

**T.C.
MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GÖRÜNTÜ İŞLEMeye DAYALI AVUÇ İÇİ İZİNİN
YAPAY SİNİR AĞI İLE TANINMASI**

Enes ÇELİK

**YÜKSEK LİSANS TEZİ
ELEKTRONİK-BİLGİSAYAR EĞİTİMİ ANABİLİM DALI
BİLGİSAYAR-KONTROL EĞİTİMİ PROGRAMI**

DANIŞMAN

Yrd. Doç. Dr. Ali BULDU

İSTANBUL 2011

**T.C.
MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GÖRÜNTÜ İŞLEMeye DAYALI AVUÇ İÇİ İZİNİN
YAPAY SİNİR AĞI İLE TANINMASI**

**Enes ÇELİK
(522109001)**

**YÜKSEK LİSANS TEZİ
ELEKTRONİK-BİLGİSAYAR EĞİTİMİ ANABİLİM DALI
BİLGİSAYAR-KONTROL EĞİTİMİ PROGRAMI**

**DANIŞMAN
Yrd. Doç. Dr. Ali BULDU**

İSTANBUL 2011

TEŐEKKÜR

Yüksek Lisans tez çalışma sürecinde beni yönlendiren, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan desteğini ve yardımını hiçbir zaman esirgemeyen tez danışmanım değerli Yrd. Doç. Dr. Ali BULDU'ya teşekkürlerimi sunarım.

Hayat boyunca her zaman yanımda olan, maddi ve manevi desteklerini hiçbir zaman esirgemeyen aileme teşekkürlerimi, sevgi ve saygılarımı sunarım.

Kasım, 2011

Enes ÇELİK

İÇİNDEKİLER

SAYFA NO

TEŞEKKÜR	i
İÇİNDEKİLER	ii
ÖZET	iv
ABSTRACT	v
SEMBOLLER	vi
KISALTMALAR	vii
ŞEKİLLER	viii
TABLolar	ix
BÖLÜM I. GİRİŞ VE AMAÇ	1
I.1. GİRİŞ	1
I.1.1. Avuç İçi Görüntüsünün Özellikleri	2
I.1.2. Biyometride Yapay Zeka Uygulamaları	3
I.2. AMAÇ	4
I.3. TEZİN BÖLÜMLERİ HAKKINDA GENEL BİLGİ	5
BÖLÜM II. GÖRÜNTÜ TANIMA SİSTEMİ	6
II.1. ÖRÜNTÜ TANIMA SİSTEMİ	6
II.1.1. Avuç İçi Tanıma Sisteminin Performansının Belirlenmesi	7
II.2. GÖRÜNTÜ İŞLEME TEKNİKLERİ	8
II.2.1. Normalleştirme	8
II.2.2. Eşikleme	8
II.2.2. Histogram	9
II.2.2.1. Histogram Eşitleme	10
II.2.3. Renk Kavramı	10
II.2.3. Geometrik Dönüşüm	11
II.2.4. Kenar Belirleme	12
II.2.5. Morfolojik Görüntü İşleme	13
II.3. DALGACIKLAR TEORİSİ	15

II.3.1. Fourier Dönüşümü	15
II.3.2. Dalgacık Dönüşümü	16
II.3.3. Haar Dalgacık Dönüşümü	19
II.3.3. Sürekli Dalgacık Dönüşümü	20
II.3.4. Ayırık Dalgacık Dönüşümü	20
II.3.5. Hızlı Dalgacık Dönüşümü	21
II.4. YAPAY SİNİR AĞLARI	23
II.4.1. Biyolojik Sinir Hücreleri	23
II.4.2. Yapay Sinir Hücresi	24
II.4.2.1. Aktivasyon Fonksiyonları	25
II.4.3. Yapılarına Göre Yapay Sinir Ağları	26
II.4.3.1. İleri Beslemeli Tek Katmanlı Ağlar	27
II.4.3.2. İleri Beslemeli Çok Katmanlı Ağlar	27
II.4.3.3. Geri Beslemeli Ağlar	28
II.4.3.4. Yapay Sinir Ağlarında Danışmanlı Öğrenme	29
II.4.3.5. Yapay Sinir Ağlarında Danışmansız Öğrenme	30
II.5. AVUÇ İÇİ TANIMA SİSTEMLERİ	30
II.5.1. Avuç İçi Görüntüsü Veri Tabanları	32
II.5.2. Avuç İçinden İlgili Bölgesinin Çıkartılması	35
II.6. LİTERATÜRDEKİ ÖNCEKİ ÇALIŞMALARIN ÖZETLERİ	37
BÖLÜM III. AVUÇ İÇİ TANIMA UYGULAMASI	40
III.1. ÖZİNİTELİK ÇIKARMA AŞAMASI	41
III.2. SINIFLANDIRMA AŞAMASI	42
III.3. DENEYSEL ÇALIŞMALAR	43
III.3.1. Yapay Sinir Ağında Eğitim Aşamaları	43
III.3.2. Yapay Sinir Ağında Test Aşamaları	48
BÖLÜM IV. SONUÇLAR ve TARTIŞMA	54
BÖLÜM V. SON DEĞERLENDİRME ve ÖNERİLER	56
KAYNAKLAR	58
ÖZGEÇMİŞ	

ÖZET

GÖRÜNTÜ İŞLEMESİNE DAYALI AVUÇ İÇİ İZİNİN YAPAY SİNİR AĞI İLE TANINMASI

Günümüzde güvenilir bir şekilde kimlik tespiti hala çözüm bekleyen sorunlar arasındadır. Bu tez çalışması bu sorunların çözümüne katkıda bulunmak üzere geliştirilen algoritma ile biyometrik kimlik tanımlama ve doğrulama sistemi geliştirilmiştir. Biyometrik kimlik tespitinde avuç içi izleri önemli araçlardan birisidir. Avuç içi okuyucusundan veya tarayıcıdan alınan görüntüler bilgisayar ortamında görüntü ön işleme teknikleri ile sayısal hale çevrilmiştir. Avuç içi görüntüsünün referans alınan çalışma bölgesinin çıkarılması ve bu bölgeye iki boyutlu ayırık dalgacık dönüşümü uygulanarak avuç içi öznitelik vektörleri belirlenmiştir. Dalgacık dönüşümü sonucunda elde edilen fazla katsayılar geliştirilen algoritma ile avuç içi izini temsil edecek ve ayırt ediciliğini yitirmeden daha az katsayılara indirgenerek ileri beslemeli yapay sinir ağına eğitilerek sınıflandırılmıştır.

Yapılan çalışmada kullanılan avuç içi görüntüleri bu alanda standart olarak kabul edilen PolyU veri tabanından elde edilmiştir. Bu tez çalışmasında yapay sinir ağı ile avuç içi izi tanımlama ve doğrulama sistemi gerçekleştirilerek problemin çözümüne katkı sağlamaya çalışılmıştır. Yapay sinir ağı ile eğitim sürecinde ve test aşamasında başarı gösterilmiştir.

Kasım, 2011

Enes ÇELİK

ABSTRACT

Recognition Of Palmprint Based On Image Processing With Artificial Neural Network

Reliable identification notification is still a problem that needs solution in today's world. This thesis study was developed to contribute solutions of that problem in the light of algorithm and biometric identification notification and verification systems. Palm print traces an important role in biometric identification notification. Visions that were obtained from palm print scanner, translated numerical status with using image processing technics. To determine palm print trace attribute vectors, palm trace's referenced working region of interest omitted and two dimensionel discrete wavelet transform is implemented. Excessive coefficient that are obtained in the process of wavelet transform is classified in feedforward backprop artificial neural network without losing distinguishing characteristics.

Palm print is obtained from generally accepted standard called PolyU database system. In this thesis, purpose is contribute for solution of problem with developing of artificial neural network and palm print trace identification and verification system. In the artificial neural network train and test process success is obtained.

November, 2011

Enes ÇELİK

SEMBOLLER

r	: 0-255, 8 bit deęer aralıęı
s	: 0-1, 1 bit deęer aralıęı
th	: Eşik deęeri
C	: Kovaryans Matrisi
G	: Gri Seviye Deęişkeni
K	: Maske sabiti
R	: Maskenin resimdeki her nokta için yanıtı
W	: Maskenin katsayıları
Z	: Maskenin katsayıları ile ilişkilendirilmiş pikseldeki grinin seviyesi
$\psi(x)$: Dalgacık fonksiyonu
W_φ, W_ψ	: Ayrık dalgacık fonksiyon çiftleri
$\varphi(x)$: Ölçekleme fonksiyonu.
$g(k)$: Alçak Geçiren Filtre Katsayıları
$h(k)$: Yüksek Geçiren Filtre Katsayıları
Φ	: Yapay Sinir Aęı Eşik Deęeri

KISALTMALAR

ANFIS	: Adaptive Network Fuzzy Inference System
CASIA	: The Chinese Academy of Sciences Institute of Automation
CCD	: Charge Coupled Device
dB	: Daubechies Dalgacıđı
DNA	: Deoksiribo Nükleik Asit
DPI	: Dot Per Inch
DWT	: Discrete Wavelet Transform
ID	: Her Birey İçin Farklı Kimlik Numarası
IITK	: Indian Institute Technology of Kanpur
JPEG	: Joint Photographic Experts Group
KPCA	: Kernel Principal Component Analysis
NIR	: Near Infrared
PCA	: Temel Bileşenler Analizi
PolyU	: The Hong Kong Polytechnic University
ROI	: Region of Interest
SVM	: Support Vector Machine
YSA	: Yapay Sinir Ađı

ŞEKİLLER

SAYFA NO

Şekil I.1	Avuç İçi Çizgileri.....	2
Şekil II.1	Örüntü Tanıma Sistemi	6
Şekil II.2	Eşik Değeri	9
Şekil II.3	Eşikleme Öncesi ve Sonrası Görüntüleri.....	9
Şekil II.4	Görüntünün Histogramı.....	9
Şekil II.5	Histogramı Eşitlenmiş Avuç İçi Görüntüsü.....	10
Şekil II.6	Farklı Gri Seviye Görüntüleri.....	11
Şekil II.7	Geometrik Dönüşüm	12
Şekil II.8	3x3'lük Genel Bir Maske Matrisi	12
Şekil II.9	Gri Seviye Görüntü Üzerinde Yatay Çizgi Eğrisi.....	13
Şekil II.10	Morfolojik Aşınma ve Genleşme.....	15
Şekil II.11	Morfolojik Açılış ve Kapanış	15
Şekil II.12	Bir Boyutlu Subband Kodlama için İki Bantlı Filtre Bankası.....	18
Şekil II.13	İki Boyutlu Subband için Dört Bantlı Filtre Bankası.....	19
Şekil II.14	İki Boyutlu Analiz Filtreleme Bankası.....	21
Şekil II.15	İki Boyutlu Analiz Filtre Sonuçlarının Dağılışı.....	22
Şekil II.16	İki Boyutlu Sentez Filtreleme Bankası.....	22
Şekil II.17	Biyolojik Sinir Hücresinin Genel Yapısı.....	24
Şekil II.18	Yapay Sinir Hücresinin Genel Yapısı	24
Şekil II.19	Lineer Aktivasyon Fonksiyonu.....	26
Şekil II.20	Sigmoid Aktivasyon Fonksiyonu.....	26
Şekil II.21	Tan-Sigmoid Aktivasyon Fonksiyonu	26
Şekil II.22	İleri Beslemeli Tek Katmanlı Yapay Sinir Ağı	27
Şekil II.23	İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları.....	28
Şekil II.24	Geri Beslemeli Yapay Sinir Ağı.....	29
Şekil II.25	Danışmanlı Öğrenme Yapısı.....	29
Şekil II.26	Danışmansız Öğrenme Yapısı	30
Şekil II.27	Avuç İçi Tanıma ve Eğitim Aşamaları Blok Şeması	31
Şekil II.28	Avuç İçi Görüntüsü Alma Sisteminin Şeması	32

Şekil II.29	CASIA Multi Spektral Görüntüleme Cihazı	33
Şekil II.30	PolyU Avuç İçi Okuyucusundan Görüntü Alma İşlemi.....	34
Şekil II.31	PolyU MultiSpectral Avuç İçi Görüntüleri	35
Şekil II.32	PolyU ROI Avuç İçi Görüntüleri.....	35
Şekil II.33	Avuç İçi İlgi Bölgesinin Çıkartılma Aşamaları	36
Şekil III.1	Avuç İçi Tanıma Sistemi Akış Diyagramı	40
Şekil III.2	Haar 2. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları	44
Şekil III.3	Haar 4. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları	45
Şekil III.4	Haar 6. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları	45
Şekil III.5	Daubechies 4. Tip 2. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları.....	46
Şekil III.6	Daubechies 4. Tip 4. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları.....	47
Şekil III.7	Daubechies 4. Tip 6. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları.....	48
Şekil III.8	Haar Dalgacık Seviyelerine Göre Hata Değişimi	49
Şekil III.9	Daubechies Dalgacık Seviyelerine Göre Hata Değişimi.....	51
Şekil III.10	Haar Dönüşümü Doğru Tahmin Sonuçlarının İstenen Cevaba Yakınlığı.....	51
Şekil III.11	Daubechies Dönüşümü Doğru Tahmin Sonuçlarının İstenen Cevaba Yakınlığı.....	52

TABLolar

SAYFA NO

Tablo III.1	15. Kişinin Avuç İçi Öznitelik Katsayıları.....	42
Tablo III.2	Yapay Sinir Ağı İçin Giriş Datası Örneği	43
Tablo III.3	Yapay Sinir Ağı İçin Hedef Datası Örneği.....	43
Tablo III.4	Haar 2. Seviye Dalgacık için Sonuç Değerleri	44
Tablo III.5	Haar 4. Seviye Dalgacık için Sonuç Değerleri	44
Tablo III.6	Haar 6. Seviye Dalgacık için Sonuç Değerleri	45
Tablo III.7	Daubechies 4. Tip 2. Seviye Dalgacık için Sonuç Değerleri.....	46
Tablo III.8	Daubechies 4. Tip 4. Seviye Dalgacık için Sonuç Değerleri.....	47
Tablo III.9	Daubechies 4. Tip 6. Seviye Dalgacık için Sonuç Değerleri.....	47
Tablo III.10	Haar 2. Seviye Dalgacık için Test Sonuçları.....	48
Tablo III.11	Haar 4. Seviye Dalgacık için Test Sonuçları.....	49
Tablo III.12	Haar 6. Seviye Dalgacık için Test Sonuçları.....	49
Tablo III.13	Daubechies 4. Tip 2. Seviye Dalgacık için Test Sonuçları	50
Tablo III.14	Daubechies 4. Tip 4. Seviye Dalgacık için Test Sonuçları	50
Tablo III.15	Daubechies 4. Tip 6. Seviye Dalgacık için Test Sonuçları	50

BÖLÜM I

GİRİŞ VE AMAÇ

I.1. GİRİŞ


Yetkili kişilerin erişmesi istenen alanlara erişimin denetlenmesi probleminin çözümündeki teknikler gelişen teknolojiyle paralellik göstermektedir. Günümüzde bu konudaki en gelişmiş yöntemler, fiziksel özelliklerden kişiyi tanımaya dayanan ve biyometri olarak da bilinen bilim dalı olarak karşımıza çıkmaktadır. En basit tanımıyla biyometrik yöntemler, kişinin ayırt edici fiziksel özelliklerinden birini veya birkaçını bir sensör yardımı ile alıp yetkili olup olmadığını test eder ve sonuçta kişiye giriş izni veya red cevabı veren sistemlerdir. Biyometrik sistemler, kişilerin fiziksel ve biyolojik özelliklerine bakarak kimlik tespiti yapabilen bilgisayar destekli kimlik tanıma sistemleridir. Bu teknoloji sayesinde gizlilik gerektiren işlemler bir insanın kontrolüne gerek olmadan, herhangi bir kopyalamaya ve hataya meydan vermeden gerçekleştirilmektedir. Çünkü kimlik tespiti yapılırken gözönüne alınan fiziksel karakteristikler her bir bireyde farklı özellikler taşımaktadır. En yaygın olarak bilinen yöntemler arasında parmak izi tanıma, el geometrisi tanıma, avuç içi tanıma, iris/retina analizi, yüz tanıma, ses analizi, imza analizi bulunmaktadır. Hizmet vereceği sektöre göre bu yöntemlerin birbirlerine karşı avantaj ve dezavantajları vardır. Hangi yöntemin en uygun yöntem olduğu, fiyat, hata oranı, ortama duyarlılık, kullanım kolaylığı gibi birden fazla faktörün değerlendirilmesiyle belirlenir. Aralıksız süren araştırmalar sonucunda bu yöntemler her geçen gün gelişen teknolojiye paralel olarak biraz daha optimize edilmekte ve maliyetleri de düşmektedir [1].

Bu gelişmeler, biyometrik ölçümlerin kimlik tanıma açısından giderek daha güvenilir hale gelmesine imkân sağlamaktadır. Bununla beraber, biyometrik kimlik tanıma veya doğrulama amacıyla kullanılan sistemlerin çoğu yeteri derecede karmaşık olup, bunlarla ilgili araştırma ve geliştirme çalışmaları halen devam etmektedir. Bu kapsamda geliştirilen algoritmaların başarısı, uygulamada sağladıkları

kolaylıkların yanı sıra, kimlik tanıma veya doğrulamada sağladıkları doğruluk ve güvenilirlikle ölçülmektedir [2].

I.1.1. Avuç İçi Görüntüsünün Özellikleri

Avuç içi tanımlaması parmak izi eşleme algoritmaları ile aynı uygulamaya dahildir. Her iki biyometrik öznelik de çizgilerde beliren etkilerin temsil ettiği, kendine has ve daimi bilgilere dayanır. Birçok parmak izi tanınmasında olduğu gibi temel avuç içi izi tanınması ve doğrulanması korelasyona dayalı, özellik noktalarına dayalı ve çizgilere dayalı olarak sınıflandırılabilir. Bu geleneksel algoritmalar avuç içi izinin çok çözünürlüklü özelliğini dikkate almamaktadırlar, her avuç üç ana çizgiden oluşur kalp çizgisi, kafa çizgisi ve yaşam çizgisi. Avuç içindeki çizgilerin eğimleri, birbirine olan ilişkileri, sayısı ve uzaklıkları önem taşımaktadır. Bu çizgiler zamanla çok az değişikliğe uğrarlar, çizgilerin kalın olması düşük çözünürlükte analiz edilmeyi mümkün kılar, çizgilerin şekli ve yeri ise kişi tanımlamada önemli rol oynar. Avuç içi izi aynı zamanda kırışık çizgiler içerir, bu çizgiler ana çizgilerden daha ince ve düzensizdirler, orta çözünürlükte analiz edilmelidirler [3].



Şekil I.1: Avuç İçi Çizgileri [4]

Şekil I.1'deki 1: Hayat çizgisi, 2: Baş çizgisi, 3: Kalp çizgisi, 4: Venüs kuşağı, 5: Güneş çizgisi, 6: Merkür çizgisi, 7: Kader çizgisidir. Burada bir, iki, üç ana çizgiler diğerleri kırışık çizgilerdir.

I.1.2. Biyometride Yapay Zeka Uygulamaları

Bilgi teknolojileri dediğimiz bilgisayar tabanlı sistemlerde olan gelişim çağımızı teknoloji çağı yapmıştır. Amaç hep daha hızlı, daha güvenilir, daha akıllı ve daha kullanışlı sistemleri oluşturmaktır. Uygulamadaki gereksinimlerin başında işlevsel ve güvenilir olması gelmektedir. Bu ihtiyaçlar genellikle kullanıcı tanımlama ve doğrulamaya göre kişilere ilgili sistemde giriş hakkı, düzenleme hakkı, silme hakkı şeklinde olmaktadır. Bu amaçla yapılan ve günümüzde de kullanılmakta olan sistemler genellikle kullanıcı tanımlamalarını kişiye verilen bir anahtar, şifre ve manyetik kart ile yapmaktadır. Bu anahtar değerlerinin unutulabilir, kaybedilebilir ve tahmin edilebilir yapıda olması benzeri sistemlerin dezavantajıdır. Bu eksiklikleri büyük ölçüde ortadan kaldıran sistemler biyometrik sistemlerdir. Bireyin ölçülebilen fizyolojik veya davranışsal özelliklerine Biyometri denilmektedir. Biyometrik özellikler; parmak izi, avuç içi bilgisi, retina, iris, el ve yüz yapısı, ses, dişler, yürüyüş, konuşma şekli, el yazısı, damar ağı ve DNA'dır. Biyometrik sistemlerin en büyük üstünlüğü bu özelliklerin unutulmayan, kaybedilmeyen ve tahmin edilmeyen yapılar olmasıdır. Kişiden kişiye değişen ve bu nedenle transfer edilmesi zor olan bu özellikler biyometriyi güvenlik sistemlerinde en çok tercih edilen alan haline dönüştürmüştür. Biyometrik özellikleri kullanan sistemlere biyometrik sistemler adı verilir. Günümüzde biyometrik sistemler bankacılık, kriminoloji, güvenlik ve oylama gibi birçok farklı alanda kullanılmaktadır. Biyometri problemlerinden bilgisayarlı kimlik tespiti ve kişinin tanınması yapay zeka araştırmalarının önemli alanlarından [5].

