



T.C.
KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANABİLİM DALI



PARMAK GÖRÜNTÜLERİ ÜZERİNDEN KİŞİ YAŞ ve CİNSİYET TAHMİNİ YAPILMASI

ISLAM NAHEDH FADHIL ALABDOO

YÜKSEK LİSANS TEZİ

KIRŞEHİR

2024



T.C.
KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANABİLİM DALI



PARMAK GÖRÜNTÜLERİ ÜZERİNDEN KİŞİ YAŞ ve CİNSİYET TAHMİNİ YAPILMASI

İSLAM NAHEDH FADHİL ALABDOO

YÜKSEK LİSANS TEZİ

DANIŞMAN

DR. ÖĞR. ÜYESİ MEHMET ALİ YALÇINKAYA

KIRŞEHİR

2024

YÜKSEK LİSANS TEZ ONAYI

Bu Yüksek Lisans Tezi/...../2024 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından Değerlendirilmiş ve Oy Birliği / Oy Çokluğu ile Kabul Edilmiştir.

Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA (Danışman).....

Doç. Dr. Emrah AYDEMİR (Jüri)

Dr. Öğr. Üyesi Murat IŞIK (Jüri)

Bu Tez Kırşehir Ahi Evran Üniversitesi, Fen Bilimleri Enstitüsü, İleri Teknolojiler Anabilim Dalında hazırlanmış ve onaylanmıştır.

Tez No:

Prof. Dr. Rüştü HATİPOĞLU

Enstitü Müdürü

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, tablo ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

KIRŐEHİR AHİ EVRAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŐMASI
ETİK BEYANI

Kırőehir Ahi Evran Üniversitesi Bilimsel Araőtırma ve Yayın Etięi Yönergesini okuduęumu ve anladığımı ve Kırőehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduęum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettięimi,
- Tüm bilgi, belge, deęerlendirme ve sonuçları bilimsel etik kurallarına uygun olarak sunduęumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir deęişiklik yapmadığımı,
- Tez olarak sunduęum bu çalışmanın özgün olduęunu,

bildirir, aksi bir durumda bu konuda hakkımda yapılacak tüm yasal işlemleri ve aleyhime doğabilecek tüm hak kayıplarını kabullendięimi beyan ederim./...../2024

Öęrenci
Islam Nahedh Fadhil ALABDOO

İÇİNDEKİLER DİZİNİ

	Sayfa No
İÇİNDEKİLER DİZİNİ	I
TEŞEKKÜR	III
ÖZET	IV
ABSTRACT	V
TABLolar DİZİNİ	VI
ŞEKİLLER DİZİNİ	VII
SİMGELER VE KISALTMALAR DİZİNİ	VIII
1. GİRİŞ	1
1.1. Fizyolojik Biyometri	4
1.2. Davranışsal Biyometri	5
1.3. Biyometrik Gereksinimler	7
1.4. Biyometrik Sistem Modları.....	7
1.4.1 Kayıt modu.....	7
1.4.2. Tanımlama modu.....	8
1.4.3. Doğrulama modu.....	9
1.5. Tezin Amacı ve Katkıları.....	10
1.6. Tez Organizasyonu	11
2. ÖNCEKİ ÇALIŞMALAR	13
3. MATERYAL VE METOT	19
3.1. Veri Kümesi Tanımı ve Ön İşleme	19
3.2. Makine Öğrenmesine Giriş	24
3.2.1. Denetimli öğrenme	24
3.2.2. Denetimsiz öğrenme.....	26
3.2.3. Takviyeli öğrenme.....	26
3.3. Makine Öğrenmesinin Bileşenleri.....	27
3.4. Derin Öğrenme	28
3.4.1. Evrişimli sinir ağları.....	28
3.4.2. Tekrarlayan sinir ağları	36
3.4.3. Derin tekrarlayan öğrenme	36
3.5 Geleneksel Makine Öğrenmesi Teknikleri	36
3.5.1. Destek vektör makinesi	36
3.5.2. Rastgele orman	37
3.5.3. Çok katmanlı algılayıcı	39

3.5.4. Doğrusal ve lojistik regresyon.....	39
3.6. Kombinasyon Teknikleri.....	39
3.7. Doğrulama Teknikleri	40
3.7.1 Çapraz doğrulama.....	41
3.7.2. rastgele bölme yöntemi.....	41
3.8. Önerilen Derin Tekrarlayan Parmak Fotoğraf Ağı	42
3.8.1. Girdi katmanı.....	43
3.8.2. Öznitelik çıkarma katmanları	43
3.8.2.1. Konvolüsyon katmanı.....	43
3.8.2.2. ReLU katmanı	44
3.8.2.3. Havuzlama katmanı	44
3.8.3. Sınıflandırma katmanları	45
3.8.3.1. FC katmanı	45
3.8.3.2. Softmax katmanı.....	46
3.8.3.3. Sınıflandırma katmanları	46
3.9. Performans Değerlendirme Ölçütleri	46
3.9.1. Duyarlılık	48
3.9.2. Kesinlik.....	48
3.9.3. Özgüllük	48
3.9.4. F1-skoru	48
4. BULGULAR VE TARTIŞMA	51
4.1 Bireysel Doğrulama	50
4.2. Cinsiyet Tahmini.....	57
4.3. Yaş Tahmini	61
5. SONUÇ VE ÖNERİLER	67
6. KAYNAKLAR.....	69
EKLER.....	83
EK-1.....	83
ÖZGEÇMİŞ	87

TEŐEKKÜR

Projedeki denetimi konusundaki olađanüstü çabaları için Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA 'ye içten teşekkürlerimi ve takdirimi sunarım. Deđerli rehberliđi ve sağladıđı destek sayesinde bu deneyim deđerli ve faydalı oldu. Çalışma süresince sorduđum sorular ve tezim üzerindeki katkılarıyla, ondan birçok şey öğrendim. Tezimdeki son dokunuşlar için sağladıđı destek ve rehberlik için kendisine minnettarım. O'na tüm teşekkürlerimi ve saygılarımı sunuyorum.

Ve ayrıca, savunma komitesi üyeleri Doç. Dr. Emrah AYDEMİR ve Dr. Öğr. Üyesi Murat IŐIK 'nin her birine teşekkür ederim.

Ve sevgili ailem olan eşim Moatasem ve çocuklarım Amenah, Maryam ve Maadh, öğrenim sürecim boyunca sağladıkları destek için teşekkür ederim. Ayrıca, anneme, kardeşlerime ve bu süreçte bana yardım eden herkese teşekkür ederim.

Nisan, 2024

Islam Nahedh Fadhil ALABDOO

ÖZET

YÜKSEK LİSANS TEZİ

PARMAK GÖRÜNTÜLERİ ÜZERİNDEN KİŞİ YAŞ ve CİNSİYET TAHMİNİ YAPILMASI

İslam Nahedh Fadhil ALABDOO

KIRŞEHİR AHI EVRAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İLERİ TEKNOLOJİLER ANA BİLİM DALI

Danışman: Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA
Yıl: 2024 Sayfa:87
Jüri: Dr. Öğr. Üyesi Mehmet Ali YALÇINKAYA
Doç. Dr. Emrah AYDEMİR
Dr. Öğr. Üyesi Murat IŞIK

Bu tez çalışması, Deep Recurrent Fingerphotos Network (DRFN) olarak adlandırılan, bir Derin Tekrarlayan Öğrenme (DRL) modeli, aracılığı ile parmak fotoğrafı görüntülerine dayalı kişi tanıma, yaş tahmini ve cinsiyet tahmini işlemlerini içermektedir. Önerilen DRFN modelinin mimarisi; bir giriş katmanı, birkaç gizli katman, bir çıkış katmanı ve bir geri besleme bağlantısından oluşmaktadır. Önerilen modelin doğruluğunu test edebilmek adına, araştırmacılar tarafından, tamamı özgün görüntülerden oluşan bir veri seti toplanmıştır. Söz konusu veri seti içerisinde her bir insana ait 10 parmağın farklı açıdan çekilmiş 10 fotoğrafı bulunmaktadır.

Toplanan özgün veri seti üzerinde, çalışma kapsamında gerçekleştirilen işlemler arasında parmak fotoğrafı görüntüleri aracılığıyla kişi tanıma, cinsiyet belirleme, yaş tahmini ve performans sonuçlarının değerlendirilmesi yer almaktadır. Söz konusu çalışma içerisinde ayrıca, önerilen DRFN modeli ile AlexNet, LeNet, GoogleNet, VGG16 ve ResNet-50 gibi özellik çıkarma için kullanılan diğer iyi bilinen derin öğrenme ağları arasında yapılan kapsamlı deneyler ve karşılaştırmalar da yer almaktadır. Bu değerlendirmelerde Destek Vektör Makinesi (SVM), Rastgele Orman, Çok Katmanlı Algılayıcı (MLP), Doğrusal Regresyon ve Lojistik Regresyon dahil olmak üzere çeşitli sınıflandırıcılar kullanılmıştır. Gerçekleştirilen analizlerin değerlendirilmesinde, Precision, Recall ve F1-Score gibi çok çeşitli performans ölçütleri kullanılmıştır. Elde edilen sonuçlar, önerilen DRFN modelinin kıyaslanan algoritmalarından daha iyi performans gösterdiğini ve parmak fotoğraflarının kişi tanıma, cinsiyet tanıma ve yaş tahmini gibi alanlarda kullanılabileceğini göstermiştir.

Bu tez, parmak fotoğrafı kullanarak bireysel doğrulama için DRL tabanlı bir çerçeve önermekle kalmamakta, aynı zamanda ayrıntılı deneyler ve karşılaştırmalı analizler yoluyla etkinliğini göstermektedir.

Anahtar Kelimeler: Biyometrik Doğrulama, Derin Öğrenme, Parmak Görüntüleri, Kişisel Tanıma.

ABSTRACT

MASTER'S THESIS

PREDICTION OF INDIVIDUALS AGE AND GENDER BASED ON FINGERPHOTO

Islam Nahedh Fadhil ALABDOO

**KIRŞEHİR AHİ EVRAN UNIVERSITY
INSTITUTE OF NATURAL AND APPLIED SCIENCES
DEPARTMENT OF ADVANCED TECHNOLOGIES**

Supervisor: Asst. Prof. Dr. Mehmet Ali ALÇINKAYA
Year: 2024 **Pages:** 87
Juries: Assist. Prof. Dr. Mehmet Ali ALÇINKAYA
Assoc. Prof. Dr. Emrah AYDEMİR
Assist. Prof. Dr. Murat IŞIK

This thesis work involves a Deep Recurrent Learning (DRL) model called the Deep Recurrent Fingerphotos Network (DRFN), which performs individual recognition, age estimation, and gender prediction based on finger photo images. The architecture of the proposed DRFN model consists of an input layer, several hidden layers, an output layer, and a significant feedback connection. This connection allows the sequential processing of finger photo images taken from an individual's ten fingers, enabling the DRFN to dynamically adjust the importance of each finger photo.

To test the accuracy of the proposed model, researchers have collected a dataset consisting entirely of original images, featuring samples from individuals. For each individual, there are photos of all ten fingers taken from ten different angles. The tasks performed within the scope of the study on this original dataset include individual recognition, gender determination, age estimation, and the evaluation of performance results. Additionally, the study includes extensive experiments and comparisons between the proposed DRFN and other well-known deep learning networks used for feature extraction such as AlexNet, LeNet, GoogleNet, VGG16, and ResNet-50. These evaluations also utilized various classifiers including Support Vector Machines (SVM), Random Forest, Multilayer Perceptron (MLP), Linear Regression, and Logistic Regression. A wide range of performance metrics such as Precision, Recall, and F1-Score were used in the evaluation of the analyses. The results demonstrate that the proposed DRFN model performs better than the compared algorithms and that finger photos can be used in fields such as individual recognition, gender recognition, and age estimation.

This thesis not only proposes a DRL-based framework for individual verification using finger photos but also demonstrates its effectiveness through detailed experiments and comparative analyses.

Keywords: Biometric, verification, Deep Learning, Finger Images, Personal Recognition.

