



T.C.  
İSTANBUL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ



YÜKSEK LİSANS TEZİ

ÖZELLİK ÇIKARMA VE SINIFLANDIRMA ALGORİTMALARI  
KULLANILARAK İRİS TANIMA

Koray POLAT

Elektrik Elektronik Mühendisliği Anabilim Dalı

Elektrik Elektronik Mühendisliği

DANIŞMAN

Dr. Öğrt. Üyesi Bahattin KARAKAYA

II. DANIŞMAN

Dr. Öğrt. Üyesi Abdurrahim AKGÜNDOĞDU

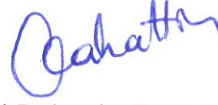
Haziran, 2018

*Bahattin Karakaya*

İSTANBUL

Bu çalışma 20.06.2018 tarihinde aşağıdaki jüri tarafından Elektrik Elektronik Mühendisliği Anabilim Dalı Elektrik Elektronik Mühendisliğinde Yüksek Lisans Tezi olarak kabul edilmiştir.

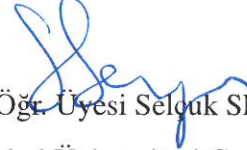
### Tez Jürisi



Dr. Öğr. Üyesi Bahattin KARAKAYA (Danışman)  
İSTANBUL ÜNİVERSİTESİ  
Elektrik Elektronik Mühendisliği



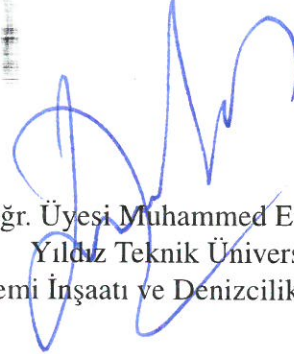
Dr. Öğr. Üyesi Abdurrahim  
AKGÜNDOĞDU  
İstanbul Üniversitesi Cerrahpaşa  
Mühendislik Fakültesi



Dr. Öğr. Üyesi Selçuk SEVGEN  
İstanbul Üniversitesi Cerrahpaşa  
Mühendislik Fakültesi



Dr. Öğr. Üyesi İbrahim GÜNEŞ  
İstanbul Üniversitesi Cerrahpaşa  
Mühendislik Fakültesi



Dr. Öğr. Üyesi Muhammed Emin BAŞAK  
Yıldız Teknik Üniversitesi  
Gemi İnşaatı ve Denizcilik Fakültesi

20.04.2016 tarihli resmi gazetede yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi'nin abonesi olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

## ÖNSÖZ

Bu tez çalışmasında iris tanıma için yeni bir yaklaşım olan yapay sinir ağlarının tanıma daki etkileri araştırılmak istenmiştir. Öncelikle tez konusunu seçerken isteklerimi göz önünde bulundurup bana yardımcı olan tez danışmanım Dr. Öğr. Üyesi Bahattin KARAKAYA'ya ve tez çalışmamda, planlamasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen yardımcı tez danışmanım Dr. Öğr. Üyesi Abdurrahim AKGÜNDOĞDU'ya sonsuz teşekkürlerimi sunarım. Bu süreçte bana destek olan değerli arkadaşım Barış ÖZ'e teşekkürlerimi sunarım. Eğitim hayatım boyunca maddi ve manevi her yönden benden desteğini hiçbir zaman eksik etmeyen değerli ailem ve bu süreçte her an yanımda olan beni destekleyen eşim Çağla'ya sonsuz teşekkürlerimi sunarım.

Haziran, 2018

Koray POLAT

# İÇİNDEKİLER

	Sayfa No
ÖNSÖZ .....	iv
İÇİNDEKİLER .....	vi
ŞEKİL LİSTESİ .....	viii
TABLO LİSTESİ .....	ix
SİMGE VE KISALTIMA LİSTESİ .....	x
ÖZET .....	xii
SUMMARY .....	xiv
<b>1. GİRİŞ .....</b>	<b>1</b>
<b>2. GENEL KISIMLAR .....</b>	<b>3</b>
2.1. İLGİLİ VE GEÇMİŞ ÇALIŞMALAR .....	3
2.1.1. Daugman'ın İntegral-Türev Operatörü .....	5
2.1.2. Kirpik ve Gürültünün Yakalanması .....	5
2.1.3. Canny Kenar Bulma Yöntemi .....	6
2.2. ÇALIŞMANIN AMACI .....	7
<b>3. MALZEME VE YÖNTEM .....</b>	<b>10</b>
3.1. SEGMENTASYON .....	10
3.1.1. Hough Dönüşümü .....	11
3.1.2. Eliptik Maske Yöntemi .....	12
3.2. NORMALİZASYON .....	15
3.2.1. Daugman'ın Elastik Levha Modeli .....	16
3.2.2. 2 Boyutlu Ayrık Dalgacık Dönüşümü (2B-DD) .....	17
3.2.3. Polinomsal Çekirdek .....	18
3.3. SINIFLANDIRMA VE TANIMA .....	21
3.4. YAPAY SİNİR AĞLARI .....	22
3.4.1. Giriş .....	22
3.4.2. Bilgisayar Modelli Öğrenme Kuralı .....	25

3.4.3. Bilgisayar Modelli Eğitim Kuralı .....	26
3.4.3.1. Başlatma .....	26
3.4.3.2. Aktivasyon veya Transfer Fonksiyonu .....	27
3.4.3.3. Ağırlıkların Eğitimi .....	27
3.4.3.4. Yineleme .....	27
3.4.4. Yapay Sinir Ağlarında Geri Yayılım (Back Propagation) .....	28
3.4.5. Çok Katmanlı Sinir Ağları .....	29
<b>4. BULGULAR .....</b>	<b>33</b>
<b>5. TARTIŞMA VE SONUÇ .....</b>	<b>36</b>
<b>KAYNAKLAR .....</b>	<b>38</b>
<b>ÖZGEÇMİŞ .....</b>	<b>40</b>

## ŞEKİL LİSTESİ

	Sayfa No
Şekil 1.1 Göz resmi ve irisin görünüşü.....	2
Şekil 2.1 Sol resim Canny kenar bulma uygulanmış sağ resim orijinal göz resmi.....	6
Şekil 2.2 İris sınıflandırma ve tanıma süreç aşamaları.....	8
Şekil 3.1 Segmentsyon süreç aşamaları.....	10
Şekil 3.2 Göz bebeğinin sınırlarının dairesel şekilde bulunuşu. ....	12
Şekil 3.3 Gradyan piksellerin bulunuşu. -0,01 altına düşen ilk nokta yatay ve dikey yarı çapın bulunuşu. ....	13
Şekil 3.4 Kırılarak genişletilen ve Gaussian Filter ( $\sigma = 3$ ) uygulanmış Şekil üzerinde aşağı yukarı gradyan piksellerin bulunuşu.....	13
Şekil 3.5 Elipsin Bulunuşu.....	14
Şekil 3.6 Eliptik maskenin elde edilmesi. ....	14
Şekil 3.7 Normalizasyon süreç aşamaları. ....	15
Şekil 3.8 Daugman elastik levha modeli.....	16
Şekil 3.9 Polar ve Daugman modelleri.....	17
Şekil 3.10 Ayırık dalgacık dönüşümü uygulaması.....	17
Şekil 3.11 Polinomsal çekirdek ile yeniden haritalandırma.....	18
Şekil 3.12 Kernel fonksiyonları : a)Lineer, b)Kuadratik, c)Polinomsal, d)Radyal. ....	20
Şekil 3.13 Sınır hücrenin biyolojik gösterimi.....	22
Şekil 3.14 Yapay sinir ağı mimarisi.....	23
Şekil 3.15 YSA'da sınıflandırma süreç aşamaları.....	24
Şekil 3.16 Tek katmanlı iki girişli öğrenme modeli. ....	25
Şekil 3.17 (a) iki girişli model, (b) üç girişli model matematiksel gösterimi. ....	26
Şekil 3.18 Üç katmanlı sinir ağı modeli. ....	29
Şekil 3.19 Sınıflandırma sonuçları. ....	30
Şekil 3.20 YSA parametreleri uygulama süreç aşamaları. ....	31

<b>Şekil 4.1</b>	Hata Matrisi ile hatalı sınıfların tespit edilmesi.....	34
<b>Şekil 4.2</b>	Sürekli ışık altında aynı kişiye ait göz bebeğinin büyümesi .....	34





## TABLO LİSTESİ

	<b>Sayfa No</b>
<b>Tablo 3.1</b> Biyolojik ve yapay sinir ağlarının karşılaştırılması.....	23
<b>Tablo 4.1</b> Diğer YSA ve DVM modelleri ile karşılaştırılması.....	35
<b>Tablo 5.1</b> Doğruluk oranlarının diğer çalışmalarla karşılaştırılması.....	36



## SİMGE VE KISALTMA LİSTESİ

### Simgeler

### Açıklama

$\nabla$	: Gradyan (Gradient)
$G_{\sigma}(r)$	: Gauss Düzeltme Fonksiyonu
$P_x$	: Pixel
$\sigma^2$	: Varyans
$\sigma$	: Standart Sapma

### Kısaltmalar

### Açıklama

<b>2B-DD</b>	: 2 Boyutlu Ayrık Dalgacık Dönüşümü
<b>CD</b>	: Çapraz Doğrulama (Cross Validation)
<b>DVM</b>	: Destek Vektör Makineleri
<b>ICA</b>	: Göç ve Kontrol Noktaları Kurumu
<b>ICM</b>	: Kesişen Kortikal Model
<b>LVQ</b>	: Vektör Niceliğini Öğrenmesi
<b>MCC</b>	: Mathew Korelasyon Katsayısı
<b>PCNN</b>	: Darbe Bağlantılı Sinir Ağı
<b>RMS</b>	: Kök Kare Ortalama
<b>WEKA</b>	: Makine öğrenmesi amacıyla Waikato üniversitesinde geliştirilmiş yazılım

## ÖZET

### YÜKSEK LİSANS TEZİ

#### ÖZELLİK ÇIKARMA VE SINIFLANDIRMA ALGORİTMALARI KULLANILARAK İRİS TANIMA

Koray POLAT

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Bahattin KARAKAYA

II. Danışman: Dr. Öğr. Üyesi Abdurrahim AKGÜNDOĞDU

Biyometrik tanıma sistemleri ile karşılaştırıldığında iris tanıma, iris yapısının benzersiz oluşu ve yapısını yaşlanmaya karşı koruması sebepleriyle tercih edilir.

Bununla birlikte, düşük kaliteli iris görüntüleri, değişen aydınlatma koşullarında görüntü elde edilmesi, göz kapağının ve iris bölgesindeki kirpiklerin gürültü etkisi genel olarak iris tanıma sistemlerinin performansını olumsuz yönde etkilemektedir.

Bu yazıda, göz görüntülerinde eliptik maske ile segmentasyon için yeni bir yöntem sunulmaktadır. Önerilen segmentasyon yönteminden sonra çıkarılan özellik vektörlerine 2 boyutlu ayrık dalgacık dönüşümü (2B-DD) uygulanır.

*MATLAB* kullanılarak çıkarılan özellikler daha sonra *WEKA* (Makine öğrenmesi amacıyla Waikato üniversitesinde geliştirilmiş yazılım) platformunda eğitilmiş ve test edilmiştir. Yapay sinir ağları (YSA) sınıflamasının performansı, farklı makine öğrenme algoritmaları ve literatürde farklı özellik çıkarma yöntemleri ile karşılaştırılmıştır.

Çalışma CASIA Thousand veritabanında uygulanmış ve rasgele seçilmiş 10 sınıf ile % 90.00 tanıma oranı elde edilmiştir. Her sınıftan 20 resim, tüm sınıflardan toplam 200 resim olarak gerçekleştirilmiştir. Bu resimlerin %70'i eğitim verileri ve %30'u test verileri olarak sınıflandırılmaktadır.

2B-DD (2 boyutlu ayrık dalgacık dönüşümü) ile çıkarılan özelliklere polinomsal çekirdek ön işlem adımı uygulanır. Deneysel sonuçlar önerilen yöntemin başarılı olduğunu ve diğer yöntemlere göre tercih edilebilir olduğunu göstermektedir.

Haziran 2018, 54 sayfa.

