

**T.C
BURSA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ ALGORİTMALARINI KULLANARAK OTOMATİK
PARMAK DAMARI TANIMA SİSTEMİ**

DOKTORA TEZİ

**Mustafa KOCAKULAK
151081602**

Mekatronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Nurettin ACIR

Eş Danışmanı: Prof. Dr. Hakan GÜRKAN

OCAK 2023

BTÜ, Lisansüstü Eğitim Enstitüsü'nün 151081602 numaralı Doktora Öğrencisi Mustafa KOCAKULAK, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "MAKİNE ÖĞRENMESİ ALGORİTMALARINI KULLANARAK OTOMATİK PARMAK DAMARI TANIMA SİSTEMİ" başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Nurettin ACIR**
Milli Savunma Üniversitesi

Eş Danışman : **Prof. Dr. Hakan GÜRKAN**
Bursa Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Ahmet Fevzi BABA**
Marmara Üniversitesi

Doç. Dr. Cemal HANILÇI
Bursa Teknik Üniversitesi

Doç. Dr. Engin Cemal MENGÜÇ
Kayseri Üniversitesi

Doç. Dr. Gökhan GELEN
Bursa Teknik Üniversitesi

Teslim Tarihi :
Savunma Tarihi : 16 Ocak 2023



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, Bursa Teknik Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

İNTİHAL BEYANI

Bu tezde görsel, işitsel ve yazılı biçimde sunulan tüm bilgi ve sonuçların akademik ve etik kurallara uyularak tarafımdan elde edildiğini, tez içinde yer alan ancak bu çalışmaya özgü olmayan tüm sonuç ve bilgileri tezde kaynak göstererek belgelediğimi, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

Öğrencinin Adı Soyadı:

İmzası:





Başta rahmetli dedem Yusuf Kocakulak ve rahmetli anneannem
Muazzez Güleç olmak üzere çok sevdiğim aileme,

ÖNSÖZ

Doktora sürecinde bilgi birikimini ve deneyimlerini benimle paylaşıp desteğini esirgemeyen Prof. Dr. Nurettin Acır'a sabrı ve yol göstericiliği için çok teşekkür ederim. Bu çalışmanın ortaya çıkmasında değerli görüşleri ve yönlendirmeleri ile katkılarını sunan tez izleme komitesindeki Doç. Dr. Cemal Hanilçi, Doç. Dr. Gökhan Gelen ve idari konularda danışma fırsatı bulduğum Prof. Dr. Hakan Gürkan'a teşekkür ederim. Ayrıca tez savunmasında yer alıp, tez ile ilgili değerli görüş ve eleştirilerini paylaşan tüm öğretim üyelerine teşekkür ederim. Doktora eğitimim sırasında sağladığı yurt dışı araştırma bursu YUDAB ile bana doktora çalışmalarına Autonoma de Madrid Üniversitesi'nde devam etme fırsatı veren Yükseköğretim Kurulu'na çok teşekkür ederim. Bu deneyimi yaşamam için beni yüreklendiren Prof. Dr. Nurettin Acır'a ve bu süreçte bana idari konularda yardımcı olan Bursa Teknik Üniversitesi'ne çok teşekkür ederim. İspanya'da geçirdiğim bir yıl boyunca bana yol gösteren, idari ve akademik konularda desteğini esirgemeyen Prof. Dr. Julian Fierrez'e ve tüm Biometrics and Data Pattern Analytics (BIDA Lab) araştırma grubu üyelerine, tezin bölümlerinin oluşumuna olan katkıları ve doktora sırasında yaşadığım bu eşsiz yurt dışı deneyimi için teşekkürü bir borç bilirim. Doktora sürecinde birlikte çalışma fırsatı bulduğum Arş. Gör. Adem Avcı, Dr. Öğr. Üyesi Ruben Tolosana, Arş. Gör. Mustafa Çoban, Dr. Öğr. Üyesi Gürkan Aydemir, Arş. Gör. Oğuzhan Kurnaz ve Arş. Gör. Tahir Bekiryazıcı başta olmak üzere fikir alışverişinde bulunduğum tüm çalışma arkadaşlarıma destekleri için teşekkür ederim. Eğitim hayatının oldukça uzun bir süreç olduğunu düşünerek, bu yaşa gelene kadar bana emek veren ve beni ben yapan değerlere katkı veren tüm öğretmenlerime çok teşekkür ederim. Umarım ben de onlar gibi ülkemize değer katacak ve aydınlık yarınlara ulaşmamıza katkı sağlayacak bireylerin yetişmesinde rol alan bir akademisyen olurum. Görev yaptığım süre içerisinde derslerine ve laboratuvarlarına destek verdiğim tüm öğrenci arkadaşlarıma bana gösterdikleri saygı ve sevgiden dolayı teşekkür ederim.

Son olarak babam İbrahim Kocakulak, annem Fatma Kocakulak, ablalarım Emine Erdem ve Hatice Karlık'a teşekkür etmek istiyorum. Hayatın her alanında olduğu gibi bu süreçte de onların bana olan inançlarını ve desteklerini hissetmek çok değerliydi. En önemlisi ise, başta sağlık ve aile olmak üzere tüm güzel şeyleri bana nasip eden Yüce Allah'a şükürümü belirtmek isterim.

Bu tez çalışmasında, makine öğrenmesinin bir alt kolu olan derin öğrenmeye ait çeşitli modeller başta parmak damarı tanıma olmak üzere, doğrulama ve görüntüleme uygulamaları için kullanılmış ve ortaya koyulan performans kapsamlı bir biçimde değerlendirilmiştir. Detaylı literatür taraması sonrası yürütülen deneyler sonucunda oluşturulan veri setinin, geliştirilen parmak damarı görüntüleme sisteminin ve sentetik görüntüleri kullanan tanıma sisteminin, bu alanda çalışan ve etkin Türkçe kaynak arayışında olan araştırmacılara katkı sağlaması dileğiyle.

İÇİNDEKİLER

Sayfa

ÖNSÖZ	vi
İÇİNDEKİLER	viii
KISALTMALAR	ix
SEMBOLLER	x
ÇİZELGELER LİSTESİ	xi
ŞEKİLLER LİSTESİ	xii
ÖZET	xiv
SUMMARY	xv
1 GİRİŞ	1
1.1 Tezin Motivasyonu, Kapsamı ve Katkıları	1
1.2 Tezin Kısıtları	2
1.3 Tezin Ana Hatları	3
2 KURAMSAL ÇERÇEVE VE LİTERATÜRDEKİ ÇALIŞMALAR	4
2.1 Biyometri	4
2.1.1 Tanımı	4
2.1.2 Kimlik doğrulama yöntemleri	4
2.1.3 Biyometrik özellikler	5
2.1.4 Biyometrik özelliklerin nitelikleri	7
2.1.5 Çok kipli biyometri	8
2.1.6 El tabanlı biyometrik özellikler	9
2.2 Parmak Damarı Tabanlı Biyometri	10
2.2.1 Parmak damarı ve özellikleri	11
2.2.2 Damar görüntüleme yöntemleri	12
2.2.3 Yakın kızılötesi ışık ve özellikleri	12
2.2.4 Görüntüleme platformunda kullanılan aydınlatma teknikleri	14
2.2.5 Halka açık parmak damarı veri setleri	15
2.2.6 Özellik çıkarma yöntemleri ve özellikleri	16
2.3 Literatürdeki İlgili Çalışmalar	19
2.3.1 Kimlik tanıma	20
2.3.1.1 Tanıma ile ilgili çalışmalar	21
2.3.2 Kimlik doğrulama	23
2.3.2.1 Doğrulama ile ilgili çalışmalar	25
2.3.3 Görüntüleme	29
3 MATERYAL VE YÖNTEM	32
3.1 Materyal	32
3.2 Yöntem	34
3.2.1 Sentetik veri seti oluşturma	34
3.2.2 Evrişimsel sinir ağları	36
3.2.3 Evrişimsel sinir ağı mimarileri	39
3.2.4 Öğrenim aktarımı	42
3.2.5 Öz dikkat mekanizması	43
3.2.6 Doğrulama uygulamalarında özellik vektörlerinin kullanılması	44
3.2.7 MediaPipe Hands çerçevesi ve avuç içi izi çıkarımı	47
3.2.8 Damar görüntüleme sistemleri	49

4 DENEYSEL SONUÇLAR ve TARTIŞMA	50
4.1 Oluşturulan Sentetik Veri Seti Hakkında	50
4.2 Tasarlanan Empirik Tanıma Modelleri ve Elde Edilen Sonuçlar	51
4.3 Artan Veri ve Öğrenim Aktarımı ile Elde Edilen Sonuçlar	56
4.4 Sentetik Veri Seti ile Tasarlanan Parmak Damarı Tanıma Uygulaması	59
4.5 Öz Dikkat Mekanizması Tabanlı Damar Doğrulama Uygulaması	63
4.6 Halka Açık Avuç İçi İzi Veri Setinde İlgi Bölgesi Çıkarımı	67
4.7 Makine Öğrenmesi Destekli Avuç İçi İzi Görüntüleme Platformu Tasarımı	71
4.8 Makine Öğrenmesi Destekli Çerçevenin Çok Kipli Tasarımlara Etkisi	76
4.9 Görüntü İşleme Destekli Damar Görüntüleme Cihazı Tasarımı	80
5 SONUÇ VE ÖNERİLER	84
KAYNAKLAR	87
ÖZGEÇMİŞ	99



KISALTMALAR

ARM	: Advanced RISC Machines
ATM	: Automated Teller Machine
CCD	: Charged Coupled Device
CMOS	: Complementary Metal Oxide Semiconductor
CPU	: Central Processing Unit
DNA	: Deoksiribonükleik Asit
DTO	: Doğru Tanıma Oranı
EHO	: Eşit Hata Oranı
ESA	: Evrişimsel Sinir Ağları
GB	: Gigabyte
GPU	: Graphics Processing Unit
LED	: Light Emitting Diode
MRI	: Magnetic Resonance Imaging
NFC	: Near Field Communication
nm	: Nanometre
PIN	: Personal Identification Number
PUK	: Personal Unlocking Key
RAM	: Random Access Memory
RFID	: Radio Frequency Identification
YEO	: Yanlış Eşleşme Oranı
YKO	: Yanlış Kabul Oranı
YRO	: Yanlış Reddetme Oranı

SEMBOLLER

θ	: Orta parmağın y eksenine göre dönme açısı
t	: ROC eğrisindeki eşik değeri
m_{pq}	: Moment bileşenleri
$X_{centroid}$: Avuç içi ağırlık merkezinin x koordinat bileşeni
$Y_{centroid}$: Avuç içi ağırlık merkezinin y koordinat bileşeni
N	: Veri tabanındaki toplam kişi sayısı
t	: Zaman
$f(i,j)$: İkili görüntü
n	: Veri setindeki toplam kişi sayısı
r	: Veri setindeki kişilerin kullanılan parmak sayısı
m	: Veri setindeki kişilerin parmaklarından alınan örnek sayısı
λ	: Dalga boyu
d	: Koordinat sistemindeki A ve B noktaları arasındaki mesafe
q	: Minkowski mesafe mertebesi
$V1$: "A" şahsı için ESA'nın çıkardığı özellik vektörü
$V2$: "B" şahsı için ESA'nın çıkardığı özellik vektörü
θ	: A ve B noktaları arasındaki açı

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1:	Sıkça tercih edilen bazı biyometrik özellikler.	6
Çizelge 2.2:	Biyometrik özelliklere ait bazı nitelikler.	7
Çizelge 2.3:	Bazı biyometrik özelliklerin öne çıkan özellikleri.	7
Çizelge 2.4:	Bazı el tabanlı biyometrik özellikler.	9
Çizelge 2.5:	Bazı içsel fiziksel biyometrik özellikler.	10
Çizelge 2.6:	Halka açık parmak damarı veri setleri ve özellikleri.	16
Çizelge 2.7:	Piyasadaki bazı parmak damarı görüntüleme cihazları.	30
Çizelge 2.8:	Akademide tasarlanan bazı parmak damarı görüntüleme cihazları.	31
Çizelge 3.1:	Bazı ESA mimarilerine dair bilgiler.	41
Çizelge 4.1:	SDUMLA-FV için tasarlanan ESA modeli.	52
Çizelge 4.2:	FV-USM için tasarlanan ESA modeli.	53
Çizelge 4.3:	MMCBNU-FV için tasarlanan ESA modeli.	54
Çizelge 4.4:	ESA modellerinin veri setlerinde ulaştığı test kesinlik değerleri. .	55
Çizelge 4.5:	ResNet50 ile elde edilen DTO sonuçları.	57
Çizelge 4.6:	DenseNet121 ile elde edilen DTO sonuçları.	58
Çizelge 4.7:	DenseNet169 ile elde edilen DTO sonuçları.	58
Çizelge 4.8:	DenseNet201 ile elde edilen DTO sonuçları.	59
Çizelge 4.9:	Önerilen Öz dikkat mekanizması tabanlı ESA modeli.	65
Çizelge 4.10:	Mesafe metrikleri için elde edilen EHO değerleri.	66
Çizelge 4.11:	Literatürde SDUMLA-FV veri seti için elde edilmiş EHO değerleri.	66
Çizelge 4.12:	Elde edilen avuç içi izi çıkarımı doğruluk ve süre değerleri. . . .	70
Çizelge 4.13:	Technocampus veri seti ve özellikleri.	77
Çizelge 4.14:	Elde edilen parmak bölgesi çıkarımı doğruluk değerleri.	78

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1:	Kimlik doğrulama yöntemleri.	5
Şekil 2.2:	Fiziksel biyometrik özelliklerin devinime göre sınıflandırılması.	6
Şekil 2.3:	Fiziksel biyometrik özelliklerin konuma göre sınıflandırılması.	6
Şekil 2.4:	Biyometrik özelliklerin 2015 yılındaki dünya geneli pazar payı.	8
Şekil 2.5:	Çok kipli biyometri çeşitleri.	9
Şekil 2.6:	Değişen dalga boylarında kandaki 3 bileşene ait emilim katsayıları.	12
Şekil 2.7:	Elektromanyetik spektrumunda görünür ışığın yeri.	13
Şekil 2.8:	Aydınlatma tekniklerinden geçiş yöntemi.	14
Şekil 2.9:	Aydınlatma tekniklerinden yansıtma yöntemi.	15
Şekil 2.10:	Parmak damarı örnekleri a) HKPU b) SDUMLA-FV.	16
Şekil 2.11:	Özellik çıkarma teknikleri.	17
Şekil 2.12:	Biyometrik bir sistemde kimlik tanıma sürecine ait akış şeması.	21
Şekil 2.13:	Biyometrik bir sistemde kimlik doğrulama sürecine ait akış şeması.	24
Şekil 2.14:	Biyometrik bir sistemde kayıt sürecine ait akış şeması.	29
Şekil 3.1:	Arayüz ile oluşturulan parmak damarının anlık görüntüleri.	35
Şekil 3.2:	Parmak damarı sentezlemeyi sağlayan parametrik arayüz.	36
Şekil 3.3:	Makine öğrenmesi ve derin öğrenme arasındaki ilişki.	36
Şekil 3.4:	Basit bir yapay sinir ağı örneği.	37
Şekil 3.5:	Basit bir ESA'ya ait özellik çıkarım katmanları.	38
Şekil 3.6:	Basit bir ESA'ya ait sınıflandırma katmanları.	39
Şekil 3.7:	ESA mimarilerinden bazıları.	40
Şekil 3.8:	Veri setlerinin performans analizi için ayrıştığı alt kümeleri.	41
Şekil 3.9:	ESA model performans değerlendirmesine ait akış diyagramı.	42
Şekil 3.10:	Öğrenim aktarımındaki temel işleyiş.	43
Şekil 3.11:	Önerilen modeldeki Öz dikkat mekanizması bloğu.	44
Şekil 3.12:	Aralarında d uzaklığı bulunan A ve B noktaları.	45
Şekil 3.13:	İki resimden ESA kullanarak öznelik vektörü çıkarımı.	46
Şekil 3.14:	Öznelik vektörlerinin doğrulama amaçlı karşılaştırılması.	46
Şekil 3.15:	MediaPipe Hands el işaretçileri (Lugaresi ve diğ, 2019).	48
Şekil 4.1:	Parmak damarı görüntüleri a) Sentetik b) Gerçek.	50
Şekil 4.2:	Aynı parmağa ait sentetik görüntüler a) İlk örnek b) İkinci örnek.	50
Şekil 4.3:	Sentetik veri setindeki bir kullanıcıya ait örnek görüntüler.	51
Şekil 4.4:	SDUMLA-FV veri setine ait kayıp ve kesinlik grafikleri.	54
Şekil 4.5:	FV-USM veri setine ait kayıp ve kesinlik grafikleri.	55
Şekil 4.6:	MMCBNU-FV veri setine ait kayıp ve kesinlik grafikleri.	55
Şekil 4.7:	Jetson Nano 4 GB.	60
Şekil 4.8:	Jetson Nano kullanarak oluşturulan tanıma programına ait kısayol.	60
Şekil 4.9:	Parmak damarı tanıma sistemine ait arayüz.	61
Şekil 4.10:	Arayüzde gerçekleşen kayıt silme bildirim ekranı.	61
Şekil 4.11:	Arayüzde gerçekleşen kullanıcı sorgulama bildirim ekranı.	62
Şekil 4.12:	Teachable Machine web arayüzüne tanıtılan sentetik veriler.	62
Şekil 4.13:	Başarıyla sonuçlanan tanıma uygulamasına ait ekran.	63
Şekil 4.14:	Başarısızlıkla sonuçlanan tanıma uygulamasına ait ekran.	63
Şekil 4.15:	Önerilen modeldeki ResNet bloğu.	64
Şekil 4.16:	Uygulamaya ait dağılımlar a) Cosine Minkowski b) Manhattan.	64

Şekil 4.17:	SDUMLA-FV için uygulamada elde edilen ROC eğrisi.	66
Şekil 4.18:	IITDTP veri setine ait örnek avuç içi görüntüsü.	67
Şekil 4.19:	Önerilen avuç içi izi çıkarma yöntemi adımları.	67
Şekil 4.20:	CLAHE sonrası el işaretçileri belirlenmiş avuç içi görüntüsü. . .	68
Şekil 4.21:	Avuç içi izi bölgesi doğru bir şekilde belirlenmiş görüntü örneği.	69
Şekil 4.22:	IITDTP veri setindeki görüntüler ve belirlenen el işaretçileri. . .	70
Şekil 4.23:	Çıkarılan örnek avuç içi izi görüntüsü.	71
Şekil 4.24:	Avuç içi izi görüntülemek için kurulan deney düzeneği.	72
Şekil 4.25:	Kurulan görüntüleme sistemi elemanları.	73
Şekil 4.26:	Raspberry Pi ve Raspberry Pi Camera bağlantı ilişkisi.	73
Şekil 4.27:	El platformda değilken ekrandaki görüntü.	74
Şekil 4.28:	El tam olarak platformda değil iken ekrandaki görüntü.	74
Şekil 4.29:	El tam olarak platformda iken ekrandaki görüntü.	75
Şekil 4.30:	Görüntüleme platformundaki el ve ona ait el işaretçileri.	76
Şekil 4.31:	Çıkarılan örnek avuç içi izi görüntüsü.	76
Şekil 4.32:	El tabanlı biyometrik özellikler (Anitha ve Rao, 2015).	77
Şekil 4.33:	Technocampus veri setinden alınan örnek görüntüler.	77
Şekil 4.34:	Önerilen parmak bölgesi çıkarma yöntemi adımları.	78
Şekil 4.35:	Örnek görüntülerde belirlenen el işaretçileri.	79
Şekil 4.36:	LG G4 telefon ekranı ve kamerası.	80
Şekil 4.37:	Tasarlanan görüntüleme cihazının önden görünüşü.	81
Şekil 4.38:	Tasarlanan görüntüleme cihazının üstten görünüşü.	81
Şekil 4.39:	Tasarlanan cihazda görüntü işlemeye imkan veren Android arayüzü.	82
Şekil 4.40:	Tasarlanan görüntüleme cihazının cepheden görünüşü.	83
Şekil 4.41:	Tasarlanan cihazdan alınan örnek parmak damarı görüntüsü. . .	83
Şekil 4.42:	Yansıtma tekniği ile elde edilmiş görüntü örnekleri a) (Zhang ve diğ, 2015) b) (Van Tien ve diğ, 2015).	84

MAKİNE ÖĞRENMESİ ALGORİTMALARINI KULLANARAK OTOMATİK PARMAK DAMARI TANIMA SİSTEMİ

ÖZET

Hızla artan dünya nüfusu ve durmadan gelişen teknoloji ile hayatın hemen her alanında, güvenlik ve erişim kontrolü gibi çeşitli sebeplerle biyometrik sistemlere ihtiyaç duyulmaktadır. Son yıllarda duyulan ihtiyacı karşılamak için makine öğrenmesi bilhassa da derin öğrenme, biyometrik sistemlerde yaygın olarak kullanılmaktadır. Bu sistemlere hızlı ve düşük maliyetli çözümler sunan parmak damarı, kişiye özgü olmak, zamanla değişime uğramamak ve dış müdahalelere kapalı olmak gibi çeşitli avantajlara sahip olan bir biyometri türüdür. Bu tez, parmak damarı biyometrisini başta parmak damarı tanıma olmak üzere 3 ana başlıkta inceleyip bu başlıklar altında karşılaşılan 3 farklı probleme, makine öğrenmesi algoritmalarını kullanarak çözüm getirmeyi amaçlamaktadır. İlk olarak, derin öğrenme uygulamalarının başarımına katkı sağlayacak sayıda kişi ve bu kişilerden alınan yeterli sayıda örnek içeren halka açık herhangi bir parmak damarı veri seti bulunmamaktadır. Bu sebeple yazılımsal bir çözüm kullanarak sentetik parmak damar görüntüleri içeren kapsamlı bir veri seti oluşturulmuş ve bu veri seti erişime açılmıştır. İkinci olarak, oluşturulan sentetik veri seti kullanılarak, yeterli sayıda kişi ve örnek içeren bir veri seti sağlandığında literatürdeki tanıma uygulamalarında elde edilen performansın ulaşabileceği değerler kestirilmiştir. Yapılan çalışmalarda, bu uygulamalarda elde edilen başarıma kişi ve örnek sayısının etkisi gözlemlenmiştir. Buna ek olarak birkaç halka açık veri seti kullanılarak tasarlanan çeşitli derin öğrenme modelleri aracılığıyla elde edilen tanıma ve doğrulama performanslarının ulaştığı başarımlar değerlendirilmiştir. Son olarak piyasada bulunan parmak damarı tanıma cihazları, kullanıcıların ham verilere erişmesine izin vermediğinden, bu çalışmada tasarlanan görüntüleme cihazı ile kullanıcılara, platformdan alınan parmak damarı görüntülerine erişim hakkı verilmektedir. Bu cihaz ile bazı el tabanlı biyometrik özelliklerin parmak damarı ile aynı anda kullanılmasını kolaylaştıran, herhangi bir fiziksel sensör kullanmayan ve çok kipli biyometrik sistemlerin önünü açan makine öğrenmesi tabanlı bir çözüm önerilmiştir.

Anahtar kelimeler: Biyometri, Doğrulama, Görüntüleme, Makine Öğrenmesi, Parmak Damarı, Tanıma.

AUTOMATIC FINGER VEIN RECOGNITION SYSTEM USING MACHINE LEARNING ALGORITHMS

SUMMARY

With the rapidly increasing world population and constantly developing technology, biometric systems are required in almost every area of life for various reasons such as security and access control. To meet the need in recent years, machine learning, especially deep learning, is widely used in biometric systems. Finger vein, which offers quick and low-cost solutions to these systems, is a type of biometrics with various advantages such as being unique, not changing over time, and being closed to outside interventions. This thesis aims to analyze finger vein biometry under 3 main headings, primarily finger vein identification, and to find solutions to 3 different problems encountered under these headings using machine learning algorithms. First, there is no publicly available finger vein dataset that contains a sufficient number of individuals and samples from these individuals to contribute to the performance of deep learning applications. For this reason, a comprehensive dataset containing synthetic finger vein images was created using a software solution and this dataset was made accessible. Secondly, when a data set containing a sufficient number of subjects and samples are provided using the synthetic data set created, the values that the performance obtained in the identification applications in the literature can reach were estimated. In the studies, the effect of the number of people and samples on the success achieved in these applications was observed. In addition, recognition and validation performances obtained through various deep learning models designed using several publicly available datasets were evaluated. Finally, since finger vein recognition devices on the market do not allow users to access raw data, users are given access to finger vein images taken from the platform with the imaging device designed in this study. With this device, a machine learning-based solution has been proposed that facilitates the simultaneous use of some hand-based biometric traits with the finger vein, does not use any physical sensors, and paves the way for multi-modal biometric systems.

Keywords: Biometrics, Verification, Imaging, Machine Learning, Finger Vein, Identification.

1. GİRİŞ

Günümüzde makine öğrenmesi, mühendislik ve finans başta olmak üzere çeşitli alanlarda yaygın olarak kullanılmaktadır. Günlük hayatta toplanan verilerin katlanarak artmasıyla başarı için veriye ihtiyaç duyan makine öğrenmesi algoritmaları, başta sınıflandırma ve regresyon olmak üzere, farklı alanlarda çeşitli problemlere etkin çözümler üretmektedir. Geleneksel öznitelik çıkarma algoritmaları kullanılmadan, makine öğrenmesi algoritmalarıyla öğrenme yeteneği kazandırılmış sistemler aracılığıyla, pek çok probleme oldukça yüksek performansla sahip çözümler sunulmaktadır.

1.1 Tezin Motivasyonu, Kapsamı ve Katkıları

Makine öğrenmesinin kullanım alanlarından biri olabilecek biyometrik sistemler, kişiye ait doğuştan gelen fiziksel özellikleri ve zaman içerisinde kişi tarafından benimsenmiş davranışsal özellikleri tanıma amaçlı yapılardır. Parmak izi tanıma, yüz tanıma, iris tanıma, el yazısı tanıma ve parmak damarı tanıma, günümüzde kullanılan başlıca biyometrik sistemlerdir. Diğer sistemlerden farklı olarak parmak damarı tanıma sistemleri düşük maliyet, kolay uygulanabilirlik ve değiştirilip dönüştürülmeye karşı dayanıklı olmak gibi bazı kullanım avantajları sunmaktadır. Kol ve el sırtı gibi damar tabanlı diğer biyometrik sistemlerle karşılaştırıldığında parmak damarı, parmak bölgesi tüysüz bir yapıda olduğu için görüntüleme sistemleri açısından daha elverişli koşullara sahiptir. Tüm bu etkenlerin yanı sıra, piyasadaki biyometrik cihazlar sadece tanıma ve doğrulama işlemine odaklanıp ham görüntülere erişim izni vermediği için araştırma konusu olarak parmak damarı biyometrisi tercih edilmiştir.

Yaklaşık 20 yıldır literatürde yer alan parmak damarı biyometrisi ve son 6 yıldır bu alanda yapılan çalışmalarda aktif bir biçimde kullanılan makine öğrenmesi algoritmaları dikkate alınarak, parmak damarı biyometrisi konusunda saygın dergilerde ortaya konulan makine öğrenmesi temelli yayınları konu edinen kapsamlı bir literatür taraması ile yola çıkılmıştır. Bu tarama, diğer tarama çalışmalarından farklı olarak derin öğrenmeden faydalanan yayınlara odaklıdır ve konuyu tanıma, doğrulama ve görüntüleme olmak üzere 3 ana başlıkta ele almıştır. Bu tezin motivasyonu, başta parmak damarı tanıma olmak üzere bu 3 başlıkta karşılaşılan problemlere makine öğrenmesi algoritmalarını kullanarak çözümler sunmaktır.

Bu çalışma sonucunda elde edilen yenilikler şu şekilde özetlenebilir: Halka açık parmak damarı veri setleri arasında en fazla görüntü sayısına sahip veri seti 100 kişiden alınan 6000 görüntüye sahipken, bu çalışmada oluşturulup paylaşımına açılan veri seti, 1600 kişiden alınan onar adet sentetik parmak damarı görüntüsüyle oluşturulmuştur ve 16000 görüntüye sahiptir. Bilindiği gibi literatürde, artan görüntü sayısının derin öğrenme uygulamalarında elde edilen performansa katkı sağlayacağı beyan edilmektedir. Başarı için veri hacmine ihtiyaç duyan makine öğrenmesi algoritmalarının parmak damarı konusunda veri ihtiyacı karşılandığında ortaya koyduğu DTO performansı, bu çalışma ile gözler önüne serilmiştir.

Üretilen sentetik veri setini kullanarak gerçekleştirilen ikinci çalışmada, 1600 farklı kullanıcı içeren bir parmak damarı tanıma sistemi oluşturulmuştur. Sentetik verileri kullanarak oluşturulan bu parmak damarı tanıma sistemi, bünyesinde bir gömülü

sistem ve bir tablet ekranı barındırmaktadır. Bilgisayar yerine Jetson Nano'nun kullanıldığı bu mobil sistemde, MySQL ile oluşturulan veri tabanı ve Tkinter kullanarak tasarlanan kullanıcı arayüzü ile tanıma işlemi, 1600 kişiye ait sentetik parmak damarı görüntülerinin "Teachable Machine" adlı web arayüzünde eğitilmesi ile Evrimsel Sinir Ağları (ESA) kullanılarak gerçekleştirilmiştir.

Oluşturduğumuz sentetik veri seti üzerinde gerçekleştirilen çalışmalar sonrası literatürdeki erişime açık parmak damarı veri setleri üzerinde tanıma ve doğrulama uygulamaları gerçekleştirilmiştir. Bu tanıma ve doğrulama uygulamalarında elde edilen performans, yine bu tez kapsamında yapılan deneylerle ortaya konulmuştur. Literatürdeki çok sayıda çalışmanın, deneysel ayrıntıları paylaşmak yerine geçiştirip ihmal etmesi, tekrar edilebilirlik açısından sorunlu olup, bu durum akademik açıdan önem arz ettiği için bazı araştırmacıların dikkatini çekmiş ve çalışmalarına konu olmuştur. Nitekim, bu tez çalışması kapsamında erişime açık veri setleri üzerinde yapılan tanıma ve doğrulama ile ilgili deneylerde elde edilen performans değerleri bir kısıt olarak karşımıza çıkmış ve bu değerlerin literatürde elde edilen gelmiş geçmiş en iyi değerlere yaklaşmadığı görülmüştür. Tez kapsamında yeni mesafe metrikleri önerilmesine rağmen bu metriklerin elde edilmiş skorları aşamadığı görülmüştür.

Bu tez çalışmasında, Google'a ait olan ve işaret dili tanıma amacıyla kullanılan makine öğrenmesi tabanlı bir çerçevenin, parmak damarı görüntüleme amacıyla görüntüleme öncesinde kullanılması önerilmiştir. Bu çerçevenin kullanılma sebebi, parmağa ait boğumları bulmaktaki üstün başarısıdır. Ayrıca bu çerçeve, parmak damarının alındığı elin sağ ya da sol el olduğunu, herhangi bir fiziksel sensör kullanımına ihtiyaç duymadan teşhis edebilmektedir. Piyasadaki parmak damarı görüntüleme sistemleri kapalı kutu formunda olup ham görüntüye erişim imkanı vermediğinden, ham veriye erişime izin veren ve eli cepheden gören bir görüntüleme sistemine ait tasarım tez kapsamında sunulmuştur. Android işletim sistemi için OpenCV kütüphanesini kullanarak yazılan ve basit görüntü işleme fonksiyonları içeren bir uygulama ile tasarlanan sistemden alınan damar görüntülerini, anlık olarak izlemek ve işlemek mümkündür.

Görüntüleme sisteminde kullanılan makine öğrenmesi tabanlı çerçevenin, avuç içi izi ilgi bölgesi çıkarımında hız ve doğruluk açısından geleneksel görüntü işleme yöntemlerine göre bazı avantajlar sağladığı, halka açık IITDTP avuç içi veri seti üzerinde kanıtlanmıştır. Bu çalışmadan hareketle, bir avuç içi izi görüntüleme sistemi Raspberry Pi 4 kullanılarak oluşturulmuş ve gerekli etik kurulu onay belgesinin alınması sonrası, veri toplama işlemi gerçekleştirilip halka açık bir avuç içi izi veri seti paylaşılacaktır. Biyometrik amaçlarla ilk kez kullanılması önerilen bu makine öğrenmesi tabanlı yapı sayesinde parmak damarı, el sırtı damarı, el geometrisi, tırnak, parmak boğumu, avuç içi izi ve avuç içi damarı gibi el tabanlı biyometrik özelliklere ait ilgi bölgelerinin kolayca çıkarılabileceği, halka açık Tecnocampus Hand Image veri seti üzerinde gösterilmiştir.

1.2 Tezin Kısıtları

Biyometrik verilerin gizliliği hususunda biyometrik verileri toplanacak kişilerin yaşadığı endişeyi gidermenin ve onları gönüllü olmaya ikna etmenin oldukça zor

olduğu yadsınamaz bir gerçektir. Buna ek olarak ani gelişen ve tüm dünyayı 2 yıl boyunca etkisi altına alan COVID-19 salgını nedeniyle, veri seti oluşturamamak karşılaştığımız ilk kısıttır. Bu kısıt, yazılım tabanlı sentetik bir veri seti oluşturularak aşılmıştır. Eldeki halka açık veri setlerinin, kısıtlı sayıda kişiden yine kısıtlı sayıda örnek görüntü içermesi derin öğrenme uygulamaları açısından bir handicap iken yaşanan bu problem, sentetik görüntüler içeren ve çalışma kapsamında oluşturulup Github (<https://github.com/mustafakocakulak>) üzerinden paylaşımına açılan kapsamlı bir veri seti ile çözülmüştür.

Kızılötesi ışıktan faydalanan parmak damarı görüntüleme sistemini platform olarak oluşturmak zor değil iken, kontrast açısından bu platformdan verimli görüntüler elde etmek oldukça zormuş. Kızılötesi ışığın karakteristiğinden kaynaklanan bu sorun, tez öncesinde öngörülememesine rağmen, platform dizaynında sunulan çeşitli çözümlerin birleşimiyle aşılmaya çalışılmıştır. Yapılan denemeler ve oluşturulan prototipler sonucunda, görüntü işlemeye imkan veren yazılımsal bir çözüm ile mobil bir görüntüleme sistemi tasarlanıp ham veriye ulaşım sağlanmış ve kullanıcıya sunulan ekran vasıtasıyla görüntüyü işleme imkanı verilmiştir.

Literatürdeki halka açık parmak damarı veri setlerini kullanan çalışmalar ve bu çalışmaları kullanarak yapılan performans karşılaştırmaları, aynı test protokolünü veya aynı veri setlerini kullanmamalarına rağmen, bir şekilde kullanılan veri seti üzerinde elde edilen en iyi değere odaklanmaktadır. Bilimsel açıdan hatalı olan bu yaklaşıma ek olarak yapılan çalışmaların tekrarlanabilirlik açısından deneysel çalışmaları yeterince açıklamaması veya veri setindeki görüntüleri performans açısından istenilen amaca ulaştıracak şekilde belirsiz sayıda ve sırada ön işleme tabi tutması, bu alanda öngöremediğimiz bir durum ve yaşadığımız bir diğer kısıttır. Biyometrik bilgiler içeren bu görüntülere uygulanan her türlü işleme ait kaynak kodların paylaşılmaması, belirtilmemesi ya da biyometrik verilerin gizliliğini ihlal etmeme adına işleme tabi tutulan görüntülerin paylaşılabilmesi, tekrarlanabilirlik açısından sorun teşkil etmektedir.

1.3 Tezin Ana Hatları

Bu tez şu şekilde organize edilmiştir: Bölüm 1, bu tezin bağlamını, motivasyonunu, sağladığı katkıları ve sahip olduğu kısıtları özetlemektedir. Bölüm 2, biyometri ve biyometrik sistemler hakkında bilgi verip parmak damarı biyometrisini detaylı olarak incelemektedir. Ayrıca parmak damarı tanıma, parmak damarı doğrulama ve parmak damarı görüntüleme konularında literatürde yer alan çalışmaların kapsamlı analizini sunmaktadır. Bölüm 3, bu ana başlıklar altında bahsedilen çalışmalarda karşılaşılan problemleri veya eksiklikleri tanımlayıp, tez kapsamında önerilip uygulanan yöntemleri açıklamaktadır. Bölüm 4, bu problemleri gidermek için yapılan deneyleri içerip, önerilen yöntemler sayesinde elde edilen performans değerlerini literatürdeki sonuçlarla karşılaştırıp değerlendirmektedir. Bu deneylerde önerilen tanıma ve görüntüleme sistemlerinin sahip olduğu avantajlar ve dezavantajlar, literatürdeki mevcut sistemlerle kıyaslanarak bu bölümde sunulmuştur. Son olarak Bölüm 5, bu tezin sağladığı katkıların bir özetini karşılaşılan zorluklara değinip sunarak, geleceğe dair bir bakış açısıyla tezi sonuçlandırmaktadır.

2. KURAMSAL ÇERÇEVE VE LİTERATÜRDEKİ ÇALIŞMALAR

2.1 Biyometri

Biyometri günümüzde finans, sağlık ve güvenlik başta olmak üzere pek çok alanda sıkça kullanılmaktadır. Küresel dünyada hızla artan nüfus ve gelişen teknolojiyle, hayatın çeşitli alanlarında gerek emniyet gerekse yönetim açısından hızlı, güvenilir ve mobil tanıma sistemlerine ihtiyaç her zamankinden fazladır. Biyometrik teknolojilerdeki hızlı gelişim, yeni biyometrik özelliklerin keşfi ve kişisel verilerin korunumuna olan ihtiyaç göz önünde bulundurulduğunda, yakın gelecekte sağlanan biyometrik servislerin ve imkanların hızla artacağı aşikardır. COVID-19 döneminde dijital teknolojilere, uzaktan çalışmaya ve nakitsiz ödemeye geçişin hızlanması bu öngörüye destekler niteliktedir. Biyometrik sistemlere duyulan ihtiyacın sebeplerini sıralayacak olursak; iş yerlerinde personel takibi, etkinliklerde katılım takibi, araç ve ev güvenliği, teknolojik araç ve ekipmanlara kişiye özel erişim, kredi kartı ve ATM kullanımı, hasta takibi, uluslararası boyutta hava, kara ve deniz sınır güvenliği ve suçluların teşhisi için kriminal bellek oluşturulması ilk olarak akla gelen sebeplerdir (Vanoni ve diğ., 2014).

2.1.1 Tanımı

Günlük hayatın ayrılmaz bir parçası haline gelen biyometri, kişilerin belirli bir güvenlik seviyesi çerçevesinde tanınması ve kimliklerinin doğrulanmasını sağlamak amacıyla fiziksel veya davranışsal özelliklerinin ölçülmesi ve analiz edilmesi olarak tanımlanabilir (National Research Council, & Whither Biometrics Committee, 2010). Dolayısıyla biyometri, tanıma ve doğrulama olmak üzere ikiye ayrılır. Tanıma, sistem tarafından kişinin kim olduğunun belirlendiği, doğrulama ise kişinin olduğunu iddia ettiği kişi olup olmadığının belirlendiği süreçlerdir (Jain ve diğ., 2004). Bir veri tabanında, kişiye ait bilgilerin veri tabanına tanıtılıp taslak halinde tutulmasının ardından sisteme yapılacak her yeni girişte, kişiye ait olan bu taslağın, giriş esnasında sunulan bilgi ile belirli bir oranda uyuşması ve eşleşmesi beklenir. Bu eşleşme oranı, belirlenen eşik değerini aşıyorsa doğrulama gerçekleşir ve erişim izni sağlanır. Her yeni girişte gerçekleşen karşılaştırmalardaki uyuşma oranı çeşitli sebeplerle farklılık gösterebilir. Örneğin; ölçümün yapıldığı platformdaki sensörün yaşı, kalibrasyonu ve çevresel faktörler gibi birçok etken, bu eşleşme performansına etki eder (Qin ve El-Yacoubi, 2017b).

2.1.2 Kimlik doğrulama yöntemleri

Kimlik doğrulama yöntemleri, Şekil 2.1'de görüldüğü gibi taşınan materyal sayesinde, sahip olunan bilgi sayesinde ve sahip olunan biyometrik özellikler sayesinde olmak üzere 3 farklı yöntem ile kişilere sisteme erişim veya sisteme kendini tanıtmaya imkanı tanır (Chandra ve Calderon, 2003). Biyometrik özelliklerin kullanılmadığı durumlarda, doğrulama veya tanıma anlık arama, kısa mesaj atma, statik kod üretimi ve girilmesi, PIN ve PUK kodu girilmesi, RFID ve NFC kart kullanımı ve tek kullanımlık şifreler gibi çeşitli yollarla gerçekleştirilebilir. Tüm bu ve buna benzer yöntemler geleneksel yöntemlerdir. Geleneksel yöntemlerle kıyaslandığında biyometrik özellikler daha emniyetli ve daha güvenilirdir (Alariki ve diğ., 2018). Şifre, kart, mesaj veya desen bazlı olan geleneksel yöntemler unutulabilir, tahmin

edilip kırılabilir veya yetkisi olmayan insanların eline geçebilir. Biyometrik özellikler ise kişiye özgüdür ve devredilemez. Biyometrik özellikler, kişiye erişim izni sağlayan şeyleri kişinin ezberinde veya yanında bulundurma zorunluluğunu ortadan kaldırdığından, tüm geleneksel yöntemlerden pozitif ayrışır.



Şekil 2.1: Kimlik doğrulama yöntemleri.

Şifre, parola ve PIN kodu, bilgi sınıfında olup kişinin bilmesi sonucu erişime izin veren doğrulama yöntemleridir (Barral, 2010). Bilgiye dayalı sistemlerin dezavantajı, bilgilerin zamanla unutulması veya kötü niyetli şahıslar tarafından tahmin edilebilme ihtimalidir. Bilgiye dayalı bu yöntemlerin kolayca tahmin edilememesi ve çalınmaya karşı korunuyor olması gerekmektedir. Bu bilgilerin, sahibi dışındaki kişilerce bilinmesi ve başka ellere geçmesi büyük güvenlik zafiyetlerine yol açmaktadır. Bu sebeple, bu tarz geleneksel yöntemlerin paylaşılabilir olmaları, kolayca tahmin edilebilir olmaları ve unutulabilir olmaları onları güvenilir kılar. NFC ve RFID kartlar, sahiplik sınıfında olup kişinin yanında bulundurması sonucu erişime izin veren doğrulama yöntemleridir (Barral, 2010). Kişinin taşıdığı, başta onu tanıtmaya ve ona erişim izni verme amacı taşıyan bu kimlik kartları, başka ellere geçtiğinde kartı sahiplenen kişiye erişim imkanı sağlayacağından, biyometrik sistem güvenliği açısından risk teşkil eder. Bu nedenle, bu tip yöntemlerin kopyalanabilir olması, paylaşılabilir olması ve kaybedilip çalınma riski içermesi onları güvenilir kılar. Kişinin doğuştan sahip olduğu fiziksel biyometrik özellikleri ya da zamanla edinip benimsediği davranışsal biyometrik özellikleri ise kişinin genellikle istemsiz olarak sahip olduğu kendisine dair özellikler vasıtasıyla erişime izin veren doğrulama yöntemleridir (Jain ve diğ, 2004). Kişiyi tanımlayan ve oluşturan bu değerler kolayca kopyalanamaz ve tahmine kapalı yapıdadır. Taklit edilmesi veya ikinci şahıslar tarafından ulaşıp suistimal edilmesi, diğer doğrulama yöntemlerine göre oldukça düşük bir ihtimalle gerçekleşebilir. Barındırdığı yüksek güvenlik seviyesi nedeniyle, biyometrik özellikler geleneksel yöntemlere kıyasla daha güvenilirdir.

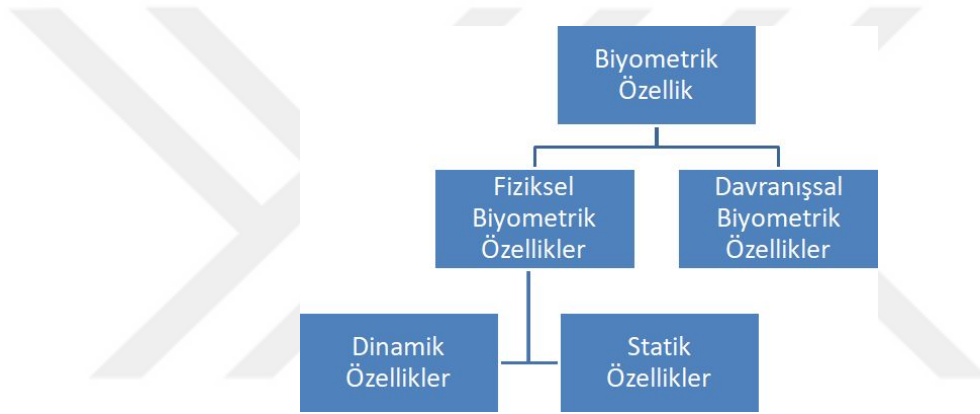
2.1.3 Biyometrik özellikler

Günümüzde sıkça kullanılan biyometrik özelliklerden bazıları Çizelge 2.1'de listelenmiştir (El-Sayed, 2015). Parmak izi (Jain ve diğ, (1997)), parmak damarı (Kumar ve Zhou, (2011)), yüz (Kshirsagar ve diğ, (2011)), iris (Daugman, (2009)), el sırtı damarı (Kumar ve Prathyusha, (2009)) ve avuç içi izi (Zhang ve diğ, (2003)) fiziksel biyometri türlerine örnektir. Ses (Ramírez ve diğ, (2007)), yürüyüş (Niyogi ve Adelson, (1994)) ve imza (El-Yacoubi ve diğ, (2002)) ise davranışsal biyometrik özelliklere örnektir.

