

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

**YEREL İKİLİ SİSTEME DAYALI PALM BASKI İLE İNSAN
TANIMLAMA METODU**

Hend Hadia Ali ALMEZOGHI

**Danışman
Jüri Üyesi
Jüri Üyesi
Jüri Üyesi
Jüri Üyesi**

**Doç. Dr. Aybaba HANÇERLİOĞULLARI
Prof.Dr. Erol KURT
Prof.Dr. Fatma KANDEMİRLİ
Dr.Öğt. Üyesi Javad RAHEBİ
Dr.Öğt. Üyesi Seçil KARATAY**

**DOKTORA TEZİ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI**

KASTAMONU – 2019

TEZ ONAYI

Hend Hadia Ali ALMEZOGHI tarafından hazırlanan " **Yerel İkili Sisteme Dayalı Palm Baskı İle İnsan Tanımlama Metodu** " adlı tez çalışması aşağıdaki jüri üyeleri önünde savunulmuş ve **oy birliği** ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı**'nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman

Doç. Dr. Aybaba HANÇERLİOĞULLARI
Kastamonu Üniversitesi

Jüri Üyesi

Prof. Dr. Erol KURT
Gazi Üniversitesi

Jüri Üyesi

Prof. Dr. Fatma KANDEMİRLİ
Kastamonu Üniversitesi

Jüri Üyesi

Dr. Öğr. Üyesi Javad RAHEBİ
Türk Hava Kurumu Üniversitesi

Jüri Üyesi

Dr. Öğr. Üyesi Seçil KARATAY
Kastamonu Üniversitesi

05/07/2019

Enstitü Müdürü

Doç.Dr.Nur BELKAYALI

TAAHHÜTNAME

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildirir ve taahhüt ederim.

Hend Hadia Ali ALMEZOGHI



ÖZET

Doktora Tezi

YEREL İKİLİ SİSTEME DAYALI PALM BASKI İLE İNSAN TANIMLAMA METODU

Hend Hadia Ali ALMEZOGHI
Kastamonu Üniversitesi
Fen Bilimleri Enstitüsü
Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Aybaba HANÇERLİOĞULLARI

Avuç içi tanıma son yıllarda bir araştırma alanı olarak değerlendirilmeye başlanmıştır. Bu tezde, avuç içi iziyle yerel ikili örüntülere (LBP) dayanan yeni bir metodun kullanıldığı bir insan tanımlama sistemi sunulmaktadır. İlk olarak avuç içi görüntüleri morfolojik tekniklerle ön işleme tabi tutulmuştur. Daha sonra bu görüntülerden öz nitelik çıkarımı yapılmıştır. Amaçlanan öz nitelikler için yerel ikili örüntüleri kullanılmıştır. Bu yaklaşım, her bireyden alınan 1, 2, 3 veya 4 görüntü ile 500 kişi üzerinde test edilmiştir. Metodumuzu ayrıca PCA metodu ile de kıyaslanmıştır. Sonuçlar, bu tezde önerilen yöntemin avuç içi tanımda etkin olduğunu ve yüksek bir performansa (%92) sahip olduğunu göstermektedir.

Anahtar Kelimeler: Tanıma ,Avuç İçi Baskı, LBP,Görüntü İşleme

2019, 69 sayfa
Bilim Kodu: 91

ABSTRACT

Ph. D. Thesis

HUMAN IDENTIFICATION METHOD WITH PALM PRINTING BASED ON LOCAL DUAL SYSTEM

Hend Hadia Ali ALMEZOGHI
Kastamonu University
Graduate School of Natural and Applied Sciences
Department of Material Science and Engineering

Supervisor: Assoc. Prof. Dr. Aybaba HANÇERLİOĞULLARI

Palm recognition is one of the research areas is considered in recent years. In this thesis, we introduce a new method for human palmprint identification system with local binary pattern. First, the palm images is preprocessed with morphological technics. Then the feature extraction is applied for images. We used local binary pattern (LBP) for desired features. This approach is tested for 500 people and there are 1, 2, 3 and 4 image from each people. Our method is compared with PCA method. The result shows that proposed method is efficiency and good performance (%92) for palmprint recognition.

Key Words: Recognition, Palm Printing, LBP, Image Processing

2019, 69 pages

Science Code: 91

TEŞEKKÜR

Tez çalışmam boyunca her türlü desteği ve imkânı sağlayarak değerli bilgilerinden yararlandığım, danışman hocam Doç. Dr. Aybaba Hancerlioğullarına teşekkür ediyorum. Türk Hava Kurumu Üniversitesi Elektrik-Elektronik Mühendisliği öğretim üyesi sayın Dr. Öğr. Üyesi Javad Rahebi her türlü analiz ve çalışmalarında bana sürekli desteklerinden dolayı teşekkür ediyorum. Aynı zamanda, bu araştırma ile ilgili birçok pratik ihtiyaçların karşılanması için, Fizik ve Malzeme Bilimi ve Mühendisliği Bölümü'nün öğretim görevlilerine ve araştırma görevlilerine teşekkür ediyorum. Kastamonu Üniversitesi'ndeki meslektaşlarıma ve Libya hükümetine destekleri için teşekkür ediyorum. Eşim ve aileme her zamanki desteklerinden dolayı, şükranlarımı ifade etmek isterim. Umarım bu çalışmanın sonuçları, gelecek çalışmalarda yeni araştırmalara katkıda bulunan kişilere faydalı olacaktır.

Hend Hadia Ali ALMEZOGHI

Kastamonu, Temmuz, 2019

İÇİNDEKİLER

	Sayfa
TEZ ONAYI.....	ii
TAAHHÜTNAME.....	iii
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR DİZİNİ	ix
ŞEKİLLER DİZİNİ.....	x
TABLolar DİZİNİ	xii
1. GİRİŞ	1
1.1. Arka Plan.....	1
1.2. Biyometrik ve Kullanım Amacı	1
1.3. El İzi ve Algoritmalar.....	3
1.4. Avuç İçi İzi Görüntülerinin Kısa Tarihi	5
1.5. Avuç İçi İzi Tarayıcıları	6
1.6. Avuç İçi İziyle Tanımlamanın Kullanım Alanları	7
1.7. Avuç İçi İziyle Tanımlamanın Avantajları.....	8
1.8. Avuç İçi İzinin Özellikleri.....	8
2. LİTERATÜR TARAMASI.....	10
2.1. Arka Plan.....	10
2.2. Önceki Çalışmalar	10
2.2.1. Örüntü Tanıma.....	11
2.2.2. Görüntü İşlemenin Temelleri.....	13
2.2.3. Görüntü Elde Etmek	16
2.2.4. Görüntü Güçlendirme / İyileştirme.....	17
2.2.5. Görüntü Onarma	17
2.2.6. Renkli Görüntü İşleme.....	17
2.2.7. Sıkıştırma.....	18
2.2.8. Morfolojik İşleme	19
2.2.9. Bölüntüleme.....	22
2.2.10. Veri Tabanı	22
2.3. Görüntü İşlemede Kullanılan Teknikler.....	22
2.3.1. Gölge Düzeltme	22
2.3.2. Normalizasyon.....	22
2.3.3. Eşikleme	23
2.4. Görüntü Güçlendirme ve Onarma Metotları.....	24
2.4.1. Keskinlik Filtresi	24
2.4.2. Gürültü Giderme.....	25

2.4.3. Kenarların Bulunması.....	26
2.5. Görüntü İşlemenin Uygulama Alanları.....	28
2.6. Histogram.....	28
2.6.1. Histogram Eşitleme	29
3. METOTLAR.....	31
3.1. Yapay Sinir Ağları.....	31
3.1.1. Biyolojik Sinir Hücreleri	31
3.1.2. Yapay Sinir Hücresi.....	33
3.1.3. Aktivasyon Fonksiyonu	34
3.2. Yapısına Göre Yapay Sinir Ağları	35
3.2.1. İleri Beslemeli Tek Katmanlı Yapay Sinir Ağları	36
3.2.2. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları.....	37
3.2.3. Geri Beslemeli Ağlar	38
3.2.4. Yapay Sinir Ağlarında Denetimli Öğrenme	39
3.2.5. Yapay Sinir Ağlarında Denetimsiz Öğrenme.....	39
3.3. Avuç İçi Tanıma Sistemleri.....	40
3.3.1. Avuç İçi Görüntüsü Veri Tabanları	42
4. DENEY SONUÇLARI	46
4.1. Yerel İkili Örüntü (LBP)	46
4.1.1. Avuç İçi Görüntüsü Veri Tabanları	46
4.1.2. Düzgün Yerel İkili Örüntü.....	47
4.1.3. Görünüm Histogramı	48
4.2. Görüntü Veri Tabanı	48
4.3. Simülasyon Sonuçları.....	49
5. SONUÇ	62
KAYNAKLAR	64
ÖZGEÇMİŞ	68

SİMGELER VE KISALTMALAR DİZİNİ

ANN	Yapay Sinir Ağı
ATM	Otomatik Vezne Makinası
CASIA	Çin Bilimler Akademisi, Otomasyon Enstitüsü (The Chinese Academy of Sciences Institute of Automation)
CBPA	Çekirdek Tabanlı Bileşen Analizi
CCD	Yükten Bağlaşımlı Aygıt
CMOS	Tümler Metal Oksit Yarıiletken
DNA	Deoksiribo Nükleik Asit
FBI	Federal Soruşturma Bürosu (ABD)
ICS	Hindistan Kamu Hizmetleri
IITK	Hindistan Teknoloji Enstitüsü Kanpur
INCITS	Uluslararası Bilişim Teknolojisi Standartları Komitesi (International Committee for Information Technology Standards)
JPEG	Birleşik Fotoğraf Uzmanları Grubu (Joint Photographic Experts Group)
PCB	Baskılı Devre Kartı
PIN	Kişisel Kimlik Numarası
RMS	Ortalama Karekök

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1. Fiziksel Tanıma Sistemi Şeması	2
Şekil 1.2. Parmak İzlerinin Toplanması	5
Şekil 1.3. Bay Konai' nin Avuç İçi Parmak ve İzleri.....	6
Şekil 1.4. Bir Kart Üzerinde Bir CCD Sensörü	7
Şekil 1.5. Avuç İçi Tanımayla Kimlik Doğrulamanın ATM' de Uygulanışı....	8
Şekil 1.6. Avuç İçi İzinde Çizgi Desenleri.....	9
Şekil 2.1. Öznitelik Çıkarımı ve Sınıflandırılması.....	12
Şekil 2.2. Somur Bir Görüntü ve Ona Karşılık Gelen Nümerik	14
Şekil 2.3. Bir Görüntünün Dijitalize Edilmesi	15
Şekil 2.4. Görüntü üzerinde sürekli bir sayma vardır. [m, n] bir noktanın konumu, o noktanın parlaklığı vb. değerlerini tanımlamaktadır.....	15
Şekil 2.5. Görüntülerin Dijital Olarak İşlenmesi	16
Şekil 2.6. Farklı Gri Seviyesinde Görüntüler.....	18
Şekil 2.7. Morfolojik Erozyon ve Genleşme.....	20
Şekil 2.8. Morfolojik Açılış ve Kapanış	21
Şekil 2.9. Eşik Değeri.....	23
Şekil 2.10. Eşiklemeden Önce (a) ve Sonra (b)	24
Şekil 2.11. Orijinal Görüntüyle Laplas Keskinlik Filtresi Uygulanmış Görüntünün Karşılaştırılması; Orijinal Görüntü (a), Laplas Görüntü (b)	25
Şekil 2.12. Farklı Tekniklerle Gürültü Giderme İşlemlerinin Karşılaştırılması .	26
Şekil 2.13. [3x3] Süzgeç Matrisi.....	26
Şekil 2.14. Gri Tonlu Bir Görüntüde Yatay Doğru.....	27
Şekil 2.15. Bir Görüntünün Histogramı	29
Şekil 2.16. Avuç İçi Görüntüsünün Histogram Eşitlemesi	30
Şekil 3.1. Bir Sinir Hücresi ve Bölümleri	32
Şekil 3.2. Yapay Sinir Hücresinin Genel Yapısı.....	33
Şekil 3.3. Doğrusal Aktivasyon Fonksiyonu.....	34
Şekil 3.4. Sigmoid Aktivasyon Fonksiyonu	35
Şekil 3.5. Tanjant-Sigmoid Aktivasyon Fonksiyonu	35
Şekil 3.6. İleri Beslemeli Tek Katmanlı Yapay Sinir Ağı.....	36
Şekil 3.7. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı	37
Şekil 3.8. Hopfield Geri Beslemeli Ağ	38
Şekil 3.9. Yapay Sinir Ağında Denetimli Öğrenme.....	39
Şekil 3.10. Avuç İçi Tanıma ve Eğitim Basamakları Blok Şeması	41
Şekil 3.11. Avuç İçi Görüntüleme Sistemi.....	42
Şekil 3.12. PolyU Avuç İçi Görüntü Elde Etme Cihazı.....	44
Şekil 3.13. PolyU Çok Bantlı Avuç İçi Görüntüleri	45
Şekil 3.14. PolyU ROI Avuç İçi Görüntüleri	45
Şekil 4.1. Görüntü Alma Cihazı ve Cihazla Alınan Görüntülerden Örnekler ..	49
Şekil 4.2. Ön İşleme Tabii Tutulmuş Bazı Avuç İçi Görüntülere Örnekler	49
Şekil 4.3. Kişi Başı Eğitim Amaçlı Kullanılan Görüntü Sayısına Bağlı Olarak Gerçekleşen Doğru Tanımlama Yüzdesi.....	52
Şekil 4.4. Döndürmeyle Değişmeyen Düzgün Örüntü R=3, p=24	53
Şekil 4.5. Döndürmeyle Değişmeyen Düzgün Örüntü R=2, p=16	54

Şekil 4.6. Döndürmeyle Değişmeyen Düzgün Örüntü $R=1$, $p=8$	55
Şekil 4.7. Döndürmeyle Değişmeyen $R=3$, $p=24$	56
Şekil 4.8. Döndürmeyle Değişmeyen $R=2$, $p=16$	57
Şekil 4.9. Döndürmeyle Değişmeyen $R=1$, $p=8$	58
Şekil 4.10. Düzgün $R=3$, $p=24$	59
Şekil 4.11. Düzgün $R=2$, $p=16$	60
Şekil 4.12. Düzgün $R=1$, $p=8$	61



TABLÖLAR DİZİNİ

Tablo 1.1. Biyometrik sistem öznitelikleri.....	Sayfa 2
---	-------------------



1. GİRİŞ

1.1. Arka Plan

İnsanların ayırt edici pek çok öznelikleri bulunmaktadır. Biyometrik sistemlerde, insanların benzersiz özellikleri bilgisayar yardımıyla ölçümlenip veri tabanına kaydedilir. Daha sonra kimlikleri doğrulanıp onaylanır ve ilgili ortamlara erişimleri sağlanır. Günümüzde her anlamda güvenilir denebilecek bir kimlik tanımlama çözümsüz kalan bir konudur ve halen çözümü beklenmektedir.

Bu tezde avuç içi görüntülerini kullanarak kimlik tanımlama konusu incelenmiştir. Hayatın her alanındaki günlük uygulamalar her bir bireyi tanımlamak için insan biyometrisine ihtiyaç duymaktadır ve bu bağlamda düşük çözünürlüklü avuç içi izi tanımlamanın kullanım alanları her geçen gün artmaktadır. Avuç içi izi, insan vücudunun biyometrik bir özelliği olarak iyi bilinmektedir. Avuç içi çizgilerin kırıklığı veya düzlüğü özneliklerini belirler. İnsan vücuduna dair başka biyometrik özelliklere örnek olarak, iris tabakası damarları, parmak izi, parmak damarları, avuç içi damarları ve insan yüzü ile tanımlama sayılabilir. Bir insana ait biyometrik özellikleri kullanarak o insanı tanımlamak için farklı seçenekler mevcuttur ancak avuç içi izinin kullanmanın belli başlı bazı avantajları bulunmaktadır. Avuç içi izinin kararlı ve zengin çizgi öznelikleri vardır. Distorsiyon düşüktür, ayrıca düşük çözünürlükteki görüntülerle yüksek oranlı performans elde etmek mümkündür.

