	1.2863	1.3316	1.3234	1.3619	1.1366	0.57666	0.88906	1.0472	0.95	0.74906	1.2091	1.7263	1.7734	2.2581	1.6697	A5
27	0.90594	1.0125	1.4906	1.3225	1.0016	1.3522	1.3713	0.05031	0.255	0.795	1.1625	0.95906	1.5484	2.1425	2.0181	1.6430	1.9019	1.3422	A5
28	0.99344	0.98625	1.4919	0.96888	1.3038	1.2166	1.2709	0.73281	0.26438	0.79219	0.68094	0.59006	1.4247	2.0319	1.8431	1.4856	2.0806	0.93344	A5
29	1.0869	0.925	1.4428	0.81031	1.0397	0.83344	1.2756	0.4	0.46937	1.0619	0.80631	0.87438	1.2775	1.3288	1.2497	1.3041	1.7481	1.3747	A5
30	1.1694	1.0459	1.2744	0.27	0.62075	0.63656	0.73469	0.50108	0.2025	0.62969	1.0022	0.73375	0.90156	1.0331	0.92312	1.3925	1.0122	1.1034	A5
31	0.84562	1.1156	1.3297	0.99525	1.0384	1.0734	1.2897	0.94625	0.49562	1.3384	0.99	0.53781	1.3961	1.9216	1.8081	0.99006	1.1409	0.6825	A5
32	1.415	2.9986	0.74887	0.99375	0.88938	0.9825	1.586	0.21666	0.075625	2.3294	3.3489	1.6684	0.80281	1.4753	1.2319	1.2797	0.61625	2.0128	A6
33	1.3072	2.4972	0.96313	0.96062	0.66663	0.87781	1.4306	0.069607	0.10094	2.3775	2.7475	1.7809	0.76531	0.965	1.0259	1.4070	1.5069	1.69	A6
34	1.5047	2.1556	1.5709	0.88375	0.87781	0.7675	1.2997	0	0.11656	2.5103	1.7247	1.5275	1.0322	1.1397	1.1884	1.7819	2.5884	1.5203	A6
35	1.7613	1.0578	0.83281	0.88084	1.2247	1.3131	1.3541	0.069897	0.23281	1.965	1.4112	1.4381	1.3884	1.8922	1.15	1.7184	2.9494	1.6216	A6
36	1.7075	1.5209	1.2025	0.74906	1.0504	0.97406	1.3	0.099062	0.031563	1.0331	1.2920	1.3920	1.4606	1.4500	1.1525	1.3766	3.0047	1.9009	A6
37	1.1931	1.595	1.3016	0.70906	0.96156	1.1034	1.1291	0.27094	1.0688	2.2647	1.4212	1.2478	1.4278	1.1391	0.9475	1.6353	2.6259	1.6809	A6
38	1.8481	1.6638	1.2809	1.3972	1.9247	1.3391	1.565	0.6475	0.68969	2.4838	0.8325	0.42812	1.7306	1.23	1.2309	2.3069	2.6847	1.8478	A7
39	1.6103	1.0616	1.2670	1.0907	1.7204	1.0556	1.5244	0.57719	0.51094	2.4853	0.64406	0.3075	0.96044	1.3725	1.0875	2.0569	2.7170	1.8519	A7
40	1.5588	2.0475	1.4844	1.4734	1.6256	1.7341	1.3597	0.77	0.49812	2.2528	0.96875	0.53281	2.0053	2.0306	1.5203	2.0328	2.4231	1.9572	A7
41	1.7337	1.9634	1.6872	2.0522	1.7153	1.9222	1.2044	0.79812	0.79888	1.1703	0.78984	0.94875	1.6344	1.6419	1.4172	1.4441	2.0894	1.6716	A7
42	1.5234	1.6001	1.4530	1.4756	1.4331	0.89219	2.0559	1.4063	0.40107	2.1959	0.61562	0.69006	1.6034	1.3075	1.8609	2.2122	2.5703	1.8041	A7
43	1.7825	2.2763	1.0994	1.0509	1.6825	1.5234	1.5375	0.55375	2.1122	1.4447	0.95375	1.1791	1.3713	1.6753	1.0428	2.8116	1.6928	1.8906	A7
44	2.0484	0.8775	1.2713	1.0444	0.59719	0.63062	1.0847	0.54594	0.38	1.0263	0.58437	0.92084	0.63684	0.98666	1.0981	1.1863	1.0063	0.75938	A8
45	2.2503	0.94656	1.0794	1.3272	0.52187	0.60044	0.91600	0.36201	0.42430	1.2030	0.51375	0.72594	0.54937	0.515	0.66107	1.1047	1.5575	1.3925	A8
46	1.7822	1.0016	1.085	1.3613	0.62187	0.63281	0.94625	0.58437	0.49281	1.2678	0.59344	0.60156	0.395	0.60781	0.99594	1.4253	1.6034	1.6053	A8


casia_1414_70

rez_nu_son

SAYI


Şekil 7. YSA ile iris tanıma yazılımı – İris veri kümesi

İris veri kümeleri ile ilgili tüm bilgiler belirlendikten sonra üst menüden yeni bir ağ oluşturulur. Bu aşamadan sonra NeuroSolutions arayüz penceresi aktif hale geçerek ağıın model özellikleri tanınması istenir (Şekil 8).




Şekil 8. YSA ile iris tanıma yazılımı – YSA model seçimi

YSA ağ modeli belirlendikten sonra eğitim aşamasına geçilir. Bu aşamada eğitim ismi, iterasyon sayısı gibi bilgiler belirlenir (Şekil 8).




Şekil 8. YSA ile iris tanıma yazılımı – Eğitim iterasyon sayısı belirleme

Eğitim sırasında gerçekleştirilen iterasyon sayısı, kalan süre, sınıflandırma bilgisi, MSE değeri gibi bilgiler ekranda gösterilir (Şekil 9).



Şekil 9. YSA ile iris tanıma yazılımı – Eğitim aşaması

Eğitim aşaması tamamlandıktan sonra test aşamasına geçilir. Bunun için ekrana gelen test penceresinden test seçenekleri belirlenir (Şekil 10).



Şekil 10. YSA ile iris tanıma yazılımı – Test seçim ekranı

Test işlemi sonucunda ekrana gelen raporda, her bir test girişinin sınıflandırma yüzdesi ve hata oranları gösterilir (Şekil 11).