Biyometrik özellikler, fiziksel ve davranışsal olmak üzere Şekil 2.2'deki gibi 2 ana kategoride incelenirken fiziksel biyometrik özellikler kendi içinde sahip olduğu devinime göre dinamik ve statik özellikler olarak incelenir (Tran ve diğ., 2021). Fiziksel biyometrik özelliklerden DNA, vücut ısısı, kan, tükürük ve ter dinamik fiziksel özelliklerden iken parmak izi, yüz ve el geometrisi statik fiziksel özelliklerdendir (Ducray ve diğ., 2017).

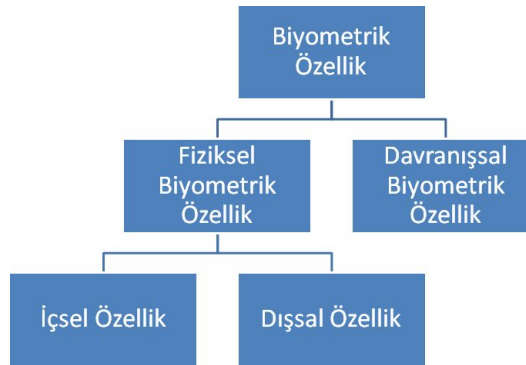
Çizelge 2.1: Sıkça tercih edilen bazı biyometrik özellikler.

Sıkça	Kullanılan	Biyometrik	Özellikler
Parmak İzi	Avuç İçi İzi	Yürüyüş	El Sırtı Damarı
Parmak Damarı	Avuç İçi Damarı	Retina	Yüz



Şekil 2.2: Fiziksel biyometrik özelliklerin devinime göre sınıflandırılması.

Ayrıca fiziksel biyometrik özellikler, vücutta buldukları konuma göre içsel ve dışsal özellikler olarak Şekil 2.3'teki gibi de sınıflandırılabilir. Parmak damarı, avuç içi damarı ve el sırtı damarı gibi deri altında bulunan ve direkt erişime kapalı türler içsel fiziksel biyometri türlerine örnek iken yüz, avuç içi izi ve iris gibi türler ise dışsal fiziksel biyometri türlerine örnektir (Qin ve Wang, 2019).



Şekil 2.3: Fiziksel biyometrik özelliklerin konuma göre sınıflandırılması.

2.1.4 Biyometrik özelliklerin nitelikleri

Tüm bu biyometrik özellikleri tanıma ve doğrulama uygulamalarında kullanmamıza imkan sağlayan nitelikler, Çizelge 2.2'deki gibi sıralanabilir (Hou ve diğ., 2022). Sıralanan nitelikleri tümüyle bünyesinde barındırıp mükemmel yakın bir seçenek olarak biyometrik uygulamalarda kullanılmak üzere karşımıza çıkan herhangi bir biyometrik özellik yoktur. Buna istinaden biyometrik özellikleri birbiriyle kıyasladığımızda, tüm biyometrik özelliklerin sahip oldukları kendilerine has birtakım avantaj ve dezavantajları söz konusudur (Kuzu ve diğ., 2020b). Burada belirleyici olan, biyometrik sistemin hangi amaçla, nasıl bir bütçeyle ve ne kadar çok insan üzerinde kullanılacağı bilgisidir. Örneğin, maliyetin öncelendiği bir sistemde, kurulum açısından maddi bir yük getirecek bir biyometrik özelliğin kullanılması söz konusu olmamalıdır.

Çizelge 2.2: Biyometrik özelliklere ait bazı nitelikler.

Biyometrik Nitelik	Tanımı
Benzersiz Olma	Kişiye özgü olmalıdır.
Kalıcı Olma	Zamanla değişip dönüşmemelidir.
Toplanabilirlik	Cihazlarla kolay ölçülebilir olmalıdır.
Kabul Edilebilirlik	Toplanan veriye karşı çekince olmamalıdır.
Performans	Yüksek hız ve doğruluğa sahip olmalıdır.
Evrensellik	Uluslararası geçerliliği olmalıdır.
Gürbüzlük	Aldatma ve ataklara karşı güvenilir olmalıdır.
Temassız Olma	Hijyenik şekilde veri toplanabilmelidir.
Canlılık	Verisi toplanacak bireyler yaşıyor olmalıdır.
Uygun Maliyete Sahip Olma	Fiyat / Performans oranı düşük olmalıdır.
Kolay Kullanım	Kullanımı kolay olmalıdır.
Taşınabilirlik	Kolay taşınabilir ve hafif olmalıdır.
Az Yer Kaplama	Az yer kaplayan boyutlara sahip olmalıdır.


Bazı biyometrik özellikleri, bu ve buna benzer durumlar için karşıladıkları beklenti nispetinde birbiriyle kıyaslayan tablo, Çizelge 2.3'te verilmiştir (Wu ve Liu, 2011). Bu tablo, herhangi bir biyometrik amaç için ihtiyaç duyulan biyometrik özelliğin seçimi hususunda kullanıcılara yol gösterir niteliktedir.

Çizelge 2.3: Bazı biyometrik özelliklerin öne çıkan özellikleri.

Biyometrik Özellikler	Avantaj	Dezavantaj	Güvenlik	Temas	Maliyet
Ses	Kolay Uygulama	Ortamdaki Gürültü	Orta	Temassız	Ucuz
Yüz	Uzaktan Tanıma	Ortamdaki Işık	Orta	Temassız	Ucuz
Parmak İzi	Yaygın Kullanım	Derideki deformasyon	Yüksek	Temaslı	Ucuz
İris	Yüksek Doğruluk	Gözlük Kullanımı	Çok Yüksek	Temassız	Pahalı
Parmak Damarı	Müdahaleye Kapalı	Kızılötesi Işık	Çok Yüksek	Temassız	Ucuz

2.1.5 Çok kipli biyometri


Çizelge 2.1’de sıralanan biyometrik özelliklerin bir kısmı, diğer özelliklere göre daha fazla talep görmektedir. Bu talebin altında yatan sebeplerden bazıları kullanım kolaylığı sağlama, özel hayat ve kişisel bilgilerin korunumuna özen gösterme, popülerlik, toplum tarafından kabul görme ve belki de en önemlisi, keşfedilip piyasaya sunulma önceliğidir (Mróz-Gorgoń ve diğ., 2022). Şekil 2.4’te görüldüğü gibi dünya genelinde yapılan bir araştırmanın 2015 yılı verilerine göre, damar bazlı biyometrik özelliklerin pazar payı parmak izi biyometrisine ait pazar payından sonra gelmektedir (Yadav ve diğ., 2020). Şüphesiz bu sıralamada, damar görüntülerinden biyometrik bilgi çıkarımının parmak izinden sonra keşfedilmiş olmasının payı büyüktür. Yüz biyometrisi izinsiz fotoğraflanabilip parmak izi biyometrisi de geride iz bıraktığı için kopyalanma riskini bünyesinde barındırır da, sahip oldukları yaygın popülarite ve tek kipli olarak kullanıldığında geniş kitlelere hitap etmelerini sağlayan biyometrik örüntü çeşitliliği sayesinde, sahip oldukları pazar payında yıllar içerisinde hissedilir bir kayıp yaşamazlar. Ancak her biyometrik özellik, örüntü çeşitliliği açısından bu iki biyometrik özellik kadar zengin seçenekler sunmaz (Qin ve El-Yacoubi, 2017a). Yani benzersiz olma niteliği kapsamında geniş kitlelere hitap etmeyi sağlayacak kadar farklı örüntü kombinasyonları içermezler.



Şekil 2.4: Biyometrik özelliklerin 2015 yılındaki dünya geneli pazar payı.

Ayrıca her biyometrik özellik her insanda mutlaka çalışacak diye bir kaide de yoktur. Bazı insanlarda, bazı biyometrik özellikler evrensellik niteliğini tümüyle yansıtamadığından, tanıma ve doğrulama uygulamalarında sisteme giriş yapabilmek için gerekli olan eşik miktarı kadar özelliği barındırmayabilir. Bu gibi durumlarda, biyometrik özelliklerin güvenilirliğini artırıp geniş kitlelere hitap edebilmelerini sağlama adına, tek kipli (unimodal) biyometrik seçeneklerin yerine çok kipli (multimodal) biyometrik seçenekler tercih edilir (Alay ve Al-Baity, 2020).

Şekil 2.5’te gösterildiği gibi çok kipli biyometri çok kopyalı (multi-instance), çok örnekli (multi-sample), çok sensörlü (multi-sensor), çok algoritmali (multi-algorithm) ve çok biyometrik özellikli (multi-biometrics) olmak üzere 5 farklı yolla sağlanabilir (Aftab, 2021). Parmak damarını örnek verecek olursak, çok kopyalı durumda, aynı parmaktan birden çok görüntü alınarak doğrulama veya tanıma uygulamalarında



Şekil 2.5: Çok kipli biyometri çeşitleri.

elde edilen başarı artırılmaya çalışılır. Çok örnekli durumda, aynı sensörü kullanıp farklı parmaklardan örnek alınır. Çok sensörlü durumda, en az 2 farklı sensörden örnek alınarak elde edilen başarı ve güvenlik artırılmaya çalışılır. Kullanılan her bir sensörün değişik kalite ve özellikte olduğu düşünüldüğünde, veri kalitesinin bu sayede artırılması olasıdır. Çok algoritmali durumda, alınan görüntüden elde edilen tanıma ya da doğrulama oranı, birden çok algoritmanın yardımıyla özellik çıkarımını yapıp tanıma ve doğrulamayı gerçekleştirir. Son olarak çok biyometrik özellikli durumda, en az 2 farklı biyometrik özellik kullanılıp bunlardan elde edilen füzyon ile tanıma ve doğrulama işlemi gerçekleştirilir. Diğer tüm çok kipli seçenekler, tek bir biyometrik özellik kullanarak çalışabilirken çok biyometrik özellikli durum için en az 2 farklı biyometrik özellik gerekmektedir (Jain ve diğ., 2004). Bu sebeple, biyometrik özelliklerin hangi biyometrik özellikle beraber kullanılacağı önemlidir (Shaheed ve diğ., 2022a). Bu bağlamda kullanılacak biyometrik özellikleri seçerken kullanılacak özelliklerin vücutta birbirine yakın konumda olmaları, veri toplama sistemi açısından tasarım ve maliyet avantajı sağlayacaktır. Aksi takdirde, kullanılacak sistemin hacmi artacak ve bu ekstra donanım maliyetini beraberinde getirecektir.

2.1.6 El tabanlı biyometrik özellikler

Çok sayıda fiziksel biyometrik özelliği bünyesinde bulunduran el bölgesi, çok kiplilik açısından kurulacak biyometrik sistemlere çeşitli avantajlar sunmaktadır (Zhang ve diğ., 2012). Çizelge 2.4'te gösterildiği gibi parmak izi, parmak damarı, parmak eklemleri, el sırtı damarı, avuç içi damarı, avuç içi izi, tırnak ve el geometrisi başta olmak üzere pek çok özellik bu bölgeden çıkarılmaktadır. Tasarlanacak cihazın mümkün olduğunca küçük boyutlara sahip olması, kullanıcı beklentilerinin arasında yer aldığından, çok biyometrik özellikli yapıları kullanacak biyometrik sistemler için el bölgesi önemlidir (Rikkerink, 2021).

Çizelge 2.4: Bazı el tabanlı biyometrik özellikler.

El Tabanlı Biyometrik Özellikler
Parmak İzi
Parmak Damarı
El Geometrisi
Avuç İçi Damarı
Avuç İçi İzi
El Sırtı Damarı
Parmak Eklemleri
Tırnak

El bölgesi ayrıca içsel fiziksel biyometrik özelliklerin yer aldığı bir bölgedir. Çizelge 2.5'te gösterilen içsel özelliklerden parmak damarı, el sırtı damarı ve avuç içi damarı bu bölgede yer almaktadır. Diğer biyometrik özelliklerle karşılaştırıldığında içsel özellikler, deri altında bulduklarından kolayca değiştirilip dönüştürülemezler. Dolayısıyla olası ataklara karşı güvenlik açısından avantaj sağlarlar (Schuiki ve diğ., 2022). Damar bazlı biyometrik özellikler, kişinin hayatta olmasını gerektirecek yapıda olduğundan, sistemi yanıtacak atakların canlı kişiler üzerinden planlanması gerekmektedir. Son olarak, parmak izinin aksine görüntüleme platformunda iz veya örüntü bırakmamanın sağladığı gizlilik, damar bazlı biyometrik özellikleri güvenilir ve popüler kılmaktadır (Kyeremeh ve diğ., 2022). Parmak damarı, kol damarı ve el sırtı damarıyla kıyaslandığında, tüysüz bir bölge görüntüsü içerdiğinden karşılaşılabilecek gürültü, parmak damarı için nispeten daha az miktardadır.

Çizelge 2.5: Bazı içsel fiziksel biyometrik özellikler.

Damar Tabanlı Biyometrik Özellikler

Parmak Damarı
Avuç İçi Damarı
El Sırtı Damarı (El Damarı)
Bilek Damarı

2.2 Parmak Damarı Tabanlı Biyometri

Damar tabanlı biyometrik özellikler parmak damarı, avuç içi damarı, el sırtı damarı ve bilek damarı olarak sıralanabilir (Van Tien ve diğ., 2015). Tüm bu özellikler deri altında yer aldığı için onları kopyalamak, bilinen yöntemlerle mümkün değildir. Bu sebeple çalınma, kopyalanma ve geride iz bırakma konularında, diğer biyometrik özelliklere karşı, damar tabanlı özelliklerin sahip olduğu bariz üstünlükler söz konusudur (Wu ve diğ., 2020). Hayatta olan bir kullanıcıdan alınma zorunluluğu olan, temassız görüntüleme imkanına sahip, acısız ve ağrısız bir uygulama sunan bu özelliğe ait görüntüleme sistemi, sadece kızılötesi ışık ve kameraya ihtiyaç duyar. Her ne kadar kullanılan ekipmanların kalitesi elde edilen görüntü kalitesine ve kontrasta direkt etki etse de, bu sistemlerin kurulum maliyeti düşüktür. 15 yaşına kadar bireylerin damar yapısının değişip değişmediğini ortaya koyan bir yayın olmamasına rağmen damar yapısının zamanla değişip dönüşmediği ve ataklara karşı güvende olduğu kabul edilmektedir. Epigenetik yapıdaki damar tabanlı özellikler kişi daha embriyo iken şekillenir ve DNA diziliminden bağımsızdır (Hartung ve Busch, 2009). Bu sebeple tek yumurta ikizlerinde dahi damar tabanlı özellikler eşsiz bir yapıdadır.

Damar tabanlı özelliklerden biri olan parmak damarı, ilk olarak 2000'li yılların başında önerildi (Kono, 2000). Görüntüleme esnasında kullanıcıya konfor sunan parmak damarı, temassız bir şekilde toplanabilir. COVID-19 salgınının baş gösterdiği günümüzde, sağlanan bu ve buna benzer tüm temassız seçenekler hijyen açısından oldukça önemlidir. Parmak damarı gürültüden, kirli parmaklardan, ortam ışığından ve parmaktaki yaralardan çok fazla etkilenmez (Chai ve diğ., 2022b). Ten rengi,

kan akış hızı, deri altı yağ oranı, kırıksıklıklar ve yaş ise, damar görünürlüğünü birinci derecede etkiler (Ton, 2012). Çok sayıda parmağa sahip olduğumuz için birisinin zarar görmesi durumunda diğerinin varlığı, biyometrik bilginin devamlılığı adına parmak damarının sağladığı bir diğer avantajdır. Sahip olduğu avantajların yanı sıra damar bazlı biyometrik özellikler bazı dezavantajlara da sahiptir. Örneğin, görüntüleme platformundaki elin konumu, dönme problemlerine sebep olur. Bu ve buna benzer kontrol edilemeyen durumlar, tanıma ve doğrulama uygulamalarında büyük performans kayıplarına yol açar (Zhang ve diğ, 2019). Kullanıcılar arası değişen el büyüklüğü, yakın kızılötesi ışık karakteristiği ve gürültülü arka plan gibi birçok etken sistem performansına negatif etki etmektedir. Ama yine de erişilemeyip kolay taklit edilemeyecek yapıda olması, canlılık gerektirmesi ve temassız görüntülenmesi parmak damarını değerli kılar.

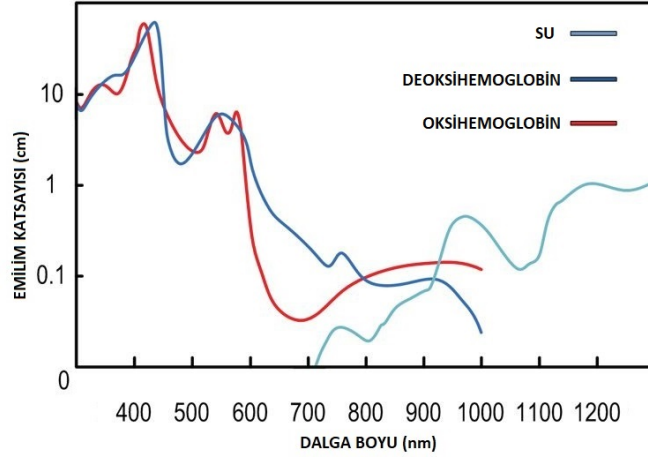
2.2.1 Parmak damarı ve özellikleri

Kardiyovasküler sistem içerisinde atardamar, toplardamar ve kılcal damar olmak üzere 3 damar çeşidi bulunmaktadır. Atardamarlar kalpten pompalanan kanı taşıyan damarlar iken, toplardamarlar ise vücutta dolaşan kanı kalbe taşıyan damarlardır (Hartung, 2012). Kısacası atardamarlar kalpten gelen oksijen açısından zengin kanı taşıırken, toplardamarlar ise hücreler tarafından oksijeni tüketilmiş olan kanı kalbe geri taşımaktadır. Atardamarlar genelde temiz, toplardamar ise genelde kirli kan taşımaktadır. Temiz kan diyerek kastedilen oksijence zengin kandır.

Parmaktaki damarlar, deriye göre derinde ve yüzeyde olmak üzere 2 temel konumdadır. Yapı itibarıyla 3 temel katmandan oluşan deride, bahsi geçen atardamarlar alt katmanlarda bulunurken, toplardamarlar vücudun yüzeyinde bulunurlar ve derinin en üst katmanına yakındırlar (Wu ve diğ, 2020). Genelde yüzeydeki damarlar parmağın sırt (dorsal) ve iç (palmar) kısmında bulunur. Enjeksiyona izin veren bu damarlar, görünür olanlardır. Bir de atardamarlara eşlik eden toplardamarlar vardır. Bunlar ise, derinlerde bulunup atardamar boyunca uzanırlar.

Vücudumuzda çeşitli maddelerin taşınımında görev alan kan, bu damarlar vasıtasıyla vücudumuzda dolaşır. Kan, organların işleyişi ve sistemlerin devamlılığı açısından hayati bir öneme sahiptir. Oksijen, kan tarafından taşınan bu maddelerden sadece birisidir. Oksijen kırmızı kan hücreleri olarak da bilinen alyuvarların içerisinde bulunan ve hemoglobin adı verilen bir kimyasal tarafından taşınır (Kyeremeh ve diğ, 2022). Oksijene sahip hemoglobine oksihemoglobin adı verilir. Hemoglobin esasen toplardamarlarımızda ve atardamarlarımızda bulunur (Huang ve diğ, 2018).

Hemoglobin, eğer kendisine bağlı oksijen söz konusu değilse yani deoksihemoglobin formunda ise, kırmızı ışığı daha çok emer (Normakristagaluh ve diğ, 2022). Bu sebeple toplardamarlarımız bu kan sayesinde atardamarlarımızdan daha koyu görünür (Van Tien ve diğ, 2015). Atardamarlarımız kırmızı ışığı daha çok yansıtacağından daha açık renkte görünür (Wilches-Bernal ve diğ, 2020). Şekil 2.6'da görüldüğü gibi oksihemoglobin ve deoksihemoglobin değişen dalga boylarındaki ışık altında farklı emilim katsayılarına sahiptir (Sassaroli, 2003).



Şekil 2.6: Değişen dalga boylarında kandaki 3 bileşene ait emilim katsayıları.

Kan alımı veya biyometrik amaçlarla toplanan görüntülerdeki kontrastı, hastanın vücudunu geçebilen ya da geçemeyen ışınlar oluşturur. Damarlar deri altındaki diğer doku ve pigmentlere göre yakın kızılötesi ışığı soğurma konusunda daha yüksek emilim katsayısına sahip olduğundan, gelen ışınların kandaki hemoglobin tarafından soğurulması sonucu kontrast oluşur ve deri altındaki kan damarları, diğer dokulardan ayırt edilme imkanı bulur. Dokularda sıkça rastlanan suyun, hemoglobine benzer seyir izleyen bir emilim katsayısı grafiği vardır ve bu grafik, su için Şekil 2.6'da verilmiştir. Kan damarlarındaki hemoglobini, yakın kızılötesi ışık altında başta su olmak üzere dokulardaki diğer maddelerden ayırabilmek için, elektromanyetik spektrumda uygun aralıkta çalışmak gerekir (Jiang ve diğ., 2017). Alınan parmak damarı görüntüsünde, kan damarları ve diğer dokular arasındaki kontrast farkını maksimum seviyeye ulaştıran en uygun aralık, yakın kızılötesi ışığa ait dalga boyunun 850 nm ile 900 nm arası olduğu aralıktır (Cuper, 2012). Damar bazlı biyometrik özelliklerin en büyük dezavantajı olan kullanılan ışığın dalga boyu, sıcaklık ve fiziksel aktivite gibi faktörler, damarın görünürlüğünde yakın kızılötesi ışık altında direkt etkiye sahiptir (Yuksel ve diğ., 2011). Bu sebeple sadece yakın kızılötesi ışık değil, birçok farklı yöntem parmak damarını görüntülemek için kullanılmaktadır.

2.2.2 Damar görüntüleme yöntemleri

Yakın kızılötesi ışık kullanımı haricinde, kan damarları emar (MRI), x ışını (X-ray) ve Ultrason (Ultrasound) ile görüntülenebilir (Hartung, 2012). Özellikle emar yoluyla oldukça yüksek kalitede görüntülere ulaşmak mümkündür (Kyeremeh ve diğ., 2022). Ayrıca turnikeyle fiziksel etki yaratarak ya da malzeme bilimi yöntemleri kullanılarak geliştirilen çeşitli jeller sayesinde parmak damarı görüntülenebilir (Yang ve diğ., 2011). Bu yöntemlerden bazılarının maliyeti oldukça yüksek iken, bazıları da kullanıcı dostu bir uygulanabilirlik sunmamaktadır. Bu sebeple, bu avantajları bünyesinde barındıran yakın kızılötesi ışıktan faydalanarak damar görüntülemeye elde edilen başarıyı artırmaya yönelik çalışmalar devam etmektedir (Miyake ve diğ., 2006).

2.2.3 Yakın kızılötesi ışık ve özellikleri

Bilindiği gibi elektromanyetik bir dalga olan ışık saçılabilir, emilebilir, yansıtılabilir ya da kırılabilir (García ve Horche, 2018). Kırılma, ışığın ortam değiştirdiğinde merkezle

yapılan açının değişmesi olarak tanımlanabilir. Yansıma, belirli bir yönde hareket eden ışık demetinin bir yüzeye çarpınca bir başka yöne doğru harekete başlaması olarak tanımlanabilir. Emilim ise, görüntülenen nesnenin belirli renkteki veya dalga boyundaki ışığı soğurması olarak tanımlanabilir (Ryer ve diğ, 1997). Örneğin, yeşil bir ışık, yeşil bir cisim tarafından emilemez. Son olarak saçılma, kızılötesi ışığın yarattığı sonuçlardan biridir ve kontrast oluşumunu engelleyip adeta görüntüde bir sis perdesi yaratan etkiye sahiptir (Kocakulak ve Acir, 2018). Tüm bunlar, görüntüde bozulmaya ya da görüntü kalitesinde düşüşe sebep olan durumlardır. Görüntüleme platformlarında kullanılan optik malzemeler, sistem tasarımı ve parmak yüzeyinin temizlik durumu ışığın yansılma ve emilme başta olmak üzere izleyeceği yolu etkiler. Kirli ortamlar ya da ortamda partiküllerin söz konusu olması, yansıma ve emilimi direkt olarak etkiler. Havanın sıkıştırıldığı ortamlar bu manada görüntüleme için en elverişli ortamlardır.



Şekil 2.7: Elektromanyetik spektrumda görünür ışığın yeri.


400 nm ile 700 nm arası, Şekil 2.7’de gösterildiği gibi insanlar açısından görünür ışığın yer aldığı görünür spektrum olarak kabul edilir (Waluş ve diğ, 2015). Yakın kızılötesi ışık ise, 700 nm ile 1000 nm arasında yer alır ve damarlar elektromanyetik spektrumda bu aralıkta görünürdür. Bu aralıktaki ışığın deriye nüfuz etme oranı, elektromanyetik spektrumda diğer aralıklardan yaklaşık 10 kat fazladır (Waluş ve diğ, 2015). Yakın kızılötesi ışığın sınırları dahilinde olan 760 nm’de bir görüntü alındığında alınan görüntüde oluşan kontrastın saf sebebi, kan plazmasında bulunan hemoglobin olarak belirlenmiştir (Wu ve diğ, 2020). Seçilen herhangi bir dalga boyundaki ışıkta, atardamarların oksihemoglobin içerdiği ve bu sebeple görüntüde kontrast oluşturmadığı görülmüştür. Kandaki su, oksihemoglobin ve deoksihemoglobin gibi bileşenlerin değişen dalga boylarında sahip oldukları emilme katsayıları Şekil 2.6’daki grafikte gösterilmiştir. Parmak damarının 730 nm ile 950 nm arasındaki farklı dalga boyuna sahip yakın kızılötesi ışık altında görünürlüğünü test eden çeşitli çalışmalar literatürde mevcuttur (Moroñ ve diğ, 2022). Ayrıca damar görüntüsü toplanan kişinin yaşı ve sahip olduğu hastalıklar da elde edilen görüntüye etki etmektedir (Waluş ve diğ, 2015). Dalga boyunun yanı sıra elde edilen görüntü kontrastına, ortam sıcaklığı ve fiziksel aktivite gibi çeşitli sebepler etki ettiği için, bu çalışmalar tek başına sistem tasarımında belirleyici nitelikte olmasa da, ışık seçiminde fikir veren niteliktedir (Sierro ve diğ, 2015).

İyonize olmayan bir radyasyona sahip olan yakın kızılötesi ışığın damar görüntülemesinde kullanılmasında sağlık açısından bir sakınca yoktur. Kanda düz bir şekilde emilen ve saçılan yakın kızılötesi ışık, yağ ve deride saçılır. Bu sebeple kan damarları koyu renktedir. Vücudun emilim katsayısı düşük olduğundan

oksihemoglobin, deoksihemoglobin ve suya yakın kızılötesi ışık nüfuz eder (Delpy ve diğ, 1997). Atardamarlar oksihemoglobin, toplardamarlar ise deoksihemoglobin içerdiğinden, özellikle 760 nm ile 850 nm arasında yakın kızılötesi ışığı iyi absorbe ederler. Şekil 2.6'da görüldüğü gibi, 800nm'de oksijen açısından zengin olan oksihemoglobin, 760nm'de ise oksijen açısından fakir olan deoksihemoglobin daha yüksek emilim katsayısına sahiptir. 810nm'de oksihemoglobin ve deoksihemoglobin eşit emilim katsayısına sahiptir (Kyeremeh ve diğ, 2022). 810 nm altında deoksihemoglobin, 810 nm üzerinde ise oksihemoglobin daha yüksek emilim katsayısına sahiptir. 700 nm ile 900 nm arasındaki bu pencere, terapötik pencere olarak nitelendirilir (Wu ve diğ, 2020). Bu aralıkta hemoglobin, suya göre daha yüksek emilim katsayısına sahiptir. Damar çapı, vücutta damarın ne kadar derinde olduğu, kullanıcı yaşı, yağ oranı, kilo, çevresel sıcaklık, nem, fiziksel aktivite, ten rengi ve ırk gibi faktörler damarın görünürlüğünü etkiler (Badawi, 2006). Kol, boyun ve yüzde doku kalınlığı artığından yakın kızılötesi ışık iyi nüfuz edemez. Doku kalınlığı nedeniyle yaşanan bu sıkıntı görüntüleme platformunda kullanılan aydınlatma teknikleriyle çözülür.

2.2.4 Görüntüleme platformunda kullanılan aydınlatma teknikleri


Dalga boyunun yanı sıra kullanılacak olan optik sensörün tasarımdaki kullanım şekli, alınacak görüntünün kalitesini etkileyecektir. Görüntüleme platformunda kullanılacak olan LED (Light Emitting Diode) ışıklar, geçiş (transmission) ya da yansıtma (reflection) yöntemi tercih edilerek görüntüleme platformunda kullanılabilir. Bu iki yöntem arasındaki ana fark, LED'lerin pozisyonudur.



Şekil 2.8: Aydınlatma tekniklerinden geçiş yöntemi.

Şekil 2.8'de gösterilen geçiş yöntemi, daha yüksek kontrast içeren görüntüler elde edilmesini sağlar (Sierro ve diğ, 2015). Geçiş yönteminde, görüldüğü üzere kamera ve yakın kızılötesi ışık kaynağı farklı tarafta iken, yansıtma yönteminde ise Şekil 2.9'da görüldüğü gibi, kamera ve yakın kızılötesi ışık kaynağı aynı taraftadır (Sierro ve diğ, 2015). Geçiş yöntemini kullanan cihazlar daha uzundur ve daha çok yer kaplar. Bu sebeple taşınabilirlik açısından kullanışlı değildir. Yansıtma yöntemi, geçiş yöntemine göre daha az güç tüketir. Yansıtma yönteminde parmağa nüfuz eden ışık oldukça azdır (Hsia ve Liu, 2022). Bu sebeple yansıtma yönteminde daha az kontrast elde edilir. Her iki aydınlatma yönteminde yakın kızılötesi ışık geri yansıtılabilir ya da parmak pozisyonunda kaymalar yaşanabilir. Işığın platform genelinde homojen olarak dağılması ise, ortak bir problemdir (Pascual ve diğ, 2010). Alınan parmak görüntüsünün arka plandan ayrışabilmesi için tasarlanan sistemlerde kompleks bir arka plan olmamalıdır. Ayrıca tasarlanan görüntüleme platformlarında gürültü oluşması kızılötesi ışığın karakteristik

özellikleri nedeniyle muhtemeldir. Literatürde, geçiş yöntemini kullanan çok sayıda cihaz tasarımı varken, yansıtma yöntemini kullanan cihaz sayısı oldukça azdır çünkü yeterli kontrast içeren görüntüye bu yöntem vasıtasıyla ulaşmak zordur. Tüm bu faktörlerin yanı sıra görüntüleme platformu çevresinde bulunanlar, açık ya da kapalı platform tasarımı, platformun iç kısımlarının rengi ve opaklığı gibi birçok neden aydınlatmayı ve dolayısıyla elde edilen kontrastı etkiler. Hatta platformda görüntülenen parmağın iç kısmı ya da sırt kısmının kullanılması dahi elde edilen kontrastı etkiler. Bu nedenle halka açık veri setlerindeki örnek görüntülerin kalitesi ve içerdiği kontrast birbirinden çok farklıdır.




Şekil 2.9: Aydınlatma tekniklerinden yansıtma yöntemi.

2.2.5 Halka açık parmak damarı veri setleri

Performans ölçümü sonrası karşılaştırmalı analiz yapmak için gerçekleştirilen deneylerin ortak veri setleri üzerinde gerçekleştirilmesi gerekmektedir. Erişime açık olan ve çalışmalar arası ortak literatürün oluşmasını sağlayan en popüler veri setleri Çizelge 2.6'daki gibidir. THU-FVDT1 veri seti, 220 kişiden toplanmış 440 görüntüden oluşur. 2 farklı seansta, her seansta kişilerden birer görüntü toplanarak oluşturulmuştur (Yang ve diğ., 2009). VERA-FV veri seti, 110 gönüllüden toplanan 440 görüntü içerir. Bu görüntüler, 2 farklı seansta her 2 elin işaret parmaklarından alınmıştır (Tome ve diğ., 2014). UTFVP veri seti, 60 kişiden toplanan 1440 adet görüntüden oluşur. 2 farklı seansta, kullanıcıların her iki elinin orta, işaret ve yüzük parmağından 2 örnek alınarak oluşturulmuştur (Ton ve Veldhuis, 2013). MMCBNU-FV veri seti, 20 farklı ülke vatandaşı 100 gönüllünün her iki elinin orta, işaret ve yüzük parmağından 1 seansta alınan onar örnekle oluşturulmuştur (Lu ve diğ., 2013). SDUMLA-FV veri seti, 1 seansta 106 farklı gönüllünün her iki elinin işaret, orta ve yüzük parmağından alınan altışar örnekle oluşturulmuştur (Yin ve diğ., 2011). FV-USM veri seti, 123 gönüllünün 4 parmağından 2 farklı seansta altışar örnekle alınmış 5904 adet görüntüden oluşmaktadır (Asaari ve diğ., 2014). HKPU veri seti, 156 farklı kullanıcıdan alınmış 3132 görüntüden oluşmaktadır (Kumar ve Zhou, 2011). Bu veri seti 2 farklı seansta toplanmıştır. 156 kişiden 105'i her 2 seansa katılırken, kalan 51 kişi sadece bir seansa katılmıştır. Seanslarda ise, tek ele ait işaret ve orta parmak kullanılıp altışar örnek alınmıştır.

SDUMLA-FV (Yin ve diğ., (2011)) ve HKPU veri (Kumar ve Zhou, (2011)) setlerine ait örnek parmak damarı görüntüleri Şekil 2.10'daki gibidir. Görüldüğü üzere, görüntüleme kullanılan cihaz, o cihazın faydalandığı aydınlatma tekniği ve kullanılan kızılötesi ışığa ait dalga boyu farklı olunca, o platformlarda toplanan parmak damarı görüntülerinin kontrast dağılımları ve damar görünürlükleri de farklı olmaktadır. Bu çizelgede listelenen veri setlerine ait niceliksel özelliklere bakıldığında, bir derin öğrenme modelini eğitip yüksek kesinlik (accuracy) elde

edecek kapasitede olmadıkları görülür (Chai ve diğ., 2022b). Buradaki birincil sebep, veri hacimlerinin toplam görüntü anlamında az olmasıdır. İkincil sebep ise, parmak başına alınan örnek sayısının yetersiz oluşudur (Sidiropoulos ve diğ., 2021). Ayrıca niteliksel olarak değerlendirildiğinde, alınan görüntülerin kızılötesi ışığın karakteristik özelliği olan saçılmanın, negatif etkisi altında olduğu görülmektedir. Kontrast açısından belirgin özelliklerin görüntüde oluşmasına, ışığın saçılma etkisinin engel olduğu bilinmektedir.



Şekil 2.10: Parmak damarı örnekleri a) HKPU b) SDUMLA-FV.

2.2.6 Özellik çıkarma yöntemleri ve özellikleri

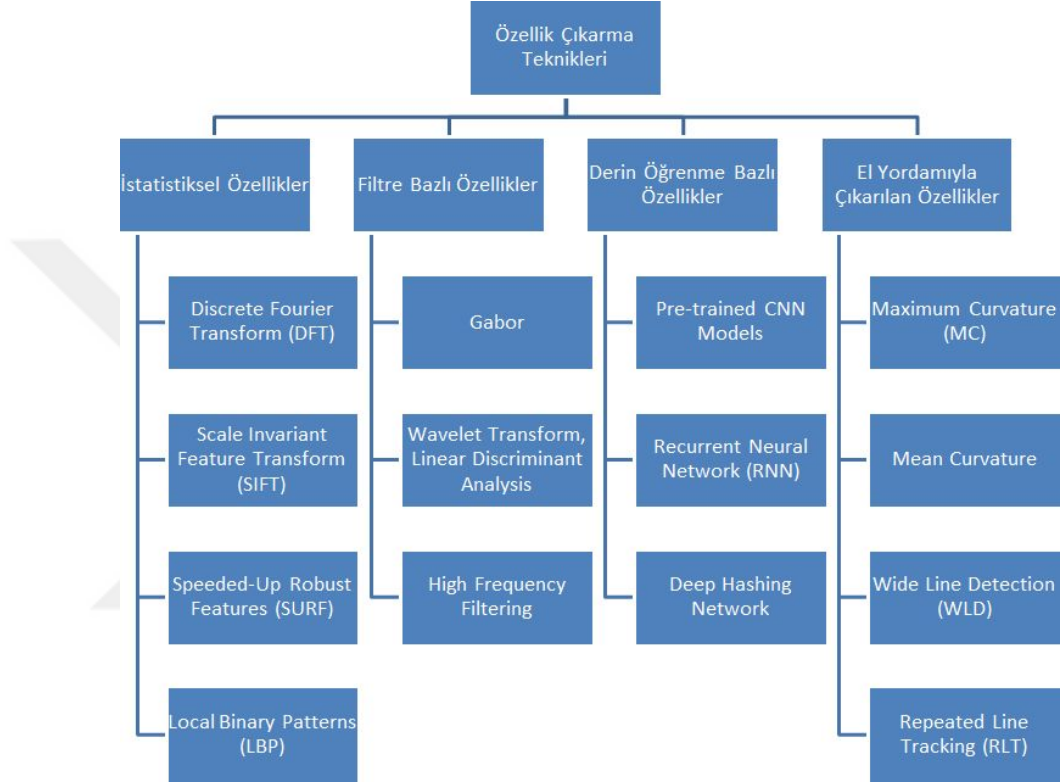
Son yıllarda popüler olan derin öğrenme modelleri, tanıma ve doğrulama uygulamalarında kullanılmadan önce, bir biyometrik süreç sırasıyla veri akışı, ön işleme, özellik (feature) çıkarımı ya da diğer bir deyişle öznitelik çıkarımı ve karar verme adımlarını içermekteydi (Shaheed ve diğ., 2022a). Bu adımlar arasında, tanıma ve doğrulama konusunda karar vermeyi sağlayan adım olan, özellik çıkarımı oldukça önemlidir. Bu aşama, biyometrik özelliklerin çıkarılıp sayısallaştırıldığı aşamadır. Literatürde bu işlemi yapabilmek adına çeşitli yöntemler önerilmiştir. Bu yöntemleri, Şekil 2.11'deki gibi 4 ana başlıkta incelemek mümkündür (Aftab, 2021). Bu başlıklar arasında yer alan derin öğrenme bazlı öznitelik çıkarma yöntemleri, öznitelik çıkarma yerine öznitelik öğrenmeyi sağlamaktadır (Sidiropoulos ve diğ., 2021). Derin öğrenme bazlı yöntemlerin esasen geleneksel yöntemler dediğimiz Şekil 2.11'deki diğer 3 başlıktaki yöntemlerden ayrıştığı nokta budur.

Şekil 2.11'deki istatistiksel yöntemler, doku yani piksel bazlı uzamsal değerlere odaklanıp, buradan istatistik bazlı komşu pikseller arası bağımlılıklar ve ilişkiler yakalamaya çalışır (Aftab, 2021). Filtre bazlı yöntemler, eldeki verilere uyguladığı değişen sayıda filtre ve bu filtrelere ait parametrelerle, verileri iyileştirip, buradan öznitelik çıkarmaya çalışır (Aftab, 2021). El yordamıyla (hand-crafted) özellik çıkaran yöntemler, tam manasıyla geleneksel sınıflandırma odaklı yöntemlerdir. Bu yöntemler,

Çizelge 2.6: Halka açık parmak damarı veri setleri ve özellikleri.

Veri seti	Kişi	Parmak	Örnek	Seans	Toplam	Format	Boyut
HKPU	156 (105 - 51)	2	12 / 6	2	3132	bitmap	513 x 256
VERA-FV	110	2	1	2	440	png	665 x 250
SDUMLA-FV	106	6	6	1	3816	bitmap	320 x 240
THU-FVDT1	220	1	2	1	440	bitmap	720 x 576
MMCBNU-FV	100	6	10	1	6000	bitmap	640 x 480
FV-USM	123	4	6	2	5904	bitmap	640 x 480
UTFVP	60	6	4	2	1440	png	672 x 380

parmağın veya elin büyüklüğü ve elin sınırları gibi fiziksel özelliklerle istatistiksel özellikleri harmanlayan yöntemlerdir (Aftab, 2021). Şekil 2.11'deki başlıklar altında belirtilen yöntemler, bu 3 başlık altında yer alan yöntemlerin bazılarıdır. Bu yöntemlerin dezavantajı, damar görüntülerinin düşük kontrasta sahip olması nedeniyle özellik çıkarımı açısından bu yöntemlere uygun imkanlar sağlayamamasıdır. Kamera pozisyonu, ışık dağılımı, parmak pozisyonu, oryantasyonu ve ışığın pozisyonu gibi etkenlerden dolayı "geleneksel" diye tanımlanan yöntemler dezavantajlıdır (Noh ve diğ 2021)



Şekil 2.11: Özellik çıkarma teknikleri.

Örneğin, el yordamıyla çıkarılan özellikler için sıkça kullanılan Maximum Curvature (MC) algoritması, damar teşhisinde görüntüdeki damarların orta kısımlarına odaklanır (Miura ve diğ, 2007). Bu sebeple değişen damar kalınlıklarına karşı başarısızdır. Bu algoritmanın ilk adımı, damarların merkez noktalarının belirlenmesidir. İkinci adımı ise, bu merkez noktalarına ait damar genişlik ve eğriliğine (curvature) dayanarak damara ait skorların hesaplanmasıdır. Bu hesaplanan skorlar, algoritma boyunca bir matriste tutulur. Bu süreçte, gürültü ve bozulmalar nedeniyle düzgün bir biçimde tespit edilemeyen merkez noktaları da söz konusudur. Bu amaçla doğrusuyla yanlışıyla belirlenen merkez noktalar birleştirildikten sonra filtrelenip varsa bu gürültüler giderilir. Sonrasında uygulanan eşikleme (thresholding) ile görüntü, ikili (binary) hale getirilir. Bu eşikleme sürecinde ise, oluşturulan skor matrisinin medyan değeri eşik değeri (threshold value) olarak alınır. Bu algoritmanın ilk adımı olan damarlara ait merkez noktalar, görüntüye uygulanan birinci ve ikinci türev sonucunda elde edilen içbükey (concave) ve dışbükey (convex) yapılardan içbükey olanların, geçerli damar olarak addedilmesi ile elde edilir. İstenildiği takdirde türev mertebesi 1 veya 2'den farklı olacak şekilde artırılabilir (Miura ve diğ, 2007).

Bir diğel el yordamıyla özellik çıkararak yöntem olan Repeated Line Tracking (RLT), görüntü içerisindeki damar örüntülerini, siyah çizgilerin takip edilmesiyle belirlemeyi amaçlar (Miura ve diğ, 2004). Defaatle ve rastgele belirlenen noktalarda, vadi (valley) teşhisi ile damar takibinin başlatılması sonucu, eđer o noktaya komşu olan piksellerde, damara dair örüntü söz konusu ise, örüntü yayılarak ilerler. Eđer komşu piksellerde devamlılık sağlayacak örüntü bulunamazsa, görüntü içinde başka rastgele bir noktaya atlanarak vadi teşhisine gidilir. Bu vadi arama işleminin, kaç defa yapılıp tekrar edileceđi (iteration) ayrıca önemlidir. Birden çok defa bir çizgiye dahil olan ve damar olması kuvvetle muhtemel olan piksellerin takip edilme sayıları, bir matriste tutulup kaydedilir. Bu kayıtlar ise, eşikleme sürecinde kullanılır. Belirlenen eşik deđerinin üstünde sayıda takibe sahip olan pikseller, görüntünün ikili hale getirilmesi sürecinde damar olarak etiketlenir. Pikselleri birbirine bağlayan ve örüntüde devamlılık sağlayan şey ise, belirlenen damar yarıçapı ve oryantasyonudur. İstenildiđi takdirde damar yarıçapı ve tekrarlama sayısı artırılıp azaltılabilir (Miura ve diğ, 2004).