Bu kapsamda yapay sinir ağları uygulamalarını esas alan yapay zeka tabanlı işlemler, konu ile ilgili çalışmalar arasında önemli bir yer almaktadır [6].

Avuç içi tanıma sistemlerinde, öznitelik tabanlı ve işlenmemiş görüntü tabanlı yaklaşım olmak üzere iki tür yaklaşım kullanılmaktadır. İşlenmemiş görüntü tabanlı yaklaşımda, önışlem aşamaları olmaksızın doğrudan avuç içi görüntüsünün özyapısından elde edilen veriler üzerinde çalışılmaktadır. Öznitelik tabanlı yaklaşımda ise avuç içi görüntülerinden çalışma bölgesi çıkarılarak kullanılmaktadır. Bu yaklaşımda, avuç içi tanıma temel olarak avuç içi önışleme, öznitelik çıkartma ve eşleme olmak üzere üç ana aşamada gerçekleştirilmektedir. Avuç içi önışleme aşaması, tarayıcıdan alınan avuç içi görüntüsünün iyileştirilmesi, iz yönlerinin bulunması, bölütleme, ikilileştirme ve inceltme işlemlerini kapsamaktadır. Avuç içi öznitelik çıkartma aşamasında, inceltmiş görüntüden kalp, baş ve hayat ana

çizgilerinden yararlanılarak bu öznelikler eşleme ve sınıflandırma aşamasında kullanılmaktadır [7].

Dalgacıklar en çok kullanılan öznelik çıkarma yöntemidir. Bu yöntemle görüntü üzerinde bütün ve detaylar hakkında öznelikler çıkarmak mümkündür. İki boyutlu dalgacık momentleri bir görüntüde değişmeyen özneliklerin çıkarılmasında önemlidir. Momentler bir noktanın referans ya da eksene olan uzaklığının nümerik ölçümlerini tanımlar. Aynı örüntüye ait farklı derecelerdeki momentler farklı bilgi içermektedir [8].

I.2. AMAÇ

Güvenilir kimlik tespiti hala çözüm bekleyen sorunlar arasındadır. Gelişen teknoloji ve bilgisayar sistemleri ile daha hızlı ve kolay kimlik tespiti gerçekleştirilmektedir. Bu tespit az bir hata ile gerçekleşiyor ve sahtekârlığa yol açabileceği için hala çözüm bekleyen konular arasındadır. Bu tez çalışması bu sorunların çözümüne katkıda bulunmak için biyometrik kimlik tanımlama ve doğrulama sistemi tasarlamıştır.

Bu tez çalışmasında avuç içi görüntülerini temsil edecek özneliklerin çıkartılması ve avuç içi görüntü analizine dayalı bir kimlik tanımlama ve doğrulama sistemini gerçekleştirilmesi amaçlanmıştır. Bu çalışmada sorgulanan bir avuç içi görüntüsünün tanıma amacıyla kullanılan bir veri tabanındaki görüntüler içerisinde olup olmadığının belirlenmesi hedeflenmiştir.

Yapılacak uygulamada literatürde standart olarak kullanılan PolyU avuç içi görüntüleri veri tabanı kullanılarak özneliklerin çıkartılmasında ayırık dalgacık dönüşümü katsayıları kullanılarak veri setleri oluşturulmuştur. Bu veri setleri yapay sinir ağına giriş verisi olarak, çıkışına hedef veri setlerinin kullanılacağı bir eğitim süreci ile sınıflandırılmıştır.

Avuç içi görüntüsüne yapılacak işlemler Matlab ortamındaki görüntü işleme araç kutusu ve dalgacık araç kutusunun hazır komut ve fonksiyonları kullanılacaktır.

Bu çalışma kapsamında avuç içi görüntülerinin tanımadaki performans analizleri, deney ve test aşamalarının kimlik tanımlama ve doğrulamanın başarılması ve sonuçlarının değerlendirilmesi amaçlanmıştır.

I.3. TEZİN BÖLÜMLERİ HAKKINDA GENEL BİLGİ

Bölüm II’de avuç içi görüntülerinin analizi ile ilgili temel konular üzerine bir inceleme yapılmıştır. Bu kapsamda görüntü işleme ile ilgili temel konular hakkında teorik bilgiler verilmiştir. Öznitelik vektörlerini oluşturmak için Fourier ve Dalgacık dönüşümleri hakkında teorik bilgiler verilmiştir. Sınıflandırma aşamasında kullanılacak yapay sinir ağları ile ilgili teorik bilgiler verilmiştir. Bu bölümün sonunda literatürde avuç içi tanıma ve doğrulama üzerine yapılan çalışmalarla ilgili bir araştırmanın sonuçları da verilmiştir.

Bölüm III’de avuç içi görüntülerinin analizi ile kimlik tanımlama ve doğrulama için öznitelik verilerinin üretilmesi, veri tabanının oluşturulması üzerine yapılan bütün çalışmalar ve sonuçları ile beraber verilmiştir.

Bölüm IV’de elde edilen sonuçlar yorumlanmış ve performans değerlendirmeleri ile ilgili karşılaştırmalar ve tartışmalar yapılmıştır.


Bölüm V’de yapılan test sonuçları değerlendirilerek, ileriye dönük çalışmalar için tavsiyeler verilmiştir.

BÖLÜM II

MATERYAL VE YÖNTEMLER

II.1. ÖRÜNTÜ TANIMA SİSTEMİ

Son yıllarda bilgisayarlarında insanlar gibi örüntüleri ayırt edebilmeleri için çok miktarda çalışma yapılmıştır. Üzerinde çalışılan örüntülerden bazıları karakterler, semboller, resimler, ses dalgaları, elektrokardiyogramlardır. Genellikle karmaşık hesaplamalardan dolayı yorumlanması zor veya değerlendirmelerde insana aşırı yük getiren problemler bilgisayarlı tanımda kullanılmaktadır. Örüntü tanımının en basit yolu şablon eşlemedir. Bu durumda her bir örüntü sınıfı için bir şablon olmak üzere şablonlar kümesi veri tabanı şeklinde bellekte saklanır. Bilinmeyen sınıf her sınıfın şablonu ile karşılaştırılır. Sınıflama daha önceden belirlemiş bir eşleme kriterine veya benzerlik kriterine göre yapılır. Örüntünün tamamını şablonlarla karşılaştırmak yerine bazı özellikleri karşılaştırmak daha hızlı ve çoğu zaman da daha doğru sonuç vermektedir. Bu sebepten ki örüntü tanıma işlemi iki ayrı safhada incelenmektedir. Özellik çıkarma ve sınıflamadır [9].



Şekil II.1: Örüntü Tanıma Sistemi [5]

Şekil II.1'deki özellik çıkarma örüntü üzerinde bazı ölçümler yaparak sonuçlarını bir özellik vektörü haline getirmektir. Bu özellik problemin yapısına göre oldukça farklılık gösterebilir. Ayrıca özelliklerin birbirine göre önem dereceleri ve maliyetleri de farklı olabilir. Bu sebeple özelliklerin sınıfları birbirinden iyi ayırt edecek ve elde edilmiş maliyetleri düşük olacak şekilde seçilmesi gerekmektedir. Özellikler her örüntü tanıma problemi için farklıdır [5].

Sınıflama aşamasında çıkarılan özelliklere dayanarak verilen objenin hangi sınıfa ait olduğuna karar verilir. Özellik çıkarma örüntü tanıma problemine göre farklılık göstermesine rağmen sınıflayıcılar belirli kategorilerde toplanmıştır [5].

Örüntü tanıma görüntü örneklerinin yorumlanması veya tanınmasıyla ilgilenir. Görüntü hakkında bilgi edinerek sınıflama işlemini gerçekleştirmeyi amaçlar. İki büyük sınıflama tekniği; Şablon eşleştirme ve özellik çıkarmadır [10].

Şablon eşleme en yaygın sınıflama yöntemidir. Bu yöntemde görüntünün her pikseli özellik olarak kullanılır. Sınıflama giriş görüntüsünün tüm sınıf şablonlarının karşılaştırılmasıyla yapılır. Karşılaştırma sonucunda giriş bilgisi ile şablon arasındaki benzerlik ölçüsü ortaya çıkar. Şablon ile giriş görüntüsünün piksel bazında eşitliği benzerlik derecesini artırır, birbirine denk düşen piksellerdeki farklılığı ise benzerliği azaltır. Tüm şablonlar karşılaştırıldıktan sonra en çok benzerlik derecesi veren şablonun sınıfı seçilir. Yapısal sınıflama teknikleri örüntüyü sınıflayabilmek için yapısal özellikleri ve karar verme kuralları kullanmaktadır. Örneğin; karakterlerdeki çizgi türleri, delikler ve eğimler yapısal özelliklerindedir. Çıkarılan bu özellikler kullanılarak kural tabanlı sınıflama yapılır. Birçok örüntü tanıma sistemi hatalı sınıflamayı azaltmak için matematiksel temellere dayanmaktadır. Bu sistemler piksel tabanlı olup yapısal özellikleri kullanır. Bunlara örnek olarak Gabor özellikleri, kontur özellikleri, gradyan özellikleri ve histogramlar verilebilir. Sınıflayıcı olarak da diskriminant fonksiyonu sınıflayıcıları, bayesian sınıflayıcılar ve yapay sinir ağlarını içeren sınıflayıcılar kullanılabilir [11].

II.1.1. Avuç İçi Tanıma Sisteminin Performansının Belirlenmesi

Avuç içi tanıma sisteminin performansı için üç önemli performans ölçümü yapılır. Doğru tanıma, yanlış tanıma ve reddetme performansdır. Doğru tanıma performansı veri tabanı içerisindeki kişilere ait giriş resminin sistem tarafından doğru bir şekilde tanınmasıdır. Girişteki resmin veri tabanı içerisindekilerden farklı olması yani aynı kişiye ait farklı bir avuç içi görüntüsü gerekmektedir. Yanlış tanıma performansı veri tabanı içerisindeki kişilere ait giriş resminin sistem tarafından hatalı bir şekilde tanınmasıdır. Girişteki resmin veri tabanı içerisindekilerden farklı olması gerekmektedir. Reddetme performansı veri tabanı içerisinde olmayan kişilerin giriş verilen resimlerinin tanıma sistemi tarafından bu resmin veri tabanı içerisindeki bir kişiye ait olup olmadığının belirlenmesi ile ölçülür. Doğru bir şekilde tanınan kişilerin yüzdesi, yanlış tanınan kişilerin yüzdesi, ret edilen kişilerin yüzdesi, yüzdelik olarak belirtildiğinde doğru tanıma, yanlış tanıma ve reddetme oranlarının toplamı 100'e eşittir. Dolayısıyla tanıma sisteminin performansını belirtirken iki tanesinin değerlerini vermek yeterlidir [12].

Algoritmaların çoğunda yanlış tanıma yüzdesiyle geri çevirme yüzdesi arasında bir değişim vardır. Örneğin; eğer sistemin %0 gibi bir oranda yanlış tanıma yapması istenirse geri çevirme oranı yükselebilir. Geri çevirme oranı düşürülebilir ama bu da yanlış tanıma oranını artırır. Yukarıdaki tanımlara dayanarak otomatikleştirilmiş avuç içi tanımlamada şöyle belirtilebilir. Avuç içi görüntüleri veri tabanına verildiğinde giriş resminin veri tabanında bulunan bir kişiye ait olup olmadığına karar vermesi ve eğer bu resim veri tabanına aitse sistemin giriş resminin kimliğini belirlemesi şeklinde tanımlanabilir [12].

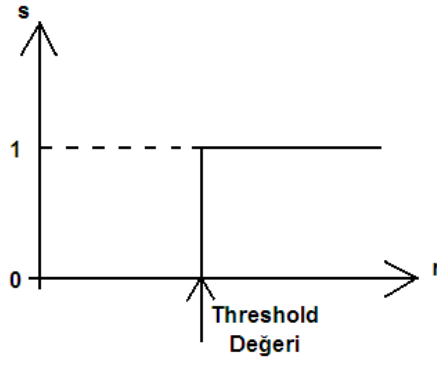
II.2. GÖRÜNTÜ İŞLEME TEKNİKLERİ

II.2.1. Normalleştirme

Görüntünün işlemeye tabi tutmadan önceki yapılan süreçlerdir. Bu ön işlem mümkün olduğunca kısa tutulmalıdır. Çünkü normalleştirmedeki amaç, kaba bilgiler için kullanılacak algoritmanın cevabı ve davranışını incelemektir. Tarayıcıdan alınan resimlerin boyutları, çözünürlükleri birbirinden farklıdır. Tarayıcıdan alınan renkli görüntüler gri seviyeye çevrilir. Genellikle bu resimlerin boyutları büyük olmakta ve bu halleri ile resim işlemeye tabi tutulursa yapay sinir ağında öğrenme ve test aşamalarının uzun zaman alması anlamına gelmektedir. Nitekim bu kadar büyük ebatlar kullanılması işlem sürecini arttırmakta ve performansı ise düşürmektedir. Bu yüzden tarayıcıdan alınan resimleri belirli bir standarda indirgemek gerekir. Bu saptama sonucunda proje uygulamamız görüntülerin piksel sayısı 128x128 olarak belirlenmiştir.

II.2.2. Eşikleme


Görüntü işlemede kullanılan temel tekniklerden birisidir. Sayısal bir görüntünün eşikleme işlemine tutulmasındaki amaç, görüntünün özelliklerini belirlemede kolaylık sağlamaktır. Değişik gri ton seviyelerine sahip bir resmi binary hale yani siyah ve beyaz renkte göstermek üzere görüntü iki renkle ifade edilebilir biçime getirilir. Görüntüyü eşikleme işlemine tabi tutmadan önce bir eşik değeri saptanır. Şekil II.1'deki gibi bir eşik değeri seçilerek yapılabilir. Eşik değerinden daha yüksek gri seviye değerine sahip olan piksellere 1 değeri daha küçük değerlere sahip olan piksellere ise 0 değeri ataması yapılarak, görüntü daha basit bir biçime siyah ve beyaza getirilmiş olur. Şekil II.3'de bir görüntünün, eşikleme işleminden önceki (sol resim) ve sonraki durumu (sağ resim) görülmektedir [13].



Şekil II.2: Eşik Değeri [13]

$$r \geq th \Rightarrow s = 1 \quad (\text{II.1.a})$$


$$r < th \Rightarrow s = 0 \quad (\text{II.1.b})$$



Şekil II.3: Eşikleme Öncesi ve Sonrası Görüntüleri [13]

II.2.2. Histogram


Görüntünün içerdiği piksel değerlerinin ağırlığını belirten grafiksel bir gösterimdir. Histogramlarda konum bilgisi bulunmaz, sadece frekans bilgisi bulunur. Gri seviyedeki (0-255) bir resme ilgili bir değer seçilerek maskeleye yapmak mümkündür. Şekilde bir resmin gri seviye histogramı gösterilmektedir [14].



Şekil II.4: Görüntünün Histogramı [15]

II.2.2.1. Histogram Eşitleme

Histogram gri seviyede belirli bölgelerde yığılma olan görüntülerde kullanışlıdır. Bu tarz görüntüleri karşılıklı azdır ve histogram eşitleme sonrası daha iyi işlenebilir hale gelebilir. Aşağıdaki şekillerden de görülebileceği gibi, histogram eşitlemede amaç, renklerin frekanslarının histogram üzerinde bir yerde yığılmadan, düzgün dağılmasını sağlamaktır [15].



Şekil II.5: Histogramu Eşitlenmiş Avuç İçi Görüntüsü [15]

Şekil II.5'deki sol görüntü gri seviyede 61-142 arasında değer aralığında iken histogram eşitleme sonrası sağ görüntüdeki gri seviyede 0-255 arası değerler almıştır.

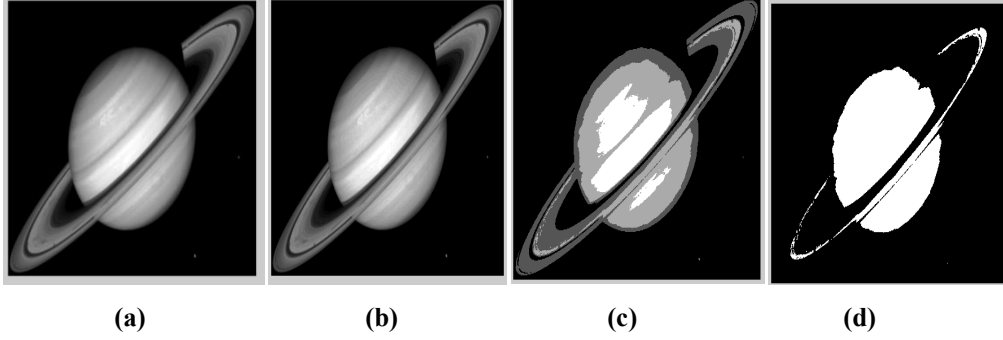
II.2.3. Renk Kavramı

Renk, ışığın değişik dalga boylarının gözün retinasına ulaşması ile ortaya çıkan bir algılamadır. İnsan tarafından renklerin algılanması ışığın cisimler tarafından yansıtılışına ve öznenin göz yardımıyla beyne iletilmesi sayesinde gerçekleşir. Bu algılama ışığın maddeler üzerine çarpması ve kısmen soğurulup kısmen yansması nedeniyle çeşitlilik gösterir ki bunlar renk tonu veya renk olarak adlandırılmaktadır. Tüm dalga boyları birden aynı anda göze ulaşırsa beyaz, hiç ışık ulaşmazsa siyah olarak algılanmaktadır [16].

Renkli görüntüler bilgisayar ekranlarında 24 bitlik veri olarak görüntülenir. Görüntüleme kırmızı, yeşil, mavi kodlanmış aynı objeye ait üç adet gri düzeyli görüntünün üst üste ekrana iletilmesi ile oluşur. Elektromanyetik spektrumda 0,4-0,5 mm dalga boyu mavi renge; 0,5-0,6 mm dalga boyu yeşil renge; 0,6-0,7 mm dalga boyu kırmızı renge karşılık gelir. Bu dalga boylarında elde edilmiş üç adet 8 bitlik görüntü bilgisayar ekranında sırası ile kırmızı-yeşil-mavi kombinasyonunda üst üste düşürülecek olursa renkli görüntü elde edilmiş olur [17].

Gri tonlu görüntülerde; görüntü farklı gri ton değerlerinden oluşur. Gri değer aralıkları: $G=\{0,1,2,\dots,255\}$ şeklinde ifade edilir. Bunun anlamı şudur: Bir gri tonlu görüntüde 256 tane farklı gri ton değeri daha doğrusu farklı gri değer bulunabilir.

Burada 256 gri deęer bir byte olarak tanımlanabilir, 1 byte=8 bit ve $2^8=256$ 'ya karşılık gelir. 0 gri deęeri kural olarak siyah renge, 255 gri deęeri ise beyaza karşılık gelir. Bu deęerler arasında ise gri tonlar oluşur.




Şekil II.6: Farklı Gri Seviye Görüntüleri [15]

Şekil II.6'da (d) 1 bit gri seviye, (c) 2 bit gri seviye, (b) 5 bit gri seviye, (a) 8 bit gri seviye görüntüleridir.