1.2. Biyometrik ve Kullanım Amacı

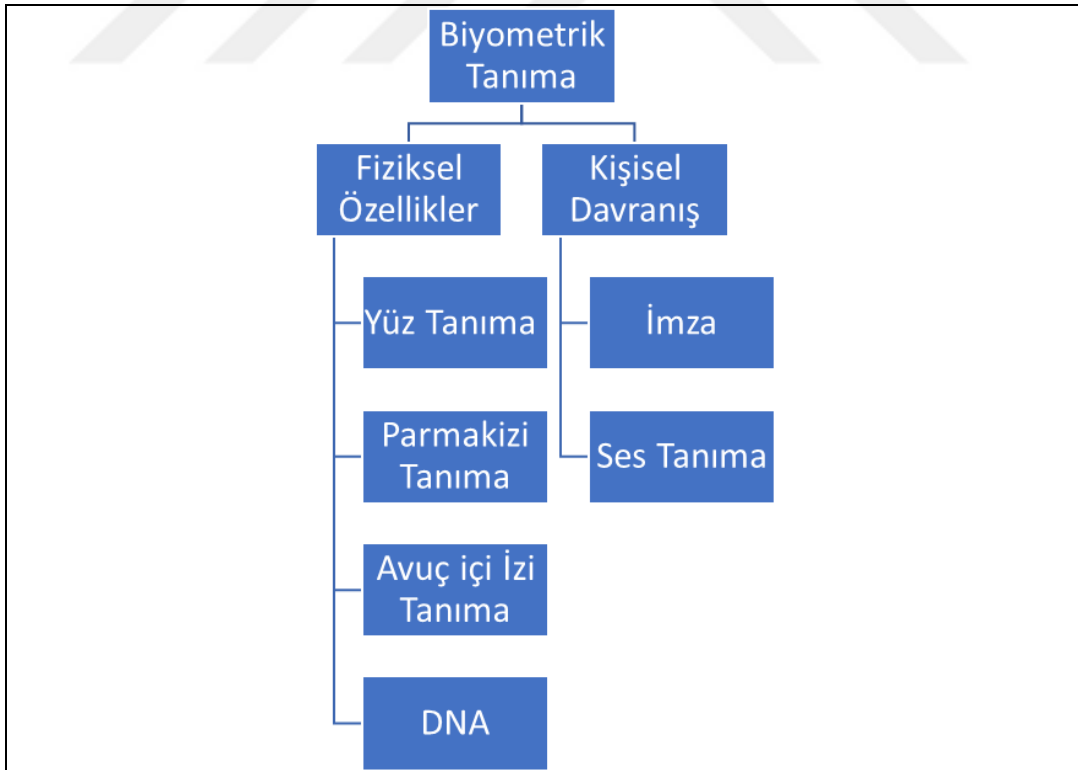
Biyometrik, biyolojik veri kullanımıyla kimlik doğrulamasıdır. Kimlik doğrulamak için oldukça güçlü bir yöntemdir. Biyometrinin genel amacı, kopyalanamayacak veya taklit edilemeyecek özneliklerin kullanımıyla insanları birbirinden ayırt etmektir. Diğer metotlara göre daha az risklidir çünkü, insanların fiziksel özelliklerini değiştirmesi, kaybetmesi veya unutması söz konusu değildir. Biyometrik ölçü birimi olarak tanımlanan bu özneliklerin şifre veya parola olarak kullanımı, INCITS (International Committee for Information Technology Standards,

Uluslararası Bilişim Teknolojisi Standartları Komitesi) tarafından belirlenen uluslararası standartlar çerçevesinde gerçekleşmektedir. Biyometrik sistem öznelikleri tablo 1.1’de gösterilmektedir.

Tablo 1. 1. *Biyometrik sistem öznelikleri*

Biyometrik Sistemlerin Öznelikleri
Evrensellik: Tüm insanlarda aynı biyometrik özneliklerin tanımlanabilir olması.
Benzersizlik: Her bir bireyin farklı olması.
Sürekli: Söz konusu özneliklerin zaman içinde değişmezlik özelliği.
Kullanılabilirlik
Kabul edilebilirlik: Bireylerin özelliklerinin kabul edilmesi.

Biyometrik tanıma sistemlerinin çeşitleri ve özellikleri Şekil 1.1’de verilmiştir.



Şekil 1. 1. Fiziksel tanıma sistemi şeması

DNA (Deoksiribo Nükleik Asit), iris, parmak izi, avuç içi izi, ve yüze ait öznitelikler fizyolojik özniteliklere, mimikler, imza ve ses ise kişisel davranışa ait özniteliklere dahildir. Fizyolojik veya davranışsal özellikler ölçümlenirken, yaş, sağlık veya kişinin ruh hali gibi faktörlerin bu ölçümlerde bertaraf edilmesi gerekir. Mevcut kişi tanımlama sistemleri yeterli değildir, kullanıcı adıyla beraber PIN (kişisel kimlik numarası) veya plastik kartların kullanımı da külfetli olup yeterince güvenli değildir. İdeal bir biyometrik tabanlı kişi tanımlama sistemi, bireyin kimliğini eşsiz olarak teşhis etmeli veya veri tabanından tanımlamayı doğru, güvenilir ve son derece verimli bir şekilde tasdik etmelidir. Bu sebeple sistemin kolay uygulanabilir olması, alıcılarda düşük seviyede bozunum, çevresel faktörler veya sinyal karışması gibi durumlarla başa çıkabilmesi ve zaman içinde değişmezlik özelliğine sahip olması gerekir. En yaygın kullanılan biyometrik öznitelik parmak iziyken en güvenilir olanı da iristir.

Bu tezde fiziksel özniteliklerden biri olan avuç içi izi tanıma sistemi ele alınmıştır. Avuç içi takibinin diğer biyometrik özniteliklere kıyasla bazı avantajları bulunmaktadır. Gerekli olan görüntülerin toplanması düşük maliyetli bir işlemdir ve görüntüler herhangi bir bozunuma yol açmaz; yanlış onaylama veya yanlış reddetme oranları kabul edilebilir seviyededir. Bir sistem için hatalı kabul veya ret oranları, hatalı kabul veya ret için gerçekleşen toplam girişim sayısının bir kısmıdır [1].

1.3. El İzi ve Algoritmalar

El izi tanıma, var olan parmak izi için eşleştirme algoritmaları sağlar: her iki biyometrik sistem, kişisel bilgilere dayanır ve bu kişisel bilgiler çizgiler üzerinde görülen etkilerle temsil edilir. FBI yetkilileri tarafından yapılan istatistik çalışmaları, el izi tanımlamasının, daha popüler olan parmak izi tanımlama sistemlerini tamamlayan bir biyometrik sistem olduğu gerçeğini yansıtmaktadır. Bu çalışmalarda ortaya konan bulgular, olay yerinde suçluların geride bıraktığı izlerin %70'inin parmak izi, %30'unun ise avuç içi izi olduğunu göstermektedir. Avuç içi izi tanıma algoritmaları otomatikleştirildiğinde, işleme kapasitesinin ve canlı tarama teknolojilerinin eksikliği nedeniyle, parmak izi tanıma algoritmalarına göre daha yavaş çalışır. 1994'ten beri parmak izi ve avuç içi izini beraber kullanan tanımlama

sistemlerine ilgi artmaktadır. Avuç içi izi tanımlama, parmak izinde olduğu gibi avuç içi kıvrımlarda saklanan muazzam bilgiye dayanmaktadır. Avuç içi izi ya da parmak izi, avucun yüksek ve noktalı kısımlarını temsil eden, belli bir sırası olan koyu çizgilerden ve bu çizgiler arasındaki çukurları temsil eden beyaz çizgilerden oluşur. Avuç içi izi tanıma teknolojisi bu özelliklerin bazılarını kullanmaktadır.

Avuç içi izinin algılanması ve doğrulanması algoritmaları, parmak izi tanımlamada kullanılan algoritmalara benzer. Bu algoritmalar temel olarak, öznitelik noktalarından (ufak ayrıntılar) ve parmak veya avuç içindeki kabarık çizgilerden kaynaklanan korelasyona dayanır. Temel olarak korelasyon-tabanlı eşleştirme, iki görüntüdeki birbiriyle uyumlu çizgilerin tespit edilmesi için aynı anda iki avuç içi görüntüsü birden alınmasıdır. Öznitelik-tabanlı eşleştirme ise avuç içi görüntüsündeki belirli öznitelik noktalarının lokasyon (konum) ve oryantasyon bilgilerinin belirlenmesi ve bu bilgilerin kıyaslanmasına dayanır. Çizgi-tabanlı eşleştirme tekniği avuç içi izini tasnif ederken öznitelik noktası analizini ve buna ek olarak çizgilerin geometrik özelliklerini ve desen analizini kullanır.

Korelasyon-tabanlı algoritmalar diğer metotlardan daha hızlı çalışır, ancak görüntüdeki bozulmalara ve döndürmeden kaynaklı değişikliklere karşı daha az toleransları vardır. Öznitelik-tabanlı algoritmalarda yüksek kalitede görüntüye ihtiyaç duyulur ve kullanıcının dokusal veya görsel özelliklerinden yararlanılmaz. Son olarak çizgi-tabanlı algoritmalarda ise, iyi kalitede görüntü elde edebilmek için yüksek çözünürlüklü bir sensörün yanı sıra, öznitelik noktalarından önemli ölçüde daha az sayıda olan karakteristik çizgilerin ayırt edici özelliklerine gereksinim duyulur. Parmak izi için de bu tekniklerin olumlu ve olumsuz yanları aynı ölçüde geçerlidir [2].



Şekil 1.2. Parmak izlerinin toplanması [3]

1.4. Avuç İçi İzi Görüntülerinin Kısa Tarihi

John Herschel'in oğlu olan William James Herschel bir astronomdu. Babası kendisinden astronomi dışında bir kariyere yönelmesini istedi, bunun üzerine o da Doğu Hindistan Kumpanyası'nda çalışmaya başladı ve 1853'te Bengal'e tayin edildi. 1858'deki Hint İsyanından sonra ise Herschel, ICS'nin (Hindistan Kamu Teşkilatı, Indian Civil Service), bir üyesi haline geldi ve Jungipoor'da görevlendirildi.

1858'de orada ikamet etmekte olan Bay Konai ile yol yapım malzemelerinin imalatı için bir kontrat yaptı. Daha sonra imzasını inkar etmesini önleyebilmek için Herschel, Şekil 1.3'teki görülen belgeye Konai'nin el izini bastırdı. Herschel el izlerini tecrübe etmeye devam etti ve kısa zaman sonra parmakları kullanmanın gerekli olduğunun farkına vardı. Arkadaşlarından ve ailesinden parmak izleri aldı ve elde ettiği sonuçlara göre parmak izleri zaman içinde değişim göstermiyordu. Bengal Valisi, imzaların taklit edilmesinin veya kontratların daha sonra inkar edilmesinin önüne geçebilmek için resmi evraklarda parmak izi kullanılması önerisinde bulundu ancak bu öneri kabul görmemiştir. [4].

Artık insanlar suç vakalarını aydınlatmak için avuç içi izleri ve parmak izlerini kullanıyorlar; örneğin olay yerinde herhangi bir obje üzerinde parmak izi veya avuç içi izi bulunursa bu izler öncelikle veri tabanında kayıtlı sabıkalı kişilerin parmak veya avuç içi izleriyle kıyaslanıyor. Ayrıca resmi evraklarda ve sağlık


uygulamalarında da insanlar bu izleri kişinin imzası gibi kullanıyorlar; dolayısıyla avuç içi iz görüntülerinin kullanılabileceği bir çok saha vardır.



Şekil 1. 3. Bay Konai'nin avuç içi ve parmak izleri [4]

1.5. Avuç İçi İzi Tarayıcıları

Avuç içi izi tarayıcılarında genellikle CCD (yükten bağımlı aygıt) sensörleri kullanılır. CCD sensöründe, sensörün piksellerine düşen ışık (yük) devrenin bir veya sadece birkaç çıkış düğümünden iletilir. Yükler, voltaj seviyelerine dönüştürülür, tamponlanır ve analog bir sinyal olarak gönderilir. Bu sinyal daha sonra yükseltilir ve sensörün dışındaki bir A/D dönüştürücüsüne dönüştürülür. CCD teknolojisi özellikle kameralar için geliştirilmiştir ve CCD sensörleri 30 yıldan uzun süredir kullanılmaktadır. Geleneksel olarak, CCD sensörlerinin, CMOS (Tümler Metal Oksit Yarıiletken) sensörlerine göre; daha iyi ışık hassasiyeti ve daha az parazit gibi bazı avantajları vardır. Şekil 1.4'te bir PCB (Baskılı Devre Kartı) üzerinde bir CCD sensörü görülmektedir [5].




Şekil 1.4. Bir kart üzerinde bir CCD sensörü [5]

1.6. Avuç içi İziyle Tanımlamanın Kullanım Alanları

- Bankacılık Sektörü; kimlik doğrulama, internet bankacılığı, ATMler (Otomatik Vezne Makinası) ve kredi kartı başvuruları. Şekil 1.5'te ATM'de avuç içi izi kullanarak kimlik doğrulama yapan bir cihaz örneği görülmektedir.
- Sağlık Sektörü; hasta kimliğinin doğrulanması, polikliniklerde hasta takibi, tıbbi muayene prosedürleri.
- Havacılık Sektörü; Banka işlemleri, bilet satışları, uçağın giriş/çıkış işlemleri.
- Sigorta Sektörü; Kimlik tespiti, hizmet tanımlaması.
- Bilişim Sektörü; Ağ ve veri güvenliği, kullanıcı doğrulama.
- Eğitim Sektörü; Öğrenci takibi, bilgi paylaşımı.
- İnşaat Sektörü; Akıllı binalar, güvenlik.
- Kamusal Uygulamalar; Adli vakalar, Vergi.
- Özel Eğitim Uygulamaları; Kimlik doğrulama, hizmet güvenliği, ödeme planı.
- Güvenlik; Kamu güvenliği, güvenlik takibi.
- Personel takibinin ve sınırlı erişimin söz konusu olduğu bütün sektörler.

Yukarıda belirtildiği gibi avuç içi tanıma sistemlerinin çok geniş bir kullanım sahası bulunmaktadır.



Şekil 1. 5. Avuç içi tanımayla kimlik doğrulamanın ATM’de bir uygulaması [6]


1.7. Avuç İçi Tanımlamanın Avantajları

- Her insanın avuç içi izi tektir; dolayısıyla avuç içi tanımayla kimlik doğrulama, mükemmel bir kimlik doğrulama yöntemidir.
- Avuç içi iziyle tanıma sisteminin güvenilirliği çok yüksektir çünkü çalınması imkansızdır.
- Avuç içi izi sağlık, havacılık, eğitim, inşaat ve bankacılık gibi pek çok sektörde kullanılmaktadır. Dolayısıyla avuç içi iziyle tanımlama kullanıcı dostu bir sistemdir.
- Avuç içi iziyle tanıma sistemi küçük ve portatiftir.
- Avuç içi izi tanıma sisteminin kullanılması temas gerektirmediği için hijyeniktir.

1.8. Avuç İçi İzinin Öznitelikleri

Avuç içi izi karardır ve zengin çizgi özniteliklerine sahiptir; avuç içinde üç tür çizgi deseni görünür. Bunlar temel çizgiler, kırışıklıklar ve kabartılardır. Temel çizgiler, avuç içi izinde bulunan en uzun ve en geniş çizgilerdir. Temel çizgiler, avuç içi üzerindeki en ayırt edici yön özelliklerini tayin ederler. Çoğu insanın avuç

içinde üç temel çizgi bulunur ve bu çizgiler genellikle kalp çizgisi, kafa çizgisi ve yaşam çizgisi olarak adlandırılır. Kırışıklıklar, daha ince ve daha düzensiz çizgi desenleri olarak kabul edilirler. Kırışıklıklar, özellikle de temel çizgiler etrafında aşık olan kırışıklıklar, avuç içi izinin ayırt edilebilirliğine de katkıda bulunabilirler. Öte yandan, kabartılar ise avuç içi yüzeyi boyunca dağılmış ince çizgi dokusudur. Kabartı özneliği, bireyi ayırt edebilmek için daha az kullanışlıdır çünkü kötü görüntüleme kaynağınca algılanamazlar. Şekil 1.6'da avuç içi izindeki çizgiler görülmektedir [7].



Şekil 1. 6. Avuç içi izinde çizgi desenleri [7]

2. LİTERATÜR TARAMASI

2.1. Arka Plan

Bu tezde görüntü işleme konusuna ve bu alanda daha önce geliştirilmiş metotlara belli bir seviyede incelenmiştir. Söz konusu metotları birbiriyle kıyaslanıp ve bu metotlar üzerine yeni matematiksel modeller ve iş-akış algoritmaları geliştirilmiştir.

2.2. Önceki Çalışmalar

Avuç içi izinin özneliklerine dayalı olarak yapılan tanımlama ve doğrulamada kesin bir çözüme kavuşturulamamış problemler halen mevcuttur. Bu problemlerin çözümüne odaklanan, farklı yollarla geliştirilmiş araştırmalar bulunmaktadır. Parmak izlerinde olduğu gibi, burada da genellikle Gabor filtresi, dalgacık dönüşümü, Fourier dönüşümü vb. yöntemler kullanılmıştır. Parmak izi ile kıyaslandığında, avuç içi izleri çok fazla çizgiye sahiptir ve tanımlamada daha yüksek bir performans gösterir. Parmak izleri yüksek çözünürlük gerektirse bile, palindromik izler bunu gerektirmez ve düşük çözünürlükte tanımlama daha kolaydır. Literatürde, öznelik çıkarma ve tasnif etmede oryantasyon yöntemlerinin, dalgacık dönüşümünün ve yapay sinir ağlarının kullanıldığı görülmektedir.

Fei ve diğ. 2016'da [8], Yarım Oryantasyon Kodu üzerine çalıştılar. Avuç içi izinde pek çok aslında eğri olan "doğru" bulunmaktadır. Bu eğriler üzerindeki noktaların çoğunlukla iki tane baskın olan doğrultusu bulunmaktadır. Dahası, görünüşe göre avuç içi izinde kesişen pek çok kırıklılık da bulunmaktadır. Bu kırıklılıkların kesişme noktasında baskın olan iki doğrultu vardır. Avuç içi izlerin çıkarılması ve tanımlanması için ikili Yarım-Oryantasyon-Kodu-tabanlı basit ve etkin bir metot önerilmiştir. Bu metotta, avuç içi izinin doğrultusunun elde edilmesi için "yarım Gabor" filtrelerinden oluşan bir yığın/küme tanımlanır. Tek baskın oryantasyonla kıyaslandığında, ikili yarım-oryantasyon avuç içi izinin

global oryantasyonunu daha net karakterize edebilir. Üç farklı avuç içi veri tabanında yapılan kapsamlı deneyler sonucu önerilen metodun parmak izi tanımlama ve doğrulamada gelecek vaat eden bir performansın olduğu, dahası bu performansın oryantasyon özelliklerine dayalı olarak geliştirilen diğer metotlardan daha iyi olduğu da görülmüştür.

Wei Jia ve diğ. 2014'te, avuç içi izi tanıma için yönlendirilmiş doğruların histogramı üzerine çalıştılar. Geliştirdikleri metod ışıklandırmadaki değişikliklere karşı duyarsız ve küçük çaplı dönüştürme etkilerine karşı da bir derece kararlıydı [9].