Parmak damarı, parmak izi gibi çizgisel özellikler ve ayrıntılar konusunda zengin seçenekler sunmadığından, sınıf içi (intra-class) ve sınıflar arası (inter-class) özellik çıkarımı konusunda geleneksel yöntemler, düşük görüntü kalitesi ve düşük görüntü kontrastı kaynaklı problemlerle karşılaşmaktadır (Tan ve diğ, 2013). Başta çatal, göz, köprü, sağ döngü, sol döngü vb. olmak üzere sayısız ayrıntı (minutiae) içeren parmak izinin sağladığı çeşitlilik parmak damarında yoktur (Win ve diğ, 2020). Parmak damarı, görüntü başına kısıtlı sayıda çatal, göz ve köprü gibi ayrıntılar içerir (Krishnan ve diğ, 2020). Bu güçlük, derin öğrenme bazı yöntemler sayesinde türetilen modellerle giderilebilmektedir (Qin ve Wang, 2019). Parmak damarı, düzensiz aydınlatmadan dolayı gölge ve gürültüler içeren bir yapıda olduğundan, homojen dağılmayan ışığa karşı gürbüz bir çözüm sunulması, performans açısından olmazsa olmazdır. Başta kontrast iyileştirme, beyazlık dengeleme, Gama düzeltme (Gamma correction) ve medyan filtreleme olmak üzere birçok görüntü işleme yöntemi, parmak damarı görüntülerini iyileştirip kontrastını artırmak için destekleyici çözümler getirmektedir. Literatürde bu manada pek çok yayın bulunmaktadır. Ayrıca derin öğrenme yöntemlerini kullanmadan hemen önce görüntü işleme yöntemlerinden faydalanmak da mümkündür (Bilal ve diğ, 2021). Ancak ön işleme işlemleri uygulamak hem zaman hem de efor açısından problemlidir olduğundan, sadece derin öğrenme yöntemlerini kullanmak bu gibi durumlarda daha caziptir. Derin öğrenme yöntemleri, görüntü iyileştirmeye yeltenmeden modele ait katmanlar vasıtasıyla gerekli öznitelik çıkarımını gerçekleştirebilir (Alay ve Al-Baity, 2020). Geleneksel yöntemler ise, bu gibi problemler karşısında gürbüz çözümler üretmeyip, yüksek kompleksliğe sahip çözümlerle probleme yaklaşır. Derin öğrenme, evrişimsel sinir ağları tarafından sağlanan üstün genelleme yeteneđi ile basitten başlayarak karmaşığa doğru özelliklerin çıkarımını otomatik olarak gerçekleştirmektedir. Ayrıca geleneksel yöntemlerin bir diğel dezavantajı, bu yöntemler kullanılırken otomatik çıkarım yerine kullanılan veri bazı yani sadece o anki veriye uygun çözümler üretilmesidir. Yani verinin sahip olduğu problemi çözebilmek için, yöntemin o veri üzerinde en iyi performansı verdiđi, en uygun parametrelerin seçilip belirlenmesi gerekir.

Derin öğrenme bazlı yöntemler ise, öznitelik çıkarımını es geçip öznitelik öğrenerek sınıflandırma ya da doğrulama problemlerini çözdüğü için geleneksel yöntemlere nazaran daha fazla ilgi görmektedir. Kompleks özellikleri ve bunların kombinasyonlarını otomatik olarak çıkarıp kullanabilmeyi mümkün kılan derin öğrenme yöntemlerine, gerekli sayıda eğitim verisi sağlanamadığı için bazı problemlerin çözümünde derin öğrenme yöntemleri sıkıntı yaşamaktadır. Ancak bu durumlarda öğrenim aktarımı (transfer learning) ya da veri artırımı (data augmentation) uygulanarak bu ihtiyaç giderilmektedir. Kısacası veri eksikliği bir şekilde giderildiğinde, derin öğrenmenin geleneksel yöntemlere göre daha hiyerarşik özelliklere erişim sağladığı ve birbirinden bağımsız komşuluk ilişkilerini dahi erişilebilir kıldığı bilinmektedir. Bu özelliğin parametreye dayalı olmayıp otomatik gerçekleştirilebilmesi de bu yöntemlerin sağlamış olduğu en büyük avantajdır. Ancak unutulmamalıdır ki derin öğrenme daha doğru ve daha etkin tanıma imkanı sağlarken eğitilmesi uzun sürer ve çok sayıda veriye ihtiyaç duyar. Bu sebeplerden dolayı, gereksiz durumlarda kullanımı dezavantajlıdır.

2.3 Literatürdeki İlgili Çalışmalar

Biyometrik sistemler, bireylerin doğuştan gelen fiziksel özelliklerini ve benimsenen davranışlarını tanımayı amaçlar. Diğer biyometrik özellikler gibi, parmak damarı da benzersiz olmak, evrensel olmak, kalıcı olmak ve kullanıcı dostu olmak gibi çeşitli avantajlar sunar (Jain ve diğ., 2004). Bu avantajları sağladığı için parmak damarı, biyometrik uygulamalarda güvenilir ve tercih edilen bir özellik olarak kabul edilmiştir. Ancak, yakın kızılötesi ışığın saçılma etkisinden dolayı damar görüntülerinin kontrastı oldukça düşüktür ve biyometrik sistemler, parmak damarının bu karakteristik özelliğinden epey muzdariptir (Daas ve diğ., 2020). Damar görüntüleri çok net olmadığından ve parmak damar modellerini formülize etmek için kesin herhangi bir matematiksel formül bulunmadığından, literatürde çeşitli sayıda "geleneksel" diye tabir edilen öznitelik çıkarma yöntemleri önerilmiştir (Qin ve El-Yacoubi, 2017a). Bilindiği gibi ESA, bu geleneksel öznitelik çıkarma yöntemlerinden daha etkili bir genelleme yeteneğine sahiptir (Krizhevsky ve diğ., 2012). Bu nedenle, derin öğrenmedeki gelişmelerle birlikte ESA, parmak damarı biyometrisi için daha önemli hale gelmiştir. ESA öznitelik çıkarımı yerine öznitelik öğrenmeyi sağladığından, geleneksel öznitelik çıkarma temelli çalışmaların yerini derin öğrenme temelli çalışmalar hızla almaktadır.

Bu avantajlar göz önünde bulundurulduğunda son yıllarda parmak damarı için ESA sıklıkla kullanılmaktadır. Halka açık veri setleri üzerinde elde edilen doğrulama ve tanıma performansını iyileştirmek için, literatürde çeşitli derin öğrenme modelleri önerilmiştir. Derin öğrenme tabanlı bu yaklaşımlar, bu veri setlerinde dikkat çeken bir performansa sahiptir ve oldukça etkili çözümler sunmuştur. Bununla birlikte, literatürde test protokollerinin hakkıyla kullanılmaması ve mevcut çalışmalarla karşılaştırılabilirliğin eksikliği gibi çözülmesi gereken problemler bulunmaktadır. Literatürde yayınlanmış çalışmaların bir kısmı, önceki çalışmalarla ortak bir protokol kullanmamakta ve sadece halka açık olan belirli veri setlerinde, en iyi performans oranlarını elde etmeyi amaçlamaktadır. Bu çalışmalar, hiperparametre (hyperparameter) seçimleri ve deney protokolleri ile ilgili detayları paylaşmayıp sadece elde edilen sonuçları raporlamaktadır (Eglitis ve diğ., 2021).

Bilgisayar grafik işlemci birimlerindeki (Graphics Processing Units (GPUs)) teknolojik gelişmeler, derin öğrenmeye dayalı parmak damarı biyometrisi yayınlarındaki artışın bir diğer nedenidir. Ancak bu yayınların çoğunda farklı performans metrikleri kullanılmış olup yapılan deneylerde ortak bir protokol uygulanmamıştır (Sidiropoulos ve diğ, 2021). Bu çalışmalar, farklı sayıda veri seti üzerinde yapılan deneyleri sunup, yalnızca en iyi performansa sahip veri setlerini raporlamayı tercih etmiştir. Bu yayınlarda, literatürde elde edilenden daha yüksek performans sonuçlarını elde etmek için farklı deney protokolleri kullanılmıştır. Ayrıca bu çalışmalardan bir kısmı, Eglitis ve diğ, (2021),’nin belirttiği gibi en iyi performansı elde etmek için, uygulama hakkında gerekli olan ayrıntıları vermeden, birtakım ön işleme ve veri artırımı yöntemlerini kullanmıştır. Aynı sınıflandırma yöntemi kullanılırken, farklı hiperparametreler kullanarak bile farklı performans sonuçları elde etmenin mümkün olduğu düşünüldüğünde, bu bağlamda yaşanan bilimsel sıkıntılar aşıkardır (Mery ve diğ, 2016).

Ayrıca, tanıma (recognition), kimlik tanıma (identification) ve kimlik doğrulama (verification) tanımlarının birbirinin yerine kullanılması konusunda bazı karışıklıklar söz konusudur. Bilindiği gibi bir biyometrik sistem, temelde 2 modda çalışabilir (Shaheed ve diğ, 2022a). Bu modlar kimlik doğrulama ve kimlik tanımadır. Kimlik tanıma ve kimlik doğrulama, diğer bir deyişle tanımanın alt kümeleridir. Ancak genel manada tanıma terimi, kimlik doğrulama ve kimlik tanıma terimleri arasında bir ayrım yapmamak için kullanılabilir (Jain ve diğ, 2004). Tanımanın belirtilen kullanımı parmak damarı literatüründe kafa karışıklığına neden olmaktadır. Tanıma başlıklı makaleler, kimlik tanıma modu veya kimlik doğrulama modu ile ilgili deneyleri önerebilir veya önermeyebilir. Yapılan literatür taraması, bu nüansı göz önünde bulundurarak literatürdeki çalışmalarını incelemiştir. Kimlik tanıma için, performans metriği olarak Doğru Tanıma Oranı’ni (DTO) yani Correct Identification Rate (CIR) kullanan 12 derin öğrenme tabanlı yayın ele alınmıştır. Doğrulama için, Eşit Hata Oranı’ni (EHO) yani Equal Error Rate (EER) kullanan 15 derin öğrenme tabanlı yayın incelenmiştir. Kimlik tanıma ve doğrulama için, ISO/IEC 19795-1 (Mansfield, 2006)’dan alınan performans metrikleri referans alınmıştır.


2.3.1 Kimlik tanıma

Kimlik tanıma uygulamalarında bir biyometrik sistem, bir kişinin kimliğini tanımak için sistem veri tabanındaki tüm bireylerin saklanan şablonlarını (templates) tarar. Bu nedenle sistem, elde edilen sensör verilerini bire çok (1-N) eşleşme yöntemini kullanarak Şekil 2.12’de gösterildiği gibi veri tabanındaki kayıtlarla karşılaştırır (Jain ve diğ, 2015). Burada N sayısı, veri tabanında kayıtlı olan kişi sayısını temsil etmektedir. Kısacası tanıma, kişinin gerçekte kim olduğuna karar verir. Yani, kullanılmak üzere seçilen ESA, çok sınıflı bir sınıflandırma problemini çözmek üzere eğitilir. ESA modeli, giriş olarak verilen görüntünün ait olduğu sınıfa karar verirken, model için tanımlanan sınıflardan maksimum olasılık değerine sahip olan sınıfı model çıkışında seçip belirtir.

$$DTO = \% \left(\left(\frac{\text{Doğru Sınıflandırılan Görüntü Sayısı}}{\text{Toplam Görüntü Sayısı}} \right) \times 100 \right) \quad (2.3.1)$$

Bu uygulamalarda performans metriği olarak kullanılan kesinlik, doğru sınıflandırılan görüntü sayısının, bire çok eşleşmesi kullanılarak test edilen toplam görüntü sayısına

oranı olarak tanımlanabilir (Mansfield, 2006). Bu oran, test aşamasında başarıyla sınıflandırılan örneklerin toplam örnek sayısına oranıdır. Bu orana ayrıca Rank-1 kesinliği de denir (Chai ve diğ., 2022b). Denklem 2.3.1’de tanımlanan bu orana verilen bir diğer isim ise, DTO’dur. Yüksek bir DTO, sistemin bireyleri yüksek derecede kesinlikle doğru bir şekilde tanımlayabildiğini gösterir (Ren ve diğ., 2022).



Şekil 2.12: Biyometrik bir sistemde kimlik tanıma sürecine ait akış şeması.

2.3.1 Tanıma ile ilgili çalışmalar

2016’da Radzi ve diğ., (2016), parmak damarı biyometrisi için ESA kullanımını önererek, konuya farklı bir bakış açısı getirdi. Bu çalışma, öznelik öğrenimi için ESA konseptini ilk kez kullanmayı önerdiği için, parmak damarı tanıma bir kilometre taşıdır. Farklı sayıda denekle kendilerine ait veri setleri üzerinde yürüttükleri deneylerde önemli DTO performansı elde ettiler.

2018’de Das ve diğ., (2018), UTFVP, SDUMLA-FV, FV-USM ve HKPU olmak üzere halka açık 4 veri seti üzerinde biyometrik tanıma için tasarlanmış bir ağın yeteneklerini araştırdı. Bu çalışmada, parmak damarı görüntüleri üzerinde kontrast iyileştirme yöntemleri uygulayıp, bu veri setlerinden bazıları için kontrastlı parmak damarı görüntülerinin, orijinal görüntüden daha iyi tanıma performansına sahip olduğunu kanıtladılar. Bununla birlikte, herhangi bir görüntü iyileştirme olmaksızın ESA tabanlı tanıma yaklaşımının, hatırı sayılır bir performansı garanti ettiğini belirlediler. En önemlisi, daha fazla eğitim görüntüsüne sahip olunarak, tanıma kesinliğinin artırılabilceğini bu çalışmada bildirdiler.

2019’da Avcı ve diğ., (2019), herkes tarafından bilinen popüler ESA mimarilerinin orijinal (vanilla) versiyonlarını kullanmak yerine yüksek tanıma kesinliği elde etmek için 4 ampirik ESA modeli tasarladılar. Herhangi bir ön işleme işlemi ve veri artırımı kullanmaksızın tatmin edici bir DTO performansı elde ettiler. Bu tasarımlar üzerinde, seyreltme (dropout) ve yığın normalleştirme (batch normalization) kullanarak SDUMLA-FV, HKPU, FV-USM ve MNCBNU-FV veri setleri için 4 farklı model sundular. Kullandıkları 4 farklı parmak damarı veri seti üzerinde, her bir parmağı ayrı bir sınıf olarak kabul edip sınıflandırma işlemini gerçekleştirdiler.

2019’da Zhang ve diğ., (2019), yüksek kaliteli görüntüler oluşturmak için Fully Connected Generative Adversarial Network (FCGAN) yani hafif (lightweight) bir yapıda olan tam bağlantılı çekişmeli üretici ağ mimarisini sundu. Bu mimari ile yeni görüntüler oluştururken, Generative Adversarial Network (GAN) yani geleneksel

çekişmeli üretici ağ tabanlı yöntemlerle ilgili sorunları çözdüler. Ayrıca parmak damarı tanıma için yeni bir ağ mimarisi olan Fully Connected Generative Adversarial Network-Convolutional Neural Network (FCGAN-CNN) yani tam bağlantılı çekişmeli üretici ağ ile evrimsel sinir ağlarını birleştiren yapıyı önerdiler. 3 farklı çekişmeli üretici ağ tabanlı mimari kullanarak, ESA sınıflandırma performansını SDUMLA-FV veri setini kullanarak karşılaştırdılar.

2019'da Gumusbas ve diğ., (2019), öğrenim aktarımı kullanmadan, yüksek kimlik tanıma kesinliği elde etmek için Kapsül Ağları'nın (Capsule Networks) kullanılmasını önerdi. Halka açık veri setlerinde kişi başına sınırlı bir örneklem sayısına sahip olunmasına rağmen, bu çalışma Kapsül Ağları'nın özellik öğrenme yeteneğinden yararlandı. Ağa verilen giriş görüntülerine kesme, RLT ve yeniden boyutlandırma gibi ön işleme işlemleri uyguladılar. Önerilen ağın SDUMLA-FV, UTFVP, HKPU ve MMCBNU-FV veri setlerindeki performansını, LeNet-5'in performansı ve ablasyon (ablation) kullanarak önerdikleri ağın ESA tabanlı eşdeğerinin performansı ile ayrı ayrı karşılaştırdılar.

2020'de Mehdi Cherrat ve diğ., (2020), parmak izi, parmak damarı ve yüz tanıma sistemlerinin performanslarının birleşimine dayalı hibrit bir sistem önerdi. Bir ablasyon çalışması ile SDUMLA-FV veri seti için elde edilen kesinlik üzerinde bırakma mekanizmasının etkisini incelediler. Ayrıca kontrast iyileştirme ve görüntü kırpma gibi ön işleme işlemlerinin performans üzerindeki etkisini de sundular. Her biyometrik özellik için, Destek Vektör Makinesi, Lojistik Regresyon ve Rastgele Orman gibi farklı sınıflandırıcılarla ESA kullanarak kimlik tanıma performansını rapor ettiler.

2020'de Boucherit ve diğ., (2020), farklı görevleri yerine getirirken birkaç ağ kullanan, birleştirilmiş ESA kullanmayı önerdi. Böylece önerilen model ile daha sağlam öznitelikler çıkarmayı amaçlayıp oldukça iyi kesinlik performansı elde ettiler. Farklı filtre boyutları, farklı sayıda katman ve farklı aktivasyon fonksiyonları aracılığıyla en iyi performansı bulmak için önerilen modeli oluştururken, farklı topolojileri test ettiler. İlgi bölgesi yani Region of Interest (ROI) çıkarma ve Kontrast Sınırlı Uyarlamalı Histogram Eşitleme yani Contrast Limited Adaptive Histogram Equalization (CLAHE) kullanarak, görüntü kalitesini ve elde edilen kesinliği iyileştirmek için parmak damarı görüntülerinin kalitesini artırdılar. Herhangi bir ağ modeli tasarlanırken belirli bir zorunluluk veya tanımlanmış bir kural olmadığından SDUMLA-FV, THU-FVFD2 ve FV-USM veri setleri üzerinde farklı konfigürasyonlar ve farklı deney protokolleri deneyerek, kesinlik oranı açısından çeşitli performans sonuçları elde ettiler.

2021'de Tao ve diğ., (2021), çift yönlü özellik çıkarma ve öğrenim aktarımını kullanan yeni bir yaklaşım önerdi. Öznitelikleri iki yönde çıkarıp FV-USM ve başka bir veri seti üzerinde tanıma kesinliğini artırmayı amaçladılar. Ayrıca, ImageNet üzerinde eğitilen VGG19 ve ResNet50'den öznitelik çıkarma modellerinin aktarıldığı öğrenim aktarımı için tek yönlü bir model önerdiler. VGG19 ve ResNet50 gibi önceden eğitilmiş (pre-trained) modelleri kullanarak, bir füzyon yöntemi tercih edip çıkarılan öznitelikleri birleştirdiler. Elde edilen performansı zaman ve kesinlik açısından karşılaştırdılar.

2021'de Bilal ve diğ, (2021), tanıma için VGG16 modelinin değiştirilmiş bir versiyonunu kullandı. Önerilen hafif mimarinin konfigürasyonunu ayrıntılı olarak sunup elde edilen kesinliği artırmak için parmak damarı görüntülerinde Gama düzeltme, parmak lokalizasyonu ve görüntü keskinleştirme gibi çeşitli görüntü ön işleme işlemlerini kullandılar. Ağlarının performansını SDUMLA-FV, UTFVP, FV-USM ve THU-FVFDT2 veri setleri üzerinde değerlendirdiler.


2021'de Lu ve diğ, (2021a), ortaklama mekanizmaları tarafından sağlanan sınırlı rotasyonel değişmezliği (rotational invariance) önlemek için Vision Transformer tabanlı parmak damarı tanıma modelini önerdi. Parmak damarı görüntülerini yamalar halinde bölerek görüntüleri Transformer mimarisine uygun hale getirdiler. Önerilen modelde Çok Başlı Dikkat Mekanizması (Multi Head Attention Mechanism) ile pikseller arasında uzun menzilli bağımlılıklar sağladılar. Vision Transformer modelinin SDUMLA-FV, FV-USM ve MNCBNU-FV veri setleri üzerindeki rotasyonel değişmezlik yeteneği vasıtasıyla daha sağlam öznelikler çıkarmayı amaçladılar. Son olarak, modellerinin performansını LeNet-5 ve oluşturdukları ESA tabanlı eşdeğer bir modelle karşılaştırdılar.

2022'de Shaheed ve diğ, (2022b), öğrenim aktarımı ve derinlemesine ayrılabilir (depth-wise seperable) ESA kullanan Xception modeline dayalı bir parmak damarı tanıma ağı sundular. Bu önceden eğitilmiş model ile önerilen mimari, parmak damarı özelliklerini verimli bir şekilde öğrendiğinden, sağlam özellikler çıkarmak için daha etkili ve daha az karmaşık bir mimari sağlamış oldular. Önerilen modeli eğitmeden önce, görüntüleri standart bir formata dönüştürmek için veri artırımı ve ön işleme işlemlerini kullandılar. Önerilen modeli, SDUMLA-FV ve THU-FVFDT2 veri setlerinde VGG16, VGG19, InceptionV3 ve DenseNet121 modellerini kullanan diğer modellerle, işlem süresi tahsisi ve eğitim kesinliği açısından karşılaştırdılar. Yapılan deneylerde farklı bölme oranları (split rates) kullanarak önerilen modelin performansını detaylı olarak değerlendirdiler.

2022'de Chai ve diğ, (2022a), dikdörtgen filtreler ve hafif yapıya sahip yarı önceden eğitilmiş (semi pre-trained) ağlar kullanarak sığ (shallow) ağları keşfettiler. Tanıma ve doğrulama için SDUMLA-FV, FV-USM ve HKPU veri setleri üzerinde deneyler yaptılar. Bu deneylerle dikdörtgen filtrelerin, kare filtrelere göre daha iyi performans gösterdiğini bildirdiler. Ayrıca, hafif yarı önceden eğitilmiş bir ağın, önceden eğitilmemiş bir ağdan daha iyi performans gösterdiğini belirttiler.

2.3.2 Kimlik doğrulama

Kimlik doğrulama uygulamalarında biyometrik bir sistem, alınan sensör verileri ile sistem veri tabanında deneğe ait saklanan verileri karşılaştırarak deneğin kimliğini doğrular. Buradaki sistem biyometrik verileri, birebir (1-1) eşleşme yöntemini kullanarak Şekil 2.13'te gösterildiği gibi veri tabanındaki kayıtlarla karşılaştırır (Jain ve diğ, 2015). Kısacası doğrulama, veri tabanındaki bir kayıt ile sensörden alınan veriyi kıyaslama işlemidir.



Şekil 2.13: Biyometrik bir sistemde kimlik doğrulama sürecine ait akış şeması.

Önerilen doğrulama yöntemlerinin adil bir değerlendirmesini sağlamak için bazı popüler performans metrikleri Watanabe, (2009), tarafından listelenmiştir. Bu metrikler, Yanlış Eşleşme Oranı (YEO) yani False Matching Rate (FMR) ve Yanlış Eşleşmeme Oranı yani False Non-Matching Rate (FNMR) kullanılarak türetilir. FRR ve FAR, kendi içlerinde yapılan yanlış teşhislerin tüm işlemlere oranı olarak tanımlanabilir. Tüm bu metrikler, biyometrik sistem performansının daha doğru değerlendirilmesi için kullanılmaktadır (Biometrics, 2014). Sisteme kayıt olan kişi, kayıt sonrası sistem tarafından yetkili kişi yani (genuine) olarak bilinir. Bu kişi dışında, sisteme giriş yapmaya çalışan kişiler veya onlara ait örnekler ise, yetkisiz kişi (imposter) yani sahtekar kişi olarak bilinir.

$$YKO = \frac{\text{Toplam Yanlış Kabuller}}{\text{Toplam İşlem Sayısı}} \quad (2.3.2)$$

İki farklı denekten alınan biyometrik örneklerin aynı denek ile karıştırılma olasılığı, yani aynı kişiye ait birer örnek olarak değerlendirilmeleri Yanlış Eşleşme Oranı olarak bilinir. YEO, zaman zaman Denklem 2.3.2'deki Yanlış Kabul Oranı (YKO) yani False Acceptance Rate (FAR) ile karıştırılır. Aynı anlama sahip olmasalar dahi, bazı durumlarda YEO, YOK yerine kabul edilip kullanılabilir (Cappelli ve diğ., 2005). YKO, sistemin bir sahtekarı gerçek bir kullanıcı olarak kabul etme eğiliminin bir ölçüsüdür. Sistemin bir sahtekarı gerçek bir kullanıcı olarak yanlış bir şekilde tanımlama sayısının, sahtekarlar tarafından yapılan tanımlama girişimlerinin toplam sayısına bölünmesiyle hesaplanır. Düşük bir FAR, sistemin sahtekarları tespit etmede ve reddetmede etkili olduğunu gösterir. Eşik olarak t parametresi kullanılarak, sistem güvenlik toleransını düzenlemek için sürekli bir fonksiyon olan FMR(t) tanımlanabilir. t azaltılırsa, FMR(t) değerini artırır (Jain ve diğ., 2004). Buradaki t sistemin güvenlik seviyesine karar verip belirleyen eşik değeridir.

$$YRO = \frac{\text{Toplam Yanlış Reddedişler}}{\text{Toplam İşlem Sayısı}} \quad (2.3.3)$$

Aynı deneğe ait iki biyometrik ölçüm verisinin 2 farklı deneğe ait olma olasılığı, yani aynı kişiye ait iken farklı kişilere ait birer örnek olarak değerlendirilmeleri Yanlış Eşleşmeme Oranı olarak bilinir. FNMR, FRR ile eş anlamlı olmasa da, bazı durumlarda FNMR, Denklem 2.3.3'teki Yanlış Reddetme Oranı (YRO) yani False Rejection Rate (FRR) olarak kabul edilebilir (Cappelli ve diğ., 2005). YRO, sistemin gerçek bir kullanıcıyı sahtekar olarak reddetme eğiliminin bir ölçüsüdür. Sistemin gerçek bir kullanıcıyı yanlış bir şekilde sahtekar olarak tanımlama sayısının, gerçek kullanıcılar tarafından yapılan tanımlama girişimlerinin toplam sayısına bölünmesiyle hesaplanır. Düşük bir FRR, sistemin gerçek kullanıcıları

doğru bir şekilde tanımlamada etkili olduğunu gösterir. Eşik olarak t kullanılarak, sistem güvenlik toleransını düzenlemek için sürekli bir fonksiyon olan $FNMR(t)$ tanımlanabilir. t artarsa, $FNMR(t)$ değerini artırır (Jain ve diğ, 2004).

Tanımlanan $FMR(t)$ ve $FNMR(t)$ değerleri Receiver Operating Characteristic (ROC) Curve yani Karar Değerlendirme eğrisinin çiziminde kullanılır. ROC eğrisini çizmek için, t eşikinin tüm çalışma noktalarında $FMR(t)$ ve $1-FNMR(t)$ değerleri hesaplanır (Jain ve diğ, 2004). Her bir eşikte FMR ve $FNMR$ hesaplanır. ROC, eşleşen algoritmanın performansını göstermek için FMR 'yi $1-FNMR$ 'ye karşı çizen grafiklerdir ve biyometrik uygulamalarda performans ve güvenlik açısından esas alınmaktadır çünkü bir sınıflandırma probleminde sistemin güvenlik seviyesini belirleme adına en uygun eşik değerinin belirlenmesi ile bu eğrinin izlediği seyir değişecektir. Bu sayede eşik değerinin sistemin sınıflandırma başarısına etkisini görmek mümkündür. Eşit Hata Oranı yani Equal Error Rate, bu çizilen grafikte $FMR(t)$ 'nin $FNMR(t)$ 'ye eşit olduğu eşik değeri olan t olarak kabul edilir (Jain ve diğ, 2004). EHO hem doğru hem de yanlış tanımlamaları dikkate alarak sistemin genel kesinliğinin bir ölçüsüdür. EHO, tanımadaki kesinlik hakkında tahmini bilgi verir (Biometrics, 2014). YKO ve YRO, EHO'yu hesaplamak için kullanılır ve sırasıyla, sistemin ya sahtekarları gerçek kullanıcılar olarak kabul etme ya da gerçek kullanıcıları sahtekarlar olarak reddetme eğilimini ölçer. Detection Error Tradeoff (DET) Curve yani Tespit Hatası Takası eğrisi, $FNMR$ 'yi FMR 'ye karşı çizer ve ROC eğrisinin değiştirilmiş bir versiyonu olarak bilinir (Mansfield ve Wayman, 2002).

Özetle, doğrulama sistemlerinde, kişinin sensörden alınan verileri ile veri tabanında kayıtlı olan ve kişinin o kişi olduğunu kanıtlayan verileri arasında yüksek derecede benzerlik varsa, sensör verileri, sistemin kişiyi yetkili olarak kabul etmesini sağlar. Sensörden alınan veri ile veri tabanındaki kayıtlı verileri arasında yüksek derecede benzerlik yoksa, sistem kişinin yetkisiz olduğunu gösterir. Burada, yüksek derecede benzerlik ya da yüksek derecede farklılık aramak, tamamen biyometrik sisteme sahip kişinin sistemden beklediği güvenlik seviyesiyle ilişkilidir. Kısacası, sistemin güvenlik seviyesine göre kullanılacak olan eşik değerine karar verilir ve sistem, o eşik değerine göre giriş yapmaya çalışan kişilerin yetkili ya da yetkisiz olduğuna karar verir. Bundan dolayı, farklı eşik değerlerinde, yetkili puan (genuine score) ve yetkisiz yani sahtekar puan (imposter score) dağılımları (distributions) değişim gösterir (Hu ve diğ, 2018). Bu dağılımlar, uygulanan yöntemin, doğrulamaya konu olan sınıfları, yani gerçek kişiyi ve sahtekarı, ne kadar doğru bir şekilde ayırdığını gösterir.

2.3.2 Doğrulama ile ilgili çalışmalar

2017'de Qin ve El-Yacoubi, (2017a), belirli bir görüntüdeki piksellerin damar olup olmama olasılığını tahmin ederek damar piksellerini segmentlere ayırmak için bir derin öğrenme modeli önerdiler. Sınırlı bilgi verilmesine rağmen pikselleri otomatik olarak etiketlediler. Etiketlenmiş pikseller oluşturmak için geleneksel yöntemleri kullanırken, daha sağlam etiketler atamak için temel yöntemlerin çıktılarını birleştirmeyi önerdiler. Yamalara dayalı FV-USM ve HKPU veri setlerinden bir veri seti oluşturarak parmak damarı doğrulaması için ESA tabanlı bir yapı kullandılar. Son olarak, eksik damar modellerini kurtarmak için Tam Evrişimsel Ağ yani (Fully Convolutional Network (FCN)) kullanarak bir damar kurtarma modeli geliştirdiler. Değişken sayıda çekirdek

(kernel), yama (patch) boyutu, çekirdek boyutu ve katman (layer) sayısı karşısında, doğrulama performansı değişikliklerini bildirmek için yoğun bir deneysel protokol yürüttüler.

2018'de Fang ve diğ, (2018), MMCBNU-FV ve SDUMLA-FV veri setleri üzerinde 2 kanallı bir ağ sundular. 2 akışlı ağ yapısı sayesinde, yeterli eğitim örneklerinin olmamasından kaynaklanan aşırı öğrenme (overfitting) sorununun üstesinden geldiler. Önerilen yapı aracılığıyla eğitim örneklerinin sayısını artırdılar. Ayrıca, 2 akışlı bir ağ, çıkarılan minimum ilgi bölgesi görüntüsü ile birleştirilerek, görüntüdeki rotasyonel değişim problemini çözdüler. Yürütülen deneylerde, veri eğitimi ve testi için bölme oranı belirlemede bir standarda ihtiyaç olduğunu belirttiler. Önerilen hafif ağ çözümü ile, yüksek hesaplama maliyeti ve nispeten yüksek bellek ihtiyacı olmadan, tatmin edici doğrulama performansı elde ettiler.

2018'de Hou ve Yan, (2018), FV-USM veri setinin çıkarılmış ilgi bölgesi görüntülerinde evrişimli otomatik kodlayıcıyı evrişimli sinir ağıyla birleştiren bir doğrulama ağı önerdiler. Sunulan ağ üzerindeki kodlayıcı (encoder) mekanizması yardımıyla parmak damarı öznelikleri verimli bir şekilde çıkardılar. Evrişim katmanlarının sayısı ve filtrelerinin sayısı gibi hiperparametreleri değiştirilerek, kapsamlı testler yoluyla oldukça iyi bir doğrulama performansı elde ettiler.

2018'de Jalilian ve Uhl, (2018), tamamen evrişimli derin sinir ağlarını kullanan parmak damarı için yeni bir tanıma modeli önerdiler. Anlamsal bölütleme (semantic segmentation) için 3 farklı ağ aracılığıyla SDUMLA-FV ve UTFVP veri setlerinin damar desenlerini çıkardılar. Manuel olarak etiketlenmiş eğitim verilerini kullanarak 3 ağ üzerinden otomatik olarak etiket oluşturmaya çalıştılar. Tanıma performansını iyileştirmek için deney kapsamında oluşturulmuş ve ikili özellikler içeren etiketleri kullandılar. Değişen sayıda etiket için, eğitim verilerinin bölütleme kalitesinin elde edilen performans üzerindeki etkisini karşılaştırdılar ve her ağın EER ve ROC açısından tanıma performansını raporladılar. Karşılaştırılabilirlik ve tekrarlanabilirlik için eğitim parametrelerini değiştirmeden sabit tuttular ve bilinen bir test protokolü kullandılar (Maio ve diğ, 2004). Bu çalışma ile doğrulama performansını izlemenin yanı sıra manuel etiket ihtiyacını ortadan kaldırmayı amaçladılar.

2019'da Lu ve diğ, (2019), doğrulama için derin evrişimli sinir ağlarından yararlanmak için önceden eğitilmiş bir ESA modelinden ESA filtreleri seçtiler. Kamuya açık parmak damarı veri setlerinin örneklem büyüklüğü ve toplam görüntü sayısı sınırlı olduğundan ve bir ESA modelini eğitmek için yeterli olmadığından, ESA filtrelerinin çıktılarını karşılaştırdılar ve SDUMLA-FV ve MMCBNU-FV veri setleri üzerinde kapsamlı deneyler yaparak en uygun olanları seçip kullandılar. Filtreleri görselleştirip karşılaştırdıktan sonra, en iyi görüntü temsilini oluşturmak için nihai histogramı oluşturmak ve farklı özelliklerin çıkarılmasını desteklemek için bu histogramı kullandılar. Seçilen ESA filtrelerinden oluşan bir banka kullanarak, bu bankanın elemanlarının sırasına ve büyüklüğüne karar verdiler. Yapılan deneylerin kapsamlı görselleştirilmesini sağlayarak tatmin edici bir doğrulama performansı elde ettiler.

2019'da Tang ve diğ, (2019), Siyam Sinir Ağı'nı yani Siyame Neural Network kullanarak bir parmak damarı doğrulaması önerdiler. Eğitim verisi eksikliğinin

üstesinden gelmek için, FV-USM, MNCBNU-FV ve diğeri bir veri seti için yeni görüntü örnekleri oluşturmak üzere 24 farklı veri artırımı stratejisi uygulayarak kapsamlı şekilde veri artırımı politikasından faydalandılar. Ayrıca, veri problemini azaltırken artırılmış veriye katkıda bulunmak için, çıkarılan düşük seviyeli ortak özellikler sağlayan önceden eğitilmiş ağırlıklar (pretrained weights) kullandılar. Ardından, önceden eğitilmiş ResNet-50 katmanlarını ve diğeri bazı özel katmanları kullanarak bir ESA tasarladılar. Bu ağı, çıkarılan öznelikler arasındaki mesafeyi ölçerek örnekleri eşleştirmek ve karşılaştırmak için kullanılan Siyam Ağı'nda kullandılar. Bu çalışmada, daha ayırt edici öznelikleri çıkarmak için yeni bir kayıp (loss) fonksiyonu önerdiler. Son olarak, bilgiyi hafif bir ağı üzerinden gömülü cihazlara aktarmak için önceden eğitilmiş ağırlıklar kullandılar.

2019'da Qin ve Wang, (2019), damar özelliklerini çıkarmak için ESA ile Uzun Kısa Süreli Bellek yani Long Short Term Memory (LSTM) kullanmayı önerdi. Bazı el yapımı damar bölütleme yöntemlerinin bir kombinasyonunu kullanarak parmak damarı görüntüleri için karşılık gelen etiketleri otomatik olarak atadılar. Her etiketli piksel için farklı yönlerde 4 dizi ürettiler. Her bir dizinin damar olup olmadığını test ederken LSTM, pikseller arasındaki uzamsal bağımlılıkları yakaladı. Eşleştirme hatalarından ve ekstra hesaplama maliyetlerinden kaçınmak için, kırılmış görüntü arka planlarını ve HKPU veri setinin görüntü ön planlarını kullandılar.

2020'de Kuzu ve diğeri, (2020a), omurga (backbone) evrimsel sinir ağlarının üzerinde yoğun bağlantılı evrimsel otomatik kodlayıcı kullanarak damar doğrulaması sundu. Omurga ESA yapısında DenseNet-161 ve ResNext-101'in özelleştirilmiş versiyonlarını kullandılar. Oluşturulan özelliklerin kapasitesini iyileştirmek için bir otomatik kodlayıcı kullandılar. Mevcut veri setleri sınırlı sayıda örnekten ciddi şekilde zarar gördüğünden, bu mimari ile ayırt edici özellik çıkarımı sağlamayı amaçladılar. Bu sistemi, parmak damarı, avuç içi damarı ve dorsal el damarı veri setlerini kullanarak test ettiler. Parmak damarı için SDUMLA-FV veri seti kullanılırken, bildirilen eğitim ve test seti bölünme oranları ile açık küme protokolü (open set protocol) kullanarak, kapsamlı deneylerle doğrulama süreçlerini tamamladılar.

2020'de Zhao ve diğeri, (2020a), öznelik vektörlerinin sınıf içi mesafesini en aza indiren bir merkez kayıp fonksiyonuna sahip ESA kullanan yeni bir doğrulama yaklaşımı tanıttı. Bu çalışma, kayıp fonksiyonlarının elde edilen performansa katkısını analiz etmek için hafif bir ESA önermiştir. MNCBNU-FV ve FV-USM veri setlerinde merkez kayıp fonksiyonunun elde edilen performansını, Softmax ve üçlü kayıp fonksiyonu (triplet loss function) ile karşılaştırmışlardır. Dinamik düzenleme (dynamic regularization) ile kullanılan veri setleri kısıtlı özelliklere sahip olsa da, azaltılmış aşırı uydurma ile verimli yakınsama sağladılar.

2020'de Kuzu ve diğeri, (2020b), tasarlanan ağları eğitmek için yeterince büyük herhangi bir veri seti olmadığından, ImageNet veri setinin önceden eğitilmiş ağırlıklarını kullanarak öğrenim aktarımı ile mevcut mimarileri kullanmayı önerdi. Açık küme protokolünü ve kapalı küme protokolünü (closed set protocol) kullanarak parmak damarı, avuç içi damarı ve dorsal damar veri setleri için doğrulama performansını değerlendirdiler. Parmak damarı için SDUMLA-FV veri seti üzerinde deneyler yapıldı. VGG19, Inception-v3 ve DenseNet-161 gibi birkaç ESA modelinin EER

performansını karşılaştırdılar. DenseNet-161 mimarisini değiştirerek ve ImageNet veri setinin önceden eğitilmiş ağırlıklarını kullanarak, literatürdeki en yüksek EER performansını elde ettiler. EER, ROC eğrisi ve ayrıca gerçek-sahte dağılımlarını (genuine-imposter distributions) kullanarak elde edilen performans sonuçlarını raporladılar. DenseNet-161 mimarisini kullanarak ve önceden eğitilmiş ImageNet'e ait ağırlıklardan faydalanarak literatürde elde edilmiş en yüksek EER değerlerini elde ettiler.

2021'de Hou ve Yan, (2021), önerilen yöntemin performansını değerlendirmek için açık küme ve kapalı küme protokollerini kullandı. Bu çalışmada, arkkosinüs (arccosine) kayıp fonksiyonunu önerdiler ve kayıp fonksiyonunun elde edilen tanıma performansına katkısını göstermek için birleşik kayıp fonksiyonundan faydalandılar. Arkkosinüs kayıp fonksiyonu ile sınıf içi mesafeyi azaltmayı ve sınıflar arası mesafeyi artırmayı amaçladılar. Doğrulama için, verimli kanal dikkat artık (residual) ağı içeren tasarlanmış bir ESA kullandılar. 2 kat çapraz doğrulama (2 fold cross validation) kullanarak, FV-USM, SDUMLA-FV, HKPU ve kendi veri setleri üzerinde güvenilir bir performans elde etmeyi amaçladılar.

2021'de Ou ve diğ, (2021), FV-USM, MMCBNU-FV, HKPU ve kendi veri setlerinde elde edilen doğrulama performansını veri artırımı, kayıp fonksiyonu seçimi ve ağ mimarisi tasarımının etkisini dikkate alarak artırma için bir çerçeve önerdiler. Bu çalışmada, aşırı öğrenme problemlerinden kaçınmak için dikey çevirme (vertical flipping) kullanıp veri ihtiyacını karşıladılar. Derin ağların genelleme (generalization) yeteneğini geliştirmek için 2 farklı kayıp fonksiyonunu birleştirerek bir füzyon tasarladılar. Ayrıca açık küme protokolünü kullanarak çeşitli ağ tasarımlarını analiz ettiler. Öğrenim aktarımını kullanarak VGG-16, ResNet-18 ve ResNet-34 gibi farklı ESA mimarilerini uyguladılar. Elde edilen performansı değerlendirmek için FVC2004 protokolünü benimsediler (Maio ve diğ, 2004). Bu ESA mimarileri kullanılarak yapılan deneylerde, minimum model karmaşıklığına rağmen ResNet-18 ile üstün performans elde ettiler.

2021'de Huang ve diğ, (2021), yakın kızılötesi görüntülerin özelliklerinden kaynaklanan düşük görüntü çözünürlüğüne rağmen uzamsal alanda özellik öğrenme kapasitesini artırmak için dikkat (attention) mekanizması kullanan bir çerçeve önerdiler. Dikkat modüllerini istifleyerek bir parmak damarı kimlik doğrulama mimarisi tasarladılar ve açık küme protokolünü kullanarak MMCBNU-FV, FV-USM, SDUMLA-FV ve diğer bir parmak damarı veri setinde doğrulama performansını test ettiler.

2022'de Li ve diğ, (2022), tarafından FV-USM, SDUMLA-FV, MMCBNU-FV, HKPU ve THU-FVFD3'te ayırt edici özellikler elde etmek için dinamik bir Softmax kayıp fonksiyonu sunuldu. Elde edilen doğrulama performansını artırmak için bu çalışma ile sınıflar arası mesafeyi artırmak ve sınıf içi mesafeyi azaltmak amaçlandı. Ayrıca mevcut kayıp fonksiyonlarının dezavantajları da bu çalışmada belirtilmiştir.

2022'de Hou ve Yan, (2022), doğrulama için yeni bir GAN önerdi. Bu ağ, geleneksel GAN tarafından üretilen sahte verileri kullanarak öğrenme yeteneğini ve ayırt etme yeteneğini geliştirmektedir. Önerilen ağ, GAN ve üçlü kayıp tabanlı ESA sınıflandırıcı

içerir. Deneyler, açık küme ve kapalı küme protokolleri kullanılarak SDUMLA-FV, FV-USM, HKPU ve kendi veri setleri üzerinde gerçekleştirilmiştir. Performans güvenilirliği sağlamak için yürütülen deneyler boyunca 2 kat çapraz doğrulama kullanılmıştır.

2.3.3 Görüntüleme

Biyometrik süreçlerin ilk adımı olan veri akışı, diğer bir deyişle veri toplama süreci, sensörler yardımıyla içinde biyometrik bilgi saklı olan verinin elde edildiği aşamadır. Şekil 2.14'te gösterildiği gibi sisteme yapılan kayıt ve her türlü tanıma ve doğrulama amaçlı karşılaştırma, parmak damarı biyometrisi için görüntüleme adını verdiğimiz süreçten faydalanmaktadır. Parmak damarı biyometrisi için kamera ve yakın kızılötesi ışık kaynakları ile kurulan platformdan alınan görüntüler, toplanan veriyi ifade etmektedir. Görüntüleme sistemleri, kullanılan kamera ve yakın kızılötesi ışık kaynaklarının çeşitleri ve görüntüleme platformlarındaki konumları ile tasarlanan sistemde kamera lensinde ekstra filtre kullanılıp kullanılmama durumuna göre, değişen topolojilere sahip olabilir. Kullanılan kamera CMOS ya da CCD olabilirken, ışık kaynakları değişen dalga boylarına sahip olabilir. Bu süreç esasen biyometrik sistemler açısından en önemli süreçtir. Bu adımda kullanılan topoloji, elde edilen verinin direkt olarak sahip olduğu kaliteye etki edecektir. Bunun dışında kaç parmaktan görüntü alındığı, o parmaklardan kaç örnek alındığı, alınan görüntünün boyutu ve çözünürlüğü, alınan görüntülerin üst üste binip binmemesi yani art arda alınan örneklerin neredeyse aynı bilgiyi içerip içermemesi elde edilen tanıma başarısında görüntü kalitesi gibi önemli rol oynar (Biometrics, 2014). Kısacası, parmak damarı görüntülerken neredeyse kaçınılmaz olan ışığın homojen dağılması, görüntüde iz (blur) oluşması ve parmağın platforma yerleşiminde yaşanan sapmalar, tasarlanacak herhangi bir görüntüleme sisteminden elde edilen görüntünün kalitesini önemli oranda etkileyecektir (Zhang ve diğ, 2019).