TABLolar DİZİNİ

	Sayfa No
Tablo 2.1. İlgili Parmak Fotoğrafları Tanıma Literatür Taraması İçin Özet	16
Tablo 3.1. CNN Mimarilerine Karşılaştırmalı Genel Bakış: AlexNet, LeNet, GoogLeNet, VGG16 ve ResNet-50	34
Tablo 4.1. Dengeli Sınıflandırma Testinde Her Sınıf İçin Doğruluk Metrikleri	52
Tablo 4.2. Parmak Fotoğraflarıyla Cinsiyet Sınıflandırması İçin Ayrıntılı Doğruluk Metrikleri	57
Tablo 4.3. Dengeli Veri Seti Kullanılarak Cinsiyet Sınıflandırması İçin Doğruluk Metrikleri	58
Tablo 4.4. Çeşitli DL Ağlarının Performans Metriklerinin Karşılaştırmalı Analizi	59
Tablo 4.5. Karşılaştırmalı Analiz: DRFN ve Öznitelik Çıkarma Modelleri ve Sınıflandırıcılara Ait Performans Metrikleri	60
Tablo 4.6. 6 Sınıfın Dikkate Alındığı İlk Ana Deney İçin Yaş Sınıfları	62
Tablo 4.7. Parmak Fotoğraflarının Yaşa Özgü Sınıflandırma Doğruluğu İçin Değerlendirme Metrikleri	62
Tablo 4.8. Parmak Fotoğraflarının Yaşa Özgü Sınıflandırma Doğruluğu İçin Değerlendirme Metrikleri	63
Tablo 4.9. Deney 2'deki Dengeli Yaş Grupları için Performans Metriklerinin Değerlendirilmesi	64
Tablo 4.10. DRFN ile Çeşitli Öznitelik Çıkarıcı- Sınıflandırıcı Kombinasyonlarının Karşılaştırmalı Performans Metrikleri	66

ŞEKİLLER DİZİNİ

	Sayfa No
Şekil 1.1. Farklı parmak izi özelliklerinin gösterimi (Krish et al., 2019)	3
Şekil 1.2. Bu tezde kullanılan veri kümesinden bir parmak fotoğrafı örneği	3
Şekil 1.3. Her biri fizyolojik biyometrik özellik olarak kullanılabilen çeşitli insan özellik örnekleri (Raid Rafi Omar Al-Nima, 2017)	4
Şekil 1.4. Her biri davranışsal biyometrik özellik olarak kullanılabilen çok sayıda kişisel stil davranışsal özellik örneği (Raid Rafi Omar Al-Nima, 2017).....	5
Şekil 1.5. Kayıt modunun tipik işlemleri(Raid Rafi Omar Al-Nima, 2017).....	8
Şekil 1.6. Tanımlama modunun tipik işlemleri(Raid Rafi Omar Al-Nima, 2017)	9
Şekil 1.7. Tipik doğrulama modu işlemleri (Raid Rafi Omar Al-Nima, 2017)	10
Şekil 3.1. FITF veri seti için elde edilen ham parmak fotoğrafı örnekleri.....	21
Şekil 3.2. Ön İşlemden Sonra Parmak Fotoğrafı ROI Örnekleri	23
Şekil 3.3. Bir CNN yapılandırma örneğinin gösterimi (Kiranyaz et al., 2021)	29
Şekil 3.4. LeNet'in Temel Mimarisi (LeCun et al., 1998)	30
Şekil 3.5. AlexNet'in Temel Mimarisi (Krizhevsky et al., n.d.)	30
Şekil 3.6. GoogLeNet'in Temel Mimarisi (Szegedy et al., 2015).....	31
Şekil 3.7. VGG16'nın Temel Mimarisi (Ewe et al., 2022).....	32
Şekil 3.8. ResNet-50'nin Temel Mimarisi (Bezdán & Bačanić Džakula, 2019)	32
Şekil 3.9. Önerilen DRFN modelinin mimarisi	43
Şekil 4.1. Sınıf 1 İçin Karmaşıklık Matrisi	55
Şekil 4.2. Sınıf 50 İçin Karmaşıklık Matrisi	56
Şekil 4.3. Sınıf 100 İçin Karmaşıklık Matrisi	56
Şekil 4.4. Parmak Fotoğraflarıyla Cinsiyet Sınıflandırması İçin Karmaşıklık Matrisi.....	57
Şekil 4.5. Dengeli Veri Seti ile Cinsiyet Sınıflandırması İçin Karmaşıklık Matrisi.....	58
Şekil 4.6. İlk Yaş Grubu İçin Karmaşıklık Matrisi.....	63
Şekil 4.7. 2. Yaş Gruplandırması için Karmaşıklık Matrisi.....	65

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler	Açıklama
β	: Belirlenmiş bir insan parmağının ağırlığı
I	: Geometrik Moment
X, Y	: Pozitif olmayan tam sayılar
Z, N	: Piksel koordinatları
M	: Piksel yoğunluğu
IMF	: Parmak Fotoğrafi Görüntüsü
V, q	: Evrişim özellik haritası
z, t	: Bir uzaysal koordinatı temsil eder
D	: Sapma
j, k, i, q	: Uzaysal konum
$L_{z,t,q}$: ReLU Katman
$k_{a^l, b^l, c}$: Havuzlama katmanının sonucu
h_p^l, h_p^l	: Havuzlanmış bir kanalın yüksekliği
w_p^l, w_p^l	: Havuzlanmış bir kanalın genişliği
FL_r	: FC katmanının çıkışı
mc_1^{l-1}	: Bağlama katmanındaki bir kanalın yüksekliği
mc_2^{l-1}	: Havuzlama katmanındaki bir kanalın genişliği
K	: Havuzlama katmanının çıkışları
mc^l	: FC katmanında gereken nöron sayısı
SL_r	: Softmax katmanının sonucu
FC_r	: Sınıflandırma katmanının bir çıkış kararı

Kısaltmalar	Açıklama
AFIS	: Otomatik Parmak İzi Tanımlama Sistemi'nin (Automated Fingerprint Identification System)
ATM	: Otomatik Vezne Makineleri(Automated Teller Machines)
CASIA-BLU	: Mavi spektrumda görüntüler içeren (Çin Bilimler Akademisi Otomasyon Enstitüsü) veritabanı (Chinese Academy of Sciences Institute of Automation) database with images in the blue spectrum
CASIA-WHT	: Beyaz spektrumda görüntüler içeren (Çin Bilimler Akademisi Otomasyon Enstitüsü) veritabanı (Chinese Academy of Sciences Institute of Automation) database with images in the white spectrum
CDFL	: Bir Çift Derin Parmak Fotoğrafi Öğrenme (Couple of Deep Fingerphotos Learning)
COTS	: Raf Üstü Ticari (Commercial Off-The-Shelf)
DDFL	: Çift Derin Parmak Fotoğrafi Öğrenme (Dual Deep Fingerphoto Learning)
DDFL	: Çift Derin Parmak Fotoğrafi Öğrenme (Dual Deep Fingerphoto Learning)
DFCN	: Derin Parmak İzi Sınıflandırma Ağı (Deep Fingerprint Classification Network)
DFL	: Derin Parmak Fotoğrafi Öğrenme (Deep Fingerphoto Learning)
DFTL	: Derin Parmak Dokusu Öğrenme (Deep Finger Texture Learning)
DNA	: DeoksiriboNükleik Asit (DeoxyriboNucleic Acid)
DRFN	: Derin Tekrarlayan Parmak Fotoğrafları Ağı (Deep Recurrent Fingerphotos Network)
DRL	: Derin Tekrarlayan Öğrenme (Deep Recurrent Learning)
EER	: Eşit Hata Oranı (Equal Error Rate)
FAR	: Yanlış Kabul Oranı (False Acceptance Rate)
FC	: Tam Bağlantılı (Fully Connected),

FG	:	Parmak Geometrisi (Finger Geometry)
FIK	:	Parmak İç Ekleme (Finger Inner Knuckle)
FITF	:	On Parmaklı Parmak Fotoğrafları (Fingerphoto Images of Ten Fingers)
FN	:	Yanlış Negatif (False Negative)
FOK	:	Parmak Dış Ekleme (Finger External Joint)
FP	:	Yanlış Pozitif (False Positive)
FRR	:	Yanlış Reddetme Oranı (False Rejection Rate)
FT	:	Parmak Dokusu (Finger Tissue)
FT	:	Parmak Dokusu (Finger Tissue)
FV	:	Parmak Damarları (Finger Veins)
FVC	:	Parmak İzi Doğrulama Yarışması veritabanı (Fingerprint Verification Competition) database
IITD	:	Hindistan Teknoloji Enstitüsü Delhi veritabanı
JPG	:	Ortak Fotoğraf Uzmanları Grubu formatı (Joint Photographic Experts Group format)
LED	:	Işık Yayan Diyot (Light Emitting Diode)
MBASSy	:	Modüler Biyometrik Kimlik Doğrulama Servis Sistemi (Modular Biometric Authentication Service System)
PolyU2D	:	Hong Kong Politeknik Üniversitesi Temassız 3D/2D Veritabanı
ReLU	:	Doğrultulanmış Doğrusal Birim (Rectified Linear Unit)
RGB	:	Kırmızı, Yeşil, Mavi (Red,Green,Blue)
ROI	:	İlgi Bölgesi (Region of Interest)
SVM	:	Destek Vektör Makinesi(Support Vector Machine)
TN	:	Gerçek Negatif (True Negative)
TP	:	Gerçek Pozitif (True Positive)

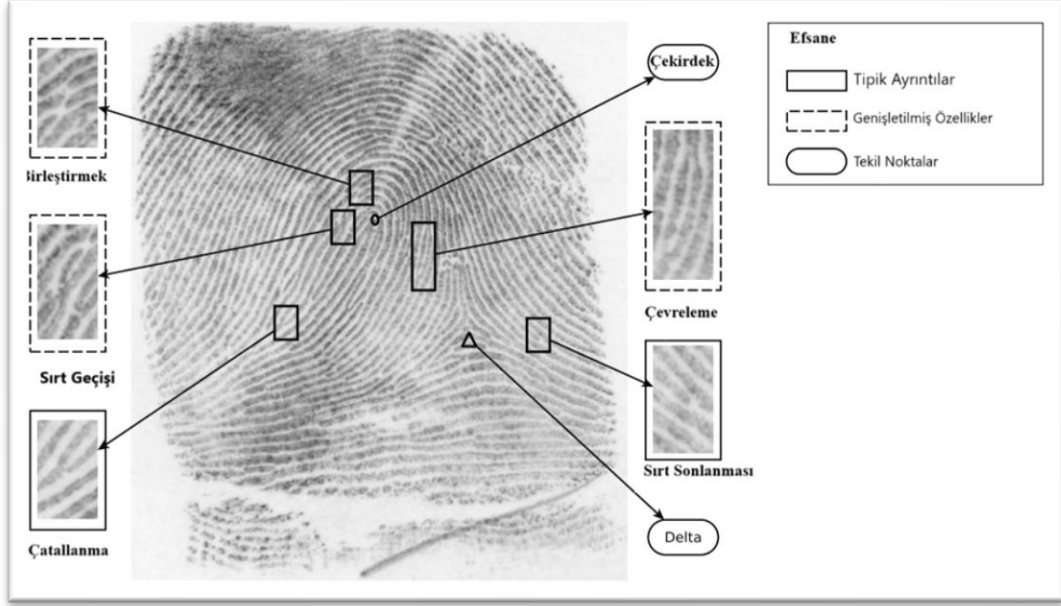
1. GİRİŞ

Biyometrik verilerin kullanıldığı kimlik doğrulama süreçlerinin kökenleri, bireylerin ayırt edici özelliklerine göre tanındığı eski uygarlıklara kadar uzanmaktadır. Özellikle Babilliler işlemlerinde kil tabletler üzerinde parmak izlerini, Çinliler ise belgeler üzerinde el izlerini kullanmışlardır. Ancak modern çağ, biyometrik kimlik doğrulama teknolojilerinin geliştirilmesinde önemli adımlar atmıştır. 19. yüzyılda Fransız polis memuru Alphonse Bertillon, kimlik tespiti için fiziksel ölçümlere dayanan antropometri sistemini tanıtmıştır. Bu arada, 19. yüzyılın sonları ve 20. yüzyılın başlarında Sir Francis Galton ve Sir Edward Henry parmak izi tanımlamanın temelini atan önemli katkılarda bulunmuşlardır. Otomatik Parmak İzi Tanımlama Sistemi'nin (AFIS) 1970'lerde kullanılmaya başlanması, büyük veri tabanlarına karşı parmak izi eşleştirmesinin otomatikleştirilmesinde kritik bir ilerleme olarak kaydedilmiştir. 20. yüzyılın sonlarında, temel algoritmaları kullanan ilk sistemlerle birlikte yüz tanıma teknolojilerinin yükselişi görülmüştür. Bu dönemde ayrıca iris tanımanın güvenilir bir biyometrik yöntem olarak ortaya çıkışı da incelenmiştir. Derin öğrenme ve yapay zeka alanındaki gelişmeler, 21. yüzyılın başlamasıyla birlikte biyometrik sistemleri daha da geliştirerek daha hassas özellik çıkarma ve eşleştirme algoritmalarına olanak sağlamıştır. Birden fazla tanıma yöntemini içeren çok modlu biyometrikler, doğruluğu ve güvenliği artırmak için yaygın bir alan haline gelmiştir. Teknoloji gelişmeye devam ettikçe, biyometrik kimlik doğrulama, geleceğini şekillendiren devam eden araştırmalarla dinamik bir alan olmaya devam etmektedir (Fosdick, 1915).