2008'de Yu, çalışmasında avuç içi tanımda Değiştirilmiş Kesikli Kosinüs Dönüşümü-tabanlı öznitelik çıkarma yaklaşımını kullandı. Burada tasnif için radyal-tabanlı yapay sinir ağları kullanılmaktadır. Radyal-tabanlı yapay sinir ağlarından ayrıca, çok fazla olan verinin kabul edilebilir derecede küçültülüp eğitime verileri olarak kullanılmasında da faydalanılır [10].


2008'de Yang'ın önerdiği sistemde ise, avuç içinin geometrik öznitelikleri ve desen özellikleri, CBPA (çekirdek tabanlı bileşen analizi) yardımıyla elde edilir. Daha sonra ANN ,yapay sinir ağları uygulanarak, çok fazla olan veriden küçük bir veri kümesi seçilerek avuç içinin geometrik özellikleri elde edilmiştir. Tanımlama aşamasında radyal-tabanlı yapay sinir ağları kullanılmıştır. [11].

2.2.1. Örüntü Tanıma

Son yıllarda bu alana odaklanmış pek çok insanın yaptığı çalışmalar neticesinde örüntülerden ayırıştırıcı özniteliklerin elde edilmesi mümkün olmuştur. Çalışılan örüntülerin bazıları karakterler, semboller, resimler, ses dalgaları, elektrokardiyogramlar olarak sayılabilir. Tanımlama genellikle çok kompleks olduğu, çok fazla hesaplama veya aşırı yüklenme gibi problemler söz konusu olduğu ve elde edilen neticeyi yorumlamak zor olduğu için bilgisayar kullanımı kaçınılmazdır. Her halükârda izlenecek yol, örüntüye çıkmaktadır. Bu durumda, her bir örüntü sınıfı için sadece bir örüntü olacak şekilde, örüntüler kümesi bir

bellekte depolanır. Tam olarak ne kadar örüntü sınıfının söz konusu olacağı kesin olarak bilinemez. Burada sınıflandırma önceden belirlenmiş bir eşleştirme kriteri veya benzerlik kriterine dayanmaktadır. Bir örüntüyü başka bir örüntünün tamamıyla kıyaslamaktansa, sadece belli öznitelikleri kıyaslamak çoğu zaman daha hızlıdır ve daha kesin sonuçlar verir. Bu sebeple örüntü tanıma işlemi, öznitelik çıkarımı ve sınıflandırılma iki ayrı aşamada incelenmiştir [12].

Şekil 2.1, öznitelik çıkarımı, örüntü üzerinde bazı ölçümlerin yapılması ve sonuçların bir öznitelik vektörüne dönüştürülmesini göstermektedir.



Şekil 2. 1. Öznitelik çıkarımı ve sınıflandırılması [13]

Bu öznitelikler eldeki problemin doğasına göre çok farklılıklar gösterebilir. Ayrıca özniteliklerin önem derecesi veya maliyetleri farklı olabilir. Bu sebeple, öznitelikler sınıfları birbirinden ayırt edecek ve maliyetleri düşük olacak şekilde seçilmelidir.


Her bir örüntü tanıma problemi için öznitelikler farklıdır. Sınıflandırma aşamasında çıkarılan özniteliklere göre, eldeki objenin hangi sınıfa ait olduğuna karar verilir. Her ne kadar özneliğin elde edilmesi örüntü tanımlama problemine göre farklılık göstermese de, ayırıştırıcılar/sınıflandırıcılar belirli kategorilere ayrılırlar [14].

Örüntü eşleştirme en yaygın sınıflandırma yöntemidir. Bu yöntemde, görünümün her bir pikseli bir öznitelik olarak kullanılır. Sınıflandırma, görüntü girdisini tüm örüntü sınıflarıyla karşılaştırarak yapılır. Karşılaştırma, girdi bilgisi ile örüntü sınıfı arasında bir benzerlik ölçümü verir; örüntü sınıfı ile girdi görüntüsünün

piksel temelli denkliği benzerlik ölçümünü arttırırken, karşılık gelen piksellerde farklılıklar aynı ölçümü azaltır. Tüm örüntüler ile karşılaştırıldıktan sonra, en çok benzerlik ölçümünü veren örüntünün sınıfı seçilir. Yapısal sınıflandırma teknikleri, örüntüleri sınıflandırmak için yapısal özniteliklere ve belirli karar kurallarına dayalıdır. Örneğin; karakterlerdeki, çukurlardaki ve eğimlerdeki çizgi tipleri yapısal özniteliklerdir. Çıkarılan bu öznitelikler kullanılarak kural tabanlı bir sınıflandırma yapılır. Örüntü tanıma sistemlerinin çoğu, yanlış sınıflandırmayı minimize etmek için matematiksel temellere dayandırılmıştır. Bu sistemler piksel tabanlıdır ve yapısal öznitelikleri kullanırlar. Örnek olarak Gabor öznitelikleri, kontur özellikleri, gradyan özellikleri ve histogramlar gösterilebilir. Sınıflandırıcı olarak ise, ayırtaç işlevi sınıflandırıcıları, Bayes sınıflandırıcıları ve yapay sinir ağları kullanılabilir [15].


2.2.2. Görüntü İşlemenin Temelleri

Karanlığı işlemek ve görüntüleri kullanabilmek için en basit ifadesiyle girdi ve çıktıya uygun olan iki cihaz gereklidir; görüntüyü dijitalize eden ve görüntüleyen cihazlar. Bu cihazların doğası gereği, görüntüler bilgisayar analizinin doğrudan kaynağını oluşturmazlar. Bilgisayarlar görüntü verileri yerine nümerik değerlerle çalıştığından, işleme başlamadan önce görüntünün nümerik bir formata dönüştürülmesi gerekir. Şekil 2.2'de, somut bir görüntünün sıralanmış bir sayı dizisince nasıl temsil edilebileceği gösterilmektedir. Somut görüntü "biçim elemanları" veya "piksel" olarak adlandırılan küçük bölgelere ayrıştırılmıştır. Yine Şekil 2.2'de en kapsamlı alt bölüm şeması olan dikdörtgen kafes cihazı da gösterilmiştir. Dijital görüntüde, her piksele atanan değer o noktanın parlaklığına göre belirlenir.

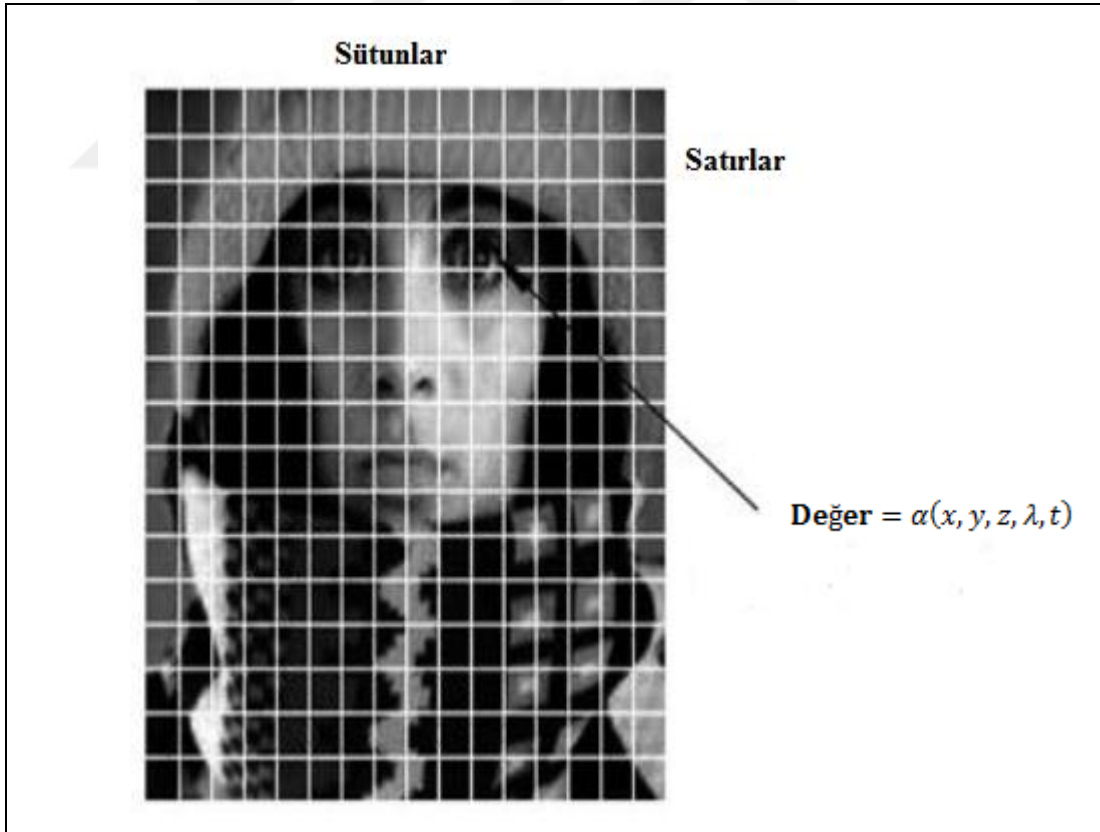


Şekil 2. 2. Somut bir görüntü ve ona karşılık gelen nümerik [16]

Burada gerçekleşen dönüşüm işlemi sayısal dönüşüm olarak isimlendirilir. Şekil 2.3'te bu durum anlatılmaktadır; örnek olarak her bir pikselin parlaklığı sayısal olarak şemaya tamamen aktarılmıştır. İşlemin bu kısmı, her bir pikselin parlaklığını veya karanlığını göstermektedir. Bu işlem tüm piksellere uygulandığında, görüntü dikdörtgen şeklinde ekrana yansıtılmaktadır. Her pikselin tam bir yeri veya izi (satır ve sütun sayısı) ve aynı zamanda bir değeri vardır ve bu değer o pikselin gri seviyesi olarak adlandırılır. Bu nümerik verilerden oluşan dizi artık bir bilgisayarda işlenmek üzere kullanılabilir durumdadır. Şekil 2.4, sürekli bir görüntünün nümerik durumunu göstermektedir [16].




Şekil 2. 3. Bir görüntünün dijitalize edilmesi [16]



Şekil 2. 4. Görüntü üzerinde sürekli bir sayma vardır. $[m, n]$ bir noktanın konumu, o noktanın parlaklığı vb. değerlerini tanımlamaktadır [16]

Dijital görüntü çalışmaları iki ana gruba ayrılabilir; birinci grup hem girdinin hem de çıktının görüntü olduğu gruptur, ikinci grup ise girdilerin görüntü olduğu, ve bu girdilerden çeşitli metotlar kullanarak bir nevi bir damganın, bir imzanın, bir özniteliğin veya bir kimliğin çıkarıldığı gruptur. Görüntü işlemenin genel organizasyonu Şekil 2.5'te görülmektedir.



Şekil 2. 5. Görüntülerin dijital olarak işlenmesi

2.2.3. Görüntü Elde Etme

Şekil 2.5'te en üstte yer alan ilk işlemdir, genel olarak ön işlem prosesi olarak anılır, prototip oluşturmak gibidir, çünkü ciddi boyutta nümerik veri ortaya çıkar.

2.2.4. Görüntü Güçlendirme/İyileştirme

Görüntü işlemenin en kullanışlı aşamalarından biridir. Temel olarak, görüntü güçlendirmenin altında yatan ana düşünce, bir nokta veya alanın detaylarının belirginleştirilmesi veya bazı sabit özelliklerin ön plana çıkarılmasıdır. İlk yapılacak iş görüntüdeki kontrastın artırılmasıdır. Görüntü güçlendirme kişiden kişiye değişiklik gösterebilir; sonuç kişinin tercihlerine göre değişiklik gösterebilir.

2.2.5. Görüntü Onarma


Görüntü onarma görüntüyü daha iyi hale getirir. Görüntü güçlendirme öznel bir konseptken, görüntü onarma nesnel bir konsepttir. Görüntü kayıplarının giderilmesi için matematiksel ve öngörücü modeller kullanılır.

2.2.6. Renkli Görüntü İşleme

Renk, farklı dalga boylarındaki ışığın gözün retinasına ulaştığında ortaya çıkan algıdır. İnsanların renk algısı, nesnelerin ışığı yansıtması ve bunun gözler aracılığıyla beyne iletilmesiyle oluşur. Bu algıya renk tonu veya sadece renk denir çünkü herhangi bir nesneye vuran ışık kısmen soğrulur ve kısmen de yansıtılır. Eğer dalgaboyunun tamamı aynı anda görünür olursa nesne beyaz, hiç ışık yansıtılmazsa nesne siyah olarak algılanır [16].

Renkli görüntüler bilgisayar ekranına 24-bitlik veri olarak yansıtılır. Ekrandaki görüntü, aynı nesneye ait üç farklı –kırmızı, yeşil ve mavi– gri seviyesinin üst üste ekrana yansıtılmasıyla elde edilir. 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 denk gelmektedir. Sırasıyla bu dalga boyları aralığında yer alan, yani kırmızı-yeşil-mavi kombinasyonuna sahip, üç adet 8-bitlik görüntü bilgisayar ekranına yansıtılırsa renkli bir görüntü elde edilmiş olur [17].

Gri tonlamalı görüntülerde görüntü, farklı grilik-tonu değerlerini barındırır. Gri seviyesi değerleri şu şekilde ifade edilir: $G = [0,1,\dots, 255]$. Bunun anlamı toplam 256 farklı grilik tonunun, veya farklı gri değerlerinin mümkün olduğudur. Burada 256 farklı gri değeri, 1 bayt olarak ifade edilebilir, 1 bayt = 8 bittir ve $2^8 = 256$ 'dır. 0-gri değeri kural olarak siyah renge, ve 255-gri değeri de beyaza tekabül eder. Grinin tonları bu iki değer arasında yer alır.



Şekil 2. 6. Farklı gri seviyesinde görüntüler

Şekil 2.6'da Satürn gezegenine ait (a) 8-bitlik gri görüntüsü, (b) 5-bitlik gri görüntüsü, (c) 2-bitlik gri görüntüsü, (d) 1-bitlik gri görüntüsü görülmektedir.

2.2.7. Sıkıştırma

Bu uygulama, bir görüntünün hafızaya alınabilmesi ve saklanabilmesi için belirli bir boyuta indirgenmesidir. Kapsayıcı teknolojiler zaman içerisinde aşırı gelişmiş olsa da, aynı transfer yani iletim teknolojileri için söylenemez. Bu, özellikle internet kullanımında ve görüntü içeriği konusunda çok önemli hale gelmiştir. JPEG (Joint Photographic Experts Group, Ortak Fotoğraf Uzmanları Grubu) bir görüntü sıkıştırma standartıdır ve bu format bilgisayarda dosya uzantılarından tanınabilir [18].

2.2.8. Morfolojik İşleme

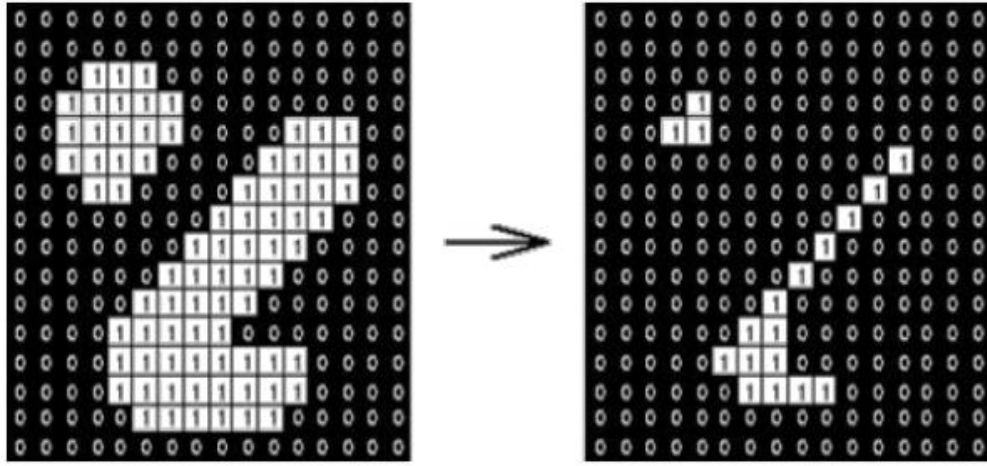
Morfoloji, biyolojinin canlı organizmaların şekil ve dış yapılarıyla ilgilenen dalıdır. Temel küme işlemlerine dayanan matematiksel morfoloji; sınırların, iskelet yapısının belirlenmesi ve tanımlanması, gürültünün temizlenmesi, kesimleme gibi işlemler için gerekli bir araçtır. Ön işleme veya son işlem için işlemde geçirilen görüntüde inceltme, budama gibi morfolojik filtreleme işlemleri yapılmaktadır.

Matematiksel morfoloji, kümeler kuramına dayanan ve bir görüntünün biçimsel yapısını esas alan bir yaklaşımdır. Bu metodun temelinde iki morfolojik işleç yatmaktadır, erozyon ve genişleme. Sayısal sinyaller için erozyon işleci, bir Minkowski küme ayırma işlecidir, ve genişleme ise Minkowski küme birleştirilmesi tarafından gerçekleştirilir. Erozyon işlemi cluster cebirinde kesişim işlemine, genişleme ise birleşim işlemine karşılık gelmektedir.


Genişleme işlemi, bir nesneyi büyütme veya kalınlaştırmak amacıyla gerçekleştirilen morfolojik bir işlemdir. Sayısal bir görüntü genişlemesi için kesişimlere kadar büyütülür. İşleme tabi tutulacak görüntünün her bir pikseli yapısal elemanın merkez noktasına konular ve genişletilir.