Piyasadaki parmak damarı görüntüleme cihazları halka açık veri setlerinin oluşturulmasına imkan sağlamadığından Twente Üniversitesi bu açığı kapatmak için çeşitli cihazlar tasarlamıştır (Rozendal, 2018). Bu cihazlardan birinde, dokunmatik ekran vasıtasıyla kullanıcıyla etkileşime girip sağladıkları kullanıcı arayüzü ile farklı bir deneyim sunmuşlardır. Bu cihazda ışık parlaklık ayarına izin vererek kaliteli görüntü almayı amaçlamışlardır (Elderem, 2022). Kullanıcıların parmaklarının kalınlık açısından birbirinden farklı olmasını, sundukları yazılımla çözerek parmağa ait sınırları belirleyip ilgi bölgesine ulaşmayı başarmışlardır. Eldeki dönmeden kaynaklı sapmaları, görüntüsü alınan parmağın orta noktasına odaklanarak bir çizgi



Şekil 2.14: Biyometrik bir sistemde kayıt sürecine ait akış şeması.

ile çözmüşlerdir. Damar kalınlığı bilindiği ve beklendiği gibi parmak içinde hep aynı olmadığından aydınlatma konusunda farklı parlaklık ve farklı akım değerlerine sahip LED ışıklarla bu kalınlık farkını gidermeyi amaçlamışlardır. Cihaz tasarımı yapan üniversitelerden birisi de Dongguk Üniversitesi'dir. Sunulan görüntüleme cihazı, bazı tasarım problemlerine sahip olsa da, platform üzerinde kullanıcıyı, parmağını konumlandırması konusunda yönlendiren bir yapıya sahiptir (Pham ve diğ., 2022). Her iki üniversiteye ait tasarımlarda, kullanıcılar yönlendirilerek, kayma ve dönmeden kaynaklanabilecek hataların en aza indirilmesi amaçlanmıştır.

Akademik cihazların üretilme sebebi, piyasadaki ürünlerin tak-çalıştır yapıda olup genel olarak ham görüntü erişimine izin vermemesidir. Bu cihazlar sadece tanıma ve doğrulama uygulamalarına odaklanmaktadır. Bu sebeple akademik cihazlar üretilerek halka açık parmak damarı veri setleri toplanıp paylaşılabilmiştir. Piyasada biyometrik amaçlarla parmak damarı görüntüleme cihazı üreten markalardan bazıları şunlardır: Hitachi, Mofira, IDEMIA, M2SYS, MYID ve GERWIN (Hou ve diğ., 2022). Piyasada yaygın olarak kullanımda olan cihazlardan bazıları ise şunlardır: Hitachi Secua VeinAttestor, EverFocus EBC980R, Korecen FV-100 ve ZKTeco FV350 (Elderen, 2022). Bu cihazlar kullanıcıya anlaşılması kolay bir kullanım imkanı sağlarken, görüntüye erişim imkanı sağlamazlar. Değişen fiyat, hız ve doğruluk parametrelerine ek olarak sundukları ekran seçenekleri ile kullanıcılara vadettikleri tanıma ve doğrulama performanslarına ulaşan bu cihazlar, iç yapıları bir muamma olan ve "kapalı kutu" diye tabir edilen bir yapıdadır.

Çizelge 2.7: Piyasadaki bazı parmak damarı görüntüleme cihazları.

Damar Görüntüleme Cihazları

UMTEC Vein Finder
Vivolight Handheld Infrared Vein Finder
IVYRISE Infrared Vein Finder
Veinlite LEDX
Respironics Wee Sight Transilluminator
Venoscope II Transilluminator Adult/Baby
Illumivein Portable Red LED Flashlight Vein Finder
AccuVein Vein Finders
Intellivision Red Infrared Vein Finder
VeinGram New Handheld Projection Vein Viewer
Bestman Vein finder (BVF)
Vein Finder Glasses
Verdict—Best Vein Finders

Biyometrik amaçlar dışında çeşitli sebeplerle damar görüntülemek için kullanılan cihazlara ait marka veya modeller ise Çizelge 2.7'de sıralanmıştır. Görüntülemeyi gerektirecek bu sebeplerden birincisi, obezite ve çeşitli hastalıklar nedeniyle damar yoluyla kişinin beslenmesini gerektiren durumlardır. Koldaki damarları bulmanın önemli olduğu bu gibi durumlarda ten rengi, koldaki tüy oranı, yara veya dövmeyle sahip olmak, damarların görüntülenmesine etki edebilir (Abdul Kadir ve diğ., 2022).

Sebeplerden ikincisi, yaşlılardan ve bebeklerden kan alınmasının zaman zaman oldukça zor olmasıdır (Van Tien ve diğ, 2015). Bu tip bireylerde damarlar herhangi bir teknik yardım alınmadan bulunamamaktadır. Bir diğer sebep ise, hastalık teşhisidir (Hartung ve Busch, 2009). Görüntülenen damarın şekli ve yapısına göre hastalık teşhisinde bulunmak mümkündür. Markaları veya modelleri listelenen bu cihazların yapısı ve çalışma mantığı, akademide biyometrik amaçlar için geliştirilen cihazlara referans olmuştur. Akademik amaçlarla geliştirilen bazı parmak damarı görüntüleme cihazları ve sahip oldukları özellikler Çizelge 2.8'deki gibidir.

Çizelge 2.8: Akademide tasarlanan bazı parmak damarı görüntüleme cihazları.

İlgili Yayınlar	Kullanılan Sensör (Kamera)	Dalga boyu (λ)
(Kumar ve Zhou, 2011)	Yakın Kızılötesi Kamera	850 nm
(Asaari ve diğ, 2014)	Sony PSEye Kamera	850 nm
(Ton ve Veldhuis, 2013)	Monokrom Kamera	850 nm
(Kauba ve diğ, 2019)	Monokrom Kamera	808 nm

Tasarlanan görüntüleme sistemlerinden elde edilen örnek görüntüler, geliştirilen herhangi yeni teknoloji ya da yeni algoritmanın değerlendirilmesinde kullanılır. Veri tabanında saklanan bu görüntülerden oluşan veri setinin bazı özellikleri, değerlendirme süreçleri açısından çok önemlidir. Örneğin; görüntülerin alındığı sensörün kalitesi, hava sıcaklığı, nem ve cihaz ergonomisi gibi çevresel faktörler, gönüllülerin yaşa, cinsiyete, ırka, mesleğe göre eşit dağılım göstermesi, kaç parmaktan veri toplandığı, her parmaktan kaç örnek alındığı, alınan örneklerin kaç seansta alındığı, bu seanslar arası geçen sürenin makul olup olmayışı gibi etkenler oluşan veri setinin karakteristik özelliklerini tayin edecektir (Biometrics, 2014). Bu özellikleri tümüyle bünyesinde barındıran birebir aynı özelliklere sahip veri setleri bulunmadığından geliştirilen her teknoloji ya da her algoritmayı değişik veri setleri üzerinde kullanıp değerlendirmek mümkün iken, bu veri setlerini karşılaştırmak olası değildir (Biometrics, 2014).

3. MATERYAL VE YÖNTEM

Bu bölümde, tez sürecinde kullanılan donanımlar, masaüstü uygulamalara ait geliştirme ortamları (integrated development environments (IDEs)), modüller, çevrimiçi (online) platformlar ve parmak damarı haricinde tezde kullanılan veri setleri hakkında bilgi verilmiştir.

3.1 Materyal

Tez çalışması için gerçekleştirilen uygulamalarda Google Colaboratory, Jetson Nano 4 GB, Raspberry Pi 4 Module B, HP Probook 4540s, Google Teachable Machine ve LG G4 kullanılmıştır. Kullanılan cihaz ve platformlara ilişkin bilgiler sırasıyla şu şekildedir:

Google Colaboratory: Google Colaboratory ya da Colab, Google tarafından geliştirilip kullanıcılarına ücretsiz bulut ve GPU tahsis eden bir platformdur. Google Drive’da yer alan bu platform, Gmail hesabına sahip olmak dışında herhangi bir ön şarta sahip değildir. Keras, Tensorflow ve OpenCV başta olmak üzere Python diline entegre olabilen tüm modül ve kütüphanelere erişim olanağı sağlaması nedeniyle, GPU olanaklarına sahip olmayan kullanıcılar tarafından oldukça sık tercih edilmektedir. GPU’ya erişimin maliyet açısından zor olduğu göz önünde bulundurulduğunda, tez sürecinde parmak damarı tanıma ve doğrulama uygulamaları için sıkça Colab tercih edilmiştir.

Jetson Nano 4 GB: 64 bit ARM CPU ve 128 çekirdek NVIDIA GPU’ya sahip Jetson Nano, bir mikro bilgisayardır. Sahip olduğu GPU ile Raspberry Pi 4’e karşı görüntü işleme ve makine öğrenmesi uygulamalarında çeşitli üstünlüklere sahip bu gömülü sistem, yazılan kullanıcı arayüzü programının Visual Studio IDE kullanılarak Python 3.7’de çalışmasına olanak sağlamıştır.

Raspberry Pi 4 Model B: Raspberry Pi 4 Model B, 4 Çekirdekli CPU ve 4 GB DRR4 RAM’e sahip bir mikro bilgisayardır. USB-C güç girişine sahip bir adaptörle beslenen Raspberry Pi mikro HDMI, USB 3.0 ve Bluetooth 5.0 özelliklerine sahiptir. Avuç içi izi veri setinin oluşturulması için kullanılan bu gömülü sistem, MediaPipe Hands çerçevesinin kullanımına olanak sağlayacak asgari CPU özelliklerini fazlasıyla barındırmaktadır.

HP Probook 4540s: Matlab’ta gerçekleştirilen sentetik damar görüntüsü üretimi ve Python’da gerçekleştirilen avuç içi izi çıkarımı uygulamalarında faydalanan bu 64 bitlik bilgisayar, Intel(R) Core(TM) i5 işlemciye sahiptir. Sahip olduğu yeteneklerle belirtilen uygulamalar esnasında kullanılmıştır.

Google Teachable Machine: Matlab kullanılarak çevrimiçi olarak oluşturulan sentetik parmak damarı görüntülerinin etiketlenip eğitildiği ve sonrasında elde edilen modelin dışa aktarılabilirdiği bu platform, Google tarafından geliştirilmiştir. Teachable Machine, eğitim sonrası ortaya çıkan modele ait kodu otomatik oluşturduğu ve kullanım kolaylığına sahip olduğu için kullanışlı seçeneklere sahiptir.

LG G4: Görüntüleme platformunda kamera vazifesi gören bu telefon, sahip olduğu girinti ve çıkıntılar, ekran boyutu, kızılötesi ışık ve arka kamerası ile tasarıma yön vermiştir. Android uygulamasının, yazılımsal olarak erişim sağladığı kamera ve kızılötesi ışık özellikleri tasarım için hayati değere sahiptir.

Listelenen donanımlarla gerçekleştirilen uygulamalarda kullanılan geliştirme ortamları ise şu şekildedir:

Android Studio: Görüntüleme platformunda görüntü işlemeye imkan veren ve parmağın telefon kamerasıyla görüntülenebilmesini sağlayan arayüz, Java dilinde Android Studio'nun sağladığı ortam kullanılarak yazılmıştır. Android Studio, Eclipse sonrası Android için mobil uygulamalar yazılmasını Java dilinde mümkün kılmaktadır.

Visual Studio Code: Jetson Nano ve Raspberry Pi'de gerçekleştirilip Python dilinde yazılan programlarda kullanılan bir geliştirme ortamıdır. Windows için de seçenekler sunan Visual Studio Code, oldukça gelişmiş bir geliştirme ortamına sahiptir.

Spyder IDE: Tıpkı PyCharm gibi oldukça popüler olan Python programlama platformlarından biridir. Yapısı itibariyle Matlab'a benzer bir arayüzü sunduğundan kullanıcılarına kullanım kolaylığı sağlamaktadır. Hp Probook üzerinde kurulu olan Spyder ile GPU gerektirmeyen deneyler ve görüntü işleme uygulamaları gerçekleştirilmiştir. Bunlardan biri MediaPipe Hands kullanarak gerçekleştirilen avuç içi izi çıkarım uygulamasıdır.

Jupyter Notebook: Python programlamaya izin veren geliştirme ortamlarından biridir. Google Colab ve Anaconda dağıtımında (distribution) kendisine yer bulan Jupyter Notebook, programlama haricinde not tutma ve ders notu hazırlama amacıyla da kullanılabilir. Tanıma ve doğrulama uygulamaları için tez kapsamında Jupyter Notebook'tan faydalanılmıştır.

Tinkercad: AutoDesk tarafından sunulan 3 boyutlu tasarıma olanak sağlayan çevrimiçi bir platforma sahip olan Tinkercad, tasarlanan çizimlerin, yazıcılara aktarılıp basılmasına imkan veren bir yapıdadır. Ücretsiz olduğu için tasarlanan görüntüleme cihazı Tinkercad kullanılarak çizilmiştir.

Geliştirilen uygulamalarda kullanılan başlıca modül, kütüphane ve çerçeveler (frameworks) ise şunlardır:

OpenCV: Intel tarafından geliştirilip Google tarafından satın alınan OpenCV, açık kaynak kodlu bir bilgisayarlı görü (computer vision) kütüphanesidir. C++, Java ve Python dillerine entegre olabilen bu kütüphane, görüntü işleme uygulamalarının gerçekleştirilebilmesine olanak sağlamaktadır.

MediaPipe Hands: Google tarafından piyasaya sürülen MediaPipe Hands, artırılmış gerçeklik ve işaret dili tanıma uygulamaları için geliştirilmiş bir çerçevedir. El takibi amacıyla geliştirilen bu çerçeve, tez kapsamında avuç içi ve parmak bölgesinin çıkarımı için kullanılmıştır.

Tkinter: Python dilinde kullanıcı arayüzü uygulamaları yazmayı nispeten kolaylaştırması ve kullanıcı dostu bir yapıya sahip olması nedeniyle Tkinter tercih edilmiştir. Bu modül, Windows ve Linux işletim sistemine sahip bilgisayarlarda gerçekleştirilen masaüstü uygulamalara kullanıcı arayüzü yazmak için oldukça iyi seçenekler sunmaktadır. Oluşturulan sentetik parmak damarı görüntülerini kullanan parmak damarı tanıma uygulamasına ait kullanıcı arayüzünün geliştirilmesinde Tkinter kullanılmıştır.

MySQL: Oluşturulan veri tabanı ile Python'da yazılan kullanıcı arayüzü arasında entegrasyonu sağlayan MySQL modülü, açık kaynak kodlu olması nedeniyle sıkça tercih edilmektedir. Çeşitli dillere sağladığı destek ve yazımının diğer veri tabanı dillerine benzerliği, kullanım açısından onu popüler kılmaktadır. Oluşturulan kullanıcı arayüzünde kullanıcının girdiği verilerin veri tabanında saklanması veya veri tabanından silinmesi amacıyla kullanılmıştır.

Gerçekleştirilen deneylerde kullanılan programlama dilleri ise Python, Java ve Matlab'tır. Python programlama dili görüntü işleme, makine öğrenmesi, veri tabanı programlama, kullanıcı arayüzü tasarımı, web programlama gibi çeşitli alanlarda hizmet verip herhangi bir ücret gerektiren lisansa ihtiyaç duymadığı için tercih edilmiştir. Kurulumu kolay ve yazımı oldukça basit bir dil olan Python, özellikle yapay zeka alanında sağladığı imkanlarla bilinip çevrimiçi ve masaüstü platformlarda çeşitli geliştirme ortamları tarafından desteklenmektedir. Başta Google Colab, Spyder ve Visual Studio Code olmak üzere çeşitli geliştirme ortamlarında kullanılan bu yazılım dili oldukça popülerdir. Java programlama dili, Android işletim sistemine sahip LG G4 marka telefonda gerçekleştirilen uygulamayı devreye almak amacıyla tasarlanan arayüz için tercih edilmiştir. Python kadar olmasa da çeşitli alanlarda etkinliğini devam ettiren Java, herhangi bir ücretli lisans gerektirmeden mobil uygulamaların yazımına olanak sağlamaktadır. Android Studio'nun OpenCV kütüphanesiyle entegrasyon sağlaması, oluşturulan uygulamaların görüntü işleme amacıyla kullanımına imkan vermektedir. Matlab programlama dili, sentetik parmak damarı görüntüleri elde edebilmek için kullanılmıştır. Açık kaynak koda sahip olup tasarımcıları tarafından sunulan kullanıcı arayüzünde çeşitli parametreleri değiştirip kullanmak için faydalandığımız bu dil, matris temelli çarpımları ele alış biçimi ve sahip olduğu sayısız eklenti ile birçok seçeneği içerisinde barındırmaktadır. Son olarak, parmak damarı veri setleri haricinde tez kapsamında kullanılan veri setleri şu şekilde sıralanabilir:

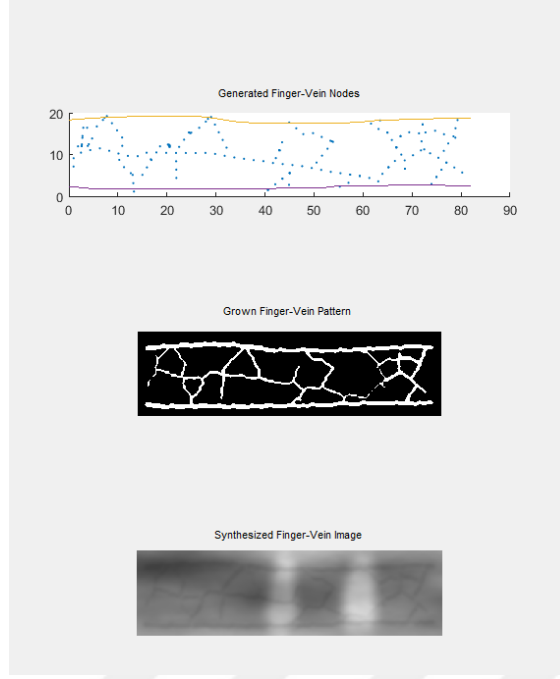
IITDTP Avuç İçi Veri Seti: IITDTP veri seti, 230 kişinin iki elinden alınan, elleri cepheden gören toplam 2601 görüntüden oluşmaktadır (Kumar, 2008). Bu görüntüler, platformda kişiyi yönlendirmeden ve kişiye temas etmeden alındığı için birtakım ölçek ve kayma problemlerine sahiptir. Bu veri seti, farklı parmaklara takılmış, çeşitli sayıda yüzük kullanımının yanı sıra kopuk parmak yani uzuv kaybı gibi sıra dışı durumlar içeren görüntülere de sahiptir.

Technocampus Hand Images Veri Seti: Technocampus Hand Images veri seti, 100 denekten alınan 6000 görüntüden oluşur (Faundez-Zanuy ve diğ., 2014). Bu multispektral bir veri setidir ve görünür, yakın kızılötesi ve termal olmak üzere 3 tip görüntü içerir. Her kategori 100 deneğin ellerinin el sırtının ve el içlerinin her biri için alınan 10 farklı örnekten oluşmaktadır.

3.2 Yöntem

3.2.1 Sentetik veri seti oluşturma

Çok sayıda kullanıcı ve o kullanıcılara ait görüntüler içeren bir veri seti oluşturmak, verilerin gizliliği ve korunumu konusunda gönüllülerin yaşadığı endişe nedeniyle zor olduğundan, halka açık parmak damarı veri setlerinin en kapsamlı olanı, 100 kişiye ait 6 farklı parmaktan onar örnek alınarak toplanmış 6000 adet görüntüden oluşmaktadır (Lu ve diğ., 2013). Derin öğrenme uygulamaları için duyulan ihtiyaç göz önünde bulundurulup, sentetik veri üretme fikri ile Matlab kullanılarak Hong Kong Polytechnic Üniversitesi tarafından geliştirilen Şekil 3.1'deki arayüz, parmak damarını ve parmak yapısını taklit eden bir görüntü oluşturur (Hillerström ve Kumar, 2014). Bu esnada sınıf içi ve sınıflar arası çeşitlilik sağlanarak biyometrik tanıma uygulamalarında kullanılacak nitelikte görüntüler yaratılmış olur. Parmak izi, iris ve avuç içi izi için çok sayıda görüntü ve kullanıcı içeren veri setlerine dair ihtiyaç literatürde karşılanmışken, parmak damarı için halen karşılanmamış olması şaşırtıcıdır.



Şekil 3.1: Arayüz ile oluşturulan parmak damarının anlık görüntüleri.

Damar üretimi gerçeğe uygun bir biçimde, bir merkezden başlayıp doğal damar örüntüsünün sergilediği bir anlayışla sentezlenmiştir (Hillerström ve Kumar, 2014). Damar anatomisinin analizi sonrası belirlenen formülasyona göre oluşturulan görüntülerde kök-damar düğümlerinin belirlenmesi sonrası, bu düğümleri dallandırıp büyüten ve her parmak için kalınlaştıran bir mantık söz konusudur. Kalınlık ayarının ardından görüntüye yakın kızılötesi ışığa ait özelliklerin eklenmesi sonrası nihai görüntü oluşur. Parmak kemiğinin modellenmesi sonrası parmak eklem noktalarının ve arasındaki bölgelerin karakteristiğinin görüntüye eklenmesi ile aslına uygun bir üretim gerçekleştirilmiş olur. Sunulan kullanıcı arayüzü ile parmak damarı görüntüsünün oluşumunu etkileyen parametreler görselleştirilip, bunları kullanarak damar görüntüsü üretme imkanı araştırmacılara verilmiştir. Oluşturulan parmak damarı görüntülerinin etkilendiği parametrelerden kişinin falanjiyal (phalangeal) çizgilerinin milimetre cinsinden uzunluğu, parmak uzunluğu, ortalama ana damar uzunluğu, deri kalınlığı, yakın kızılötesi ışığın saçılmasına bağlı optik parametreler ve kameraya dair iç parametreler gibi pek çok parametre, Şekil 3.2’de gösterildiği gibi kullanıcıya sunulmaktadır (Hillerström ve Kumar, 2014).

Sentetik veri üretmek yerine, veri artırımı yoluyla ya da GAN kullanarak hacimli veri setleri oluşturmak mümkündür. Ancak veri artırımı sırasında kullanılan çevirme (flipping) ve kesme (cropping) gibi bazı yöntemler sınıf içi ve sınıflar arası çeşitlilik oluşturma konusunda verimli sonuçlar sunmadığından tercih edilmez (Zhang ve diğ., 2019). Veri artırımı sonucu oluşan görüntüler ile orijinal görüntü arasında güçlü bir korelasyon söz konusudur (Hu ve diğ., 2018). Kural tabanlı kullandığımız ve deterministik bir yapıda olan bu Matlab tabanlı arayüz, her ne kadar azımsanmayacak sayıda parametre seçeneğine sahip olsa da yine de kısıtlı sayıda görüntü işleme imkanına sahiptir. GAN ise, kural tabanlı üretimlere göre daha olasılıksal bir dağılım sergilediğinden gerçek görüntüye daha çok benzeyen veriler üretme şansına sahiptir (Yang ve diğ., 2020).

GUIDatabaseGeneration

Synthetic Finger-Vein Image Database Generator
Department of Computing
The Hong Kong Polytechnic University

General Parameters

Number of subjects: 1000
Number images for every subject: 10
Database location:
 Generate database

Finger Dimensions

	Mean	Deviation
Finger width (mm)	20	
Proximal phalanx length (mm)	39.78	4.94
Middle phalanx length (mm)	22.38	2.51
Distal phalanx length (mm)	19.66	2.85

Vein Grow Parameters

	min	max
Stepsize	2	
Killing distance	1	2
Birth distance proximal phalanx	4	7
Birth distance middle phalanx	4	6
Birth distance top phalanx	4	5
Birth distance edges	2	5
Birth distance starting points	3	10
Density sources top phalanx 1/	130	200
Less density middle phalanx	5	10
Less density proximal phalanx	10	20
# stable sources proximal phalanx	3	5
# stable sources middle phalanx	3	5
# stable sources top phalanx	2	3
# stable sources edges	2	3
# starting points	2	3
# sample points main veins	4	8
Distance main vein from edge	1.5	5.5
Var dist main veins from edge	1	2
Change new sources	0.3	0.5
Distance source from main veins	3	

Pattern Parameters

Generating image of different subjects

	Min	Max
Scale	10	
Offset	10	
Dilate width	15	
THBasic	7.5	9.4
THInc	0.006	0.01
THDec	0.001	0.002
Minimal thickness of a vessel	0.5	

Generating images same subjects

	Min	Max
VarTHBasic	0	2
VarTHInc	0	0.006
VarTHDec	0	0.0005

Illumination Parameters

Generating image of different subjects

	Min	Max
Orientation Gabor filter	0.62832	2.5133
Basic depth of vessels	7	15
Minimal depth of tissues	3	5
Skin thickness	1.5	3.5
Bone less value	0.02	0.15
Distance finger and camera (mm)	4	6

Generating images same subjects

	Min	Max
Dilation width for joints	8	10
Variation in orientation Gabor filter	-0.1	0.1
Variation in density map	0.99	1.01
Variation in vessel depth	-3	3
Variation in minimal depth of tissues	-0.25	0.25
Variation distance finger and camera	-0.5	0.5

Şekil 3.2: Parmak damarı sentezlemeyi sağlayan parametrik arayüz.

3.2.2 Evrişimsel sinir ağları

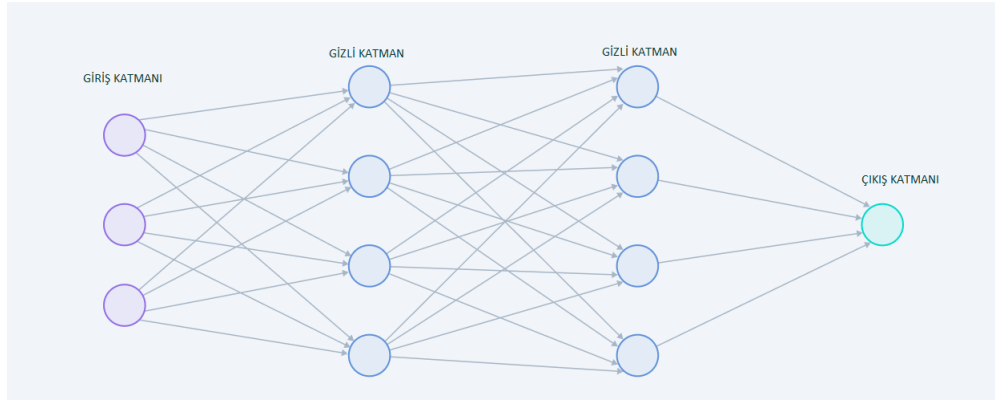
Geleneksel yöntemlerin ulaştığı performans sınırı ve bu sınırı zorlamanın tek yolu olan geleneksel yöntemlere ait en uygun parametrelerin belirlenip kullanılan veri setine özel çözüm üretme mecburiyeti göz önünde bulundurulduğunda, görüntü işleme problemlerinin çözümünde geleneksel yöntemlerin yerini hızla ESA almaktadır. ESA özellik çıkarımı, seçimi ve sınıflandırması için kompakt bir yapı sunmaktadır.



Şekil 3.3: Makine öğrenmesi ve derin öğrenme arasındaki ilişki.

Şekil 3.3'te gösterildiği gibi makine öğrenmesinin bir alt kümesi olan derin öğrenme, görüntü işleme alanında birçok probleme etkin çözümler getirmektedir (Abdul Kadir ve diğ, 2022). Evrişimsel sinir ağlarını temel alarak geliştirilen mimariler aracılığıyla


başta biyomedikal görüntüleme, uzaktan algılama ve robotik gibi alanlar olmak üzere çeşitli alanlarda çözümler sunan derin öğrenmenin altında yatan temel mantık Artificial Neural Networks (ANNs) olarak bilinen Yapay Sinir Ağları'dır (Widrow ve Hoff, 1960). İnsan vücudundaki sinir hücrelerini aldığı, taşıdığı ve işlediği sinyal açısından taklit eden yapay sinir ağlarını temsil eden örnek bir yapı Şekil 3.4'te gösterilmiştir. Giriş katmanı, 2 gizli katman ve çıkış katmanına sahip bu yapay sinir ağı, girişte aldığı sinyali çıkış sinyaline dönüştürürken başta katmanlardaki düğüm (node) sayıları ve ağıdaki gizli katman sayısı olmak üzere pek çok parametreden etkilenir. Giriş katmanında bulunan düğümlerden çıkışa en çok etki etmesi beklenen düğüme en fazla ağırlığın verilmesi ile modellenen yapay sinir ağı, dışarıdan herhangi bir müdahaleye ihtiyaç duymadan kendi kendine öğrenerek belirlenmiş amaca yani hedeflenen çıkış değerine ulaşabilir. Giriş sinyalinin ve ulaşmayı hedeflediği çıkış değerinin önceden bilindiği bu modelde, giriş sinyalinin ağıda işlenip ulaştığı anlık çıkış değerlerinin hedeflenen çıkış değerine olan uzaklığı hesaplanıp ağıdaki ağırlıkların güncellenmesini esas alan bu yapı, gizli katmanların yardımıyla en karmaşık problemlere bile çözüm üretmekte mahirdir. Yapay sinir ağlarının temel görevi, üzerinde çalışılan veri setinin yapısını öğrenmek ve bu veri seti üzerinde geliştirme yeteneği kazanmaktır. Bu sebeple, eğitim verisi üzerinde yapılan çalışmalar katmanlarda bulunan düğümlere atanacak ağırlıkları belirlemek önemlidir. İlk atanan ağırlıklar sonrası yapılan her yeni gözlemlerle güncellenen ağırlıklar, giriş değerlerini hedeflenen çıkış değerine ulaştırma konusunda yaptığı tahmini en az hataya sebep olacak şekilde günceller ve zamanla daha isabetli tahminler üretip hedeflenen çıkış değerinden daha az sapan sonuçlar üretir. Yapay sinir ağlarının herhangi bir problem karşısında üreteceği çözüm başta da dile getirildiği gibi katman sayısı, düğüm sayısı, verilen ağırlıklar gibi mühendislik gerektiren kararlarla yakından ilişkilidir ancak bu parametrelere verilecek değerler için belirlenen bir formül olmadığından deneme yanılma yoluyla test ederek karar verilmelidir.



Şekil 3.4: Basit bir yapay sinir ağı örneği.

Basit bir ağ ile derin bir ağ arasındaki farkı yaratan yine bu bahsi geçen parametrelerin sayısıdır. Katmanlardaki düğüm sayısı ve üçten fazla gizli katman içermesi, tasarlanan yapıyı derin olarak nitelendirmemize sebep olur. Karşılaşılan karmaşık problemlerin çözümünde ihtiyaç duyulan derin ağların bilgisayarlar kullanılarak gerçekleştirilmesi, bilgisayar teknolojisinde meydana gelen hızlı ve süregelen gelişmeler sayesinde mümkün olmuştur. Özellikle bilgisayarların grafik işlemci birimlerindeki teknolojik gelişmeler, görüntü işleme gibi matris formundaki

yapay sinir ağı modellerinin gerçekleşmesinde arařtırmacıların önündeki engelleri kaldırmıřtır. ESA ile bilgisayarlı görü problemleri karřısında sinir ađlarının sunduđu olanaklardan faydalanan derin öğrenme, bu esnada 4 çeřit katmandan faydalanır (Bilal ve diđ, 2021). Genel olarak evriřim katmanı (convolution layer), ortaklama katmanı (pooling layer), aktivasyon katmanı (activation layer) ve tam bađlantılı katman (fully connected layer) olmak üzere 4 katmanın deđiřen sayı ve sırada bir araya getirilmesiyle oluřan ESA, Őekil 3.5'te gösterilen parmak damarı görüntüsünün girdi olarak kullanıldıđı ardıřık evriřim ve ortaklama katmanlarına sahip model sayesinde görüntüdeki damarları herhangi bir görüntü iřleme algoritmasına ya da geleneksel yöntemle ihtiyaç duymadan teřhis edebilir ya da belirginleřtirebilir (Chai ve diđ, 2022b). Bu Őekilde gösterilen katmanlar özellik çıkarma (feature extraction) amacını güdüp giriř resminden anlam çıkarmakla görevlidir.

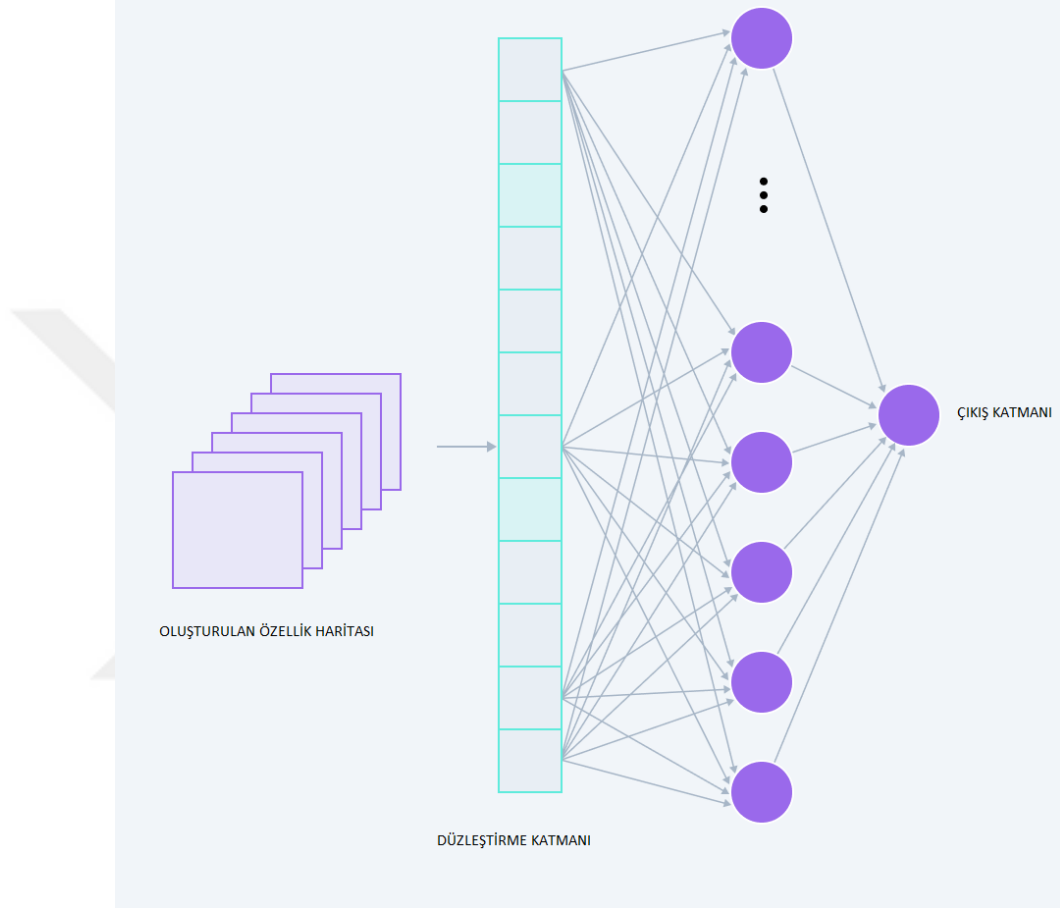


Őekil 3.5: Basit bir ESA'ya ait özellik çıkarma katmanları.

Őekil 3.5'teki son ortaklama katmanı sonrası oluřan özellik haritasının (feature map) Őekil 3.6'daki gibi olduđu düşünülüp ađın kaldıđı yerdan devam ettiđi varsayıldıđında, bu özellik haritasının resmin içeriđi hakkında bilgi sahibi olmamızı sađlayacak bilgiler içerdiđi bilinmelidir (LeCun ve diđ, 1998). Eđitim sırasında modele sunulan diđer damar görüntülerinin ve o görüntülerin bir damara ait olduđu bilgisinin bir etiket (label) ile modele verildiđi ESA'da, eđitim sırasında oluřan ađırlıkların görüntüyü anlamlandırmaya başlaması sonucu modele verilen her yeni test amaçlı damar görüntüsünü sınıflandırmak, Őekil 3.6'daki düzleřtirme katmanı (flattering layer) sayesinde mümkündür. Bu katman sonrası Tam Bađlantılı Katman, girdi olarak alınan damar görüntüsünün kime ait olup olmadıđı bilgisini, ađa verilen sınıf bilgileri arasından en yüksek olasılıđa sahip sınıfa ait bir etiket olarak bize çıkıř katmanında (output layer) sunar. Geleneksel yöntemlerin aksine özellik ya da öznitelik çıkarmak yerine öznitelik öğrenme yoluna giden derin öğrenme yöntemleri sayesinde ESA'lar, hızlı ve adaptif sonuçlar vadetmektedir (Sidiropoulos ve diđ, 2021).

Giriř katmanında verilen bir görüntünün genelde ilk maruz kaldıđı operasyon evriřim katmanı aracılıđıyla uygulanır. Temel amacı görüntüden öznitelik çıkarmak olan bu katman, matris formuyla temsil edilebilen görüntülere ait piksel deđerlerinden görüntü içeriđine dair anlam çıkarmamıza yardımcı olur. Çođunlukla evriřim katmanından hemen sonra uygulanan ve ađa dođrusal olmayan özellikler kazandırıp genelleřtirme yeteneđini pekiřtiren aktivasyon katmanı, sahip olduđu fonksiyon çeřitleri ile hızlı ve dođru öğrenmenin anahtarı konumundadır. Evriřim katmanı sonrası belirli aralıklarla uygulanan bir diđer temel katman ise ortaklama katmanıdır. Oluřturulan modeldeki

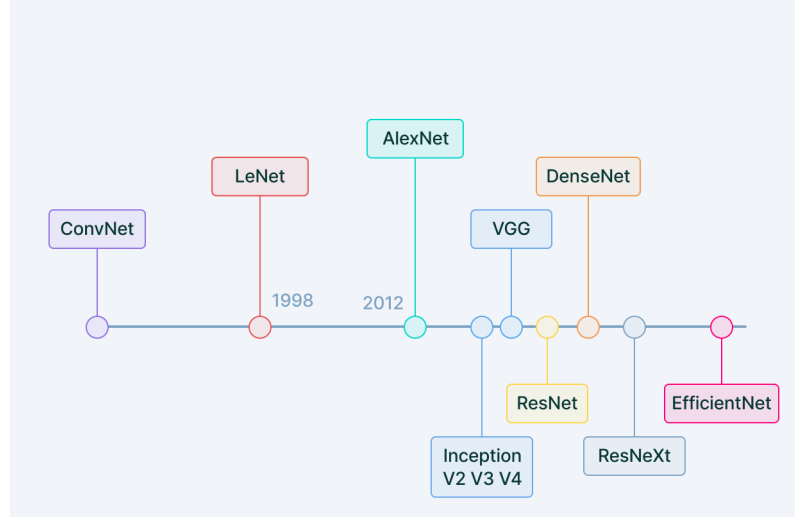
parametre sayısını azaltıp istenilen amaca ulaşırken iş gücünden tasarruf sağlayıp işlem yükünü azaltma görevi gören bu katman, aynı zamanda azalan boyuta rağmen görüntü içerisinde saklanan bilginin ve o bilginin sahip olduğu girift ilişkinin korunmasında görevlidir. Düzenli olmasa da belirli aralıklarla tekrar eden bu iki katmanın kullanımı sonrası neredeyse tüm sinir ağlarında bulunan ve çıkış katmanının boyutunu belirleyen tam bağlantılı katman, karşılaşılan problemde ihtiyaç duyulan sınıf sayısına göre belirlenen bir yapıdadır.



Şekil 3.6: Basit bir ESA'ya ait sınıflandırma katmanları.

3.2.3 Evrimsel sinir ağı mimarileri

Evrimsel sinir ağlarını oluşturan katmanların sayı ve sıralarının ihtiyaca göre şekillendiği ve kullanılan derin öğrenme modellerinin bu şekilde oluşturulduğu gerçeği ortada iken, 1000 sınıftan oluşan yaklaşık 1.2 milyon görüntüyü başarıyla sınıflandırma amacı güden bir yarışma sırasında tasarlanan AlexNet mimarisi bu alanda oluşturulmuş namzet mimarilerdendir (Krizhevsky ve diğ, 2017). Öncesinde el yazısı içeren dokümanlardaki sayıları tanıma amacı güden LeNet mimarisi ile başlayan mimari önerme süreci sonraki yıllarda Şekil 3.7'de gösterildiği gibi hız kesmeden devam etmiştir. 2012 yılında önerilen AlexNet 5 evrim katmanından oluşmuştur ve 3x3'ten başlayarak 11x11'e kadar değişen boyutlarda filtrelere sahiptir. 3x3 boyutlu maksimum ortaklaşmanın (max pooling) kullanıldığı AlexNet, yığın normalleştirme ve seyreltme mekanizmalarına da bünyesinde yer vermiştir.



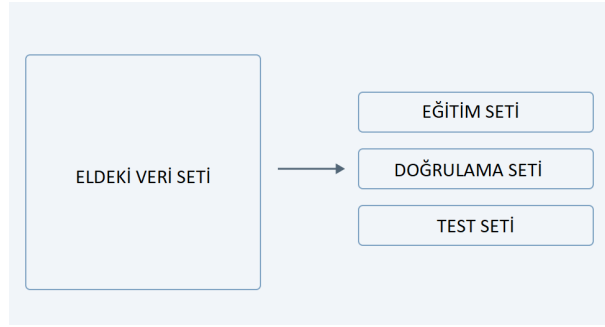
Şekil 3.7: ESA mimarilerinden bazıları.

Daha sonraları VGG16 ve VGG19 ile devam eden mimari önerileri, ESA tasarımının çıkarılan bilgiler açısından bilgisayarlı görü problemleri için önemini göstermektedir. 2014 yılında önerilen VGG16 ESA modeli, içerdiği 13 evrişim katmanı ve 3 tam bağlantılı katman sebebiyle bu ismi almıştır (Simonyan ve Zisserman, 2014). 3x3 boyutlu filtreler ile ReLU aktivasyon fonksiyonunun kullanıldığı bu modelde, ortaklama yöntemi olarak maksimum ortaklama kullanılmıştır ve adım sayısı (stride) 2 olarak alınmıştır. VGG16'ya benzer sebeple, VGG19 da içerdiği evrişim katmanı ve tam bağlantılı katman sayısı toplamı 19 olduğu için bu ismi almıştır. Bu iki yapı, basit sınıflandırma problemlerinde kullanıcılarına etkin çözümler üretmektedir. ResNet mimarisi ise AlexNet, VGG16 ve VGG19 gibi mimarilerden farklı bir yapıdadır. Sahip olduğu artık blok yapısı ile katmanlar arası bilgi aktarımına olanak sağlayan ResNet, 2015 yılında ortaya konulmuş olup 152 katmanlı bir evrişimsel model ile etkin bir öğrenmeye imza atmıştır (He ve diğ., 2016). ResNet'i alışageldiğimiz mimarilerden ayıran özellik, doğrusal ve ReLU aktivasyon katmanları arasındaki artık değerlerin sonraki katmanları beslemesi ve bunun öğrenmeyi pekiştirebilmesidir. Her artık blokta bulunan 2 adet 3x3'lük evrişim filtresi ve 2 olan adım sayısı ile ResNet, atlama bağlantıları aracılığıyla etkin bir performans sağlamaktadır. Son olarak DenseNet mimarisi evrişim ve ortaklama esnasında yitirilen veya katmanlar arasında kaybedilen bilgilerin korunması amacıyla önerilmiştir (Huang ve diğ., 2017). Bunu yapabilmek adına her bir katmanı ileriye doğru diğer katmanlara bağlama amacı güden DenseNet, her katmanın kendisinden önce gelen tüm katmanlardan faydalanabilmesini amaç edinmiştir. Bu sayede özellik haritasında, katmanlar arasında yitip giden özellikler belirli oranda korunmuştur. DenseNet'in sağladığı bir diğer özellik ise katmanlar arası geçişlerde parametre sayısını azaltmasıdır. Literatürün olgunlaşması sonrası üretilen yeni aktivasyon fonksiyonlarının da etkin olarak kullanıldığı bu mimari, katmanlar arası etkileşimi sağlama adına iyi bir örnektir. Diğer popüler ağlara kıyasla, ResNet ve DenseNet güçlü derin öğrenme ağlarıdır. ResNet, yapısındaki bağlantılar sayesinde, ağınc önceki katmanlarında daha az bilgi kaybı yaşanmasına sebep olur. DenseNet ise sahip olduğu bağlantılarla, her katmanın tüm önceki katmanlarla bağlantılı olmasını sağlar. Bu, ağınc bilgi kaybını azaltır. Bu nedenlerle ResNet ve DenseNet, güçlü tanıma performansları elde etmek için önemli mimarilerdir. Bu ve bunlar gibi literatürde sıkça kullanılan bazı ESA mimarileri Çizelge 3.1'de verilmiştir.