**Anahtar kelimeler:** İris tanıma, eliptik maske, 2 boyutlu ayrık dalgacık dönüşümü, polinomsal çekirdek



## **SUMMARY**

### **M.Sc. THESIS**

#### **IRIS RECOGNITION USING FEATURE EXTRACTION AND CLASSIFICATION ALGORITHMS**

**Koray POLAT**

**İstanbul University**

**Institute of Graduate Studies in Science and Engineering**

**Department of Electrics and Electronic Engineering**

**Supervisor: Dr. Öğr. Üyesi Bahattin KARAKAYA**

**Co-Supervisor: Dr. Öğr. Üyesi Abdurrahim AKGÜNDOĞDU**

The iris is preferred as a biometric property comparing other biometrics by courtesy of its stability and uniqueness.

However, low quality iris images, acquisition under varying lighting conditions, noise effect of eyelid and eyelashes on iris area have negative impact on the performance of iris recognition systems in general.

This paper presents a novel method for segmentation through elliptic mask on eye images. The feature extraction is applied through 2 Dimensional Discrete Wavelet Transform after proposed segmentation method.

The features extracted using MATLAB are then trained and tested on WEKA platform. The performance of Artificial Neural Network classification is compared with different machine learning algorithms as well as different feature extraction methods in the literature.

The work is applied on CASIA Thousand database and %90.00 recognition rate is achieved with randomly selected 10 classes. Twenty pictures are used from each of the classes as a total of 200 pictures from all classes. 70 percent of these pictures are classified as training data and 30 percent of them as test data.

PolyKernel preprocess step is applied to the pictures that are feature extracted by 2D DWT.

The experimental results show that proposed method is a success and preferable to compare other state of the art methods.

June 2018, 54 pages.

**Keywords:** Iris recognition, elliptic mask, artificial neural network, 2 dimensional discrete wavelet transform, PolyKernel



## 1. GİRİŞ

Özellikle gelişen teknolojik cihazlar ve uygulamalarla birlikte birey tanıma amaçlı olarak yaygın bir şekilde kullanılmaya başlanmıştır. Öncelikle yüksek güvenlik gerektiren alanlarda kullanılan biometrik tanıma sistemleri, zamanla daha da yaygınlaşmıştır.

Son yıllarda gelişen akıllı telefon, tablet bilgisayar ve kişisel bilgisayar uygulamaları, biometrik uygulamaların yaygınlaşmasına neden olmuştur. Teknolojik ürünlerin hayatın her alanına girmiş olması bu alanda ihtiyaç duyulan güvenlik sorununu da beraberinde getirmiştir. Kartlı ve güvenlik kodu gerektiren güvenlik sistemlerinde, kişiden bağımsız girişlere imkân vermesi nedeniyle güvenlik açığı meydana gelmektedir.

Bu sorunlar son yıllarda biometrik sistemlerle çözümlenmeye başlamıştır ve çok önemli bir yere sahip olmuştur özellikle de toplum güvenliği ve bilgi güvenliği konularında. Güvenlik sistemi olarak, parmak izi, DNA, retina taraması, yüz taraması, avuç içi taraması ve iris tanıma sistemleri gibi sistemler biometrik olarak başlıcalarıdır.


Parmak izi veya ses tanıma temelli teknolojilerde dezavantaj olarak sayılabilecek özelliklerden, parmak izinin yanarak veya ıslak, nemli kullanıldığında ayrıca kullanılan antibiyotiklerle ve soğuk algınlığının ses tellerini deforme etmesi, ses tanıma sistemlerinde hatalara sebep olabilmektedir. Diğer biometrik sistemlere göre güvenlik amaçlı iris tanımanın büyük bir paya sahip olduğunu belirtmek gerekir.

Hâli hazırda Londra Heathrow, Dubai Abu Dabi havalimanlarında iris tanıma sistemli vize kontrol noktaları oluşturulmuştur. İris tanıma, kişinin tanınmasında biyometrik tanıma sistemleri arasında aktif bir araştırma konusu olmaya devam etmektedir.

Iris kişiye özgü bir yapıya sahiptir. Yaşlanmaya karşıtı yapıya sahiptir hatta iki gözün bile birbirinden farklı iris yapılarına sahip olduğunu belirtmek gerekir. Gözlük ve kontakt lens gibi protezlerden etkilenmez yapısını kişi ölene kadar korur.

Bu koruma işlemini göz kapağı, kornea ve gözün sıvı yapısı üstlenmiştir. Bu nedenle iris tanıma doğru ve hızlı sonuçlar üretmek için tercih edilen güvenilir biometrik bir tekniktir.

Gözdeki iris bölgesi göz bebeği (pupil) ile beyaz kısım (sclera) arasındaki bölgedir. Iris dokusu çil, koron, şeritler, kılçıklar vb. gibi birçok özellik sunar. İrisin anatomik yapısındaki bu benzersiz özellikler bireyler arasındaki farklılaşmayı kolaylaştırır. Belirtilen sebeplerden, iris tanıma çalışılmıştır.



Şekil 1.1: Göz resmi ve irisin görünüşü.

Iris tanıma önceki çalışmalardan özetle 3 aşamada gerçekleşmektedir. Iris görüntüsünün yakalanması, ön işleme ve tanıma. İris tanımanın ön işleme işlemleri, iris lokalizasyonu ve geliştirmelerin sağlandığı bölümdür.

Bu adımların her biri için farklı algoritmalar kullanılmıştır. Lokalizasyon aşamasında irisin iç ve dış sınırlarının belirlenmesi ve göz kapaklarının alt ve üst sınırları belirlenmesi sağlanmıştır. İç çember göz bebeği ile iris arasında yer alır. Dış çember ise iris ile sclera bölümünün arasında kalacak şekilde belirlenir.

Göz yapılarının değişkenliği sebebiyle iris'in lokalizasyonu büyük problem teşkil etmiştir. Lokalizasyon işlemi için gradyan tabanlı Hough dönüşümünden destek alınır. Hough dönüşümü ayrıca irisin konumunu bulma işlemleri için de kullanılmıştır.

Önerilen çalışmada da iris tanıma 3 aşamada gerçekleştirilecektir. Eliptik maskeleme ve YSA ile desteklenecektir ve tanıma işlemi tamamlanacaktır.



## 2. GENEL KISIMLAR

### 2.1. İLGİLİ VE GEÇMİŞ ÇALIŞMALAR

İris desenlerinin harika ve zengin bir yapıya sahip olduğu ve diğer fizyolojik özelliklerin aksine karmaşık dokularla dolu olduğu yıllardır bilinmektedir. İris, göz bebeği ve sklera yapısının arasında kalan renkli dairesel bölgedir.

İlk olarak Bertillion 1885'te iris'in özelliklerinden ve renk yapısından kimliklendirme işlemi yapılabileceğini belirtmiştir. Güvenliğin ve dolayısıyla güvenlik önlemlerinin git gide değer kazanmasıyla birlikte irisin yapısından kaynaklı (kişiye özgünlük, yaşlanmama, çevresel faktörlerden etkilenmemesi) daha çok tercih edilen biyometrik sistemlerden biri olmuştur.

İris yapısından dolayı, son on beş yıldır ve günümüzde İngiltere, Almanya, Japonya'da kullanıcılar tarafından banka hesaplarına erişmek için doğrulama kodu olarak iris tanıma tercih edilmektedir. Bu, kullanıcıların bir PIN veya şifreler girme ihtiyacını azaltmıştır. Ayrıca, havalimanları gibi güvenli alanlardan geçerken çalışanların kimliklerini tespit etmek için iris taramasını kullanmaya başladı. Londra Heathrow ve Abu Dabi Uluslararası havalimanlarında güvenlik kontrolü amaçlı iris kontrol noktaları bulunmaktadır. Diğer uygulamalar arasında, hapisane transferleri yanı sıra çevrimiçi satın alma, bankacılık, oylama ve hisse senedi alım satım işlemlerini doğrulamak için tasarlanmış projeler bulunmaktadır.

İris ile daha önceki çalışmaları gözden geçireceğiz. Daugman 2002'de, iris için bir 2048 ikili özellik kodu oluşturmak üzere 2D Gabor filtrelerini ve faz kodlamasını kullanmıştır [1].

Wildes tarafından 1994'te, iris kodunu oluşturmak için iris ve bir Laplas piramidi dört çözünürlük seviyesiyle yerleştirmek için Hough dönüşümü kullanılmıştır [2].

1998 de Boles ve Boashash, irisin gri seviye imzasının 1D temsilini oluşturmuş ve iris temsilini oluşturmak için çift dalga dalgacık dönüşümünün sıfır geçişine uygulamıştır [3]. Ma, Wang ve Tan 2003'de, iris profilini yakalamak için bir Gabor filtresi bankası kullanmışlardır [4].

Lim, Lee, Byeon ve Kim 2001'de 2D Haar dalgacık modeline dayanarak, 87 ikili kod üretmek için yüksek frekanslı bilgi çıkardı ve sınıflandırma için LVQ yöntemini kullanmıştır [5].

Daubechies dalgacığının fazına dayanarak, Poursaberi 2005'de irisin ikili kod gösterimini oluşturup ayrıca eşleştirme için minimum bir Öklid mesafesi kullanmıştır [6]. Özellik çıkarma aşamasında ikili kodlama, eşleştirme işleminin daha hızlı ve kolay bir şekilde yapılmasına da neden olmuştur.

Chen ve Chu, 2009'da bir başka ana iris öznitelik çıkarma tekniği, irisin 1D dairesel profili ile özellik çıkarma tekniği ve olasılıklı sinir ağı ve partikül topluluğu optimizasyonuna dayanan akıllı bir sınıflandırıcı ile daha iyi tanıma sonuçları üretmiştir [7].

Xu, Zhang ve Ma 2009'da, iris kodlarını ve karşılaştırılan iris kodları arasındaki Hamming mesafesini oluşturmak için kesişen kortikal model (ICM) sinir ağını kullanmıştır. Bu ICM sinir ağı, görüntü bölütleme için mükemmel performansla sahip olan darbe eşlemeli sinir ağının (PCNN) basitleştirilmiş bir modelidir, böylece kodlama işlemi yeterince hızlı bir şekilde gerçekleştirilebilmiştir [8], [9].

Hassanien ve arkadaşları 2009'da ICA katsayıları ile iris desenlerini temsil etmiş, her sınıfın merkezini rekabetçi öğrenme mekanizması ile belirlemiş ve son olarak Öklid mesafelerine dayalı deseni tanımlamıştır. Bu yöntem, göz kapaklarının ve kirpiklerin neden olduğu değişken aydınlatma ve gürültü faktörüne karşı duyarsızdır ve hatta bulanık iris görüntüsü için bile iyi algılanabilir olduğunu göstermiştir [10].

Murakami, Takano ve Nakamura 2003'deki çalışmalarında iris tanıma için nöral ağ (R-SAN net) yayılan bir rotasyon kullandılar. Çalışmaya göre bu tip bir sinir ağı, şeklinden bağımsız olarak nesnenin yönelimini tanımak için uygundur. Tanıma deneylerinde, sinir ağlarının yayılma rotasyonu, eşzamanlı olarak, öğrenilen kişilerin iris görüntülerinin oryantasyonunu tanıyabilmiştir [11]. Önceki çalışmalarda en sık kullanılan segmentasyon yöntemlerinden bazıları bir sonraki sayfada açıklanmıştır.

### 2.1.1. Daugman'ın İntegral-Türev Operatörü

Daugman, dairesel iris ve pupil bölgesi ve hatta alt ve üst göz kapaklarının yaylarını bulabilmek için bir integral-türev operatörü kullanır [1]. İhtiyaç duyduğu iris ve göz bebeği yarıçap ve merkez koordinatlarını bulabilmek için kullandığı operatör aşağıdaki gibi ifade edilmiştir.

$$\max_{(r,x_0,y_0)} = \left| G_{\sigma}(r) \frac{\partial}{\partial x} \oint_{r,x_p,y_0} \frac{I(x,y)}{2\pi r} ds \right| \quad (2.1)$$

Operatörde  $I(x,y)$  göz resmini ifade eder. Aranan yarıçap  $r$  ile ifade edilir.  $G_{\sigma}(r)$  Gauss düzeltme fonksiyonunu (Gauss düzeltme fonksiyonunu) simgeler [12]. Ayrıca çevre  $s$ ,  $(r,x_0,y_0)$  şeklinde ifade edilmiştir. Operatör, dairesel çevrenin yarıçapını ve merkez ve  $x,y$  koordinatlarını değiştirerek piksel değerlerinde maksimum değişimin olduğu dairesel yolu verir.

Operatör en doğru konumu bulabilmek için kademeli olarak azaltılan düzeltme miktarı ile tekrarlı bir şekilde uygulanır. Göz kapağı da benzer şekilde konumlandırılır. Çevre entegrasyonu yolu daireselden bir yaya dönüşür. İntegra-türev modeli de Hough dönüşümü'nün bir diğer varyasyonu olarak düşünülebilir. Her ikisi de görüntünün ilk türevlerini kullanır. Geometrik parametreleri bulmak için arama yapar.