Yapısal eleman, kalınlaştırma işleminin nasıl yapılacağını tayin eder. Genişleme işleminden geçmiş bir görüntüde, görüntünün aslında var olan boşlukların ve deliklerin doldurulduğu ve köşe noktaların biraz daha yumuşatıldığı görülebilir.

Erozyon işlemi ise, ikili görüntü (imge) içerisindeki bir objenin küçültülmesi veya inceltilmesi için gerçekleştirilen morfolojik bir işlemdir. Erozyon ve genişleme işlemleri bir anlamda birbirlerinin tersi olarak düşünülebilirler. Bunun neticesinde görüntü içinde yer alan nesnelere küçülürken, boşluklar genişler ve birbirine temas halinde veya yakın olan nesnelere de birbirinden uzaklaşmaya başlar [19].




(a)




(b)

Şekil 2. 7. Morfolojik erozyon ve genişleme

Şekil 2.7’de, üstte siyah-beyaz bir görüntünün matrix şeklinde erozyona uğraması görülmektedir.Siyah-Beyaz bir görüntünün matrix şeklinde genişmesi görülmektedir [19].



(a)



(b)

Şekil 2. 8. Morfolojik açılış ve kapanış

Şekil 2.8'de, üstte siyah-beyaz bir görüntünün morfolojik açılış işlemi görülmektedir. Siyah-Beyaz bir görüntünün morfolojik kapanış işlemi görülmektedir.[19].

İkili görüntülere (imge) veya gri-tonlamalı görüntülere morfolojik işlemler uygulanabilir. Gri tonlamalı görüntü yayma işlemi, görüntüdeki koyu alanları açar. Görüntüyü çevreleyen parlak alanlar koyu alanlarla çevrili iken, parlak alanlarla çevrili koyu alanlarda, görüntüdeki elemanın ve koyu tonlu alanların boyutuna bağlı olarak, zayıflama görülür. Gri tonlamalı görüntü erozyonu işlemi görüntünün parlaklığını artırır. Görüntünün koyu alanlarıyla çevrili gölgeli alanlar küçülür, parlak alanlarla çevrili koyu tonlu bölgeler genişler [19].

2.2.9. Bölüntüleme

Görüntü işlemedeki en zor fonksiyonlardan biri bölüntülemedir. Segmentasyon, yani parçalara ayırma ne kadar realist olursa, tanıma işlemi o kadar hassas ve hatasız olacaktır.

2.2.10. Veri Tabanı

Görüntü işleme cihazının veri tabanında kullanılan kod önem arz etmektedir. Her bir işlemi yönlendirmesinin yanı sıra, veri tabanı modüller arası iletişimi sağlamaktadır.

2.3. Görüntü İşlemede Kullanılan Teknikler

2.3.1. Gölge Düzeltme

Görüntüler somut maddi nesnelere elde edildiğinde, görüntü üzerinde ışık kaynağından, alıcıdan veya nesneden kaynaklı belirgin gölgeler oluşabilir. Bazı durumlarda, görüntü ortadaki parlak kenarlara yaklaştıkça daha da ağırlaşır veya tam tersine ortadaki karanlık kenarlara doğru ağırlaşabilir. Veya soldan sağa doğru, aydınlanma azalabilir veya çoğalabilir. Gölgeleme olabilir, aydınlatma her yerde aynı düzgünlükte olmayabilir, yine kameranın duyarlılığı her tarafta aynı düzgünlükte olmayabilir, hatta merceğe kirli olabilir. Bu nedenle, gölgelenme istenmeyen bir durumdur. Bununla birlikte, amaç görüntü analizi ise, bir bakış açısıyla görüntü düzeltmeden sonra aynı olacaktır [20].

2.3.2. Normalizasyon

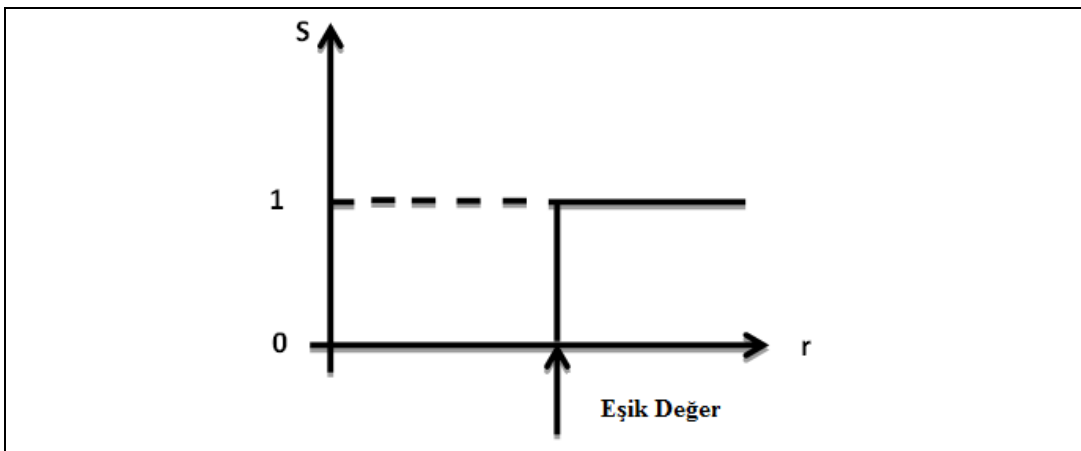
Burada yapılan işlemler görüntü işlemeye başlamadan önce yapılan işlemlerdir. Bu ön işleme mümkün olduğunca kısa olmalıdır. Çünkü normalleştirme amacı, kullanılacak algoritmanın gereksiz bilgiler için tepkisini, performansını yani genel olarak eylemini incelemektir. Tarayıcıdan alınan görüntüler boyut ve çözünürlük bakımından değişiklik gösterebilir. Tarayıcıdan gelen renkli görüntüler önce gri

seviyesine deđiřtirilir. Bu grntlerin boyutu byk olursa, grnt iřleme yapılacađında, yapay sinir ađının ğrenme ve analiz etme ařaması uzun zaman alır. Aslında, byk boyutlar kullanıldıđında iřlem sresi artmakta ve iřlem verimliliđi de azalmaktadır.

Bu sebeple tarayıcıdan sađlanan grntlerin belli bir standarda indirilmesi gereklidir [17]. Bu ıkarım nedeniyle, grntlerin boyutu 128x128 piksel řeklinde olmalıdır.

2.3.3. Eřikleme


Grnt iřlemede kullanılan temel metotlardan birisi eřiklemedir. Gri seviyesine gre nmerik hale getirilmiř bir grntye eřikleme uygulamadaki temel ama, grntnn temel zelliklerini belirlemenin kolaylařtırılmasıdır. Farklı gri seviyesi olan bir grnty sadece siyah ve beyaz renklere sahip ikili (binary) hale dnřtrmek iin her bir piksele iki renkten biri atanır. Bu iřlem eřikleme ile yapılır, eřikleme yapmadan nce bir eřik deđer olmalıdır. Bu eřik deđer Şekil 2.9'da grldđ gibi belirlenir. Gri seviyesi eřik deđerinin zerinde olan piksellere 1 deđer, gri seviyesi eřik deđerine eřit veya daha dřk olan piksellere ise 0 deđer verilir ve bylece grnt basit bir řekilde siyah-beyaza dnřtrlmř olur. Şekil 10'da, eřikleme ncesi grnt (sol) ve eřikleme sonrası grnt (sađ) verilmiřtir[21].



Şekil 2. 9. Eřik deđer

$$r \geq th \Rightarrow s = 1 \quad (2.1)$$

$$r < th \Rightarrow s = 0 \quad (2.2)$$



(a) (b)
Şekil 2. 10. Eşiklemeden önce (a) ve sonra (b)

2.4. Görüntü Güçlendirme ve Onarma Metotları

Sayısal görüntünün elde edilme süresi zaman zaman görüntü kaybına neden olmaktadır. Mekanik problemler, odaklanma problemleri, lensin hareket etmesi, uygun olmayan ışık gibi durumlar asıl görüntüden daha kötü bir sayısal görüntü elde edilmesine sebep olur. Görüntü güçlendirmede amaç, kayıt altına alınmış görüntüden görsel olarak en ideal görüntüyü elde etmektir. Görüntü onarmanın amacı ise, kayıtlı görüntüden orjinal görüntüye en yakın olabilecek görüntüye geçişi sağlamaktır. Görüntü güçlendirmedeki amaç güzelleştirmek iken, görüntü onarımındaki amaç gerçekliktir [22].

2.4.1. Keskinlik Filtresi

Görüntü güçlendirmede yaygın metotlardan biri görüntüdeki bir nesnenin kenarlarının geliştirilmesidir. Bu metoda keskinlik filtresi denir. Keskinlik filtresi ile görüntü kenarlarının geliştirilmesine önceleri bu kenarların ayrıştırılması denmiştir, daha sonra güçlendirme ve görüntüye eklenti yapma olarak anılmıştır.


Şekil 2.11’de Laplas Keskinlik Filtresi ile güçlendirilmiş bir görüntü gösterilmiştir. [22].



Şekil 2. 11. Orjinal görüntüyle Laplace Keskinlik Filtresi uygulanmış görüntünün karşılaştırılması (a) Orjinal (b) Laplace

2.4.2. Gürültü Giderme

Gürültü giderme işleminde kullanılan süzgeçler arasında en iyi filtrelemeyi sağlayan Wiener süzgecidir. Burada kullanılacak uygun bir tabir, ortalama hatayı (ortalama-karesel hata) vermektir. En uygun süzgeç de aynı zamanda kare kök ortalama (RMS) hatadır. Şekil 2.12'de gürültü giderme işlemi için beş farklı yöntem gösterilmiştir, görüntü spektrumu ve kirlilik spektrumu için verilen görüntü süzgeci uygulanmaktadır. Diğer süzgeçlerin değerleri (komşuluk ölçümü vb.) minimum RMS seçilerek yapılmıştır [22].



Şekil 2. 12. Farklı tekniklerle gürültü giderme işlemlerinin karşılaştırılması

2.4.3. Kenarların Bulunması

Sayısal görüntüde, gri seviyesinin sürekliliğini, çizgileri ve kenarları tespit edebilmek için kullanılan pek çok teknik vardır. Bu, süzgeç matrisinden geçirilerek yapılır. Şekil 2.13'te görüldüğü gibi, her bir süzgeç 3x3 boyutlarında birer matristir.

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

Şekil 2.13. [3x3] süzgeç matrisi

Süzgeçten geçirilecek olan piksellerdeki gri seviyeleri ile matristeki katsayılar birbiriyle çarpılıp toplanır. Genel olarak, matrisin tam orta noktası, süzgecin her


bir noktasının cevap alanı olarak tanımlanır. Bu görüntüdeki her bir noktanın bağıntısı denklem 2.3 de gösterilmiştir.

$$R = w_1z_1 + w_2z_2 + w_3z_3 + k + w_nz_n \quad (2.3)$$

$$R = \sum_{i=1}^n w_i z_i$$

Kenar algılama uygulandığında renk geçişleri keskinleştirilir ve bu da, görüntüdeki nesnelerin algılanmasını veya farklılıkların elde edilmesini kolaylaştıran bir yaklaşımdır. Farklı görüntü işleme yöntemlerini uygun şekillerde kullanarak en başarılı sonucu elde eden modern bir yaklaşım olarak da tanımlanabilir. Görüntüde kenar algılama, görüntünün anlamlı özniteliklerini içerdiği ve farklı bilgileri açığa çıkarmaya yaradığı için çok önemlidir. Kenarlar genellikle nesnelerin sınırlarına ve gölge geçişlerine uyarlanır.

Kenar, bir pikselin bulunduğu bölgeye ve yakın komşuluğuna, ayrıca boyuta ve yöne ait bir özelliktir. Kenar hesaplamalarında oldukça açık renkli görüntüler kullanılır ve görüntünün gradyan fonksiyonu kenarları hesaplar. Kenardan kenara gri renk gradyanlarının ölçülmesi önemlidir.



Şekil 2. 14. Gri tonlu bir görüntüde yatay doğru

Şekil 2.14'te gri tonlu görüntülerde en ideal kenar özneliği sol taraftakidir, sağdaki ise ideal kabul edilmez. Geçişlerde bulanıklaşma yoktur.Sağdaki görüntüde soldaki gibi geçişler doğrudan ve keskin olmayacaktır. Sağda gösterilen eğimli kenar boyunca, eğim kenarların bulanıklaşması seviyesiyle ilintilidir [18].

2.5. Görüntü İşlemenin Uygulama Alanları

Modern teknoloji basit devre sistemlerinden karmaşık bilgisayar sistemlerine kadar pek çok yerde çok boyutlu sinyallerin işlenmesini olanaklı kılmaktadır. Bu işlemin amacı [23] :

Görüntü İşleme >Görüntü girdisi – Görüntü çıktısı

Görüntü Analizi> Görüntü girdisi – Ölçümlenmiş boyut çıktısı

Görüntünün Anlaşılması> Görüntü girdisi – Daha yüksek boyutlu çıktı

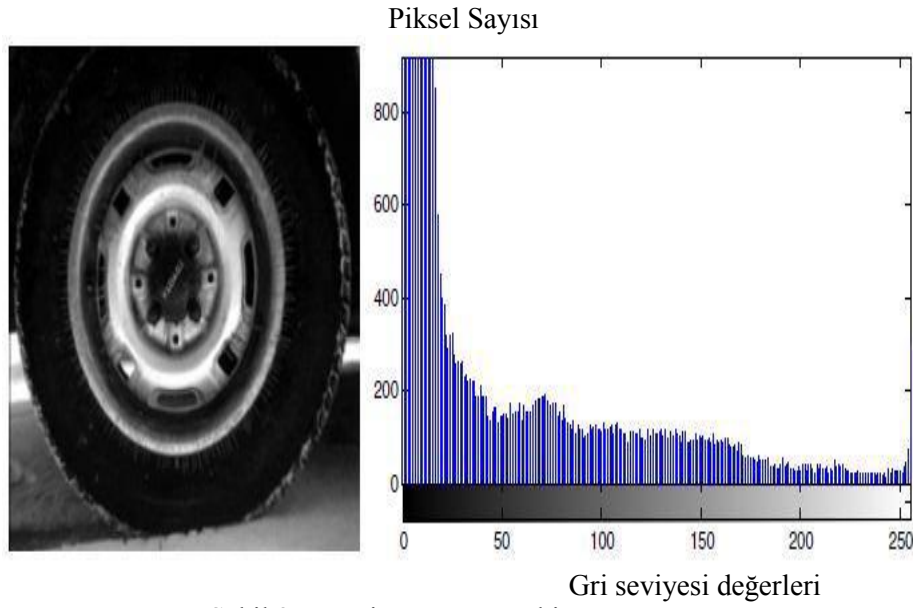
şeklinde üç kategoriye ayrılır [24].

2.6. Histogram

Görüntü bir ölçektir ve her bir piksel belirli bir değere sahiptir. Gri seviye histogramı veya birinci seviyeden elde edilen histogram, resimdeki parlaklığın dağılımını gösterir. Görüntü histogramındaki iterasyon sayısının grafik gösterimi piksel parlaklık değerleri olarak adlandırılır. Histogramda ayrıca yatay eksen piksellerin parlaklığını, ve dikey eksen ise o parlaklıktaki piksel sayısını verir, yani görüntüdeki her piksel temsil edilir. Görüntü piksel cinsinden belirli bir değere ölçeklendirilmektedir.

Gri seviye histogramı veya birinci seviyeden elde edilen histogram, resimdeki parlaklığın dağılımını gösterir. Görüntü girdisinin parlaklığı, 256 değerli bir gri seviyesinin söz konusu olduğu varsayılırsa, görüntünün her bir pikseli için değer aralığı [0, 255] dir.Görüntünün histogramını elde etmek için (yalnızca görüntüden


alınacak olan pikseller ile), her parlaklık düzeyindeki piksel sayısı hesaplanır. Basit bir histogramda, pikselin uzay konum bilgileri, yani koordinat bilgileri kaybolur ve görüntüdeki piksellerin sadece gri değerleri elde edilir. Histogramların konum bilgisi yoktur, sadece frekans bilgisi vardır. Görüntü ile ilgili bir gri seviye değeri seçerek süzgeçlemek mümkündür (0-255). Şekil 2.15, bir görüntüye ait gri seviyesi histogramını göstermektedir. [16].



Şekil 2. 15. Bir görüntünün histogramı [25]

2.6.1. Histogram Eşitleme

Histogram eşitleme, gri seviyesinin çok değişiklik göstermediği alanlardan oluşan görüntüler için oldukça kullanışlıdır. Bu şekilde görüntü kontrastı düşük olur ve histogram senkronizasyon sonrası kolaylıkla işlenebilir. Şekil 2.16'da görüldüğü gibi, histogram, renklerin histogramdaki frekanslarının sönümlenmeden, doğru ve uygun şekilde dağıtılabildiğini sağlamak için tasarlanmıştır [25].



Şekil 2. 16. Avuç içi görüntüsünün histogram eşitlemesi [25]

Şekil 2.16'da soldaki görüntünün gri seviyesi 61-142 aralığındadır; senkronizasyon sonrası sağdaki görüntünün histogramı ise 0-255 aralığındadır.

3. METOTLAR

3.1. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin karakteristik özelliklerini kullanarak ve herhangi bir yardıma ihtiyaç duymaksızın yeni bilgiler elde etme ve öğrenme yeteneği ve yenilerini keşfetme amacıyla geliştirilmiş bilgisayar sistemleridir. Geleneksel programlama yöntemleriyle bu tür yeteneklerin realize edilmesi çok zor hatta imkansızdır. Bu sebeple yapay sinir ağlarının, bilgisayar biliminin programlanması zor veya imkansız durumlar için uyarlanabilir bilgi işlem geliştirmeye ilgilene alanı olduğu söylenebilir [26].