'Biyometri' terimi genellikle bireyleri tanıma tekniğini ifade etmek için kullanılır. Güvenlik sistemleri, adli soruşturmalar ve kişisel tanımlama gibi çeşitli alanlarda uygulanmaktadır. İnsan vücudunun iris, sklera, yüz, avuç içi izi, ses ve Parmak Dokusu (FT) gibi çok sayıda özelliği kapsamlı bir şekilde araştırılmıştır. Biyometrik tanıma, cep telefonları, dizüstü bilgisayarlar ve Otomatik Vezne Makineleri (ATM'ler) gibi teknolojik cihazlara güvenli erişim sağlayan çok sayıda tanıma sisteminde önemli bir rol oynamaktadır. Biyometrik özellikler genel olarak iki kategoride sınıflandırılır: fizyolojik biyometri ve davranışsal biyometri. Fizyolojik biyometri örnekleri arasında parmak izleri, iris desenleri, avuç içi izleri ve parmak fotoğrafları yer alır. Yüksek güvenilirlik için kullanılırlar. Davranışsal biyometriye örnek olarak imzalar, tuş vuruş dinamikleri ve ses verilebilir. Bu biyometri türleri, güvenilirliklerini potansiyel olarak etkileyen duygusal durumlardan etkilenir (Raid Rafi Omar Al-Nima, 2017).

Parmaklar, Parmak Geometrisi (FG) gibi birçok yararlı biyometrik özelliğe sahiptir (Ayurzana et al., 2013; Sanchez-Reillo et al., 2000a), Parmak Damarları (FV) (Khanam et al., 2019), Parmak Dış Eklemi (FOK) (R. R. O. Al-Nima et al., 2020), Parmak İç Eklemi (FIK) (Bahmed et al., 2019; M. Liu & Yan, 2013) ve Parmak Dokusu (FT) (Al-Kaltakchi et al., 2019; R. R. O. Al-Nima et al., 2017). Bu özelliklerin her biri önemli bir anlamlılık düzeyi sağlayabilir. Ancak son zamanlarda yapılan çalışmalar parmak fotoğrafını önemli bir biyometrik özellik olarak vurgulamaktadır (R. R. Al-Nima et al., 2020; Wasnik et al., 2018). Temel olarak, bir akıllı telefon tarafından doğrudan dokunmadan (temassız) alınan parmak izini ifade eder.

Bir parmak fotoğrafının parmak izi, parmak izi özelliği ile benzer kavramlara sahiptir. Parmak izleri en iyi bilinen biyometriklerden biri olarak hizmet vermektedir. Benzersiz olmaları nedeniyle kullanılmaktadırlar. Her birey, kişisel tanımlama için ideal bir araç sağlayan farklı çıkıntılar ve girdaplardan oluşan bir koleksiyona sahiptir. Parmak izi, adli soruşturmalar için vazgeçilmez hale gelmiş ve dünyanın dört bir yanındaki kolluk kuvvetlerine suçların çözülmesinde yardımcı olmuştur. Ayrıca sistemlere güvenli erişim, göçmenlik kontrolleri ve güvenlik sınırlarının geçilmesi de dahil olmak üzere çeşitli alanlardaki uygulamalarını genişletmiştir. Parmak izlerinin bireyin yaşamı boyunca kalıcı ve değişmeyen doğası, kimlik tespiti ve güvenlikte doğruluk ve güvenilirliğin sağlanmasında çok önemli bir rol oynamaktadır. Parmak izlerinin kalıcı biyolojik özelliği, toplumdaki bireyleri ve toplulukları korumak için temel bir araç olmaya devam etmektedir (Chowdhury & Imtiaz, 2022; Venkatesh, 2022). Parmak izleri birleşme, sırt geçişi, çatallanma, çekirdek, çevreleme, sırt sonlanması ve delta şekli gibi değerli özelliklere sahiptir. Bu özellikler Şekil 1.1'de gösterilmektedir (Krish et al., 2019).



Şekil 1.1. Farklı parmak izi özelliklerinin gösterimi (Krish et al., 2019)

Yine, parmak fotoğrafı akıllı telefon tarafından çekilen parmak izi anlamına gelmektedir. Şekil 1.2'de bu tezde kullanılan veri kümesinden alınmış bir parmak fotoğrafı örneği gösterilmektedir.




Şekil 1.2. Bu tezde kullanılan veri kümesinden bir parmak fotoğrafı örneği

Raporlara ve tanımlara göre biyometri genel olarak iki gruba ayrılabilir (Bača et al., 2009):

1.1. Fizyolojik Biyometri


Fizyolojik biyometri, bireyin vücut fizyolojik özelliklerinin tanımlanması ve analiz edilmesi ile ilgilidir. Bu özelliklere örnekler arasında parmak izleri (Stein et al., 2013), DNA (Lahmer et al., 2020), iris desenleri (Shirke & Rajabhushnam, 2019), yüz özellikleri (Alghamdi et al., 2020), ellerin geometrisi (Sanchez-Reillo et al., 2000b), kulak izleri (Abaza & Ross, 2010) ve parmak dokuları (Omar et al., 2019) bulunmaktadır. Çeşitli fizyolojik biyometrik özelliklerin kapsamlı bir genel bakışı Şekil 1.3 (Raid Rafi Omar Al-Nima, 2017) 'de bulunabilir.



Şekil 1.3. Her biri fizyolojik biyometrik özellik olarak kullanılabilen çeşitli insan özellik örnekleri (Raid Rafi Omar Al-Nima, 2017)

1.2. Davranışsal Biyometri

Davranışsal biyometri, bireylerin davranış kalıpları ile ilgili bir kavramdır. Davranışsal biyometriye örnek olarak imza (Malik et al., 2020) ve tuş vuruş dinamikleri (Bernardi et al., 2019; R. K. Das et al., 2014) verilebilir. Şekil 1.4, çeşitli davranışsal biyometrik özellikleri detaylandırmaktadır (Raid Rafi Omar Al-Nima, 2017).



Şekil 1.4. Her biri davranışsal biyometrik özellik olarak kullanılabilen çok sayıda kişisel stil davranışsal özellik örneği (Raid Rafi Omar Al-Nima, 2017).

Fizyolojik biyometri tipik olarak daha yüksek derecede doğruluk ve güvenilirlik ile karakterize edilirken, davranışsal biyometri potansiyel olarak hastalık veya stres gibi duygusal durumlardan etkilenebilir. Yaygın fizyolojik ve davranışsal özelliklerin kısa açıklamaları aşağıdaki bölümlerde sunulmuştur:

- İris içindeki kas yapılarının oluşturduğu benzersiz desen gözün renkli bölgesinde, göz bebeği ile sklera arasında yer alır. Tanıma sistemlerindeki olağanüstü benzersizliği ve güvenilirliği nedeniyle iris, kişisel tanımlamada geniş kullanım alanı bulmuştur.
- El Geometrisi kavramı öncelikle avuç içi, parmak uzunlukları ve parmak genişlikleri dahil olmak üzere el şeklinin genel özelliklerini dikkate alır.
- Yüz, zengin dokular ve çeşitli nesnelere içerir, bu da onu yüz algılama, yüz duygu tanıma ve yüz özelliklerinin tanınması gibi çeşitli alanlarda yararlı kılar.
- Elin avuç içi yüzeyi, çıkıntılar, kırışıklıklar ve çizgiler gibi tutarlı bir dizi biyometrik özelliğe sahiptir. Bu özellikler, kişisel tanımlama söz konusu olduğunda kişinin avantajına kullanılabilir.
- Deoksiribonükleik Asit (DNA), adli soruşturmalarda şüpheli kişilerin kimliklerinin belirlenmesi için etkili bir şekilde uygulanabilecek ilgi çekici bir dizi yararlı koda sahiptir.
- Retina, göz küresinin arkasında, kişisel tanımlama için kullanılabilen benzersiz damar desenlerine sahip bir yapıdır.
- İmza, kişiye özgü birçok özelliği barındırmaktadır. İmzanın grafik biçimi ve el yazısı desen dağılımının yoğunluğu gibi çeşitli hususlar dikkate alınabilir.
- Her kişinin tuş vuruşu farklı bir tona sahip olduğundan dolayı biyometrik bir özellik olarak kullanılabilir.
- Çok sayıda yayın, konuşmacı tanıma için ses özelliğini incelemiş ve kullanmıştır.
- Yürüyüş tarzı üzerinden bir kişiyi tanımlamak veya doğrulamak mümkündür.
- Parmak fotoğrafları her kişi için benzersizdirler ve ayırt edici desenleri nedeniyle güvenilir bir biyometrik tanımlama olarak kullanılabilirler. Tanıma sistemlerinde parmak fotoğraflarının kullanılması, hassas ve güvenli doğrulama sağlayarak erişim kontrolünü, tanımlamayı ve genel siber güvenliği geliştirir.

1.3 Biyometrik Gereksinimler

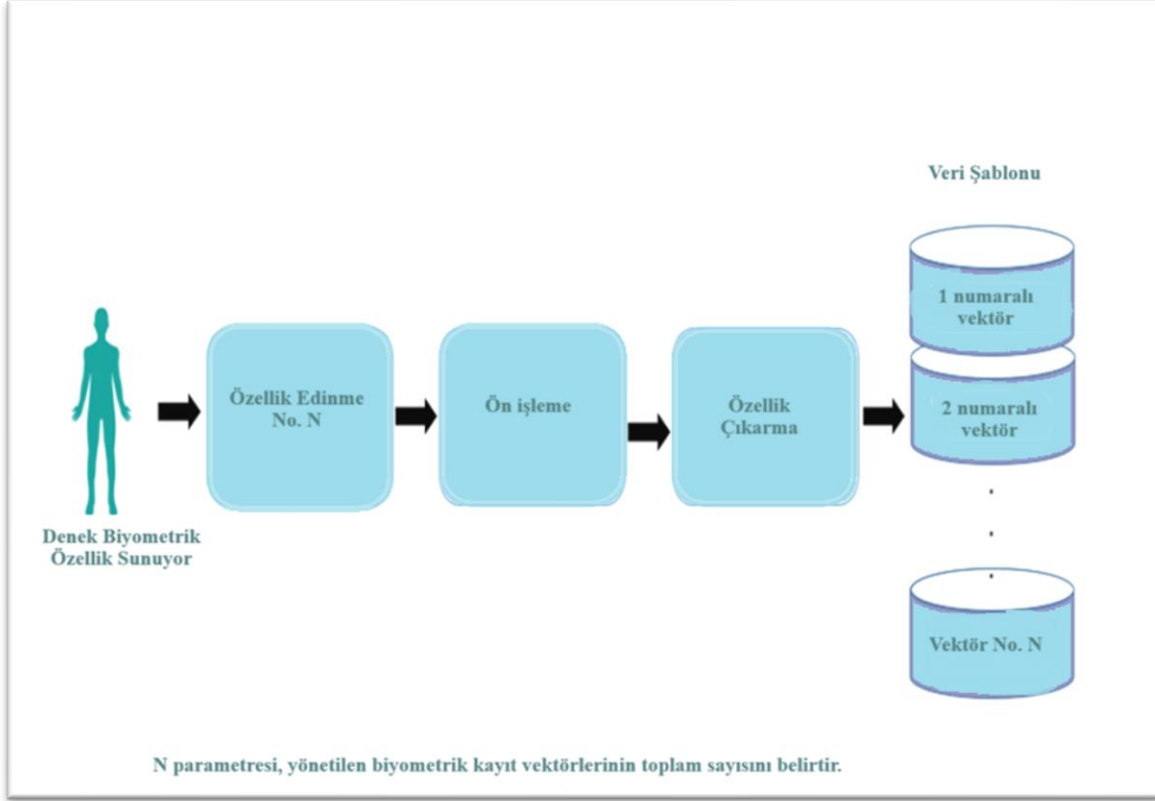
Herhangi bir fizyolojik veya davranışsal özelliğin biyometrik özellik olarak sınıflandırılabilmesi için bir dizi gereksinimin karşılanması gerekmektedir. Bu gereksinimler sırası ile kararlılık, benzersizlik ve popülerliktir. Kararlılık; biyometrik modellerin uzun ömürlü ve istikrarlı olması anlamına gelir. Benzersizlik; özelliğin niteliklerinin farklı olmasını ve herhangi iki kişi arasında farklılık göstermesini ifade eder. Toplanabilirlik, toplanan biyometrik özelliklerin ölçülebilir ve değerli doğası ile ilgilidir. Popülerlik ise biyometrik özelliğin insanlar arasında yaygın olarak tarafından tercih edilmesini veya onlara özel olmaması anlamına gelir.