Çizelge 3.1: Bazı ESA mimarilerine dair bilgiler.

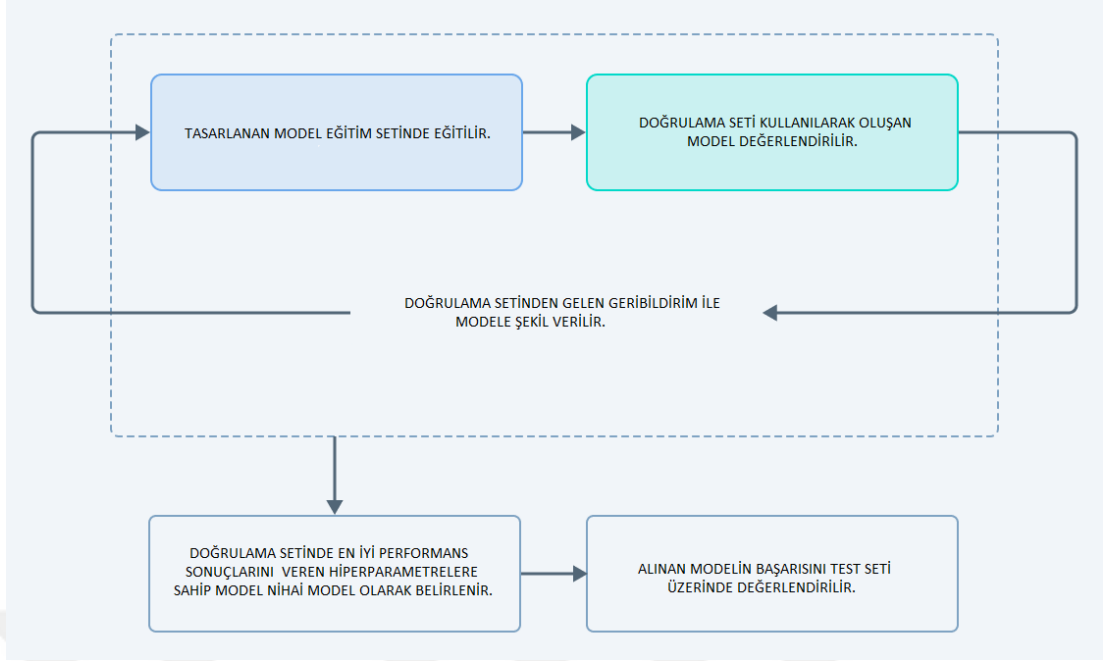
Mimari	Derinlik	Parametre Sayısı	Giriş Boyutu
AlexNet	8	61×10^6	227 x 227
VGG16	16	138×10^6	224 x 224
VGG19	19	144×10^6	224 x 224
GoogleNet	22	7×10^6	224 x 224
Inceptionv3	48	23.9×10^6	299 x 299
ResNet50	50	25.6×10^6	224 x 224
DenseNet201	201	77×10^6	224 x 224

Ünlü ESA mimarilerini kullanarak ya da deneme yanılma yoluyla ancak belirli kriterler ışığında tasarlanan herhangi bir ESA modelinin göstereceği performansı ölçmek için probleme konu olan görüntü veri seti, Şekil 3.8’de gösterildiği gibi eğitim seti, doğrulama seti ve test seti olmak üzere üçe ayrılır. Bu 3 sete ait oranlara karar vermek tamamen modeli eğiten kişinin uhdesindedir. Test, eğitim ve doğrulama setlerinin oranlarına karar verirken dikkate alınması gereken en önemli husus, kullanılan veri setindeki sınıf sayısı ve sınıf içi örnek sayısıdır. Eğer yeterince veri içeren bir sete sahip bir problem ise eğitim setine, doğrulama ve test setlerine oranla yüksek oranda veri ayırmaya gerek yoktur. Ancak hal böyle değilse, yani probleme konu olan veri seti az sayıda veri içeriyorsa genelde eğitim, doğrulama ve test seti oranları yüzdesel olarak sırasıyla 80-10-10 ya da 70-20-10 şeklinde belirlenmektedir.



Şekil 3.8: Veri setlerinin performans analizi için ayrıştığı alt kümeleri.

Herhangi bir ESA modeline ait performans değerlendirmesine ait akış diyagramı Şekil 3.9’da gösterilmiştir. Kullanılan veri setini eğitim, doğrulama ve test olarak birbirine karışmayan yani ayrık 3 kümeyle ayırmamızın ardından, tasarlanan model eğitim setindeki verilerle eğitilir. Eğitim sonrası belirli özellikleri belirlenip şekil almaya başlayan model doğrulama verileriyle sınanır. Bu veri setinde gösterilen performans göz önünde bulundurularak modelin sahip olacağı optimum hiperparametrelere karar verilir. Bu hiperparametrelerden bazıları döngü (epoch) sayısı, öğrenme oranı (learning rate) ve yığın boyutu (batch size)’dur (Das ve diğ., 2018). Son olarak, aşırı uyum ya da öğrenme problemi yaşaması engellenen modelin performansı, daha önce eğitim ve doğrulama aşamasında kullanılmayıp ayrı tutulmuş test verileri üzerinden sınanıp belirlenir.

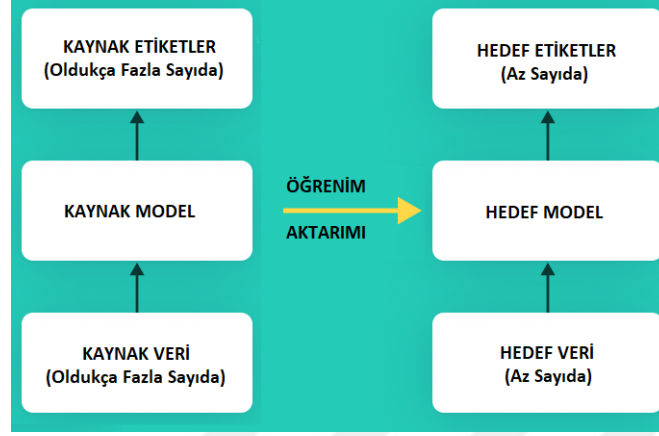


Şekil 3.9: ESA model performans değerlendirmesine ait akış diyagramı.

3.2.4 Öğrenim aktarımı

Ünlü mimarileri kullanmak ya da belirli bir alan için yeni bir ESA modeli geliştirmek oldukça zordur. Tasarlanan modelin derinleşmesi, hesaplama gücü açısından eldeki donanımsal kaynakları zorlarken veri kısıtlılığında kaynaklanan yetersizlik, tıpkı geleneksel yöntemlerde olduğu gibi elde edilen performansın belirli seviyeyi aşamamasına sebep olur. Eğitim verisi bulmanın zor olduğu ya da eldeki donanımın işlemci açısından yetersiz oluşu düşünüldüğünde, önceden eğitilmiş bir modeli kullanıp onun özelliklerini transfer etmek oldukça iyi bir seçenektir (Kuzu ve diğ., 2020b). Herhangi bir alan için önceden eğitilmiş olup belirli sınıflara ait görüntülerin sınıflandırılmasında rol alan bir modele ait belirli kısımların, bir özellik haritası olarak aktarımı olarak tanımlanabilen öğrenim aktarımı belirli esaslara dayanır. Literatürde yer alan ve herkeşçe bilinen sınıflandırma problemlerine çözüm aranan yarışmalarda önerilen ünlü ESA modellerinin ImageNet gibi büyük çaplı veri setleri kullanılarak eğitilmesi sonucu elde edilen özellik haritalarının, başka problemlerin çözümü için transfer edilip kullanılması için ilk adım, bu özellik haritasının indirilip oluşturulacak yeni modele yüklenmesidir. Yüklenen bu kaynak model öğrenim aktarımını gerçekleştirirken şekil, renk ve kenar gibi basit özelliklerin aktarılmasına yönelik katkıda bulunur. Düşük seviyede özellikleri çıkaran bu katmanlar, oluşturulan modele eklenirken eski modele ait olan ve kullanılan modelin kullanım alanına yönelik spesifik özelliklerin çıkarılmasına katkı sağlamayacak katmanlar ise transfer edilen özellik haritasına dahil değildir. Kaynak modele dair spesifik özellikleri içermesi muhtemel bu katmanlar, yeni oluşturulan modelden elde edilecek performansı düşürmeme adına transfer edilmemektedir. Böylelikle önceden eğitilmiş kaynak modelin son katmanları atılmış olur. Atılan bu katmanlar yerine yeni modelin spesifik ihtiyaçlarına yönelik yeni katmanlar eklenir. Oluşturulan yeni model, eğitim verisi ve gerekli hiperparametre seçimleriyle eğitilince ortaya yepyeni bir model çıkar. Eğitilen bu model, test setinde sınanarak sistemin sahip olacağı performansı öğrenim aktarımı

ile Şekil 3.10'da özetlendiği şekilde belirler. Öğrenim aktarımı, burada belirtildiği gibi bir modeli önceden eğitilmiş bir modelin ağırlıklarını kullanarak yeniden eğitmek için kullanılır. Bu yöntem, yeni bir veri kümesiyle modeli eğitirken, önceden eğitilmiş modelin ağırlıklarını kullanır. Ağırlıklar, genellikle paylaşımına açık olarak mevcuttur.

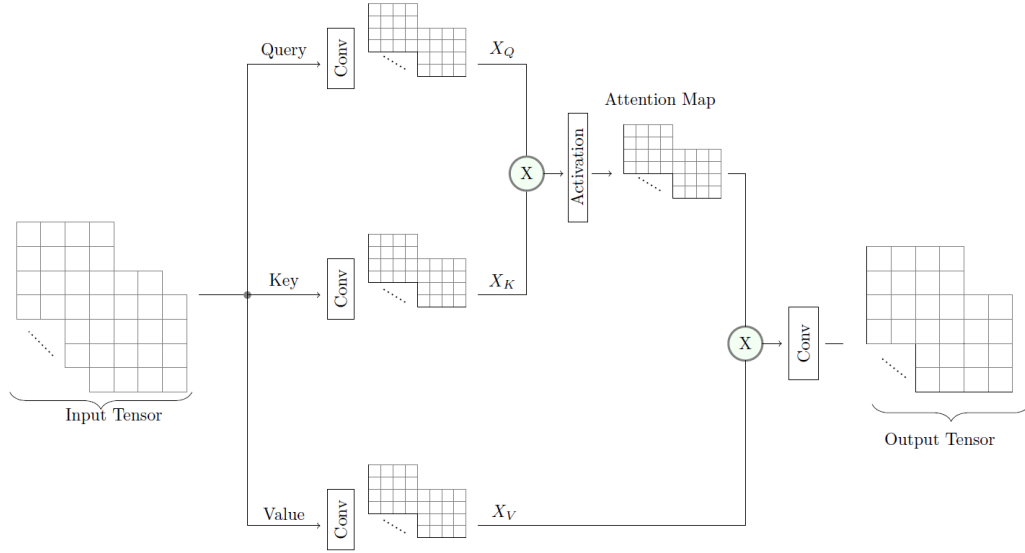


Şekil 3.10: Öğrenim aktarımındaki temel işleyiş.

3.2.5 Öz dikkat mekanizması

Öz dikkat mekanizması (Self-attention mechanism) ve ESA'lar, görüntü tanıma uygulamalarında etkili olan modellerdir. Öz dikkat, bir veri setinde her bir ögenin diğerlerine olan etkisini hesaplamaya yarayan bir mekanizmadır ve ESA'larla birlikte kullanıldığında, görüntülerin işlenmesinde daha iyi bir performans sağlayabilir (Zhao ve diğ, 2020b). Bilindiği üzere ESA'lar, görüntülerin özelliklerini bulmak için kullanılan yapılardır ve girdi görüntülerini bir dizi filtreler kullanarak evrişim katmanları ile işlerler. Filtreler, görüntülerin özelliklerini bulmak için hareket eder ve filtrelerin çıktısı, görüntünün özelliklerini bulup gösterir. Öz dikkat ise, girdi verileri arasındaki bağlantıları hesaplamaya yarar ve veri setinde her bir ögenin diğerlerine olan etkisini gösterir. Görüntü üzerinden düşünülürse piksellerin birbiriyle olan uzamsal ilişkileri komşuluk aramaksızın Öz dikkat mekanizması tarafından bulunup belirlenebilir. Alışlagelen evrişimsel katmanlar yerine 1x1 evrişim kullanarak uzamsal ilişkiler yerine görüntü kanalları arasındaki ilişkilere odaklanılır. Öz dikkat ve ESA'lar bir arada kullanıldığında sorgu (query), anahtar (key) ve değer (value) değerleri bir görüntüyü daha iyi tanımak için kullanılabilir (Zhao ve diğ, 2020b). Sorgu, girdi görüntüsünde aranan özelliği belirtir. Anahtar, girdi görüntüsünde aranan özelliği bulmaya yardımcı olan özelliği belirtir. Değer ise, anahtar ile eşleşen özelliği gösterir. Bu değerler, Öz dikkat mekanizmasını kullanarak girdi görüntüsünde aranan özellikleri bulmaya yardımcı olur ve böylece görüntü tanıma uygulamalarında daha iyi bir performans sağlanabilir.

Şekil 3.11'de "Input Tensor" olarak gösterilen giriş görüntüsüne ait yapı, Query, Key ve Value değerlerine 1x1 evrişim kullanımıyla ayrıştırılır. Bu ayrışma, giriş verisinin Query ve Key kavramları kullanılarak kodlanmasını (encoding) sağlar. Bir önceki aşamada oluşturulan kodun (encoded structure), Value kavramına sıkıştırılması sonucu kod çözümü (decoding) gerçekleşir. Bu işlem, Şekil 3.11'de gösterilen matrisel çarpımlar ve noktasal toplama (point-wise addition) yoluyla gerçekleşir. Bu sayede




Şekil 3.11: Önerilen modeldeki Öz dikkat mekanizması bloğu.

giriş görüntüsü bu 3 kavramla ilişkilendirilmiş olur (Zhao ve diğ., 2020b). Bu ilişkilendirme işlemi kullanılan kavramların piksel bazlı etkisini ağırlıklı ortalama olarak çıkışa yansıtır. Her bir Value değerine atanan ağırlık değeri, Query ile tüm Key değerlerinin noktasal çarpımı (dot product) vasıtasıyla bulunur. Daha yalın bir ifadeyle açıklamak gerekirse Key, Query ve Value değerleri, giriş görüntüsündeki (i,j) piksel konumundaki özelliklerin ve komşuluğundaki piksellerin lineer dönüşümü ile hesaplanan değerlerdir. Burada, komşulukta bulunan piksellerin tercih edilme sebebi sisteme hesaplama açısından ağır yük bindirmemek içindir. Yani tüm pikseller arası ilişkiyi ele alan bir yapı yerine komşulukla yetinen yerel bir dikkat mekanizması tercih edilmiştir. O halde, üzerinde dolaşılacak anlık (current) piksel Query, ona ait komşuluklar Key ise bunların noktasal çarpımının Şekil 3.11’de gösterildiği gibi aktivasyon fonksiyonuna tabi tutulması sonucu, dikkat mekanizmasını sahip olduğu ağırlıklar elde edilir. Aktivasyon fonksiyonu bu ağırlıkları normalize eder. Kullanılan bu 3 kavram ile girişteki yapı, yerini pikseller arası saklı olan ilişkinin yakalandığı bir projeksiyon matrisine bırakır.

3.2.6 Doğrulama uygulamalarında özellik vektörlerinin kullanılması

Öklid mesafesi (Euclidean distance) başta olmak üzere mesafe metriklerinin kullanımı, görüntü veya özellik eşleştirmek için sıkça başvurulan stratejiler arasındadır ve oldukça yaygındır. Bir eşik değeri belirleyip bu eşik, sorgulanan görüntü ile veri setindeki diğer tüm görüntüler arasındaki mesafeyi hesaplamak için kullanarak gerçek eşleşme ve sahtekar eşleşme dağılımlarını hesaplamak mümkündür. Bu eşleşme stratejisini görselleştirmek adına Şekil 3.12’de gösterilen A ve B noktalarının arasındaki d mesafesi, aradaki θ açısı, A ve B noktalarına ait koordinat değerleri olan (x_1, y_1) ve (x_2, y_2) değerlerini kullanarak görüntüleri birbiriyle kıyaslamak için kullanılacak mesafe metrikleri tanımlanabilir. Koordinat sisteminde 2 noktaya tekabül eden A ve B noktaları arasındaki uzaklığı hesaplamak için farklı stratejiler izleyen bu metrikler sırasıyla Manhattan mesafesi (Manhattan distance), Öklid mesafesi, Kosinüs mesafesi (Cosine distance) ve Minkowski mesafesi (Minkowski distance) şeklinde sıralanabilir (Kavitha ve diğ., 2019):



Şekil 3.12: Aralarında d uzaklığı bulunan A ve B noktaları.

Manhattan Mesafesi : Manhattan mesafesi, Denklem 3.2.1’de gösterildiği gibi, orijine göre Şekil 3.12’deki A ve B noktalarının oluşturduğu iki vektörün mutlak olarak farklarının toplamıdır.

$$d = |x_1 - x_2| + |y_1 - y_2| \quad (3.2.1)$$

Öklid Mesafesi : Pisagor Teoremi’ni kullanarak iki nokta arasındaki mesafeyi hesaplayan metriktir. Buna göre Öklid mesafesi, Denklem 3.2.2’de gösterildiği gibi, Şekil 3.12’de gösterilen iki noktanın x ve y koordinatlarının ayrı ayrı farklarının hipotenüsüne eşittir.

$$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (3.2.2)$$

Kosinüs Benzerliği (Cosine Similarity) :

Şekil 3.12’de gösterilen iki noktanın arasındaki açıyı kullanarak tanımlanır ve bu tanım, Denklem 3.2.3’te gösterilmiştir. Kosinüs benzerliği, iki vektörün aynı yönü gösterip göstermediğini belirler ve Kosinüs mesafesinin tanımlanmasında kullanılır.

$$\text{Cosine Similarity} = \frac{(\sqrt{(x_1 + y_1)^2} * \sqrt{(x_2 + y_2)^2}) * \text{Cos}(\theta)}{(\sqrt{(x_1 + y_1)^2} * \sqrt{(x_2 + y_2)^2})} \quad (3.2.3)$$

Kosinüs Mesafesi : Kosinüs mesafesi Denklem 3.2.4’te gösterildiği gibi Kosinüs benzerliğinden faydalanarak hesaplanır. Bu iki değerden biri artarsa, diğeri tanım gereği azalır.

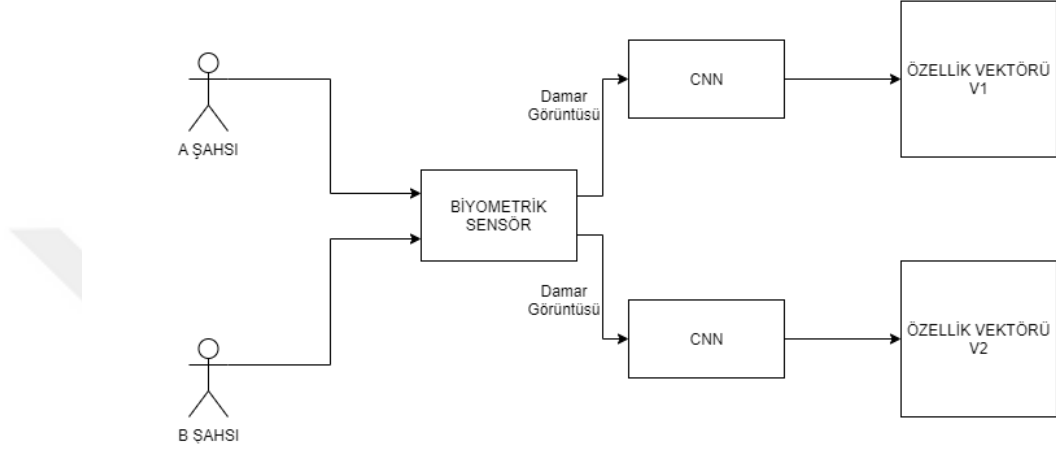
$$d = 1 - \text{Cosine Similarity} \quad (3.2.4)$$

Minkowski Mesafesi : Minkowski mesafesi, Öklid mesafesi ve Manhattan mesafesinin genelleştirilmesiyle oluşturulur. Denklem 3.2.5’teki q parametresine göre işlemler yapılır. Eğer q=1 ise, Minkowski mesafesi, Manhattan mesafesine eşit olur. q=2 olduğunda ise, Minkowski mesafesi, Öklid mesafesine eşit olur. Burada q değeri daha büyük değerler alabilir.

$$d = \sqrt[q]{(x_1 - x_2)^q + (y_1 - y_2)^q} \quad (3.2.5)$$

Bilindiği gibi bir ESA yani CNN modeli, resimlerin sınıflandırılmasında kullanılabilir. Bu model, giriş verileri olarak resimleri alır ve bu resimlerden öznitelikler, Şekil 3.13’teki gibi çıkartılır (Meng ve diğ, 2017). Bu öznitelikler, resimlerin özelliklerini ve özellikleri arasındaki ilişkiyi herhangi bir ön işleme ihtiyacı duymadan açıklar. Daha sonra, bu öznitelikler kullanılarak resimler sınıflandırılır. Bu sınıflandırma işlemi, iki resmin özniteliklerini karşılaştırarak Şekil 3.14’ teki gibi yapılır (Meng ve diğ, 2017). A şahsına ait bir damar görüntüsü ile B şahsına ait bir damar görüntüsünün biyometrik sensör yardımıyla elde edilmesinden sonra bu görüntülerin ESA modelinden geçirilip özellik vektörleri, V1 ve V2 şeklinde oluşturulur. Bu resimleri karşılaştırmak için,

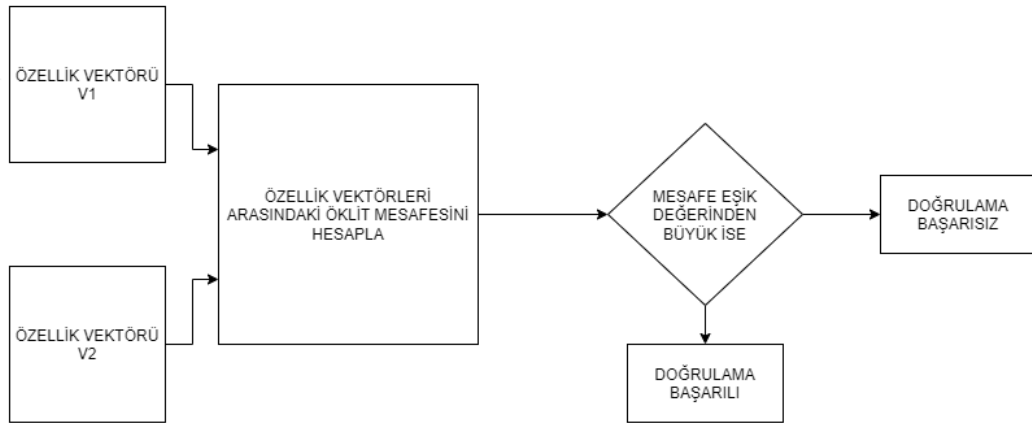
V1 ve V2 öznitelik vektörleri arasındaki mesafe hesaplanır. Başta Öklid mesafesi olmak üzere, tüm tanımlanan metrikler iki vektör arasındaki mesafeyi ölçmek için kullanılabilir. Bu mesafe, genellikle iki vektör arasındaki benzerlik veya farklılığı ölçmek için kullanılır. Bu mesafeler kullanılarak iki resim arasındaki benzerlik derecesi ölçülür ve bu benzerlik derecesine göre iki resim kıyaslanır. Eğer iki resmin benzerlik derecesi yüksekse, bu resimler aynı kişiye ait olarak yani gerçek olarak kabul edilebilir. Eğer benzerlik derecesi düşükse, bu resimler farklı kişilere ait yani sahtekar olarak kabul edilebilir.



Şekil 3.13: İki resimden ESA kullanarak öznitelik vektörü çıkarımı.

Oluşturulan V1 ve V2 özellik vektörlerinin boyutuna göre Denklem 3.2.6'daki noktaların boyutunu temsil eden n değeri belirlenir (Yan ve diğ, 2019). Oluşan bu mesafe denklemi her ne kadar örnekte Öklid için tanımlandıysa da, diğer metrikler için de aynı kural geçerlidir.

$$\text{Vektörler Arası Mesafe} = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2} \quad (3.2.6)$$



Şekil 3.14: Öznitelik vektörlerinin doğrulama amaçlı karşılaştırılması.


2004 yılındaki FVC (Fingerprint Verification Competition) protokolü, bir parmak izi tanıma sisteminin performansını ölçmek için kullanılan bir standarttır (Maio ve diğ, 2004). Bu protokolde, bir parmak izi tanıma sistemi için genel olarak "genuine" yani gerçek ve "imposter" yani sahtekar örnekleri toplamak gerekir. Gerçek örnekler, kullanıcının kendi parmak izlerinden oluşur ve sistemin bu örnekleri gerçek olarak niteleyip tanınması beklenir. Sahtekar örnekler ise, farklı kullanıcılardan alınan parmak izlerinden oluşur ve sistemin bu örnekleri sahte olarak niteleyip tanınması beklenir (Hu ve diğ, 2018). FVC protokolüne göre, bir parmak izi tanıma sisteminde kullanılacak olan genuine ve imposter örneklerin sayısı, kullanıcı sayısı (n), kullanılan parmak sayısı (r) ve alınacak parmak izi örneklerinin sayısı (m) gibi faktörlerden etkilenir. Imposter örnekler, farklı kullanıcılardan alınan parmak izi örneklerinden oluşur. Bu örnekler arasında yapılacak olası karşılaştırmaların sayısı ise, Denklem 3.2.7'deki gibi hesaplanır (Schuiki ve diğ, 2022). Bu formül, n kullanıcı için (n-1) farklı kullanıcıdan oluşan imposter örneklerin sayısını verir ve bu örnekler arasında yapılacak olası karşılaştırmaların sayısını gösterir. Imposter örnekler için hesaplanan karşılaştırma sayısının yanı sıra genuine örnekler arası da karşılaştırmalar yapılmaktadır. Ancak bu sayı, imposter için yapılan karşılaştırmaya göre işlem yükü olarak çok daha zahmetsizdir. Bu protokolü, parmak izi yerine parmak damarı için de kullanmak mümkündür. Bu durumu sayısal olarak örneklendirmek gerekirse, bünyesinde 60 farklı gönüllü, bu gönüllülerin 6 farklı parmağının her birinden alınan dörder örnek içeren bir veri seti kullanımı söz konusu olduğunda, gerçek ve sahtekar dağılımlarını mesafe metriklerini kullanarak hesapladığımızda Denklem 3.2.7 gereği 64620 farklı karşılaştırma yapmak gerekir. Genuine karşılaştırmaları ise protokole göre sadece 3600 adettir.

$$\text{Karşılaştırma Sayısı} = \frac{(n \times r) \times ((n \times r) + 1)}{2} \quad (3.2.7)$$

3.2.7 MediaPipe Hands çerçevesi ve avuç içi izi çıkarımı

Avuç içi izi, görüntüleme platformlarının düşük maliyetli ve kullanıcı dostu yapısı sayesinde günlük hayatta biyometrik sistemler tarafından oldukça sık tercih edilmeye başlamıştır (Toygar ve diğ, 2020). Avuç içi izi, düşük çözünürlüğe sahip görüntülerde dahi kolayca görüntülenebildiği için kompleks görüntüleme platformu tasarımlarına gerek duymaz (Michael ve diğ, 2008). Özellik çıkarımı için ilgi bölgesi olarak belirlenen bir avuç içi alanından çıkarılan avuç içi izi bilgisi ile biyometrik sistemler, aynı anda minimum biyometrik bilgi kaybını ve maksimum tanıma kesinliğini sağlar. Bununla birlikte, elin görüntüleme platformunda değişen konumu ve kullanıcılara ait el büyüklüğündeki farklılıklar nedeniyle dinamik olarak avuç içi izi ilgi bölgesini çıkarmak kolay değildir (Zhang ve diğ, 2003). Biyometrik bilgileri içeren bölgenin adaptif olarak çıkarılması, tanıma performansını artırmak için önemli bir adımdır (Damak ve diğ, 2018). Araştırmacılar literatürde bu bölgeyi belirlemek için çeşitli çözümler önermişlerdir. İlgi bölgesinin belirlenmesindeki ana adımlar olarak, el sınırı tespiti ve tespit edilen eldeki avuç içi bölgesinin çıkarımı sıralanabilir (Damak ve diğ, 2018). Avuç içi görüntüleri için kullanılan kabaca 3 popüler el sınırı algılama yöntemi vardır: Önceden Tanımlanmış Pencere Tabanlı Yöntemler, Maske Tabanlı Yöntemler ve Eşik Tabanlı Yöntemler. Bu yöntemler, bazı dezavantajlara sahip olmalarına rağmen önemli performans değerlerine ulaşabilmektedir. Önceden

Tanımlanmış Pencere Tabanlı Yöntemler, kullanıcının el boyutundaki değişikliklerden ve el yönelimindeki değişikliklerden etkilenen bir yapıdadır ve uyarlanabilir değildir (Lu ve diğ., 2021a). Maske Tabanlı Yöntemler, el sınırlarını tespit ederken arka plan gürültüsüne karşı çok hassastır (Lu ve diğ., 2021b). Son olarak Eşik Tabanlı Yöntemler, görüntüleme ortamının homojen dağılmamış aydınlatmasından ciddi şekilde etkilenir (Yang ve diğ., 2015). Tüm bu yöntemler, halka açık avuç içi veri setlerinin ilgi bölgesinin çıkarılması için yaygın olarak kullanılmaktadır. Ancak bu yöntemlerin hiçbiri el sınırını kusursuz bir biçimde tespit edemez. Bu dezavantajların üstesinden gelmek ve uyarlanabilir çözümler sağlamak için literatürde bazı ilgi bölgesi çıkarım yöntemleri önerilmiştir. Örneğin, Li ve diğ., (2004), dikdörtgen tabanlı bir konumlandırma yerine daire tabanlı bir bölütleme yaklaşımı kullanmıştır. Poon ve diğ., (2004), ise dinamik olarak ilgi bölgesi çıkarmak için işaret parmağı ile orta parmak arasındaki parmak ağını ve orta parmak ile yüzük parmağı arasındaki parmak ağını kullanmıştır. Bu 2 ağdan birini, üzerinde maksimum büyüklükte çizilebilecek karesel bir bölgenin merkezlendiği eksen olarak kullanmışlardır. Sıralanan literatürdeki yöntemler analiz edildiğinde, yoğun işlem yükü gerektiren görüntü işleme adımlarının ilgi bölgesi çıkarımı süresini uzattığı görülmüştür. Ardışık ön işleme ve özellik çıkarım işlemleri nedeniyle geleneksel görüntü işleme yöntemleriyle elde edilen sonuçlar veri setine has çözümler sunup genelleme yeteneğine sahip olmadığından, bu yöntemlerin sahip olduğu kısıtların makine öğrenmesi tabanlı yöntemlerle giderilebileceği öngörülmüştür.



Şekil 3.15: MediaPipe Hands el işaretçileri (Lugaresi ve diğ., 2019).

Bu çalışmada, makine öğrenmesi tabanlı bir el izleme çerçevesi olan ve jest tanıma ile el tabanlı artırılmış gerçeklik gibi uygulamalar için kullanılan MediaPipe Hands, ilgi bölgesi çıkarımı için önerilmiştir. MediaPipe Hands, Google tarafından geliştirilen açık kaynaklı ve iyi eğitilmiş bir el izleme çerçevesidir (Zhang ve diğ., 2020). Bu çerçeve, el görüntüsü içeren video verilerinde 21 adet el işaretçisinin koordinatlarının tahmini için kullanılır. Bu işaretçiler Şekil 3.15'te gösterilmektedir. MediaPipe Hands, bir avuç içi algılama modeli ve bir el işaretleme modeli içerir. MediaPipe Hands, sahip olduğu hafif yapısıyla bu 2 modelin karmaşıklığını gizler ve el tespiti için gürbüz bir çözüm sunar (Zhang ve diğ., 2020). Açık kaynak kodlu bir çerçeve olduğundan, MediaPipe Hands'in vanilya versiyonu, sağlanan kodda herhangi bir parametre ayarı yapmadan bile el izleme uygulamalarında yüksek performans ile çalışır.

3.2.8 Damar görüntüleme sistemleri

Bir görüntüleme sisteminden beklenen özelliklerin başında kullanım kolaylığı, makul görüntü kalitesi ve ham veriye erişim izni gelmektedir. Opak yani ışığı yansıtmayan olan bir kutu tasarımı, kapalı sistemlerde ışığın yansıtılması ve saçılmasından kaynaklanan problemleri minimuma indirme adına önemlidir. Bunu başarmak için genelde siyah bir platform tasarımı tercih edilir. Geçiş ya da yansıtma başta olmak üzere seçilen aydınlatma yöntemlerinin alınan görüntü kontrastı ve kalitesi üzerinde büyük etkisi vardır. Piyasada satılan profesyonel cihazlarla "ev tipi" diye geçen sıradan kameralarla tasarlanan cihazlar arasında bariz farklar vardır (Takatani ve diğ., 2022). Ayrıca platformda kullanıcıyı yönlendiren donanımsal veya yazılımsal çözümler, kayma ve öteleme kaynaklı problemleri minimuma indirip tanıma oranını yükseltecektir. Fiziki yani donanımsal çözümlere örnek olarak, elin ya da parmağın yerleştirileceği bir kılavuz çizgisi ya da tutulacak bir sopa verilebilir. Kamera ile görüntüsü alınacak biyometrik özelliğin arasındaki mesafenin net olarak belirlenmesi, alınan görüntülerin kayma ve öteleme problemleri yaşama olasılığını en aza indirir. Veri tabanına kayıt esnasında ya da tanıma uygulamaları için görüntü alınırken, alınan görüntünün anlık olarak bir ekrandan izlenip takip edilebilmesi önemli bir avantaj ve atlanmaması gereken bir ayrıntıdır. Daha pahalı ve daha kaliteli cihazlarla ve destekleyici ekipmanlarla daha iyi tasarımlar ve performanslar mümkün iken, düşük maliyetli ve yüksek doğruluğa sahip sistemler de kurabilmek mümkündür. Eğer bu tasarım önerileri gerçekleştirilemiyorsa, kızılötesi ışığı bant geçiren bir filtreden geçirmek ya da ışığı dağıtan bir difüzör kullanmak yerinde bir adım olacaktır (Badawi, 2006). Difüzörler, alınan görüntüyü iyileştirmek için kullanılan optik bileşenlerdir. Alınan ışığı dağıtmak amacıyla kullanılan difüzörler aydınlatmadaki yoğunluğunun yumuşatılmasına ve daha iyi görüntü alınmasına yardımcı olur. Ayrıca görüntü işleme yöntemlerini kullanarak platformdan alınan görüntünün iyileştirilerek kaydedilmesi, elde edilen tanıma ve doğrulama performansına pozitif etki edecektir. Sıralanan tüm bu etkenlerin yanında cihazın bulunduğu ortamdaki nem, sıcaklık, kullanıcının ten rengi, kullanılan yakın kızılötesi ışığın dalga boyu, kullanılan kameranın CMOS ya da CCD olması, tasarlanan kutunun fiziksel özellikleri ve aydınlatma şeklini belirleyen ışık ve kameraların pozisyonu gibi etkenler, bir görüntüleme cihazının ulaşacağı performansı önemli ölçüde etkileyecektir.


İncelenen yayınlar arasında (Garcia-Martin ve diğ., (2020)) ve (Yildiz ve Boyraz, (2019)) Raspberry Pi kullanımı ve sade görüntüleme platformu tasarımlarıyla, (Altay ve Gumus, (2021)) ve (Yildiz ve Boyraz, (2019)) sundukları difüzör ve band geçiren filtre seçenekleriyle, (Garcia-Martin ve Sanchez-Reillo, (2021)) ve (Debiasi ve diğ., (2018)) ise cep telefonu kullanımını önererek ortaya çıkan sistem tasarımının sahip olduğu nihai özelliklere örnek teşkil etmiştir.

4. DENEYSEL SONUÇLAR ve TARTIŞMA

Bu bölümde, literatür taraması sırasında karşılaşılan problemlere çözüm bulma amacıyla gerçekleştirilmiş deneylerde kullanılan veya bu deneyler sırasında tanıma veya görüntüleme amacıyla ilk kez önerilen yöntemler hakkında bilgiler verilmiştir. Tanıma ve doğrulama konularında gerçekleştirilmiş deneylerin detayları ve elde edilen sonuçlar ile geliştirilen görüntüleme cihazlarına dair ayrıntılar yine bu bölümde paylaşılmıştır.


4.1 Oluşturulan Sentetik Veri Seti Hakkında

Şekil 4.1’de üretilmiş örnek bir parmak görüntüsü ve halka açık VERA-FV veri setinden alınmış gerçek bir parmak damar görüntüsü verilmiştir. Kullanılan arayüzün parmak damarı görüntüsü üretimi konusundaki başarısı, bu şekil üzerinden niteliksel olarak gözlemlenebilmektedir.



Şekil 4.1: Parmak damarı görüntüleri a) Sentetik b) Gerçek.

Şekil 4.2’de ise, arayüz kullanılarak üretilmiş örnek iki parmak görüntüsü bulunmaktadır. Birinci görüntü parmaktan alınan ilk örneği gösterirken, diğeri ise aynı parmaktan alınan ikinci örneği göstermektedir. Bu iki görüntü karşılaştırıldığında, damar örüntülerinin birbirine benzediği ve yer yer kızılötesi ışığın karakteristiğinden kaynaklanan kontrast farklılıklarının yaşandığı görülmektedir. Başta ışığın dağılım şekliyle yaratılan kontrast farkı olmak üzere, birkaç farklı yolla sağlanan sınıf içi ve sınıflar arası çeşitlilik, tüm veri seti görüntülerinde geçerlidir.



Şekil 4.2: Aynı parmağa ait sentetik görüntüler a) İlk örnek b) İkinci örnek.

Bu çalışma kapsamında oluşturulan veri seti, 1600 kişiden alınan onar örnek içermektedir. 16000 görüntü ile oluşturulan bu veri setindeki 1600 kullanıcıdan birine ait üretilen tüm görüntüler Şekil 4.3’te gösterilmiştir. Bu veri seti, tez çalışması kapsamında gerçekleştirilen tanıma uygulamalarında kullanılmıştır.



Şekil 4.3: Sentetik veri setindeki bir kullanıcıya ait örnek görüntüler.

4.2 Tasarlanan Empirik Tanıma Modelleri ve Elde Edilen Sonuçlar

Güvenlik ve gizlilik anlayışı nedeniyle görüntüleme sistemlerinin kurulmasının zor olması, parmak damarı biyometrisi ile uğraşan araştırmacıları özellikle derin öğrenme alanında erişime açık veri setlerini kullanmaya yöneltmiştir. Bu veri setlerinden bazıları SDUMLA-FV, MMCBNU-FV ve FV-USM'dir. Çizelge 2.6'da görüldüğü gibi, SDUMLA-FV veri seti için 106 kişi için, 6 farklı parmaktan, her bir parmak için 6 farklı örnek alınmıştır. FV-USM veri seti için 123 kişi için 4 farklı parmaktan, her bir parmak için 6 farklı örnek alınmıştır. MMCBNU-FV veri seti için ise 6 farklı parmaktan, her bir parmak için 6 farklı örnek alınmıştır. Veri setlerindeki kişi sayısı yeterli sayıda olmadığından, veri setinde kişilerin sayısını artırmak amacıyla kişilere ait parmakların her biri farklı bir bireyi temsil ediyor kabulünden yola çıkarak, kişi sayıları dolayısıyla sınıf sayıları her bir veri seti için artırılmıştır. Son durumda, SDUMLA-FV veri seti 636 sınıf, MMCBNU-FV veri seti 600 sınıf ve FV-USM veri seti ise, 492 sınıf içermektedir. Eğitim, test ve doğrulama setlerine ayrılacak örnek sayısı ise, her bir parmaktan alınan örnek sayısına göre şekillenmektedir. Alınan örnek sayıları kısıtlı olduğundan, bunlara ait kombinasyonlar da o derece sınırlıdır. Bu çalışmaya konu olan ESA, temel olarak evrişim (convolution) katmanı, ortaklama katmanı ve tam bağlantılı (fully connected) katman olmak üzere 3 kısımdan oluşur (Krizhevsky ve diğ., 2012). Bu üç katmanın çeşitli kombinasyonları ile çok çeşitli ESA modelleri oluşturmak mümkündür ve bu zamana kadar çeşitli modeller üretilip literatürdeki yerini almıştır. AlexNet, (Krizhevsky ve diğ., (2017)), ResNet, (He ve diğ., (2016)), VGG, (Simonyan ve Zisserman, (2014)) ve SqueezeNet, (Iandola ve diğ., (2016)), bu modellerin öne çıkanlarıdır. Literatürdeki bu modeller, elimizde çok sayıda parmak damarı görüntü örneği bulunmadığından, aşırı öğrenme problemi ile karşılaşmamıza engel olamaz. Bu sebeple bu çalışmada kullanılmamışlardır.

Çizelge 4.1: SDUMLA-FV için tasarlanan ESA modeli.

Tasarlanan ESA Modeli
Input Image 320 x 240 x 3
Conv 1 Layer 12 filters (3x3) strides (2x2)
Max Pool 1 (2x2)
Batch Normalization 1
Conv 2 Layer 20 filters (5x5) strides (2x2)
Max Pool 2 (2x2)
Batch Normalization 2
Conv 3 Layer 32 filters (5x5) strides (2x2)
Max Pool 3 (2x2)
Batch Normalization 3
Conv 4 Layer 48 filters (5x5) strides (2x2)
Max Pool 4 (2x2)
Flatten
Batch Normalization 4
Dropout (0.5)
Output Layer (636)

Bilindiği gibi ESA, genellikle resimleri sınıflandırmak için kullanılır. ESA, sınıflandırma işlemini herhangi bir ön işleme (preprocessing) işlemi kullanmadan ve de kullanmaya gerek duymadan yapar. Halbuki geleneksel yöntemler veri setine mahsus, ona bağımlı yani butik (domain specific) çözümler getirmektedir. Bu yönüyle ESA'nın çok aşamadan oluşan kendi kendine özellik çıkaran yapısı ile sunduğu avantaj yadsınamaz. Bu aşamaların her biri filtreler içerir ve her bir filtre sınıflandırmaya katkı koyarak bir diğer filtreye daha özümsemiş bilgi aktarır. Bu çalışmada görüntüye, görüntüyü iyileştirecek herhangi bir ön işlem uygulanmamıştır. Resmi çevirme, kırpma ve aynalama gibi bir işlem uygulanıp veri artırımı gerçekleştirilmemiştir. Bu işlemler yerine sistematik bir biçimde, 3 farklı dataseti için 3 farklı ESA modeli geliştirilmiştir (Avcı ve diğ., 2019). Hiperparametrelerle oynayarak modelin en iyi kesinlik ve kayıp değeri verecek son hali alması hedeflenmiştir. Bir ESA yapısında aktivasyon fonksiyonu, nöron sayısı, katman sayısı, filtre boyutu, filtre sayısı, ortaklama metodu, öğrenme katsayısı, ilk ağırlık değerinin atanması, optimizasyon fonksiyonu seçimi, verinin test-eğitim-doğrulama olarak ayrılma oranları vb. gibi hiperparametreler mevcuttur. Bu parametreleri sistematik bir şekilde değiştirerek ideale ulaşmak bu çalışmada hedeflenmiştir. Bu amaçla yola çıkıldığında, ilk olarak ön sezgi ve bilgilerden (intuition) yola çıkarak, neyin kurulan ağda işe yarayacağı neyin ise işe yaramayacağı düşünülmüş ve model, bu minvalde yaratılmaya başlanmıştır.

Kullanılan 3 farklı veri setine ait 3 farklı ESA modeli Çizelge 4.1, Çizelge 4.2 ve Çizelge 4.3'te verilmiştir (Avcı ve diğ., 2019). Bu çalışmada ulaşılmak istenilen temel amaç, oluşturulan nihai modelin genelleme işlemini en iyi şekilde gerçekleştirmesidir. Genelleme eğer iyi yapılırsa, model gördüğü verilerde (eğitim verileri) ve görmediği verilerde (test verileri) başarıya ulaşacaktır. SDUMLA-FV için oluşturulan nihai modeldeki evrişim katmanlarındaki filtre sayıları düşük tutulmuştur. Bu modelden önce denenen modeller eğitimde aşırı uyum problemine takılmıştır. Bundan

Çizelge 4.2: FV-USM için tasarlanan ESA modeli.