Bir artı olarak ham türev bilgileri ile çalıştığı için Hough dönüşümü'nün maruz kaldığı eşikleme problemine maruz kalmaz integral-türev model. Bunun yanı sıra algoritma yansılardan olumsuz etkilenebilir, lokal bir ölçekte çalıştığı için, göz görüntüsünde gürültü olduğu yerlerde çalışmayabilir.

### 2.1.2. Kirpik ve Gürültünün Yakalanması


Kong ve Zhang kirpik tespiti için bir yöntem sunmuşlardır [13]. Burada kirpikler iki türe ait olarak ele alınır. Görüntüde izole edilebilen ayrılabilir kirpikler, göz görüntüsünde bir araya getirilen ve üst üste binen çok sayıda kirpik bulunmaktadır. Ayrılabilir kirpikler 1D Gabor filtreleri kullanılarak tespit edilir [5].

Çünkü ayrılabilir bir kirpiğin Gauss'un doğrulama fonksiyonu ile konvolüsyonu düşük bir çıktı değeri ile sonuçlanır. Bu yüzden sonuçtaki bir nokta, bir eşik değerden daha küçük ise bu noktanın bir kirpiğe ait olduğu anlaşılır. Çoklu kirpikler yoğunluk varyansı kullanılarak tespit edilir. Eğer küçük bir pencerede yoğunluk değerlerinin varyansı eşikten düşük ise, pencerenin merkezi bir kirpikte nokta olarak kabul edilir.

Kong ve Zhang modeli aynı zamanda bağlanma kriterlerini de kullanır, böylece bir kirpikteki her nokta bir kirpikteki veya bir göz kapağındaki başka bir noktaya bağlanmalıdır. Gözdeki görüntüye olan spesifik yansımalar, bu bölgelerdeki yoğunluk değerleri görüntüdeki diğer bölgelerden daha yüksek olacağından, eşikleme kullanılarak tespit edilir.

### 2.1.3. Canny Kenar Bulma Yöntemi

İris kenarlarının tespit edilmesinde kullanılan yöntemlerden biridir canny metodu. İris sınırının kolayca lokalize olabileceği gözün ana kenarlarını verir. Görüntüdeki gürültü faktörlerinin elenmesinde ve düzgün görüntü elde edilmesinde kullanılır. Hataları bulmak için olasılık hesabını kullanır. Karmaşık hesaplamalara sahiptir. Fakat daha az bellek karmaşıklığı ile daha kısa zamanda sonuç üretir. Oldukça basit bir metottur.



Şekil 2.1: Sol resim Canny kenar bulma uygulanmış sağ resim orijinal göz resmi.

Canny metodu Gauss filtresini kullanır [14], amacı  $x, y$  ve ayrıca çekirdek olarak tanımlanan  $\sigma^2$ 'ı ayarlamaktır. Aşağıdaki operatör ile ifade edilmiştir.

$$\nabla_F = 1/2\pi\sigma^2 e^{-((x^2+y^2))/2\sigma^2} \quad (2.2)$$

Gauss filtresinde  $\sigma^2$  (2.2) operatörü ile ayarlanır.

Operatör, (2.2) operatörünü ve görüntüye göre elde edilen çekirdek görüntüyü kıvrımlar,  $x$  ve  $y$  yönlerine göre gradyen bulunur (2.3) operatörü ile ifade edilmiştir.

$$\nabla_f = \nabla \sqrt{x^2 + y^2} \quad (2.3)$$

(2.4) operatörü ile gradyan açısı elde edilmiştir.

$$\text{Gradyen açısı, } \nabla_f = \arctan(-y/x) \quad (2.4)$$

## 2.2. ÇALIŞMANIN AMACI

İris, eşsiz epigenetik yapısı olan, dışarıdan görülebilen ve çok iyi korunan bir organdır. Bireyin hayatı boyunca sabit yapısını korur. Bu özelliklerinden dolayıdır ki bireylerin tanınmasında biyometrik olarak iris tanımanın kullanılması çok caziptir.


Görüntü işleme teknikleri, gözün sayısallaştırılmış görüntüsünden eşsiz bir iris deseni çıkarmak ve bir veritabanında saklanabilen biyometrik bir şablona kodlamak için kullanılabilir. Bu biyometrik şablon benzersiz bilgilerin, nesnel matematiksel temsilini içerir. İris içinde saklanır ve şablonlar arasında karşılaştırılmalar yapılmasına izin verir.

Kişisel güvenliğin son derece önem kazanması ile pek çok uluslararası stratejik öneme sahip kurumda iris tanıma sistemleri kullanılmaya başlanmıştır. Örneğin; havalimanlarının vize kontrol noktalarında, bankacılık işlemlerinde, kişisel telefonlarda kullanılmaya başlanmış bir biyometrik sistemdir iris tanıma sistemi.

Son yıllardaki geliştirmelerle iris tanıma sistemleri, yapay zekâ unsurlarının da kullanılmaya başlanmasıyla daha hızlı sonuç elde etmeye fırsat vermiştir. İris tanıma sistemleri güvenlik mottosunu iris'in eşsiz yapısıyla en yüksek ve en hızlı şekilde gerçekleştirmektedir.

İris tanıma genellikle yüksek matematik algoritma tabanlı dalgacık algoritması gibi gerçek zamanlı veri sunan yüksek çözünürlüklü kameralar desteği ile yapılmaktadır. Bu çalışmada farklı bir yaklaşım olarak makine öğrenmesi yapay sinir ağlarından faydalanılacaktır.

YSA doğrusal olmama, genelleme yapabilme, öğrenebilirliği, uyarlanabilirliği ve hata toleransı ve süratli olmasından dolayı çalışmada tercih edilmiştir. İris yapısı itibarı ile kişiye özgü ve değişmeyen dış faktörlerden etkilenmeyen yaşlanmaya dirençli bir yapıya sahiptir. Hatta kişinin, iki gözünün iris yapılarının bile farklı olduğu gözlemlenmiştir. Buradan yola çıkarak sağ ve sol göz verilerinin birbirleriyle eşleştirilmesi sağlanacaktır.



Şekil 2.2: İris sınıflandırma ve tanıma süreç aşamaları

Bu aşamada ilk olarak normalizasyon ve segmentasyon çalışmalarının ardından elde edilen iris öz nitelik vektörlerinin veri kümesi olarak kullanılacağı çalışmada sınıflandırma ve eşleştirme algoritmaları kullanılacaktır.

İki tür sınıflandırma yapılacaktır. Sağ ve sol göz veri kümelerinin %70'i eğitim kümesi, %30'u test kümesi olarak kullanılacaktır. Çapraz doğrulama ile kontrolleri gerçekleştirilecektir.

Çalışmada veri girişi olarak alınan göz resimlerine uygulanacak ilk yöntem Hough dönüşümüdür. Hough dönüşümü kullanılarak göz bebeğinin doğru konumlandırılması hedeflenmektedir. Daha sonra normalizasyon aşamasında iris ve göz bebeği daireleri çıkartılacak ve kartezyen koordinatlar, polar koordinatlara dönüştürülerek normalize edilmiş değerler elde edilecektir.

Elde edilen bu matrisler üzerine 2B-DD uygulanacak, yine elde edilen matrislere  $4 \times 4$  veya  $8 \times 8$  median filtre uygulanarak iris bölgesi çözünürlüğü artırılabacaktır.

Filtrelenmiş matrislere tekrar 2B-DD ve median filtre uygulanacaktır. Elde edilen matrislere destek vektör makineleri algoritmalarından polinomsal çekirdek yöntemini uygulayarak, sınıflandırma için kullanılacak öznitelik vektörleri elde edilecektir.

Elde edilen öznitelik vektörleri yapay sinir ağlarının bir modeli olan çok katmanlı yapıya uygulanacaktır. Eşleştirme başarı yüzdelere göre DD (ayrık dalgacı dönüşümü) boyutu ve median filtre boyutları değiştirilerek sonuçların optimizasyonu sağlanması hedeflenmektedir. Şekil 2.2'de belirtilen süreç aşamalarına uyularak iris tanıma, YSA ile gerçekleştirilecektir.

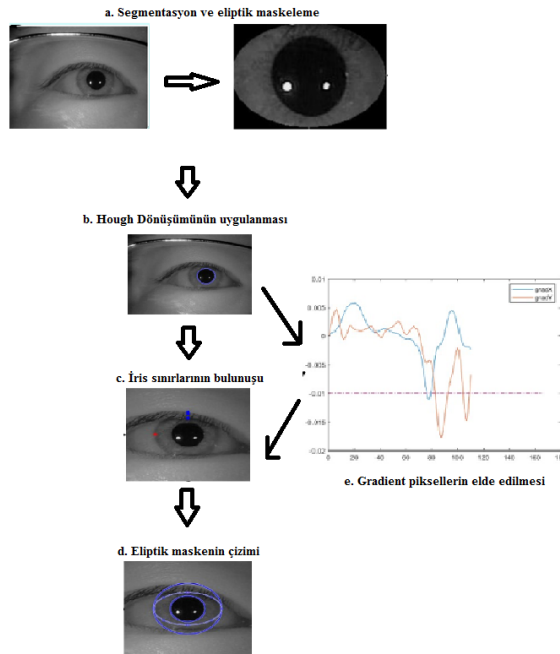
YSA'nın karakteristik özellikleri aktif bir şekilde kullanılacak ve elde edilen bulgular diğer çalışmalarla kıyaslanacaktır. Elde edilen öznitelik vektörleri 3 farklı YSA ile denenecektir ve her kullanılan yöntem ile önerilen yöntem arasındaki farklar değerlendirilecek sonuç bölümünde tartışılacaktır. Önerilen çalışmanın artı ve eksileri değerlendirilerek çalışma tamamlanacaktır.

### 3. MALZEME VE YÖNTEM

#### 3.1. SEGMENTASYON

İris tanımanın ilk aşaması, gerçek iris bölgesini bir dijital göz görüntüsünde izole etmektir. İris bölgesi iki çember yardımıyla yaklaşık olarak hesaplanabilir. Çemberlerden birincisi iris ile göz bebeği arasında kalan sınır halkası ikincisi iris sklera sınırı içindir.

Göz kapakları ve kirpikler iris görüntüsünü alttan ve üstten engelleyen faktörlerdendir. Ayrıca iris görüntüsünü engelleyen speküler yansımalar oluşabilir. Tüm bu olumsuz faktörlerin iris tanıma işlemi için giderilmesi gerekmektedir. Önerilen çalışma ile gürültü faktörleri ortadan kaldırılmaya gerek duyulmadan segmentasyon işlemi yapılacaktır. Segmentasyon aşamasında kullanılan yöntemler şemada belirtilmiştir. Şekil 3.1. Tanıma işlemlerinde CASIA Thousand veri tabanı kullanılmıştır [15]. 10 kişiye ait sağ ve sol göz verilerinden 10'ar resim kullanılmıştır. Toplamda 200 resim ile çalışma gerçekleştirilmiştir.



Şekil 3.1: Segmentsyon süreç aşamaları.



### 3.1.1. Hough Dönüşümü

Hough dönüşümü, bir görüntüde mevcut olan çizgiler ve daireler gibi basit geometrik nesnelerin parametrelerini belirlemek için kullanılabilen standart bir bilgisayarlı modelleme algoritmasıdır. Dairesel Hough dönüşümü, göz bebeği ve iris bölgelerinin yarıçapını ve merkez koordinatlarını çıkarmak için kullanılabilir. Önerilen çalışmada Hough dönüşümü göz bebeği sınırlarının bulunmasında kullanılmıştır.

Dairesel Hough dönüşümüne dayanan otomatik segmentasyon algoritması Wildes ve arkadaşları [2], ayrıca Kong ve Zhang tarafından kullanılmıştır. Hough dönüşümünde ilk olarak, bir göz görüntüsündeki yoğunluk değerlerinin ilk türevlerinin hesaplanması ve daha sonra sonucun eşleştirilmesiyle bir kenar haritası oluşturulur.

Kenar haritasından, her kenar noktasından geçen dairelerin parametreleri için Hough uzayında yoğunluklar hesaplanır [13]. Hesaplanan parametreler oluşturulacak çemberin merkez koordinatları  $X_c$  ve  $y_c$  ve yarıçap  $r_c$  olacak şekilde genel çember denklemini tanımlar.

$$x^2 + y^2 - r^2 = 0 \quad (3.1)$$

Hough uzayındaki maksimum nokta, kenar noktaları tarafından en iyi tanımlanan dairenin yarıçapına ve merkez koordinatlarına karşılık gelecektir. Belirtilen çember denklemi ile göz bebeği yarı çapı ve merkez koordinatları elde edilmiştir.