1.4 Biyometrik Sistem Modları

Her biyometrik sistem temel olarak bir biyometrik özelliğin elde edilmesiyle başlayan ve sistem moduna göre nihai bir işlem oluşturmak için özellik çıkarma ve ön işleme (segmentasyon ve morfolojik işlemler gibi) yoluyla ilerleyen bir dizi işlemden oluşur(Jain et al., 2004)(Dorizzi, 2013). Biyometrik bir sistem genellikle tanımlama veya doğrulama için kullanılır. Özellikle, aşağıdaki üç moddan herhangi birinde çalışacak şekilde ayarlanabilir:

1.4.1 Kayıt modu

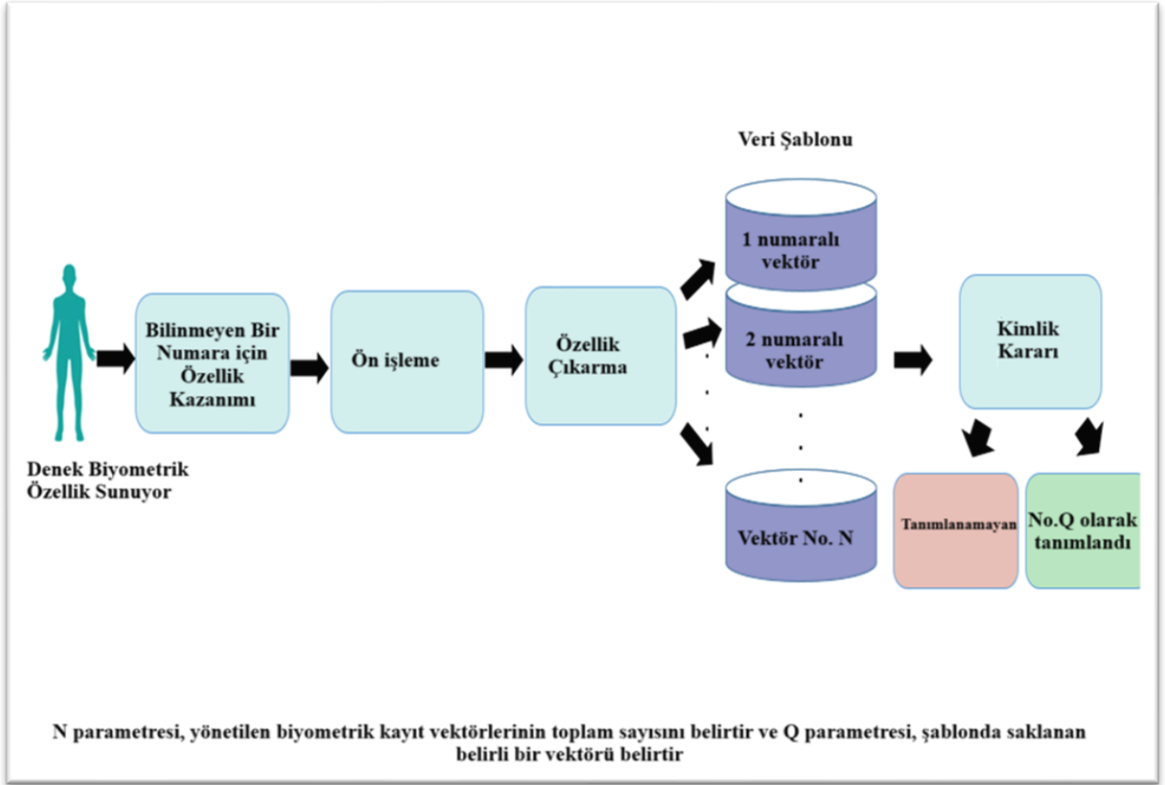
Birbiri ardına gelen kayıt modları politika olarak bilinir. Kayıt, bir veri şablonunun kayıtlı biyometrik özelliğin çıkarılan özelliklerini topladığı herhangi bir biyometrik sistemdeki ilk adımdır. Her girdi, elde etme sürecinin başlangıcından çıkarılan özelliklerin şablonda depolandığı noktaya kadar bu mod tarafından bağımsız ve ayrı olarak ele alınır. Kayıt modunun normal işlemleri Şekil 1.5'te gösterilmektedir (Raid Rafi Omar Al-Nima, 2017).



Şekil 1.5. Kayıt modunun tipik işlemleri(Raid Rafi Omar Al-Nima, 2017)

1.4.2. Tanımlama modu

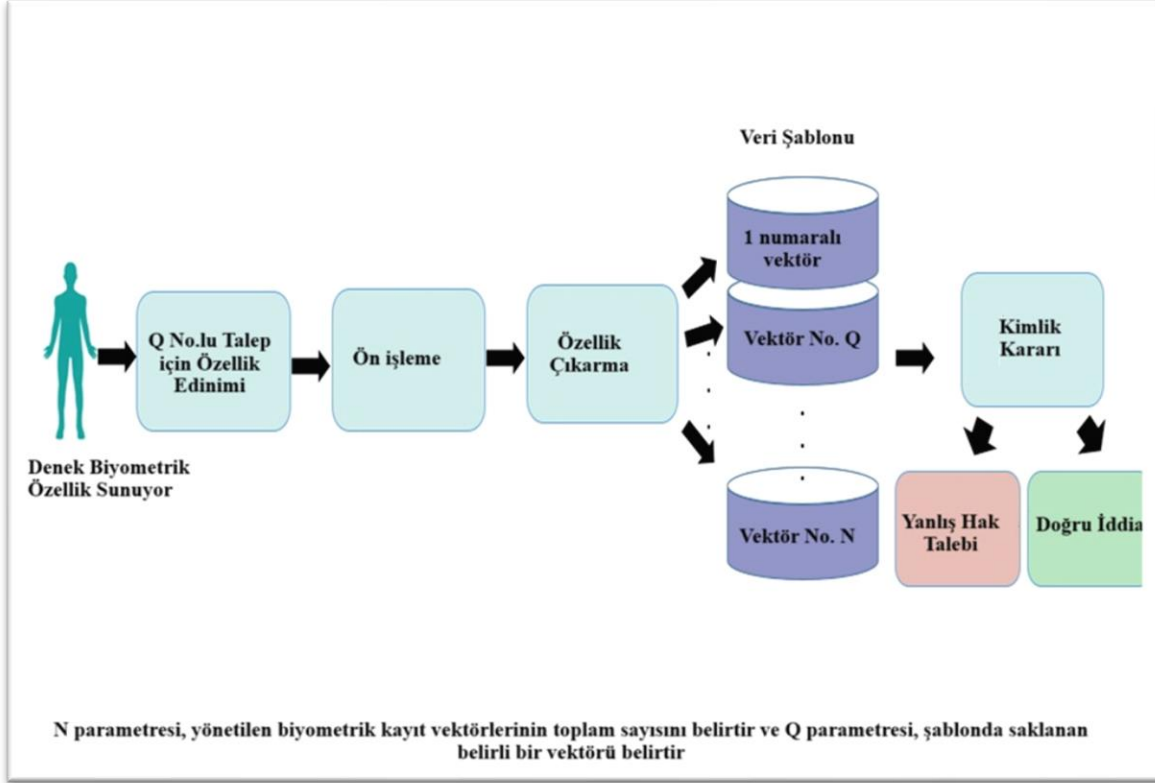
Tanımlama modunu bire-çok politikası yönetir. Benzer şekilde, önceki modlar bir dizi edinim, ön işleme ve özellik çıkarımı ile sunulur. Bu noktadan itibaren, şablonda depolanan tüm veriler çıkarılan özellik bilgileriyle eşleştirilir. Bu modda kullanıcı kimliğini açıklamadığı için, kimliğini atayıp atamamak kullanıcının tercihine kalmıştır. Kimlik belirleme modunun tipik işlemleri Şekil 1.6'da gösterilmektedir (Raid Rafi Omar Al-Nima, 2017).



Şekil 1.6. Tanımlama modunun tipik işlemleri(Raid Rafi Omar Al-Nima, 2017)

1.4.3. Doğrulama modu

Bu doğrulama modu bire bir politika kullanır. Kullanıcı bu moddayken kimliğini beyan eder. Edinme, ön işleme ve özellik çıkarma adımları benzer bir sırayla gerçekleştirilir. Çıkarılan özellik bilgileri kullanıcının saklanan verileri ile karşılaştırılır. Sonuç olarak, kişisel kimlik iddiasının kabul edilip edilmeyeceği belirlenir. Doğrulama modunun tipik işlemleri Şekil 1.7'de gösterilmektedir (Raid Rafi Omar Al-Nima, 2017).



Şekil 1.7. Tipik doğrulama modu işlemleri (Raid Rafi Omar Al-Nima, 2017)

1.5 Tezin Amacı ve Katkıları

Bu tezin amacı, Derin Tekrarlayan Öğrenme (DRL) kullanarak geliştirilen Derin Tekrarlayan Parmak Fotoğraf Ağı (DRFN) isimli bir modelin test edilmesi ve kişi doğrulama, yaş tahmini ve cinsiyet tahmini için parmak fotoğraf biyometrisinin potansiyelini araştırmaktır.

Gerçekleştirilen çalışmanın temel hedeflerden biri, geniş bir parmak fotoğrafı görüntüleri koleksiyonu içeren Fingerphoto Images of Ten Fingers (FITF) veri setinin derlenmesi ve kullanılmasıdır. Bu veri kümesi, çalışmanın ögün kısımlarından birini oluşturmaktadır. Veri seti içerisinde yer alan her bir fotoğraf bizzat tarafımızca çekilmiş ve veri seti içerisinde eklenmiştir. Toplanan veri seti, önerilen modelin eğitimi ve değerlendirilmesi için temel oluşturarak modelin çeşitli senaryolarda etkinliğini sağlamakta ve biyometrik doğrulama için sağlam bir çerçeve oluşturmaktadır.

Bu araştırma aynı zamanda kişisel doğrulama görevlerinde mevcut model ve sınıflandırıcılara kıyasla önerilen modelin performansının değerlendirilmesi amaçlamaktadır. Araştırma, yüksek doğrulama başarısını hedefleyerek, önerilen modelin biyometrik güvenlik alanında uygulanabilirliğini göstermeyi amaçlamaktadır.

Ayrıca tez, önerilen model ile diğer tanınmış derin öğrenme mimarileri arasında kapsamlı bir karşılaştırmalı analiz yapmayı ve mevcut teknolojik standartlar bağlamında modelin performansının altını çizmek için bir dizi değerlendirme ölçütü uygulamayı amaçlamaktadır.

Ek bir amaç da önerilen modelin cinsiyet ve yaş tahmini gibi kimlik doğrulama dışındaki uygulamalardaki faydasını araştırarak modelin çok yönlülüğünü ve FITF veri setinin kapsamlılığını test etmektir. Yapılan bu araştırmalar, modelin daha geniş uygulanabildiği farklı alanları keşfetmek için gerçekleştirilmiştir.

Özünde bu tez, parmak fotoğrafı biyometrisi ile biyometrik güvenlik teknolojilerinin devam eden gelişimine katkıda bulunmayı ve bu yöntemlerinin verimliliğini ile güvenilirliğini artırmayı amaçlamaktadır.

1.6 Tez Organizasyonu

Bu tez çalışması içerisinde yer alan bölümler şu şekilde sıralanabilir: 1. bölümde giriş, 2. bölümde literatür taraması, 3. bölümde materyal ve yöntemler, 4. bölümde araştırma bulguları, 5. bölümde ise tartışma ve sonuçlar yer almaktadır.

2. ÖNCEKİ ÇALIŞMALAR

Literatürde yer alan çalışmalar incelendiğinde, parmak fotoğrafının kullanıldığı çalışma sayısında bir artış olduğu görülmektedir. Parmak fotoğraflarının tanınması için mevcut literatürde bir araştırma yapılmış ve çeşitli algoritmaların oluşturulmasıyla sonuçlanmıştır. Tablo 2.1'de ilgili parmak fotoğrafı tanıma çalışmalarının literatür taraması için bir özet verilmiştir. Bu çalışmalar aşağıdaki gibi incelenebilir:

Stein ve arkadaşları 2012 yılında akıllı telefon kameralarını kullanarak parmak izi tanıma kabiliyetini ve uygulamasını araştıran bir kimlik doğrulama tekniği önermişlerdir. Görüntü yakalama ve ön işleme için iyileştirici algoritmalar dahil edilmiştir. İki deneysel cihazdan alınan görüntüleri içeren bir veri kümesi toplamda sadece 41 katılımcıdan toplanmıştır (Stein et al., 2012).

2015 yılında Tiwari ve arkadaşları, mobil el cihazları için herhangi bir fiziksel temas olmadan çalışan ve alternatif, geleneksel olmayan ölçekle değişmeyen özellikleri kullanan bir parmak fotoğrafı tanıma sisteminin uygulanmasını önermiştir. Parmak fotoğrafı analizi yoluyla mobil el cihazlarında insan kullanıcıların kimliğini doğrulamak için önerilen sistem, belirli tarama cihazlarına olan bağımlılığı ortadan kaldırmıştır. Kullanılan veri kümesi 50 kişiden oluşmaktadır (Tiwari & Gupta, 2015).

2017 yılında Birajadar ve arkadaşları, monojenik dalgacık tabanlı ve faz tutarlılığı özelliklerini kullanarak bir parmak fotoğrafı iyileştirme tekniğini entegre etmiştir. Yazarlar, çevresel olarak kısıtlanmamış koşullar altında parmak fotoğrafçılığı için başarılı bir şekilde bir veri kümesi oluşturdu. Canlı tarama görüntüleri ile birlikte bir akıllı telefon kamerası kullanılmıştır. Veri kümesi, her bir deneğin 4 görüntü ile ilişkilendirildiği 50 denekten oluşuyordu. Sonuç olarak, veri kümesindeki toplam görüntü sayısı 200'e ulaşmıştır. (Birajadar et al., 2017).