Tasarlanan ESA Modeli
Input Image 640 x 480 x 1
Conv 1 Layer 16 filters (3x3) strides (2x2)
Max Pool 1 (3x3)
Batch Normalization 1
Conv 2 Layer 24 filters (5x5) strides (2x2)
Max Pool 2 (3x3)
Batch Normalization 2
Conv 3 Layer 32 filters (5x5) strides (2x2)
Max Pool 3 (3x3)
Batch Normalization 3
Conv 4 Layer 48 filters (5x5) strides (2x2)
Max Pool 4 (2x2)
Flatten
Batch Normalization 4
Dropout (0.5)
Fully Connected Layer 1 (250)
Batch Normalization 5
Dropout (0.5)
Output Layer (492)

kaçınma adına dropout kullanılmış ve rastgele seçilme oranı 0.5 olarak seçilmiştir. Model eğitiminde Adam optimizasyon yöntemi kullanılırken, öğrenme hızı olarak 0.00008 belirlenmiştir. FV-USM için oluşturulan model ele alındığında, nihai modeldeki evrişim katmanlarındaki filtre sayıları yine düşük tutulmuştur. Bu model oluşturulmadan önce farklı modeller denenmiş ve oluşturulan modeller eğitimde hızla öğrenip yüksek kesinlik oranlarına çıksa da, doğrulama değerleri istenilen seviyelere ulaşamamıştır. Modelin eğitim sırasında aşırı uyum problemi yaşamaması ve ezberden kaçınması için evrişim katmanlarından sonra ve tam bağlantılı katman ile çıkış katmanı arasında dropout kullanılmıştır. Dropout yönteminde rasgele seçilme oranı yine 0.5 olarak alınmıştır. Model eğitiminde Adam optimizasyon yöntemi kullanılmış ve öğrenme hızı 0.00005 olarak belirlenmiştir.

Son olarak MMCBNU-FV için oluşturulan model ele alındığında, oluşturulan son modeldeki evrişim katmanlarındaki filtre sayıları düşük tutulmuştur. Bu model oluşturulmadan önce denenen modeller, eğitimde hızla öğrenip yüksek kesinlik değerlerine ulaşırsa da, doğrulama değerleri istenen seviyelere ulaşamamıştır çünkü modelin eğitim setindeki verileri ezberlediği görülmüştür. Bundan kaçınma adına dropout kullanılmış ve 0.5 rastgele seçilme oranı olarak seçilmiştir. Model eğitiminde Adam, optimizasyon yöntemi olarak kullanılırken öğrenme hızı olarak 0.00005 belirlenmiştir. Model eğitimi mini batch (mini yığın) modunda gerçekleştirilmiş ve yığın boyutu olarak da 64 alınmıştır. Veri setindeki görüntüler, modele normalize edilmeden verilmiştir. Böylelikle erişilen görüntüyü herhangi bir ön işleme tabi tutmadan, modelin sınıflandırma yapılabilmesi sağlanmıştır.

Çizelge 4.3: MNCBNU-FV için tasarlanan ESA modeli.

Tasarlanan ESA Modeli
Input Image 320 x 240 x 1
Conv 1 Layer 16 filters (3x3) strides (2x2)
Max Pool 1 (3x3)
Batch Normalization 1
Conv 2 Layer 32 filters (5x5) strides (2x2)
Max Pool 2 (3x3)
Batch Normalization 2
Conv 3 Layer 64 filters (7x7) strides (2x2)
Max Pool 3 (2x2)
Batch Normalization 3
Conv 4 Layer 96 filters (5x5) strides (2x2)
Max Pool 4 (2x2)
Flatten
Batch Normalization 4
Dropout (0.5)
Fully Connected Layer 1 (100)
Batch Normalization 5
Dropout (0.5)
Output Layer (600)




Şekil 4.4: SDUMLA-FV veri setine ait kayıp ve kesinlik grafikleri.

3 farklı veri seti için oluşturulan modellere ait hiperparametre listesi, bu modellerin kullanılmasıyla elde edilen kesinlik ve kayıp değerleri Şekil 4.4, Şekil 4.5 ve Şekil 4.6'da gösterilmiştir (Avcı ve diğ., 2019). Bu modellerde sıklıkla yer alan yığın normalleştirilmesi, her bir katmanın kendi başına öğrenmesini sağlarken bu yapı sayesinde oluşan veri adaptif bir biçimde normalize edilir. Diğer bir sık kullanılan yapı olan dropout ise, bir düzenleme yöntemidir ve aşırı uyumu belli başlı nöronları rastgele devre dışı bırakarak engeller. Oluşturulan tüm modellerde Adam, en iyileyici (optimizer) olarak kullanılır. Categorical cross entropy ise, aktivasyon fonksiyonu olarak kullanılır. Veri setleri için oluşturulan ESA modellerinin ulaştığı başarı Çizelge 4.4'teki gibidir. Örnek sayısının kişi ve parmak başına sınırlı olması nedeniyle eğitim-test-doğrulama dağılımı (partition) senaryoları da sınırlıdır. Bu şartlar altında en iyi


Çizelge 4.4: ESA modellerinin veri setlerinde ulaştığı test kesinlik değerleri.

Veri Seti	Eğitim-Test-Doğrulama Oranları	Test Kesinliği	Referans Sonuçlar
SDUMLA-FV	4-1-1	%99.21	%98.90 (Das ve diğ, 2018)
FV-USM	8-2-2	%98.44	%97.02 (Das ve diğ, 2018)
MMCBNU-FV	6-2-2	%98.58	-

accuracy ve loss değerlerinin elde edildiği senaryo bu tabloda belirtilmiştir. Örnek vermek gerekirse SDUMLA-FV veri seti için parmak başına 6 örnek söz konusu olduğundan bunun ilk dördünün eğitim, beşinci örneğin test ve altıncı örneğin ise, doğrulama olarak ayrıldığı senaryo bu veri seti için en iyi değerlerin elde edilmesini sağlamıştır. Bu tablo göz önünde bulundurulduğunda en yüksek skor %99.21 ile SDUMLA-FV veri setinde elde edilmiştir.



Şekil 4.5: FV-USM veri setine ait kayıp ve kesinlik grafikleri.



Şekil 4.6: MMCBNU-FV veri setine ait kayıp ve kesinlik grafikleri.

Eğer başarıyı daha da artırmak gerekirse sınıf sayısı çok olan veri setlerinde kişi veya parmak başına düşen örnek sayısı artırılmalıdır. Bu çalışmada dropout ve batch normalization periyodik olarak uygulanmıştır ve overfitting modele etki edememiştir. Ayrıca batch normalization eğitim süresini önemli ölçüde azaltmıştır. Bunu yaparken, normalize edip belirli değerler arasında tuttuğu giriş değerlerinden faydalanmıştır. Bu çalışma erişime açık veri setlerinden üç tanesini kullanarak gerçekleştirilmiştir. Bu sayıyı 3'ten 7'ye çıkarılarak daha kapsamlı ve detaylı bir karşılaştırma gerçekleştirmek mümkündür. Veri artırımı, eğitim verilerini artırma

yoluna gidip overfitting probleminden kaçınmanın ilk yolu olarak akla gelir. Bu sayede kısıtlı olan parmak damarı görüntüsü ESA'da kullanılmak üzere artırılabilir. Son ve en önemli çözüm olarak, erişime açık veri setleri yerine tasarlanması muhtemel olan bir görüntüleme sistemine sahip olmaktır. Bu sistemle çok sayıda kullanıcıdan alınacak çok sayıda örnek ile ağdaki başarı artırılabilir.

4.3 Artan Veri ve Öğrenim Aktarımı ile Elde Edilen Sonuçlar

Bu çalışmada empirik yollarla tasarlanan bir ESA modeli ya da herkes tarafından yapısı bilinen AlexNet, VGG16, VGG19, Lenet gibi ESA modellerinden birini kullanmak yerine öğrenim aktarımı kullanan ESA yapısı tercih edilmiştir. Halka açık parmak damarı veri setleri arasında 100 kişiden, her iki elin üçer parmağından onar örnek alınarak 6000 örnekle oluşturulan ve muadillerine göre en kapsamlı veri setlerinden olan MNCBNU-FV ve ürettiğimiz 1600 kişiden alınan onar örnek içeren sentetik veri setinin kullanıldığı bu çalışmada, kapalı küme protokolü kullanılmıştır. Kapalı küme protokolü, bir biyometrik sistemdeki kullanıcıların önceden belirlenmiş bir kümesini kullanır. Yani bu, sistemin doğrulama yapacağı kullanıcıların listesi ve onlara ait örneklerin önceden bilinmesi anlamına gelir. Örneğin, bir fabrikanın tüm çalışanlarının parmak izleri önceden taranarak sisteme kaydedilir ve sistem sadece bu çalışanların parmak izleriyle doğrulama yapar. Bu senaryo kapalı küme protokolüne örnektir. Fabrika çalışanları harici dışarıdan gelecek birisi ve ona ait biyometrik örnekler bu protokolde kullanılmaz. Açık küme protokolü ve kapalı küme protokolü arasındaki en önemli fark, veri tabanının içeriğidir. Açık küme protokolü, birçok farklı kişinin verilerini içerebilirken, kapalı küme protokolü sadece belirli bir kullanıcı grubunun verilerini içerebilir (Hu ve diğ., 2018). Bu nedenle, kapalı küme protokolü daha güvenli bir yapıdır ve genellikle özel organizasyonlar ve fabrikalar tarafından tercih edilir. Ancak, açık küme protokolü daha geniş bir kullanım alanına sahiptir ve insanların kimliklerini doğrulamak için daha yaygın olarak kullanılır.

Bu çalışmada öğrenim aktarımı sırasında ResNet50, DenseNet121, DenseNet169 ve DenseNet201'e ait ağırlıklar kullanılmıştır. Tüm bunlar, çok çeşitli nesne kategorileri için etiketlere sahip büyük bir görüntü veri kümesi olan ImageNet veri seti üzerinde önceden eğitilmiş derin öğrenme modelleridir. Bu modeller, bu çalışmada olduğu gibi eğitilme amacının dışında çok farklı bir görevi çözmek için paylaşılmaktadır. ResNet50, kaybolan gradyan (vanishing gradient) probleminden etkilenmeden daha derin ağları eğitmeye yardımcı olup çeşitli bilgisayarla görme görevlerinde yaygın olarak kullanılmaktadır. DenseNet121, DenseNet169 ve DenseNet201 ise, DenseNet mimarisinin varyasyonlarıdır. DenseNet121'de 121, DenseNet169'da 169 ve DenseNet201'de 201 katman vardır. DenseNet'ler, katmanlar arasında yoğun bağlantılar kullanan ve her katmanın önceki tüm katmanlardan girdi aldığı ESA modelleridir. Bu özellikleri, DenseNet'lerin geleneksel ESA'lardan daha verimli çalışmasını ve daha kolay eğitilmesini sağlar.

Kullanıcı sayısı ve alınan örnek sayısı halihazırda literatürde bulunan halka açık veri setlerine kıyasla daha çok olan ürettiğimiz sentetik veri seti ile ona en yakın özelliklere sahip MNCBNU-FV veri setinin kullanıldığı bu çalışma, literatürde sıkça kullanılan ve önemli özelliklerin çıkarımına katkı sağlayan ResNet50, DenseNet121, DenseNet169 ve DenseNet201 modellerini kullanmaktadır. Bu çalışmada amaçlanan

artan kullanıcı sayısı ve örnek sayısının tanımaya olan etkisini gözlemlemektir çünkü genel geçer bir kural olarak sıkça karşılaştığımız veri eksikliğinin elde edilen başarıyı olumsuz yönde etkilediği algısını, bu çalışma değişen kullanıcı sayısı, test ve eğitim sayısı gibi hiperparametre değişiklikleri ile gözlemlemeye çalışmıştır (Friedman ve diğ., 2019).

Bu çalışmada MNCBNU-FV ve üretilen sentetik veri seti kullanılmıştır. Öncelikle üretilen sentetik veriler, eğitim ve test veri setinde kullanılan sınıfların sayısının elde edilen başarıya etkisinin incelenmesi adına, farklı sınıf sayısına sahip 3 ayrı veri setine bölünmüştür. 1600 kişi içeren bu veri setine ait alt veri setleri sırasıyla 100, 500 ve 1000 sınıfa ait veri setleridir. MNCBNU-FV veri seti, 100 kişinin her 2 elinin üçer parmağından onar örnekle oluşan 6000 resimden oluşur. Literatürde kapsamlı veri eksikliği nedeniyle her bir parmağa farklı bir sınıf muamelesi yapıldığından bu çalışmada MNCBNU-FV veri setinin 100 yerine 600 sınıfa sahip olduğu varsayılmıştır. Oluşturulan sentetik verilerin ve kullanılan gerçek verilerin boyutları birbirinden farklı iken aynı boyuta sahip olmaları adına boyutları 240x120 olacak şekilde değiştirilmiştir.

Bilindiği gibi her iki veri setinde de her bir sınıfta onar örnek bulunmaktadır. Protokol kapsamında gerçek ve sahte değerlerinin karşılaştırılıp hesaplanması gerekmektedir. Yapılan deneysel çalışmada kapalı küme protokolü kullanılmıştır. Protokol kapsamında, DTO hesabının yapıldığı test verileri ile model eğitiminin yapıldığı veriler ayrılmıştır. Bu sebeple test veri setinde genuine hesabı yapabilmek için minimum 2 adet aynı sınıftan veri olması gerekmektedir. Deney kapsamında bu değerlerin etkisinin görülmesi adına 3 resim ile 7 resim arasında değişecek şekilde veri setleri eğitim ve test olarak Çizelge 4.5'teki gibi bölünmüştür. Her sınıf için geri kalan veriler, kullanılan modellerin eğitiminde kullanılmıştır. DTO deneyleri gerçekleştirilirken 2 boyutlu tek kanallı veya 2 boyutlu çok kanallı görüntü verilerinin vektörler ile gösterilmesi istenmiştir. Böylelikle her bir parmak damarı verisi aynı boyutlara sahip vektörler ile ifade edilebilecektir. Bu vektörler arasındaki uzaklığın hesaplanması, bu verilerin gerçek ya da sahtekar olarak tayin edilebilmesi için gereklidir.

Verilerin vektörler halinde ifade edilebildiği bu çalışmada derin sinir ağlarından faydalanılmıştır. Öğrenim aktarımı ile belli bir yapıya sahip olan modellerin geniş bir veri setinde eğitilip elde edilen katsayıları ile parmak damarı veri setinde ince ayar (fine tuning) yoluyla kullanılması sağlanmıştır. Kullanılan modeller sırasıyla

Çizelge 4.5: ResNet50 ile elde edilen DTO sonuçları.

Eğitim Örneği	Test Örneği	Sentetik (100)	Sentetik (500)	Sentetik (1000)	MNCBNU-FV
7	3	%100	%100	%97,43	%98,72
6	4	%100	%100	%100	%98,77
5	5	%100	%99,96	%99,95	%99,21
4	6	%100	%99,96	%100	%98,36
3	7	%98,23	%99,86	%99,27	%96,63

Çizelge 4.6: DenseNet121 ile elde edilen DTO sonuçları.

Eğitim Örneği	Test Örneği	Sentetik (100)	Sentetik (500)	Sentetik (1000)	MMCBNU-FV
7	3	%100	%99,86	%100	%99,77
6	4	%100	%100	%100	%99,27
5	5	%100	%99,64	%100	%99,61
4	6	%99,93	%100	%99,99	%99,33
3	7	%100	%99,94	%99,94	%98,44

Resnet50, Densenet121, Densenet169 ve Densenet201 modelleridir. Bu modeller oluşturulduğu ve eğitildiği ImageNet veri setinde iyi sonuçlar vermesi sebebiyle seçilmiştir. Bu modeller kullanılırken modellerin son ortaklama katmanından sonraki katmanlar alınmamıştır. Giriş katmanından bu katmana kadar olan katmanlar alınmış ve ardından dropout katmanı ile çıkış katmanı eklenmiştir. Çıkış katmanındaki nöron sayıları veri setinde bulunan sınıf sayısına göre değişiklik göstermektedir. Farklı veri setleri için nöron sayıları 100, 500, 600 ve 1000 değerlerini almaktadır. Ayrıca girişte verilen veriler öğrenim aktarımı için uygun değildir. Eğitilmiş modeller ImageNet veri setine uygun olduğu için girişte bir convolution katmanı ile tek kanallı veriler 3 kanala çıkarılmış ve diğer boyutlar değiştirilmemiştir. Bu kısımda eklenen katmanlar ve transfer edilen modelin tamamı parmak damarı verisi ile tekrar eğitilmiştir. Bu kısımda modellerin eğitiminde hep aynı hiperparametreler kullanılmıştır. Eğitim sırasında yığın boyutu 32 olarak alınmıştır. Adam optimizasyon yöntemi olarak kullanılırken, öğrenme katsayısı 0.0001 olarak alınmıştır. Toplamda 120 epoch boyunca model eğitilmiştir. Modelin eğitimi sırasında accuracy değeri kısa sürede yani yaklaşık 10 ila 15 epoch arasında %100'e ulaşabilse de loss değerinin daha düşük olması istenerek eğitime devam edilmiştir. Fine tuning yapılan modellerin son katmanı atılarak test veri setindeki verilerin son ortaklama katmanından sonra vektör olarak alınması sağlanmıştır. Öğrenim aktarımında kullanılan modele göre bu vektör boyutları değişmektedir. Bu çalışma kapsamında iki vektörün benzerliği Öklid mesafesi gibi bir mesafe ölçüsü olan Kosinüs benzerliği (Cosine similarity) ile ölçülmüştür.

Bu çalışma kapsamında elde edilen sonuçlar Çizelge 4.5, Çizelge 4.6, Çizelge 4.7 ve Çizelge 4.8'de verilmiştir. Bu tablolarda, 4 farklı model ile elde edilen değerler görülmektedir. Her çizelge, 3 ile 7 arasında değişen eğitim ve test örnek veri

Çizelge 4.7: DenseNet169 ile elde edilen DTO sonuçları.

Eğitim Örneği	Test Örneği	Sentetik (100)	Sentetik (500)	Sentetik (1000)	MMCBNU-FV
7	3	%100	%100	%100	%99,16
6	4	%100	%100	%100	%99,55
5	5	%90,6	%99,88	%99,99	%99,08
4	6	%100	%100	%99,97	%99,37
3	7	%98,57	%99,95	%99,9	%99,13

Çizelge 4.8: DenseNet201 ile elde edilen DTO sonuçları.

Eğitim Örneği	Test Örneği	Sentetik (100)	Sentetik (500)	Sentetik (1000)	MMCBNU-FV
7	3	%100	%100	%100	%99,88
6	4	%100	%100	%100	%99,75
5	5	%100	%100	%100	%99,4
4	6	%99,66	%100	%99,95	%98,97
3	7	%98,28	%99,95	%99,90	%99,11

sayısını içermektedir. Test veri setindeki veri sayısı artarken eğitimde kullanılan veri miktarı azalmaktadır. Bu sebeple kullanılan modeller tanıma için yeteri kadar öğrenmeyi sağlayamamaktadır. Kısacası, derin öğrenmede artan veri sayısının elde edilen başarıdaki etkisini gözlemlemek için üretilen sentetik verideki kullanıcı sayısı ve örnek sayısı halen yeterli değildir.

4.4 Sentetik Veri Seti ile Tasarlanan Parmak Damarı Tanıma Uygulaması

Bu bölümde, sentetik veriler kullanılarak tanıma uygulaması gerçekleştirilmiştir. Bu uygulamada önceki bölümlerde oluşturulan ve öğrenim aktarımı sonucu oluşmuş modeller kullanılmamıştır. Bunun yerine Google'a ait "Teachable Machine" adlı model oluşturma arayüzünden faydalanılmıştır. Teachable Machine, makine öğrenimi modelleri oluşturmayı hızlı ve kolay hale getiren bir web aracıdır. Google'a ait grafik işlemci birimleri kullanılarak gerçekleştirilen bu yoğun deney, aşırı öğrenme problemi yaşamamak ve optimum modeli bulabilmek adına bu platformda gerçekleştirilmiştir. Deney sonucunda oluşan modele ait ağırlıklar, dışa aktararak Python'da Tkinter kütüphanesi kullanılarak tasarlanan arayüzü de konu alan bir tanıma uygulamasına olanak sağlamıştır. Oluşturulan arayüzde kullanıcıya ait ad, soyad, cinsiyet gibi birtakım bilgiler kullanıcıdan istenilip veri tabanına kaydedilmektedir. Bu arayüzde tanımlanan kullanıcı bilgileri ile üretilen sentetik damar görüntüleri ilişkilendirilip tanıma uygulaması temellendirilmektedir. Sentetik damar görüntülerini kullanan Teachable Machine arayüzünde tanımlanan sınıflara verilen isim ile oluşturulan Tkinter kütüphanesi tabanlı arayüze girilen kullanıcı ad ve soyadları birebir aynı tanımlanıp, gereken bağ kurulmuştur. Böylelikle model ile arayüz ilişkilendirilmiştir.

Üretilen sentetik veri seti görüntülerinin kullanıldığı bu çalışmada, 1600 kullanıcıya ait onar görüntünün sekizi eğitimde model oluşturmak için, biri kişiyi MySQL veri tabanına kaydedip tanıtmak için ve kalan görüntü ise, belirlenen bir dosya yolunda tanıma işlemini gerçekleştireceğimiz test için kullanılmıştır. Test amaçlı tutulan 1600 kişiye ait birer görüntüyü karşılaştırma esasına dayanan bu sınıflandırma uygulaması, veri tabanında tutulan kaydın kişiye ait olması durumunda tanımayı başarılı, aksi durumlarda ise başarısız olarak nitelendirmektedir.


Bu çalışmada, hızlı ve yüksek işlem gücüne sahip olup oldukça düşük güç tüketen Şekil 4.7'de gösterilen Jetson Nano 4 GB kullanılmıştır. Görüntü işleme ve makine öğrenmesi konuları başta olmak üzere pek çok prototipleme çalışmasında sıkça kullanılan Jetson Nano, 128-core Maxwell GPU, 4 çekirdekli –core ARM A57 ve 4



Şekil 4.7: Jetson Nano 4 GB.

GB RAM'e sahiptir. 70x45 mm boyutlarındaki bu mikro bilgisayar, harici 5v/4A ile beslenir ve dahili bir belleğe sahip değildir.

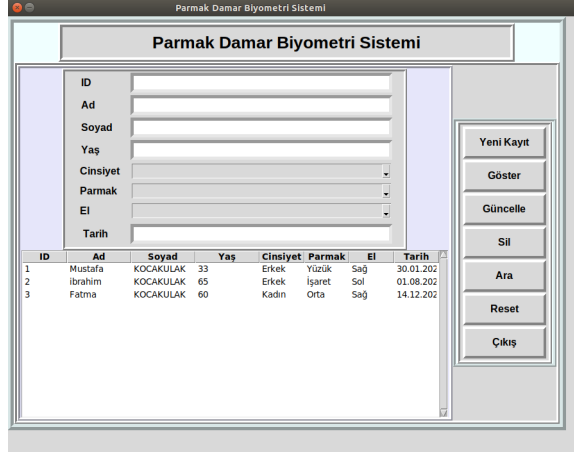
Jetson Nano 4 GB üzerinde koşturulan bu tanıma uygulamasında, Tkinter kütüphanesi, MySQL veri tabanı ve "Teachable Machine" adlı web arayüzü kullanılmıştır. Şekil 4.8'de görüldüğü gibi, bu tanıma uygulaması "Parmak Damar Biyometrisi" adlı bir kısayola sahip olup, masaüstünde sağ tarafta yer almaktadır.



Şekil 4.8: Jetson Nano kullanarak oluşturulan tanıma programına ait kısayol.

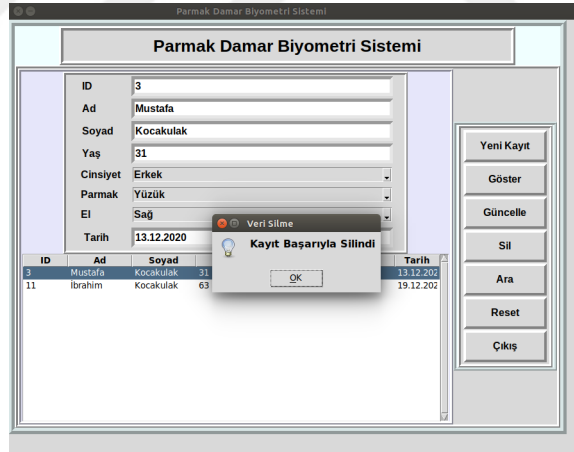
Masaüstü uygulaması haline getirilen bu tanıma programı için tasarlanan arayüz, Şekil 4.9'daki gibidir. Bu arayüz, Python'daki Tkinter kütüphanesi kullanılarak oluşturulmuştur. Bu arayüz kullanıcıya yeni kayıt yapma, kayıt bilgisi gösterme, kayıt güncelleme, kayıt silme, isimle veri tabanında kayıt sorgulama ve programdan çıkış seçenekleri sunmaktadır. Veri tabanında tutulan kayıtları anlık olarak takip etme şansını kullanıcıya sunan döküm listesi, veri tabanına yapılan her müdahale sonrası güncelle butonuna basılması halinde yenilenip güncellenmektedir.

Bu arayüzde kullanıcıya verilen ad ve soyad bilgilerinin, Teachable Machine arayüzündeki sınıflara verilen etiketle birebir aynı olması gerektiğinden, kayıt sırasında yaşanabilecek yazım hatalarını telafi etme adına kayıt silme ve kayıt güncelleme seçenekleri kullanıcıya arayüz üzerinden sunulmuştur. Bu hatayı gidermenin bir diğer yolu olan MySQL veri tabanının anlaması nispeten zor




Şekil 4.9: Parmak damarı tanıma sistemine ait arayüz.

arayüzüyle kullanıcıyı muhatap etmeme adına, veriler anlık olarak bu arayüzde listelenmiştir. Veri tabanına yapılan bir kaydın başarılı olduğu ya da veri tabanında gerçekleştirilen kayıt silme işleminin başarılı olduğu gibi durum bilgileri Şekil 4.10'da gösterildiği gibi kullanıcıya anlık olarak bildirilmektedir. Bu sayede, gerçekleştirilecek tanıma uygulaması öncesi, bilgileri doğru bir şekilde girilmiş ve veri tabanında 1 adet parmak damarı görüntüsüne sahip her kullanıcı, Teachable Machine tarafından dışa aktarılan derin öğrenme modelini kullanan tanıma uygulamasını, sahip olduğu tek görüntüsü ile kullanabilecektir.



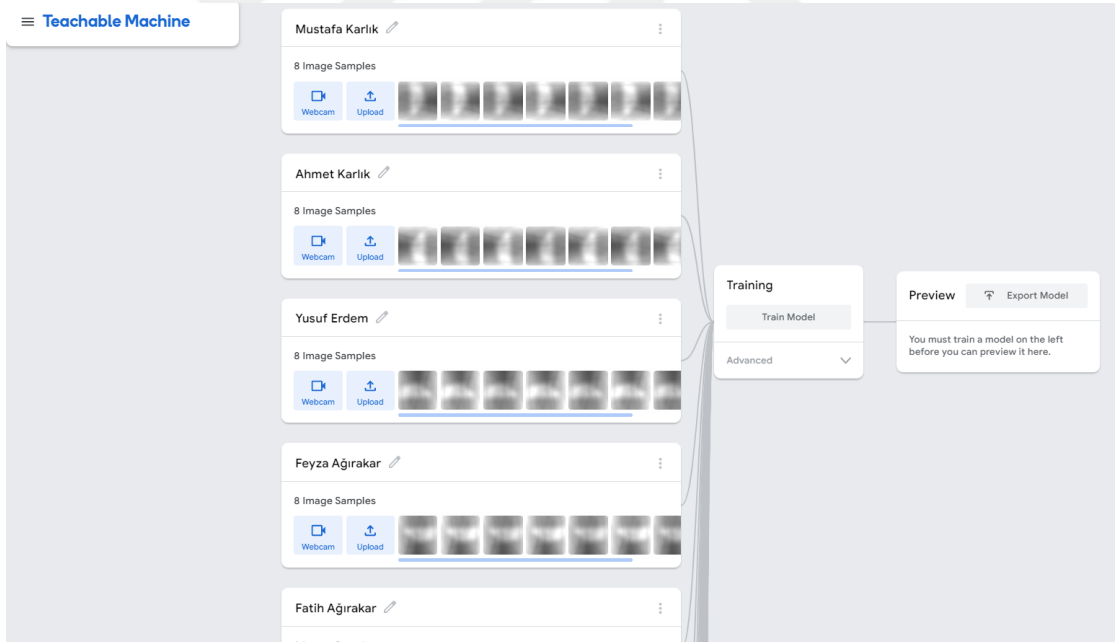
Şekil 4.10: Arayüzde gerçekleşen kayıt silme bildirim ekranı.

Veri tabanında ilgili kişiye dair kayıt olup olmadığı bilgisi ise, "Ara" butonuna basılarak ilgili ad veya soyad bilgisi sorgulanarak Şekil 4.11'deki gibi denetlenebilmektedir. Bu özelliğin arayüze eklenme sebebi, 1600 kişilik veri tabanını kısıtlı ekran genişliğine sahip bu arayüz üzerinden yönetilebilir kılmaktır. Aksi takdirde, tüm verilerin döküm listesine sığma şansı yoktur.



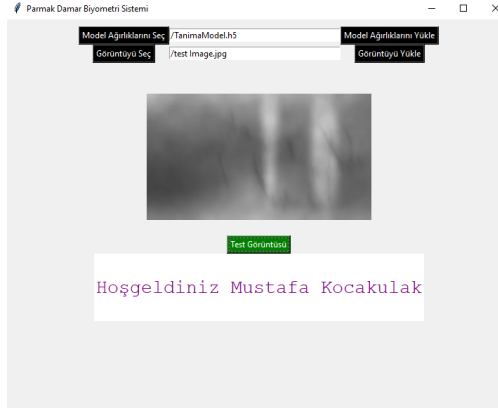
Şekil 4.11: Arayüzde gerçekleştirilen kullanıcı sorgulama bildirim ekranı.

MySQL kullanarak oluşturulan veri tabanında ad, soyad, yaş, cinsiyet, görüntünün hangi elden ve hangi parmaktan alındığı bilgisi, kayıt tarihi ve doğrulama amaçlı saklanan görüntü yer almaktadır. Bu sütuna, 1600 kullanıcının her biri için, o kişi için sentezlenen 10 adet görüntüsünden biri seçilerek kaydedilmiştir. Bu kayıt sayesinde kişi veri tabanına tanıtılmıştır.



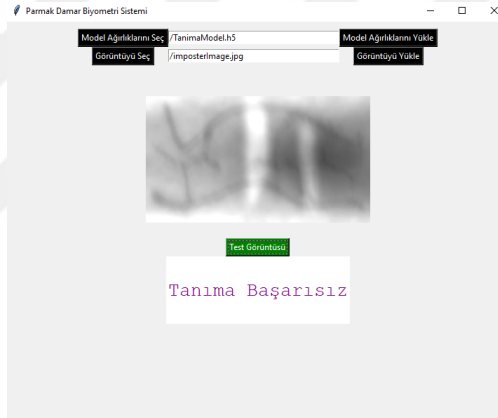
Şekil 4.12: Teachable Machine web arayüzüne tanıtılan sentetik veriler.

Son olarak "Teachable Machine" adlı web arayüzü kullanılarak kullanıcılara ait 8 eğitim görüntüsü, 1600 farklı kişi için 1600 farklı sınıf oluşturularak Şekil 4.12'deki gibi eğitilmiştir. Bu arayüzde kişilere verilen etiketler, Tkinter kütüphanesi ile tasarlanan arayüzdeki ad ve soyad bilgisiyle eşleştirilmiştir.



Şekil 4.13: Başarıyla sonuçlanan tanıma uygulamasına ait ekran.

Tüm bu adımların başarıyla tamamlanması sonrası veri tabanındaki kayıt resmi ile dosya yolu, tasarlanan arayüzle sunulan test görüntüsü karşılaştırılır. Eğitilip dışa aktarılan modelin tanıma başarısı nispetinde, tanıma işlemi Şekil 4.13'te ve Şekil 4.14'te gösterildiği gibi sonuçlanabilir.

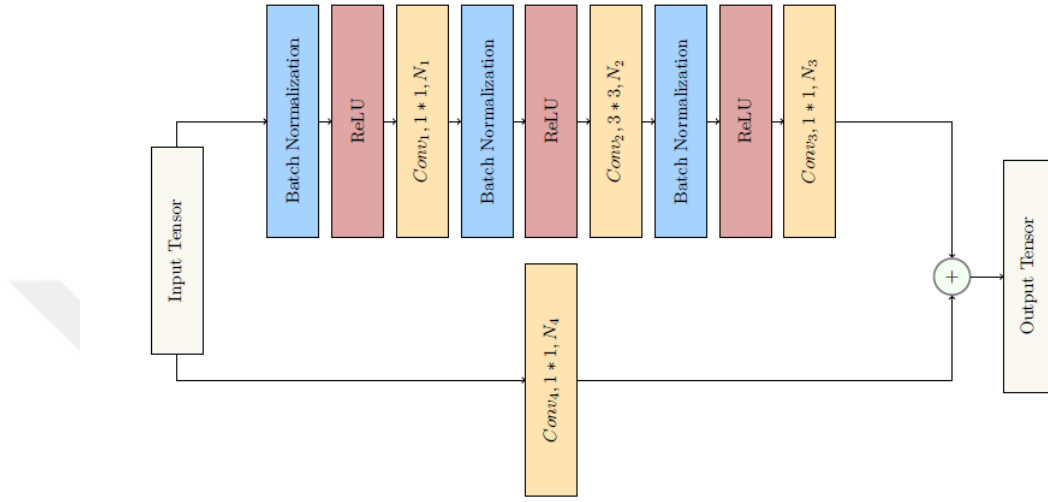


Şekil 4.14: Başarısızlıkla sonuçlanan tanıma uygulamasına ait ekran.

4.5 Öz Dikkat Mekanizması Tabanlı Damar Doğrulama Uygulaması


Bu çalışmada, önceden eğitilmiş herhangi bir model veya mevcut herhangi bir ağ mimarisi kullanmak yerine damar doğrulama performansını iyileştirmek ve genelleme kabiliyetini artırmak için Öz dikkat tabanlı ESA kullanımı önerilmiştir. Son literatürde listelenen ESA mimarileri yalnızca öteleme eşdeğerliği (translational equivariance) ve öteleme değişmezliği (translational invariance) sağladığından, önerilen modelde bağlamın kritik bölümlerine odaklanarak doğrulama performansını artırmak için Öz dikkat mekanizması kullanılmıştır. Bu çalışmada, yerel olmayan alıcı alan (non-local receptive fields) etkileşimlerini yakalamak için, Şekil 3.11'de gösterildiği gibi evrişim katmanları ile Öz dikkat blokları kullanılmıştır. Sınıflandırma problemlerinde üstün performans elde etmek için, bir ESA'nın derinliği kritik bir parametre olarak bilinir (Krizhevsky ve diğ., 2017). Ancak, daha fazla katman kullanarak ağın derinliğini artırmak aşırı uyuma sebep olabilir. Bu nedenle, normalleştirme katmanları ve kısayol bağlantıları (shortcut connections) içeren bir ResNet bloğu yardımıyla özel bir ESA tasarlanmıştır. Krizhevsky ve diğ., (2017), tarafından önerilen artık bloğa benzer

olan kullanılan blok Şekil 4.15'te gösterilmiştir. Bu iki yapıyı bir araya getiren ve nihayetinde oluşan bir model ile oluşturulan ağ eğitilmiştir. Öz dikkat mekanizmasının sağladığı avantajı belirli aralıklarla evrişim katmanlarıyla harmanlayan ve iki yapıyı bir araya getiren bir model ile oluşturulan ağ Çizelge 4.9'daki gibi oluşturulup ağ eğitilmiştir.



Şekil 4.15: Önerilen modeldeki ResNet bloğu.

Tüm sonuçlar, SDUMLA-FV veri setinde açık set protokolü kullanılarak elde edilmiştir. Euclidean, Cosine, Minkowski ve Manhattan adlı mevcut 4 mesafe ölçüsünü kullanarak, elde edilen her bir doğrulama performansı, önerilen model üzerinde EHO açısından karşılaştırılmıştır. Ayrıca, elde edilen en iyi doğrulama performansını iyileştirmek için mevcut mesafe metrikleri, Kosinüs (Cosine) mesafesi ile çarpılarak yeni mesafe metrikleri türetilmiştir. Önerilen bu mesafe metrikleri, özellik vektörleri arasındaki mesafeler üzerinden doğrulama performansını değerlendirirken bakış açımızı değiştirmek amacıyla önerilmiştir çünkü Kosinüs mesafesi özellik vektöründeki bireysel noktaların etkisini sönümleme etkisi yaratabilecek özelliktedir (Hou ve Yan, 2021).



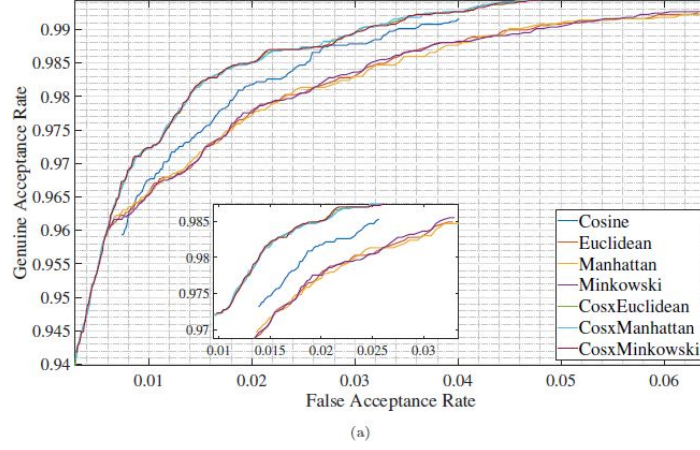
Şekil 4.16: Uygulamaya ait dağılımlar a) Cosine Minkowski b) Manhattan.

Çizelge 4.9: Önerilen Öz dikkat mekanizması tabanlı ESA modeli.

Katmanlar	Giriş Boyutu	Çıkış Boyutu	Model
Input Layer	224x224	224x224	
Scale Activation	224x224	224x224	
Convolution	224x224	75x75	
Max Pooling	75x75	38x38	2x2 max pool, stride 2
ResNet Block1	38x38	38x38	1x[128, 128, 128, 128]
Self-attention Block	38x38	38x38	128 filters
Max Pooling	38x38	19x19	2x2 max pool, stride 2
ResNet Block2	19x19	19x19	4x[128, 256, 256, 256]
Self-attention Block	19x19	19x19	256 filters
ResNet Block3	19x19	19x19	1x[128, 256, 256, 256]
Self-attention Block	19x19	19x19	256 filters
ResNet Block4	19x19	19x19	1x[128, 256, 256, 256]
Self-attention Block	19x19	19x19	256 filters
ResNet Block5	19x19	19x19	1x[128, 256, 256, 256]
Max Pooling	19x19	10x10	2x2 max pool, stride 2
ResNet Block6	10x10	10x10	3x[256, 512, 512, 512]
Self-attention Block	10x10	10x10	512 filters
ResNet Block7	10x10	10x10	1x[128, 256, 256, 256]
Self-attention Block	10x10	10x10	512 filters
ResNet Block8	10x10	10x10	1x[512, 1024, 1536, 1536]
Average Pool	10x10	1536	global average pool

Bu çalışmada, Şekil 4.16'daki Gerçek Eşleşme Dağılımı (Genuine Matching Distribution (GMD)) ve Sahtekar Eşleşme Dağılımı (Imposter Matching Distribution (IMD))'nı belirleyen değişen eşik değerleri için sistem performansları hesaplanmıştır. Eşik değerlerine bağlı olarak gerçek ve sahtekar yani gerçek pozitif değerler ve yanlış pozitif değerlerin dağılımları belli bir oranda iç içe geçmiştir. İdeal bir sistemde iç içe geçmemesi gereken ama fiili olarak mümkün olmayan bu dağılım grafiği, elde edilen sistemin performansını belirtmesi sebebiyle önemlidir. Bu dağılımlar oluşturulurken yapılan hesaplamalarda, özellik vektörlerini kıyaslarken sırasıyla Cosine Minkowski ve Manhattan mesafe metrikleri kullanılmıştır. Damar doğrulama performansı, Çizelge 4.10'da gösterildiği gibi mevcut ve önerilen mesafe metrikleri aracılığıyla Öz dikkat tabanlı bir ESA ile EHO açısından değerlendirilmiştir. Yapılan deneyde, önerilen uzaklık metrikleri ile mevcut metriklere göre daha iyi EHO performansları elde edilmiştir. Çizelge 4.10 içindeki en iyi EHO performans değerleri, Cosine Minkowski ölçümü için elde edilmiştir.

Şekil 4.17, tüm önerilen ve mevcut mesafe metrikleri için SDUMLA-FV parmak damarı veri setinin ROC eğrilerini gösterir. Önerilen metriklerin eğrilerinin altında kalan alanlar, mevcut metriklerin eğrilerinin altında kalan alanlardan daha büyüktür. Şekil 4.17'de ve Çizelge 4.10'da gösterildiği gibi, önerilen mesafe metriklerinin performansları, mevcut mesafe metriklerinin performanslarından biraz daha iyidir. Elde edilen ROC eğrileri, Çizelge 4.10'da belirtilen değerleri doğrular niteliktedir.



Şekil 4.17: SDUMLA-FV için uygulamada elde edilen ROC eğrisi.

Çizelge 4.10: Mesafe metrikleri için elde edilen EHO değerleri.

Mesafe Metrikleri	SDUMLA-FV
Cosine (Mevcut)	%1.9078
Euclidean (Mevcut)	%2.1174
Manhattan (Mevcut)	%2.1593
Minkowski (Mevcut)	%2.1174
Cosine Euclidean (Önerilen)	%1.6771
Cosine Manhattan (Önerilen)	%1.6771
Cosine Minkowski (Önerilen)	%1.6562

Yapılan deney boyunca herhangi bir veri artırımı ya da ön işleme kullanılmamış ve önerilen kişisel dikkat mekanizmasının elde edilen performans üzerindeki mutlak etkisi incelenmiştir. Bununla birlikte, literatürde önerilen yöntemler, mümkün olduğunca yüksek bir doğrulama performansı elde etmek için veri artırımı ve ön işleme işlemlerini kullanmaktadır. SDUMLA-FV veri seti için literatürde elde edilen performans sonuçları Çizelge 4.11’de verilmiştir. Önerilen modelde çeşitli avantajlar sunan Öz dikkat mekanizması kullanılmasına rağmen literatürde elde edilen başarıya yaklaşamamıştır. Buna sebep olarak FVC protokolünün uygulandığı bu çalışmaya ters düşecek şekilde literatürdeki bazı çalışmalarda ya protokol kullanılmadığı ya da açık küme protokolünde kullanılan gerçek ve sahte çiftlerin hesaplanmasının farklı olduğu fark edilmiştir. Elde ettiğimiz EHO başarısını önemli hale getiren ve bu farklılığı konu alan çalışmalar literatürde vardır ve bu durum çalışmaları birbiriyle kıyaslamayı neredeyse imkansız hale getiren bir tutarsızlıktır (Eglitis ve diğ, 2021).

Çizelge 4.11: Literatürde SDUMLA-FV veri seti için elde edilmiş EHO değerleri.


Referans Çalışma	SDUMLA-FV
(Song ve diğ, 2019)	%2.35
(Yang ve diğ, 2019)	%0.94
(Xie ve Kumar, 2019)	%9.77
Önerilen Yöntem	%1.65

4.6 Halka Açık Avuç İçi İzi Veri Setinde İlgili Bölgesi Çıkarımı

Bu çalışmada kullanılan IITDTP veri seti, 230 kişinin iki elinden alınan, elleri cepheden gören toplam 2601 görüntüden oluşmaktadır (Kumar, 2008). Bu görüntüler, platformda kişiyi yönlendirmeden ve kişiye temas etmeden alındığı için birtakım ölçek ve kayma problemlerine sahiptir. Bu veri seti, farklı parmaklara takılmış, çeşitli sayıda yüzük kullanımının yanı sıra kopuk parmak yani uzuv kaybı gibi sıra dışı durumlar içeren görüntülere de sahiptir. IITDTP veri setine ait örnek bir görüntü Şekil 4.18'de gösterilmektedir (Kumar, 2008).



Şekil 4.18: IITDTP veri setine ait örnek avuç içi görüntüsü.




Şekil 4.19: Önerilen avuç içi izi çıkarma yöntemi adımları.

Önerilen ilgili bölgesi çıkarma yönteminin Şekil 4.19'da gösterildiği gibi 6 ana adımı vardır (Kocakulak ve Acir, 2022). Görüntü akışının sağlandığı ilk adımda, IITDTP veri setinde bulunan kullanıcılara ait sağ ve sol el görüntüleri görüntüleri işleyebilme adına tek bir klasör altında toplanmıştır. İkinci adımda, kapalı bir görüntüleme kutusunda toplanan görüntülerdeki düzensiz kontrast dağılımını dengelemek adına görüntülere CLAHE uygulanmıştır (Pizer, 1990). MediaPipe Hands'in içerdiği makine öğrenmesi tabanlı modeller, çok farklı aydınlatma koşullarında iyi sonuçlar verecek şekilde eğitilmiş olsa da, bu veri seti için CLAHE kullanılmış ve MediaPipe

Hands'in el işaretçilerini bulmaktaki başarısı artırılmıştır. Üçüncü adımda, kontrastı dengelenmiş görüntüler MediaPipe Hands çerçevesinden geçirilerek el işaretçileri Şekil 4.20'deki gibi belirlenmiştir.