Wildes ve arkadaşları ayrıca Kong ve Zhang da göz kapaklarını tespit etmek için parabolik Hough dönüşümünü kullanmıştır. Aşağıdaki formül ile temsil edilen parabolik yaylarla üst ve alt göz kapaklarının temsil edilmesi sağlanmıştır.

$$(-(x - h_j)\sin\theta_j + (y - k_j)\cos\theta_j)^2 = a_j((x - h_j)\cos\theta_j + (y - k_j)\sin\theta_j) \quad (3.2)$$


Bu denklemde;  $a_j$  eğriliği kontrol eder,  $(h_j, k_j)$  Parabolün tepe noktası,  $\theta$  açısı  $x$ -ekseni ile yaptığı dönme açısıdır.

Önceki kenar saptama adımının gerçekleştirilmesinde, Wildes ve arkadaşları göz kapaklarını

tespit etmek için yatay yönde türevleri saptar ve irisin dış dairesel sınırını saptamak için düşey yönde türevleri saptamıştır.

Bunun için asıl motivasyon, göz kapaklarının genellikle yatay olarak hizalanmasıdır ve eğer tüm gradyan verileri kullanılırsa göz kapağı kenar haritası dairesel iris sınır kenar haritasını bozar.

İris sınırını bulmak için sadece dikey gradyanları almak, yuvarlak Hough dönüşümü yaparken göz kapaklarının etkisini azaltacaktır ve tüm başarılı lokalizasyon işlemleri için çemberi tanımlayan kenar pikselleri gerekli olacaktır. Bu sadece daire lokalizasyonunu daha doğru yapmakla kalmaz, aynı zamanda daha verimli hale getirir. Şekil 3.2'de göz bebeğine uygulanmış hough dönüşümü ile göz bebeğinin sınır halkası başarıyla bulunmuştur.




**Şekil 3.2:** Göz bebeğinin sınırlarının dairesel şekilde bulunuşu.

Dairesel yapıdaki görüntülerin resim üzerinde yakalanmaları için kullanılan Hough Dönüşümü ile göz resmindeki göz bebeğinin keşfi kolaylaşmıştır. Gözün dikey ve yatay kenar sınır haritalarının çıkarılmasında faydalanılmıştır. Hough dönüşümü ile dairesel yapıdaki göz bebeğinin merkez koordinatları bulunabilmiştir.

### **3.1.2. Eliptik Maske Yöntemi**

Hough dönüşüm algoritması ile gözün geometrik yapısından yararlanılmıştır. Hough dönüşümü ile bulunan göz bebeğinin dairesel bir şekilde keşfedilmesini sağlar. İris sınırları tamamen daire şeklinde olmamakla birlikte birçok metotta eş merkezli olmayan iki daire olarak modellenir. İstisnalar olmakla birlikte bu sınırlar genellikle elipse benzemektedir.


Çalışmada eliptik maske yöntemi yukarıdaki genellemeden dolayı kullanılmıştır. Eliptik



**Şekil 3.3:** Gradyan piksellerin bulunuşu. -0,01 altına düşen ilk nokta yatay ve dikey yarı çapın bulunuşu.

maskeleme uygulanmasından önce göz bebeğinin keşfedilmesi için Hough dönüşümünden yararlanılmıştır. Daha sonra göz bebeği merkez alınarak dikey ve yatay eksenlerde piksel farklılıkları göz önünde bulundurulmuştur.


Hough dönüşümü ile bulunan gözbebeği resminin sağdan soldan üstten ve alttan 120 px genişletilerek elde edilen görüntü üzerine Gauss filtresi uygulanmıştır. Şekil 3.3'te resimlere uygulanan gradyan piksellerin elde edilişi diagram olarak gösterilmiştir.




**Şekil 3.4:** Kırılarak genişletilen ve Gaussian Filter ( $\sigma = 3$ ) uygulanmış Şekil üzerinde aşağı yukarı gradyan piksellerin bulunuşu.

( $\sigma = 3$ ) bu uygulamadan sonra gözbebeğinin ortasından başlayarak sola ve yukarı piksel gradyanın bulunması sağlanmıştır. (gradX, gradY). -0,01'in altına düşen ilk

nokta gözbebeğinin yatay ve dikey yarıçapını vermiştir. Bu yarıçapa göre maske elips oluşturulmuştur. Bu aynı zamanda iris üzerine gelen kirpik benzeri gürültü faktörlerinin de ortadan kaldırılmasını sağlamış veya en aza indirilmesi konusunda destek olmuştur.



**Şekil 3.5:** Elipsin Bulunuşu.




**Şekil 3.6:** Eliptik maskenin elde edilmesi.

Eliptik maske yöntemi ile segmente edilen iris görüntüsü normalizasyon işlemlerine hazır hale getirilmiştir. Kirpik ve göz kapağının gürültü etkisini de ortadan kaldırmak veya en aza indirmek amaçlanmış elips şeklindeki iris maskesi hazırlanmıştır. İris yapıları dairesel olarak görünse de çoğunlukla elips şeklindedir. Bu yüzden eliptik maskeleme yapılmıştır.

İris veri kümesini en çok da göz bebeğine yakın kısımlarında barındırmaktadır. Göz bebeğinin yakınında daha büyük bir iris alanı maskelenmiş ve basık bölgelerden gelmesi mümkün kirpik ve göz kapağı faktörlerinin olumsuz etkileri azaltılmak hedeflenmiştir.

### 3.2. NORMALİZASYON

İris bölgesinin göz bebeğinden ayrılması işleminden sonraki aşama diğer irisler ile karşılaştırabilmek için sabit boyutlara sahip olacak şekilde iris bölgesini dönüştürmektir.




**Şekil 3.7:** Normalizasyon süreç aşamaları.

Çalışma, belirtilen süreç aşamalarından geçerek gerçekleştirilecektir. Şekil 3.7. Göz bebeğinin maruz kaldığı ışığın değişen seviyelerde olması, pupil yapısının genişlemesine ve irisin gerilmesine sebep olarak, göz görüntülerinin farklı boyutlarda olmasına sebep olur. Ayrıca göz görüntülerinin görüntülenme mesafesi, kameranın açısı, başın eğimi, göz yuvasındaki gözün hareketi gibi faktörler de göz görüntülerinin farklı olması yani tutarsız olması anlamına gelmektedir. Normalizasyon süreci aynı sabit bölgelere sahip olan iris bölgelerinin edilmesini sağlayacaktır. Bu sayede farklı koşullar altında aynı irisin iki fotoğrafı aynı karakteristik özelliklere sahip olacaktır.

### 3.2.1. Daugman'ın Elastik Levha Modeli

Daugman tarafından tasarlanmış elastik levha modelidir. Tasarlanan modele göre iris bölgesindeki her noktayı yarıçapı  $r$ ,  $(0, 1)$  aralığında olan ve  $\theta$  açısı  $(0, 2\pi)$  aralığında olan bir çift kutupsal koordinat ile eşler  $(r, \theta)$ .



Şekil 3.8: Daugman elastik levha modeli.

Kutupsal koordinat ile işleme aşağıdaki gibi formülize edilir.

$$I(x(r, \theta), y(r, \theta)) \rightarrow I(r, \theta) \quad (3.3)$$


$$x(r, \theta) = (1 - r)x_p(\theta) + rx_l(\theta) \quad (3.4)$$

$$y(r, \theta) = (1 - r)y_p(\theta) + ry_l(\theta) \quad (3.5)$$

Formülde  $I(x, y)$  ifadesi iris bölgesinin resmini ifade eder ve  $(x, y)$  orjinal kartezyen koordinatları ifade eder,  $(r, \theta)$  normalize edilmiş polar koordinatları ifade eder,  $x_p$  ve  $y_p$  göz bebeğinin sınırlarını ifade ederken  $x_l$  ve  $y_l$  iris sınırlarını  $\theta$  doğrultusunda ifade eder. Göz bebeğinin dış faktörlere duyarlı olmasına dolayısıyla genişlemesini ve boyut değiştirmelerini dikkate alır Daugman'ın modeli.

Bu şekilde göz bebeği merkez alınarak iris ile göz bebeği arası lastik bir levha olarak modellenebilmiştir. Lastik levha modeli göz bebeğindeki genişlemeyi dikkate alırken rotasyon bozukluklarına karşı yetersiz kalmıştır.

Daugman'ın modeli  $\theta$  doğrultusunda iris şablonlarını hizalanana kadar kaydırarak oluşan rotasyon bozuklukları eşleştirme sırasında hesaba katılmıştır. Daugman'ın modeli ile göz bebeğinden ayrılan iris görüntüsü halka yapısından kurtulup dikdörtgenel olarak ifade edilebilmiştir. Kartezyen yapıdan polar koordinat yapısına dönüştürülmüştür. Gözbebeği hesaba katılmadığından, gözbebeği üzerindeki parlaklıkların giderilmesi (noise rejection) ön işlemine gerek duyulmamıştır.




Şekil 3.9: Polar ve Daugman modelleri.

### 3.2.2. 2 Boyutlu Ayırık Dalgacık Dönüşümü (2B-DD)

DD bir görüntüyü bir defadan fazla çözebilir [16]. Çözümleme işlemi iki şekilde olabilir (i) piramit çözümlemesi, (ii) paket çözümlemesi. Piramit çözümlemesinde, sadece LL alt bandında başka ayrışmalar uygulanır. Her seviyede yaklaşma alt bandı daha da ayrıştırılmış olur.

Paket çözümlemesinde ise ayrışma LL alt-bandı ile sınırlı değildir, sadece her alt-bandın her seviyede daha fazla ayrışmasına izin verir. Bu çalışmada paket çözümlemesi kullanılmıştır  $8 \times 8$  boyutlar kullanılmıştır ve özellik çıkarımı her yöne uygulanmıştır.  $64 \times 256$  boyutlu normalize iris görüntüsü küçültülerek oluşturulan frekans analizi gerçekleştirilmiştir.



Şekil 3.10: Ayırık dalgacık dönüşümü uygulaması.


DD çok yönlü sinyal işleme aracı olarak kullanılmıştır. Dalgacıklar, dalgacıkların enerjisinin zaman içinde yoğunlaştığı ve hala dalga benzeri (periyodik) özelliklere sahip olduğu gerçeği nedeniyle, sinyallerin hem zaman hem de frekans analizine olanak sağlar.

DD, farklı alt bantlara bir dijital sinyal ayrıştırır, böylece daha düşük frekans alt bantları daha yüksek frekans alt bantlarına kıyasla daha ince frekans çözünürlüğüne sahiptir. Dalgacık katsayılarını mümkün olan her ölçekte hesaplamaya gerek yoktur. Bu çalışmada da iris görüntüsünden çıkarılan özellik kümesini geliştirmek için 2B – DD yöntemi ile elde edilen özellikler kullanılmıştır.

Dalgacık dönüşümünün avantajı ve özellik çıkarımı için kullanışlı kılan özelliği hem uzamsal hem de frekans çözünürlüğüne sahip olmasıdır. DD, bir resme ait dört alt örnekleme görüntüsüne, (L): alçak geçiren filtre, (H): yüksek geçiren filtre ve ikinci kez uygulamada elde edilen (LL): alçak geçiren filtre üzerine alçak geçiren filtre, (HL): yüksek geçiren filtre üzerine alçak geçiren filtre, (LH): yüksek geçiren filtre üzerine alçak geçiren filtre ve (HH): yüksek geçiren filtre üzerine yüksek geçiren filtre olarak adlandırılan bu filtreler uygulanarak görüntülere ayrıştırılır. Bu nedenle,  $N \times N$  boyutundaki orijinal görüntü,  $\frac{N}{2} \times \frac{N}{2}$  boyutlarının her biri için dört alt görüntüye ayrılır ve farklı frekans bileşenlerinden bilgi içerir. Şekil 3.10, birinci ve ikinci ayrışma basamağının temsili blok-gösterimini göstermektedir.