II.2.3. Geometrik Dönüşüm

İşlenmemiş görüntüler genellikle geometrik bozulmaları içerir. Görüntülerin geometrik olarak düzeltilmeleri sonucunda bozulmalar giderilerek görüntü koordinatları x,y ve nesne uzay koordinatları x,y,z arasında analitik bir ilişki kurulur. Görüntünün yeniden örneklenmesi belirlenmiş bir sistemde görüntünün tanımlanmasıdır. Tanımlama için görüntü ve sistemdeki ortak özellikler kullanılır. Bu özellikler kontrol noktaları olarak adlandırılır. Kontrol noktaları saptanırken görüntüde belirgin obje veya obje grupları kullanılmalıdır. Geometrik dönüşümde kullanılan kontrol noktalarında aranan temel özellik; kolayca belirlenebilmeleri ve yüksek konum doğruluğuna sahip olmalarıdır. Kontrol noktalarına ilişkin bu gereksinimlerin görüntüde ve dönüşümü yapılacak referans sistemde sağlanması gerekmektedir. Küçük objeler yüksek bir doğrulukla kontrol noktası olarak belirlenebilir fakat bu tür objelerin her iki sistemde eşlenmesi kimi zaman güç olabilir. Örneğin bir görüntünün bir harita ile karşılaştırılması durumunda; haritadaki bir noktanın görüntüdeki karşılığının bulunması görüntünün elverdiği çözünürlüğe bağlıdır. Büyük objeler daha kolay tanımlanabilir. Kontrol noktaları belirlenirken objeler arasındaki kontrast gri seviye farklılıkları veya zıtlıkları önemli rol oynar. Kontrol noktaları dönüşümün geometrik duyarlılığını doğrudan belirler. Küçük ölçekli haritalardan işaretlenen kontrol noktalarının duyarlılığı uygulamada yeterli değildir. Doğru kontrol noktası belirlemede önemli bir konu noktanın harita ve görüntüde

eşlenik olmasıdır. Kontrol noktası belirlenirken harita ve görüntü arasındaki zamansal ve fiziksel farklılıklar göz önünde bulundurulmalıdır [18].



Şekil II.7: Geometrik Dönüşüm [18]

Şekil II.7 göz önünde bulundurulduğunda en yakın komşuluk yönteminde (i,j) pikselinin çevresindeki 4 pikselden en yakın olanının yansıma değeri (i',j') pikselinin yansıma değeri olarak atanır. Çift yönlü doğrusal enterpolasyon (i,j) pikseline en yakın dört pikselin bu piksele olan ağırlıklı uzaklıkları esas alınarak yeni parlaklık değeri hesaplanır.

II.2.4. Kenar Belirleme

Kenar belirleme yöntemlerine geçmeden önce bu yöntemlerde anahtar rolü üstlenen maskelerden bahsedelim. Dijital resimde gri düzeyin devamlılığının üç temel unsur noktaları, satırları ve kenarları belirlemek için birçok teknik kullanılmaktadır. Bu geçişleri bulmak için resim üzerinden maske geçirilerek yapılır. Şekil II.8'de görüldüğü gibi maskeler genellikle 3x3'lük bir matristir [19].

$$\begin{bmatrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{bmatrix}$$

Şekil II.8: 3x3'lük Genel Bir Maske Matrisi [19]


Maske tarafından resimde gezdirilen ayrı ayrı pikseller üzerindeki gri düzeyin içerdiği katsayıların birbirleri ile olan çarpımının toplamsalıdır. Genel olarak matrisin tam orta noktası, maskenin her nokta için yanıtına karşılık gelen yer olarak tanımlanır. Bu maskenin resimdeki her nokta için yanıtı;

$$R = W_1 Z_1 + W_2 Z_2 + W_3 Z_3 + K + W_n Z_n$$

$$R = \sum_{i=1}^n W_i Z_i \quad (\text{II.2})$$

Kenar Bulma, uygulanarak renk geçişlerinin keskinleştirildiği, bu sayede resmin içindeki objelerin ya da farklılıkların elde edilmesinin kolaylaştırıldığı yaklaşımdır. Bunun dışında farklı görüntü işleme yöntemlerini uygun şekilde kullanarak en başarılı sonuca ulaşan modern bir yaklaşım olarak da tanımlanabilir. Kenar belirlenmesi resimleri anlamada çok önemlidir çünkü resimlerin anlamlı özelliklerini barındırırlar ve bu özelliklerin, bilgilerin ortaya çıkmasını sağlarlar. Kenarlar genellikle nesnelerin sınırlarına ve gölge geçişlerine uyarlanır [19].

Kenar, bir pikselin bir bölgesinin ve yakın komşularının özelliğidir. Ayrıca büyüklüğü ve yönü veren bir vektördür. Çok açık renkli resimler, kenar hesaplamalarında kullanılır ve resmin Gradient fonksiyonu kenarları hesaplar. Kenar belirleme gri rengin geçişlerini anlamlı bir şekilde ölçmemize yarar [20].



Şekil II.9: Gri Seviye Görüntü Üzerinde Yatay Çizgi Eğrisi [20]

Şekil II.9'da en ideal kenarın özelliği gri seviyede sol görüntü, gri seviyede sağ görüntü ise ideal olmayan olarak gösterilmiştir. Renk geçişlerinde bulanıklaşma vardır, soldaki gibi direk ve keskin olmaz. Sağda gösterilen rampalı kenar modelinde, kenarın eğimi kenardaki bulanıklaştırmanın derecesi ile ilgilidir.

II.2.5. Morfolojik Görüntü İşleme

Biyolojinin, canlıların şekil ve yapıları ile ilgilenen dalına morfoloji veya biçim bilimi adı verilmektedir. Matematiksel morfoloji ise temel küme işlemlerine


dayanan, imgedeki sınırlar, iskelet gibi yapıların tanımlanması ve çıkartılması, gürültü giderimi, bölütleme gibi uygulamalar için gerekli bir araçtır. İmge işlemede genellikle, morfolojik süzgeçleme, inceltme, budama gibi ön veya son işlem olarak da sıkça kullanılırlar. Matematiksel morfoloji, imgenin şekilsel yapısına dayanan kümeler teorisine üzerine kurulmuş bir yaklaşımdır. Bu metodun temelinde iki morfolojik operatör olan aşınma ve genişleme yatmaktadır. Dijital sinyaller için aşınma işlemi, bir Minkowski küme çıkarma işlemi, genişleme işlemi ise Minkowski küme toplama işlemidir. Aşınma işlemi kümeler cebirinde kesişim işlemine, genişleme işlemi ise kümeler cebirinde birleşim işlemine denk düşmektedir [21].

Genleşme İşlemi ikili imgedeki nesneyi büyütme ya da kalınlaştırmaya yarayan morfolojik işlemidir. Sayısal bir imgeyi genişletmek imgeyi yapısal elemanla kesiştiği bölümler kadar büyütme işlemidir. İşlenecek imgenin her bir pikseli, yapısal elemanın merkez noktasına oturtularak genişleme işlemi yapılmaktadır. Kalınlaştırma işleminin nasıl yapılacağını yapısal eleman belirler. Genleşme işlemi uygulanmış bir imgede, imge içerisindeki deliklerin ve boşlukların doldurulması ve köşe noktasının yumuşaması gözlenir [21].

Aşınma işlemi ikili imgedeki nesneyi küçültme ya da inceltmeye yarayan morfolojik işlemidir. Aşınma işlemi tam anlamıyla olmasa da bir bakıma genişleme işleminin tersi gibidir. İmge içerisindeki nesnelere ufalır, delik varsa genişler, bağlı nesnelere ayrılma eğilimi gösterir [21].


Açma İşlemi imge üzerinde aşınma işleminin hemen ardından genişleme işleminin uygulanması sonucu açma işlemi elde edilir. İmge içerisindeki nesnelere ve nesnelere arasındaki boşluklar yapısal elemanın büyüklüğüne göre temizlenir. İmge üzerinde kalan nesnelere orijinal imgedeki şekillerinden biraz daha küçük hale gelir. Açma işlemi ile birbirine yakın iki nesne imgede fazla değişime sebebiyet vermeden ayrılmış olurlar [21].

Kapama İşlemi imge üzerinde genişleme işleminin hemen ardından aşınma işleminin uygulanması sonucu kapama işlemi elde edilir. Dolayısıyla birbirine yakın iki nesne imgede fazla değişiklik yapılmadan birbirine bağlanmış olur. Kapama işlemi sonunda imge içerisindeki noktalar birbirlerini kapatırlar, imgedeki ana hatlar daha da dolgunlaşır. Genleşme işlemine benzer bir şekilde kapama işleminde de birbirine yakın olan noktalar arasındaki boşluklar dolar ve noktalar birleşir [21].



Şekil II.10: Morfolojik Aşınma ve Genleşme [60]

Şekil II.10'da sol görüntüde siyah-beyaz herhangi bir görüntünün matris formunda aşındırılması işlemi gerçekleştirilmiş, sağ görüntüde siyah-beyaz herhangi bir görüntünün matris formunda genişletilmesi işlemi sonrası görüntüleri verilmiştir.



Şekil II.11: Morfolojik Açılış ve Kapanış [60]

Şekil II.11'de sol görüntüde siyah-beyaz herhangi bir görüntünün matris formunda açılması işlemi gerçekleştirilmiş, sağ görüntüde siyah-beyaz herhangi bir görüntünün matris formunda kapatılması işlemi sonrası görüntüleri verilmiştir.

Morfolojik operasyonlar ikili imgelere uygulanabileceği gibi, gri tonlu imgeler için de tanımlıdır. Gri tonlu imgede yayma işlemi, imgedeki koyu tonlu bölgeleri açmaktadır. İmgede koyu tonlu bölgelerle çevrili parlak bölgeler genişlerken, parlak bölgelerle çevrili koyu tonlu bölgeler zayıflamakta, hatta yapı elemanı ve koyu tonlu bölgenin boyutuna bağlı olarak kaybolabilmektedir. Gri tonlu imgede aşındırma işlemi, imgenin parlaklığını artırmaktadır. İmgede koyu tonlu bölgelerle çevrili parlak bölgeler daralırken, parlak bölgelerle çevrili koyu tonlu bölgeler genişlemektedir [22].

II.3. DALGACIKLAR TEORİSİ

II.3.1. Fourier Dönüşümü

Fourier Dönüşümü Fransız matematikçi Joseph Fourier tarafından bulunmuş matematiksel bir yöntemdir. Bu dönüşüm sürekli olarak tanımlanır ve fonksiyonların sürekli olarak kabul edildiği durumlarda uygulanır. Birçok branşta örneklenmiş sinyalleri dönüştürmek için kullanılmaya başlanmıştır. Fourier dönüşümünün

kullanımı ile zaman tanım kümesindeki bir işaretin frekans içeriğini analiz etmede büyük yarar sağlamasıdır. Dönüşüm, ilk olarak tanım kümesi zaman olan bir fonksiyonu, tanım kümesi frekans olan bir fonksiyona çevirerek çalışır. O zaman sinyalin frekans içeriğini inceler. Çünkü dönüştürülen fonksiyonun Fourier katsayıları, her frekans değerinde sinüs ve kosinüs fonksiyonlarının her birinin katkısını temsil eder. Ters Fourier dönüşümü de, verinin frekans tanım kümesinden zaman tanım kümesine dönüştürülmesini gerçekleştirir [23]. Fourier, periyodu 2π olan herhangi bir $f(x)$ fonksiyonu, o fonksiyonun Fourier serisi;

$$f(x) = a_0 + \sum_{k=1}^{\infty} (a_k \cos kx + b_k \sin kx) \quad (\text{II.3})$$

Denlem II.3'deki toplam ile temsil edilebilir. Buradaki a_0 , a_k , b_k katsayıları denklemler II.4'deki formüller ile hesaplanır.

$$a_0 = \frac{1}{2\pi} \int_0^{2\pi} f(x) dx \quad (\text{II.4.a})$$

$$a_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \cos(kx) dx \quad (\text{II.4.b})$$

$$b_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \sin(kx) dx \quad (\text{II.4.c})$$

II.3.2. Dalgacık Dönüşümü

1950'li yılların sonlarına kadar resim işlemede Fourier dönüşümleri başlıca dayanak olmasına rağmen dalgacık dönüşümleri resim işlemeyi yani sıkıştırma, genişletme ve analizleri daha da kolaylaştırdı. Fourier dönüşümlerinin basit fonksiyonları sinüs ve kosinüs iken dalgacık dönüşümü değişken sıklıkta ve limitli süredeki küçük dalgalara dayanmaktadır. Bu küçük dalgalara dalgacık denilmektedir. Geleneksel Fourier dönüşümlerinde bilgi fazlalığı sağlamasının yanında, dönüşüm işlemlerinde geçici bilgiler kaybolmaktadır. Dalgacık serileri birçok farklı alana uygulanabilen bir yöntem olup, bunlar arasında uygulamalı matematik, sinyal işleme teknikleri, ses ve görüntü sıkıştırma teknikleri başta gelmektedir. Dalgacıklar ilk

olarak Jean Morlet ve A. Grossman tarafından coğrafi bilgi sistemleri için kullanılmaya başlanmıştır. Gerçekte, dalgacıkların temel başlangıcı Joseph Fourier'e ve onun Fourier dönüşümüne kadar gitmektedir. 1807'den sonra Fourier denklemlerinin ortaya çıkmasıyla matematikçiler sinyali tanıma için frekans alanında çalışmaya yöneldiler. Dalgacıklar ilk olarak "Haar Dalgacık" olarak adlandırılan Haar'ın tezinde görülmüştür. Haar dalgacıklar bazı sınırlı uygulamalar için geçerli olup, bilinen en basit ve en eski dalgacık fonksiyonudur [20].


1977'lerde Esteban ve Galand yeni bir süzgeç kavramını ortaya attı ancak bu yolla ana sinyalin yeniden elde edilmesinde hata çok yüksekti. Dalgacık terimi ilk kez 1984'de Morlet ve Grossman tarafından kuantum fiziği çalışmalarında kullanıldı. 1987'de Mallat dalgacık ve süzgeç grupları arasındaki ilişkiyi ortaya çıkardı. Meyer kendi adıyla anılan ilk dalgacıkları ortaya attı. Bu Haar dalgacıkların aksine, sürekli uygulamalarda kullanılabilen bir fonksiyon idi. Yıllar geçtikçe, Ingrid Daubechies bir takım dik tabanlı dalgacık serilerini ortaya atarak günümüzdeki birçok uygulamaya temel teşkil etmiştir. Tanım olarak, bir dalgacık, ortalama değeri sıfır olan ve zamanla sınırlı bir dalga şeklindedir. Zaman ekseninde kaydırma ve ölçekleme parametreleri dalgacıkların temelini oluşturmaktadır [24].

Çoklu çözünürlüklü resimlerin analiz etmek için en önemli resim tekniklerinden ikisi resim piramidi ve subband kodlamadır [25].

Resim piramidi, orijinal olarak makine görüşü ve resim sıkıştırma uygulamaları için tasarlanmıştır. Azalan çözünürlükteki resimlerin toplamı piramidin şeklinin içinde dizilmesine resim piramidi denir. Piramidin en altında yüksek çözünürlüklü işlenecek resim vardır, tepe de ise düşük çözünürlüklü resim vardır. Piramitte yukarı çıkıldığında hem boyut hem de çözünürlük azalmaktadır. En alttaki resim orijinal resimdir. Girilen resmin düşük çözünürlüklü yaklaşımları hesaplanır. İnterpolasyon filtresi uygulanarak girilen resmi ne kadar doğrulukla tahmin edildiği belirlenir. Genel olarak piramidin düşük çözünürlük düzeyleri bütün bir resmin analizini etmek için kullanılabilir [20].

Subband kodlama da resimler ufak parçalara ayrılabilir, bu ufak parçalara subband denir. Daha sonra bu subbandlar birleşerek yeniden resmi hatasız oluşturabilir. Konuşma ve resim sıkıştırma için geliştirilmiştir. Her resim alçak geçiren filtreden geçirilerek subbandlar üretilir. Sonuçlanmış subbandların bant genişliği orijinal resimden ufaktır. Subbandlar bilgi kaybı olmadan downsampled işlemi yapılabilir. Bu işlem, resim boyutunu küçültmek için resimdeki piksellerin

kaldırılmasıdır. Upsampling, filtreleme işlemleri ve subbandların başlı başına toplanması ile orijinal resmin yeniden yapımı tamamlanır. Upsampling işlemi; dijital resmi büyötmek için resme piksellerin eklenmesidir [20].

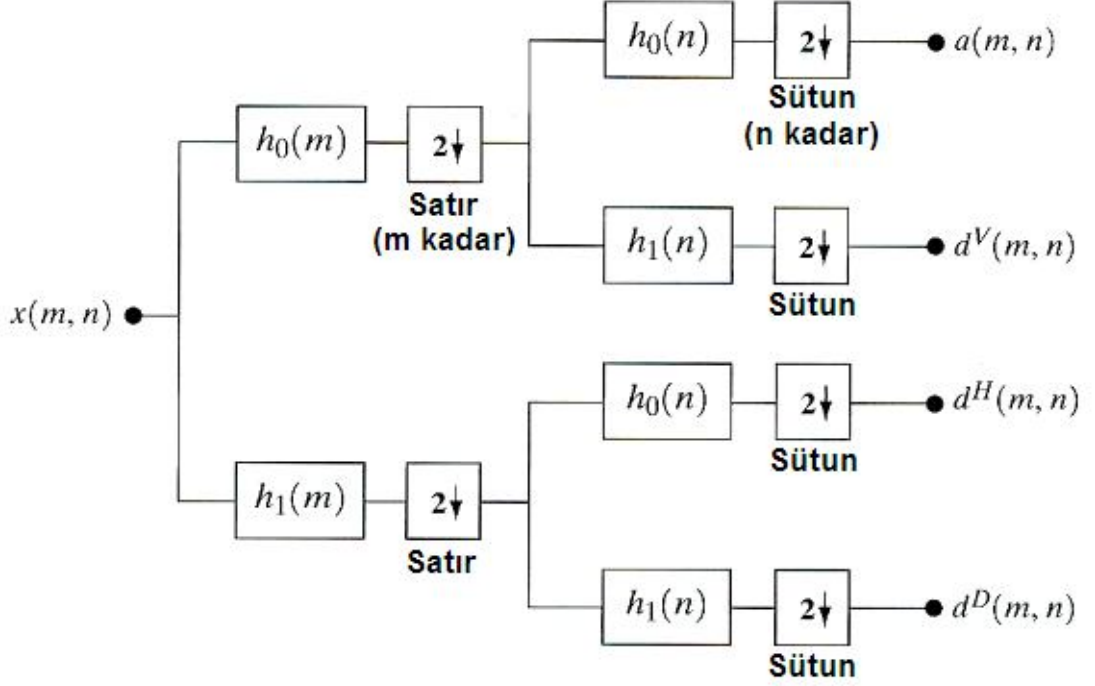


Şekil II.12: Bir Boyutlu Subband Kodlama için İki Bantlı Filtre Bankası [20]

Şekil II.12’de bahsedilen banka, veri bankası olarak düşünölmektedir. Veri bankası, bilgisayarca düzenlenen, işlenen, belleğe aktarılan, uzaktan ve çevrimiçi sorgulamaya elverişli bilgi kümesidir. Burada bilgi kümesi olarak da yapılan filtreleme ve işlemlerdir. $x(n)$ ayrık zaman sinylidir. $\hat{x}(n)$, n çıkış dizisidir. $x(n)$; $h_0(n)$ ve $h_1(n)$ analiz filtrelemeleri ile ayrıştırılır, $g_0(n)$ ve $g_1(n)$ sentez filtrelemeleri kullanarak oluşturulur. $h_0(n)$ ve $h_1(n)$ geçiş karakterlerini idealleştiren yarım bant dijital filtreleridir. $h_0(n)$, $x(n)$ 'nin bir tahmini düşük frekans geçirme filtresidir. $h_1(n)$ ise $x(n)$ 'nin yüksek frekans geçirme filtresidir. Bütün filtrelemeler, darbe cevapları ile her filtrelemenin girişı zaman alanında gerçekleşir. h_0 , h_1 , g_0 , g_1 seçersek giriş tekrardan oluşturulabilir. Bu yüzden çıkış ile giriş birbirine eşittir [20].

$$\hat{x}(n) = x(n) \quad (\text{II.5})$$

Resimleri işlemek bir boyutlu filtreler iki boyutlu ayrılabilir filtreler olarak kullanılabilir. Şekil II.13’de ayrılabilir filtreler ilk olarak bir boyut (dikey) üzerinde uygulanır ve sonra diğer boyutta (yatay) uygulanır. İkinci filtrelemeyi yapmadan önce genel hesaplama sayısı azaltılır yani işlem sayısı azaltılır. Elde edilen filtrelenmiş çıkışlar $a(m,n)$, $d^V(m,n)$, $d^H(m,n)$, $d^D(m,n)$ bunlar sırasıyla resimdeki "subband"ların yaklaşımı, dikey detayları, yatay detayları ve diyagonal (köşegen) detaylar olarak adlandırılırlar. Bir veya daha fazla subbands, daha küçük dört subbandlara, onlarda daha küçük subbandlara ayrılabilir [20].