Dördüncü adımda ise, el görüntülerinin orta parmağa göre doğrultma işlemi gerçekleştirilmiştir. Bilindiği üzere IITDTP veri setindeki bazı görüntülerde, görüntü alımı sırasında temassız ve kılavuzsuz görüntüleme nedeniyle, kayma söz konusudur. Yani elin platformda beklenen oryantasyonda olmadığı görülmektedir. Elin yer değiştirmesi, esasen orta parmağın y eksenine paralel olmamasıdır. Çıkarılan 5 numaralı el işaretçisi ile 9 numaralı el işaretçisi arasındaki açıyı veya 17 numaralı el işaretçisi ile 9 numaralı el işaretçisi arasındaki açıyı kullanarak olası doğrultma işlemi gerçekleşir. Aradaki açıyı tahmin etmek için iki açı arasından daha büyük olan açı tercih edilir. Böylece dönme açısı θ , Denklem 4.6.1'deki gibi hesaplanır. Bu denklemde x_1 , y_1 , 9 nolu el işaretçisinin koordinatlarıdır ve x_2 , y_2 , 5 nolu el işaretçisinin veya 17 nolu el işaretçisinin koordinatlarıdır.



Şekil 4.20: CLAHE sonrası el işaretçileri belirlenmiş avuç içi görüntüsü.

$$\theta = \arctan\left(\frac{y_2 - y_1}{x_2 - x_1}\right)\left(\frac{180}{\pi}\right) \quad (4.6.1)$$


Beşinci adımda, belirlenen el işaretçilerini kullanarak çıkarılacak ilgi bölgesinin doğruluğunu artırmak adına görüntülerin ağırlık merkezi hesaplanmıştır. Ağırlık merkezi yani moment değeri, piksel yoğunluklarının ağırlıklı ortalaması olarak tanımlanabilir (Kekre ve diğ., 2012). IITDTP'deki görüntüler, sadece görüntüsü alınan el ve görüntüleme sistemine ait arka planı içerdiğinden, görüntülere ait histogramlardaki bölgeleri ayıran uygun eşik değerleri belirlenirse, el ile arka planı birbirinden ayırmak mümkündür. Görüntülerin ağırlık merkezinin koordinatlarını bulmadan önce, 3 kanallı olan orijinal görüntüler gri ölçekli (grayscale) görüntülere çevrilmiş ve ikilileştirme için her gri ölçekli görüntüye Otsu'nun Eşikleme Yöntemi uygulanıp ideal eşikler bulunmuştur (Otsu, 1979). X_{centroid} ve Y_{centroid} olarak tanımlanan avuç içi görüntülerinin ağırlık merkezinin x ve y koordinatlarını bulmak için Denklem 4.6.2 ve Denklem 4.6.3 kullanılmıştır. Bu koordinatlar bulunurken m_{pq} olarak tanımlanan moment değerleri Denklem 4.6.4'teki gibi hesaplanmıştır. Bu denklemde i ve j değerleri, görüntü pikselleridir ve $f(i,j)$, Otsu yöntemiyle ikilileştirilmiş avuç içi görüntüsüdür. Momentler hesaplanırken görüntüye ait uzamsal piksel değerleri taranarak ikili bir blobun merkezinin koordinat değerleri bulunur. Bu çalışmada, önerilen yöntemin başarısını perçinlemek için hesaplanan X_{centroid} ve Y_{centroid} değerleri kullanılır. Şekil 4.21'de gösterildiği gibi, tespit edilen 0, 5 ve 17 numaralı el işaretçileri ile oluşturulan üçgensel bölge içinde, mavi ile gösterilen

merkeze ait koordinatlar bulunuyorsa, önerilen yöntemin etkinliğini doğrulanmış olur. Eğer bulunmuyorsa, görüntüye ait ilgi bölgesi doğru bir biçimde çıkarılamamış demektir.

$$X_{Centroid} = \frac{m_{01}}{m_{11}} \quad (4.6.2)$$

$$Y_{Centroid} = \frac{m_{10}}{m_{11}} \quad (4.6.3)$$

$$m_{pq} = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} i^p j^q f(i, j) \quad (4.6.4)$$



Şekil 4.21: Avuç içi izi bölgesi doğru bir şekilde belirlenmiş görüntü örneği.

Bu deneylerde, Mediapipe Hands ile algılanan el işaretçileri, avuç içi sınırlarını bulmak için kullanılmıştır. Tespit edilen el işaretçileriyle, doğrultulmuş görüntüde ilgi bölgeleri adaptif olarak çıkarılmıştır. Doğrultulmuş görüntü üzerinde 0, 5 ve 17 numaralı el işaretçilerinin x ve y piksel koordinatlarından faydalanıp, çıkarılan ilgi bölgelerinin sınırları bulunmuştur. 0 numaralı el işaretçisinin y koordinat değeri, y eksenindeki alt sınır olarak kullanılırken, üst sınır olarak 5 ve 17 numaralı el işaretçilerinin y koordinat değerlerinin büyük olanı seçilmiştir. x eksenindeki alt sınır olarak 0 numaralı el işaretçisinin x koordinat değeri kullanılırken, x eksenindeki üst limit olarak ise, 17 numaralı el işaretçisinin x koordinat değeri kullanılmıştır. Bu adımlar takip edilerek ilgi bölgeleri 2601 görüntü için çıkarılmıştır.

Bu çalışmada önerilen yöntemin performansı, doğruluk ve ortalama ilgi bölgesi çıkarma süresi kullanılarak hesaplanmıştır. Doğruluk, Denklem 4.6.5'te gösterildiği gibi, düzgün olarak çıkarılan ilgi bölgelerinin sayısının veri setindeki toplam görüntü sayısına oranı olarak tanımlanır (Damak ve diğ., 2018). Herhangi bir ilgi bölgesi çıkarımını doğru olarak sınıflandırmak için, çıkarılan ilgi bölgesi görüntüsü, yalnızca avuç içi bölgesini içerip görüntüleme sistemine ait arka plan görüntüsü içermemelidir.

$$\text{Doğruluk} = \frac{\text{İlgi Bölgesi Doğru Çıkarılan Görüntü Sayısı}}{\text{Toplam Görüntü Sayısı}} \quad (4.6.5)$$

IITDTP veri seti, Şekil 4.22'de gösterildiği gibi çeşitli el görüntülerini içerir (Kumar, 2008). Şekildeki görüntüler kına, yüzük ve parmak eksikliği gibi zorlayıcı şartlara sahip olsa da ilgi bölgelerini çıkarma adına el işaretçileri MediaPipe Hands tabanlı yöntem ile dinamik olarak belirlenebilmektedir. Ulaşılan doğruluk

Çizelge 4.12: Elde edilen avuç içi izi çıkarımı doğruluk ve süre değerleri.


İlgi Bölgesi Çıkarma Yöntemi	Doğruluk (%)	Zaman (saniye)
(Zambre ve Mishra, 2019)	%98	8.27
(Kocakulak ve Acir, 2022)	%93	2.64

performansını, çeşitli görüntü işleme yöntemleri ile ya da orijinal MediaPipe Hands çerçevesine ait parametrelerde değişiklik yaparak artırmak mümkün iken, bu çalışma MediaPipe Hands'ın ilgi bölgesi çıkarmadaki saf kabiliyetine odaklanmaktadır. Önerilen yöntemin hafif bir yapıya sahip olması ve oldukça hızlı çalışması mobil uygulamalarda bu yöntemin tercih edilmesini sağlayacaktır.



Şekil 4.22: IITDTP veri setindeki görüntüler ve belirlenen el işaretçileri.

Tüm deneyler, Intel(R) Core(TM) i5-2450M CPU @ 2.50GHz, 8.00 GB, 64 bit özellikteki Hp Probook 4540s marka bir bilgisayarda gerçekleştirilmiştir. Görüntü başına ortalama ilgi bölgesi 2.64 saniyede çıkarılmıştır. Görüntü başına gereken çıkarma süresini niteleyen bu ortalama değer, aynı prosedür 1000 kez tekrarlanarak hesaplanmıştır. 2601 görüntüden 2419'una ait ilgi bölgeleri düzgün bir biçimde çıkarılırken, 182'sinin ilgi bölgesi düzgün çıkarılamamıştır. Bu yüzden ilgi bölgesi çıkarımındaki doğruluk %93 olarak hesaplanmıştır. Tüm bu değerler Çizelge 4.12'de gösterilmektedir. MediaPipe Hands yardımı ile belirlenip çıkarılan avuç içi izi bölgelerine dair örnek çıktı Şekil 4.18'deki görüntüye ait avuç içi izi bölgesi olan Şekil 4.23'te gösterilmektedir.



Şekil 4.23: Çıkarılan örnek avuç içi izi görüntüsü.

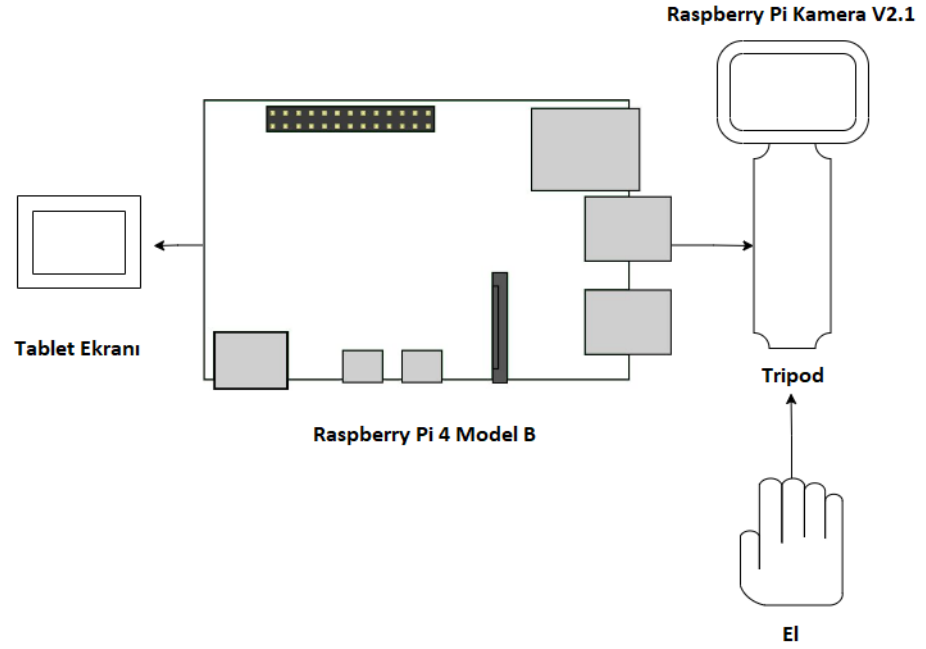
Bu çalışmada, avuç içi izi dışında avuç içi damarı ve el sırtı damarı görüntüleri için kullanılabilir bir yöntem önerilmiştir. Şekil 3.15'teki 0, 9, 5 ve 17 numaralı işaretçiler kullanılarak amaçlanan ilgi bölgeleri çıkarılmıştır. Bu çalışmada, önerilen yöntemin ilgi bölgelerini bulmakta ne kadar uyarlanabilir olduğu incelenmiştir. Avuç içi izi tanıma performansı sadece ilgi bölgesi çıkarımına bağlı olmadığından, bu çalışmada sadece ilgi bölgelerinin çıkarımına odaklanılmıştır. Çizelge 4.12'de görüldüğü gibi ulaşılan doğruluk ve hız değerleri, literatürde bu konuyu ele alan başka bir çıkarım algoritmasının ulaştığı değerlerle karşılaştırılmıştır. Yapılan bu çalışma ile MediaPipe Hands'in avuç içi izi ilgi bölgesi çıkarımında hız ve doğruluk açısından vadettiği potansiyel ortaya konmuştur.

4.7 Makine Öğrenmesi Destekli Avuç İçi İzi Görüntüleme Platformu Tasarımı

COVID-19 sonrası temassız sistemlere duyulan ihtiyaç fark edildiğinden, kullanıcının platforma dokunmasına ihtiyaç duymayan ve avuç içi izini uzaktan algılayan düşük maliyetli bir görüntüleme sistemi önerilmiştir. Bu çalışmada gerçek zamanlı bir video akışında kullanıcının avuç izlerinin ilgi alanı dinamik olarak çıkarılmıştır. Gerçekleştirilen deneyler sırasında, MediaPipe Hands'in mobil avuç içi izi görüntüleme uygulamalarında hız ve doğruluk sağlama potansiyeli fark edilmiştir. Bu çalışma, kontrol edilmeyen ortam ışığına maruz kalan, düşük maliyetli ve hijyenik avuç içi izi görüntüleme sistemleri için MediaPipe Hands'in oldukça önemli olduğunu göstermektedir. Garcia-Martin ve Sanchez-Reillo, (2021), tarafından önerilen mobil cihaz ekranında anlık görüntüleme olanağının kullanıcıya verilmesinin yanında hijyenik bir platform tasarımının sağlanması ayrıca önemlidir.

Literatürde genellikle temasa dayalı tasarımlar yaygın iken, temassız avuç içi izi görüntüleme sistemlerini konu edinen çalışmalar da oldukça fazladır. Morales ve diğ., (2012), iki plaka arasında dikey hareketle bir elin görüntülerini yakalayan çoklu örneklemeli bir görüntüleme cihazı tasarlamıştır. Temassız yapısı ile önerilen tasarım, el geometrisi ve avuç içi izi görüntülerini aynı anda yakalayabilmektedir. Aykut ve İkinci, (2015), iris lensli ve düşük maliyetli bir CCD kamera kullanan sistem geliştirmiştir. Önerilen tasarımla, kamera ile kullanıcının eli arasındaki mesafeyi sabitleyerek, kullanıcının eli ile kamera arasındaki mesafenin değişmesi sorununu çözmüşlerdir. Xiao ve diğ., (2019), yarı kapalı bir kutudan faydalanarak doğal ışık altında düşük maliyetli bir avuç izi görüntüleme cihazı tasarlamıştır. Bu cihaz, kullanıcının elini kısmen yerine tümünden görüntüleyen bir yapıdadır.

Gerçekleştirdiğimiz bu çalışmada ise, tablet ekranına yansıtılan görüntü sayesinde kullanıcının eli ile kamera arasındaki mesafe kabaca hesaplanmaktadır ve kullanıcı ekran yardımıyla yönlendirilebilmektedir. Bu özellik, kullanıcıları görüntüleme platformunda fiziki herhangi bir kısıtlama getirmeden yönlendirdiği için, nispeten



Şekil 4.24: Avuç içi izi görüntülemek için kurulan deney düzeneği.

kullanıcı dostudur. Herhangi bir kapalı veya yarı kapalı kutu kullanılmadan, düşük maliyetli bir sistem tasarımı sağlayan bu çalışmada, Raspberry Pi Kamera V2.1 kamera, Raspberry Pi 4 Model B ve MediaPipe Hands çerçevesiyle, doğal ışık altında gerçek zamanlı olarak avuç izi görüntüleri toplanmıştır.


Kurulan deney düzeneği Şekil 4.24'te gösterilmiştir. Bu görüntüleme sistemi Şekil 4.25'te gösterildiği gibi bir gömülü sistem, ona ait kamera, tripod ve tablet ekranından oluşmaktadır. Bu çalışmada düşük maliyetli ve kompakt bir tasarıma sahip oldukları için Raspberry Pi 4 Model B ve Raspberry Pi Kamera NoIR V2.1 beraber kullanılmıştır. Raspberry Pi Kamera Modülü, sabit odaklı lense sahiptir ve bünyesinde 8 megapiksel Sony IMX219 görüntü sensörü barındırır (Altay ve Gumus, 2021). Bu kamera, yakın kızılötesi bir kamera kategorisindedir. Kamera, çeşitli çözünürlük ve saniye başına düşen kare oranında videoyu destekler. Jetson Nano ve Raspberry Pi 4 Model B tarafından desteklenen bu kamera, ilgili kartın üstünde bulunan küçük sokete bir şerit kablo ile Şekil 4.26'daki gibi bağlanır. Bu kartlarla uyumlu olmasının yanı sıra, kameranın fiyatının Amerikan Doları bazında uygun olması, boyutlarının küçük ve ağırlığının az olması, bu tarz görüntüleme sistemlerinde kullanımını kolaylaştırır. Kamera, elleri yakalamak için bir tripoda monte edilmiş ve sonrasında görüntü yakalamak için kamera ve kullanıcı eli, görüntüleme platformunun üzerine yerleştirilmiştir. İlk olarak, kamera ile görüntüler alınıp sonrasında kullanıcının kameraya olan anlık mesafesi hesaplanmıştır. El görüntüsü Raspberry Pi üzerinde MediaPipe Hands çerçevesi yardımıyla işlenirken, mevcut durum ve belirlenen ilgi bölgeleri tablet ekranında takip edilebilmektedir. Görüntüleme platformu üzerinde kullanıcının eli yoksa Şekil 4.27'deki görüntü ekranda görünmektedir.




Şekil 4.25: Kurulan görüntüleme sistemi elemanları.

Kullanıcılara, platformdaki elin pozisyonu hakkında geri bildirim vermek için Python tabanlı bir yazılım çözümü kullanılmıştır. Eğer el tam olarak platformda değilse Şekil 4.28'deki görüntü ekranda görünmektedir. Eğer el tam anlamıyla platformun üzerindeyse, MediaPipe Hands çerçevesi tarafından sağlanan el işaretçileri kullanılarak işaret parmağı, orta parmak ve yüzük parmağının konumu Şekil 4.29'daki gibi sabitlenip bu parmakların boğumlarının pozisyonları izlenmiştir. Ekrandaki renk göstergeli bu 3 parmaktan pozisyon onayı alındıktan sonra yapılan mesafe hesabı ile avuç izi için ilgi bölgesi çıkarma işlemine geçilmektedir.

Tasarlanan sistemdeki akış şu şekildedir: El ile kamera arasındaki mesafeyi bulmak için öncelikle el, MediaPipe Hands tarafından algılanır. El platformda mevcutsa, gerçek mesafeyi santimetre cinsinden hesaplamak için el işaretçisi 5 ve el işaretçisi 17 kullanılır. Bu 2 nirengi noktasının x ve y piksel koordinat değerleri arasındaki uzaklık esas alınarak gerçek mesafe doğru bir şekilde bulunurken, döndürme problemleriyle




Şekil 4.26: Raspberry Pi ve Raspberry Pi Camera bağlantı ilişkisi.



Şekil 4.27: El platformda değilken ekrandaki görüntü.

uğraşmamak için Öklid mesafesi hesaplanır. El işaretçilerinin Öklid mesafesi ile bunlara karşılık gelen gerçek kamera mesafesi arasındaki ilişkiyi bulmak için ikinci dereceden bir fonksiyon tanımlanarak, gerçek mesafe eğri uydurma yardımıyla kabaca tahmin edilir. Elin kameraya olan gerçek uzaklığına dair tutulan 50 örnekle ile el işaretçilerinin x ve y koordinat değerleri, ellinci örnek sonrası platforma konulan herhangi bir elin kameraya uzaklığına dair bir öngörüde bulunabilmektedir. Bu regresyon problemindeki örnek sayısı kabaca 50 olarak belirlenmiştir. Tablet ekranı, yakalamanın gerçek zamanlı video akışını görüntülemek için kullanılır. Böylece herhangi bir fiziksel mesafe sensörü kullanılmadan kullanıcının eli ile kamera arasındaki mesafe sabitlenir. El platformda değilse ya da tam istenilen pozisyonda değilse ya da tam istenilen pozisyondaysa, tüm bu durumlar, tablet ekranındaki kırmızı, sarı ve yeşil renkli uyarılarla kullanıcıya belirtilmektedir.



Şekil 4.28: El tam olarak platformda değil iken ekrandaki görüntü.

Kısacası deney esnasında kamera, sürekli bir video akışında avuç içi izi görüntülerini yakalamaktadır. Kullanıcı elini kameranın önüne herhangi bir fiziksel yönlendirme olmadan yerleştirebilir, çekim sırasında elini istediği gibi hareket ettirebilmektedir. Eğer kullanıcı avuç içi izi görüntüsü kaydedilsin istiyorsa, tablet ekranındaki yazılımsal yönlendirmelere uyararak bunu gerçekleştirebilmektedir.


Tanım sistemleri doğası gereği hızlı çözümler sunar ve günlük hayatta güvenlik ve mahremiyet amacıyla kullanılır. Bu çalışmada, bir avuç içi izi görüntüleme platformu ve bu görüntüleme platformunda makine öğrenmesi tabanlı bir el takip çerçevesi olan Mediapipe Hands'in kullanılması önerilmiştir. İlgi bölgesi çıkarımı



Şekil 4.29: El tam olarak platformda iken ekrandaki görüntü.


için bu çerçeve tarafından sağlanan el işaretçileri kullanılmıştır. Tanıma performansı sadece ilgi bölgesi teşhisine bağlı olmayıp, uygulanan öznelik çıkarma yöntemleri ve kullanılan parametreler gibi diğer faktörlere de bağlı olduğundan, bu çalışma sadece bir görüntüleme sistemi tasarlamayı ve yakalanan avuç içi izi görüntülerinin ilgi bölgelerini, Bölüm 4.6'da detaylandırılan adımları takip ederek çıkarmayı amaçlamıştır. Geliştirilen görüntüleme platformu etkili, temassız ve hijyeniktir. Gelecekteki çalışmalarda, yeterli sayıda kullanıcı, örnek ve oturum içeren büyük ölçekli bir avuç izi veri tabanı yayınlanacaktır. Yeterli kişi sayısı, her iki elin kullanılması, farklı seanslarda örnek toplanması, bu seanslar arasında gün veya saat olarak makul bir fasıla bulunması ve tüm bu beklentilerin gerçekleşmesi neticesinde toplanan toplam görüntü sayısının literatürdeki muadil veri setlerini geçip, derin öğrenme modellerinin eğitilmesine imkan sağlayacak kapasitede olması, oluşturulacak bir veri setinden beklenen en önemli özelliklerdir. Bu özelliklerin dışında görüntü formatı olarak seçilen sıkıştırma formatının görüntü kalitesinde minimum bozulma ve kayba neden olması, alınan görüntünün yeterli bir çözünürlüğe sahip olması, boyutlarının ve kanal sayısının muadillerini aratmaması beklentiler dahilindedir (Zhang ve diğ., 2021). Halka açık olması beklenen bu veri setleri, erkek ve kadın gönüllülerin sayısı eşit olacak şekilde oluşturulmalıdır. Bu gönüllülerin yaşlarının çeşitli olması ve bu yaşların dağılımının homojen olması beklenir. Kullanıcıların her iki elinden değişik oryantasyonlarda ve pozlarda toplanan görüntülerin orta, işaret ve yüzük parmaklar başta olmak üzere aksesuar içeren hallere sahip olması da sıra dışı durumlarla karşılaşıldığında gösterilecek başarıyı sınavabilme adına önemlidir. Son olarak, oluşturulacak veri setinin halihazırda çıkarılmış ilgi bölgesi içeren görüntüleri barındıran bir alt klasör içermesi oldukça önemlidir. Bu sayede önerilecek yeni ilgi bölgesi çıkarım yöntemlerine karşılaştırma yapabilecekleri bir zemin sağlanmış olur.

Önerilen sistem, Şekil 4.30'da gösterildiği gibi el işaretçilerini bulur ve ilgi bölgesini Şekil 4.31'deki gibi çıkarır. Kullanıcının konforunu artırmak için cihaz tasarımındaki mevcut eğilim kutudan çıkmış bir yapıya doğru olduğundan, görüntü alımı için temassız bir yöntem önerilmiştir. Temassız yöntem, çeviri ve döndürme sorunlarına neden olsa da, MediaPipe Hands ve önerilen yazılım, bu sorunları etkin bir şekilde çözmektedir. Böylece COVID-19 sonrası, görüntü alımı sırasında cihaz yüzeyi ile kullanıcının eli arasındaki fiziksel temas kesilecektir. Bu çalışmanın sağladığı bir diğer avantaj, MediaPipe Hands kullanımı ile platformdan elde edilen görüntünün sağ ya da sol el olduğu bilgisine, kullanıcıların bu çerçeve yardımıyla ulaşabilmesidir.



Şekil 4.30: Görüntüleme platformundaki el ve ona ait el işaretçileri.

Tüm deneyler, 4 GB RAM ve 64 bit dört çekirdekli işlemciye sahip Raspberry Pi 4 Model B üzerinde gerçekleştirilmiştir. Önerilen ilgi bölgesi çıkarma yöntemi, Visual Studio IDE kullanılarak Python 3.7’de uygulanmıştır. Sistemi oluşturmak için Python betiği kullanılmış ve MediaPipe Hands, OpenCV kullanılarak içe aktarılmıştır.




Şekil 4.31: Çıkarılan örnek avuç içi izi görüntüsü.

4.8 Makine Öğrenmesi Destekli Çerçevenin Çok Kipli Tasarımlara Etkisi


El bölgesi çeşitli biyometrik özellikleri bünyesinde barındırdığı için, MediaPipe Hands’ten faydalanarak Şekil 4.32’de gösterilen parmak damarı, tırnak, parmak eklemi gibi parmak tabanlı biyometrik özelliklere ait ilgi bölgelerini çıkarmak mümkündür. Bunun için el görüntülerinde parmağın bulunduğu bölgeye odaklanmak gerekmektedir. Bu çalışmada kullanılan Technocampus Hand Images veri seti, 100 denekten alınan 6000 görüntüden oluşur (Faundez-Zanuy ve diğ., 2014). Bu multispektral bir veri setidir ve görünür, yakın kızılötesi ve termal olmak üzere 3 tip görüntü içerir. Her kategori 100 denegin ellerinin el sırtının ve el içlerinin her biri için alınan 10 örnekten oluşmaktadır. Ancak erişilen veri seti, Çizelge 4.13’te gösterildiği gibi 3 farklı spektrumda, 111 denegin ellerinin iç ve dış yüzleri için toplanmış 6000’den fazla görüntü içermektedir.

Bu çalışmada veri setinin termal görüntüleri kullanılmamıştır. Önerilen çerçeve, bu spektrumdaki görüntülerle eğitilmediği için termal görüntüler üzerinde iyi sonuçlar vermediğinden, deneyler 4278 görüntü üzerinde gerçekleştirilmiştir. Bu veri setine ait, elin iç ve dış taraflarını görünür ve yakın kızılötesi ışık altında gösteren örnek görüntüler Şekil 4.33’teki gibidir. Şekilde a) ve c) görüntüleri kızılötesi ışık kullanılarak avuç içi ve el sırtı için alınırken, b) ve d) görüntüleri ise, görünür ışık altında alınmıştır (Faundez-Zanuy, 2014).



Şekil 4.32: El tabanlı biyometrik özellikler (Anitha ve Rao, 2015).

Önerilen parmak bölgesi çıkarma yöntemi 4 ana adımdan oluşmaktadır. Bu adımlar Şekil 4.34’te gösterilmiştir. Technocampus Hand Image veri setinde bazı görüntülerde kayma sorunu vardır. Kayma sorunu olan bu görüntülerde, orta parmak y eksenine paralel hale getirilerek elin yer değiştirme sorunu ortadan kaldırılabılır. Orta parmaktan çıkarılan 2 adet el işaretçisi kullanılarak yer değiştirme sorunu giderilir. x_1, y_1 piksel koordinatlarına sahip 9 ve x_2, y_2 piksel koordinatlarına sahip 12 nolu el işaretçileri arasındaki açı kullanılarak, Denklem 4.6.1’deki gibi kayma açısı θ hesaplanabilir.




Şekil 4.33: Technocampus veri setinden alınan örnek görüntüler.

MediaPipe Hands’in tespit ettiği el işaretçileri, parmak bölgesinin sınırlarını bulmak için kullanılmıştır. Algılanan işaretlerle hizalanmış görüntü üzerinde, Şekil 3.15’te gösterilen 5, 9, 12 ve 13 numaralı işaretçilerinin x ve y piksel koordinatları kullanılarak, orta parmak için parmak bölgesinin sınırları belirlenmiştir. Dikdörtgensel parmak bölgesi çıkarılırken yatayda ve dikeyde en uzak noktalar belirlenmiştir. 9 nolu

Çizelge 4.13: Technocampus veri seti ve özellikleri.

	Görünür	Kızılötesi	Termal
El Sırtı Görüntüleri	1070	1070	1070
El İçi Görüntüleri	1068	1070	1070
Toplam Görüntü	2138	2140	2140



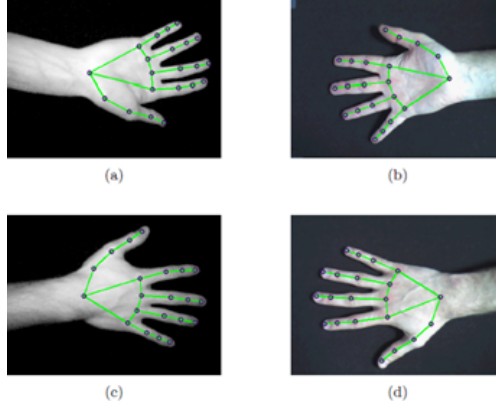
Şekil 4.34: Önerilen parmak bölgesi çıkarma yöntemi adımları.

el işaretçisinin y koordinatı, y ekseninde alt limit olarak, 12 nolu el işaretçisinin y koordinatı, y ekseninde üst limit olarak kullanılmıştır. 5 nolu nirengi noktası ile 9 nolu nirengi noktası arasındaki orta noktanın x koordinatı, x ekseninde alt sınır olarak, 9 nolu nirengi noktası ile 13 arasındaki orta noktanın x koordinatı, x ekseninde bir üst sınır olarak kullanılmıştır. Bu el işaretçileri arasındaki orta noktalar, işaret parmağı, orta parmak ve yüzük parmağı arasındaki parmak ağlarına karşılık gelir. Değişen aydınlatmaya rağmen MediaPipe Hands, görünür ve yakın kızılötesi görüntülerin iç ve dış taraflarında el işaretçilerini yüksek doğruluk oranıyla bulur. Orta parmağın eğriliğinden dolayı çıkarılan parmak bölgesi zaman zaman arka plan bilgisi içerebilir. Çarpık parmaklarda karşılaşılan bu problemi ortadan kaldırmak için arka plan çıkarma yöntemleri kullanılabilir ve bu sorun çözülebilir ancak bu durum bu çalışmanın kapsamında değildir (Al-Nima ve diğ., 2017).

Bu çalışmada, el görüntülerinin iç ve dış taraflarını içeren kapsamlı bir veri seti olduğu için Technocampus Hand Image kullanılmıştır. Bu veri seti, içerdiği yakın kızılötesi görüntüler ile avuç içi damarı ve parmak damarı biyometrisi için de test amaçlı kullanılabilir. Ayrıca, bu veri seti, içerdiği görünür spektrum görüntüleri ile parmak eklemleri, tırnaklar ve avuç içi izi için de kullanılabilir (Michael ve diğ., 2010). Bu çalışmada, Technocampus Hand Image veri setinin görünür ve yakın kızılötesi spektrumunda elde edilmiş görüntülerinde el işaretçilerini bulmak için MediaPipe Hands çerçevesi kullanılmıştır. Şekil 4.33'teki örnek görüntüler için tespit edilen el işaretçileri Şekil 4.35'te gösterilmiştir. Farklı aydınlatma koşulları ve el pozlarına rağmen, MediaPipe Hands görünür ve yakın kızılötesi spektrumdaki görüntülerin çoğunda oldukça iyi performans sergilemiştir.

Çizelge 4.14: Elde edilen parmak bölgesi çıkarımı doğruluk değerleri.

	Görünür	Kızılötesi	Doğruluk
El Sırtı Görüntüleri	%98.50	%95.98	%97.24
El İçi Görüntüleri	%99.71	%95.70	%97.70
Toplam Görüntü	%99.11	%95.83	%97.47



Şekil 4.35: Örnek görüntülerde belirlenen el işaretçileri.

Technocampus Hand Image veri setinde el işaretçilerinin çıkarım başarısı için elde edilen sonuçlar Çizelge 4.14'te verilmiştir. Görünür spektrumdaki 1068 palmar görüntü için 1065 görüntünün el işaretçileri %99.71 doğrulukla tespit edilmiş ve parmak bölgeleri doğru bir biçimde bulunmuştur. 1070 yakın kızılötesi palmar görüntüsünden 1054'ünün el işaretçileri %95.70 doğrulukla tespit edilmiş ve bu görüntülerin parmak bölgeleri doğru bir şekilde bulunmuştur. Görünür spektrumdaki 1070 dorsal görüntü için, 1027 görüntünün el işaretçileri %98.50 doğrulukla tespit edilmiş ve parmak bölgeleri doğru olarak bulunmuştur. 1070 yakın kızılötesi dorsal görüntüden 1024'ünün el işaretçileri %95.98 doğrulukla tespit edilmiş ve bu görüntülerin parmak bölgeleri doğru bir şekilde bulunmuştur. Görüldüğü gibi, çalışmanın tekrarlanabilirliği için MediaPipe Hands'in vanilya versiyonu tercih edilmesine rağmen, elde edilen oranlar yeterince yüksektir. Palmar ve dorsal görüntülerde elde edilen doğruluk sonuçları birbirine çok yakın olup, sırasıyla %97.70 ve %97.24'tür. Ancak, yakın kızılötesi ve görünür spektrumlarda elde edilen sonuçlar biraz farklıdır ve sırasıyla %95.83 ve %99.11'dir. Yakın kızılötesi görüntüler için ışığın eşit olmayan dağılımı nedeniyle, elde edilen doğruluk sonuçları görünür ışıktaki görüntülerden daha azdır. El işaretçilerinin çıkarılması için elde edilen toplam doğruluk %97.47'dir. MediaPipe Hands uygulanmadan önce görüntüler üzerinde uyarlanabilir histogram eşitleme ve morfolojik filtreleme gibi görüntü işleme teknikleri kullanılarak ve vanilya versiyonunun parametreleri ayarlanarak, el işaretçileri çıkarma başarısı kolayca artırılabilirdi. Ancak bu çalışma sadece önerilen yöntemin etkinliğini göstermeyi amaçlamaktadır.

Bu çalışmadaki tüm deneyler, 64-bit ARM CPU ve 128-core NVIDIA GPU ile Jetson Nano üzerinde gerçekleştirilmiştir. Önerilen parmak bölgesi çıkarma yöntemi, Visual Studio IDE kullanılarak Python 3.7'de uygulanmıştır. MediaPipe Hands, Python'da OpenCV kullanılarak içe aktarılmıştır.

Bu çalışmada parmak damarı, parmak izi, parmak eklemi ve tırnak görüntülerinde kullanılacak adaptif bir parmak bölgesi çıkarma yöntemi önerilmiştir. Bölge çıkarımının tanıma performansı üzerindeki etkisini değerlendirmek yerine, önerilen yöntemin biyometrik bilgi içeren bölgeleri bulmadaki uyarlanabilirliği incelenmiştir. Tanıma performansı sadece ilgilenilen bölgeye değil, öznel çıkarma yöntemleri ve bu işlemler için kullanılan parametreler gibi diğer faktörlere de bağlı olduğundan, bu çalışmanın amacı basitçe parmak bölgelerini çıkarmaktır. Bu çalışma, MediaPipe

Hands'i parmak bölgesi çıkarıcı olarak kullanarak, herhangi bir tanıma sistemi için elde edilen el görüntülerinden en az 2 farklı parmak tabanlı biyometrik özelliğin aynı anda çıkarılabilmesinin mümkün olduğunu göstermiştir. MediaPipe Hands çerçevesi, el işaret dili tanıma ve jest tanıma gibi el takip uygulamaları için geliştirilmiş olsa da, yavaş yavaş biyometrik amaçlarla kullanılmaya başlanmıştır ve daha da popüler hale gelecektir. Tırnaklar için Şekil 3.15'teki 11 ve 12 numaralı işaretçiler kullanılarak, parmak damarı için 10 ve 11 numaralı işaretçiler kullanılarak ve son olarak avuç içi izi ve avuç içi damarı için 0, 5 ve 17 numaralı işaretçiler kullanılarak amaçlanan ilgi bölgeleri çıkarılabilir. Önerilen yöntem veya benzeri bir makine öğrenimi tabanlı çözüm sayesinde, el görüntülerinden sağlanan çoklu ilgi bölgesi çıkarımı, çok kiplilik açısından biyometrik sistemlere güvenilirlik kazandıracaktır.


4.9 Görüntü İşleme Destekli Damar Görüntüleme Cihazı Tasarımı

Bu çalışma kapsamında görüntü işleme yöntemlerini kullanan bir platform tasarımı sunulmuştur. Şekil 4.36'da gösterilen LG marka G4 model cep telefonuna ait dahili CMOS tipi kameranın kullanıldığı tasarımda, yine telefona ait kızılötesi ışıktan ve flaştan, ışığa ihtiyaç duyulan durumlarda faydalanılmıştır. Alınan görüntüde oldukça sınırlı oranda kontrast oluşturabilen bir yöntem olan yansıtma tipi aydınlatma yöntemi kullanılarak parmak damarı görüntüleme işlemi tamamlanmıştır. LED sayısı, dalga boyu ve konumu konusunda bir tasarım uygulamasına girişime adına aydınlatma tekniği olarak geçiş yerine yansıtma yöntemi seçilmiştir. Zira damar görüntülerinde elde edilen kontrast, bahsi geçen bu ve bunun gibi faktörlerden etkilenmektedir.



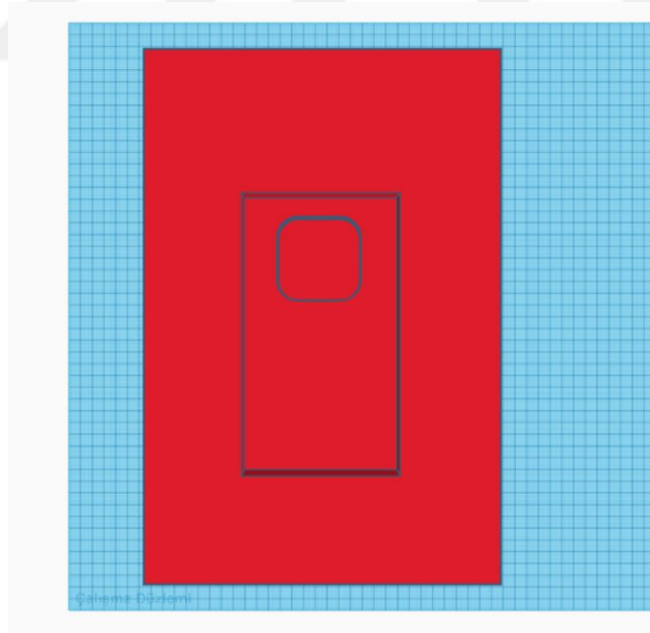
Şekil 4.36: LG G4 telefon ekranı ve kamerası.

"Tinkercad" adlı ücretsiz tasarım programı kullanılarak oluşturulan platform tasarımına ait önden ve üstten görünüş sırasıyla Şekil 4.37 ve Şekil 4.38'deki gibidir. Şekil 4.38'de görülen yuva, telefonun sabit bir tablet ekranı olarak kullanıcıya hizmet etmesini sağlamaktadır. Telefona ait arka kamerayı ve ışıkları, telefonun konulduğu yuvanın ortasına açılan oyukta tutan bu tasarım sayesinde, görüntüyü anlık takip edebilme ve görüntüyü işleyip kontrastı artırma imkanları kullanıcıya verilmiş olur.



Şekil 4.37: Tasarlanan görüntüleme cihazının önden görünüşü.

Java programlama dili ve OpenCV kütüphanesi kullanılarak Android işletim sistemi için yazılan bir uygulama ile sağlanan görüntünün negatifini alma ve basit 2 boyutlu filtreler uygulamak gibi görüntü iyileştirme imkanları, alınan görüntüdeki damarları Şekil 4.39'daki gibi daha görünür kılar.



Şekil 4.38: Tasarlanan görüntüleme cihazının üstten görünüşü.


Geliştirilen bu tasarımda, telefon ekranının kullanıcıya arayüz olarak sunulması tasarıma ait en büyük avantajdır. Kızılötesi ışığın saçılma problemi yaşatması nedeniyle platformdaki ışığı yansıtma adına siyah ve 3 tarafı kapalı bir kutu şeklinde dizayn edilen yapı, kameranın ele veya parmağa olan uzaklığını 5 cm, 10 cm ve 15 cm olacak şekilde kademeli olarak değiştirebilme imkanını kullanıcıya tasarlanan esnek yapısı ve 1 adet ince ve siyah zemin plakasıyla sunmaktadır. Kamera pozisyonunun sabit olduğu platformda, elin bulunduğu zemini değiştirebilme adına kademeli bir tasarıma gidilmiştir. Çıkarılıp takılabilen platform zeminine sahip bu tasarım sayesinde, bu zeminin kameraya yaklaştırılıp uzaklaştırılabilmesi sağlanmıştır. Tasarlanan şekli cepheden gösteren Şekil 4.40'ta, kademeli uzaklığa izin veren takılabilir zemine ait bu tasarım boşlukları mavi renkle gösterilmektedir. Işığın düzgün dağılmasını sağlama adına difüzör kullanımına imkan veren tasarım boşluğu yine bu şekilde açık bir biçimde gösterilmektedir. Telefona ait yuvada, kamera ile kutu arasına ince bir plaka şeklinde difüzörün yerleştirilebilmesine olanak sağlayan bu yapı, ışığın homojen dağılmasını sağlama adına önemli bir ayrıntıdır. Bu çalışmadaki tasarım, Yongnuo YN160 / YN300 Led Işık Uyumlu difüzöre uyumlu olacak şekilde gerçekleştirilmiştir.



Şekil 4.39: Tasarlanan cihazda görüntü işleme imkan veren Android arayüzü.

Kullanıcının platformda elinin veya parmağının kaymaması adına platform tasarımında orta parmağı konumlandırırken kılavuz vazifesi görecektir çıkıntı noktaları oluşturulmuştur. Şekil 4.37'de gösterilen yeşil renkteki bu noktalar, elin kameraya olan uzaklığı kademeli olarak değiştirilse de, yeni oluşan düzende de yerini alacak şekilde yapılan tasarımda planlanmıştır. Bu sayede dönmeden veya kaymadan kaynaklanabilecek hataları en aza indirmek hedeflenmiştir.

Bu sistem sayesinde alınan örnek parmak damarı görüntüsü Şekil 4.41'deki gibidir. Alınan görüntüye uygulanan görüntü işleme filtreleri sayesinde elde edilen parmak damar görüntüsüne ait kontrastın artırılabilir olduğu, bu görüntüyü halka açık veri setlerine ait görüntülerle kıyaslayarak kolayca anlaşılabilir.




Şekil 4.40: Tasarlanan görüntüleme cihazının cepheden görünüşü.



Şekil 4.41: Tasarlanan cihazdan alınan örnek parmak damarı görüntüsü.

Bu amaçla, yansıtma tekniği ile alınmış Şekil 4.42'deki parmak damarı görüntüleri incelendiğinde, elde ettiğimiz Şekil 4.41'deki görüntüye ait kontrastın, yansıtma tekniği için muadillerinden ikisi olan bu görüntüye kıyasla yeterli olduğu görülecektir. Elde edilen görüntüdeki gürültüyü, Android ile OpenCV kütüphanesinin entegrasyonu sonucu sağlanan 2 boyutlu filtre seçenekleriyle, telefon ekranı üzerinden kayıt öncesinde gidermek mümkündür.



Şekil 4.42: Yansıtma tekniği ile elde edilmiş görüntü örnekleri a) (Zhang ve diğ, 2015) b) (Van Tien ve diğ, 2015).

5. SONUÇ VE ÖNERİLER

Tanıma sistemleri, başta parmak izi olmak üzere çeşitli biyometri türleri ile günlük hayatta sıkça karşımıza çıkmaktadır. Diğer biyometri türlerine göre farklı ve çeşitli avantajlar sunan parmak damarı biyometrisini konu edinen bu tez, parmak damarı konusunda makine öğrenmesinden faydalanan yayınları içeren kapsamlı bir literatür taraması sonucu tanıma, doğrulama ve görüntüleme üst başlıkları altında belirlenen birer problemi ele alıp, toplamda 3 farklı probleme çözüm üretmeye çalışmıştır.

Bu tezde ele alınan problemler ve sunulan çözümler şu şekilde sıralanabilir: Literatürde belirli sayıda kullanıcıdan alınan, doğrulama ve tanıma uygulamaları açısından yeterli sayıda örnek içeren kapsamlı bir parmak damarı veri seti olmadığından, bu tez öncelikle bu ihtiyaca karşılık vermeye çalışmıştır. COVID-19 nedeniyle veri toplayıp ilgili deneyleri tamamlamak mümkün olmadığından, 1600 kişiye ait onar adet görüntü içeren sentetik bir parmak damarı veri seti oluşturulup deneyler bu veri seti üzerinde gerçekleştirilmiştir. Oluşturulan sentetik veri seti, diğer araştırmacılar ve bu manada duyulan ihtiyaç düşünülerek paylaşımına açılmıştır. Bu veri setinin üretilip kullanılması, derin öğrenme uygulamalarını hedeflenen performans değerlerine ulaştırıp ulaştıramama konusunda fikir sahibi olmak adına önemlidir.