Yapay sinir ağları, insanların olayları ne şekilde öğrenilebilecek ve daha sonra uygulanabilecek tepkiler verdiğini belirleyen bilgisayar sistemleridir. Bunlar insan beyninin fonksiyonel özelliklerine benzer şeylerdir; öğrenme, ilişkilendirme, sınıflandırma, genelleme, öznitelik tanımlama ve optimizasyon. Yapay sinir ağları bugünlerde derinlemesine inceleme gerektiren birçok soruna çözüm üretebilmektedir. Yapay sinir ağları, birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşur. Proses elemanı olarak da adlandırılan bu hücrelerin birbirine bağlı olduğudur [26].

3.1.1. Biyolojik Sinir Hücreleri

Sinir hücresi (nöron) sinir sisteminin en temel fonksiyonel birimidir. Bu hücreler çeşitli şekil ve boyutlarda olabilirler ve nöral stimülasyonun neticesi olan elektriksel ve kimyasal sinyalleri iletirler. Hücre gövdesi büyüktür, çekirdek burada yer alır. Sinir sisteminin oluşturan sinir hücrelerinin kısa uzantıları dendritlerdir, tek ve uzun olan kısım ise akson olarak isimlendirilir. Sinir hücresinin türüne göre, gövdesinden çıkan uzantıların sayısı ve şekli farklıdır. Bu uzantılar akson veya dendrit olarak adlandırılır. Diğer hücrelerden gelen uyarılar dendritlerden alınır ve aksonlardan başka hücrelere iletilir. Aynı kuptan çıkan

tek bir akson ve tek bir dendrit varsa bu tip sinir hücreleri tek kutuplu (unipolar) olarak isimlendirilir. Eğer dendrit ve akson, nöron gövdesinin zıt iki bölgesinden çıkıyorsa, bu tip sinir hücreleri iki kutuplu (bipolar) olarak isimlendirilir. Nöronun gövdesinden çok sayıda dendrit ve tek bir akson çıkıyorsa, bu tip sinir hücrelerine ise çok kutuplu (multipolar) denilir.

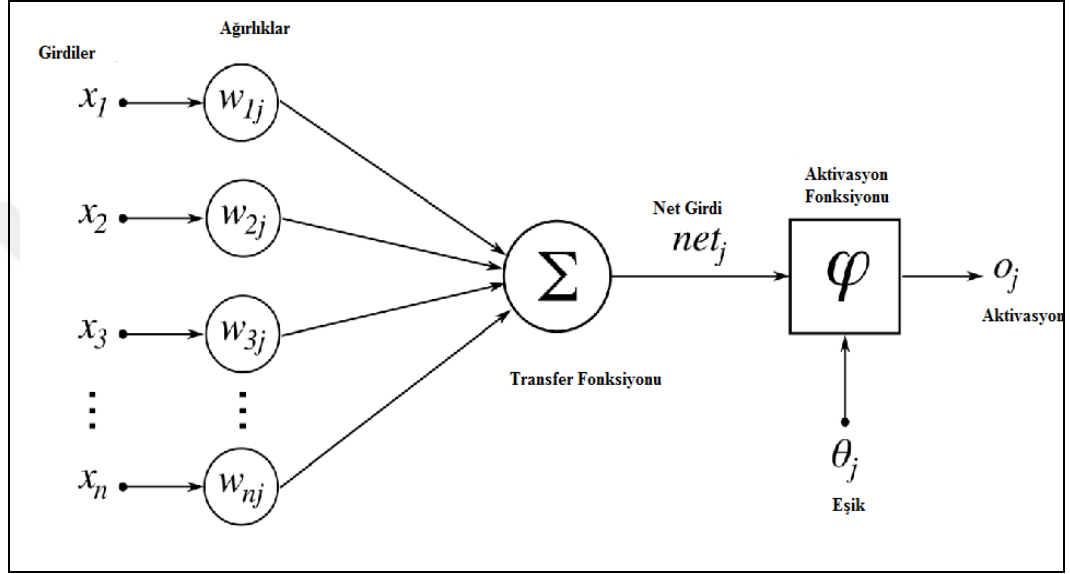
Biyolojik sinir ağları, hafife alınmayacak derecede karmaşık olaylarla başa çıkabilen bir performans göstermektedir. Biyolojik sinir ağları, yani sinir hücreleriyle beraber bütün bir sinir sistemi, insanların çevrelerini ve bütün davranışlarını anlamalarını sağlar. Biyolojik sinir ağları, beş duyudan elde edilen bilgiler ışığında geliştirilen algı ve anlayış mekanizmalarını çalıştırarak olaylar ve konseptler arasındaki ilişkileri öğrenir. Bu karakteristik özellikler kısmen örnek alınarak yapay sinir ağları geliştirilmiştir. Şekil 3.1’de bir nöron görülmektedir [27,28].



Şekil 3.1. Bir sinir hücresi ve kısımları [28]

3.1.2. Yapay Sinir Hücresi

Biyolojik sinir ağlarında sinir hücreleri bulunduğu gibi, yapay sinir ağlarında da yapay sinir hücreleri bulunmaktadır. Yapay sinir hücrelerine mühendislik biliminde prosesler veya işlemler de denir. Her işlem veya proses elemanı beş ana bölümden oluşur.



Şekil 3. 2. Yapay sinir hücresinin genel yapısı [29]


Şekil 3.2’de görülen yapay sinir hücresi temel olarak beş kısımdan oluşmaktadır. Bunlar; girdi(ler), ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı(lar)dır. Yapay sinir ağlarında öğrenme süreci girdiler üzerinden yürütülür. Dış dünyadan veya bir önceki katmandan sağlanan bilgi, yapay sinir hücrelerine girdi olarak gönderilir. Ağırlıklar ise girdilerin yapay sinir hücreleri üzerindeki etkilerini belirleyen ve öğrenmenin gerçekleşmesine olanak verecek olan katsayılarıdır. Yapay sinir hücresine ulaşacak olan net girdiyi ise toplama fonksiyonu belirler. Burada en sık kullanılan yöntem ağırlıklı toplamın hesaplanmasıdır. Yapay sinir hücresine ait ağırlıklı toplamın hesaplanması için, her bir girdinin kendisine ait ağırlıkla çarpımına eşik değeri eklenir. Eşik değeri, yapay sinir hücrelerinde, biyolojik sinir hücrelerinin yüzeyindeki potansiyel farkına benzer bir değer elde etmek için kullanılan katman sayısıdır. Çıktı fonksiyonu ise, sonucun dış dünyaya veya diğer hücelere gönderildiği yerdir. Bir

sinir hücresinin yalnızca bir çıktısı vardır. Bir yapay sinir hücresinin çıktısı, onu takip eden başka bir yapay sinir hücresinin girdisi olabilir. Yapay sinir ağları sadece dijital girdi bilgileriyle çalışır. Bu sebeple, girdi bilgileri genellikle ölçeklendirilir.


$$net = \sum_i^n X_i w_i + \phi \quad (2.4)$$

3.1.3. Aktivasyon Fonksiyonu


Transfer veya aktivasyon fonksiyonu öğrenme eğrisi olarak da adlandırılır. Aktivasyon fonksiyonu, sinir hücresinin çıktısının genliğini istenen değerler arasında sınırlandırır. Bu değerler genellikle $[0,1]$ veya $[-1,1]$ aralığı olarak tanımlanır. Buna ek olarak aktivasyon fonksiyonu, yapay sinir ağına bir öngerilim değeri (bias) uygulanarak geliştirilebilir. Yapay sinir ağlarında kullanılacak fonksiyonlar sürekli ve türevlenebilir olmalıdır. Yapay sinir ağının kullanım amacı doğrultusunda tek veya çift kutuplu aktivasyon fonksiyonları kullanılabilir. Yapay sinir ağlarında doğrusal ya da doğrusal olmayan transfer fonksiyonlarının kullanılması, karmaşık problem uygulamalarına olanak sağlar. En yaygın kullanılan aktivasyon fonksiyonları şekil 3.3, 3.4 ve 3.5'te gösterilmektedir [30].



Şekil 3. 3. Doğrusal aktivasyon fonksiyonu [30]



Şekil 3. 4. Sigmoid aktivasyon fonksiyonu [30]



Şekil 3. 5. Tanjant-Sigmoid aktivasyon fonksiyonu [30]

3.2. Yapısına Göre Yapay Sinir Ağları

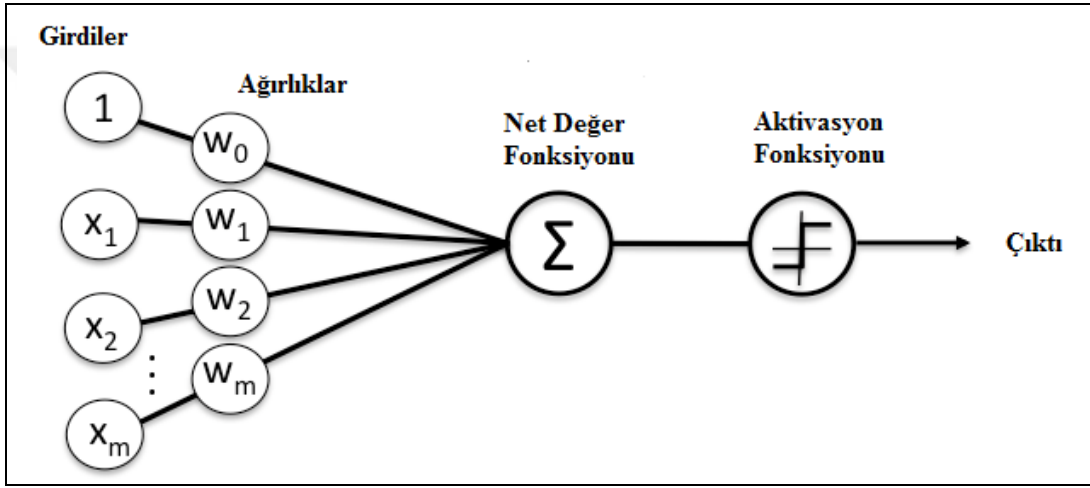
Yapay sinir ağları genel olarak; ağ yapısına göre, ileri beslemeli veya geri beslemeli; öğrenme kuralına göre, Hebb, Hopfield, Delta veya Kohonen; öğrenme algoritmasına göre danışmanlı öğrenme, danışmansız öğrenme veya destekleyici öğrenme; kural ve pratiğe göre çevrim-içi veya çevrim-dışı şeklinde sınıflandırılır.

Buna ek olarak, ağırlık matrisleri simetrik veya asimetric olabilir, ağırlık matris değerleri, ağdaki düğümlerin özelliklerine, kullanılan aktivasyon fonksiyonlarının deterministik veya stokastik niteliğine bağlı olarak sabit veya değişken olarak sınıflandırılabilir. İleri beslemeli yapay sinir ağları, örüntü tanıma problemlerinde,

geri beslemeli yapay sinir ağı ise, optimizasyon problemlerinde yaygın olarak kullanılır.

3.2.1. İleri Beslemeli Tek Katmanlı Yapay Sinir Ağları

Bu ağlarda girdi sinyallerinin ve ilgili ağırlıkların bir fonksiyonu hesaplanır ve sonuç takip eden bütün yapay sinir hücrelerine iletilir. Bu ağlara ileri beslemeli çok katmanlı yapay sinir ağları denilir, şekil 3.6'da bir ileri beslemeli tek katmanlı yapay sinir ağı görülmektedir.

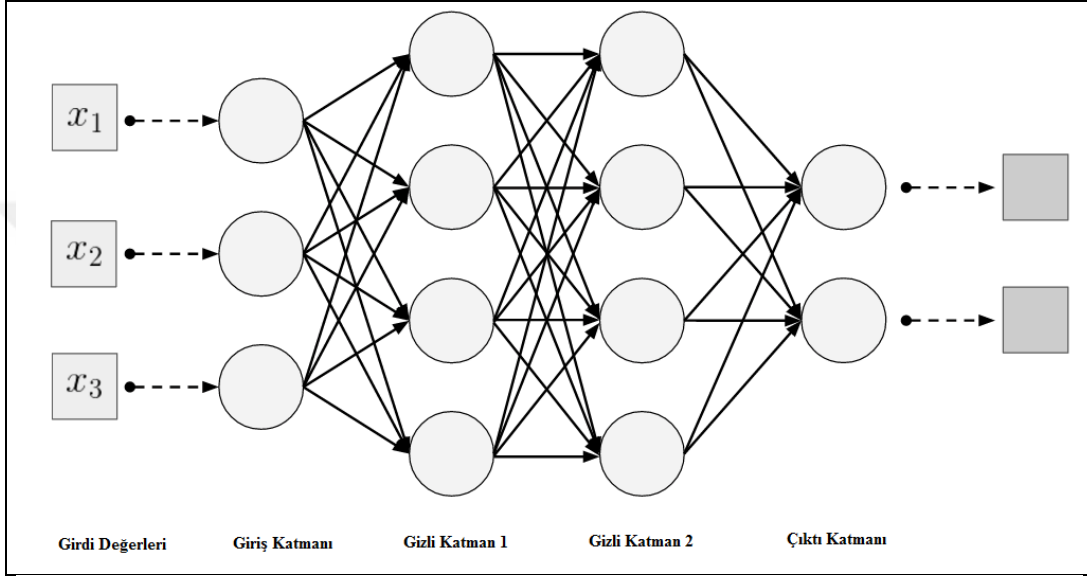


Şekil 3. 6. İleri beslemeli tek katmanlı yapay sinir ağı [31]

Bu algılayıcı, ilk olarak Rosenblatt tarafından örüntü sınıflandırma amacıyla geliştirilmiştir. Algılayıcı, bir sinir hücresinin birden fazla girdi neticesinde bir çıktı üretmesi prensibine dayanmaktadır. Ağın çıktısı mantıksal bir değerdir, sıfır veya bir değerini alır. Çıktı değerini hesaplamak için eşik değeri fonksiyonu kullanılır. Bu ağlarda proses elemanlarının değerlerini koruyan ve dolayısıyla net çıktının sıfır olmasını engelleyen bir eşik değeri vardır. Tek katmanlı ağlarda, çıktı fonksiyonu doğrusal bir fonksiyondur. Ağa iki sınıftan örnekler gösterilir ve ağın doğru bir şekilde bu iki sınıfı ayrıştırmasına çalışılır [32].

3.2.2. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları

Yapay sinir ağının öğrenmeye çalıştığı olaylar arasında doğrusal olmayan bir ilişki söz konusuysa, daha önce izah edilen modelleri kullanarak öğrenmenin realize edilmesi imkansızdır. Bu tip olguların öğrenilmesi daha sofistike modeller gerektirir. Çok katmanlı ağlar bunlardan biridir [33].



Şekil 3. 7. İleri beslemeli çok katmanlı yapay sinir ağı [34]


Bu ağlar üç katmandan oluşurlar. Girdi katmanı dış dünyadan bilgiyi alır, ve bu katmanda bilginin herhangi bir şekilde işlenmesi söz konusu değildir. Çıktı bir sonraki katmanda yer alan proses elemanlarına iletilir. Ara (gizli/saklı) katman kendisine sürüklenen bilgiyi işler. Pek çok problemin tek bir ara katmanla çözülmesi mümkündür. Problemin girdisi ve çıktısı arasındaki ilişki doğrusal değildir. Eğer problemin karmaşıklığı artarsa birden fazla ara katman kullanılabilir. Çıktı katmanı ise ara katmandan gelen bilgiyi işler ve ağa sunulan girdiye karşılık ağın ürettiği çıktıyı bulur. Bu çıktı dış dünyaya iletilir.

Çok katmanlı ağın eğitimi sırasında, ağ tarafından elde edilen çıktıyla hedeflenen çıktı arasındaki fark, bu farkın zamanla giderilmesi amacıyla ağın ağırlıkları arasında dağıtılır. Öğrenme sırasında, ağa girdiler sunulur ve bu girdilere karşılık

gelen çıktılar elde edilir. Bu işleme ileriye doğru hesaplama denilir. Daha sonra, elde edilen çıktı istenen çıktı ile karşılaştırılır ve hata ağırlıkları değiştirecek şekilde yeniden düzenlenir. Bu işleme de geriye doğru hesaplama denilir [35].

3.2.3. Geri Beslemeli Ağlar

Geri beslemeli ağ mimarileri, genellikle danışmansız öğrenme kurallarının uygulandığı ağlarda kullanılır. Geri beslemeli ağlarda, adından da anlaşılacağı gibi bir tür geri besleme işlemi vardır. Hopfield ağı bu mimariye sahip olan bir yapay sinir ağıdır. Geri beslemeli yapay sinir ağlarında, bir hücrenin çıkışı başka bir hücre veya girdi katmanı için girdi olabilir. Bağlantı çift yönlüdür. Yapay sinir ağlarının aksine, bir bağlam katmanı var. Bu katman, gizli katmanın çıkışı üzerinde bir ağırlık değerlendirmesi yapar ve tekrar gizli katmana gönderir [36]. Şekil 3.8’de geri beslemeli bir ağ örneği sunulmaktadır.