Aynı yıl Carney ve meslektaşları, akıllı telefonlar kullanarak, sadece arka kamera ve Işık Yayan Diyot (LED) flaş kullanarak parmak izlerinin yakalanmasına olanak tanıyan Çoklu Parmak Temassız parmak izi sistemi kurdular. Bu özel sistem, dokunmaya dayalı bir baskıyı simüle etmek için her parmağın karşılık gelen bir görüntüsünün tanımlanmasını ve geliştirilmesini kolaylaştıran otomatik bir görüntü yakalama mekanizması içeriyordu. Değerlendirme amacıyla 1400 temassız parmak izi ve 6600 dokunmatik tabanlı parmak izinden oluşan bir ön test veri seti kullanılmıştır (Carney et al., 2017).

2018 yılında Deb ve arkadaşları parmak fotoğraflarının arka özelliklerini toplamak için iki Android uygulaması oluşturmuştur. Sağ ve sol eller için 309 denekte

yalnızca iki başparmak ve iki işaret parmağı kullanılmıştır. Her parmağı bağımsız olarak analiz ettikten sonra, üç füzyon prosedürü kullanılmıştır: iki başparmak arasında füzyon veya iki işaret parmağı arasında füzyon; her elin başparmağı ve işaret parmağı arasında füzyon; ve kullanılan tüm parmakların füzyonu (her iki elin başparmağı ve işaret parmağı). Kullanılan her bir füzyon için, puan seviyelerinin kombinasyonları için toplama kriterleri uygulanmıştır (Deb et al., 2018).

Aynı yıl Omer ve arkadaşları parmak dokusu (FT) üzerine parmak izinden önce alt parmak ekleminden üst parmak kemiğine kadar olan alanı kapsayan Derin Parmak Dokusu Öğrenme (DFTL) isimli bir çalışma gerçekleştirmiştir. Önerilen yöntem dört veri tabanı kullanılarak değerlendirilmiştir: PolyU2D, IITD, CASIA-BLU ve CASIA-WHT. Bu çalışmada aynı elin işaret ve orta parmakları kullanılmıştır. Sonuçlar, PolyU2D, IITD, CASIA-BLU ve CASIA-WHT veritabanları için sırasıyla %100, %98,65, %100 ve %98'lik doğrulama doğrulukları elde ederek kayda değer bir performans ortaya koymuştur (Omar et al., 2019)

2019 yılında Birajadar ve arkadaşları temassız parmak izlerini geliştirmek için monojenik dalgacık tabanlı bir algoritma kullanmışlardır. Yazarlar, deneysel analizlerinde yaygın olarak kullanılan üç açık kaynaklı ve Ticari Kullanıma Hazır (COTS) eşleştirme sistemini kullanmışlardır. Önerilen algoritma, mevcut dokunma tabanlı parmak izi eşleştiricileri için zor olan temassız parmak izi görüntülerinden güvenilir minutiae özellikleri çıkarma zorluğunu ele almıştır. Veri kümesi, her denek için 4 örnek olmak üzere 200 denekten alınan 800 temassız parmak izi görüntüsünden oluşmuştur. (Birajadar et al., 2019)

2020 yılında, Al-Nima ve arkadaşları birey tanıma için parmak fotoğrafı görüntülerini kullanarak Dual Deep Fingerphoto Learning (DDFL) yöntemini tanıtmıştır. Bu yaklaşım, her ikisi de Deep Fingerphoto Learning (DFL) olarak adlandırılan iki derin öğrenme ağını bir araya getirmiştir. Çalışmada özellikle IITD akıllı telefon parmak fotoğrafı veri kümesi kullanılmış ve burada yalnızca sağ elin orta ve işaret parmaklarının parmak fotoğrafı görüntüleri dikkate alınmıştır. Veri kümesi, her biri 8 görüntü ile temsil edilen 64 denek içeriyordu (R. R. Al-Nima et al., 2020).

2021'de İbrahim ve arkadaşları, gerçek ve sahte parmak izlerini ayırt etme doğruluğunu artırmayı amaçlayan bir derin parmak izi sınıflandırma ağı (DFCN) modeli tanıttı. Her iki el için de işaret ve orta parmaklar kullanılmıştır. Model, ATVS-FFp_DB veri kümesinden 512 görüntü kullanılarak değerlendirilmiş ve %99,22 sınıflandırma performansı elde edilmiştir. (İbrahim et al., 2021).

2021 yılında da Kauba ve arkadaşları, temassız parmak izi alımı için polis memurlarının iş akıllı telefonlarını kullanmanın fizibilitesini araştırmış ve temasa dayalı veri kümeleriyle karşılaştırmıştır. Bu araştırma sadece mobil cihazlarda parmak izi tanımanın teknik zorluklarını ele almakla kalmamış, aynı zamanda parmak izi tanıma araç zincirindeki farklı aşamaların ayrıntılı bir analizini de sağlamıştır. Bu çalışmada, TensorFlow Object Detection API ve özellikle MobileNetV2 kullanılarak transfer öğrenimi de dahil olmak üzere çeşitli yöntemler kullanılmıştır. Veri kümesi, yalnızca 17 kişi için toplam 2640 temassız parmak ucu görüntüsünden oluşuyordu (Kauba et al., 2021).

Aynı yıl, Priesnitz ve arkadaşları akıllı telefonlar için temassız bir parmak izi tanıma sisteminin oluşturulmasını tartışmış, cihaz üzerinde görüntü yakalama, renk ve kontrast kullanarak segmentasyon ve arka plan iş akışını vurgulamışlardır. COVID-19 salgını sırasında toplanan veri kümesi, 29 denekten temassız örnekleri ve toplam 1360 parmak izini içeriyordu. Sistem, kısıtlı olmayan ortamlarda yüksek tanıma performansını ve kullanıcı kabulünü sürdürmenin yanı sıra temassız yakalama cihazının görsel geri bildirimleriyle ilgili endişeler konusunda zorluklarla karşılaştı (Priesnitz et al., 2022).

2023 yılında Al-Nima ve arkadaşları, Parmak Fotoğrafına dayalı kişisel doğrulama için ek derin öğrenme teknikleri üzerine bir çalışma sunmuştur. Çift Derin Parmak Fotoğrafı Öğrenme (CDFL) önerilmiştir. IIITD akıllı telefon parmak fotoğrafı veri kümesi de kullanılmıştır. Bu veri kümesi, sağ eldeki yalnızca iki parmak (orta ve işaret) için parmak fotoğrafı görüntüleri içerir (Omar Al-Nima et al., 2023).

Bazı çalışmalar yaş ve cinsiyet tahmini üzerine odaklanır. 2019'da Rafique ve arkadaşları, yaş ve cinsiyet tahmini yapmak için büyük bir yüz fotoğrafı veri seti üzerinde eğitilmiş derin evrişimli sinir ağları (CNN) kullanarak bir yöntem önerdi. Derin CNN modelini eğitmek için HAAR Özellik-tabanlı Kaskad Sınıflandırıcıları kullandılar. Derin CNN modeli, yaş ve cinsiyet tahmininde %79 doğruluk oranı elde etti (Rafique et al., 2019).

2019'da Jhang ve arkadaşları, CNN tabanlı cinsiyet ve yaş grup tahmin modellerinin, özellikle kamera tabanlı testlerde, gri tonlamalı görüntülerle mi yoksa RGB görüntülerle mi daha iyi performans gösterdiğini araştırdı. Yazarlar, cinsiyet ve yaş tahmini gibi yüz analizi görevleri için zorlayıcı bir veri seti olan Adience veri setini kullandı. Veri seti, hem cinsiyet hem de yaş grup etiketleri ile yaklaşık 12.000 eğitim resmi ve 3.800 test resmi içerir. En iyi cinsiyet tahmin doğruluğu, gri tonlamalı GoogleNet modeli kullanılarak %92'nin üzerindedir. En iyi yaş grubu tahmin doğruluğu

ise gri tonlamalı GoogleNet modeli kullanılarak tam isabetle %60 ve 1-off ile %85 olarak gerçekleşti(Jhang & Cho, 2019).

2023'te Deepanshi ve arkadaşları, yaş ve cinsiyet tespiti için çeşitli yaklaşımlar ve algoritmalar hakkında kapsamlı bir inceleme sağlayarak birçok çalışmayı gözden geçirdi. Makale, yaş ve cinsiyet tespit sistemlerinin doğruluğunu ve uyarlanabilirliğini artırmak için IMDB-WIKI veri seti ve DEX Sistemi gibi çeşitli veri setlerinin kullanımını tartışıyor. Ayrıca, özellikle veri seti önyargısı ve cinsiyet kimliklerinin evrilen doğası nedeniyle yüksek doğruluk elde etmede kalıcı zorlukların olduğunu belirtiyor(Deepanshi et al., 2023).

Tablo 2.1. İlgili Parmak Fotoğrafi Tanıma Literatür Taraması İçin Özet

nd.	Referans	Yöntem	Çalışan Veri Kümesi	Kullanılan Biyometrikler	Performans
1	(Stein et al., 2012b)	Modüler Biyometrik Kimlik Doğrulama Servis Sistemi (MBASSy)	41 denek, Parmak İzi Doğrulama Yarışması (FVC) veritabanı	Sol ve sağ işaret parmakları	EER=%19,1
2	(Tiwari & Gupta, 2015b)	Geleneksel olmayan ölçek değişmez özellikleri	50 birey	Sadece sol el	CRR=%96,67 EER=%3,33
3	(Birajadar et al., 2017b)	Monojenik dalgacık ve faz tutarlılığı özellikleri	50 denek, toplam görüntü sayısı = 200	Belirtilmemiş	EER=4,8
4	(Carney et al., 2017b)	COTS minutiae tabanlı eşleştirici.	1400 temassız parmak izi ve 6600 dokunmatik tabanlı parmak izleri	Dört parmak	Dokunmatik eşleşme oranı %98,6 FAR= %0,0
5	(Deb et al., 2018b)	Parmaklar arasında füzyon, COTS parmak izi eşleştirici	309 denek	Sadece başparmaklar ve iki işaret parmağı	Gerçek Kabul Oranı (TAR) =95,79 FAR=%0,1

6	(Omar et al., 2019)	Derin Parmak Dokusu Öğrenimi (DFTL),	dört veri tabanı kullanmıştır: PolyU2D, IITD, CASIA-BLU ve CASIA-WHT	Aynı elin orta ve işaret parmakları	EER= %0 EER= %1,35 EER= %0 EER= %2
7	(Birajadar et al., 2019)	Kaynak-AFIS, NBIS-NIST, Verifinger SDK	200 denek 800 fotoğraf	Belirtilmemiş	EER= 47,85, EER= 35,9, EER= 10,67
8	(R. R. Al-Nima et al., 2020)	Çift Derin Fingerphoto Learning (DDFL), Sığ CNN modeli	IITD veritabanı Kişi sayısı 64 denek, 8 görüntü	Sağ el için orta ve işaret parmakları	EER=%2,34
9	(Ibrahim et al., 2021)	derin parmak izi sınıflandırma ağı (DFCN) CNN modeline dayalı	ATVS-FFp_DB 512 görüntü	Orta ve işaret parmakları	EER= %0,78
10	(Kauba et al., 2021)	TensorFlow nesne algılama API'si ve transfer öğrenimi, MobileNetV2	Eğitim, doğrulama ve test veri kümeleri sırasıyla 1176 görüntü, 168 görüntü ve 784 görüntüden oluşmaktadır	Başparmaklar hariç tüm parmaklar kullanılır	EER= 5,87 EER= 4,21 EER= 1,65
11	(Priesnitz et al., 2022)	Dört parmağı işleyebilen bir parmak izi tanıma iş akışı için iş akışı ve kullanılabilirlik sorunları	29 denekten 1360 örnek	Dört iç parmak	EER= 10,71
12	(Omar Al-Nima et al., 2023b)	Birkaç Derin Parmak Fotoğrafı CNN Tabanlı Öğrenme (CDFL)	IITD veri seti	Dizin ve orta parmaklar	EER=3,52

13	(Rafique et al., 2019)	Yaş ve cinsiyet tahmini yapmak için CNN modelini eğitmek üzere kullanılan HAAR Özellik Tabanlı Kaskad Sınıflandırıcılar	Büyük veri seti	Yüz görüntüleri	EER=21%
14	(Jhang & Cho, 2019)	CNN tabanlı	Adience veri setini kullanın	Cinsiyet ve yaş tahmini gibi yüz analizi görevleri için 12,000 eğitim görüntüsü ve 3,800 test görüntüsü	EER=8% EER=40%
15	(Deepanshi et al., 2023)	Geleneksel teknikler ve derin öğrenme yöntemleri	IMDB-WIKI veri seti ve DEX Sistemi	Çeşitli veri setleri	Yüksek doğruluk elde etmede zorluklar devam etmektedir

Literatürde yer alan çalışmalar incelendiğinde, çok sayıda birey için 10 parmağın tamamından parmak fotoğrafı görüntülerinden oluşan bir veri kümesinin toplandığı ve bireylerin 10 parmağın tamamından parmak fotoğraflarını kullanarak kişi, cinsiyet ve yaş tahmininin yapıldığı bir çalışma ile karşılaşılmamıştır.