Eldeki bu veri seti ilk olarak, derin öğrenmenin tanıma uygulamalarında ihtiyaç duyduğu veri hacmi sorununa çare olduğundan yapılan deneylerde, kapsamlı bir veri setinin, elde edilen performans açısından çeşitli derin öğrenme modellerine sağladığı katkı gözlemlenmiştir. Bu sayede veri hacminin artmasının beklenen ama emin olunamayan pozitif etkiyi yaratmadığı bu tez kapsamında elde edilen düşük performans değerleri üzerinden görülmüştür. Bu sonucun ortaya çıkmasında, üretilen sentetik verinin deterministik yollarla yaratılmasının ve yine üretilen verinin halen toplamda yetersiz sayıda oluşunun etkisi yadsınamaz.

Tanıma ve doğrulama amacıyla tasarlanan derin ağlarda, empirik yollarla belirlenen, öğrenim aktarımı ve Öz dikkat mekanizmasını kullanan evrişimsel sinir ağları kullanılıp tez kapsamında literatürde elde edilen sonuçlara ulaşma konusunda çeşitli deneyler yapılmıştır. Ancak elde edilen performans sonuçlarının, literatürdeki sonuçları geçemediği görülmüştür. Bu konuda yaşanan başarısızlık, literatürdeki çalışmalardaki protokol eksikliğinden ve uygulanan adımlara dair bazı ayrıntıların paylaşılmamasından kaynaklanmaktadır. Bu deneyler sırasında, popüler sınıflandırma yöntemleri yerine derin öğrenmenin temel birimi olan ESA'nın yapısındaki son

katmanı sınıflandırıcı olarak kullanılmış ve özellik vektörleri arasındaki mesafeler ölçülmüştür. Geleneksel yöntemlerin aksine gelişen işlemci teknolojisiyle çeşitli imkanlar sağlayan ve sürekli bir gelişim içinde olan derin öğrenmeden faydalanıp halka açık veri setlerinde, çeşitli metrikler üzerinde literatürde elde edilen maksimum performans değerlerini yakalayıp geçmek hedeflenmiştir ancak kısmen başarılı olunmuştur.

Bu tezde sentetik görüntüler kullanılarak "Jetson Nano 4 GB" adlı gömülü sistem yardımıyla bir tanıma uygulaması gerçekleştirilmiştir. Tkinter ile tasarlanan kullanıcı arayüzü, MySQL ile oluşturulan veri tabanı ve kullanıcılara ait görüntüleri Google'a ait "Teachable Machine" adlı web arayüzü ile eğitilip dışa aktarılan model ağırlıkları kullanılarak, 1600 kişiye hitap eden bir tanıma uygulaması gerçekleştirilmiştir.

Bu tez kapsamında LG marka G4 model telefon ve sahip olduğu kızılötesi ışık kullanılarak, Android için yazılan Java tabanlı arayüz ile kullanıcı dostu bir parmak damarı görüntüleme cihazı, aydınlatma tekniği olarak geçiş yerine yansıtma kullanılarak tasarlanmıştır. Bu sebeple tasarlanan cihazın boyutları artmıştır. Bu cihaz sayesinde eli cepheden gören ham el görüntülerine erişim sağlanmıştır. Tasarlanan görüntüleme sistemine dair ayrıntılar açıkça belirtilirken, kameranın ele olan uzaklığı değişen zemin uzaklığı ile ayarlanabilir özellikte tasarlanmıştır. Sağlanan difüzör deliği ve platformdaki yönlendirici kılavuz ile literatürde sıkça kullanılan özellikler, tasarlanan bu cihazda toplanmıştır. Piyasadaki görüntüleme cihazları kapalı yapıda olup sadece tanıma ve doğrulama işlemlerine izin verdiğinden, bu çalışma ile bu kısıt giderilmiştir. Ancak bu çalışma ile elde edilen görüntülerin kamera, tasarlanan platform ve ortam sıcaklığı gibi çevresel faktörlerin yanı sıra kullanıcı kaynaklı bireysel faktörlerden epey etkilendiği yaşanan süreçte fark edilmiştir. Ancak daha kaliteli bir kamera kullanımıyla bu negatif etkileri gidermek mümkündür.

Tez kapsamında tasarlanan ikinci görüntüleme sistemi "Raspberry Pi 4 Model B" adlı gömülü sistem, ona uyumlu Raspberry Pi NoIR Camera, tripod ve tablet ekran kullanarak, kullanıcı dostu yapısıyla temassız avuç içi izi görüntüsü elde etmeyi mümkün kılmıştır. Yapılan çalışmada "MediaPipe Hands" adlı, işaret dili tanıma amaçlı tasarlanan Google'a ait makine öğrenmesi tabanlı çerçeve, avuç içi izi verilerini toplama adına kullanılmıştır. Bu tasarımda, herhangi bir fiziksel sensör ya da fiziksel bir kılavuz kullanmadan platformdaki kullanıcıya ait el, yazılımsal bir çözümle yönlendirilmiştir. Bu sayede kapasitif ya da optik sensörler kullanılmayıp maliyet açısından tasarruf sağlanmıştır. Sunulan çözümlerle elin platformda kameraya olan uzaklığı kabaca hesaplanıp kayma ve öteleme kaynaklı problemler minimuma indirilmiştir. Platformdan görüntüleri alınan kullanıcıya ait elin, sağ ya da sol el olma bilgisi yine MediaPipe Hands sayesinde teşhis edilebilmiştir. Bu özellik, oluşturulacak veri setine kullanıcının hangi elinden veri toplandığını gösterebilmesi adına önemlidir.

Tasarlanan görüntüleme platformlarından alınan görüntülerde ya da el görüntülerini cepheden gören halka açık veri setlerindeki görüntülerde, MediaPipe Hands çerçevesi kullanılarak çok kipli biyometrik sistemlerin önünü açan bir çözüm önerilmiştir. Başta el geometrisi, avuç içi izi ve avuç içi damarı olmak üzere, el tabanlı biyometrik özelliklere ait ilgi bölgesinin bu çerçeve yardımıyla kolayca çıkarılabileceği halka açık Tecnocampus Hand Image ve IIT Delhi Touchless Palmprint veri setleri üzerinde

gösterilmiştir. Bu çerçevenin avuç içi izi ilgi bölgesi çıkarımında hız ve doğruluk açısından geleneksel görüntü işleme yöntemlerine kurduğu üstünlük, halka açık bu 2 veri seti kullanılarak kanıtlanmıştır.

Oldukça iyi taranan literatür sonrası, parmak damarı biyometrisi hakkında detaylı bilgi sunulup derin öğrenmeden faydalanan yayınlara odaklanılmıştır. Gerçekleştirilen deneyler sırasında ilgili adımlar açıklanarak tekrarlanabilir bir çalışma ortaya konulmuştur. Tez sürecinde karşılaşılan kısıtlar kısaca şu şekilde sıralanabilir: Yeterli görüntüye sahip ve erişime açık parmak damarı veri setinin eksikliği, COVID-19 nedeniyle kendi veri setimizi oluşturamamamız, kızılötesi ışığın damar görüntüleme de yaşattığı görüntüleme problemleri, literatürdeki tanıma ve doğrulama uygulamalarındaki protokole sadık kalmadan yapılan performans karşılaştırmalarından kaynaklanan eksiklikler veya hatalar.

Tüm bu kısıtlar göz önünde bulundurulduğunda gelecekte yapılacak öncelikli çalışmalar şu şekilde listelenebilir: Gerekli etik kurul onayları alınarak tez çalışması kapsamında tasarlanan görüntüleme sistemleri aracılığıyla kapsamlı bir parmak damarı veri seti ve avuç içi izi veri seti oluşturmak hedeflenmektedir. Bu 2 veri seti oluşturulurken kullanıcı sayısı, kullanıcılardan alınan örnek sayısı, kullanıcılara ait her iki elin kullanılması ve veri setine katkı sağlayan gönüllülerin ten rengi, ırk, yaş ve cinsiyet açısından dengeli bir dağılımla seçilmesi gibi nitelikler göz önünde bulundurulacaktır.

Bu tezde sentetik parmak damarı görüntülerini içeren bir veri seti kullanılarak ilgili çalışmalar gerçekleştirilmiştir ancak daha iyi bir değerlendirme ve analiz için sentetik görüntülerinin yerini gerçek damar görüntülerine bırakması gerekmektedir. Bu sebeple tasarlanan görüntüleme sistemi vasıtasıyla oluşturacağımız kapsamlı bir veri seti ya da paylaşılması halinde aynı ölçekte halka açık herhangi bir parmak damarı veri seti üzerinde, derin öğrenme yöntemlerinin artan kişi ve görüntü sayısı karşısında sergileyeceği performans incelenecektir. Özellikle bu çalışmada yer verilen ve kullanımı önerilen Öz dikkat mekanizmasının, farklı ESA mimarileri içerisinde kullanılıp parmak damarına uygulanabilmesi halinde, elde edilen performansın daha da artacağı düşünülmektedir.

Bu çalışmada aydınlatma tekniği olarak kullanılan yansıtma yerine gelecek çalışmalarda geçiş tekniğini kullanmak mümkündür ancak bunu gerçekleştirebilmek için LED'lerin en etkili şekilde kullanılmasını sağlayacak LED'lerin yerleşimi, dalga boyu ve sayısı konusunda gerekli çalışmalar yürütülmelidir. Zira geçiş yöntemiyle elde edilecek görüntü kontrastı, bu çalışmada elde edilenden daha yüksek olacaktır. Ayrıca tasarlanan cihazın boyutları da küçülecektir. Bu tasarımda, sabit akımda çalışan bir LED devresi tasarlayıp devredeki her elemanın parlaklığına müdahale etme seçeneğini kullanıcıya sunmak, görüntüde optimum kontrast elde etmek açısından önemlidir ve ortaya çıkacak tasarımı, muadillerine göre bir adım öne çıkaracaktır.

KAYNAKLAR

- Abdul Kadir, N. H., Abdul Wahab, N. H., Meng, G. C., Lim, C. H., Sayed Aluwee, S. A. Z. B., Bajuri, M. N., & Harun, S. Z.** (2022). A Near Infrared Image of Forearm Subcutaneous Vein Extraction Using U-Net, *In Proceedings of the 6th International Conference on Electrical, Control and Computer Engineering, Springer, Singapore.*, (pp. 1093-1103)
- Aftab, A., Khan, F. A., Khan, M. K., Abbas, H., Iqbal, W., & Riaz, F.** (2021). Hand-based multibiometric systems: state-of-the-art and future challenges, *PeerJ Computer Science*, 7, e707.
- Alariki, A. A., Faiz, M., Balagh, S., & Murray, C.** (2018). A review of finger-vein biometric recognition, *In Proceedings of the World Congress on Engineering and Computer Science*, (Vol. 1).
- Alay, N., & Al-Baity, H. H.** (2020). Deep learning approach for multimodal biometric recognition system based on fusion of iris, face, and finger vein traits, *Sensors*, 20(19), 5523.
- Al-Nima, R. R. O., Dlay, S. S., Al-Sumaidae, S. A., Woo, W. L., & Chambers, J. A.** (2017). Robust feature extraction and salvage schemes for finger texture based biometrics, *IET Biometrics*, 6(2), 43-52.
- Altay, A., & Gumus, A.** (2021, November). Development of Low-Cost Portable Blood Vessel Imaging System, *TIPTEKNO*, (pp. 1-4). IEEE.
- Anitha, M. L., & Rao, K. R.** (2015). Extraction of region of interest (ROI) for palm print and inner knuckle print, *International Journal of Computer Applications*, 124(14).
- Asaari, M. S. M., Suandi, S. A., & Rosdi, B. A.** (2014). Fusion of band limited phase only correlation and width centroid contour distance for finger based biometrics, *Expert Systems with Applications*, 41(7), 3367-3382.
- Avci, A., Kocakulak, M., & Acir, N.** (2019). Convolutional neural network designs for finger-vein-based biometric identification, *In 2019 11th International Conference on Electrical and Electronics Engineering (ELECO)*, (pp. 580-584). Ieee.
- Aykut, M., & Ekinici, M.** (2015). Developing a contactless palmprint authentication system by introducing a novel ROI extraction method, *Image and Vision Computing*, 40, 65-74.
- Badawi, A. M.** (2006). Hand Vein Biometric Verification Prototype: A Testing Performance and Patterns Similarity, *IPCV*, 14(3), 9.
- Barral, C.** (2010). Biometrics & Security: Combining fingerprints, smart cards and cryptography, *École Polytechnique Fédérale De Lausanne*.
- Bilal, A., Sun, G., & Mazhar, S.** (2021). Finger-vein recognition using a novel enhancement method with convolutional neural network, *Journal of the Chinese Institute of Engineers*, 44(5), 407-417.

- Biometrics, P.** (2014). Understanding biometric performance evaluation, URL: <https://precisebiometrics.com/wp-content/uploads/2014/11/White-Paper-Understanding-Biometric-Performance-Evaluation.pdf> (pristupljeno: srpanj 2018.)[10].
- Boucherit, I., Zmirli, M. O., Hentabli, H., & Rosdi, B. A.** (2020). Finger vein identification using deeply-fused Convolutional Neural Network, *Journal of King Saud University-Computer and Information Sciences*.
- Cappelli, R., Maio, D., Maltoni, D., Wayman, J. L., & Jain, A. K.** (2005). Performance evaluation of fingerprint verification systems, *IEEE transactions on pattern analysis and machine intelligence*, 28(1), 3-18.
- Chai, T., Li, J., Prasad, S., Lu, Q., & Zhang, Z.** (2022a). Shape-driven lightweight CNN for finger-vein biometrics, *Journal of Information Security and Applications*, 67, 103211.
- Chai, T., Li, J., Wang, Y., Sun, G., Guo, C., & Zhang, Z.** (2022b). Vascular Enhancement Analysis in Lightweight Deep Feature Space, *Neural Processing Letters*, 1-16.
- Chandra, A., & Calderon, T. G.** (2003). Toward a biometric security layer in accounting systems, *Journal of Information Systems*, 17(2), 51-70.
- Cuper, N. J.** (2012). Near-infrared vascular imaging in peripheral venous and arterial access (Doctoral dissertation, Universiteit Utrecht).
- Daas, S., Yahi, A., Bakir, T., Sedhane, M., Boughazi, M., & Bourennane, E. B.** (2020). Multimodal biometric recognition systems using deep learning based on the finger vein and finger knuckle print fusion, *IET Image Processing*, 14(15), 3859-3868.
- Damak, W., Boukhris Trabelsi, R., Alima Damak, M., & Sellami, D.** (2018). Dynamic ROI extraction method for hand vein images, *IET Computer Vision*, 12(5), 586-595.
- Das, R., Piciucco, E., Maiorana, E., & Campisi, P.** (2018). Convolutional neural network for finger-vein-based biometric identification, *IEEE Transactions on Information Forensics and Security*, 14(2), 360-373.
- Daugman, J.** (2009). How iris recognition works. In *The essential guide to image processing*, Academic Press, (pp. 715-739).
- Debiasi, L., Kauba, C., Prommegger, B., & Uhl, A.** (2018, October). Near-infrared illumination add-on for mobile hand-vein acquisition, *In 2018 IEEE 9th International Conference on Biometrics Theory, Applications and Systems (BTAS)*, (pp. 1-9).
- Delpy, D. T., & Cope, M.** (1997). Quantification in tissue near-infrared spectroscopy, *Philosophical Transactions of the Royal Society of London. Series B: Biological Sciences*, 352(1354), 649-659.

- Ducray, B., Cobourne, S., Mayes, K., & Markantonakis, K.** (2017, May). Comparison of dynamic biometric security characteristics against other biometrics, *In 2017 IEEE International Conference on Communications (ICC)*, (pp. 1-7).
- Eglitis, T., Maiorana, E., & Campisi, P.** (2021, September). Influence of Test Protocols on Biometric Recognition Performance Estimation, *In 2021 International Conference of the Biometrics Special Interest Group (BIOSIG)*, (pp. 1-5).
- Elderen, M.** (2022). Designing a stand alone finger vein scanner (Bachelor's thesis, *University of Twente*).
- El-Sayed, A. Y. M. A. N.** (2015). Multi-biometric systems: a state of the art survey and research directions, (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, 6.
- El-Yacoubi, M. A., Gilloux, M., & Bertille, J. M.** (2002). A statistical approach for phrase location and recognition within a text line: An application to street name recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(2), 172-188.
- Fang, Y., Wu, Q., & Kang, W.** (2018). A novel finger vein verification system based on two-stream convolutional network learning, *Neurocomputing*, 290, 100-107.
- Faundez-Zanuy, M., Mekyska, J., & Font-Aragonès, X.** (2014). A new hand image database simultaneously acquired in visible, near-infrared and thermal spectrums, *Cognitive Computation*, 6(2), 230-240.
- Friedman, L., Stern, H., Prokopenko, V., & Komogortsev, O.** (2019). Relationship between number of subjects and biometric authentication equal error rates, *Go to reference in article*, 6(2).
- García, A. M., & Horche, P. R.** (2018). Light source optimizing in a biphotonic vein finder device: Experimental and theoretical analysis, *Results in Physics*, 11, 975-983.
- Garcia-Martin, R., & Sanchez-Reillo, R.** (2020). Wrist vascular biometric recognition using a portable contactless system, *Sensors*, 20(5), 1469.
- Garcia-Martin, R., & Sanchez-Reillo, R.** (2021). Deep Learning for Vein Biometric Recognition on a Smartphone, *Ieee Access*, 9, 98812-98832.
- Gumusbas, D., Yildirim, T., Kocakulak, M., & Acir, N.** (2019, December). Capsule network for finger-vein-based biometric identification, *In 2019 IEEE Symposium Series on Computational Intelligence (SSCI)*, (pp. 437-441).
- Hartung, D., & Busch, C.** (2009, September). Why vein recognition needs privacy protection, *In 2009 Fifth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, (pp. 1090-1095).
- Hartung, D.** (2012). Vascular pattern recognition: And its application in privacy-preserving biometric online-banking systems.

- He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (pp. 770-778).
- Hillerström, F., & Kumar, A.** (2014). On generation and analysis of synthetic finger-vein images for biometrics identification, *Technical Report No. COMP-K-17.*
- Hou, B., & Yan, R.** (2018, June). Convolutional auto-encoder based deep feature learning for finger-vein verification, *In 2018 IEEE international symposium on medical measurements and applications (MeMeA)*, (pp. 1-5).
- Hou, B., & Yan, R.** (2021). ArcVein-arccosine center loss for finger vein verification, *IEEE Transactions on Instrumentation and Measurement*, 70, 1-11.
- Hou, B., & Yan, R.** (2022). Triplet-Classifier GAN for Finger-Vein Verification, *IEEE Transactions on Instrumentation and Measurement*, 71, 1-12.
- Hou, B., Zhang, H., & Yan, R.** (2022). Finger-Vein Biometric Recognition: A Review, *IEEE Transactions on Instrumentation and Measurement*.
- Hsia, C. H., & Liu, C. H.** (2022). New hierarchical finger-vein feature extraction method for iVehicles, *IEEE Sensors Journal*, 22(13), 13612-13621.
- Hu, H., Kang, W., Lu, Y., Fang, Y., Liu, H., Zhao, J., & Deng, F.** (2018, August). FV-Net: learning a finger-vein feature representation based on a CNN, *In 2018 24th International Conference on Pattern Recognition (ICPR)*, (pp. 3489-3494).
- Huang, J., Tu, M., Yang, W., & Kang, W.** (2021). Joint attention network for finger vein authentication, *IEEE Transactions on Instrumentation and Measurement*, 70, 1-11.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q.** (2017). Densely connected convolutional networks, *In Proceedings of the IEEE conference on computer vision and pattern recognition*, (pp. 4700-4708).
- Huang, Q., Hu, K., Zhou, P., Luo, Y., & Wu, L.** (2018, May). Design of finger vein capturing device based on ARM and CMOS array, *In 2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC)*, (pp. 193-196).
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., & Keutzer, K.** (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. arXiv preprint arXiv:1602.07360.
- Jain, A., Hong, L., & Bolle, R.** (1997). On-line fingerprint verification, *IEEE transactions on pattern analysis and machine intelligence*, 19(4), 302-314.
- Jain, A. K., Ross, A., & Prabhakar, S.** (2004). An introduction to biometric recognition, *IEEE Transactions on circuits and systems for video technology*, 14(1), 4-20.
- Jain, A., Klare, B., & Ross, A.** (2015, May). Guidelines for best practices in biometrics research, *In 2015 International Conference on Biometrics (ICB)*, (pp. 541-545).

- Jalilian, E., & Uhl, A.** (2018, December). Finger-vein recognition using deep fully convolutional neural semantic segmentation networks: The impact of training data, *In 2018 IEEE International Workshop on Information Forensics and Security (WIFS)*, (pp. 1-8).
- Jiang, R., Al-Maadeed, S., Bouridane, A., Crookes, D., & Beghdadi, A.** (2017). Biometric Security and Privacy, *ISpringer International Publishing AG.*
- Kauba, C., Prommegger, B., & Uhl, A.** (2019). Combined fully contactless finger and hand vein capturing device with a corresponding dataset, *Sensors*, 19(22), 5014.
- Kavitha, K., & Rao, B. T.** (2019). Evaluation of distance measures for feature based image registration using alexnet, *arXiv preprint arXiv:1907.12921*.
- Kekre, H. B., Sarode, T., & Vig, R.** (2012, October). An effectual method for extraction of ROI of palmprints, *In 2012 International Conference on Communication, Information & Computing Technology (ICCICT)*, (pp. 1-5).
- Kocakulak, M., & Acir, N.** (2018, May). Enhancement of finger vein images using Gabor filter, *In 2018 26Th Signal Processing And Communications Applications Conference (Siu)*, pp. 1-4).
- Kocakulak, M., & Acir, N.** (2022, May). Dynamic ROI Extraction for Palmprints using MediaPipe Hands, *In 2022 30th Signal Processing and Communications Applications Conference (SIU)*, pp. 1-4).
- Kono, M.** (2000). A new method for the identification of individuals by using of vein pattern matching of a finger, *In Proc. Fifth Symposium on Pattern Measurement, Yamaguchi, Japan, 2000*, (pp. 9-12).
- Krishnan, A., Nayar, G. R., Thomas, T., & Nystrom, N. A.** (2020, September). FEBA-An Anatomy Based Finger Vein Classification, *In 2020 IEEE International Joint Conference on Biometrics (IJCB)*, (pp. 1-9).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2017). Imagenet classification with deep convolutional neural networks, *Communications of the ACM*, 60(6), 84-90.
- Kshirsagar, V. P., Baviskar, M. R., & Gaikwad, M. E.** (2011, March). Face recognition using Eigenfaces, *In 2011 3rd International Conference on Computer Research and Development*, (Vol. 2, pp. 302-306). IEEE.
- Kumar, A.** (2008, December). Incorporating cohort information for reliable palmprint authentication, *In 2008 Sixth Indian Conference on Computer Vision, Graphics & Image Processing*, (pp. 583-590).
- Kumar, A., & Prathyusha, K. V.** (2009). Personal authentication using hand vein triangulation and knuckle shape, *IEEE Transactions on Image processing*, 18(9), 2127-2136.
- Kumar, A., & Zhou, Y.** (2011). Human identification using finger images, *IEEE Transactions on image processing*, 21(4), 2228-2244.

- Kuzu, R. S., Maiorana, E., & Campisi, P.** (2020a). Vein-based biometric verification using densely-connected convolutional autoencoder, *IEEE Signal Processing Letters*, 27, 1869-1873.
- Kuzu, R. S., Maiorana, E., & Campisi, P.** (2020b). Vein-based biometric verification using transfer learning, *In 2020 43rd International Conference on Telecommunications and Signal Processing (TSP)*, (pp. 403-409).
- Kyeremeh, G. K., Abdul-Al, M., Abduljabbar, N., Qahwaji, R., Abdul-Atty, M. M., Amar, A. S., & Abd-Alhameed, R. A.** (2022, July). Finger vein Recognition, *In 2022 International Telecommunications Conference (ITC-Egypt)*, (pp. 1-5).
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P.** (1998). Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), 2278-2324.
- Li, H., Lyu, Y., Duan, G., & Chen, C.** (2022). Improving finger vein discriminant representation using dynamic margin softmax loss, *Neural Computing and Applications*, 34(5), 3589-3601.
- Li, W. X., Xia, S. X., Zhang, D. P., & Zhuo-Qun, X. U.** (2004). A new palmprint identification method using bi-directional matching based on major line features, *Journal of computer research and development*, 41(6), 996-1002.
- Lu, H., Li, Y., Zhao, C., Liu, W., Li, Y., & Ma, N.** (2021a, May). A Novel Finger-vein Recognition Approach based on Vision Transformer, *In International Conference on Frontiers of Electronics, Information and Computation Technologies*, (pp. 1-6).
- Lu, H., Wang, Y., Gao, R., Zhao, C., & Li, Y.** (2021b). A novel ROI extraction method based on the characteristics of the original finger vein image, *Sensors*, 21(13), 4402.
- Lu, Y., Xie, S., & Wu, S.** (2019). Exploring competitive features using deep convolutional neural network for finger vein recognition, *Ieee Access*, 7, 35113-35123.
- Lu, Y., Xie, S. J., Yoon, S., Wang, Z., & Park, D. S.** (2013, December). An available database for the research of finger vein recognition, *In 2013 6th International congress on image and signal processing (CISP)*,(Vol. 1, pp. 410-415). IEEE.
- Lugaresi, C., Tang, J., Nash, H., McClanahan, C., Uboweja, E., Hays, M., ... & Grundmann, M.** (2019). Mediapipe: A framework for building perception pipelines. arXiv preprint arXiv:1906.08172.
- Maio, D., Maltoni, D., Cappelli, R., Wayman, J. L., & Jain, A. K.** (2004, July). FVC2004: Third fingerprint verification competition, *In International conference on biometric authentication. Springer, Berlin, Heidelberg.*, (pp. 1-7)
- Mansfield, A. J., & Wayman, J. L.** (2002). Best practices in testing and reporting performance of biometric devices
- Mansfield, A.** (2006). Information technology–biometric performance testing and reporting–part 1: Principles and framework, *ISO/IEC*, 19795-1.

- mehdi Cherrat, E., Alaoui, R., & Bouzahir, H.** (2020). Convolutional neural networks approach for multimodal biometric identification system using the fusion of fingerprint, finger-vein and face images, *PeerJ Computer Science*, 6, e248.
- Meng, G., Fang, P., & Zhang, B.** (2017). Finger vein recognition based on convolutional neural network, *In MATEC Web of Conferences*, (Vol. 128, p. 04015).
- Mery, D., Zhao, Y., & Bowyer, K.** (2016, September). On accuracy estimation and comparison of results in biometric research, finger-vein and face images, *In 2016 IEEE 8th International Conference on Biometrics Theory, Applications and Systems (BTAS)*, (pp. 1-8).
- Michael, G. K. O., Connie, T., & Jin, A. T. B.** (2010, June). Robust palm print and knuckle print recognition system using a contactless approach, *In 2010 5Th IEEE Conference On Industrial Electronics And Applications*, (pp. 323-329).
- Michael, G. K. O., Connie, T., & Teoh, A. B. J.** (2008). Touch-less palm print biometrics: Novel design and implementation, *Image and vision computing*, 26(12), 1551-1560.
- Miura, N., Nagasaka, A., & Miyatake, T.** (2004). Feature extraction of finger-vein patterns based on repeated line tracking and its application to personal identification, *Machine vision and applications*, 15(4), 194-203.
- Miura, N., Nagasaka, A., & Miyatake, T.** (2007). Extraction of finger-vein patterns using maximum curvature points in image profiles, *IEICE TRANSACTIONS on Information and Systems*, 90(8), 1185-1194.
- Miyake, R. K., Zeman, H. D., Duarte, F. H., Kikuchi, R., Ramacciotti, E., Lovhoiden, G., & Vrancken, C.** (2006). Vein imaging: a new method of near infrared imaging, where a processed image is projected onto the skin for the enhancement of vein treatment, *Dermatologic surgery*, 32(8), 1031-1038.
- Morales, A., Ferrer, M. A., Travieso, C. M., & Alonso, J. B.** (2012, October). Multisampling approach applied to contactless hand biometrics, *In 2012 IEEE International Carnahan Conference on Security Technology (ICCST)*, (pp. 224-229).
- Moroń, T., Bernacki, K., Fiołka, J., Peng, J., & Popowicz, A.** (2022). Recognition of the finger vascular system using multi-wavelength imaging, *IET Biometrics*, 11(3), 249-259.
- Mróz-Gorgoń, B., Wodo, W., Andrych, A., Caban-Piaskowska, K., & Kozyra, C.** (2012). Biometrics Innovation and Payment Sector Perception, *Sustainability*, 14(15), 9424.
- National Research Council, & Whither Biometrics Committee.** (2010). Biometric recognition: Challenges and opportunities.
- Niyogi, S. A., & Adelson, E. H.** (1994, June). Analyzing and recognizing walking figures in XYT, *In CVPR*, (Vol. 94, pp. 469-474).

- Noh, K. J., Choi, J., Hong, J. S., & Park, K. R.** (2021). Finger-vein recognition using heterogeneous databases by domain adaptation based on a cycle-consistent adversarial network, *Sensors*, 21(2), 524.
- Normakristagaluh, P., Laanstra, G. J., Spreeuwers, L., & Veldhuis, R.** (2022). Understanding and modeling finger vascular pattern imaging, *IET Image Processing*, 16(5), 1280-1292.
- Otsu, N.** (1979). A threshold selection method from gray-level histograms, *IEEE transactions on systems, man, and cybernetics*, 9(1), 62-66.
- Ou, W. F., Po, L. M., Zhou, C., Rehman, Y. A. U., Xian, P. F., & Zhang, Y. J.** (2021). Fusion loss and inter-class data augmentation for deep finger vein feature learning, *Expert Systems with Applications*, 171, 114584.
- Pascual, J. E. S., Uriarte-Antonio, J., Sanchez-Reillo, R., & Lorenz, M. G.** (2010, October). Capturing hand or wrist vein images for biometric authentication using low-cost devices, *In 2010 Sixth International Conference on Intelligent Information Hiding and Multimedia Signal Processing*, (pp. 318-322).
- Pham, T. D., Park, Y. H., Nguyen, D. T., Kwon, S. Y., & Park, K. R.** (2015). Nonintrusive finger-vein recognition system using NIR image sensor and accuracy analyses according to various factors, *Sensors*, 15(7), 16866-16894.
- Pizer, S. M.** (1990, May). Contrast-limited adaptive histogram equalization: Speed and effectiveness stephen m. pizer, r. eugene johnston, james p. ericksen, bonnie c. yankaskas, keith e. muller medical image display research group, *In Proceedings of the first conference on visualization in biomedical computing, Atlanta, Georgia*, (Vol. 337, p. 1).
- Poon, C., Wong, D. C., & Shen, H. C.** (2004, August). A new method in locating and segmenting palmprint into region-of-interest, *In Proceedings of the 17th International Conference on Pattern Recognition, 2004. ICPR 2004.* (Vol. 4, pp. 533-536).
- Qin, H., & El-Yacoubi, M. A.** (2017a). Deep representation-based feature extraction and recovering for finger-vein verification, *IEEE Transactions on Information Forensics and Security*, 12(8), 1816-1829.
- Qin, H., & El-Yacoubi, M. A.** (2017b). Deep representation for finger-vein image-quality assessment, *IEEE Transactions on Circuits and Systems for Video Technology*, 28(8), 1677-1693.
- Qin, H., & Wang, P.** (2019). Finger-vein verification based on LSTM recurrent neural networks, *Applied Sciences*, 9(8), 1687.
- Radzi, S. A., Hani, M. K., & Bakhteri, R.** (2016). Finger-vein biometric identification using convolutional neural network, *Turkish Journal of Electrical Engineering and Computer Sciences*, 24(3), 1863-1878.
- Ramírez, J., Segura, J. C., Górriz, J. M., & García, L.** (2007). Improved voice activity detection using contextual multiple hypothesis testing for robust speech

- recognition, *IEEE Transactions on Audio, Speech, and Language Processing*, 15(8), 2177-2189.
- Ren, H., Sun, L., Guo, J., & Han, C.** (2022). A Dataset and Benchmark for Multimodal Biometric Recognition Based on Fingerprint and Finger Vein, *IEEE Transactions on Information Forensics and Security*.
- Rozendal, S. P.** (2018). Redesign of a finger vein scanner (Bachelor's thesis, University of Twente).
- Ryer, A., Light, U., & Light, V.** (1997). Light measurement handbook.
- Schuike, J., Linortner, M., Wimmer, G., & Uhl, A.** (2022). Attack Detection for Finger and Palm Vein Biometrics by Fusion of Multiple Recognition Algorithms, *IEEE Transactions on Biometrics, Behavior, and Identity Science*, 4(4), 544-555.
- Shaheed, K., Mao, A., Qureshi, I., Kumar, M., Hussain, S., & Zhang, X.** (2022a). Recent advancements in finger vein recognition technology: methodology, challenges and opportunities, *Information Fusion*, 79, 84-109.
- Shaheed, K., Mao, A., Qureshi, I., Kumar, M., Hussain, S., Ullah, I., & Zhang, X.** (2022b). DS-CNN: A pre-trained Xception model based on depth-wise separable convolutional neural network for finger vein recognition, *Expert Systems with Applications*, 191, 116288.
- Sidiropoulos, G. K., Kiratsa, P., Chatzipetrou, P., & Papakostas, G. A.** (2021). Feature Extraction for Finger-Vein-Based Identity Recognition, *Journal of Imaging*, 7(5), 89.
- Sierro, A., Ferrez, P., & Roduit, P.** (2015, September). Contact-less palm/finger vein biometrics, *In 2015 International Conference of the Biometrics Special Interest Group (BIOSIG)*, (pp. 1-12).
- Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Song, J. M., Kim, W., & Park, K. R.** (2019). Finger-vein recognition based on deep DenseNet using composite image, *Ieee Access*, 7, 66845-66863.
- Takatani, M., Suzuki, H., Tsubaki, N., Matsuki, J., & Yamaguchi, M.** (2022) Contactless Authentication Solution Using Finger Vein Authentication Technology.
- Tan, D., Yang, J., Shi, Y., & Xu, C.** (2013, November). A hierarchal framework for finger-vein image classification, *In 2013 2nd IAPR Asian Conference on Pattern Recognition*, (pp. 833-837).
- Tang, S., Zhou, S., Kang, W., Wu, Q., & Deng, F.** (2019). Finger vein verification using a Siamese CNN, *IET Biometrics*, 8(5), 306-315.
- Tao, Z., Zhou, X., Xu, Z., Lin, S., Hu, Y., & Wei, T.** (2021). Finger-vein recognition using bidirectional feature extraction and transfer learning, *Mathematical Problems in Engineering*, 2021.

- Tien, T. V., Mien, P. T., Dung, P. T., & Linh, H. Q.** (2015). Using near-infrared technique for vein imaging, *In 5th International Conference on Biomedical Engineering in Vietnam. Springer, Cham.*, (pp. 190-193).
- Tome, P., Vanoni, M., & Marcel, S.** (2014, September). On the vulnerability of finger vein recognition to spoofing, *In 2014 International Conference of the Biometrics Special Interest Group (BIOSIG)*, (pp. 1-10).
- Ton, B.** (2012). Vascular pattern of the finger: Biometric of the future?. University of Twente, 3.
- Ton, B. T., & Veldhuis, R. N.** (2013, June). A high quality finger vascular pattern dataset collected using a custom designed capturing device, *In 2013 International conference on biometrics (ICB)*, (pp. 1-5).
- Toygar, Ö., Babalola, F. O., & Bitirim, Y.** (2020). FYO: a novel multimodal vein database with palmar, dorsal and wrist biometrics, *IEEE Access*, 8, 82461-82470.
- Tran, Q. N., Turnbull, B. P., & Hu, J.** (2021). Biometrics and privacy-preservation: How do they evolve?, *IEEE Open Journal of the Computer Society*, 2, 179-191.
- Vanoni, M., Tome, P., El Shafey, L., & Marcel, S.** (2014, October). Cross-database evaluation using an open finger vein sensor, *In 2014 IEEE workshop on biometric measurements and systems for security and medical applications (BIOMS) proceedings*, (pp. 30-35).
- Waluś, M., Bernacki, K., Konopacki, J., & Nycz, M.** (2015, June). NIR finger vascular system imaging in angiology applications, *In 2015 22nd International Conference Mixed Design of Integrated Circuits & Systems (MIXDES)*, (pp. 69-73).
- Watanabe, M.** (2009). Palm Vein.
- Widrow, B., & Hoff, M. E.** (1960). Adaptive switching circuits, *Stanford Univ Ca Stanford Electronics Labs*.
- Wilches-Bernal, F., Núñez-Álvares, B., & Vizcaya, P.** (2020). A database of dorsal hand vein images. arXiv preprint arXiv:2012.05383.
- Win, K. N., Li, K., Chen, J., Viger, P. F., & Li, K.** (2020). Fingerprint classification and identification algorithms for criminal investigation: A survey, *Future Generation Computer Systems*, 110, 758-771.
- Wu, J. D., & Liu, C. T.** (2011). Finger-vein pattern identification using SVM and neural network technique, *Expert Systems with Applications*, 38(11), 14284-14289.
- Wu, W., Elliott, S. J., Lin, S., Sun, S., & Tang, Y.** (2020). Review of palm vein recognition, *IET Biometrics*, 9(1), 1-10.
- Xiao, Q., Lu, J., Jia, W., & Liu, X.** (2019). Extracting palmprint ROI from whole hand image using straight line clusters, *IEEE Access*, 7, 74327-74339.
- Xie, C., & Kumar, A** (2019). Finger vein identification using convolutional neural network and supervised discrete hashing, *Pattern Recognition Letters*, 119, 148-156.

- Yadav, J. K. P. S., Jaffery, Z. A., & Singh, L.** (2020). A short review on machine learning techniques used for fingerprint recognition, *Journal of Critical Reviews*, 7(13).
- Yan, L., Lu, H., Wang, C., Ye, Z., Chen, H., & Ling, H.** (2019). Deep linear discriminant analysis hashing for image retrieval, *Multimedia Tools and Applications*, 78(11), 15101-15119.
- Yang, H., Fang, P., & Hao, Z.** (2020, December). A GAN-based Method for Generating Finger Vein Dataset, *In 2020 3rd International Conference on Algorithms, Computing and Artificial Intelligence*, (pp. 1-6).
- Yang, L., Yang, G., Zhou, L., & Yin, Y.** (2015, May). Superpixel based finger vein ROI extraction with sensor interoperability, *In 2015 International Conference on Biometrics (ICB)*, (pp. 444-451).
- Yang, S., Ryu, J., Kwon, M., Lee, W., Macdonald, J. G., & Kim, J. R.** (2011).
- Yang, W., Hui, C., Chen, Z., Xue, J. H., & Liao, Q.** (2019). FV-GAN: Finger vein representation using generative adversarial networks, *IEEE Transactions on Information Forensics and Security*, 14(9), 2512-2524.
- Yang, W., Yu, X., & Liao, Q.** (2009, October). Personal authentication using finger vein pattern and finger-dorsa texture fusion, *In Proceedings of the 17th ACM international conference on Multimedia*, (pp. 905-908).
- Yildiz, M. Z., & Boyraz, Ö. F.** (2019). Development of a low-cost microcomputer based vein imaging system, *Infrared Physics & Technology*, 98, 27-35.
- Yin, Y., Liu, L., & Sun, X.** (2011, December). SDUMLA-HMT: a multimodal biometric database, *In Chinese Conference on Biometric Recognition. Springer, Berlin, Heidelberg.*, (pp. 260-268).
- Yuksel, A., Akarun, L., & Sankur, B.** (2011). Hand vein biometry based on geometry and appearance methods, *IET computer vision*, 5(6), 398-406.
- Zambre, S. R., & Mishra, A.** (2019). A Novel Approach to the ROI Extraction in Palmprint Classification, *In Information and Communication Technology for Intelligent Systems. Springer, Singapore.*, (pp. 675-684).
- Zhang, C., Liu, Z., Liu, Y., Su, F., Chang, J., Zhou, Y., & Zhao, Q.** (2015). Reflection-type finger vein recognition for mobile applications, *Journal of the Optical Society of Korea*, 19(5), 467-476.
- Zhang, D., Kong, W. K., You, J., & Wong, M.** (2003). Online palmprint identification, *IEEE Transactions on pattern analysis and machine intelligence*, 25(9), 1041-1050.
- Zhang, F., Bazarevsky, V., Vakunov, A., Tkachenka, A., Sung, G., Chang, C. L., & Grundmann, M.** (2020). Mediapipe hands: On-device real-time hand tracking. arXiv preprint arXiv:2006.10214.

- Zhang, J., Lu, Z., Li, M., & Wu, H.** (2019). GAN-based image augmentation for finger-vein biometric recognition, *IEEE Access*, 7, 183118-183132.
- Zhang, Y., Sun, D., & Qiu, Z.** (2012). Hand-based single sample biometrics recognition, *Neural Computing and Applications*, 21(8), 1835-1844.
- Zhang, Z., Zhong, F., & Kang, W.** (2021). Study on Reflection-Based Imaging Finger Vein Recognition, *IEEE Transactions on Information Forensics and Security*.
- Zhao, D., Ma, H., Yang, Z., Li, J., & Tian, W.** (2020a). Finger vein recognition based on lightweight CNN combining center loss and dynamic regularization, *Infrared Physics & Technology*, 105, 103221.
- Zhao, H., Jia, J., & Koltun, V.** (2020b). Exploring self-attention for image recognition, *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, (pp. 10076-10085).

ÖZGEÇMİŞ

Ad-Soyad : Mustafa KOCAKULAK

Doğum Tarihi ve Yeri :

E-posta :

ÖĞRENİM DURUMU:

- **Lisans** : 2012, Bilkent Üniversitesi, Elektrik Elektronik Mühendisliği
- **Yüksek Lisans** : 2015, Bursa Teknik Üniversitesi, Mekatronik Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- **ARAŞTIRMA GÖREVLİSİ:** Bursa Teknik Üniversitesi (2015-2022)
- **DOKTOR SIRASI ARAŞTIRMACI:** Universidad Autonoma De Madrid (2018-2019)

TEZDEN ÜRETİLEN ESERLER, SUNUMLAR VE PATENTLER:

- Kocakulak, M., & Acır, N. (2018). Enhancement of finger vein images using Gabor filter. 2018 26th Signal Processing and Communications Applications Conference (SIU), 1-4.
- Avcı, A., Kocakulak, M., & Acır, N. (2019). Convolutional Neural Network Designs for Finger-vein-based Biometric Identification. 2019 11th International Conference on Electrical and Electronics Engineering (ELECO), 580-584.
- Gumusbas, D., Yıldırım, T., Kocakulak, M., & Acır, N. (2019). Capsule Network for Finger-Vein-based Biometric Identification. 2019 IEEE Symposium Series on Computational Intelligence (SSCI), 437-441.
- Kocakulak, M., & Acır, N. (2022). Dynamic ROI Extraction for Palmprints using MediaPipe Hands. 2022 30th Signal Processing and Communications Applications Conference (SIU), 1-4.

DİĞER ESERLER, SUNUMLAR VE PATENTLER:

- Kocakulak, M., & Temel, T. (2016). Implementation of Special Cases for RSA Algorithm Where Plaintext is Equal to Ciphertext in Java. ICENS, Sarajevo, May.
- Kocakulak, M., & Butun, I. (2017). An overview of Wireless Sensor Networks towards internet of things. 2017 IEEE 7th Annual Computing and Communication Workshop and Conference (CCWC), 1-6..
- Kocakulak, Mustafa. Masalara Monte Edilebilen Ayaklık. Faydalı Model. Türk Patent ve Marka Kurumu, No. 2017/00937, 23 Aralık 2019.
- Aydemir, G., Avcı, A., Kocakulak, M., & Bekiryazici, T. (2021). Ensemble of LSTM Networks for Fault Detection, Classification, and Root Cause Identification in Quality Control Line.
- Aydemir, G., Kurnaz, O., Bekiryazici, T., Avcı, A., & Kocakulak, M. (2021). Driver Drowsiness Detection using MobileNets and Long Short-term Memory. 2021 13th International Conference on Electrical and Electronics Engineering (ELECO), 220-223.
- Kocakulak, M., & Nurettin, A. C. I. R. (2023). A Contactless Palmprint Imaging System Design Using Mediapipe Hands. Journal of Innovative Science and Engineering, (Yayın Aşamasında).
- Kocakulak, M., & Acir, N. (2023). A review of deep learning-based studies on finger-vein biometrics. Neurocomputing, (İnceleme Aşamasında).
- Kocakulak, M., Avcı, A. & Acir, N. (2023). Automated Vein Verification Using Self-attention-based Convolutional Neural Networks. Expert systems with applications, (Revizyon Aşamasında).
- Kocakulak, M., & Acir, N. (2023). Finger Region Extraction from Hand Images using MediaPipe Hands. Journal of Aeronautics and Space Technologies, (Revizyon Aşamasında).