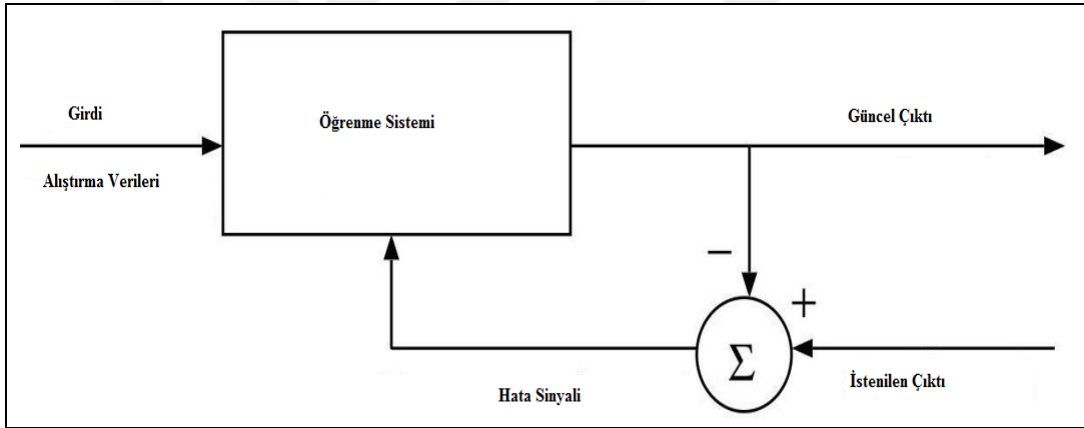


Şekil 3. 8. Hopfield geri beslemeli ağ [37]

3.2.4. Yapay Sinir Ağlarında Denetimli Öğrenme

Denetimli öğrenmede girdi ve çıktı çiftinden oluşan bir eğitim bilgisi vardır. Ağa gelen girdiye göre elde edilen çıktı ile istenen çıktı kıyaslanır ve ağırlıkları değiştirerek kullanılacak bilgi elde edilir. Elde edilen çıktı ile hedeflenen çıktı arasındaki fark, yani hata değeri, daha önceden belirlenmiş bir değerin altına inene kadar eğitime devam edilir. Hata değeri istenen değerin altına indiğinde bütün ağırlıklar sabitlenir ve eğitim süreci sonlandırılır. Eğer verilen bir girdiye karşı istenen çıktı elde edilemiyorsa, bağlantı ağırlıkları çıktıdaki hatayı minimize edecek şekilde değiştirilir [38].

Şekil 3.9'da bir yapay sinir ağında denetimli öğrenme örneği sunulmuştur.



Şekil 3. 9. Yapay sinir ağında denetimli öğrenme [39]

3.2.5. Yapay Sinir Ağlarında Denetimsiz Öğrenme


Bir denetim yoksa, sistem doğru çıkış, yani işlemi ne zaman sonlandıracağına dair hiçbir bilgiye sahip değildir ve girdilere göre kendisi örnekler oluşturur. Danışmansız eğitilen ağlar, istenen çıktı veya varış yeri olmaksızın, ağırlık değerlerini girdi bilgilerinin özelliklerine göre ayarlarlar. Danışmansız olduğunda, ağ dışarıdan sağlanan kısıtlamalarla değil, girilen bilgilerle çalışır. Bu tür öğrenme durumunda, gizli sınırlar veya katmanlar, dış yardım olmaksızın kendilerini organize etmenin bir yolunu bulmak zorundadırlar. Bu yaklaşımda, verilmiş olan girdi vektörleri için ağın performansını ölçebilen bir çıktı örneği sağlanmaz, yani

ağ yoluyla öğrenilir. Başka bir deyişle ağ eğitimini, girdi vektörlerinin en yakın benzerliklerinden başlayarak sınıflandırır [40].

3.3. Avuç içi Tanıma Sistemleri


Avuç içi tanıma sistemleri iki kısımdan oluşur. Şekil 3.10'da, ilk bölümde, eğitim kümesinin formasyonu ve ikinci kısımda tanıma işlemini gösterilmektedir. Eğitim kümesinin hazırlanmasında, avuç içi tarama cihazından elde edilen ham görüntüler kullanılır. Avuç içi görüntülerinin geliştirilmesi, çalışma alanının filtrelenmesi, düzeltilmesi, çıkarılması ve normalize edilmesi şeklinde ön işleme tabi tutularak sağlanır. Daha sonra, bu görüntülerin nitelikleri çıkarılır ve bu nitelikler, yani avuç içi vektörleri oluşturulur ve veri tabanına kaydedilir.

Tanıma işleminde, avuç içi görüntüsü eğitim aşamasında geçtiği aynı işlemlerden aynı sırayla geçirilir. Bu avuç içi görüntülerinden elde edilen avuç içi vektörleri veri tabanındaki vektörlerle karşılaştırılır. Tanıma, daha önce belirlenmiş olan eşik değeri doğrultusunda gerçekleştirilir [41].



Şekil 3. 10. Avuç içi tanıma ve eğitim basamakları blok şeması [41]

Avuç içi izinin görüntüsünü elde edileceğinde, görüntü alınırken farklı ışık koşullarında farklılıkların oluşmasını engellemek amacıyla, yarı kapalı bir ortam, etrafı çevrelenmiş bir halka kullanılır. Kontrol noktasının, yada avuç içinin istenen şekilde cihazın platformuna yaklaştırılması için parmakların koyulacağı yerlerde çıkıntılar olabilir. Analog dijital dönüştürücü ve kamera ile çekilen ham görüntüler bilgisayara aktarılır. Bu ham görüntüler ilk önce 24 bit derinliğe, sonra 8 bit derinliğe dönüştürülür, yani renkli görüntü gri seviyeye dönüştülür, sonra görüntü istenen boyuta ayarlanır. Avuç içinde çalışırken, 128x128 piksellik bir bölge elde edilir. Daha sonra işlem öznitelik vektörlerinin elde edilmesi ve sınıflandırılmasıyla tamamlanır. Şekil 3.11'de avuç içi görüntüsünün alındığı sistem gösterilmektedir [42].



Şekil 3. 11. Avuç içi izi görüntüleme sistemi [42]

3.3.1. Avuç içi Görüntüsü Veritabanları


IITK (Indian Institute of Technology, Kanpur) veri tabanı: Düşük çözünürlüklü bir tarayıcıyla, 183 farklı kişiden toplam 549 avuç içi görüntüsü elde edilmiştir. Her bir avuç içinin üç görüntüsü alınmıştır. Tarayıcıdan elde edilen görüntüler 200 dpi'da 256 grilik seviyesindedir [43].

CASIA (The Chinese Academy of Sciences Institute of Automation) veri tabanı: 312 farklı kişiden alınan 5502 avuç içi görüntüden oluşur. Her bir bireyden 8 adet sağ el 8 adet sol el olmak üzere toplam 16 avuç içi görüntü alınmıştır. Cihazdan elde edilen görüntüler JPEG formatında 8-bitlik grilik seviyesindedir. Veri tabanındaki her bir görüntü 640x480 piksel boyutlarındadır. Aynı kişiye ait olan 16 adet görüntü tek bir klasöre konulmuştur. Yani 312 kişi için 312 farklı dosya mevcuttur [44].

CASIA Multi-Spectral avuç içi görüntü veri tabanı ise 100 farklı bireyden çok bantlı (multispectral) bir cihazla alınan görüntülerden oluşur. Toplam olarak 720 avuç içi görüntü vardır. Avuç içi görüntüleri 8-bit grilik seviyesinde JPEG dosyalarıdır. Her bir el için iki seansta görüntüler elde edilmiştir. İki seans arası geçen süre bir aydır. Her seansta üçer görüntü alınmıştır. Her bir grup altı farklı elektromanyetik spektrumla aynı anda elde edilen altı farklı görüntüden oluşur. Altı farklı spektruma tekabül eden aydınlatma dalga boyları sırasıyla 460 nm, 630 nm, 700 nm, 850 nm, 940 nm ve beyaz ışıktır. İki örnek arasında elin pozisyonundan kaynaklanan belli seviyede farklılıklar olabilir. Bu bağlamda, sınıflandırma çeşitleri arttırılmıştır. Avuç içinin pozisyonunu kısıtlayan herhangi bir mandal vs. kullanılmamıştır, sadece cihaza yerleştirilmesi yeterli görülmüştür. Cihaz, eşit şekilde dağıtılmış bir aydınlatma sağlayan ışıklandırma ve cihazın altında sabit bir CCD kamera yardımıyla avuç içi görüntüyü alır [45].

Hong Kong Politeknik Üniversitesi Biyometrik Araştırma Merkezi mavi, yeşil, kırmızı ve kızılötesi aydınlatma altında avuç içi görüntülerini gerçek zamanlı olarak alabilen, çok bantlı bir avuç içi görüntü yakalama cihazı geliştirmiş ve bunu kullanarak da büyük ölçekli bir çok bantlı avuç içi görüntü veri tabanı oluşturmuştur; ve akademik araştırma amacıyla geliştirilen avuç içi doğrulama algoritmalarını test etmek amacıyla ücretsiz olarak kullanılabilmesi için veri bankası olarak yayınlamıştır [46].

PolyU veri tabanı (The Hong Kong Polytechnic University Multispectral Palmprint Database) da bir avuç içi görüntü veri tabanı oluşturmuştur. PolyU avuç içi veri tabanındaki bütün görüntüler şekil 3.12'de görülen avuç içi tanıma cihazıyla elde edilmiştir [47].




Şekil 3.12. PolyU avuç içi görüntü elde etme cihazı [47]

Çözünürlük 96 dpi, ve 128x128 pikseldir, 256 grilik seviyesinde 8-bittir. 195 erkek ve 55 kadından oluşan 250 gönüllü katılımcıdan görüntüler alınmıştır. Yaşları 20 ila 60 arası değişen katılımcılardan çok bantlı avuç içi görüntüler sağlanmıştır. Örnekler iki farklı seansta toplanmıştır. Her bir seansta 6 avuç içi görüntü alınmıştır. Her seansta 4 farklı ışıklandırmayla 2 avuç içi görüntü alınarak toplam 24 avuç içi görüntü elde edilmiştir. 500 kişinin farklı ışıklandırmalarla toplam 6000 avuç içi görüntüsü alınmıştır. Birinci ve ikinci seans arası ortalama zaman aralığı yaklaşık olarak 9 gündür [46].


Her bir klasör "nnnn" formatında isimlendirilmiştir, ve "nnnn" 1 ve 500 arasındaki kişisel kimlik numarasını temsil etmektedir. Her bir klasörde ilk seansta elde edilen 6 avuç içi görüntü "1_mm", ikinci seansta elde edilen 6 avuç içi görüntü ise "2_mm" formatında kaydedilmiştir. "mm" seanstaki avuç içi görüntü sırasını vermektedir. "Blue.rar", "Green.rar", "Red.rar", ve "NIR.rar" mavi, yeşil, kırmızıyı ve NIR ise ışıklandırmayla elde edilen orijinal bütün avuç içi görüntüleri kapsar. Ayrıca, avuç içi görüntüsünden sadece ilgilenilen alanın ayıklandığı bir

veri tabanı da mevcuttur. Avuç içi görüntüleri alınırken, görüntüyü ayarlamak için bir parmak takozu kullanılmaktadır [46].



(a) (b)
Şekil 3. 13. PolyU çok bantlı avuç içi görüntüleri

Şekil 3.13'te PolyU avuç içi veri tabanındaki 15. bireyin görüntüleri verilmiştir. (a) birinci seansta, görüntü (b) ise ikinci seansta alınmıştır [46].



(a) (b)
Şekil 3.14. PolyU ROI avuç içi görüntüleri

Şekil 3.14'te ise, PolyU veri tabanından, çok bantlı avuç içi görüntüsünün sadece ilgilenilen kısmın alındığı bir görüntü sunulmaktadır. Görüntü (a) 15. bireyden ilk seansta, görüntü (b) ise ikinci seansta alınmıştır [46].

4. DENEY SONUÇLARI

4.1. Yerel İkili Örüntü (LBP)

Bir dokuyu temsil etmenin en iyi yollarından biri LBP tekniğidir ve son yıllarda farklı uygulamalarda yaygın bir şekilde kullanılmaktadır. Onaylanmış iyi ayrıştırma, grilik seviyesindeki monoton değişiklikler karşısında değişmezlik, ve hem hızlı hem de verimli hesaplamalara imkan sağlaması gibi özellikleri bu metodu görüntü analizinde en kullanışlı metotlardan biri haline getirmiştir. Avuç içi, oldukça küçük olan pek çok modelin kombinasyonunu içinde barındırmaktadır, dolayısıyla LBP metot yardımıyla çok iyi bir şekilde tarif edilmesi ve tanımlanması mümkündür.

4.1.1. Yerel İkili Örüntünün Tanımı

Yerel ikili örüntü, doku analizinde güçlü bir yaklaşım olarak kabul edilir. İlk olarak Ojala ve arkadaşları tarafından 3×3 'lük bir matris operatörü olarak ileri sürülmüştür [7]. Bu metotta yapılan işlem, komşu 8 pikselin merkezdeki pikselle kıyaslanmasıdır. Her bir piksel merkezdeki pikselle kıyaslanır, sahip oldukları değer merkezdeki pikselden büyükse veya eşitse bu piksele 1 değeri verilir, aksi takdirde bu piksel 0 değerini alacaktır. Sonunda, merkezdeki piksel komşu piksellerin ağırlıklı toplamıyla değiştirilir ve 3×3 'lük pencere diğer piksele geçer. Bu değerlerin histogramı çıkarıldığında ise, görünüm dokusunun bir tanımlayıcısı elde edilmiş olur.

Denklem (4.1), her bir piksel için belirleyici yerel ikili örüntü ilişkisini göstermektedir:

$$LBP_{P,R(x,y)} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (4.1)$$

Burada s , 1'in işaretini, g_p ve g_c ise sırasıyla komşu ve merkezdeki pikselin grilik seviyesini vermektedir. Ayrıca 2^P her bir komşu piksel için gerekli bir katsayıdır, çünkü LBP metodu farklı oranlara sahip dokular da içermektedir.

4.1.2. Düzgün Yerel İkili Örüntü

LBP'lerde yapılan ilk geliştirilme düzgün örüntü olarak tanıtılmıştır [8]. Eğer bir yerel ikili örüntünün 0'dan 1'e veya 1'den 0'a maksimum 2-bitlik geçişleri varsa bu yerel ikili örüntüye düzgün denir. Örneğin 0000000000 örüntüsü (0 geçiş) ve 11001001 örüntüsü (4 geçiş) sırasıyla düzgün ve düzgün olmayan örüntülerdir. (1, 8) ve (16, 2) komşuluklarının, bütün örüntünün %90'ını ve %70'ini kapsayabileceği gösterilmiştir. Genel olarak P bitten oluşan monoton model ikili örüntü sayısı $P+2(P-1)$ 'dir. $LBP_{P,R}^{u2}$ notasyonu düzgün LBP'leri temsil etmek için kullanılır, alttaki (P,R) komşuluğu, üstteki ise düzgün örüntüleri temsil eder. Denklem (4.2)'yi kullanarak düzgün ikili modeli şöyle ifade edebiliriz:

$$LBP_{P,R}^{u2}(x,y) = \begin{cases} I(LBP_{P,R}(x,y)) & \text{if } \begin{cases} U(LBP_{P,R}) \leq 2 \\ I(z) \in [0, (P-1)P+2] \end{cases} \\ (p-1)p+2 & \text{otherwise} \end{cases} \quad (4.2)$$

Burada $U(x)$ bitler arası geçiş sayısının detonatorüdür ve denklem (4.3)'te tanımlanmaktadır:

$$U(LBP_{P,R}) = |s(g_{p-1} - g_c) - s(g_0 - g_c)| + \sum_{p=1}^P |s(g_{p-1} - g_c) - s(g_{p-1} - g_c)| \quad (4.3)$$

Eğer $U(x)$ 2 pikselden küçükse, o piksel gösterge fonksiyonu $I(z)$ ile işaretlenir, aksi takdirde, $(P-1)P+2$ değeri verilir. $(P-1)P+2$ 'yi içeren gösterge fonksiyonu indeksi $I(z)$ belirli bir indeks için bütün düzgün örüntülere uygulanır.

4.1.3. Görünüm Histogramı


Durgun bir görünümde, görüntü piksellerinin belirli değerleri vardır. Birinci gri seviyesi histogramı ya da kısaca histogram, görüntüdeki parlaklık dağılımını gösterir. Histogramın yatay eksen, piksellerin parlaklık seviyesini ve dikey eksen ise görüntüde her bir parlaklık seviyesindeki toplam piksel sayısını gösterir. Görüntü girdisinin siyah beyaz görüntü olduğunu ve parlaklık düzeyinin 256 olduğunu varsayalım, bu durumda her bir piksel (0-255) arası değerler alacaktır. Bu görüntüye ait histogramın elde edilmesi için bütün yapmamız gereken görüntüdeki bütün piksellerin üzerinden geçmek ve her bir parlaklık düzeyine kaç piksel düştüğünü saymaktır.

Basit bir histogramda piksel konumlarının olmayacağı aşikardır, sadece gri seviyesindeki sayılar hesaplanmış olacaktır.

Başka bir deyişle, değerler ana köşegen üzerindeki büyük sayılardır ve tedrici olarak çapları küçülecektir.


4.2. Görüntü Veri Tabanı

Bu çalışmada kullanılacak olan görüntü veri tabanı, Hong Kong Politeknik Üniversitesi tarafından hazırlanan veri tabanının bir kısmıdır. Görüntüleri almak için kullanılan cihaz, CCD kameranın kullanıldığı bir tarayıcıdır. Görüntüler 750 dpi çözünürlükte 384×284 piksel boyutlardadır. Şekil 4.1’de görüntüleri alan cihaz ve bu cihazla alınan görüntülerden bazı örnekler verilmektedir [12].



Şekil 4. 1. Görüntü alma cihazı ve cihazla alınan görüntülerden örnekler

Önerdiğimiz metodu değerlendirebilmek için bu veri tabanından belirli bir sayıda görüntü alınmıştır. Bu görüntülerin, deri renklerinin farklılığı, gri seviyesindeki farklılıklar vb. sebeplerle parlaklıklarında farklılıklar görülmektedir. Orjinal görüntüler 384×284 boyutlarındadır. Önışlemeden sonra, öznetelik çıkarabilmek ve eşleştirmelerde kullanmak amacıyla görüntülerin merkezinden bir parça (128×128 boyutlarında) alınmaktadır. Şekil 4.2'de bir grup avuç içi görüntüsünün önışlemeden sonraki halleri görülmektedir.