### 3.2.3. Polinomsal Çekirdek

Sınıflandırıcılar genellikle lineer ayırım gerçekleştirirler. Bu lineer ayırım, özelliklerin sınıflandırmasını zorlaştırır. Özellikler, polinomsal çekirdek ön işlemine tabi tutularak yeniden haritalandırılır ve daha sağlıklı bir sınıflandırma sağlanır. Çalışmada sınıflandırma algoritmalarından YSA çok katmanlı bilgisayar modeli (Multilayer Perceptron) kullanılacağı için destek vektör makinelerinden polinomsal çekirdek fonksiyonu tercih edilmiştir. Bu sayede, doğrusal olmayan desenlerin öğrenilmesi mümkün olmuştur. Her  $k$  kerneli,  $\phi$  özellik sınıflandırmasıyla birleştirilir.  $\phi$ ,  $x \in \mathcal{X}$  uzayını giriş olarak alır ve bu girişi  $\mathcal{F}$  özellik sınıfına haritalandırır. İki girişli bir  $k(x,z)$  kernelinin  $\mathcal{F}$  uzayındaki benzeri, aşağıdaki gibidir. Şekil 3.11.



Şekil 3.11: Polinomsal çekirdek ile yeniden haritalandırma.



$$\phi : \mathcal{X} \mapsto \mathcal{F} \quad (3.6)$$

$$k : \mathcal{X} \times \mathcal{X} \rightarrow \mathcal{R}, k(x, z) = \phi(x)^T \phi(z) \quad (3.7)$$

Formülde  $\mathcal{F}$ , bir vektör alanı olup nokta çarpımının tanımlı olduğu bir uzayı gösterir. Bu, aynı zamanda Hilbert uzayı olarak adlandırılır [17]. Kernel fonksiyonlarının, haritalandırmada kullanılabilmesi için *Mercer* koşulunu yerine getirmeleri gerekir [18]. Bu koşul, iki kernel fonksiyonunun birbirleri ile çarpımının mümkün olması dışında,  $K$  kernel matrisinin pozitif tanımlı olması ile kararlaştırılır.


$$\int dx \int dz f(x) k(x, z) f(z) > 0, (\forall f \in L_2) \quad (3.8)$$

$N$  örnekle  $x_1, \dots, x_N$  özellik vektörü için  $K$  matrisinin  $(i, j)$  elemanı, aşağıdaki gibi tanımlanır.

$$K_{i,j} = k(x_i, x_j) = \phi(x_i)^T \phi(x_j) \quad (3.9)$$

$K_{i,j}$ , özellik uzayındaki  $i$  ve  $j$  örneklerinin benzerliğini gösterir. Gram matrisi olarak da adlandırılan bu matrisin pozitif tanımlı olması, gerekli şarttır. Destek vektör makineleri (DVM) yönteminde kullanılan kerneller, lineer, kuadratik, polinomsal, radyal temelli fonksiyon (RBF) olmak üzere dörde ayrılmıştır [19], [20]. Bu çalışmada, DVM yönteminin ön işlemlerinde sıklıkla kullanılan kerneller, elde edilen polar görüntülere uygulanmıştır.

Polinomsal çekirdek kullanılan bu çalışmada, üçüncü dereceden sınıflandırma uygulanmıştır. Aşağıda, polinomsal çekirdek uygulanan özelliklerin sınıflandırma aşamasındaki farklılığı değerlendirilmektedir.



Şekil 3.12: Kernel fonksiyonları : a)Lineer, b)Kuadratik, c)Polinomsal, d)Radyal.

Kullanılan polinomsal çekirdeğin matematiksel ifadesi aşağıda verilmiştir.

$$k(x, z) = (x^T z)^3 \quad (3.10)$$

Böylece; lineer özellik çıkarımı, nonlinear uzaya haritalandırılmış ve sonuçları tartışılmıştır. İlgili konudaki detaylar, sonuçlar bölümünde değerlendirilmiştir.

### 3.3. SINIFLANDIRMA VE TANIMA

Hem iris görüntülerinin sınıflandırılması hem de iris tanıma, öznelik vektörlerini kullanarak işlem yaptıkları için sınıflandırma ve tanıma benzer kabul edilebilir. Sınıflandırma işlemi, iris görüntülerinin önceden tanımlanmış bazı kategorilere sınıflanması anlamına gelir.

İris sınıflandırma işlemine göre, bir insan gözünden alınan bireysel kimlik iris görüntüleri aynı sınıf olarak tanımlanır. Bu şekilde, farklı kişilere ait iris sınıfları arasındaki benzerlikler veya farklılıklar tanımlanır.

Farklı kişilere ait iris sınıflarının mikro veya makro ölçüdeki farklılıkları her bireyin kendisine özgü bir sınıfının olmasını sağlar ve sınıflandırma işlemine bu şekilde yardımcı olur. Tanıma işlemlini makine öğrenmesi ile sağlayabilmek için kullanılan sınıflandırma yöntemlerinden bazıları aşağıdaki gibidir.

H.B. Kekre ve arkadaşları K-ortalamlarının bir optimizasyon algoritmasını kullanmıştır ancak algoritmanın yakınsaması uzun sürmüştür [21]. K-ortalamları için yakınsama süresini kısaltmak için kod kitabının benimsenmesi önemli ölçüde yoğunlaşmıştır.

Kod kitapları Linde Buzo ve Gray (LBG) ve Kekre'nin hızlı nesil kod çizelgesi (Fast Codebook Generation KFCG Algorithms), kullanılarak elde edilmiştir. S.Zhang ve arkadaşları iris görüntülerinin doku ilkelini kodlamak için Hiyerarşik Görsel Kod Kitabı adı verilen doku desenine dayalı bir yöntem önermiştir [13].

Desoky ve arkadaşları bir iris tanıma algoritmasını önermişlerdir; burada belirli bir gözün bir dizi iris görüntüsü bir araya getirilerek (tutarlı özellik verileri) bir final şablonu oluşturulmuştur [22].

Çalışmada YSA ile sınıflandırma yöntemleri tercih edilmiştir. YSA'nın karakteristik özellikleri doğrusal olmama, öğrenilebilirliği, genelleme yapabilmesi, hata toleransı ve donanım hızı bu tercihte önemli rol oynamıştır. Bir sonraki YSA bölümünde bahsedilen karakteristik özellikler detaylandırılmıştır.


### 3.4. YAPAY SİNİR AĞLARI

#### 3.4.1. Giriş

Makine öğrenimi, bilgisayarların deneyimlerinden ders almasını, örneklerle öğrenmesini ve analogi ile öğrenmesini sağlayan uyarlamalı mekanizmaları içeren yapıya sahiptir. Öğrenme yetenekleri zaman içerisinde akıllı bir sistemin performansını artırabilir.

Makine öğrenimi için en popüler yaklaşımlar yapay sinir ağları ve genetik algoritmalarıdır. Bir sinir ağı, insan beynine dayalı bir akıl yürütme modeli olarak tanımlanabilir. Beyin, birbiriyle bağlantılı sinir hücreleri veya nöronlar olarak adlandırılan temel bilgi işlem birimlerinden oluşur.

İnsan beyninin, aralarında yaklaşık 10 milyar nöron ve 60 trilyon bağlantı yani sinaps içerdiği varsayılmaktadır. Aynı anda birden fazla nöron kullanarak beyin, bugünkü en hızlı bilgisayarlardan çok daha hızlı işlevlerini yerine getirebilir. Her nöronun çok basit bir yapısı vardır, ancak bu tür elemanların bir ordusu muazzam bir işlem gücü oluşturur. Bir nöron, bir hücre gövdesi yani soma, dendritler adı verilen bir dizi lif ve akson denilen tek bir uzun lif içerir.



Şekil 3.13: Sinir hücresinin biyolojik gösterimi.

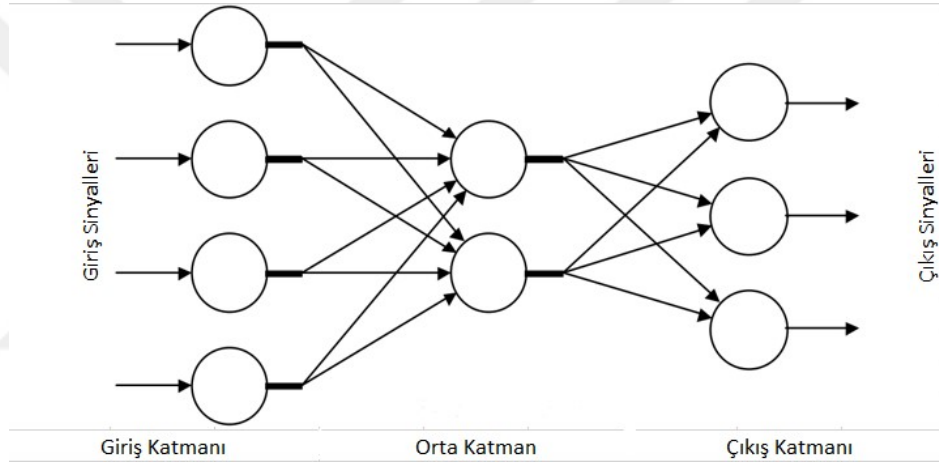
Teknolojik gelişmelerin doğadan esinlendiği hemen her alan gibi yapay sinir ağları da doğadan yani beyindeki sinir ağlarının çalışma prensibinden esinlenmiştir. İnsan beyni son derece karmaşık, doğrusal olmayan ve paralel bilgi işlem sistemi olarak kabul edilebilir.

Bilgi belirli yerlerde değil, tüm ağ boyunca eşzamanlı olarak bir sinir ağında saklanır ve işlenir. Başka bir deyişle, sinir ağında hem veri hem de işlenen veri yerel olmaktan

çok küreseldir. Küresellik verinin yalnızca sinir uçlarında değil sinir ağının tamamında saklanabilen veriyi ifade etmesinden kaynaklanır.

Öğrenme, biyolojik sinir ağlarının temel ve önemli bir karakteristik özelliğidir. Yapay bir sinir ağı, beyindeki biyolojik nöronlara benzeyen, nöronlar olarak da adlandırılan çok sayıda basit işlemciden oluşur. Bu yapıda her nöron, bir nörondan diğerine sinyaller ileten ağırlıklı bağlantılar ile bağlanır.

Çıkış sinyali, nöronun giden bağlantıları üzerinden iletilir. Giden bağlantı, aynı sinyali ileten bir dizi dala ayrılır. Giden dallar, ağdaki diğer nöronların gelen bağlantılarında sona erer. Bu saçaklı yapı iletinin dentritten aksona doğru oluşunu ifade eder Şekil 3.13 -Şekil 3.14.



Şekil 3.14: Yapay sinir ağı mimarisi.

YSA'lar doğrusal değildir ve girilen bilgi bütün ağa yayılmış durumdadır. Bu özelliği ile doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

YSA'lar öğrenilebilir yapıdadır. YSA karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

Tablo 3.1: Biyolojik ve yapay sinir ağlarının karşılaştırılması.

Biyolojik Sinir Ağı	Yapay Sinir Ağı
Soma	Nöron (Sinir Hücresi)
Dendrit	Giriş
Axon	Çıkış
Sinaps	Parametre Ağırlığı

YSA'lar genelleme yapabilir. YSA ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de istenilen tepkiyi üretebilir.

YSA'lar uyarlanabilir yapıya sahiptir. Belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir.


YSA'lar hata toleransına sahiptir. YSA, çok sayıda paralel dağılmış bir yapıya sahiptir ve ağıın sahip olduğu bilgi, ağıdaki bütün bağlantıların üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağıın doğru bilgi üretmesini etkilemez.

Nöron, giriş sinyallerinin ağırlıklı toplamını hesaplar ve sonucu bir eşik değeriyle karşılaştırır bu değer  $\theta$ 'dır. Eğer net giriş eşikten düşükse, nöron çıkışı  $-1$ 'dir. Ancak net giriş eşik değere eşit veya daha büyükse, nöron aktive olmaktadır.

Nöron, aşağıdaki transfer veya aktivasyon fonksiyonunu kullanır ve bu tip bir fonksiyon işaret fonksiyonu olarak adlandırılmıştır.

$$X = \sum_i^n x_i w_i \text{ and } Y = \begin{cases} +1, & \text{if } X \geq \theta, \\ -1, & \text{if } X < \theta, \end{cases} \quad (3.11)$$

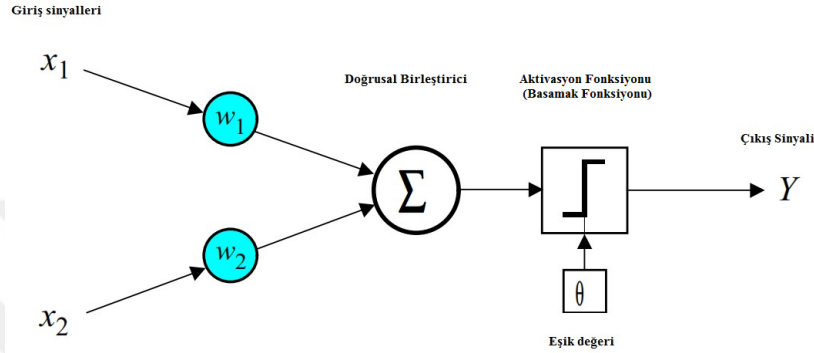
Çalışmada, önerilen YSA ile tanıma işlemleri şema ile gösterilmiştir. Belirtilen aşamalardan geçerek sınıflandırma ve tanıma gerçekleştirilecektir. Şekil 3.15. Fakat öncesinde kullanılacak algoritmalar bilgisayar modelli öğrenme kuralı açıklanacaktır.