3.MATERYAL VE METOT

3.1 Veri Kümesi Tanımı ve ön işleme

Bu çalışma kapsamında özgün fotoğraflar kullanılarak oluşturulan Fingerphoto Images of Ten Fingers (FITF) isimli veri seti, parmak fotoğraflarının ayırt edici özelliklerinden yalnızca bireysel doğrulama için değil, aynı zamanda yaş ve cinsiyet gibi özelliklerin tespiti için kullanılmıştır. Bu veri tabanı, 100 gönüllüden oluşan heterojen bir grupta bir ay boyunca akıllı telefon kamerasıyla çekilen görüntülerle oluşturulmuştur. Çoğunluğu aile üyelerinden oluşan bu katılımcılar, 16 ila 75 yaş aralığında olup geniş bir etnik çeşitlilik yelpazesini temsil etmektedir. Bu çeşitlilik, biyometrik verilerin veri tabanındaki zenginliğini önemli ölçüde artırmaktadır,

Fingerphoto Images of Ten Fingers (FITF) veri setinde yer alan verilerin kapsamlı bir şekilde anlaşılması için, toplanan görüntülerin derinliğini ve genişliğini kavramak amacıyla ekte ayrıntılı bilgiler verilmiştir. Bu detaylar Tablo A.1'de özetlenmiştir. Bu tablo, her on parmak için toplanan parmak fotoğrafı görüntülerinin sayısının yanı sıra kişisel numara, yaş ve cinsiyet dahil olmak üzere katılımcıların bilgilerini titizlikle özetlemektedir. Bu tablo, veri kümesinin bileşimi ve çeşitliliği hakkında net bir görüş sunabilir.

Projenin merkezinde, başta katılımcıların bilgilendirilmiş onayı ve mahremiyeti olmak üzere etik kurallara bağlılık yer almıştır. Şeffaflığa yapılan bu vurgu, gönüllü katılımın ve etik hususların kritik rolünü vurgulamaktadır. Mahremiyetin sağlanması için katılımcılara ilişkin veriler anonimleştirilmiş ve yalnızca çalışmanın amacına yönelik yaş ve cinsiyet bilgileri kullanılmıştır.

Veri toplama metodolojisi, yüksek kaliteli parmak fotoğraflarının elde edilmesini sağlamak için titizlikle planlanmıştır. Modern akıllı telefonlarda bulunan bir kamera teknolojisi kullanılarak, çeşitli koşullar altında kapsamlı bir parmak fotoğrafı veri seti toplanmıştır. Bu fotoğrafların çoğu, tek tip aydınlatma ve arka plan ayarları sağlamak için iç mekanlarda çekilmiştir. Bununla birlikte, doğal ışıklandırmadaki değişikliklere uyum sağlamak ve görüntülerin kalitesini ve uygunluğunu korumak için bazı fotoğraflar açık havada da çekilmiştir. Işık koşullarının yetersiz olduğu durumlarda, fotoğraf makinesinin flaş özelliği, çekilen görüntülerin tutarlılığını ve kullanılabilirliğini garanti eden düzeltici bir önlem olarak kullanılmıştır.

Oluşturulan veri setinde, her katılımcının on parmağının farklı açılardan 10' ar tane fotoğrafı toplanarak 10000 verilik bir veri seti oluşturulmuştur. Fotoğraflama süreci, kameranın konumunu dikkatlice ayarlayarak çoklu açıları içerecek şekilde tasarlanmıştır,

böylece veri kümesinin biyometrik analizler için uygulanabilirliğini artırmak için çok çeşitli perspektifler yakalanmıştır. Tutarlılığı sağlamak ve segmentasyon sürecini kolaylaştırmak için görüntüler öncelikle kontrollü ortamlarda çekilmiştir. Ancak veri setini çeşitli aydınlatma koşulları ve arka planlarla zenginleştirmek için verilerin bir kısmı açık havada da çekilmiştir. İç mekan çekimlerinde tek tip beyaz arka plan kullanılması özellikle parmakların ayrıntılı özelliklerinin vurgulanmasına yardımcı olurken, dış mekan çekimlerinde kullanılması koleksiyona ek çeşitlilik katmaktadır.

Görüntü alımı sırasında, katılımcılar ellerini akıllı telefon kamerasından yaklaşık 10 cm uzakta tutmaları için yönlendirildi; bu mesafe, yakalanan karede parmağın göreceli boyutunu optimize etmek için seçilmiştir. Parmak konumlandırmasında kısıtlama olmaması ve parmak takılarına izin verilmesi, görüntü yakalama için doğal bir durumu korumayı amaçlamıştır. Katılımcının elinin arkasında sürekli olarak beyaz bir arka plan olması segmentasyonun basitliğini ve tekdüzeliğini sağlamıştır. Kamera, her parmak için 10 farklı açıda gezinerek veri kümesine çeşitli perspektifler kazandırmıştır. Görüntüler sıralı olarak düzenlenmiş ve her katılımcı için bir tamsayı ile etiketlenmiştir.

Gerçekleştirilen çalışmada, parmak fotoğraflarından oluşan kapsamlı bir veri seti derlemek için Samsung Note 9'u kullanılmıştır. Bu cihaz çift kameraya sahiptir: 1/2.55" sensör boyutuna ve 1.4µm piksel boyutuna sahip 12 MP, f/1.5-2.4, 26mm (geniş) lens ve 1/3.4" sensör boyutuna, 1.0µm piksel boyutuna sahip 12 MP, f/2.4, 52mm (telefoto) lens, 2x optik zoom sunar. Ayrıca, 12 MP geniş açılı lensi, çok sayıda açıdan yüksek kaliteli görüntülerin yakalanmasını kolaylaştıran çift piksel teknolojisine sahiptir. Sadece tek bir cihaz kullanılmasına rağmen, Note 9'un kullanıldığı çeşitli ortamlar ve ortamlar, görüntü kalitesi ve perspektif yelpazesini garanti etmiştir. Tüm görüntüler JPEG ve JPG formatlarında depolanmış, çözünürlükleri çevredeki ortam da dahil olmak üzere çeşitli faktörlere göre ayarlanmış ve 1932 × 2576, 2592 × 4608 ile 3024 × 4032 piksel arasında değişmiştir. Kameranın otomatik modunun bir sonucu olan bu değişkenlik, veri setine çok çeşitli görüntü ayrıntıları ve nitelikleri sağlamıştır. Bu yöntemin benimsenmesi, veri kümesinde hem tutarlılık hem de çeşitlilik sağlayarak akıllı telefon kamerasının fotoğrafik yeteneklerinden tam olarak yararlanılmasını sağlamıştır. Şekil 3.1'de oluşturulan FITF isimli veri seti içerisinde yer alan parmak resim örnekleri gösterilmektedir.




(a)



(b)



(c)



(d)

Şekil 3.1. FITF veri seti için elde edilen ham parmak fotoğrafı örnekleri

FITF veri kümesini topladıktan sonra, ilk adım bir parmak görüntüsünün İlgi Bölgesini (ROI) elde etmek olacaktır. Burada ROI, yakalanan ham görüntüden parmak fotoğrafı görüntüsünü izole etme amacını ifade eder. Çekim sırasında dikkate alınan farklı açılar nedeniyle, tüm parmak fotoğrafı görüntülerinde tutarlı bir yönelim sağlamak son derece önemlidir. Bu, tek tip bir görsel perspektif sağlamak için dikkatli bir hizalama ve

ayarlar gerektirir. Tüm parmak fotoğrafları için doğru dikey hizalamanın gerçekleştirilmesi, veri kümesi için ek iyileştirmeler sağlar. Bunu başarmak için görüntü işlemede eşikleme ve kenar algılama gibi çeşitli teknikler kullanılır. Ayrıca, momentlere dayalı hizalama tekniklerinin kullanımı segmentasyon sürecinin iyileştirilmesinde kritik bir rol oynamaktadır. Bu teknikler, bir görüntüdeki piksel yoğunluklarının uzamsal dağılımını nicel olarak temsil etmek için momentler olarak bilinen matematiksel tanımlayıcıları kullanır.

Görüntü işlemede uygulama alanı bulan momentlerin özel bir gösterimi, aşağıdaki gibi temsil edilen geometrik momenttir I_{XY} olarak tanımlanır (Mukundan & Ramakrishnan, 2011):

$$I_{XY} = \sum_z \sum_n Z^X N^Y M(z, n) \quad (3.1)$$

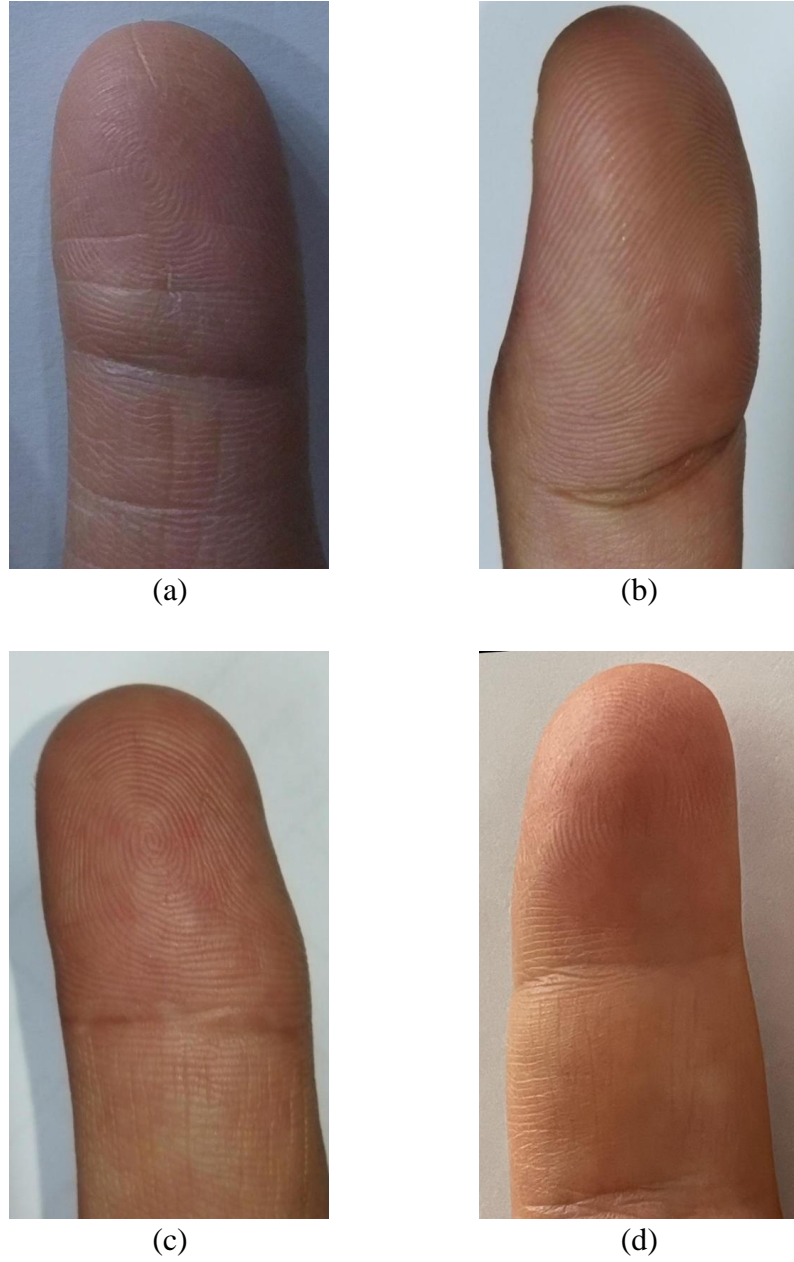
Yukarıdaki denklemde X ve Y negatif olmayan tamsayılar, Z ve N piksel koordinatları ve $M(z, n)$ koordinatlarındaki piksel yoğunluğunu temsil eder (z, n) .

Moment tabanlı hizalama teknikleri kullanılarak, ROI'nin momentleri bir referans model ile hizalanarak segmentasyon süreci iyileştirilir. Bu ayarlama, çevredeki alanlardan gelen gürültü ve parazit etkisini en aza indirmeye yardımcı olur. Hizalama işleminde momentlerin kullanılması, tıbbi görüntüleme veya nesne tanıma uygulamaları gibi hassas kayıt işleminin son derece önemli olduğu senaryolarda özellikle avantajlıdır (Meyer & Rosmus, 1975; Mukundan & Ramakrishnan, 2011).

Buna ek olarak, artırma adı verilen ek bir ön işleme tekniği kullanılmaktadır. Büyütme kullanımı, derin öğrenme modellerinin esnekliğini ve genelleme yeteneğini artırır. Yeniden boyutlandırma, döndürme ve projeksiyon gibi dönüşümler uygulayarak veri kümesindeki görüntülerin derin öğrenme ağlarının gereksinimlerine uygun olmasını sağlar. Arıtma, modelin eğitim verilerinde aşırı uzmanlaşması ve görülmeyen örneklerde zorluk yaşaması riskini azaltmada da önemli bir rol oynar (DeVries & Taylor, 2017; Shorten & Khoshgoftaar, 2019).