Şekil 4. 2. Önışleme tabi tutulmuş bazı avuç içi görüntülere örnekler

4.3. Simülasyon Sonuçları

Değerlendirmeler Hong Kong Politeknik Üniversitesi'nin hazırladığı PolyU Palm print veri tabanından sağlanan görüntüler üzerinde yapılmıştır. Bu veri tabanında

500 kişiye ait 600 avuç içi görüntü bulunmaktadır, her bir katılımcıdan 12 adet görüntü alınmıştır. Öznitelik vektörleri arasında benzerlik hesaplaması 2 yolla yapılabilir. Bu da birincisi öznitelik vektörleri arasındaki uzaklığı hesaplayarak ya da ikincisi benzerlikleri hesaplayarak. Bu iki ölçüm birbirine zıttır. Uzaklık ve benzerlik hesabı için farklı kriterler bulunmaktadır; bu çalışmada test görüntüsü S ve eğitim görüntüsü T için ki kare (chi-square) uzaklığını kullanılmıştır [13].

Bu da denklem (4.5) de aşağıdaki matematiksel ifade ile verilmiştir.

$$D(S,T) = \sum_{n=1}^N \frac{(S_n - T_n)^2}{(S_n + T_n)} \quad (4.5)$$

Test edilecek deneklere ait en az 1, en fazla 4 avuç içi görüntüsü alınmıştır. Veri tabanı üzerinde deneyler yapılmıştır. Açıkça görülebileceği gibi, PCA metodu en kötü sonuçları verirken, standart LBP metodu geri kalan metotların hepsinden daha yüksek oranda doğru sonuçlar vermiştir. Önerdiğimiz metot ise standart LBP metodundan daha yüksek bir doğruluk oranı vermiştir.

Görünüşe göre performans-merkezli yaklaşımlar eğitim görüntülerinin toplam sayısından fazlaca etkilenmektedir. Dolayısıyla üçüncü deneyde, bu parametrenin metodumuz üzerindeki etkisini değerlendirdik. Bu deneyde eğitim amacıyla her bireyden minimum 1 ve maksimum 4 görüntü alınmıştır. Veri tabanından alınan görüntüler üzerinde deneyler yapılmış ve farklı algoritmalar kullanarak elde edilen sonuçlar sunulmuştur.

Denelerimizde eğitim görüntülerinin sayısı 1 ve 4 arasında değişmektedir ve son fotoğraf ise test amaçlı kullanılmıştır. Bu deney her aşamada 20 defa tekrarlanmıştır.

Elde edilen ortalama değerler kaydedilmiştir. Şekil 4.3'te kullanılan eğitim görüntü sayısına bağlı olarak doğru sonuç verme yüzdelerindeki değişim görülmektedir.

Önerilen yaklaşımın performansını ortaya koyabilmek amacıyla deneyler yapılmıştır. Algoritmamız avuç içi görüntüleri üzerinde onaylanmıştır. Önerilen ve burada detaylarını verdiğimiz tanıma metodu, Intel Duo CPU 2.00 GHz işlemcili, 2.00 GB RAM'ı olan bir PC üzerinde, Matlab programında denenmiştir ve sonuçlar Şekil 4.3 ve 4.4'te gösterilmektedir. Deneyde, veri tabanı oluşturulurken ilk seansta elde edilen görüntüler eğitim amaçlı, ikinci seansta elde edilen görüntüler ise test amaçlı kullanılmıştır. Dolayısıyla hem eğitim amaçlı hem test amaçlı toplam görüntü sayısı 300'dür. Önerilen LBP metodu etkili bir metottur; %4'ten az olmayan bir iyileştirme, çok ölçekli bir planlama olmaksızın gerçekleşemezdi. Daha fazla bilgi elde ettiği için, önerilen metot geleneksel çok ölçekli metottan daha iyi bir sonuç verebilir. Önerilen metot ayrıca öğrenim temelli metotlardan, yani PCA'dan da daha iyi sonuç verebilir.

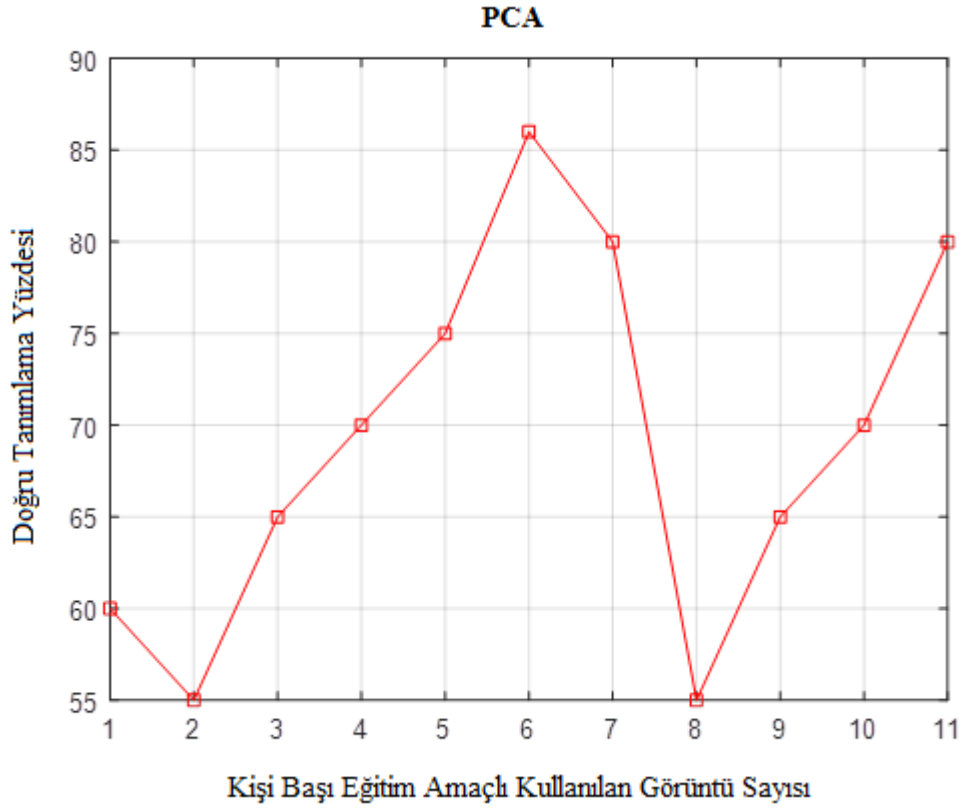
Görülebileceği gibi, önerilen metot büyük ölçüde eğitim amaçlı kullanılan görüntü sayısına bağlıdır ve 1 görüntüden 11 görüntüye kadar eğitim amaçlı kullanılan görüntü sayısının ne kadarlık bir yüzdeleri değişimi sonuç verdiği görülebilir.

PCA, görüntü tanıma ve görüntü sıkıştırma için kullanılan en başarılı tekniklerden biridir. PCA bu alanda istatistiksel bir metot olarak değerlendirilmektedir.

PCA'nın kullanıldığı metotlarda temel amaç, veri uzayının büyük olan boyutlarını küçültmektir.


PCA metodunda, veri kümesine ait matrisin özdeğerleri ve özvektörleri bulunur ve bu yolla yeni bir koordinat sistemi hesaplanır. Burada teknik olarak artık veya gereksiz sayılan kısmın minimize, varyansın ise maksimize edilmesi amacıyla veri kümesinin kovaryans matrisinin hesaplanması da yapılır.

Şekil 4.3 de PCA algoritması kullanılarak elde edilen avuç içi tanıma yüzdesi, maksimum başarı oranı yaklaşık % 86 görüntü kalitesi elde edilmiştir.



Şekil 4. 3. Kişi başı eğitim amaçlı kullanılan görüntü sayısına bağlı olarak gerçekleşen doğru tanımlama yüzdesi

Şekil 4.4'te, eğitim amaçlı kullanılan görüntü sayısının her bir metodun tanıma ve hassaslık yüzdesi üzerindeki etkisi görülmektedir.



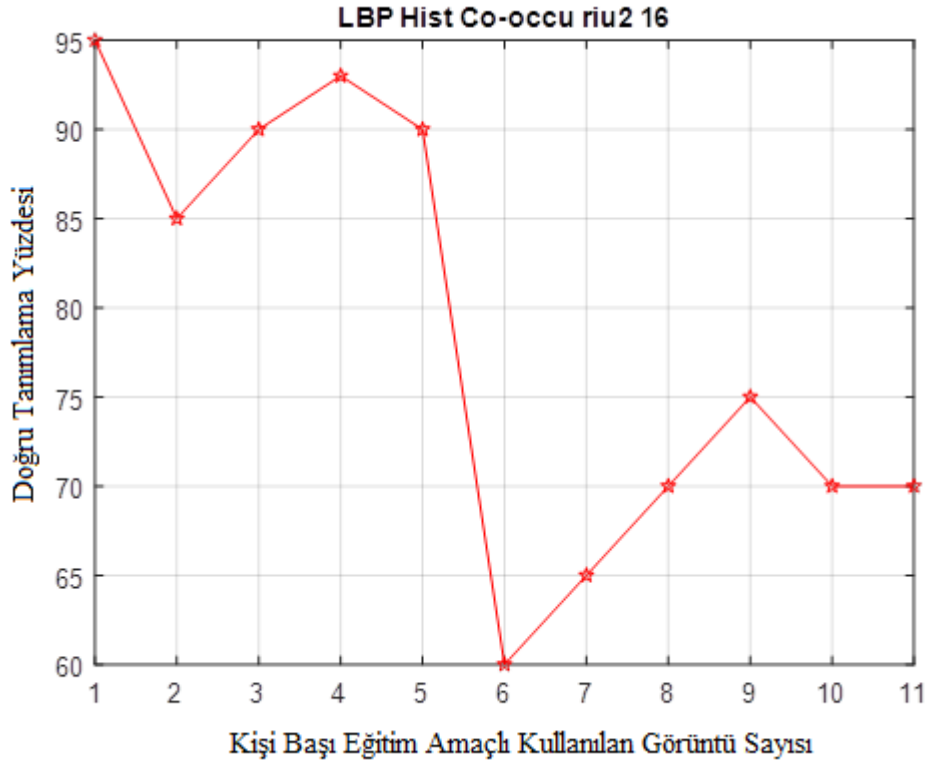
Şekil 4. 4. Döndürmeyle değişmeyen düzgün örüntü R = 3, p = 24

Döndürmeyle değişmeyen düzgün örüntü için bu verilmiştir:

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{i=0}^{P-1} s(p_i - p_c) & \text{if } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{otherwise} \end{cases}, \quad (4.6)$$


Bu şekilde riu2 24 lbp algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum %96 olan doğruluk oranı, eğitim için 4 görüntü kullanıldığında oluşmaktadır.

Şekil 4.5'te riu2 16 lbp algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum %95 olan doğruluk oranı, eğitim için tek bir görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %60 ise, eğitim için 6 görüntü kullanıldığında ortaya çıkmaktadır.



Şekil 4. 5. Döndürmeyle değişmeyen düzgün örüntü $R = 2$, $p = 16$

Şekil 4.6'da riu2 8 lbp algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum %96 olan doğruluk oranı, eğitim için tek bir görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %65 ise, eğitim için 7 görüntü kullanıldığında ortaya çıkmaktadır.

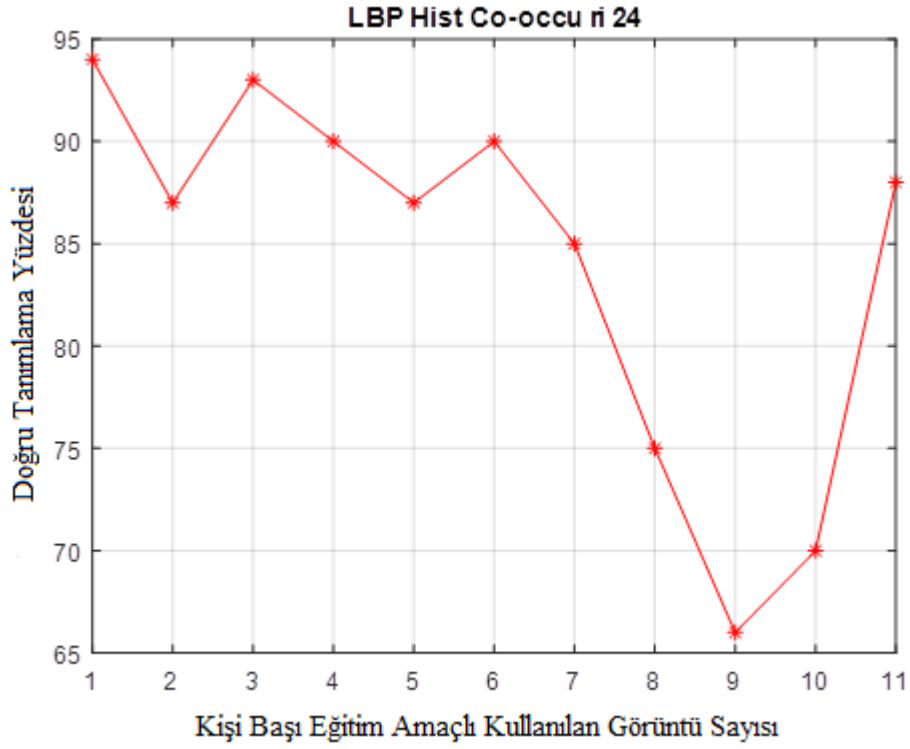


Şekil 4. 6. Döndürmeyle değişmeyen düzgün örüntü R = 1, p = 8

Döndürmeyle değişmeyen örüntüler için denklem 4.7 ile verilmiştir.


$$LBP_{P,R} = \sum_{i=0}^{P-1} s(p_i - p_c) \times 2^i, \quad (4.7)$$

Şekil 4.7’de ri24 lbp algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum %94 olan doğruluk oranı, eğitim için tek bir görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %66 ise, eğitim için 9 görüntü kullanıldığında ortaya çıkmaktadır.



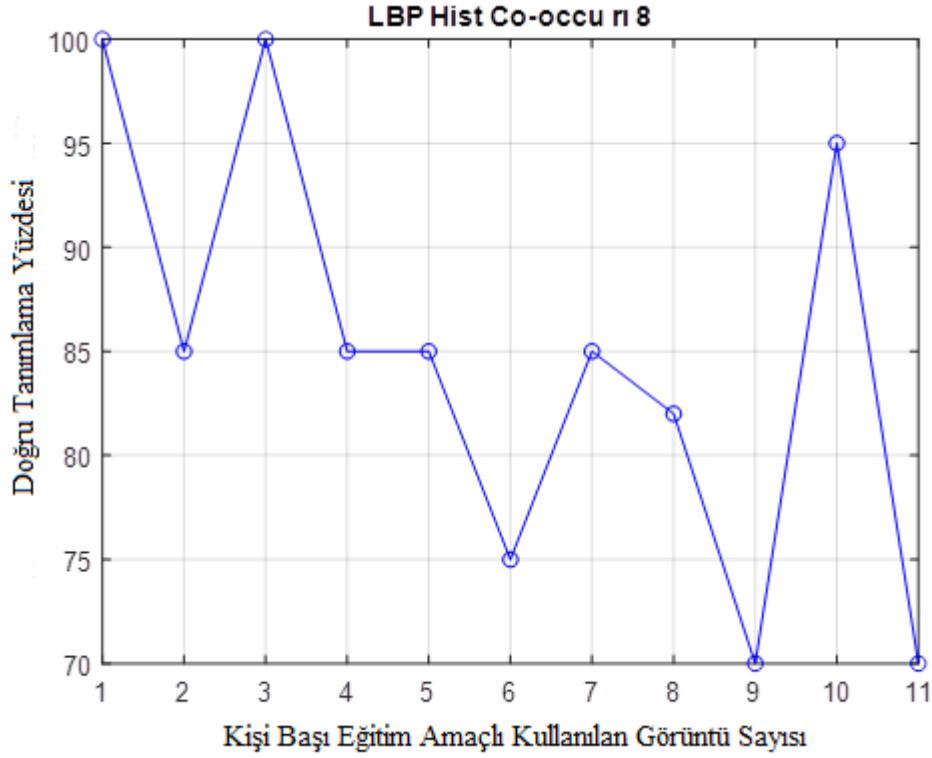
Şekil 4. 7. Döndürmeyle Değişmeyen R = 3, p = 24

Şekil 4.8’de ri 16 lbp algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum %98 olan doğruluk oranı, eğitim için 4 görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %75 ise, eğitim için 6 görüntü kullanıldığında ortaya çıkmaktadır.



Şekil 4. 8. Döndürmeyle değişmeyen $R = 2$, $p = 16$

Şekil 4.9’de $r_i = 8$ lbp algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum %100 olan doğruluk oranı, eğitim için 1 veya 3 görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %70 ise, eğitim için 9 veya 11 görüntü kullanıldığında ortaya çıkmaktadır.




Şekil 4. 9 Döndürmeyle Değişmeyen R = 1, p = 8

Burada döndürmeyle değişmeyen örüntüler için şu verilmiştir:


$$LBP_{P,R}^{U_2}(x,y) = \begin{cases} I(LBP_{P,R}(x,y)) & \text{if } U(LBP_{P,R}) \leq 2, I(z) \in [0, (P-1)P+2) \\ (P-1)P+2 & \text{otherwise} \end{cases}$$

Şekil 4.10'da u2 24 lbp algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum % 95 olan doğruluk oranı, eğitim için 4 veya 6 görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %80 ise, eğitim için 9 veya 11 görüntü kullanıldığında ortaya çıkmaktadır.