Şekil 3.15: YSA'da sınıflandırma süreç aşamaları

### 3.4.2. Bilgisayar Modelli Öğrenme Kuralı

Tek bir sinir hücresinin bir bilgiyi öğrenebilirliği yıllarca tartışılmıştır. 1958'de Frank Rosenblatt, basit bir YSA eğitimi için ilk prosedürü sağlayan bir algoritma geliştirmiştir: bilgisayar modeli (perceptron) [23].



Şekil 3.16: Tek katmanlı iki girişli öğrenme modeli.


Perceptron bir sinir ağının en basit şeklidir. Tek bir nöron, ayarlanabilir sinaptik ağırlıklar ve bir aktivasyon fonksiyonundan meydana gelmektedir. Rosenblatt'ın model çalışması McCulloch ve Pitts nöron modeline dayanmaktadır [24].

Model, doğrusal bir birleştiriciden sonra aktivasyon fonksiyonundan oluşmaktadır. Girişlerin ağırlıklı toplamına aktivasyon fonksiyonu uygulanır; bu durumda eğer giriş pozitif ise +1'e eşit bir çıktı üretir ve negatif ise -1 üretir. Modelin amacı  $x_1, x_2, x_3, \dots, x_n$  girdileri  $A_1$  ve  $A_2$  şeklinde sınıflandırmaktır. Bir temel model durumunda, n boyutlu uzay, bir hiper düzlem tarafından iki karar bölgesine bölünür. Hiper düzlem aşağıdaki doğrusal ayrılabilir fonksiyon ile gösterilir.

Öğrenme modeli bir sınıflandırma görevlerini aşağıdaki gibi öğrenir. Bu, modelin gerçek ve istenen çıktıları arasındaki farkı azaltmak için ağırlıklarda küçük ayarlamalar yaparak yapılır. Başlangıçtaki ağırlıklar rastgele olarak verilir, genellikle  $[-0.5, 0.5]$  aralığındadır ve daha sonra eğitim örnekleriyle tutarlı çıktı elde etmek için güncellenir.

Hata fonksiyonu aşağıdaki gibidir.

$$e(p) = Y_d(p) - Y(p), p = 1, 2, 3, \dots, vb. \quad (3.12)$$



Şekil 3.17: (a) iki girişli model, (b) üç girişli model matematiksel gösterimi.

Eğer yineleme işlemi yani fonksiyondaki  $p$ 'lerde gerçek çıkış  $Y(p)$  ise ve istenen çıkış  $Y_d(p)$  ise, hata şu şekilde verilir: burada  $p= 1, 2, 3, \dots$  vb. gibidir. Yineleme alanı, modele sunulan  $p$ . eğitim örneğini ifade eder. Eğer hata, yani  $e(p)$  pozitifse, model çıktısını  $Y(p)$  arttırmak gerekir, fakat negatifse  $Y(p)$  azaltmak gereklidir.

### 3.4.3. Bilgisayar Modelli Eğitim Kuralı

Bilgisayar modelli öğrenme kuralı ilk kez 1960 yılında Rosenblatt tarafından önerilmiştir. Bu kuralı kullanarak sınıflandırma görevleri için bilgisayar modelli eğitim algoritmasını türetilmiştir. Bilgisayar modelli öğrenme modeli aşağıdaki fonksiyonunu kullanır;

$$w_i(p+1) = w_i(p) + \alpha \cdot x_i(p) \cdot e(p) \quad (3.13)$$

$P= 1,2,3, \dots$ , vb. gibi değerler alınırken,  $\alpha$  öğrenme oranıdır. Bilgisayar modelli öğrenme fonksiyonundan sonra modelin eğitim algoritması 4 basamak olarak bir sonraki sayfada ifade edilmiştir.

#### 3.4.3.1. Başlatma

Başlangıç parametrelerinin ağırlıkları  $w_1, w_2, w_3, \dots, w_n$  ve eşik değeri  $\theta$  aralığındaki  $[-0.5, 0.5]$  rastgele sayılarla belirlenir. Eğer hata, yani  $e(p)$  pozitif ise, modelin çıktısını  $y(p)$  arttırmak, fakat eğer negatif ise,  $y(p)$ 'yi azaltmak gereklidir.



### 3.4.3.2. Aktivasyon veya Transfer Fonksiyonu

$x_1(p), x_2(p), x_3(p), \dots, x_n(p)$  girişleri ve istenen çıktı  $Y_d(p)$  uygulanarak model etkinleştirilir. Ve yinelemede gerçek çıktıyı  $p = 1$  için hesaplar. Aşağıdaki fonksiyonu kullanır;

$$Y(p) = \text{step} \left[ \sum_{n=1}^i x_i(p) w_i(p) - \theta \right] \quad (3.14)$$

Fonksiyonda  $n$ , modele girişleri temsil eder ve  $\text{step}$ , basamak aktivasyon fonksiyonudur.

### 3.4.3.3. Ağırlıkların Eğitimi

Modeldeki ağırlıkların güncellenmeleri aşağıdaki fonksiyon ile sağlanır;

$$w_i(p+1) = w_i(p) + \Delta w_i(p) \quad (3.15)$$

Fonksiyonda  $\delta w_i(p)$  her yineleme başına ( $p$ ) ağırlıkların doğrulanmasını kontrol eder. Ağırlıkların doğrulanması delta kuralı ile hesaplanır aşağıdaki gibidir;

$$\Delta w_i(p) = \alpha \cdot x_i(p) \cdot e(p) \quad (3.16)$$

### 3.4.3.4. Yineleme

Yineleme birer birer artırılır, 2. basamağa geri dönülür ve yakınsamaya kadar işlemi tekrarlanır.

Önerilen model tek gizli katmana sahip çok katmanlı YSA modelidir ve bilgisayarlı eğitim kuralı bölümünde bahsedilen 4 basamakta gerçekleştirilmiştir. Aktivasyon fonksiyonu ile öznitelik vektörlerinin giriş katmanında aktif edilmesi sağlanmıştır ve (3.14) eşitliği kullanılmıştır.

Giriş katmanında girilen ağırlıklar ile giriş vektörlerinin toplamları gerçekleştirilmiş ve gizli katmana aktarılmıştır. Ağırlıkların eğitimi giriş katmanı ve gizli katmanda devam etmiştir ve (3.15) eşitliği kullanılmıştır. Ağırlıkların doğrulanması delta eşitliği ile hesaplanmış ve eşitlik (3.16) ile gerçekleştirilmiştir.

#### 3.4.4. Yapay Sinir Ağlarında Geri Yayılım (Back Propagation)

Çok katmanlı bir ağda öğrenme, bir algılayıcı model (perceptron) ile aynı şekilde gerçekleşir. Sinir ağına eğitim kümesi olarak giriş kalıpları kümesi sunulur. Sinir ağı, çıktı modellerini hesaplar ve bir hata veya başka bir deyişle, gerçek ve istenen çıktı modelleri arasındaki bir fark varsa, bu hatayı azaltmak için ağırlıklar ayarlanır.

Bir geri yayılma sinir ağında öğrenme algoritmasının iki aşaması vardır. İlk olarak, sinir ağının giriş katmanına bir eğitim girdi modeli sunulur. Ağ, çıktı modelini çıktı katmanı tarafından üretilinceye kadar girdi modelini katmandan katmana doğru ilerletir. Bu model istenen çıktıdan farklıysa, bir hata hesaplanır ve daha sonra çıkış katmanı ile giriş katmanı arasında sinir ağı boyunca geriye doğru yayılır. Hatanın yayılması sırasında ağırlıklar değiştirilir.

Doğrusal olmayan aktivasyon fonksiyonu (3.14) için genellikle defalarca türevi alınabilen fonksiyonlar tercih edilmektedir gizli katmanda. Geri yayılım hesaplamaları yapılırken hata oranının azaltılabilmesi ve en uygun ağırlık değerinin belirlenebilmesi için çoğu zaman sigmoid (3.17), tanjant hiperbolik (3.18) fonksiyonlarından yararlanılmaktadır.

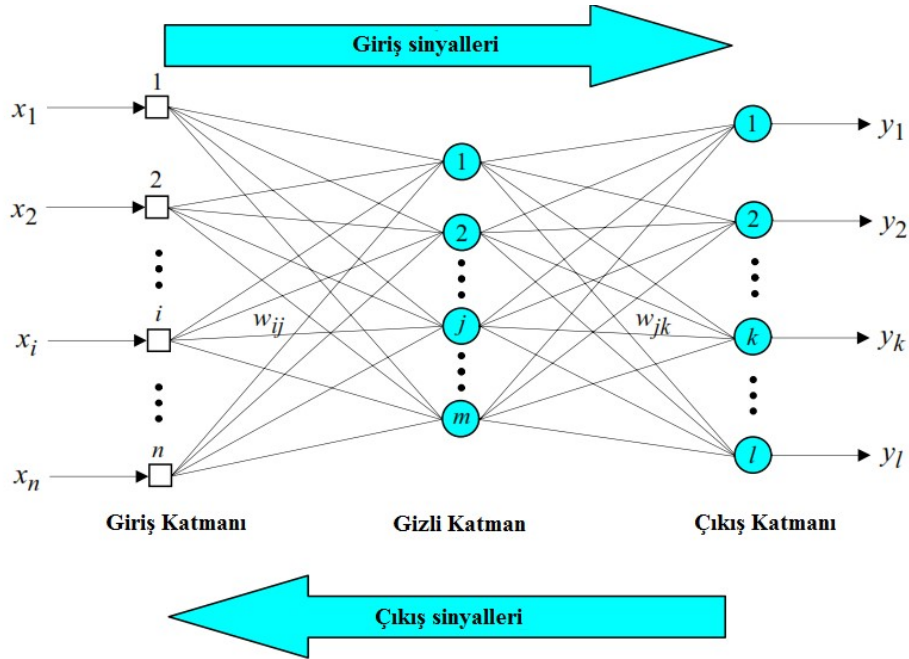
$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.17)$$

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.18)$$

Çalışmada, önerilen model ile geri yayılım kullanılmış ve istenen çıktı ile gerçek çıktılar arasındaki farkın azaltılması denenmiştir. Eğitim 500 tekrarlı geri yayılım ile gerçekleştirilmiştir ve sigmoid fonksiyon kullanılmıştır.

### 3.4.5. Çok Katmanlı Sinir Ağları

Çok katmanlı bir model (perceptron), bir veya daha fazla gizli katmanı olan ileriye dönük bir sinir ağıdır. Sinir ağı, kaynak nöronlarından oluşan bir giriş katmanından oluşur, orta katman sayısal hesaplamaların olduğu gizli nöron katmanlarından oluşur ve çıkış katmanı hesaplamaların olduğu nöron katmanından oluşur.



Şekil 3.18: Üç katmanlı sinir ağı modeli.

Çalışmada uygulanacak YSA Şekil 3.18’de şemalandırılmıştır. Burada giriş sinyalleri, katman katman bazında ileri yönde yayılır.

Çok katmanlı yapıdaki gizli katmanlar her katmandan istenen çıktıyı gizlemekle görevlidir. Gizli katmandaki nöronların sinir ağındaki davranışı giriş/çıkış şeklinde gözlenemez.

Gizli katmanın istenilen çıktısının ne olacağını bilmenin aşikâr bir yolu yoktur. Ticari amaçlı YSA, bir veya iki gizli katman dahil olmak üzere üç ve bazen dört katman içerir. Ayrıca her katman 10 ila 1000 nöron içerebilir. Deneysel sinir ağları ise üç veya dört gizli katman da dahil olmak üzere beş hatta altı katmana sahip olabilir ve milyonlarca nöron kullanabilir.