Şekil II.13: İki Boyutlu Subband için Dört Bantlı Filtre Bankası [20]

II.3.3. Haar Dalgacık Dönüşümü

Haar dönüşümlerinin temel fonksiyonlar en eski ve en basit bilinen dikey (ortogonal) dalgacıklardır. Haar dönüşümlerini hem ayrılabilir hem de simetriktir. Matris olarak gösterimi; $T = HFH^T$ böyledir. F bir $N \times N$ matrisi, H bir $N \times N$ dönüşüm matrisidir ve T bir sonuç $N \times N$ dönüşüm matrisidir. Haar dönüşümü için, dönüşüm matrisi olan H, Haar'ın temel fonksiyonlarını içerir. Fonksiyonlar, $k=0,1,2,\dots,N-1$ ve $N=2^n$ için $z \in [0,1]$ aralığı üzerinde belirtilir. H'ı üretmek için k tamsayı tanımlanır ve $k = 2^p + q - 1$, $0 \leq p \leq n-1$, $p=0$ için $q = 0$ veya 1 ve $p \neq 0$ için $1 \leq q \leq 2^p$ olmaktadır. Daha sonra Haar'ın temel fonksiyonları denklem II.6 ve II.7'dir [26];

$$h_0(z) = h_{00}(z) = \frac{1}{\sqrt{N}}, \quad z \in [0,1] \quad (\text{II.6})$$

ve

$$h_k = h_{pq} = \frac{1}{\sqrt{N}} \begin{cases} 2^{p/2} & (q-1)/2^p \leq z < (q-0.5)/2^p \\ -2^{p/2} & (q-0.5)/2^p \leq z < q/2^p \\ 0 & \text{yoksa, } z \in [0,1] \end{cases} \quad (\text{II.7})$$

$N \times N$ Haar dönüştürme matrisindeki i . satır $z = 0/N, 1/N, 2/N, \dots, (N-1)/N$ için $h_i(z)$ 'nin elemanlarını içerir.

II.3.3. Sürekli Dalgacık Dönüşümü

Bir ana dalgacık $\psi(\tau, s)$ 'si tarafından oluşturulan ortogonal temel işlevler bakımından sürekli dalgacık dönüşümü sinyallerini temsil eder. Sürekli bir zaman işareti $f(t)$ verilince dalgacık dönüşümü aşağıdaki gibi hesaplanır [12].

$$C_X(\tau, s) = \frac{1}{\sqrt{|s|}} \int f(t) \psi^* \left(\frac{t - \tau}{s} \right) dt \quad (\text{II.8})$$

τ Parametresi her bir adımda sinyal vasıtasıyla pencere fonksiyonunu kaldırmaya denk gelen dönüşüm parametresidir ve s ise dönüşüm esnasında pencere fonksiyonunun ana dalgacık ölçeğini temsil eden ölçek parametresidir [12].

II.3.4. Ayrık Dalgacık Dönüşümü

Ayrık dalgacık dönüşümü, fonksiyonların dalgacık seri açılımının kesikli düzlemdeki bir uzantısı olarak düşünülebilir. Kesikli düzlemde seri açılımda kullanılan temel fonksiyonlar ve $f(x)$ fonksiyonu; bu fonksiyonlardan elde edilen sonlu sayıda örneklenmiş noktalar ile temsil edilebilir. Bu durumda $f(x)$ kesikli fonksiyonunun ayrık dalgacık dönüşümü katsayıları denklem II.9, II.10 ve II.11'e eşit olacaktır [12].

$$W_\varphi(j_0, k) = \frac{1}{\sqrt{M}} \sum_x f(x) \varphi_{j_0, k}(x) \quad (\text{II.9})$$

$$W_\psi(j, k) = \frac{1}{\sqrt{M}} \sum_x f(x) \psi_{j, k}(x) \quad (\text{II.10})$$

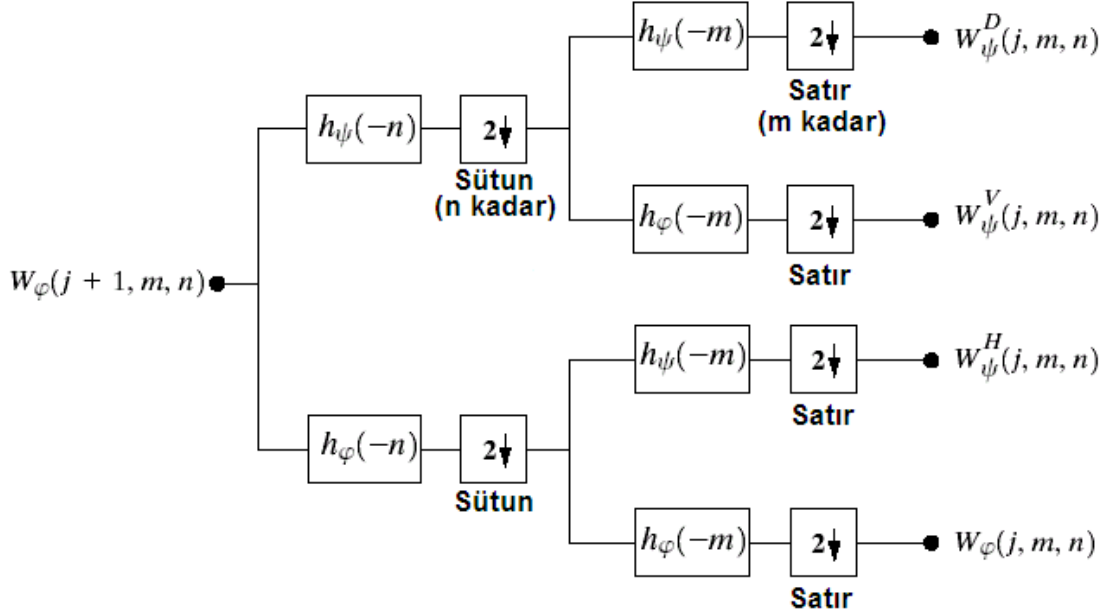
$j \geq j_0$ için;

$$f(x) = \frac{1}{\sqrt{M}} \sum_k W_\varphi(j_0, k) \varphi_{j_0, k}(x) + \frac{1}{\sqrt{M}} \sum_{j=j_0}^{\infty} \sum_k W_\psi(j, k) \psi_{j, k}(x) \quad (\text{II.11})$$

Burada $f(x)$, $\varphi_{j_0,k}(x)$ ve $\psi_{j,k}(x)$, $x = 0,1,2,\dots,M-1$ noktalarında örneklenmiş fonksiyonları göstermektedir. M sayısı genellikle $M=2^J$ şeklinde seçilir. Buradaki $W_\varphi(j_0,k)$ ve $W_\psi(j,k)$ katsayıları bir önceki seri dönüşümdeki $c_{j_0}(k)$ ve $d_j(k)$ katsayılarına karşılık gelmektedir. Yukarıdaki eşitlikler ortonormal ve sonlu büyüklükte temel fonksiyonlar için geçerlidir. Biortogonal temel fonksiyonların kullanılması durumunda φ ve ψ fonksiyonlarının eşleniklerinin kullanılması gerekir.


II.3.5. Hızlı Dalgacık Dönüşümü

Hızlı dalgacık dönüşümü ayrık dalgacık dönüşümünün verimli bir şekilde hesaplanmasını sağlar. Hızlı dalgacık dönüşümü iki bantlı subband kodlamaya benzemektedir.



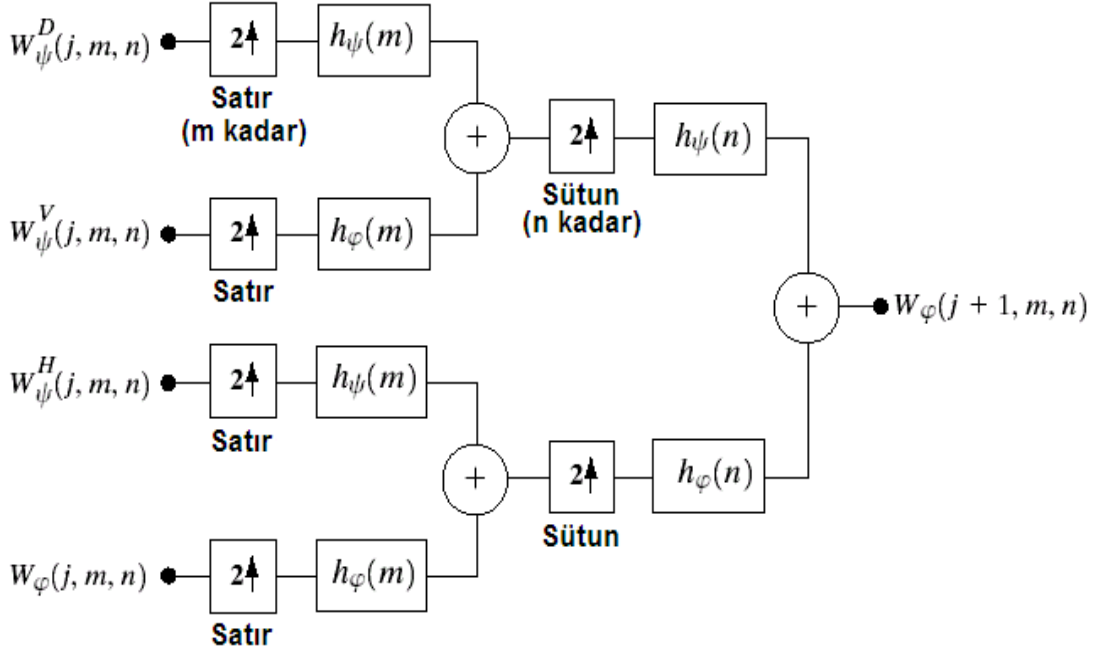
Şekil II.14: İki Boyutlu Analiz Filtreleme Bankası [20]

Şekil II.14’de üst kısmında 2 boyutlu 4 bantlık filtre bankasının yüksek çözünürlüklü bir giriş işaretine $(j+1)$ uygulanması ve sonucunda 4 tane alt bant imge elde edilmesi gösterilmektedir. En alt çıktıdan başlayarak oluşan alt bantlar şöyledir; yaklaşma (approximation) alt bandı ya da düşük ölçekte, j ölçekleme katsayısı ve bir yatay, bir dikey ve bir köşegensel detay alt bandı ya da dalgacık katsayıları; eğer $(j+1) = j_0$ ise, giriş sinyali orijinal sinyale eşittir. $2^j \times 2^j$ ’lik bir imge durumunda, maksimum $P = j$ kadar ayrıştırma derecesi elde etmek mümkündür. Bu durumda P -ölçekte ve $j-1$ (en yüksek ölçek), $j-2, \dots, j-P$ çözünürlüklerde hızlı dalgacık dönüşümü elde edilmiş olur [27].



Şekil II.15: İki Boyutlu Analiz Filtre Sonuçlarının Dağılışı [20]

Şekil II.15’de orta kısmında $P = 2$ olan bir imgenin ayrıştırılması grafiksel olarak gösterilmektedir. En sağdaki kare incelendiğinde; sol üst köşede $j-1$ çözünürlükte ölçeklenmiş imgeler bulunmaktadır, geri kalan üç komşu kareler ise ona karşılık gelen dalgacık katsayılarıdır. Bu alt bantları kullanarak j yaklaşma sinyalini geri oluşturmak mümkündür, en sonunda ise giriş olarak verilen imge, oluşan j ölçekteki yaklaşma alt bandı ve ona ait diğer detay alt bantları sağ üst, sol alt ve sağ alt kareleri kullanılarak orijinal haline geri getirilebilir [20].



Şekil II.16: İki Boyutlu Sentez Filtreleme Bankası [20]

Şekil II.16’da alt kısmında sentez bankaları tarafından yapılan yeniden düzenleme adım adım gösterilmektedir. Her tekrarda tahmin ($W_\varphi(j, m, n)$) ve ayrıntı ($W_\psi(j, m, n)$) alt imgeleri genişletilerek ve ardından biri sütunlar üzerinde, diğeri de satırlar üzerinde çalışan iki tek boyutlu filtreye konvolusyona sokulur.

Sonucun toplanması (j+1) ölçekli tahmin imgesine denk gelir ve bu işlem orijinal resim yeniden oluşturulana kadar devam ettirilir [28].

II.4. YAPAY SİNİR AĞLARI

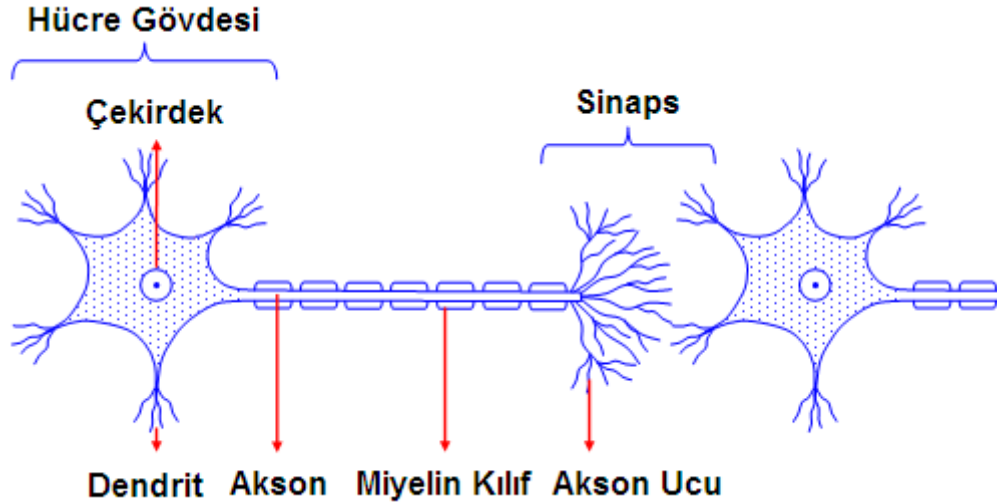
Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekleştirmek oldukça zor veya mümkün değildir. O nedenle yapay sinir ağlarının, programlanması çok zor veya mümkün olmayan olaylar için geliştirilmiş adaptif bilgi işleme ile ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir [29].

Yapay sinir ağları, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde; öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Yapay sinir ağları günümüzde birçok probleme çözüm üretebilecek yeteneğe sahiptir. Yapay sinir ağları birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmaktadır. Proses elemanları da denilen bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değeri olduğu kabul edilmektedir [29].

II.4.1. Biyolojik Sinir Hücreleri

Sinir hücresi ya da nöron sinir sisteminin temel fonksiyonel birimidir. Çeşitli biçim ve büyüklüklerde olabilir. Sinirsel uyarıları elektriksel ve kimyasal yolla iletir. Hücre gövdesi büyüktür ve çekirdek burada yer alır. Kısa uzantıları dendrit, uzun uzantıları akson olarak adlandırılan sinir sistemini oluşturan hücrelerdir. Nöron çeşitlerine göre, nöron gövdesinden çıkan uzantıların sayısı ve şekli değişiktir. Akson ve dendrit denilen uzantıları vardır. Başka hücrelerden gelen uyarılar dendritlerin uçlarından alınır ve aksonların uçlarından diğer hücrelere iletilir. Nöron gövdesinden bir dendrit, bir akson çıktıktan sonra bir araya gelerek tek bir uzantı halinde hücreden ayrılıyorsa tek kutuplu görünürler. Dendrit ve akson, nöron gövdesinin birbirine karşı gelen iki bölgesinden çıkarlırsa nöron iki uzantılıdır bu iki kutuplu nöron olarak adlandırılır. Nöron gövdesinden çok sayıda dendrit ve tek bir akson çıkıyorsa bu hücre çok kutuplu nöron adı verilir [30].


Biyolojik sinir ağlarının performansları küçümsenemeyecek kadar yüksek ve karmaşık olayları işleyebilecek yetenektedir. Biyolojik sinirler insanın bütün davranışlarını ve çevresini anlamasını sağlar. Biyolojik sinir ağları beş duyu organından gelen bilgiler ışığında geliştirdiği algılama ve anlama mekanizmalarını çalıştırarak olaylar arasındaki ilişkileri öğrenir. Yapay sinir ağları bu özelliklerden yararlanılarak geliştirilmiştir. Şekil II.17’de bir biyolojik sinir hücresinin genel yapısı verilmiştir [30].



Şekil II.17: Biyolojik Sinir Hücresinin Genel Yapısı [61]

II.4.2. Yapay Sinir Hücresi

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde proses olarak da adlandırılmaktadır. Her proses elemanının beş ana bölümü vardır.




Şekil II.18: Yapay Sinir Hücresinin Genel Yapısı [62]

Şekil II.18’de gösterilen yapay sinir hücresi temel olarak beş kısımdan oluşmaktadır. Bunlar; girişler, ağırlıklar, toplama işlemi, aktivasyon fonksiyonu ve çıkış olarak sıralanır. Yapay sinir ağlarında öğrenme işlemi girişler ile gerçekleştirilir. Dış dünyadan veya bir önceki katmandan alınan bilgiler giriş olarak yapay sinir hücrelerine gönderilir. Ağırlıklar, girişlerin yapay sinir hücreleri üzerindeki etkisini belirleyen ve öğrenme işleminin gerçekleştirilmesini sağlayan katsayılardır. Yapay sinir hücresine gelen *net* girişin hesaplanması toplama işlemi olarak adlandırılır. En yaygın kullanılan yöntem ağırlıklı toplamı bulmaktır. Ağırlıklı toplamı bulabilmek için yapay sinir hücresinin girişindeki her bir ağırlığın ait olduğu girişlerle çarpımının toplamlarına eşik değeri ilave edilir. Eşik değeri biyolojik sinir hücrelerinin yüzeylerindeki potansiyel farkının bir benzerini yapay sinir hücrelerinde elde etmek için kullanılan kat sayıdır. Çıkış işlevi sonucunun dış dünyaya veya diğer sinirlere gönderildiği yerdir. Bir sinirin bir tek çıkışı vardır. Sinirin bu çıkışı kendinden sonra gelen diğer sinirlere giriş olabilir. Yapay sinir ağları sadece sayısal giriş bilgileri ile çalışırlar. Bu nedenle giriş bilgileri genellikle ölçeklendirilir [31].


$$net = \sum_i^n x_i w_i + \phi \quad (II.12)$$

II.4.2.1. Aktivasyon Fonksiyonları


Transfer veya aktivasyon fonksiyonları, öğrenme eğrisi olarak da adlandırılmaktadır. Aktivasyon fonksiyonları bir YSA’da nöronun çıkış genliğini, istenilen değerler arasında sınırlar. Bu değerler çoğunlukla [0,1] veya [-1,1] arasındadır. Ayrıca, yapay sinir ağına bir kutuplama bias (eşik) değeri uygulanarak aktivasyon fonksiyonu artırılabilir. Yapay sinir ağlarında kullanılacak olan fonksiyonların türevi alınabilir ve süreklilik arz etmesi gerekmektedir. Yapay sinir ağının kullanım amacına uygun olarak tek ya da çift kutuplu aktivasyon fonksiyonları kullanılabilir. Lineer veya doğrusal olmayan transfer fonksiyonlarının yapay sinir ağlarında kullanılması karmaşık problemlere uygulanmasını sağlamıştır. En çok kullanılan aktivasyon fonksiyonları şekil II.19, II.20 ve II.21’de gösterilmiştir [32].



Şekil II.19: Linear Aktivasyon Fonksiyonu [32]



Şekil II.20: Sigmoid Aktivasyon Fonksiyonu [32]



Şekil II.21: Tan-Sigmoid Aktivasyon Fonksiyonu [32]


II.4.3. Yapılarına Göre Yapay Sinir Ağları

Yapay sinir ağları, genel olarak ağı yapısına göre; ileri beslemeli ve geri beslemeli olarak ikiye, öğrenme kuralına göre; Hebb, Hopfield, Delta ve Kohonen olmak üzere dörde, öğrenme algoritmasına göre; danışmanlı, danışmansız ve

takviyeli olmak üzere üçe ve uygulamaya göre de; off-line ve on-line olmak üzere ikiye ayrılabilir. Ayrıca ağırlık matrislerinin simetrik veya asimetrik oluşuna, ağırlık matrisi değerlerinin sabit veya değişken oluşuna, ağda yer alan düğümlerin özelliklerine, kullanılan aktivasyon fonksiyonlarının deterministik veya stokastik oluşuna göre de sınıflandırılabilir. İleri beslemeli ağlar genellikle örüntü tanıma problemlerinde, geri beslemeli ağlar da optimizasyon problemlerinde yaygın olarak kullanılmaktadır.

II.4.3.1. İleri Beslemeli Tek Katmanlı Ağlar

Girdi işaretlerinin ve ağırlıkların bir işlevini hesaplayıp, sonucu sonraki tüm yapay sinir hücrelerine iletir. Bu ağlar çok katmanlı ileri beslemeli ağlar olarak isimlendirilir. Şekil II.22’de ileri beslemeli tek katmanlı ağ gösterilmiştir.