Şekil 4. 10 Düzgün R = 3, p = 24

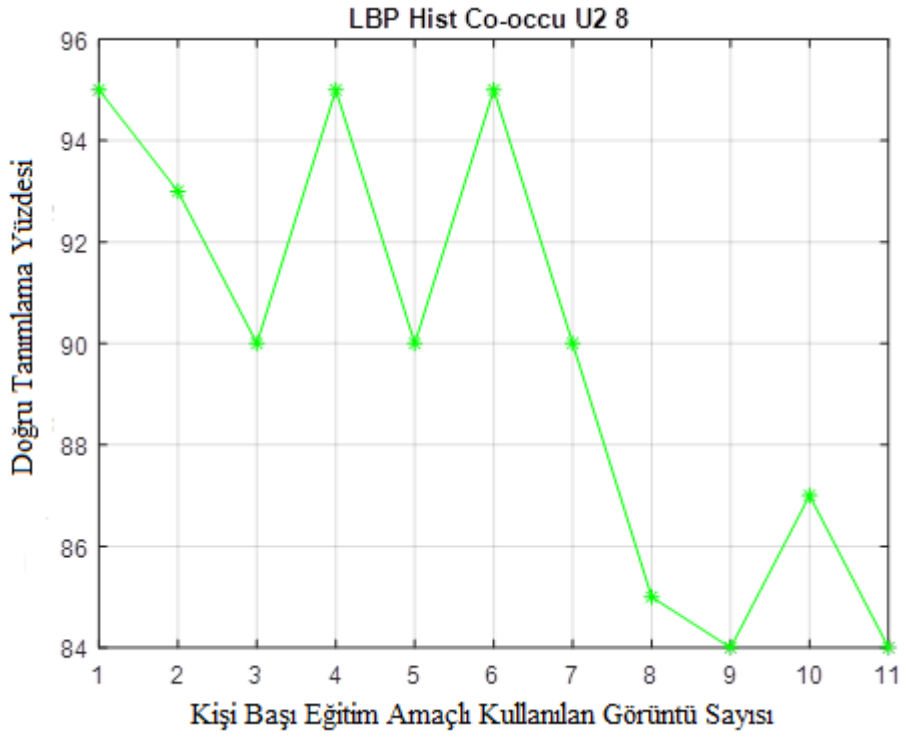
Şekil 4.11'de u2 16 LBP algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum % 100 olan doğruluk oranı, eğitim için 1 veya 3 görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %80 ise, eğitim için 4 veya 7 görüntü kullanıldığında ortaya çıkmaktadır.



Şekil 4. 11. Düzgün R = 2, p = 16

Şekil 4.12'de U2 8 LBP algoritmasının avuç içi tanıma yüzdesi verilmektedir. Görülebileceği gibi, maksimum yüzde 95 olan doğruluk oranı, eğitim için 1, 4 veya 6 görüntü kullanıldığında oluşmaktadır. Minimum doğruluk oranı olan %84 ise, eğitim için 9 veya 11 görüntü kullanıldığında ortaya çıkmaktadır.

Bu algoritma, verilen algoritmalar arasında en iyisidir. Bu algoritmayla oldukça yüksek yüzdeler elde edilmektedir.



Şekil 4. 12. Düzgün $R = 1, p = 8$

5. SONUÇ

Bu çalışmada, avuç içi görüntüler üzerine yapılan analizlere dayanarak bunlara ait öznelikleri çıkaracak, ve bu öznelikleri kullanarak tanımlama ve doğrulama yapacak bir sistemin tasarlanması amaçlanmıştır. Bu tezde, tanımlamak amacıyla sorgulanan bir avuç içi görüntüsünün elimizdeki avuç içi görüntü veri tabanında olup olmadığının saptanması amaçlanmıştır.

İkinci bölümde, avuç içi görüntülerin analiziyle ilgili önemli görülen konulara değinilmiştir. Bu bağlamda, görüntü işleme hakkındaki başlıca konulara dair teorik bilgiler verilmiştir. Ayrıca, öznelik vektörlerini oluştururken sınıflandırma aşamasında kullanılacak olan yapay sinir ağları hakkında da teorik bilgiler sunulmuştur. Bu bölümün sonunda, literatürde yer alan avuç içi tanıma üzerine yapılan çalışmaların sonuçları da verilmiştir.

Girdi verileri, pikseller arasındaki parlaklık yoğunluğunu algılayabilecek makineler tarafından sağlanmaktadır. Avuç içi görüntülerdeki parlaklık yoğunluğunun oranları, çevresel parlaklığın değişmesinin ve döndürmenin etkisi altındadır. Önerilen yöntemde kullanılan yerel ikili örüntüler, ışıklandırma ve parlaklıktaki değişikliklere karşı güçlüdür, yani bu tip değişiklikleri tolere edebilir. Ayrıca, ikili örüntülere dayanan avuç içi tanıma sistemlerinin çoğu, sadece sabit bir LBP formundan yararlanır ve bu da sadece belirli bir dereceye kadardır. Tek ölçekli LBP metotları görüntünün özneliklerini sadece belirli bir çözünürlükte elde edebilirler, ve bu metotlar görüntünün genel bir doku analizini yapmak için kullanışlı değildir, çünkü bu metotlarla ayırt edici pek çok özellik kapsam dışı bırakılmaktadır. Çok ölçekli yaklaşım, farklı şartlar altında daha fazla öznelik sağlayabilir. Dolayısıyla daha fazla ayırt edici özneliği daha az zahmetle elde edebilmek için, farklı yarıçaplardaki düzgün yerel ikili örüntülerin kombinasyonu bu tez kapsamında kullanılmıştır. Elde edilen sonuçlar, önerilen yöntemin doğru sonuç verme oranının diğer metotlardan daha yüksek olduğunu, cevap verme süresinin ise diğer metotların cevap verme sürelerine yakın olduğunu göstermiştir.

Bu veri kümeleri, yapay sinir ağı için girdi olarak sınıflandırılırlar; aynı veri kümeleri daha sonra asıl hedef olan veri kümeleri üzerindeki işlemler için eğitim kümesi olarak vazife görürler. Bu çalışma kapsamında, avuç içi görüntüler üzerinde yapılan bütün işlemler MATLAB'ın Image Processing Toolbox (Görüntü İşleme Eklentisi) paketi ile gerçekleştirilmiştir. Bu çalışmada, avuç içi görüntüleri tanıma performansının, ayrıca tanımlama ve doğrulama amaçlı testlerin ve test aşamalarının değerlendirilmesi amaçlanmıştır. Ayrıca ilerki çalışmalarda farklı simülasyon programları ve yeni matematiksel metotlar kullanılarak, test edilerek kalite güvenilirliği ve yapay zeka testleri için yeni veri bankaları oluşturulabilir.



KAYNAKLAR

- [1] U. Shafique, H. Khan, A. Sher, A. Zeb, U. Shafi, R. Ullah, *ve diğ.*, "Modern Authentication Techniques in Smart Phones: Security and Usability Perspective," *INTERNATIONAL JOURNAL OF ADVANCED COMPUTER SCIENCE AND APPLICATIONS*, vol. 8, pp. 331-340, 2017.
- [2] FBI, "Palmprint," https://webcache.googleusercontent.com/search?q=cache:4L2ndTaDx1cJ:https://www.fbi.gov/file-repository/about-us-cjis-fingerprints_biometrics-biometric-center-of-excellences-palm-print-recognition.pdf+&cd=1&hl=tr&ct=clnk&gl=tr, 2002.
- [3] csmonitor, "The Secure Communities fingerprint sharing program," https://www.google.com.tr/search?biw=1692&bih=593&tbm=isch&sa=1&ei=YdVLWvaSIYGegAalua_wBA&q=criminal+fingerprint&oq=criminal+fingerprint&gs_l=psy-ab.3.0.0i19k113.2387.3503.0.4780.8.7.1.0.0.0.271.724.0j2j2.4.0....0...1c.1.64.psy-ab..3.5.724...0j0i30k1.0.fzAD-YBP5lY#imgsrc=YoMXqtjrTU_hjM:, 2010.
- [4] J. Berry and D. A. Stoney, "The history and development of fingerprinting," *Advances in fingerprint Technology*, vol. 2, pp. 13-52, 2001.
- [5] A. C. AB, 2010.
- [6] Y. Guleryuz, "Atm," <http://yusufguleryuz.com/2015/02/10/sifre-devri-bitti-devir-biyometrik-bankacilik-devri/>, 2014.
- [7] G. Lu, D. Zhang, and K. Wang, "Palmprint recognition using eigenpalms features," *Pattern Recognition Letters*, vol. 24, pp. 1463-1467, 2003.
- [8] L. Fei, Y. Xu, and D. Zhang, "Half-orientation extraction of palmprint features," *Pattern Recognition Letters*, vol. 69, pp. 35-41, 2016.
- [9] W. Jia, R.-X. Hu, Y.-K. Lei, Y. Zhao, and J. Gui, "Histogram of oriented lines for palmprint recognition," *IEEE Transactions on systems, man, and cybernetics: systems*, vol. 44, pp. 385-395, 2014.
- [10] P.-F. Yu and D. Xu, "Palmprint recognition based on modified DCT features and RBF neural network," in *Machine Learning and Cybernetics, 2008 International Conference on*, 2008, pp. 2982-2986.
- [11] X. Cheng and S. Wang, "A New Palmprint Identification Technique Based on a Two-stage Neural Network Classifier," in *Computer Science and Software Engineering, 2008 International Conference on*, 2008, pp. 957-960.
- [12] K. Fu, *Sequential methods in pattern recognition and machine learning* vol. 52: Academic press, 1968.

- [13] D. P. ROCKETT, "Feature Extraction by Multiobjective Genetic Progr," https://www.sheffield.ac.uk/eee/research/cr/research/feature_extraction, 2008.
- [14] V. V. Nabiyev, *Yapay zeka: insan-bilgisayar etkileşimi*: Seçkin Yayıncılık, 2012.
- [15] C. Nadal and C. Y. Suen, "Applying human knowledge to improve machine recognition of confusing handwritten numerals," *Pattern Recognition*, vol. 26, pp. 381-389, 1993.
- [16] K. Castleman, "Digital Image Processing. Second," ed: Englewood Cliffs, New Jersey: Prentice-Hall.
- [17] B. Ergen and A. Çalışkan, "Biyometrik Sistemler ve El Tabanlı Biyometrik Tanıma Karakteristikleri," in *6th International Advanced Technologies Symposium (IATS'11)*, 2011, pp. 16-18.
- [18] R. C. Gonzales and R. E. Woods, "Digital image processing, 1993," *Addisio-Wesley Publishing Company*.
- [19] M. Karhan, M. Oktay, Z. Karhan, and H. Demir, "Morfolojik görüntü işleme yöntemleri ile kayıslarda yaprak delen (çil) hastalığı sonucu oluşan lekelerin tespiti," in *6th International Advanced Technologies Symposium (IATS'11)*, 2011, pp. 172-176.
- [20] V. Vakili and L. H. Shu, "Towards biomimetic concept generation," in *Proceedings of the ASME Design Engineering Technical Conference*, 2001, pp. 327-335.
- [21] İ. Türkoğlu, "Yapay sinir ağları ile nesne tanıma," *Fırat Üniversitesi Fen Bilimleri Enstitüsü*, pp. 9-30, 1996.
- [22] I. T. Young, J. J. Gerbrands, and L. J. Van Vliet, *Fundamentals of image processing*: Delft University of Technology Delft, 1998.
- [23] I. Pitas, *Digital image processing algorithms and applications*: John Wiley & Sons, 2000.
- [24] G. Dede and M. H. Sazlı, "Biyometrik Sistemlerin Örüntü Tanıma Perspektifinden İncelenmesi ve Ses Tanıma Modülü Simülasyonu," *EEBM Ulusal Kongresi*, 2010.
- [25] C. M. Thompson and L. Shure, "Image processing toolbox [for use with Matlab]," 1995.
- [26] E. Öztemel and Y. S. Ağları, "Papatya yayıncılık," ed: İstanbul, 2003.

- [27] K. Kawaguchi, "Biological Neural Networks," http://osp.mans.edu.eg/rehan/ann/2_2%20Biological%20Neural%20Networks.htm, 2000.
- [28] waybuilder, "NEURON CELL BODY," <http://www.waybuilder.net/free-ed/Courses/06%20MedHealth/HumanAnatomy/HumanAnatomyFiles.asp?iNum=113>, 2010.
- [29] medium, "Neuron," <https://medium.com/@ivaniljeqvist/the-essence-of-artificial-neural-networks-5de300c995d6>, 2015.
- [30] A. Gülbağ, "Yapay sinir ağı ve bulanık mantık tabanlı algoritmalar ile uçucu organik bileşiklerin miktarsal tayini," *Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü*, 2006.
- [31] deeplearning, "Advanced Feeding Single Layer Artificial Neural Network," <https://deeplearning4j.org/neuralnet-overview>, 2017.
- [32] F. Rosenblatt, "The perceptron: A probabilistic model for information storage and organization in the brain," *Psychological review*, vol. 65, p. 386, 1958.
- [33] S. Bilgin, "Kalp Hızı Değişkenliğinin Dalgacık Dönüşümü ve Yapay Sinir Ağları Kullanılarak Analizi," *Doktora Tezi*, 2008.
- [34] safaribooksonline, "deep-learning," <https://www.safaribooksonline.com/library/view/deep-learning/9781491924570/ch04.html>, 2017.
- [35] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *nature*, vol. 323, p. 533, 1986.
- [36] J. J. Hopfield and D. W. Tank, "'Neural' computation of decisions in optimization problems," *Biological cybernetics*, vol. 52, pp. 141-152, 1985.
- [37] hindawi, "hopfield," <https://www.hindawi.com/journals/ijp/2012/798361/fig4/>, 2012.
- [38] M. Gevrey, I. Dimopoulos, and S. Lek, "Review and comparison of methods to study the contribution of variables in artificial neural network models," *Ecological modelling*, vol. 160, pp. 249-264, 2003.
- [39] A. Radi and S. K. Hindawi, "Applying Artificial Neural Network Hadron-Hadron Collisions at LHC," in *Artificial Neural Networks-Architectures and Applications*, ed: InTech, 2013.
- [40] B. Kosko, "Feedback stability and unsupervised learning," in *Proceedings of the 2nd IEEE International Conference on Neural Networks (ICNN-88)*, 1988, pp. 141-152.

- [41] G. Shobha, M. Krishna, and S. Sharma, "Development of palmprint verification system using biometrics," *Ruan Jian Xue Bao(Journal of Software)*, vol. 17, pp. 1824-1836, 2006.
- [42] D. Zhang, G.-M. Lu, A. W.-K. Kong, and M. Wong, "Online palmprint identification system for civil applications," *Journal of Computer Science and Technology*, vol. 20, pp. 70-76, 2005.
- [43] N. K. Kachhi, "An efficient occlusion invariant palmprint based verification system," *M. Tech Thesis, Indian Institute of Technology Kanpur*, 2009.
- [44] Z. Sun, T. Tan, Y. Wang, and S. Z. Li, "Ordinal palmprint representation for personal identification [representation read representation]," in *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, 2005, pp. 279-284.
- [45] Y. Hao, Z. Sun, and T. Tan, "Comparative studies on multispectral palm image fusion for biometrics," *Computer Vision-ACCV 2007*, pp. 12-21, 2007.
- [46] D. Zhang, Z. Guo, G. Lu, L. Zhang, and W. Zuo, "An online system of multispectral palmprint verification," *IEEE transactions on instrumentation and measurement*, vol. 59, pp. 480-490, 2010.
- [47] polytechnic,"PolyU,"
<http://www4.comp.polyu.edu.hk/~biometrics/MultispectralPalmprint/MSP.htm>, 2010.

ÖZGEÇMİŞ

Adı Soyadı : Hend .H. A. ELMEZOGHI
Doğum Yeri ve Yılı : Libia / 1975
Medeni Hali : Evli
Yabancı Dili : İngilizce
E-posta : hindhh_2007@yahoo.com



Eğitim Durumu

Lise : Alshaeb Alththayir /1994
Lisans : Tripoli Üniversitesi Bilim koleji Matematik Bölümü/1999
Yüksek Lisans : Tripoli Üniversitesi Lisansüstü Çalışmalar Akademisi /2005

Mesleki Deneyim

İş Yeri : Bilgisayar ve Matematik Öğretmenliği, Libya Eğitim Bakanlığı 2000- 2007
İş Yeri : Nasır Üniversitesi (Zaytouna)/ 2007-

Yayımları

- [1] **Hend hadia almezoghy**, mansur m. Ali, javad rahebi, aybaba hancerliogullari," human identification with palm print based on local binary pattern", International journal of engineering innovation & researc, Volume 6, issue 5, Issn: 2277 – 5668.
- [2] Mansur Mohamed Ali, Khalifa Nusrat, Abdelhafid Ali I. Mohamed, Mohamed Ali Hagal, Hend **Hadia Ali Almezogi**, Javad Rahebi, Aybaba Hançerlioğullariology," finger vein recognition with gray level co- occurrence matrix based on discreet wavelet transform" international journal of computer science and technology ,ijcst vol. 8, iss ue 2, april - june 2017.

[3] **Hend hadia almezoghy** “Human identification with palm print based on local binary pattern And co-occurrence matrix”, International Journal of Research in Engineering & Technology Vol. 7, Issue 4, 2019.

[4] Hend hadia almezoghy, “Human Identification with Palm print Based on Local Binary Pattern”, International Conference on Multidisciplinary Engineering, Science, Education and Technology (IMESET’17 Baku) Hosted by Azerbaijan Technical University July 12-14, 2017.