Uygulama aşamasında çalışmada, WEKA platformunda çok katmanlı sinir ağı kullanılmıştır. Giriş sinyali olarak polinomsal çekirdek ile elde edilen  $1 \times 100$ ’lük öznelik verktörleri

kullanılmıştır. Gizli katmanda 56 sinir hücresi kullanılmıştır. Tek bir gizli katman kullanılarak 100 nöron ile çıktılar elde edilmiştir.

100 farklı giriş ile çıktı olarak 10 sınıf elde edilmiştir. Daha başarılı sınıflandırma sonuçları elde edebilmek için çok katmanlı mimari yapı tercih edilmiştir. Uygulama, temsili olarak gösterilmiştir. Şekil 3.20.

WEKA da uygulanan çok katmanlı sinir ağı modelinin sınıflandırma sonuçları 10 sınıf için istatistiksel ortalama değerler ve hata oranlarıyla elde edilmiş ve şekil 3.21’de gösterilmiştir. İstatistiksel sonuçlardan MCC performansı, ortalama hata oranı, RMS hata oranı, hassasiyet oranları önemli sonuç değerleri olarak ön plana çıkmaktadır.

```

=== Summary ===
Correctly Classified Instances      27          90    %
Kappa statistic                    0.8869
Mean absolute error                 0.0383
Root mean squared error             0.1413
Relative absolute error             21.103 %
Root relative squared error         46.6464 %
Total Number of Instances          30

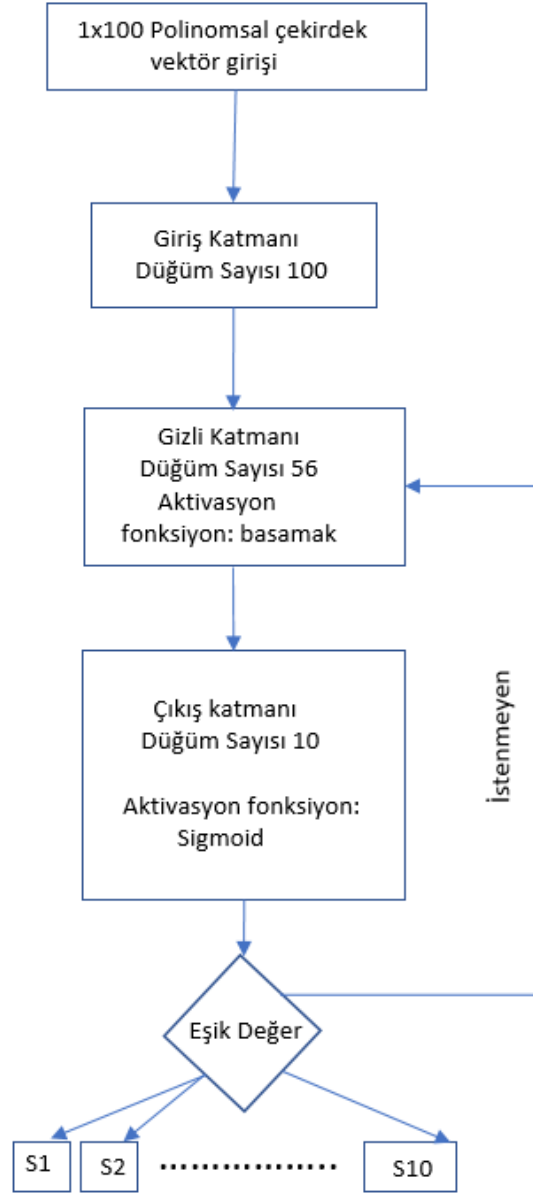
=== Detailed Accuracy By Class ===

```

	TP Rate	FP Rate	Precision	Recall	F-Measure	MCC	ROC Area	PRC Area	Class
	0,750	0,000	1,000	0,750	0,857	0,850	0,981	0,917	3
	1,000	0,000	1,000	1,000	1,000	1,000	1,000	1,000	29
	1,000	0,040	0,833	1,000	0,909	0,894	1,000	1,000	31
	1,000	0,000	1,000	1,000	1,000	1,000	1,000	1,000	32
	1,000	0,036	0,667	1,000	0,800	0,802	0,982	0,833	37
	0,800	0,000	1,000	0,800	0,889	0,877	1,000	1,000	40
	1,000	0,034	0,500	1,000	0,667	0,695	1,000	1,000	42
	1,000	0,000	1,000	1,000	1,000	1,000	1,000	1,000	49
	0,667	0,000	1,000	0,667	0,800	0,802	0,975	0,867	53
	1,000	0,000	1,000	1,000	1,000	1,000	1,000	1,000	54
Weighted Avg.	0,900	0,010	0,933	0,900	0,903	0,899	0,994	0,964	

Şekil 3.19: Sınıflandırma sonuçları.

Çalışmada öğrenme metodu olarak (3.15) eşitliği kullanılmıştır ve  $\alpha$  öğrenme oranı 3 olarak seçilmiştir. Batchsize 100 olarak seçilmiştir. Sistem 500 kez tekrar edilmiştir. Batch işleminde, veri kümesi batch değeri olarak belirlenen değere göre parçalara ayrılmakta ve her iterasyonda modelin eğitimi bu parça üzerinden yapılmaktadır. Ayrıca bazı durumlarda veri kendi içinde gruplanmış olabilmektedir. Bu durum veri kümesi içinde korelasyon oluşturacak; bu veri kümesinden seçilecek test kümesinin de yüksek başarımlı vermesini sağlayacak, böylece ezberleme (overfitting) olacaktır. Bunu önlemek için eğitim başlamadan veri kümesi parçalara ayrılmadan önce veri kümesi karıştırılmalıdır (shuffle).Batch seçiminde verilerin rastgele seçilmesi önemlidir. CD (çapraz doğrulama) ile ezberlemenin kontrolleri yapılacaktır.



Şekil 3.20: YSA parametreleri uygulama süreç aşamaları.

Uygulanan yöntemin YSA parametreleri akış şeması şekil 3.20 ile gösterilmiştir.

Algoritma akışı; öncelikle  $1 \times 100$  polinomsal çekirdek veri kümesi çok katmanlı YSA'ya girdi olarak sunulmuştur. Veri kümesi girdi ve çıktı olarak ayrıştırılıp değişkenlere atanır.

Çıktı kümesi 10 sınıftan oluşmaktadır ve nümerik olarak işlenir. Veri kümesi üzerine çok katmanlı YSA modeli uygulanır. Veri kümesi %70'i eğitim ve %30'u test kümesi olacak şekilde ayrılır.

Artık YSA sıralı olarak oluşturulur yani giriş katmanı - gizli katman - çıktı katmanı yapılarından oluşan yapı oluşturulur ve eğitim  $\alpha=3$  öğrenme oranı ile gerçekleştirilir. Bu aşamada YSA parametrelerine göre değerler güncellenir. Oluşturulan YSA modeli 500 iterasyon boyunca eğitim kümesi ile eğitilir. Gizli katmanda 56 sinir hücresi kullanılmıştır ve elde edilen sınıflandırma sonuçları 10 sınıf olarak gerçekleştirilmiştir.

Eğitim sonunda doğruluk ve hata değerleri hesaplanır. Elde edilen veriler bulgular bölümünde detaylandırılmıştır. Kontroller CD ile gerçekleştirilip modelin ezber yapmasının önüne geçilecektir.



## 4. BULGULAR

Çalışmalar CASIA Thousand veri tabanı ile yürütülmüştür [15]. Hâli hazırda kullanıma açık kaynak olarak kullanılabilen en geniş kaynaktır. CASIA Thousand veri tabanı 1000 kişiye ait 20000 iris resminden oluşmaktadır.

Çalışma, 3 aşamada gerçekleştirilmiştir: segmentasyon, normalizasyon ve sınıflandırma tanıma. İlk aşamada irisin segmentasyon, normalizasyon işlemleri MATLAB üzerinde yapılmıştır.

Hough dönüşümü ile göz bebeği bulunmuştur. Önerilen eliptik maske yöntemiyle göz bebeğine uygulanan yatay ve dikey gradyan vektörleri bulunarak iris görüntüsü segmente edilmiştir. Weka üzerinde elde edilen normalize özellikler, polinomsal çekirdek yöntemi kullanılarak  $1 \times 100$  öznitelik vektörleri elde edilmiştir.

Sonrasında uygulanan normalizasyon işlemlerinden elde edilen  $1 \times 64$ 'lük öznitelik vektörünü polinomsal çekirdek filtresinden geçirilerek  $1 \times 100$ 'lük öznitelik vektörü elde edilmiştir. Bu şekilde, öznitelik vektörlerinin hepsi normal dağılımlı hale dönüştürülmüş ve kullanılacak sinir ağının boyutu küçültülmüştür.

Daha sonra onlara  $a=0.3$  öğrenme faktörlü 100 batchsize'lı YSA uygulanmıştır. Sistem 500 kez tekrar eğitilmiştir. YSA ile sınıflandırma işleminde 10 sınıf kullanılmıştır, iris kütüphanesinden 10 kişiye ait resimler sağ ve sol göz için 10'ar resim olarak seçilmiştir. Elde edilen data %70 eğitim, %30 test olarak ayrılmış ve %90'lık başarı sağlanmıştır.

%93.3'lük hassasiyet sağlanmıştır. Çalışmanın MCC performansı %89.9. Ortalama hata oranı 0.0383, RMS hata oranı da 0.1413 olarak görülmüştür. Eğitimi 100 kez tekrar ettiğimizde %80 doğruluk oranı elde edilmiştir. Denenerek elde edilen en iyi doğruluk oranı %90 ile 500 kez tekrar eden eğitim ile gerçekleşmiştir. Öğrenme hızı 0.4 sn olarak görülmüştür. Ayrıca, CD uygulanarak aynı öznitelik vektörü kümesinde başarı oranı %85, %83 aralığında gerçekleşmiştir.

Hata matrisi ile hatalı sınıfların hangileri olduğuna ilişkin bilgi elde edilmiştir. Şekil 4.3'te iki fotoğraf ile, aynı insanın aynı gözünden arka arkaya alınmış iki fotoğraf gösterilmiştir. Fotoğraf alınırken, gözün sürekli ışığa maruz kalmasıyla göz bebeğinin büyümüş olduğu görülmüştür. Bu da iristeki detayların kaybolmasına neden olmuştur.

Yanlış sınıflandırmaya neden olabilecek bir durum teşkil etmektedir fakat hata matrisi ile hatalı sınıfları tespit edilmesi sağlanmıştır. Değişen dış faktörlerin iris detaylarının kaybolmasına sebep olduğu gözlemlenmiştir ve aşağıdaki hata matrisindeki gibi tespit edilmiştir. Şekil 4.2.

**Hata Matrisi**

a	b	c	d	e	f	g	h	i	j	←-- classified as
3	0	0	0	0	0	1	0	0	0	a = 3
0	2	0	0	0	0	0	0	0	0	b = 29
0	0	5	0	0	0	0	0	0	0	c = 31
0	0	0	4	0	0	0	0	0	0	d = 32
0	0	0	0	2	0	0	0	0	0	e = 37
0	0	1	0	0	4	0	0	0	0	f = 40
0	0	0	0	0	0	1	0	0	0	g = 42
0	0	0	0	0	0	0	2	0	0	h = 49
0	0	0	0	1	0	0	0	2	0	i = 53
0	0	0	0	0	0	0	0	0	2	j = 54

Şekil 4.1: Hata Matrisi ile hatalı sınıfların tespit edilmesi.

Matrise göre a=3 sınıfında yani 3.kişinin fotoğrafları arasında 4 tanesi test datası olarak kullanılmış, 1 tanesinin hatalı çıktığı görülmüştür. 3 tanesi doğru çıkmıştır. Hatalı çıkan iris görüntüleri Şekil 4.3'de gösterilmiştir.



Şekil 4.2: Sürekli ışık altında aynı kişiye ait göz bebeğinin büyümesi



Çalışmada, WEKA üzerinde DVM tabanlı polinomsal çekirdek öznelik vektörleri kullanılarak sınıflandırma yapılmıştır. YSA algoritmalarından çok katmanlı YSA modeli denenmiştir ve %90 doğrulukla gerçekleşmiştir. Öğrenme ortalama 0,4sn'de gerçekleşmiştir.

Çok katmanlı YSA modeli dışında sınıflandırma metodlarından *Logistic Classifier* ile %86 doğruluk elde edilmiştir. Destek vektör makineleri, *Puk Kernel* metodu ile sınıflandırma yönteminde %86.6 doğruluk sağlanmıştır.