Şekil II.22: İleri Beslemeli Tek Katmanlı Yapay Sinir Ağı [63]

Perceptron ilk defa Rosenblatt tarafından örüntü (şekil) sınıflandırma amacı ile geliştirilmiştir. Perceptron bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanmaktadır. Ağın çıktısı bir veya sıfırdan oluşan mantıksal değerdir. Çıktının değerinin hesaplanmasında eşik değer fonksiyonu kullanılır. Bu ağlarda proses elemanlarının değerlerinin ve dolayısıyla ağın çıktısının sıfır olmasını önleyen bir eşik değeri vardır. Tek katmanlı ağlarda çıktı fonksiyonu doğrusal fonksiyondur. Yani ağa gösterilen örnekler iki sınıf arasında paylaştırılarak iki sınıfı birbirinden ayıran doğru bulunmaya çalışılır. [33].

II.4.3.2. İleri Beslemeli Çok Katmanlı Ağlar

Bir yapay sinir ağının öğrenmesi istenen olayların girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler olursa o zaman daha önce anlatılan modeller ile öğrenme gerçekleştirmek mümkün değildir. Bu tür olayların öğrenilmesi için daha gelişmiş modellere ihtiyaç vardır. Çok katmanlı ağlar bunlardan birisidir [34].



Şekil II.23: İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları [64]

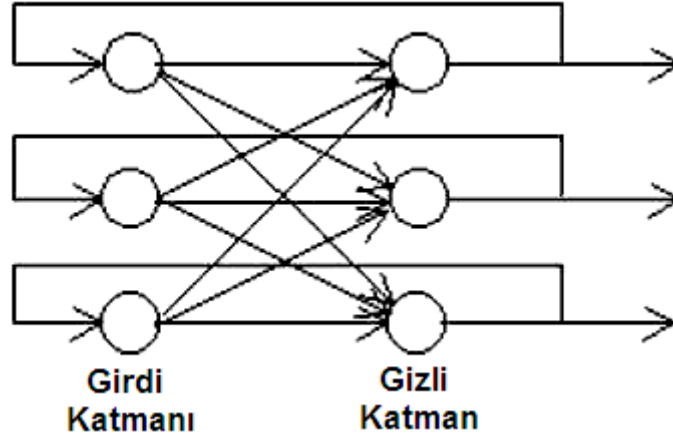
Bu ağlar üç katmandan oluşur. Girdi katmanı, dış dünyadan bilgileri alır ve bu katmanda herhangi bir bilgi işleme olmaz. Buradaki çıktı bir sonraki katmanda bulunan bütün proses elemanlarına gönderilir. Ara (gizli) katmanlar, girdi katmanından gelen bilgileri işlerler. Bir adet ara katman ile birçok problemi çözmek mümkündür. Eğer ağın öğrenmesi istenilen problemin girdi çıktı arasındaki ilişki doğrusal olmaz ve karmaşıklık artarsa birden fazla sayıda ara katman kullanılabilir. Çıktı katmanı, ara katmandan gelen bilgileri işleyerek ağa girdi katmanından sunulan girdi için ağın ürettiği çıktıyı bulur. Bu çıktı dış dünyaya iletilir [35].

Çok katmanlı ağların eğitilmesi sırasında ağın ürettiği çıktılar ile beklenen çıktılar arasındaki farkın veya hatanın ağın ağırlıklarına dağıtılarak zaman içinde bu farkın an azı indirgenmesidir. Öğrenme sırasında önce girdiler ağa sunularak bu girdilere karşılık gelen çıktılar üretilir. Bu işleme ileri doğru hesaplama denir. Daha sonra üretilen çıktı ile beklenen çıktı karşılaştırılarak aradaki hata geriye doğru dağıtılarak ağırlıklar değiştirilir. Buna da geriye doğru hesaplama denir [35].

II.4.3.3. Geri Beslemeli Ağlar

Geri beslemeli ağ mimarileri genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılmaktadır. Geri beslemeli ağlarda isimden de anlaşılacağı gibi bir tür geri besleme işlemi vardır. Hopfield ağı bu tür mimariye sahip bir yapay sinir ağıdır. Geri beslemeli yapay sinir ağlarında bir hücrenin çıktı değeri kendisine, başka bir hücreye veya giriş katmanına giriş olabilmektedir. Bağlantı çift yönlüdür. İleri beslemeli yapay sinir ağlarından farklı olarak bağlam (context) tabakası yer almaktadır. Bu tabaka gizli tabaka çıktıları ağırlıklandırılarak


tekrar gizli tabakaya girdi olarak vermektedir [36]. Şekil II. 24’de geri beslemeli yapay sinir ağı mimarisi gösterilmiştir [37].



Şekil II.24: Geri Beslemeli Yapay Sinir Ağı [37]

II.4.3.4. Yapay Sinir Ağlarında Danışmanlı Öğrenme


Danışmanlı öğrenmede giriş ve çıkış çiftlerinden oluşan eğitim bilgileri vardır. Ağ giriş bilgisine göre ürettiği çıkış değerini, istenen değerle karşılaştırarak ağırlıkların değiştirilmesinde kullanılacak bilgiyi elde eder. Girilen değerle istenilen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar eğitime devam edilir. Hata değeri istenen değer altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır. Eğer verilen giriş karşılık amaçlanan çıkış üretileniyorsa ağın çıkış değerindeki hatayı en küçükleyecek şekilde bağlantı ağırlıklarının değiştirilmesi sağlanır [38].



Şekil II.25: Danışmanlı Öğrenme Yapısı [38]

II.4.3.5. Yapay Sinir Ağlarında Danışmansız Öğrenme

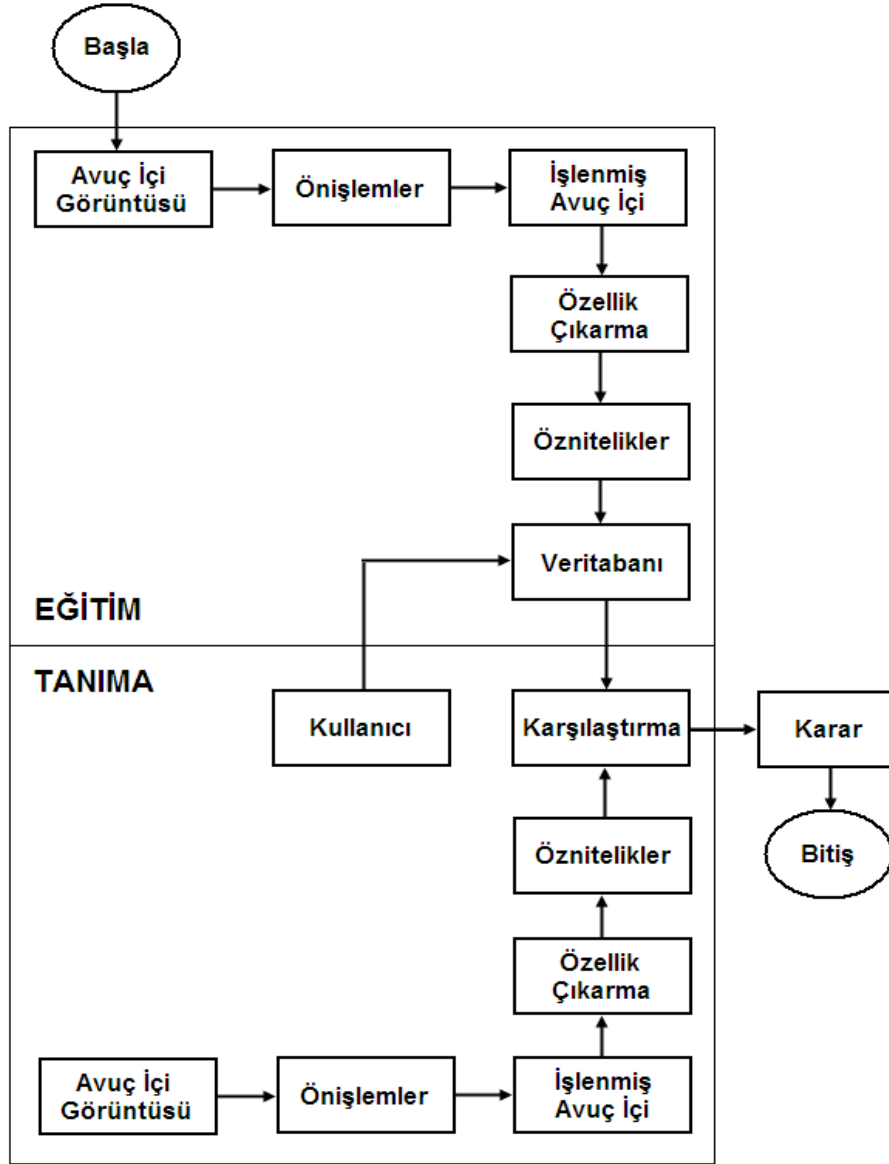
Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur ve girişlere göre kendi kendisini örnekler. Danışmansız olarak eğitilebilen ağlar istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Danışmansız öğrenmede ağ istenen dış verilerle değil girilen bilgilerle çalışır. Bu tür öğrenmede gizli sinirler dışarıdan yardım almaksızın kendilerini örgütlemek için bir yol bulmalıdırlar. Bu yaklaşımda verilen giriş vektörleri için önceden bilinebilen performansını ölçebilecek ağ için hiçbir çıkış örneği sağlanmaz veya ağ yaparak öğrenmektedir. Yani ağın eğitimini giriş vektörlerinin en yakın benzerliklerinden işe başlayarak benzer olanları gruplandırır veya sınıflandırır [39]. Şekil II.26'da danışmansız öğrenme yapısı gösterilmiştir.



Şekil II.26: Danışmansız Öğrenme Yapısı [38]


II.5. AVUÇ İÇİ TANIMA SİSTEMLERİ

Avuç içi tanıma sistemleri iki kısımdan oluşur. Şekil II.27'de birinci kısım eğitim kümesinin oluşturulması, ikinci kısım da ise tanıma işlemi gerçekleştirilmiştir. Eğitim kümesinin oluşturulması avuç içi görüntüsü okuyucuları yardımıyla avuç içi ham görüntülerinin elde edilmesiyle başlar. Avuç içi görüntülerin iyileştirilmesi, filtreleme, düzeltme ve çalışma bölgesinin çıkarılması için ön işlemlerden geçirilerek normalize edilir. Daha sonra bu görüntülere ait özellik çıkarma ve öznitelikler yani avuç içi vektörleri üretilerek veri tabanına kaydedilir. Tanıma işleminde ise tanınacak olan avuç içi görüntüsü eğitim aşamasında olduğu gibi aynı işlemlerden sırayla geçirilir. Bu avuç içi görüntüsüne ait vektörler üretilerek veri tabanındaki avuç içi vektörleri ile karşılaştırılır. Belirlenen eşik değeri doğrultusunda tanıma işlemi gerçekleştirilir [52].



Şekil II.27: Avuç İçi Tanıma ve Eğitim Aşamaları Blok Şeması [52]

Avuç izi görüntüsü elde etmek için yarı kapalı bir ortam oluşturmak amacıyla bir mahfaza içinde ve görüntü alınırken ışık koşullarının değişmemesini sağlayacak bir halka kullanılmaktadır. Platform üzerinde kontrol noktası veya elin istenen şekilde yerleşmesi için parmak arasına gelecek bir takoz olabilir. Analog dijital dönüştürücü ve kamera ile alınmış ham görüntüler bilgisayara aktarılır. Bu ham görüntüler sırasıyla önce 24 bit derinlikten 8 bit derinliğe yani renkli görüntü gri seviyeye çevrilir sonra görüntü istenen boyuta ayarlanır. Avuç içinde çalışacağımız 128x128 piksellik bölgenin çıkartılması gerçekleştirilir. Sonra öznitelik vektörleri çıkartma ve sınıflandırma işlemleri ile süreç tamamlanır. Avuç içi görüntüsü alınan sistemin Şekil II.28’de şeması gösterilmektedir [58].



Şekil II.28: Avuç İçi Görüntüsü Alma Sisteminin Şeması [58]


II.5.1. Avuç İçi Görüntüsü Veri Tabanları

IITK veri tabanı, Indian Institute Technology of Kanpur tarafından 150 kişiden alınan 183 farklı avuç içi kullanılarak toplam 549 el görüntüsü düşük maliyetli tarayıcı kullanılarak elde edilmiştir. Her avuç içinden 3 görüntü alınmıştır. Tarayıcıdan elde edilen el görüntüleri 200 dpi çözünürlüğe sahip 256 gri seviyeli resimlerdir [55].

CASIA veri tabanı (The Chinese Academy of Sciences Institute of Automation) 312 farklı kişiden alınan toplam 5502 avuç içi görüntüsünden oluşmaktadır. Her kişiden 8 sağ el ve 8 sol el olmak üzere toplam 16 avuç içi görüntüsü alınmıştır. Cihazdan elde edilen avuç içi görüntüleri 8 bit gri seviyeli JPEG formatında resimlerdir. Veri tabanındaki her bir avuç içi görüntüsü 640x480 piksel boyutundadır. Aynı kişilere ait 16 farklı görüntü tek bir klasör içerisinde gruplanmıştır. Yani 312 farklı kişi olduğu için 312 farklı klasör mevcuttur [56].

CASIA Multi-Spektral avuç içi görüntü veri tabanı, çoklu spektral görüntüleme cihazı kullanarak 100 farklı kişiden alınmıştır. Toplamda 7200 avuç içi görüntüsü vardır. Avuç içi görüntüleri 8 bit gri-düzey JPEG dosyalarıdır. Her el için iki seansta görüntüler elde edilmiştir. İki seans arasındaki zaman aralığı, bir aydan


fazladır. Her oturumda üç görüntü alınmıştır. Her bir örnek, aynı anda altı farklı elektromanyetik spektrum ile yakalanan altı avuç içi görüntülerini içerir. Altı spektrumuna karşılık gelen aydınlatma dalga boyları sırasıyla 460nm, 630nm, 700nm, 850nm, 940nm ve beyaz ışıktır. İki örnek arasında el duruş varyasyonlarına belli bir ölçüde izin verilmiştir. Bu sayede sınıf içi örneklerin çeşitliliği artırılmıştır. Avuç içi pozisyonlarını kısıtlamak için mandal kullanılmamıştır. Eli cihazın içine koymak yeterlidir. Cihaz eşit olarak dağıtılmış aydınlatma malzemeleri ve cihazın alt kısmında sabit bir CCD kamera kullanarak avuç içi görüntüsü yakalanır [57]. Şekil II.29'da CASIA Multi Spektral görüntüleme cihazı genel yapısı gösterilmiştir.



Şekil II.29: CASIA Multi Spektral Görüntüleme Cihazı [57]

Bu tez çalışmasındaki tüm deneyler, PolyU veri tabanı (The Hong Kong Polytechnic University Multispectral Palmprint Database) avuç içi görüntüsü veri bankası kullanılarak yürütülmüştür. PolyU avuç içi veri tabanındaki görüntülerin tamamı Şekil II.30'da gösterilen avuç içi tanıma cihazı ile elde edilmiştir [53].

Avuç içi görüntüleri benzersiz bir yüksek kullanılabilirlik ve güvenilir biyometrik özellikte, son derece doğru ve sağlam avuç içi kimlik doğrulama sistemi için artan talebi, multispektral görüntüleme ile daha ayrıntılı bir bilgi edinme ve avuç içi dolandırıcılığını azaltmak için elde edilmiştir [53].




Şekil II.30: PolyU Avuç İçi Okuyucusundan Görüntü Alma İşlemi [58]

Hong Kong Politeknik Üniversitesi Biyometrik Araştırma Merkezi mavi, yeşil, kırmızı ve kızılötesi aydınlatmalar altında avuç içi görüntüleri yakalayabilen gerçek zamanlı multispektral avuç içi görüntü yakalama cihazı geliştirdi ve bunu kullanarak büyük ölçekli multispektral avuç içi görüntüleri veri tabanı oluşturdu. Akademik araştırmalarda geliştirilen avuç içi doğrulama algoritmalarında serbestçe kullanabilecekleri ve test edebilecekleri bir veri bankası yayımlamıştır [54].

Çözünürlüğü 96 dpi, 128x128 boyutlarında ve 8 bit derinliğinde 256 gri seviyeli görüntülerdir. 195 erkek ve 55 kadın dâhil olmak üzere 250 gönüllü, Multispektral avuç içi görüntülerinin yaş dağılımı 20 ile 60 yaş arasında olan kişilerden toplandı. İki ayrı oturumda örnekler toplanmıştır. Her oturumda 6 adet avuç içi görüntüleri elde edilmiştir. Her oturumda 4 farklı aydınlatma ile 2 avuç içi görüntüsü alınarak bir kişiye ait toplam 24 avuç içi görüntüsü toplanmıştır. Veri tabanı toplam 6000 görüntüleri içeren, bir aydınlatma için 500 farklı kişinin avuç içi görüntüsü mevcuttur. Birinci ve ikinci oturumları arasındaki ortalama zaman aralığı yaklaşık 9 gündür [54].


Her klasör "nnnn" olarak adlandırılır, "nnnn" 1 ile 500 arasında kişi kimliğini temsil eder. Her klasörde ilk 6 adet avuç içi görüntüleri "1_mm" olarak adlandırılan ilk oturumda elde edilmiştir, ikinci 6 adet avuç içi görüntüleri "2_mm" ise ikinci oturumda elde edilmiştir. "mm" oturumdaki avuç içi görüntüleri resim dizisini temsil

eder. "Blue.rar", "Green.rar", "Red.rar" ve "NIR.rar" mavi, yeşil, kırmızı ve NIR aydınlatma ile toplanan tüm orijinal avuç içi görüntülerini içerir. Ayrıca her avuç içi görüntüsünün ilgi bölgesi (ROI) çıkartılarak sadece avuç içi ROI bölgelerinin mevcut olduğu veri tabanı da mevcuttur. Avuç içi görüntüleri elde edilirken görüntüyü ayarlamak için parmak arası takoz kullanılmıştır [54].



Şekil II.31: PolyU MultiSpectral Avuç İçi Görüntüleri [54]

Şekil II.31'deki PolyU MSPalmprint veri tabanından 15. kişinin görüntüleri; sol görüntü 1. oturumdan sağ görüntü 2. oturumdan alınmıştır.




Şekil II.32: PolyU ROI Avuç İçi Görüntüleri [54]

Şekil II.32'deki PolyU Multispektral avuç içi görüntüsünden ilgi bölgesinin çıkarılması ile elde edilen görüntülerdir. Sol görüntü 15. kişinin ilgi bölgesi 1. oturumdan, sağ görüntü ise 2. oturumdan çıkartılmıştır.

II.5.2. Avuç İçinden İlgi Bölgesinin Çıkartılması

Avuç içi görüntüleri üzerinde çalışılacak bölgenin seçiminde öncelikle avuç içi görüntüsü gri seviyede olmalıdır. Eşik değeri ile ikili görüntüye çevrilmektedir. İkili görüntü üzerinde sınırları bulma algoritması ile parmak aralarındaki sınırlar bulunur. Avuç içi görüntülerinden ilgi bölgesinin seçilmesi yönteminin işlem basamakları şu şekildedir [59]:

- Görüntü eşikleme ile ikili karşılığı bulunduktan sonra sınır izleme ile parmak aralıkları bulunur.
- İki parmak arasının (işaret parmağı ile ortanca parmak ve yüzük parmağı ile serçe parmak arası) tanjantı bulunur. Bunun için (x_1, y_1) ve (x_2, y_2) sırasıyla (F_1x_j, F_1y_j) ve (F_2x_j, F_2y_j) parmak aralıklarındaki herhangi iki nokta olsunlar. Bu durumda $F_1y_j \leq mF_1x_j + c$ bütün i ve j ler için sağlanıyorsa $y=mx+c$ doğrusu iki parmak arasının tanjantı olacaktır.
- (x_1, y_1) ve (x_2, y_2) noktaları bir doğru ile birleştirilir ve bu doğruya göre döndürme işlemi gerçekleştirilir.
- Döndürme işleminden sonra bu doğrunun orta noktasından dik bir doğru daha çizilir ve orta noktası merkeze gelecek şekilde seçilebilecek en büyük alan olan 128x128'lik bir alan avuç izi görüntüsü olarak belirlenir.



Şekil II.33: Avuç İçi İlgili Bölgesinin Çıkarılma Aşamaları [59]

Şekil II.33'de (a) orijinal görüntü (b) İkili seviye görüntü (c) Parmak arasının bulunması (d) tanjant işlemi ile görüntüyü çevirme (e) ilgi bölgesinin hesaplanması (f) ilgi bölgesinin çıkarılması.