Artırma, rastgele ön işleme işlemleri uygulayarak her dönem için eğitim verilerine değişkenlik katar. Sonuç olarak, her eğitim döngüsünde model verilerin biraz farklı versiyonlarıyla karşılaşır. Eğitim setindeki bu değişkenlik, modelin daha sağlam ve uyarlanabilir özellikler edinmesine yardımcı olur. Boosting'in bellek kullanımının verimliliğine de katkıda bulunması dikkat çekicidir. Dönüştürülen görüntüler bellekte depolanmaz, bu da büyük bir veri kümesiyle uğraşırken belirgin bir avantajdır. Bu süreç,

bir derin öğrenme modelinin genel etkinliğini ve güvenilirliğini önemli ölçüde artırabilir(Shorten & Khoshgoftaar, 2019).



Şekil 3.2. Ön İşlemden Sonra Parmak Fotoğrafı ROI Örnekleri

Şekil 3.2, On Parmağın Parmak Fotoğrafı Görüntüleri (FITF) veri setinden seçilen İlgi Alanları (ROI) örneklerini göstermekte ve kapsamlı bir ön işleme aşamasından geçtikten sonra parmakların görünümünü ortaya koymaktadır. Bu şekil, görüntülerin yalnızca parmak bölgelerini izole etmek ve vurgulamak için işlendiği ön işlemenin son aşamasını vurgulamaktadır. Bu işlem, verilerin Derin Tekrarlayan Parmak Fotoğraf Ağı

(DRFN) tarafından optimum analiz ve tanıma için mükemmel bir şekilde hazırlanmasını sağlayarak veri kümesinin kalitesinin ve kullanılan ön işleme tekniklerinin etkinliğinin net bir görselleştirmesini sunmaktadır.

3.2 Makine Öğrenmesine Giriş

Makine Öğrenmesi, Yapay Zekanın bir alt kümesidir ve verilerden öğrenen teknikler sağlamaya odaklanmıştır. Bir görevi yerine getirmek için açık talimatlara dayanan geleneksel hesaplama yöntemlerinin aksine, makine öğrenmesi bilgisayarların açıkça programlanmadan deneyimlerden öğrenmesini ve gelişmesini sağlar. Bu yöntem, makine öğrenmesi modellerinin yeni verilere bağımsız olarak uyum sağlamasına, öğrenmelerine dayalı tahminler veya kararlar almasına olanak tanır. (Badillo et al., 2020).

Makine öğrenmesi, bilgisayar bilimi, istatistik, veri bilimi ve ötesi dahil olmak üzere çeşitli alanlarla kesişen geniş ve çok disiplinli bir alanı kapsar. Bu geniş alan, bilgisayar bilimlerinden hesaplama modellerini, istatistikten analitik yöntemleri ve veri biliminden veri işleme tekniklerini kullanır ve veri analizi ve tahmini için güçlü araçlar oluşturmak üzere bu farklı perspektifleri entegre eder. Makine öğrenmesinin uygulamaları çok çeşitli ve geniş kapsamlı olup, yenilikçi yetenekleriyle çok sayıda sektörü etkilemektedir. Sağlık hizmetlerinde makine öğrenmesi, hastalıkları daha doğru bir şekilde tanımlayarak teşhis ve hasta bakımının geliştirilmesinde önemli bir rol oynamaktadır. Finans sektöründe, sofistike puanlama modelleriyle kredi değerlendirmesinde ve algoritmik ticaret stratejilerinin borsaya uygulanmasında kullanılmaktadır. Bu arada, teknoloji endüstrisinde, makine öğrenmesi, kişiselleştirilmiş içeriği düzenleyen gelişmiş öneri motorlarının geliştirilmesinin ve kullanıcı etkileşimlerini kolaylaştıran akıllı sanal asistanların oluşturulmasının arkasındaki itici güçtür. Bu geniş uygulama alanı, makine öğrenmesinin yalnızca çok yönlülüğünü değil, aynı zamanda çeşitli alanlarda önemli ilerlemeler ve verimlilikler sağlama potansiyelini de göstermektedir (Baştanlar & Özuysal, 2014; Pentakalos, 2019).

Makine öğrenmesi, ilgili öğrenme türüne veya öğrenme süreci sırasında mevcut olan geri bildirimle ilgili olarak genellikle üç farklı türe ayrılabilir. (Pentakalos, 2019; van Engelen & Hoos, 2020):

3.2.1. Denetimli öğrenme

Bu yöntemde model, etiketli bir veri setinden öğrenir ve bu öğrenmeye dayalı olarak öngörülemeyen veriler için sonuçları tahmin etmeye çalışır. Denetimli öğrenme,

algoritmaları eğitmek için etiketli veri kümelerinin kullanılmasıyla karakterize edilen makine öğrenmesindeki birincil paradigmalardan biri olarak durmaktadır. Bu öğrenme yaklaşımı “denetimli” olarak adlandırılır çünkü bir algoritmanın eğitim veri setinden öğrenme “üreci, öğ”enme sürecini denetleyen bir öğretmen olarak düşünülebilir. Öğretmen tüm doğru cevapları bilir ve algoritma eğitim verileri üzerinde yinelemeli olarak tahminler yapar ve bunlar öğretmen tarafından düzeltilir. Zaman içinde algoritma öğrenir ve mümkün olduğunca az hata yapma hedefiyle doğruluğunu optimize eder (Kotsiantis, 2007).

Sınıflandırma problemleri, girdi verilerinin önceden tanımlanmış sınıflara veya kategorilere ayrılmasını içerir. Bir sınıflandırma modelinin sonucu ayrık bir etikettir, bu da bu tür problemleri sonlu sayıda olası sonuca sahip kararlar için çok uygun hale getirir. Sınıflandırma ayrıca sınıf sayısına göre de bölünebilir (Kotsiantis, 2007):

- İkili Sınıflandırma: Bu, modelin iki olası sınıftan birini tahmin ettiği en temel sınıflandırma türüdür. Örneğin spam tespitinde model, bir e-postanın “spam” mi yoksa “spam değil” mi olduğunu tahmin eder. Benzer şekilde, tıbbi teşhiste, model bir hastanın bir hastalığa sahip olup olmadığını belirler (W. Wang et al., 2023).
- Çok Sınıflı Sınıflandırma: Bu, verileri ikiden fazla sınıfa ayırmayı içerir. Yaygın bir örnek, modelin her görüntüyü on rakamdan (0’dan 9’a kadar) biri olarak sınıflandırması gereken el yazısı rakamların tanınmasıdır (Grandini et al., 2020).
- Çok Etiketli Sınıflandırma: Bu sınıflandırma türünde, tek bir örneğe birden fazla etiket atanabilir. Örneğin, bir haber makalesi aynı anda politika, ekonomi ve sosyal konular gibi birden fazla türe kategorize edilebilir (Sadat & Caragea, 2022).

Sınıflandırma için kullanılan yaygın algoritmalar arasında lojistik regresyon (Bertsimas & King, 2017), karar ağaçları (Quinlan, 1986), destek vektör makineleri (Burges, 1998) ve sinir ağları (Cuomo et al., 2022) da örnek gösterilebilir.

Regresyon problemleri, sürekli bir miktarı veya kayan noktalı bir sayıyı tahmin etmeyi amaçlar. Çıktının ayrık bir sınıf olduğu sınıflandırmanın aksine, regresyon modelleri sürekli bir değer spektrumuyla ilgilenir. Bu da regresyonu, geçmiş verilere dayalı eğilimlerin tahmin edilmesi, kestirilmesi ve öngörülmesi için uygun hale getirir (Stewart et al., 2023). Regresyon problemlerine örnek olarak şunlar verilebilir:

- 1) Ev Fiyatlarını Tahmin Etme: Evlerin alan, konum, yatak odası sayısı gibi özellikleri göz önüne alındığında, model satış fiyatlarını tahmin eder (P. Y. Wang et al., 2021).
- 2) Borsa Trendleri: Geçmiş performans verilerine ve diğer ekonomik göstergelere dayanarak bir hisse senedinin gelecekteki değerinin tahmin edilmesi(Corizzo & Rosen, 2024).
- 3) Sıcaklık Tahminleri: Geçmiş hava durumu verilerine ve modellerine dayanarak gelecekteki sıcaklık değerlerinin tahmin edilmesi(Stewart et al., 2023).

Doğrusal regresyon regresyonun en temel şeklidir, ancak polinom regresyon, ridge regresyon, lasso regresyon ve sinir ağları gibi diğer sofistike yöntemler de sorunun karmaşıklığına ve verilerin doğasına bağlı olarak yaygın olarak kullanılmaktadır (Stewart et al., 2023).

3.2.2. Denetimsiz öğrenme

Model neyi arayacağına dair herhangi bir özel talimat olmaksızın etiketsiz verilerden örüntüleri öğrenir. Denetimsiz öğrenme, etiketlenmemiş veya etiketlenmemiş verilerle çalışarak denetimli öğrenme paradigmasından ayrılır. Bu öğrenme, öğrenme sürecini yönlendirmek için önceden tanımlanmış herhangi bir sonuca dayanmaz. Bunun yerine, öğrenme hedefini dikte etmek için herhangi bir dış denetim veya etiket olmadan veri içindeki kalıpları, ilişkileri veya yapıları tanımlamaya çalışır(Sen & Das, 2023; X. Wu et al., 2022).

Denetimsiz öğrenmenin özünde, modelin veri yapısını kendi başına ayırt etme yeteneği yatar. Algoritmaları, girdileri işlemek ve veri kümesi içindeki doğal gruplamaları, kalıpları veya ilişkileri keşfetmek için tasarlanmıştır. Bu yetenek özellikle unsurlar arasındaki ilişkilerin hemen görülemediği veya hacim ya da karmaşıklık nedeniyle verilerin etiketlenmesinin pratik olmadığı keşifsel veri analizi, anormallik tespiti ve karmaşık sistemlerde değerlidir (Sen & Das, 2023).

3.2.3. Takviyeli öğrenme

Bir ajanın bir çevre ile etkileşime girerek karar vermeyi öğrendiği bir tür makine öğrenmesi paradigmasıdır. Modelin etiketli verilerle eğitildiği denetimli öğrenmeden veya modelin verilerden örüntüleri ortaya çıkardığı denetimsiz öğrenmeden farklıdır. Açık talimatlar olmadan, takviyeli öğrenme, bir ajanın belirli bir ortamda kümülatif

ödülünü en üst düzeye çıkarmak için benimsemesi gereken stratejiyi veya politikayı öğrenmeye odaklanır (Kiran et al., 2022).

3.3 Makine Öğrenmesinin Bileşenleri

Makine öğrenmesi sistemlerinin etkinliği temelde bileşenleri tarafından belirlenir. Bu bileşenler arasında veri ve algoritmalar, öğrenme sürecini yönlendiren ve sistemlerinin içgörü elde etmesini ve tahminlerde bulunmasını sağlayan temel unsurlar olarak öne çıkmaktadır(Geyer & Singaravel, 2018).

Veri, makine öğrenmesinde temel unsur olarak hizmet eder ve algoritmalar için temel yakıt görevi görür. Örüntüleri tanımlamak ve tahminlerde bulunmak için gerekli ham girdiyi sunar. Verilerin kalitesi, miktarı ve uygunluğu, makine öğrenmesi modellerinin performansını ve doğruluğunu doğrudan etkiler. Makine öğrenmesinde veriler genel olarak iki türe ayrılabilir: yapılandırılmış ve yapılandırılmamış(Chiu et al., 2023; González-Castro et al., 2023; Hopkins et al., 2022).

Yapılandırılmış Veri, ilişkisel veritabanlarında kolayca aranabilir hale getirecek şekilde yüksek düzeyde organize edilmiş ve biçimlendirilmiştir. Yapılandırılmış veriler tipik olarak tablo şeklindedir, her sütunun belirli bir özelliği temsil ettiği ve her satırın bir kayda karşılık geldiği satırlar ve sütunlar içerir. Örnekler arasında müşteri bilgilerini içeren elektronik tablolar, işlem kayıtları ve sensör verileri yer alır. Düzenli yapısı nedeniyle, yapılandırılmış veriler makine öğrenmesi algoritmalarının işlemesi ve analiz etmesi için daha kolaydır(González-Castro et al., 2023; Richter & Khoshgoftaar, 2018).

Yapılandırılmamış veriler ise önceden tanımlanmış bir şekilde organize edilmez ve çeşitli formatlarda gelir. Metin, resim, video ve ses içerir. Dijital evrende bulunan verilerin büyük çoğunluğu yapılandırılmamıştır. Yapılandırılmamış verilerin işlenmesi, karmaşıklığı ve net bir yapısının olmaması nedeniyle makine öğrenmesi algoritmaları için daha büyük bir zorluk teşkil etmektedir. Bununla birlikte, derin öğrenme ve doğal dil işleme (NLP) alanındaki gelişmeler, makine öğrenmesi modellerinin yapılandırılmamış verilerden anlamlı kalıpları analiz etme ve türetme becerisini önemli ölçüde geliştirmiştir(González-Castro et al., 2023; Hopkins et al., 2022).

Verilerden eyleme dönüştürülebilir içgörüler elde edilmesine yönelik süreç, modelin performansını iyileştirmek için zorunlu olan temizleme, normalleştirme ve özellik çıkarma gibi ön işleme adımlarını kapsar. Bu süreç, makine öğrenmesi modelinin etkinliğini artırma amacı taşır ve kapsamlı bir ön işleme metodolojisini gerektirir(Hopkins et al., 2022).