**Tablo 4.1:** Diğer YSA ve DVM modelleri ile karşılaştırılması.

Yöntem	Doğruluk Yüzdesi	MCC	Ortalama Hata	RMS	CD
Multilayer Perceptron	%90	%89.9	0,0383	0,1413	%86
Logistic Regression	%86	%86.3	0,2822	0,0161	%80
SVM Puk Kernel	%86.6	%86.9	0,1607	0,2734	%81

Çalışma aynı yöntemle farklı eğitim sayılarıyla denenmiştir. En yüksek doğruluk oranına 500 tekrar ile ulaşıldığı görülmüştür. Daha düşük tekrarlarda örneğin; 100 tekrarda %80 doğruluk elde edilmiştir, 200 tekrarda %86 doğruluk elde edilmiştir.

Sistemin ezber yapmasının önüne geçmek için CD çapraz doğrulama yöntemi kullanılmıştır ve yapılan denemelerde %85 doğruluk oranı elde edilmiştir. Diğer YSA yöntemleri ve DVM yöntemi ile elde edilen öznelik vektörü datası test edilmiştir. Tablo 4.1'de ifade edildiği gibi bulgular elde edilmiştir ve sonuç bölümünde tartışılmıştır.

## 5. TARTIŞMA VE SONUÇ

Bu çalışmada yapay sinir ağları kullanılarak iris tanıma çalışılmıştır. MATLAB ile segmentasyon ve normalizasyon işlemleri başarıyla uygulanmıştır. Önerilen eliptik maske yöntemi ile iris bölgesinin maskelenmesi sağlanmıştır.

**Tablo 5.1:** Doğruluk oranlarının diğer çalışmalarla karşılaştırılması.

Metodoloji	Doğruluk Yüzdesi
Boles	%92,64
SC. H. Daouk	%83
Ma	%89
Szewczyk	%93
Önerilen YSA	%90

Çalışmada daha iyi frekans elde edebilmek için normalize iris görüntülerine DD uygulanmıştır. Elde edilen öznitelik vektörleri yapay sinir ağları ile sınıflandırma ve tanımda kullanılmıştır.

Eğitilen data ile iris tanıma 0.4 sn ile doğruluğu %90 olarak gerçekleştirmiştir. Çalışma CASIA Thousand iris veri tabanı ile denenmiştir. İris yapısının çeşitli dış faktörler altında bozulması, ışığın yetersiz olması veya aşırı olması, kontakt lens veya gözlük kullanımının alınan iris görüntü kalitesini düşürmesi gibi faktörler iris görüntülerinin yetersiz olmasına, dolayısıyla uygulanan çalışmaların sonuçlarını direk olarak etkiledikleri gözlemlenmiştir. İris tanıma için kullanılan YSA ile yüksek bir yüzde ve hızda tanıma gerçekleştirilmiştir.

Önerilen çalışmada, eliptik maskeleme yöntemi ve polinomsal çekirdek yöntemi ile kirpik ve göz kapağı gibi gürültü faktörlerini filtrelemeden çalışılmıştır ve başarılı sonuçlar elde edilmiştir. Çalışmaya özgünlük ve hız kazandırılmıştır. Çalışma, çıkarılan öznitelik vektörleri kullanılarak diğer YSA yöntemleriyle de denenmiştir. Ancak elde edilen sonuçlar çok katmanlı YSA modelinden düşük çıkmıştır.

Ridge tahminleyicisiyle, lojistik regresyon modelde %86 doğruluk oranı elde edilmiştir. Önerilen YSA ile elde edilen %90 doğruluk oranı, gerçekleşme hızı ve doğruluk oranı ile diğer YSA algoritmalarının karşısında daha avantajlı olarak gerçekleştirilmiştir.

Çalışmada elde edilen öznitelik vektörleri, lojistik regresyon modelinde %70 eğitim ve %30 test datası olarak parçalanarak elde edilen doğruluk oranı ve CD uygulanarak elde edilen doğruluk oranları, sırasıyla %86 ve %80'dir.

Çalışmada elde edilen öznitelik vektörleri, destek vektör makinelerinde, puk kernel yöntemi ile denenmiş ve sınıflandırma aşamasında önerilen yöntem ile elde edilen sonuçtan daha düşük gerçekleşmiştir %86,6. Ayrıca önerilen yöntem ile CD doğruluğu, puk kernel metodundan yüksek bir oran ile gerçekleşmiştir. Puk kernel yöntemi ile CD doğruluğu %81 olarak gerçekleşmiştir ve önerilen çalışmadan geride kalmıştır. %70 eğitim datası ve %30 test datası olarak parçalanarak sınıflandırıldığında ise doğruluk %86.6 olarak gerçekleşmiştir.

Önerilen çalışma, diğer çalışmalara sağladığı üstünlüğü daha geniş bir data ve daha fazla sınıf sayısı ile gerçekleştirmiştir. Szewczyk %93 doğruluğa, ters biorthogonal dalgacık dönüşümü uygulayarak ulaşmıştır. Çalışmasında 5 farklı göz resmi kullanmıştır ve küçük bir data kümesi ile çalışmasını gerçekleştirmiştir [25].

Sc. H. Daouk çalışmasını toplamda 60 resim ile gerçekleştirmiştir ve istatistiksel tanıma yöntemi kullanarak %83 doğruluğu elde etmiştir [26]. Geçmiş çalışmalardan Daugman %100'lük tanıma oranı elde etmiştir. Diğer taraftan Boles'in %92.64'lük çalışmalarının teorik karşılıkları ispat edilmiş ancak YSA kullanmadan, istatistiksel eşleştirme kullanmışlardır. Pratikte uygulanmak istendiği zaman, farklı ortam koşullarında bu yüzdelerin yakalanması, daha geniş data ile daha zor olacağı düşünülmektedir. [1], [3].

Önerilen yöntem, literatürdeki çalışmalara göre daha geniş bir data ile daha kısa sürede gerçekleşmiştir ve kabul edilebilir sonuçlar elde edilmiştir.

İleride yapılacak çalışmalarda, gerçek kişilerden daha fazla sayıda resim, daha iyi standartlar içinde öznitelik vektörlerinin oluşturulması, yapay sinir ağında daha uygun ağırlık değeri bulunması, değişik eğitim algoritmaları ve aktivasyon fonksiyonlarının kullanılması, sistemin performansını ve başarısını arttırıcı sonuçlar üreteceği düşünülmektedir.

## KAYNAKLAR

- [1]. Daugman, John 2003, “The importance of being random: statistical principles of iris recognition”, *Pattern Recognit.*, c. 36, sy 2, *Book*, 279-291.
- [2]. Wildes, R.P., 1994, “A system for automated iris recognition”, *IEEE*, 121-128.
- [3]. W.W. Boles, B.Boashash, 1998, “A human identification technique using images of the iris and wavelet transform”, *IEEE Trans. Signal Process.*, c. 46, sy 4, ss. 1185-1188.
- [4]. Y. Ma, K. Zhan, ve Z. Wang, 2009, “Pulse-Coupled Neural Networks, Applications of Pulse-Coupled Neural Networks”,*Berlin, Heidelberg: Springer Berlin Heidelberg*, ss.1-9.
- [5]. S. L. Lim, K. L. Lee, O. B. Byeon, ve T. K. Kim, 2001, “Efficient Iris Recognition through Improvement of Feature Vector and Classifier”, *ETRI J.*, c. 23, sy 2, ss. 61-70.
- [6]. A. Poursaberi ve B. N. Araabi, 2007, “A Novel Iris Recognition System Using Morphological Edge Detector and Wavelet Phase Feature”, s. 7.
- [7]. C.H. Chen ve C.T. Chu, 2009, “High performance iris recognition based on 1-D circular feature extraction and PSO–PNN classifier”, *Expert Syst. Appl.*, c. 36, sy 7, ss. 10351-10356.
- [8]. Yide Ma, Kun Zhan, Zhaobin Wang, 2003, “Pulse Coupled Neural Network”, *Springer Berliner Heidelberg*,ss. 1-9.
- [9]. Li Ma, Tieniu Tan, Yunhong Wang, ve Dexin Zhang, 2003, “Personal identification based on iris texture analysis”, *IEEE Trans. Pattern Anal. Mach. Intell.*,c. 25, sy 12, ss. 1519-1533.
- [10]. A. E. Hassanien, A. Abraham, J. F. Peters, G. Schaefer, ve C. Henry, 2009, “Rough Sets and Near Sets in Medical Imaging: A Review”, *IEEE Trans. Inf. Technol. Biomed.*, c. 13, sy 6, ss. 955-968.
- [11]. Murakami, Takano, Nakamura, Ed., 2003, “Real time iris recognition by a rotation spreading neural network”,*SICE 2003* annual conference.
- [12]. A. M. Wink ve J. B. J. M. Roerdink, 2004, “Denoising Functional MR Images: A Comparison of Wavelet Denoising and Gaussian Smoothing”, *IEEE Trans. Med. Imaging*, c. 23, sy 3, ss. 374-387.
- [13]. H. Zhang, Z. Sun, T. Tan, ve J. Wang, 2014, “Learning Hierarchical Visual Codebook for Iris Liveness Detection”, s. 6.
- [14]. Masek,Libor, 2003, “Iris Recognition”, *MSC*, ss.1-56.

- [15]. Chinese Academy of Sciences – Institute of Automation, 2003, *CASIA THOUSAND*, Database of 2000 Greyscale Eye Images. <http://www.sinobiometrics.com/THOUSAND>, 2003.
- [16]. C. Anibou, M. N. Saidi, ve D. Aboutajdine, 2014, “Multispectral images segmentation based on DWT and decisions fusion”, 2014, ss. 1-5.
- [17]. S. K. Zhou ve R. Chellappa, 2006, “From sample similarity to ensemble similarity: probabilistic distance measures in reproducing kernel Hilbert space”, *IEEE Trans. Pattern Anal. Mach. Intell.*, c. 28, sy 6, ss. 917-929.
- [18]. W. M. Campbell, D. Sturim, ve D. A. Reynolds, 2006, “Support vector machines using GMM supervectors for speaker verification”, *IEEE Signal Process. Lett.*, c. 13, sy 5, ss. 308-311.
- [19]. A. Bansal, R. Agarwal, ve R. K. Sharma, 2012, “SVM Based Gender Classification Using Iris Images”, 2012, ss. 425-429.
- [20]. C.-H. Wu, G.-H. Tzeng, ve R.-H. Lin, 2009, “A Novel hybrid genetic algorithm for kernel function and parameter optimization in support vector regression”, *Expert Syst. Appl.*, c. 36, sy 3, ss. 4725-4735.
- [21]. H. B. Kekre, T. K. Sarode, S. D. Thepade, ve V. Vaishali, 1943, “Improved texture feature based image retrieval using Kekre’s fast codebook generation algorithm”, *Thinkquest 2010, 2011*, ss. 143-149.
- [22]. A. I. Desoky, H. A. Ali, ve N. B. Abdel-Hamid, 2012, “Enhancing iris recognition system performance using templates fusion”, *Ain Shams Eng. J.*, c. 3, sy 2, ss. 133-140.
- [23]. Rosenblatt, Frank, 1958, “The perceptron: A probabilistic model for information storage and organization in the brain.”, *Psychol. Rev.*, c. 65, sy 6, 386-408.
- [24]. W. S. McCulloch ve W. Pitts, 1943, “A logical calculus of the ideas immanent in nervous activity”, *Bull. Math. Biophys.*, c. 5, sy 4, ss. 115-133.
- [25]. R. Szewczyk, P. Jaboski, et. al. 2002, “Automatic People Identification on the Basis of Iris Pattern -Extraction Features and Classification”, *Proc. Int. Conf. on Microelectronics (MIEL 2002)*, VOL 2, Yugoslavia pp. 691-694.
- [26]. SC. H. Daouk, L. A. El-Esber, F. D. Kammoun and M. A. Al Alaoui, 2002, “Iris Recognition”, *IEEE ISSPIT 2002*, Marrakesh.

## ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Koray POLAT
Doğum Yeri	İstanbul
Doğum Tarihi	16.03.1989
Uyruğu	<input checked="" type="checkbox"/> T.C. <input type="checkbox"/> Diğer:
Telefon	0538 235 22 95
E-Posta Adresi	kryolat@gmail.com
Web Adresi	http://



Eğitim Bilgileri	
Lisans	
Üniversite	Abant İzzet Baysal Üniversitesi
Fakülte	Fen Edebiyat
Bölümü	Matematik
Mezuniyet Yılı	2012

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri
Anabilim Dalı	Elektrik Elektronik Mühendisliği Anabilim Dalı
Program	Elektrik Elektronik Mühendisliği