II.6. LİTERATÜRDEKİ ÖNCEKİ ÇALIŞMALARIN ÖZETLERİ

Avuç içi izi özellikleri kullanarak kimlik tanımlama ve doğrulama günümüzde hala çözüm bekleyen sorunlar arasındadır. Araştırmalar çeşitli yöntemlerle geliştirilmiştir. Genellikle avuç içi izlerini parmak izi tanımadaki gibi yöntemler Gabor filtresi, dalgacık dönüşümleri, Fourier dönüşümü, yöntemleri kullanılarak gerçekleştirilmiştir. Parmak izi ile kıyaslandığında avuç içi izleri çok fazla çizgiye sahip ve tanımda parmak izine göre yüksek performans göstermektedir. Hatta parmak izi için yüksek çözünürlüğe ihtiyaç varken avuç içi izlerinde buna gerek yoktur, düşük çözünürlükte tanıma rahatlıkla gerçekleşir. Literatürdeki kişiler öznitelik çıkarmada dalgacık dönüşümü ve sınıflandırmada ise yapay sinir ağlarını kullanmışlardır.

Yu 2008'de çalışmasında avuç içi tanıma yaklaşımı için Modifiyeli Ayrık Kosinüs Dönüşümü tabanlı özellik çıkarma yöntemi ile avuç içi özelliklerini elde etmek için kullanılır. Sınıflandırmada Radyal tabanlı yapay sinir ağları kullanır. Radyal tabanlı sinir ağı eğitimi kolaylaştırmak amacıyla, fazla verileri makul bir boyuta azaltmak için de kullanmıştır [40].

Yang 2008'de önerdiği sistemde, avuç içi geometrik özellikleri ve doku özelliklerini çekirdek temelli bileşenler analizi (KPCA) ile elde etmiştir. El geometrisi özelliklerini seçmek için fazla veri arasından küçük bir veri seti seçmek için kendi kendini organize eden yapay sinir ağı uygulamıştır. Tanımlama aşamasında Radyal tabanlı yapay sinir ağı kullanır [41].

Lu 2008'de öncelikle avuç içi çalışma bölgesine iki boyutlu ayrık dalgacık dönüşümü ve sonra temel bileşenler analizi (PCA) uygular. Daha sonra boyutlarını azaltmak için local izdüşümleri koruma yöntemini kullanır. Son olarak, avuç içi görüntüleri hızlı bir şekilde sınıflandırmak için bir zorlamalı yapay sinir ağları ile sınıflandırır [42].

Ekinci 2008'de avuç içi görüntüsünü düşük çözünürlükte ayrıştırmak için dalgacık alt bant (subband) katsayılarını daubechies dalgacıkları ile ayrıştırır. Daha sonra Çekirdek temel bileşenler analizi (KPCA) yöntemi ile alt bantta doğrusal olmayan katsayıları ayıklamak için uygulanır. Son olarak benzerlik ölçümü için

ağırlıklı öklid doğrusal mesafe ile yapay sinir ağında sınıflandırır ve destek vektör makinesi (SVM) ile karşılaştırmalı olarak yapılmaktadır [43].

Kong 2007'de Biyometri tabanlı kimlik doğrulama ve tanımlama için etkili bir yaklaşım olarak Dalgacık dönüşümü ve Zernike moment teknikleri ile avuç içi doku özelliklerini ayıklamak için kullanır. Özelliklerin belirlenmesi aşamasında K-Means kümeleme algoritması kullanılır. Sınıflandırma aşamasında Geri Yayılımlı yapay sinir ağı kullanılmaktadır [44].

Wong 2007'de avuç içi çizgilerini farklı çözünürlük seviyelerine ayıklamak için dalgacık dönüşümü kullanır. Düşük çözünürlük düzeyinde, avuç içi ince çizgileri ayıklanır. Yüksek çözünürlük düzeyinde, avuç içi kaba çizgiler ayıklanır. 100 farklı bireylerin on sağ eli görüntüsü kullanılır. Avuç içi görüntüleri kilit noktaları bulmak için ön işleme tabi tutulur. Anahtar noktaya bakarak görüntüler döndürülmüş ve kırılmıştır. Avuç içi görüntüleri geliştirilmiş ve yeniden boyutlandırılmıştır. İki farklı dalgacık enerji seviyesi kullanılır. Bu özellik vektörleri öklid uzaklık veya ileri beslemeli geri yayılımlı yapay sinir ağı kullanarak sınıflandırılmış ve test edilmiştir. Sonuçlarına göre, %99,07 doğruluğu dB 5. tip dalgacık ve dalgacık enerji seviyesi 2 kullanılarak elde edilir [45].

Sun 2006'daki çalışmasında avantajlı Gabor dalgacık ağı ve olasılıksal yapay sinir ağı kullanmıştır. İlk olarak her bireyin avuç içi Gabor dalgacık ağı özellik vektörleri bulunur. Bunlar olasılıksal yapay sinir ağı ile eğitilmiştir. Deneysel sonuçlarda doğru tanımlama oranı %99,5 ulaşır. 1971 görüntü örnekleri içeren bir veri tabanında algoritmanın verimliliği ispatlanıyor [46].

Zhou 2006'da avuç içi görüntülerine 2 boyutlu ve 3 bantlı ayırık dalgacık dönüşümü ile düşük alt bant görüntüleri ile özellik vektörleri çıkarır. Sınıflama aşamasında destek vektör makinelerini (SVM) tercih eder. Deneysel sonuçlarda kimlik doğru tanıma oranı %100'dür [47].

Wen 2005'de bu çalışmada, parmak izlerindeki açıklık ve süreklilik geliştirmek yeni bir parmak izi geliştirme algoritması önerir. Parmak izi görüntüleri ayrıntılı alt bantlara ayrılacak, resmin yönü tahmin edilecek son olarak, parmak izi imajına dalgacık ortamında Gabor filtre kullanmıştır. Deneysel sonuçları düşük kaliteli parmak izi görüntülerde etkili olduğunu gösterir [48].

Han 2003'de Kimlik tanıma sistemi; kayıt ve doğrulama olmak üzere iki aşamadan oluşur. Kayıt aşamasında, eğitim örnekleri toplanmış ve ön işleme, öznelik çıkarma ve modelleme modülleri ile şablonlar oluşturulur. Doğrulama

aşamasında, bir sorgu örneği de ön işleme ve özellik çıkarımı modülleri tarafından işlenir ve daha sonra bunun gerçek bir örnek olup olmadığına karar vermek için referans şablonlar ile eşleştirilir. Her bir örnek için çalışma bölgesi, ön işleme modülü ile elde edilir. Daha sonra, avuç içi özellikleri Sobel metodu ve morfolojik işlemler kullanılarak elde edilir. Son olarak, şablon eşleme ve doğrulama aşamasında benzerlikleri ölçmek için geri yayımlı yapay sinir ağı kullanılır [49].

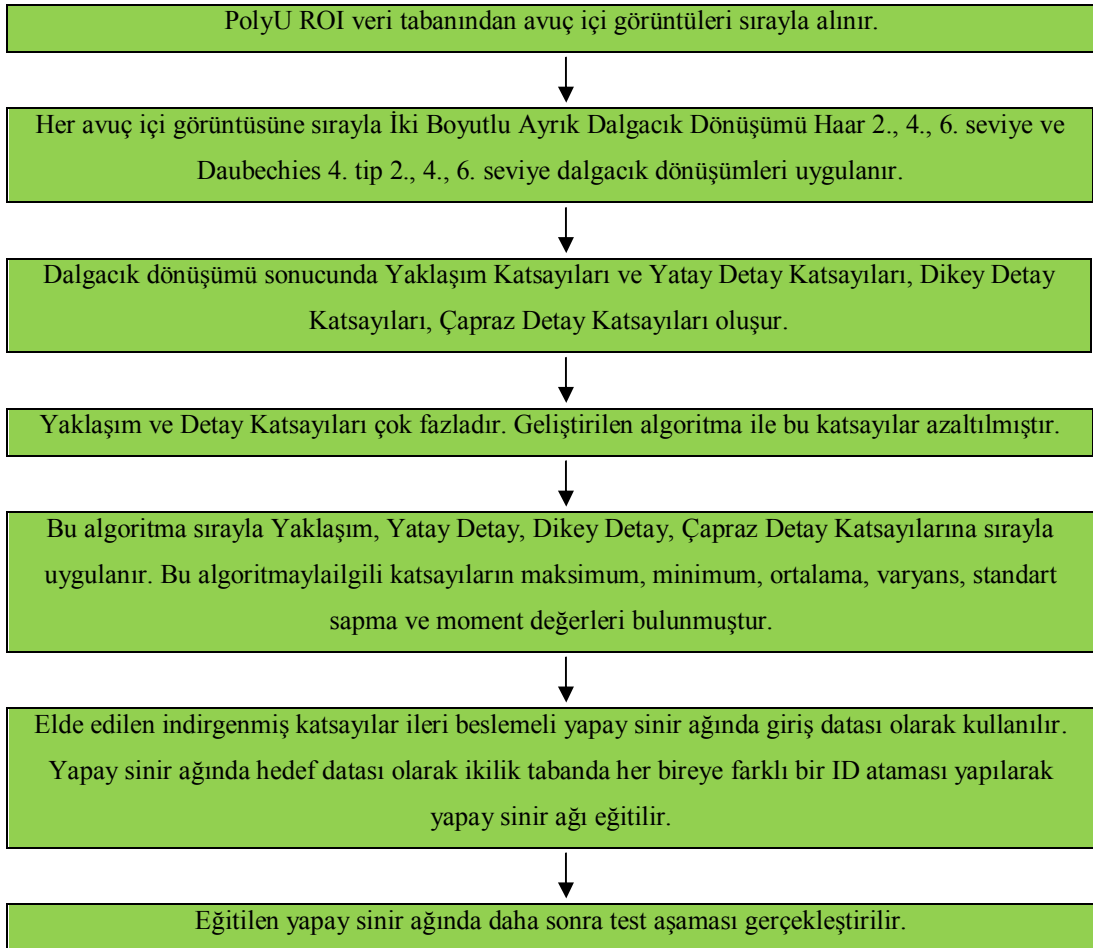
Wu 2002’de dalgacık enerji özellikleri adlı yeni bir avuç içi özelliği, çoklu çözünürlük analizi için dalgacıkları güçlü bir araç olarak kullanır. Bu çalışmada farklı dalgacık ayrıştırma düzeyleri çeşitli yönlerde ana çizgiler, kırıksıklıklar ve kabartma çizgileri dalgacık enerji dağıtımını yansıtabilir, bunlarında avuç içi ayırt ediciliği çok yüksektir [50].

Funada 1998’de avuç içi görüntüleri kabarık kalın çizgiler ve kırıksık ince çizgilerden oluşur. Parmak izi özellik çıkarma algoritmaları ile kalın çizgileri ayıklamak mümkün değildir. Bu araştırma bu koşullar altında kalın çizgileri ayıklayabilmek için yeni bir özellik çıkarma yöntemi sunar [51].

BÖLÜM III

AVUÇ İÇİ TANIMA UYGULAMASI

Bu bölümde yapılan uygulamalar Matlab R2009b programındaki hazır komutlar, fonksiyonlar kullanılarak gerçekleştirilmiştir. Bu tez çalışmasında, PolyU ROI veri tabanından 50 kişiye ait 600 adet avuç içi görüntüsü kullanılarak kimliğin tespit edilmesi sistemi tasarlanmıştır. 500 adet görüntü YSA'da eğitim aşamasında, 100 adet görüntü YSA'da test aşamasında kullanılmıştır. Avuç içi tanımlama ve doğrulama sisteminin işlem basamakları Şekil III.1'deki akış şemasında verilmiştir.



Şekil III.1: Avuç İçi Tanıma Sistemi Akış Diyagramı

III.1. ÖZİNİTELİK ÇIKARMA AŞAMASI

Eğitim aşamasında kullanılacak olan avuç içi görüntülerini birbirinden ayırt edecek öznelik vektörleri çıkartma çalışmaları yapılmıştır. Tüm avuç içi görüntülerinde çalışma bölgesi 128x128 piksel olarak belirlenmiştir. Her avuç içi görüntüsüne Matlab ortamında iki boyutlu ayrık dalgacık dönüşümü uygulanarak, dalgacık katsayıları elde edilmiştir. Bu katsayıların fazla olmasından ötürü geliştirilen algoritma ile en aza indirgenerek temsil edilecektir. Bu vektörler avuç içeri arasındaki farklılıkları temsil eden sadece o kişiye ait özellikleri barındıran katsayılardır. Avuç içi çizgileri her bireyde farklı olmasından ötürü oluşacak her öznelik vektörleri de böylelikle farklı olacaktır. Bu vektörler doğrusal olmayan nitelikte olup sınıflama aşamasında göz önün de bulundurulmalıdır. Tez çalışmasında PolyU ROI veri tabanından 50 kişiye ait her birey için 12 farklı görüntüye sırayla geliştirilen algoritma yardımı ile avuç içini temsil edecek 600 adet öznelik vektörleri çıkartılmıştır. Bunlardan 500 tanesi yapay sinir ağında eğitim aşamasında 100 tanesi yapay sinir ağında test aşamasında kullanılmıştır.

PolyU veri tabanındaki görüntüler üzerinde öznelik çıkarma yöntemleri olarak iki boyutlu ayrık dalgacık dönüşümleri uygulanacaktır. Haar dalgacık 2., 4. ve 6. seviyeleri ile Daubechies 4. tip 2., 4. ve 6. seviye dalgacık dönüşümleri uygulanmıştır. Her bir avuç içi görüntüsü için uygulanacak dalgacık dönüşümleri ve seviyeleri sonucunda oluşan katsayılar fazladır. Bu fazlalık da işlem yükünü artırır. Matlab'de geliştirilen algoritma sayesinde bu katsayılar en aza kadar indirgenir. Bu indirgemede ayırt edicilikten taviz verilmez. Bu katsayılar; yaklaşım katsayıları, yatay-dikey-köşegen katsayılarına programdaki algoritma uygulanarak katsayılar azaltılır ve sütun matrisi haline dönüştürülerek Excel dosyasına veya veri tabanına kaydedilir. Her avuç içi görüntüsüne bu program uygulanarak ilgili katsayılar sırayla Excel dosyasına kayıt edilir. Daha sonra bu katsayılar yapay sinir ağında eğitim ve test aşamasında her bireyin kimliğini temsil edecek olan katsayılardır.

Tablo III.1'deki katsayılar dalgacık dönüşümü kullanılarak ve sonrasında dalgacık katsayılarına geliştirilen algoritma uygulanarak elde edilmiş katsayılardır. Bu katsayılar daha sonra yapay sinir ağında eğitim aşamasında giriş dataları olarak kullanılacaktır. Tablo III.1'de PolyU ROI veri tabanından 15. kişiye ait 10 adet avuç içi görüntüsüne Haar dalgacık dönüşümü 2. seviye ve devamında geliştirilen algoritma yardımıyla elde edilen katsayılardır. Her sütun bir avuç içi görüntüsünü temsil eden 24 satırdan oluşan katsayılardır.

Tablo III.1: 15. Kişinin Avuç İçi Öznitelik Katsayıları

1. Avuç İçi	2. Avuç İçi	3. Avuç İçi	4. Avuç İçi	5. Avuç İçi	6. Avuç İçi	7. Avuç İçi	8. Avuç İçi	9. Avuç İçi	10. Avuç İçi
329,25	330	353	338	328,5	324,75	319,5	361,25	320,75	323,25
638	618	615	607,75	603,75	697,5	647	674,75	641,25	658,25
500,31	498,54	496,41	497,09	499,58	499,46	490,64	518,07	492,05	498,58
54,74	48,367	46,183	44,437	46,311	57,521	53,842	47,959	50,309	48,844
2996,5	2339,4	2132,9	1974,6	2144,8	3308,7	2899	2300	2531	2385,7
-33867	-59545	-48085	-55079	-80544	52034	-2390	-11778	-19194	-39019
-37,5	-34,75	-35,75	-35,75	-33,75	-34,75	-31,25	-43,5	-39,5	-34,75
43,25	39	43,75	40,5	47	45,75	47,5	49,5	43,5	48
0,7964	0,3958	0,3528	0,5454	0,4473	1,1453	0,8008	0,791	0,7974	0,6516
10,025	10,439	10,971	10,461	10,611	11,19	11,139	11,977	10,798	11,036
100,51	108,98	120,35	109,43	112,59	125,21	124,07	143,45	116,6	121,79
349,03	33,528	263,68	43,41	-60,57	482,88	460,61	411,19	362,38	225,16
-60,75	-43	-84,25	-74	-48,25	-74,75	-48,25	-63	-55,25	-52,5
61,5	72	81,75	53,25	63,5	70,25	62,75	58,25	62	67,75
-1,065	-0,22	0,2971	0,0127	-0,174	-1	-0,288	-0,516	-0,251	-0,372
13,74	13,351	13,643	13,355	13,093	13,775	14,16	14,088	13,601	13,636
188,8	178,24	186,12	178,36	171,43	189,74	200,5	198,46	184,98	185,93
935,21	1819,3	728,42	17,012	696,33	416,95	1507,4	797,25	1076,2	857,96
-36,75	-36	-44,5	-39,5	-36,5	-47,75	-31,75	-36	-35,75	-36,25
35,5	30	35,5	36,25	30,75	38,75	32,75	40,5	30	34
0,1011	-0,111	0,1877	-0,229	-0,243	-0,005	0,0474	-0,147	0,0513	0,0251
8,3074	7,9984	8,147	8,2396	7,5887	9,1016	8,9093	8,7621	8,6855	8,3353
69,014	63,974	66,374	67,892	57,589	82,84	79,376	76,775	75,438	69,477
117,1	-1,252	27,4	-87,18	34,793	14,682	52,903	126,48	84,537	75,084

III.2. SINIFLANDIRMA AŞAMASI

Görüntü işlemeye dayalı otomatik tanıma sistemimizin son aşaması sınıflandırmadır. Elde ettiğimiz avuç içi öznitelik vektörleri sınıflandırma aşamalarından geçirilmiştir. Bunlardan bir tanesi öklid doğrusal ayırtıcıdır. Bu yöntem doğrusal olarak ayırma gerçekleştirdiğinden ve düşük başarı verdiği için tercih edilmemiştir. Çünkü avuç içini temsil eden vektörler doğrusal olmayan katsayılarıdır. Bundan ötürü ileri beslemeli geri yayımlı yapay sinir ağı kullanılmıştır. Günümüzde yapay sinir ağının parametrelerini ayarlamak için bir standart yoktur bunun için parametreler deneme yanılma ile tespit edilmiştir. Matlab ortamında kullanılan yapay sinir ağına verilen giriş dataları yapay sinir ağı tarafından otomatik olarak ölçeklendirilerek kullanılmıştır.

Tablo III.2: Yapay Sinir Ağı İçin Giriş Datası Örneği

1. Kişi	2. Kişi	3. Kişi	4. Kişi	N. Kişi
323,125	330,6091	335,0077	340,5038	...
642,5353	640,0876	652,492	652,5064	...
501,141	501,4156	501,2499	509,7957	...
56,46068	57,40661	57,23808	53,03166	...
3187,808	3295,519	3276,198	2812,357	...
...

Tablo III.2’de yapay sinir ağına 50 kişiye ait her avuç içini temsil edecek olan öznelik katsayıları sütun matrisi halinde sıralandırılmış ve giriş datası olarak verilmiştir.

Tablo III.3: Yapay Sinir Ağı İçin Hedef Datası Örneği

1. Kişi ID	2. Kişi ID	3. Kişi ID	4. Kişi ID	N. Kişi ID
1	0	0	0	0
0	1	0	0	0
0	0	1	0	0
0	0	0	1	0
0	0	0	0	0
...	1 (N. satır)

Tablo III.3’te yapay sinir ağının girişine karşılık gelen her birey için farklı bir ID ataması yapılarak hedef datası verilmiştir.

III.3. DENEYSEL ÇALIŞMALAR

III.3.1. Yapay Sinir Ağında Eğitim Aşamaları


Avuç içi görüntüleri üzerindeki yapılan ilk inceleme yapay sinir ağlarındaki eğitim sürecidir. Yapay sinir ağı tipi olarak ileri beslemeli geri yayımlı (feed forward backprop), eğitim fonksiyonu olarak TrainBR (bayes yöntemi), adaptasyon öğrenme fonksiyonu LEARNGD (gradient descent), performans fonksiyonu MSE (mean squared error), katman sayısı 3, her katman için transfer fonksiyonu TANSIG (tanjant sigmoid) ve sinir (neuron) sayısı 10 verilmiştir. Tüm eğitim aşamalarında bu parametreler kullanılmıştır.

Giriş datası olarak 50 kişiye ait her birey için 10 adet farklı avuç içi görüntüsüne Haar 2. seviye dalgacık dönüşümü ve geliştirilen algoritma ile elde edilen katsayılar yapay sinir ağının girişine verilmiştir. Hedef datası olarak her birey

için ikilik tabanda farklı bir ID ile temsil edilir. Eğitim süreci 17 iterasyonda (döngüde) gerçekleşerek %98 regresyon, test datalarında %65 oranını göstermiştir. Tablo III.4'te eğitim sonucundaki değerler, Şekil III.2'de eğitim ve test sonuçları gösterilmiştir.

Tablo III.4: Haar 2. Seviye Dalgacık için Sonuç Değerleri

Dalgacık Dönüşümü	Kişi Sayısı	Max	Min	Mean	İstenen Cevabın Mean Değeri	Epochs
Haar 2	50	0,9914	0	0,025	0,02	17




Şekil III.2: Haar 2. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları

Giriş datası olarak 50 kişiye ait her birey için 10 adet farklı avuç içi görüntüsüne Haar 4. seviye dalgacık dönüşümü ve geliştirilen algoritma ile elde edilen katsayılar yapay sinir ağının girişine verilmiştir. Hedef datası olarak her birey için ikilik tabanda farklı bir ID ile temsil edilir. Eğitim süreci 21 iterasyonda gerçekleşerek %99 regresyon, test datalarında %62 oranını göstermiştir. Tablo III.5'te eğitim sonucundaki değerler, Şekil III.3'te eğitim ve test sonuçları gösterilmiştir.

Tablo III.5: Haar 4. Seviye Dalgacık için Sonuç Değerleri

Dalgacık Dönüşümü	Kişi Sayısı	Max	Min	Mean	İstenen Cevabın Mean Değeri	Epochs
Haar 4	50	0,9959	0	0,0231	0,02	21




Şekil III.3: Haar 4. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları

Giriş datası olarak 50 kişiye ait her birey için 10 adet farklı avuç içi görüntüsüne Haar 6. seviye dalgacık dönüşümü ve geliştirilen algoritma ile elde edilen katsayılar yapay sinir ağının girişine verilmiştir. Hedef datası olarak her birey için ikilik tabanda farklı bir ID ile temsil edilir. Eğitim süreci 19 iterasyonda gerçekleşerek %99 regresyon, test datalarında %66 oranını göstermiştir. Tablo III.6’da eğitim sonucundaki değerler, Şekil III.4’te eğitim ve test sonuçları gösterilmiştir.

Tablo III.6: Haar 6. Seviye Dalgacık için Sonuç Değerleri

Dalgacık Dönüşümü	Kişi Sayısı	Max	Min	Mean	İstenen Cevabın Mean Değeri	Epochs
Haar 6	50	0,9957	0	0,0212	0,02	19




Şekil III.4: Haar 6. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları

Buraya kadar özetleyecek olursak yapay sinir ağlarında Haar dalgacıkları için eğitim süreci sonunda dalgacık seviyesi yükseldikçe istenen cevaba yaklaşması artıyor, gerek max ve gerek mean değerlerinde bu gözükmiştir.

Giriş datası olarak 50 kişiye ait her birey için 10 adet farklı avuç içi görüntüsüne Daubechies 4. tip 2. seviye dalgacık dönüşümü ve geliştirilen algoritma ile elde edilen katsayılar yapay sinir ağının girişine verilmiştir. Hedef datası olarak her birey için ikilik tabanda farklı bir ID ile temsil edilir. Eğitim süreci 25 iterasyonda gerçekleşerek %95 regresyon, test datalarında %53 oranını göstermiştir. Tablo III.7’de eğitim sonucundaki değerler, Şekil III.5’te eğitim ve test sonuçları gösterilmiştir.

Tablo III.7: Daubechies 4. Tip 2. Seviye Dalgacık için Sonuç Değerleri

Dalgacık Dönüşümü	Kişi Sayısı	Max	Min	Mean	İstenen Cevabın Mean Değeri	Epochs
Db 2	50	0,9781	0	0,026	0,02	25




Şekil III.5: Daubechies 4. Tip 2. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları

Giriş datası olarak 50 kişiye ait her birey için 10 adet farklı avuç içi görüntüsüne Daubechies 4. tip 4. seviye dalgacık dönüşümü ve geliştirilen algoritma ile elde edilen katsayılar yapay sinir ağının girişine verilmiştir. Hedef datası olarak her birey için ikilik tabanda farklı bir ID ile temsil edilir. Eğitim süreci 17 iterasyonda gerçekleşerek %96 regresyon, test datalarında %58 oranını göstermiştir. Tablo III.8’de eğitim sonucundaki değerler, Şekil III.6’da eğitim ve test sonuçları gösterilmiştir.

Tablo III.8: Daubechies 4. Tip 4. Seviye Dalgacık için Sonuç Değerleri

Dalgacık Dönüşümü	Kişi Sayısı	Max	Min	Mean	İstenen Cevabın Mean Değeri	Epochs
Db 4	50	0,9832	0	0,0253	0,02	17




Şekil III.6: Daubechies 4. Tip 4. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları

Giriş datası olarak 50 kişiye ait her birey için 10 adet farklı avuç içi görüntüsüne Daubechies 4. tip 6. seviye dalgacık dönüşümü ve geliştirilen algoritma ile elde edilen katsayılar yapay sinir ağının girişine verilmiştir. Hedef datası olarak her birey için ikilik tabanda farklı bir ID ile temsil edilir. Eğitim süreci 18 iterasyonda gerçekleşerek %97 regresyon, test datalarında %50 oranını göstermiştir. Tablo III.9’da eğitim sonucundaki değerler, Şekil III.7’de eğitim ve test sonuçları gösterilmiştir.

Tablo III.9: Daubechies 4. Tip 6. Seviye Dalgacık için Sonuç Değerleri

Dalgacık	kişi sayısı	Max	Min	Mean	İstenen Cevabın Mean Değeri	Epochs
Db 6	50	0,9966	0	0,0234	0,02	18



Şekil III.7: Daubechies 4. Tip 6. Seviye Dalgacık için YSA Eğitim ve Test Sonuçları

Buraya kadar özetleyecek olursak yapay sinir ağlarında Daubechies 4. tip dalgacıkları için eğitim süreci sonunda dalgacık seviyesi yükseldikçe istenen cevaba yaklaşması artıyor, gerek max ve gerek mean değerlerinde bu gözükmiştir.

III.3.2. Yapay Sinir Ağında Test Aşamaları

Yapay sinir ağlarındaki eğitim sürecinde 50 kişiye ait her birey için 10 avuç içi görüntüsü ile eğitim yapılmıştır ve her bireye ait diğer 2 avuç içi görüntüsü test için saklanmıştır. Yapay sinir ağlarında eğitim sonrasında her dalgacık çeşidi ve seviyesi için ayrı ayrı testler yapılmıştır. Eğitilmiş olan yapay sinir ağına öncelikle, Haar dalgacık dönüşümü 2. seviye ve geliştirilen algoritma ile elde edilen öznitelik vektörleriyle, eğitilmiş YSA'da test sonuçlarında 64 doğru tahmin ve 36 yanlış tahmin yapmıştır. Tablo III.10'da 50 kişiyi ait 100 avuç içi görüntüsü için Haar dalgacık dönüşümü 2. seviye için test sonuçları gösterilmiştir.

Tablo III.10: Haar 2. Seviye Dalgacık için Test Sonuçları

Dalgacık Dönüşümü	Öznitelik Aralığı	Eğitim Oranı (%)	Doğru Tahmin	Yanlış Tahmin	Max Değer	Min Değer	Sonuçların Ortalaması
Haar 2	-187074 ~ +70886	98	64	36	0,99	0,15	0,68

Haar dalgacık dönüşümü 4. seviye ve geliştirilen algoritma ile elde edilen öznitelik vektörleriyle, eğitilmiş YSA'da test sonuçlarında 72 doğru tahmin ve 28

yanlış tahmin yapmıştır. Tablo III.11’de 50 kişiyi ait 100 avuç içi görüntüsü için Haar dalgacık dönüşümü 4. seviye için test sonuçları gösterilmiştir.


Tablo III.11: Haar 4. Seviye Dalgacık için Test Sonuçları

Dalgacık Dönüşümü	Öznitelik Aralığı	Eğitim Oranı (%)	Doğru Tahmin	Yanlış Tahmin	Max Değer	Min Değer	Sonuçların Ortalaması
Haar 4	-10426274 ~ +6517623	99	72	28	0,98	0,15	0,79

Haar dalgacık dönüşümü 6. seviye ve geliştirilen algoritma ile elde edilen öznitelik vektörleriyle, eğitilmiş YSA’da test sonuçlarında 73 doğru tahmin ve 27 yanlış tahmin yapmıştır. Tablo III.12’de 50 kişiyi ait 100 avuç içi görüntüsü için Haar dalgacık dönüşümü 4. seviye için test sonuçları gösterilmiştir.

Tablo III.12: Haar 6. Seviye Dalgacık için Test Sonuçları

Dalgacık Dönüşümü	Öznitelik Aralığı	Eğitim Oranı (%)	Doğru Tahmin	Yanlış Tahmin	Max Değer	Min Değer	Sonuçların Ortalaması
Haar 6	-224245310 ~ +383972967	99	73	27	0,99	0,21	0,78



Şekil III.8: Haar Dalgacık Seviyelerine Göre Hata Değişimi

Şekil III.8’de Haar dalgacık dönüşümü seviyesi arttıkça toplam hata miktarında azalma olduğu gözükmiştir. Özetle bunların yanında Haar dalgacık seviyesi arttıkça yanlış tahmin oranında azalma, sonuçların ortalaması istenen değere

%80'e yaklaştığı gözüküyor. Aynı zamanda Haar dalgacık dönüşümü seviyelerinin artması ile öznitelik değer aralığı arttığı için doğru tahmin oranında artma olmuştur.

Daubechies 4. tip dalgacık dönüşümü 2. seviye ve geliştirilen algoritma ile elde edilen öznitelik vektörleriyle, eğitilmiş YSA'da test sonuçlarında 62 doğru tahmin ve 38 yanlış tahmin yapmıştır. Tablo III.13'te 50 kişiyi ait 100 avuç içi görüntüsü için Daubechies 4. tip dalgacık dönüşümü 2. seviye test sonuçları gösterilmiştir.

Tablo III.13: Daubechies 4. Tip 2. Seviye Dalgacık için Test Sonuçları

Dalgacık Dönüşümü	Öznitelik Aralığı	Eğitim Oranı (%)	Doğru Tahmin	Yanlış Tahmin	Max Değer	Min Değer	Sonuçların Ortalaması
Db4 2	-224988 ~ +131063	95	62	38	0,97	0,05	0,64

Daubechies 4. tip dalgacık dönüşümü 4. seviye ve geliştirilen algoritma ile elde edilen öznitelik vektörleriyle, eğitilmiş YSA'da test sonuçlarında 66 doğru tahmin ve 34 yanlış tahmin yapmıştır. Tablo III.14'te 50 kişiyi ait 100 avuç içi görüntüsü için Daubechies 4. tip dalgacık dönüşümü 4. seviye test sonuçları gösterilmiştir.

Tablo III.14: Daubechies 4. Tip 4. Seviye Dalgacık için Test Sonuçları


Dalgacık Dönüşümü	Öznitelik Aralığı	Eğitim Oranı (%)	Doğru Tahmin	Yanlış Tahmin	Max Değer	Min Değer	Sonuçların Ortalaması
Db4 4	-8360293 ~ +16323764	96	66	34	0,99	0,11	0,66

Daubechies 4. tip dalgacık dönüşümü 6. seviye ve geliştirilen algoritma ile elde edilen öznitelik vektörleriyle, eğitilmiş YSA'da test sonuçlarında 68 doğru tahmin ve 32 yanlış tahmin yapmıştır. Tablo III.15'te 50 kişiyi ait 100 avuç içi görüntüsü için Daubechies 4. tip dalgacık dönüşümü 6. seviye test sonuçları gösterilmiştir.

Tablo III.15: Daubechies 4. Tip 6. Seviye Dalgacık için Test Sonuçları

Dalgacık Dönüşümü	Öznitelik Aralığı	Eğitim Oranı (%)	Doğru Tahmin	Yanlış Tahmin	Max Değer	Min Değer	Sonuçların Ortalaması
Db4 6	-877230785 ~ +1663646626	97	68	32	0,95	0,1	0,62

Şekil III.9'da Daubechies dalgacık dönüşümü seviyesi arttıkça toplam hata miktarında azalma olduğu gözükmektedir. Özetle bunların yanında Daubechies dalgacık seviyesi arttıkça yanlış tahmin oranında azalma, sonuçların ortalaması %70'e yaklaştığı gözükmiştir. Aynı zamanda Daubechies dalgacık dönüşümü seviyelerinin artması ile öznelilik değer aralığı arttığı için doğru tahmin oranında artma olmuştur.

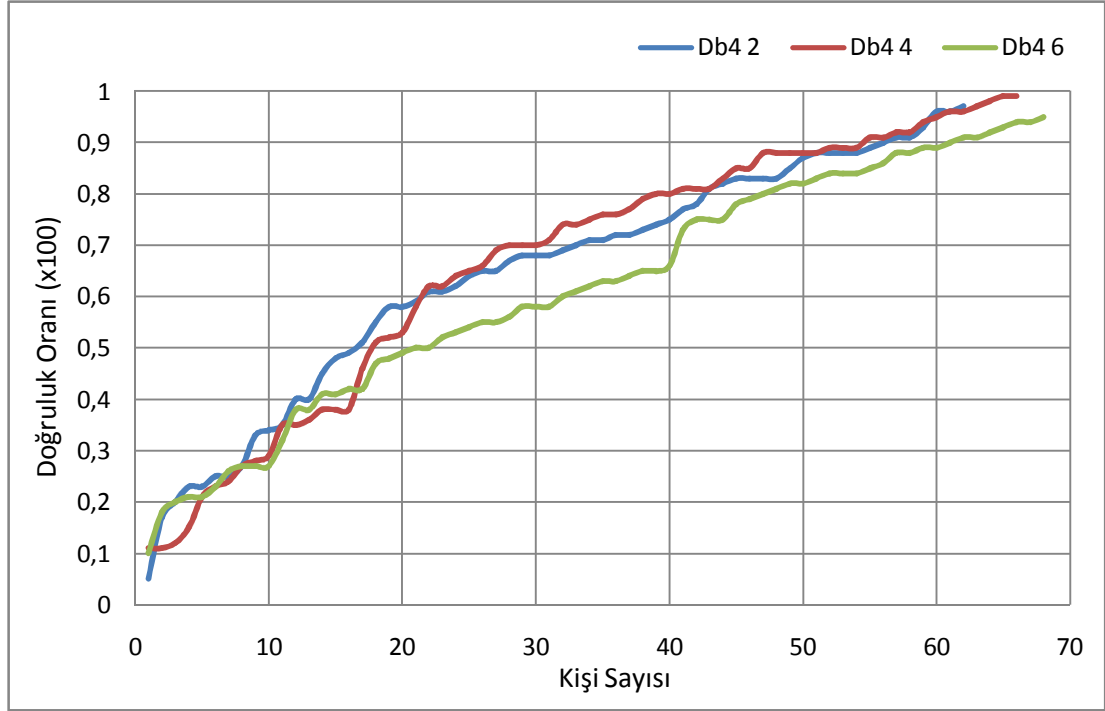


Şekil III.9: Daubechies Dalgacık Seviyelerine Göre Hata Değişimi



Şekil III.10: Haar Dönüşümü Doğru Tahmin Sonuçlarının İstenen Cevaba Yakınlığı

Haar dalgacık katsayıları ile yapılan testler gösteriyor ki, 100 adet avuç içi görüntüsünü temsil eden ve doğru tahminler arasındaki Haar dalgacıklarının seviyesi arttıkça sonuçların istenen cevaba yakınlığı artmaktadır. Şekil III.10'da doğru tahmin sonuçlarının istenen değere yakınlığını gösteren grafik verilmiştir.



Şekil III.11: Daubechies Dönüşümü Doğru Tahmin Sonuçlarının İstenen Cevaba Yakınlığı

Daubechies dalgacık katsayıları ile yapılan testler gösteriyor ki, 100 adet avuç içi görüntüsünü temsil eden ve doğru tahminler arasındaki Daubechies dalgacıklarının seviyesi arttıkça Haar dalgacık seviyelerine nazaran istenen cevaba yakınlığı artmamaktadır. Şekil III.11'de doğru tahmin sonuçlarının istenen değere yakınlığını gösteren grafik verilmiştir.

Test aşamasında göz önünde bulundurulana diğer bir noktada sahte datalar üzerinde yapılan eşlemedir. Burada %100'e yakın hepsini reddetmesi istenir. Yani buradaki kabul oranının sıfıra yakın olması gerekir. Haar 2. seviye dalgacık dönüşümü ile geliştirilen algoritma yardımıyla elde edilen sahte öznelik vektörleri üzerinde yapılan test aşamasında belirlenen eşik değerine göre 23 kişiyi kabul etmektedir. Yani 77 kişiyi reddederek doğru bir tahmin yapmış olmaktadır.

Haar 4. seviye dalgacık dönüşümü ile geliştirilen algoritma yardımıyla elde edilen sahte öznelik vektörleri üzerinde yapılan test aşamasında belirlenen eşik

değerine göre 32 kişiyi kabul etmektedir. Yani 68 kişiyi reddederek doğru bir tahmin yapmış olmaktadır.

Haar 6. seviye dalgacık dönüşümü ile geliştirilen algoritma yardımıyla elde edilen sahte öznelik vektörleri üzerinde yapılan test aşamasında belirlenen eşik değerine göre 31 kişiyi kabul etmektedir. Yani 69 kişiyi reddederek doğru bir tahmin yapmış olmaktadır.

Daubechies 4. tip 2. seviye dalgacık dönüşümü ile geliştirilen algoritma yardımıyla elde edilen sahte öznelik vektörleri üzerinde yapılan test aşamasında belirlenen eşik değerine göre 15 kişiyi kabul etmektedir. Yani 85 kişiyi reddederek doğru bir tahmin yapmış olmaktadır.

Daubechies 4. tip 4. seviye dalgacık dönüşümü ile geliştirilen algoritma yardımıyla elde edilen sahte öznelik vektörleri üzerinde yapılan test aşamasında belirlenen eşik değerine göre 22 kişiyi kabul etmektedir. Yani 78 kişiyi reddederek doğru bir tahmin yapmış olmaktadır.

Daubechies 4. tip 6. seviye dalgacık dönüşümü ile geliştirilen algoritma yardımıyla elde edilen sahte öznelik vektörleri üzerinde yapılan test aşamasında belirlenen eşik değerine göre 16 kişiyi kabul etmektedir. Yani 84 kişiyi reddederek doğru bir tahmin yapmış olmaktadır.

BÖLÜM IV

SONUÇLAR ve TARTIŞMA

Bu tez çalışmasında, PolyU ROI veri tabanından 50 kişiye ait 600 adet avuç içi görüntüsü kullanılarak kimliğin tespit edilmesi sağlanmıştır. 500 adet görüntü YSA'da eğitim aşamasında, 100 adet görüntü YSA'da test aşamasında kullanılmıştır. Bu sistem, özellik çıkarma, eğitim ve test aşamaları olmak üzere üç aşama gerçekleştirilmiştir.

İlk aşama, avuç içi görüntülerine iki boyutlu ayrık dalgacık dönüşümü ile öznitelikleri çıkarılmış ve fazla olan yaklaşım ve detay katsayılarının indirgenmesi için geliştirilen algoritmalar üzerinde çalışılmıştır. Bu indirgenmiş katsayılar ayırt edici olan öznitelik vektörlerinin çıkarılmasında başarılı sonuçlar vermiştir.

İkinci aşama, PolyU veritabanındaki bir kişiye ait 10 adet avuç içi görüntüsü ile temsil edilen öznitelik vektörleri eğitim aşamasında kullanılmıştır. Eğitim aşaması ileri beslemeli geri yayımlı yapay sinir ağlarında gerçekleşmiştir. Sonuçlar eğitim aşamasında Şekil III.2'de Haar 2. seviye dalgacık katsayıları ile %98, Şekil III.3'te Haar 4. seviye dalgacık katsayıları ile %99, Şekil III.4'te Haar 6. seviye dalgacık katsayıları ile %99, Şekil III.5'te Daubechies 4. tip 2. seviye dalgacık katsayıları ile %95, Şekil III.6'da Daubechies 4. tip 4. seviye dalgacık katsayıları ile %96, Şekil III.7'de Daubechies 4. tip 6. seviye dalgacık katsayıları ile %97 eğitim oranları ölçülmüştür. Elde edilen bu sonuçlar, bu uygulamanın avuç içi tanıma alanında kullanılabilecek etkili bir sistem olduğunu göstermektedir.

Üçüncü aşama ise avuç içi özniteliklerinin test edilmesine bağlıdır. 50 kişiye ait 100 adet avuç içi görüntüsü test aşamasında kullanılmıştır. Eğitilmiş olan ileri beslemeli yapay sinir ağında doğrulama aşamasında Tablo III.10'da Haar 2. seviye dalgacık katsayıları ile doğru tahmin %64, ve hata yanlış tahmin %36, Tablo III.11'de Haar 4. seviye dalgacık katsayıları ile doğru tahmin %72 ve hata yanlış tahmin %28, Tablo III.12'de Haar 6. seviye dalgacık katsayıları ile doğru tahmin %73 ve hata yanlış tahmin %27, Tablo III.13'te Daubechies 4. tip 2. seviye dalgacık katsayıları ile doğru tahmin %62 ve hata yanlış tahmin %38, Tablo III.14'te

Daubechies 4. tip 4. seviye dalgacık katsayıları ile doğru tahmin %66 ve hata yanlış tahmin %34, Tablo III.15'te Daubechies 4. Tip 6. seviye dalgacık katsayıları ile doğru tahmin %68 ve hata yanlış tahmin %32 doğrulama oranları ölçülmüştür.

Şekil III.8 ve Şekil III.9'da dalgacık dönüşümü seviyeleri arttıkça toplam hata miktarında azalma olmuştur. Dalgacık seviyeleri arttıkça doğru tahmin oranında artma ve yanlış tahmin oranında azalma olmuştur.

Şekil III.10 ve Şekil III.11'de dalgacık seviyelerine göre doğru tahminlerin istenen cevaba yakınlığı gösterilmiştir.

Bu çalışmada amaçlanan, avuç içi görüntülerine iki boyutlu ayrık dalgacık dönüşümü ve ileri beslemeli geri yayımlı yapay sinir ağları yardımı ile kimliğinin tespit edilmesi uygulaması gerçekleştirilmiştir.

BÖLÜM V

SON DEĞERLENDİRME ve ÖNERİLER

Avuç içi görüntüsü ile kimlik tespitinde sonuçlar neticesinde eğitim aşamasında %99,6 tanıma oranı ile başarı elde edilmiştir. Ancak Haar dalgacık dönüşümü 6. seviye katsayılarına geliştirilen algoritma uygulanarak elde edilen katsayılar ile yapılan testler de %27 hata oranı ile gerçekleştirilmiştir. Eğitim oranının yüksek olmasına rağmen test sonuçları düşük çıkmıştır. Literatürdeki başarı oranları %90~%100 arasında değişirken uygulamamızın iyileştirilmesi ve geliştirilmesi gerekmektedir. Bu uygulamada Haar dalgacıklarının Daubechies dalgacıklarına göre daha iyi sonuçlar verdiği gözlemlenmiştir. Dalgacık seviyelerinin artması yani öznitelik değerlerinin artması uygulamanın başarısını artırmıştır. Aynı zamanda sisteme doğru ve yanlış tahmin olasılığının yanında reddetme özelliği de eklenerek bir tam otomatik avuç içi tanıma ve doğrulama sistemi geliştirilebilir.

Uygulamadaki PolyU veri tabanındaki avuç içi görüntülerinin gri seviyede belirli bir aralıkta olduğu için veya çözünürlüğü az olduğundan sistemin başarısı düşük olabilir. Gri seviyedeki dar olan aralığı genişletmek için histogram eşitleme tekniği veya zıtlığı artırmak için yüksek geçiren filtre uygulanarak uygulamanın performansı tekrar denenebilir.

Yapay sinir ağında gerçekleşen eğitim aşamasında parametrelerin seçiminin deneme yanılma yöntemi ile yapılması performans sonuçlarının düşmesine sebep olmaktadır. Bu yüzden yapay sinir ağlarında parametre seçiminin uygun olarak yapılması önemli bir noktadır.

Bu uygulamada sınırlı sayıda, 50 kişiye ait veri tabanı kullanılması, çok sayıdaki veri tabanları performanslarına göre kıyaslama yapılamaması dezavantaj olarak görülmüştür. Tezde veri tabanından seçilen kişi sayısının az olması zaman açısından tanımlama ve doğrulama işlemlerin süresini, yüksek data'lı sonuçlara göre kıyaslama yapılmasını zorlaştırmıştır. Gelecekte yapılacak uygulamalar da veri tabanından seçilen kişi sayısı artırılarak bu sistemin performansı ve işlem süresi ölçülebilir.

Dalgacık dönüşümü özellikle güvenlik amaçlı kullanılan yerlerde en kısa zamanda en iyi sonucu almak için tercih edilebilmektedir. Dalgacık dönüşümleri öznitelik vektörleri çıkartma noktasında başarılı olmuştur. Dalgacık dönüşümü sonucunda fazla sayıda katsayı üretmesi istenmeyen bir durum olarak karşımıza çıkmıştır. Dalgacık dönüşümü sonucunda fazla olan katsayıları indirmek için geliştirilen algoritmada iyileştirmelere gidilebilir.

Günümüz teknolojisinde avuç içinin otomatik olarak tanınmasının gerektiği güvenlik erişim noktalarında bu uygulama kullanılabilir. Bu çalışmayla elde edilen sonuçlardan hareketle gelecekte benzer çalışmaların yapılmasına kılavuzluk yapmak ve öneriler vermektir.

KAYNAKLAR

- [1] <http://www.elektrik.gen.tr/icerik/fiziksel-ozelliklerden-yararlanarak-kimlik-tespit-etme> (10.10.2011).
- [2] Jain, A.K.; Ross, A.; Prabhakar, S.: “An Introduction to Biometric Recognition”, *IEEE Transactions on Circuits and Systems for Video Technology* (Special Issue on Image- and Video-Based Biometrics), Vol. 14, No 1, (2004).
- [3] Sönmez, E.B.; Özbek N.Ö.; Özbek Ö.: “Dalgacık Dönüşümüne Dayalı Çoklu Model Biyometrik Sistem”, İstanbul Bilgi Üniversitesi, Bilgisayar Bilimleri Bölümü, İstanbul (2000).
- [4] <http://www.sciencedirect.com/science/article/pii/S2090447910000067> (28.10.2011).
- [5] NabiyeV, V.V.: *Yapay Zeka İnsan Bilgisayar Etkileşimi*, Seçkin Yayıncılık, Ankara, Türkiye, (2010) 477-480.
- [6] Kong, J.; Lu, Y.; Wang, S.; Qi, M.; Li, H.: “A Two Stage Neural Network-Based Personal Identification System Using Handprint”, *Science Direct, Neurocomputing*, Vol. 71, (2008) 641-647.
- [7] Oral, L.: “Uyarlamalı Sinir-Bulanık Sınıflayıcı ile Parmak İzi Tanıma ve Dalgacık Tabanlı Momentlerle Özellik Çıkarma”, *Yüksek Lisans Tezi*, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta, Türkiye, (2010) 12-14.
- [8] Cetişli, B.: “El Yazısı Karakter Tanıma: Dalgacık Moment Özniteliklerinin Yenilenen ANFIS ile Sınıflandırılması”, *Doktora Tezi*, Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü, Eskişehir, Türkiye, (2005) 156.
- [9] Fu, K.S.: “Sequential Methods in Pattern Recognition and Machine Learning”, Academic Press, (1970) 1-13.
- [10] Senior, A.W.; Robinson, A.J.: “An Off-line Cursive Handwriting Recognition System”, *Proceedings of IEEE, Pattern Recognition and Machine Intelligence, PAMI*, Vol. 20, No 3, (1998) 309-322.

- [11] Nadal, C.; Suen, C.Y.: "Applying Human Knowledge to Improve Machine Recognition of Confusing handwritten Numerals", *Pattern Recognition*, Vol. 26, No 3, (1993) 381-389.
- [12] Özdemir, A.: "Dalgacık Dönüşümünü Kullanarak Ön Cepheden Çekilmiş İnsan Yüzü Resimlerinin Tanınması", *Yüksek Lisans Tezi*, Kahramanmaraş Sütcü İmam Üniversitesi Fen Bilimleri Enstitüsü, Kahramanmaraş, Türkiye, (2007) 1-27.
- [13] Türkoğlu, İ.: "Yapay Sinir Ağları ile Nesne Tanıma", Fırat Üniversitesi Fen Bilimleri Enstitüsü, (1996) 9-30.
- [14] Castelman, R.K.: "Digital Image Processing", Prentice Hall, Englewood Cliffs, New Jersey, USA, (1996).
- [15] Image Processing Toolbox for use with MATLAB, User's Guide, The Mathworks Inc., (1998) 7-18.
- [16] Metlek, S.: "Üretim Bandı Üzerindeki Renkli Silindir Parçalarının Makine Görme Sistemiyle Tanımlanması ve Sınıflandırılması", *Yüksek Lisans Tezi*, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Isparta, Türkiye, (2009) 13-14.
- [17] Russ, J.C.: "*The Image Processing Hand Book*", Third Edition, CRC Press, ISBN:0-8493-2532-3, (1999).
- [18] Bayram, B.: "Sayısal Görüntü İşleme", (2011), <http://www.yildiz.edu.tr/~bayram/sgi/saygi.htm> (15.10.2011).
- [19] Chang, C.; Huang, C.: "Edge Detection Based On Class Ratio", Shenkeng, Taipei, Taiwan, (2002).
- [20] Gonzales, R.C.; Woods, R.E.; "*Digital Image Processing*", 2nd Edition, ABD, ISBN: 0-13-094650-8, (2001) 1-750.
- [21] Karhan, M.; Oktay, M.O.; Karhan, Z.; Demir, H.: "Morfolojik Görüntü İşleme Yöntemleri ile Kayıslarda Yaprak Delen Hastalığı Sonucu Oluşan Lekelerin Tespiti", 6th *International Advanced Technologies Symposium*, Elazığ, Türkiye, Mayıs, (2011) 172-176.
- [22] Acar, U.; Bayram, B.: "Morfolojik Görüntü Filtreleri ile İkonos Görüntülerinden Otomatik Bina Çıkarımı", 12. *Türkiye Harita Bilimsel ve Teknik Kurultayı*, Ankara, Türkiye, Mayıs, (2009).

- [23] Türkoğlu, İ.; Arslan, A.; İlkay, E.: “An Intelligent System for Diagnosis of Heart Valve Diseases with Wavelet Packet Neural Networks”, *Computer in Biology and Medicine*, Vol. 33, No 4, (2003) 319-331.
- [24] Coşkun Ö.; Çömlekçi S.: “Wavelet Teorisinin Medikal Alana Uygulanması”, Dumlupınar Üniversitesi, Akademik Bilişim, Kütahya, (2007).
- [25] Gonzales, R.C.; Mahdavih, Y.: “Advances in Image Analysis”, SPIE Press, (1992).
- [26] Chen, C.F.; Hsiao, C.H.: “Haar Wavelet Method for Solving Lumped and Distributed-Parameter Systems”, Proceedings of IEEE, *Control Theory and Applications*, Vol. 144, No 1, (1997) 87-94.
- [27] Misiti, M.; Misiti, Y.; Oppenheim, G.; Poggi, J. M.: Wavelet Toolbox for use with MATLAB, User’s Guide, The Mathworks Inc., (2002).
- [28] Mallat S.G.: “A Theory for Multi resolution Signal Decomposition: The Wavelet Representation”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 11, No 7, (1989) 674-693.
- [29] Öztemel, E.: *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul, Türkiye, (2006) 29-30.
- [30] http://tr.wikipedia.org/wiki/Sinir_hücre (23.10.2011).
- [31] Haykin, S.: *Neural Networks: A Comprehensive Foundation*, Pearson Prentice Hall, 2nd Edition, (2005).
- [32] Gülbağ, A.: “Yapay Sinir Ağı ve Bulanık Mantık Tabanlı Algoritmalar ile Uçucu Organik Bileşiklerin Miktarısal Tayini”, *Doktora Tezi*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, Türkiye, (2006) 13-41.
- [33] Rosenblatt, F.: “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”, *Psychoanalytic Review*, Vol. 65, (1958) 386-408.
- [34] Bilgin, S.: “Kalp Hızı Değişkenliğinin Dalgacık Dönüşümü ve Yapay Sinir Ağları Kullanılarak Analizi”, *Doktora Tezi*, Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya, Türkiye, (2008) 46.
- [35] Rumelhart, D.E.; Hinton, G.E.; Williams, R.J.: “Learning Representations by Backpropagation Errors”, *Nature*, Vol. 323, (1986) 533-536.
- [36] Hopfield, J.J.; Tank D.W.: “Neural Computation of Decisions in Optimization Problems”, *Biological Cybernetics*, Vol. 52, (1985) 141-152.
- [37] Allahverdi, N.: “Nöron Ağları Mimarisi”, (2001),

<http://farabi.selcuk.edu.tr/egitim/ysa/english/ysa/bolum04.htm> (11.10.2011).

- [38] Elmas, Ç.: *Yapay Zeka Uygulamaları*, Seçkin Yayıncılık, Ankara, Türkiye, (2007) 88-137.
- [39] Kosko, B.: “Feedback Stability and Unsupervised Learning”, Proceedings of IEEE, International Conference on Neural Network, Vol. 1, (1988) 141-152.
- [40] Yu, P.F.; Xu, D.: “Palmpoint Recognition Based on Modified DCT Features and RBF Neural Network”, *Proceedings of the Seventh International Conference on Machine Learning and Cybernetics*, Kunming, Vol. 7, (2008) 2982-2986.
- [41] Yang, W.; Wang, S.; Jie, L.; Shao G.: “A New Palmpoint Identification Technique Based on a Two-Stage Neural Network Classifier”, *Computer Science and Software Engineering*, Vol.6 (2008) 957-960.
- [42] Lu, J.; Zhao, Y.; Xue, Y.; Hu, J.: “Palmpoint Recognition via Locality Preserving Projections and Extreme Learning Machine Neural Network”, *9th International Conference on Signal Processing, ICSP*, (2008) 2096-2099.
- [43] Ekinci, M.; Aykut, M.: “Palmpoint Recognition by Applying Wavelet-Based Kernel PCA”, *Journal of Computer Science and Technology*, Vol. 23, No 5, (2008) 851-861.
- [44] Kong, J.; Li, H.; Lu, Y.; Qi, M.; Wang, S.: “Hand-Based Personal Identification Using K-Means Clustering and Modified Zernike Moments”, Proceedings of IEEE, *International Conference on Natural Computation, ICNC*, IEEE, Vol. 5, (2007) 651-655.
- [45] Wong, K.Y.E.; Sainarayanan, G.; Chekima, A.: “Palmpoint Identification Using Wavelet Energy”, *International Conference on Intelligent and Advanced Systems*, (2007) 714-719.
- [46] Sun, D.; Qui, Z.; Li Q.: "Palmpoint Identification Using Gabor Wavelet Probabilistic Neural Networks", Proceedings of IEEE, *8th international Conference on Signal Processing, ICSP*, Issue: 0509, (2006) 1-4.
- [47] Zhou, X.; Peng, Y.; Yang, M.: "Palmpoint Recognition Using Wavelet and Support Vector Machines", *Pacific Rim International Conferences on Artificial Intelligence, PRICAI*, (2006) 385-393.
- [48] Wen, M.; Liang, Y.; Pan, Q.; Zhang, H.; “A Gabor Filter Based Fingerprint Enhancement Algorithm in Wavelet Domain”. *Communications and Information Technology, ISCIT*, Vol. 2, (2005) 1421-1424.

- [49] Han, C.C.; Cheng, H.L.; Lin, C.L.; Fan, K.C.: "Personal Authentication Using PalmPrint Features", *Pattern Recognition*, Vol. 36, (2003) 371-381.
- [50] Wu, X.; Wang K.; Zhang, D.: "Wavelet Based Palmprint Recognition", *Proceedings of IEEE, Conference on Machine Learning and Cybernetics*, Beijing, (2002) 1253-1257.
- [51] Funada, J.; Ohta, N.; Mizoguchi, M.; Tema, T.; Nakanishi, K.; Murai, A.; Sugiuchi, T.; Wakabayashi, T.; Yamada, Y.: "Feature Extraction Method for Palmprint Considering Elimination of Creases", *Fourteenth International Conference on Pattern Recognition*, Vol. 2, (1998) 1849 -1854.
- [52] Shobha, G.; Krishna, M.; Sharma, S.C.: "Development of Palmprint Verification System Using Biometrics", *Coden Ruxew Journal of Software*, Vol. 17, No 8, (2006) 1824-1836.
- [53] <http://www4.comp.polyu.edu.hk/~biometrics/MultispectralPalmprint/MSP.htm> (17.10.2011).
- [54] Zhang, D.; Guo, Z.; Lu, G.; Zhang, L.; Zuo, W.: "An Online System of Multi-spectral Palmprint Verification", *IEEE Transactions on Instrumentation and Measurement*, Vol. 59, No 2, (2010) 480-490.
- [55] Kachhi N.K.: "An Efficient Occlusion Invariant Palmprint Based Verification System", Bachelor Master Of Technology to The Department Of Computer Science And Engineering, Indian Institute of Technology Kanpur, (2009).
- [56] Sun, Z.; Tan, T.; Wang, Y.; Li, S.Z.: "Ordinal Palmprint Representation for Personal Identification", *Proceedings of IEEE, International Conference on Computer Vision and Pattern Recognition*, Vol.1, (2005) 279-284.
- [57] Hao, Y.; Sun, Z.; Tan, T.: "Comparative Studies on Multispectral Palm Image Fusion for Biometrics", *Proceedings of Asian Confererence on Computer Vision*, Vol. 2, (2007) 12-21.
- [58] Zhang, D.; Kong, W.K.; You, J.; Won, M.: "Online Palmprint Identification", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 25, No 9, (2003).
- [59] Lu, J.; Zhang, E.; Kang, X.; Xue, Y.; Chen, Y.: "Palmprint Recognition Using Wavelet Decomposition and 2D Principal Component Analysis", *International Conference on Communication Circuits and Systems*, (2006) 2133-2136.

- [60] Verim, V.: “Görüntü İşleme Yöntemleri ile Doku Sınırlarının Belirlenmesi”, *Yüksek Lisans Tezi*, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, Türkiye, (2005) 16-19
- [61] <http://bilgimce.com/ilkogretimkonu/fen/denetleyici-duzenleyici-sistemler2.html> (19.10.2011).
- [62] http://www.kliniken.de/lexikon/Medizin/Neurowissenschaften/Neuroinformatik/Kunstliches_Neuron.html (21.10.2011).
- [63] <http://www.ilkeymeseli.com/2011/10/yapay-sinir-aglarinin-mimarisi-ve-yapielemanlari/> (25.10.2011).
- [64] http://commons.wikimedia.org/wiki/Artificial_neural_network (29.10.2011).

ÖZGEÇMİŞ

Enes ÇELİK 26.03.1984'de Giresun'un Bulancak ilçesinde doğdum. 2005 yılında Bulancak Teknik Lisesi Bilgisayar Yazılımı bölümünü bitirdim. 2009 yılında Marmara Üniversitesi Teknik Eğitim Fakültesi Bilgisayar ve Kontrol Öğretmenliği programını bitirdim. 2009 yılında Marmara Üniversitesi Fen Bilimleri Enstitüsünde tezli yüksek lisansa Elektronik ve Bilgisayar Eğitimi Ana Bilim Dalı Bilgisayar ve Kontrol Eğitimi programında eğitimime başladım ve halen tez aşamasında devam etmekteyim.

T.C.
MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KABUL ve ONAY BELGESİ

Enes ÇELİK'in **GÖRÜNTÜ İŞLEMeye DAYALI AVUÇ İÇİ İZİNİN YAPAY SİNİR AĞI İLE TANINMASI** başlıklı Lisansüstü tez çalışması, M.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 28.11.2011 tarih ve 2011/27-07 sayılı kararı ile oluşturulan jüri tarafından Elektronik-Bilgisayar Eğitimi Anabilim Dalı Bilgisayar ve Kontrol Öğretmenliği Programında YÜKSEK LİSANS Tezi olarak Kabul edilmiştir.

Danışman : Yrd. Doç. Dr. Ali BULDU
1. Üye : Doç. Dr. Hakan KAPTAN
2. Üye : Dr. Abdülkerim ÖNCÜ

Marmara Üniversitesi
Marmara Üniversitesi
TÜBİTAK

(Handwritten signatures)

Tezin Savunulduğu Tarih: 05.12.2011

ONAY

M.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 13.12.2011 tarih ve 2011/28-02 sayılı kararı ile Enes ÇELİK'in Elektronik-Bilgisayar Eğitimi Anabilim Dalı Bilgisayar ve Kontrol Öğretmenliği Programında Yüksek Lisans (MSc.) derecesi alması onanmıştır.

(Handwritten signature)

Fen Bilimleri Enstitüsü Müdürü

Prof. Dr. Meral ÜNAL