3.4 Derin Öğrenme

Makine öğrenmesi ve yapay zekanın bir alt kümesi olan Derin Öğrenme (DL), günümüzün Dördüncü Sanayi Devrimi'nin temel teknolojisi olarak kabul edilmektedir (Sarker, 2021). Derin öğrenme teknolojisi, son on yılda veri bilimi üzerinde önemli bir etki yaratmıştır (Shukla et al., 2023). Yapay sinir ağları (YSA) kökenli olan derin öğrenme, verilerden öğrenme yeteneği nedeniyle sıcak bir konu haline gelmiştir (Sarker, 2021). Derin öğrenme modelleri, sinir ağı araştırmalarında yeniden canlanmaya yol açtıkları için genellikle "yeni nesil sinir ağları" olarak adlandırılır. Bu modeller sağlık hizmetleri, görsel tanıma, metin analizi, siber güvenlik ve daha birçok uygulama alanında yaygın olarak kullanılmaktadır. (Sarker, 2021).

Derin sinir ağları tasarlamak için kullanılan temel yapılar arasında ileri beslemeli sinir ağları, evrişimli sinir ağları ve tekrarlayan sinir ağları yer alır (Sarker, 2021; Shukla et al., 2023). Bu ağlar, denetimli veya ayırt edici öğrenme, denetimsiz veya üretken öğrenme ve hibrit öğrenme gibi farklı öğrenme görevleri için kullanılabilir. Ancak, gerçek dünya problemlerinin ve verilerinin dinamik yapısı ve çeşitliliği nedeniyle uygun bir derin öğrenme modeli oluşturmak zor olabilir. Dahası, temel anlayış eksikliği, derin öğrenme yöntemlerini standart düzeyde geliştirmeyi engelleyen kara kutu makinelere dönüştürmektedir (Sarker, 2021). Bu zorluklara rağmen derin öğrenme, çok sayıda uygulama ve devam eden araştırmalarla gelecek vaat eden bir alan olmaya devam etmektedir. Gelecekte de gelişmeye ve çeşitli sektörlerde katkıda bulunmaya devam etmesi beklenmektedir (Sarker, 2021; Shukla et al., 2023).

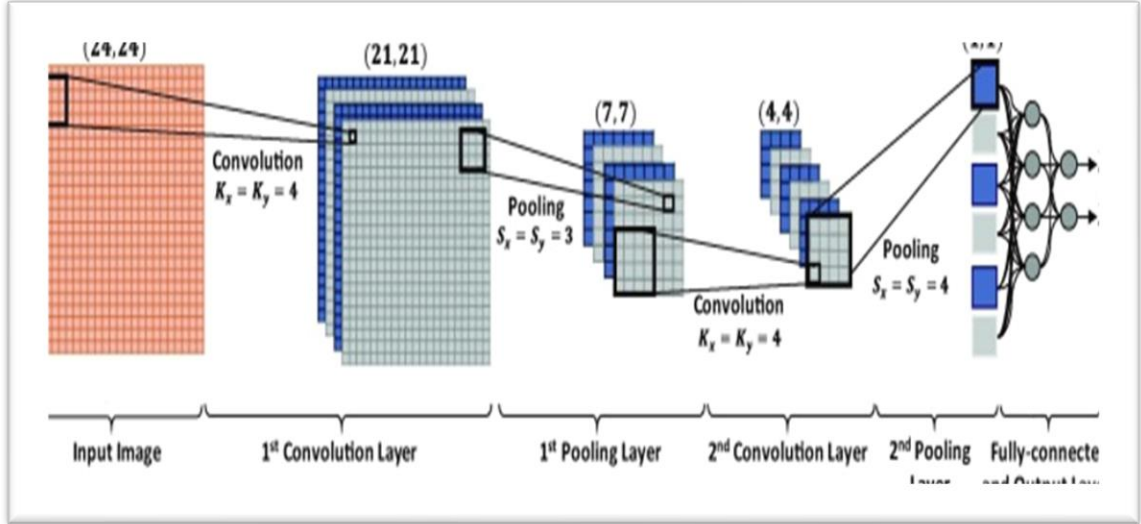
Bu tez kapsamında, çeşitli derin öğrenme teknikleri ele alınmıştır:

3.4.1. Evrişimli sinir ağları (CNN'ler):

Evrişimli sinir ağları, görüntü tanıma ve işleme alanlarında modern derin öğrenmenin temel taşı temsil eder. Bu tür derin sinir ağları, piksel verilerini işlemek ve evrişimsel filtreler uygulayarak görüntülerdeki uzamsal hiyerarşileri etkili bir şekilde yakalamak için özel olarak tasarlanmıştır. CNN'lerin mimarisi, hayvan görsel korteksinin organizasyonundan esinlenmiştir ve özellikle görsel imgelerdeki karmaşık desenleri otomatik olarak öğrenme ve tanımlama konusunda uzmandır. Yıllar içinde, her biri derin öğrenme ortamını aşamalı olarak şekillendiren önemli yenilikler ve ilerlemeler getiren birkaç önemli CNN mimarisi ortaya çıkmıştır (Fukushima, 2019, 2021).

Bir CNN'in temel mimarisi tipik olarak bir dizi konvolüsyonel katman ve havuzlama katmanından oluşur ve genellikle sonunda bir veya daha fazla tam bağlantılı

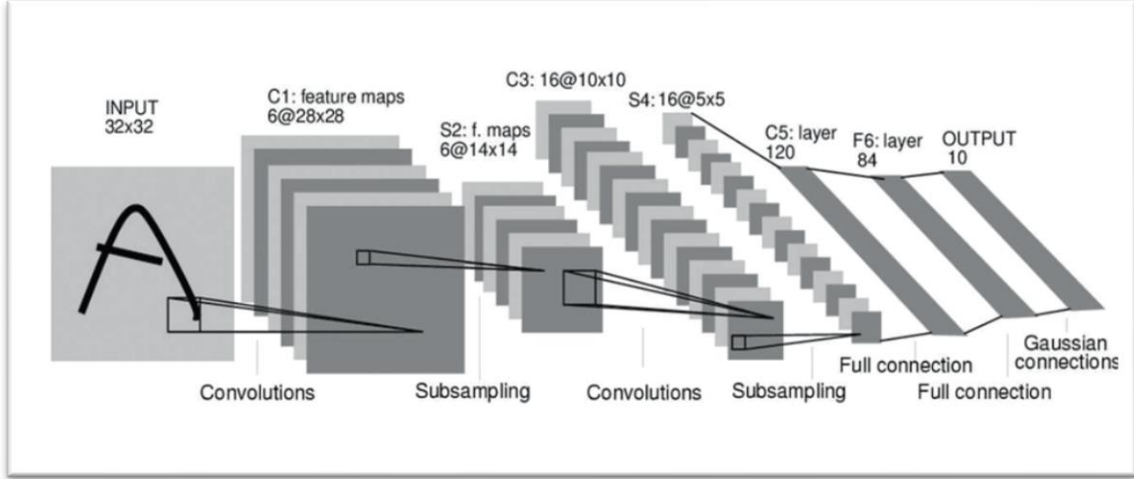
katman izler. Bu yapı, görüntüleri verimli bir şekilde işlemek ve analiz etmek için tasarlanmıştır ve ağın özellikleri, desenleri ve nesnelere yüksek doğrulukla tespit etmesini sağlar. Şekil 3.3'de bir CNN yapılandırma örneğinin temel blokları gösterilmektedir (Alzubaidi et al., 2021; Fukushima, 2021).



Şekil 3.3. Bir CNN yapılandırma örneğinin gösterimi (Kiranyaz et al., 2021)

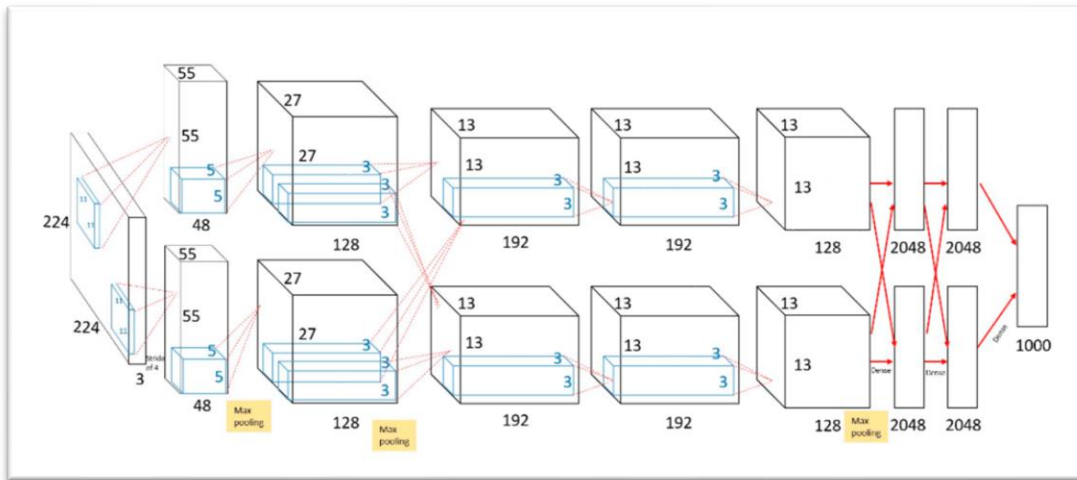
AlexNet, LeNet, GoogLeNet, VGG16 ve her biri derin öğrenme ve bilgisayarla görme alanında birçok örnek vardır. Bu ağlar, çeşitli görüntü tanıma ve sınıflandırma görevlerindeki olağanüstü performansları nedeniyle önemli bir etkiye sahip olmuştur. Bu ağların gelişimi sadece makine öğrenmesinde mümkün olanın sınırlarını zorlamakla kalmamış, aynı zamanda görüntü sınıflandırmadan nesne algılamaya kadar çok çeşitli görevlerde verimlilik için yeni standartlar oluşturmuştur (Çınar & Tuncer, 2021; Li & Lima, 2021). Aşağıda her bir bileşene ilişkin kısa bir genel bakış sunulmaktadır:

LeNet, 1990'ların sonunda geliştirilmiştir, görüntü tanıma görevleri için potansiyellerini gösteren ilk CNN'lerden biridir. Mimarisi, konvolüsyon katmanlarının ve ardından havuzlama katmanlarının kullanılmasına yönelik temel tasarımı ortaya koymuştur (Saradhi et al., 2023; Vimalarani & Ramachandraiah, 2022). Şekil 3.4 LeNet'in temel mimarisini göstermektedir (LeCun et al., 1998).



Şekil 3.4. LeNet'in Temel Mimarisi (LeCun et al., 1998)


AlexNet 2012'de ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasını (ILSVR) büyük bir farkla kazandığında derin öğrenmede önemli bir kilometre taşına işaret etti. Rectified Linear Unit (ReLU) aktivasyon fonksiyonu, düzenlilik için dropout ve eğitim için Grafik İşleme Birimi (GPU) hesaplama kullanımını içeriyordu. AlexNet'in başarısı CNN'leri derin öğrenmenin ön saflarına taşıdı ve bu alandaki ilgi ve araştırmaların artmasına yol açtı (Khan et al., 2020)Şekil 3.5 AlexNet mimarisini göstermektedir ((Krizhevsky et al., n.d.).



Şekil 3.5. AlexNet'in Temel Mimarisi (Krizhevsky et al., n.d.)


GoogLeNet (Başlangıç Ağı) 2014 yılında tanıtıldı ve hesaplama maliyetlerini kontrol ederken ağ derinliğini ve genişliğini optimize etmede ileriye doğru bir sıçramayı temsil etti. Başlangıç modülü, bilginin çeşitli ölçeklerde verimli bir şekilde işlenmesine

olanak sağlamış ve 22 katmanlı derinliği, hesaplamada orantılı bir artış olmadan modelin kapasitesini önemli ölçüde artırmıştır (Michalski & Plechawska-Wójcik, 2022; Muhammad et al., 2018). Şekil 3.6 GoogLeNet'in temel yapısını göstermektedir (Szegedy et al., 2015).




Şekil 3.6. GoogLeNet'in Temel Mimarisi (Szegedy et al., 2015)

VGG16 mimarisi basitliği ve derinliği ile ünlüdür. Artan derinlikte üst üste yığılmış 3x3 konvolüsyonel katmanları eşit olarak kullanır. Basit mimarisine rağmen, görüntü tanıma görevlerinde oldukça etkili olmuş ve sinir ağlarında derinliğin gücünü göstermiştir. Ayrıca ağ içindeki farklı katmanlarda özellik temsilinin anlaşılmasına da katkıda bulunmuştur (Ewe et al., 2022; Jiang et al., 2021)Şekil 3.7'da bir VGG16 mimarisi gösterilmektedir (Ewe et al., 2022).



Şekil 3.7. VGG16'nın Temel Mimarisi (Ewe et al., 2022)

ResNet veya Residual Network, bazı katmanların üzerinden atlamak için atlama bağlantıları veya kısayollardan oluşan devrim niteliğinde bir tasarım ilkesi getirmiştir. Bu bağlantılar kaybolan gradyan sorununu çözerek ağır önceki mimarilere göre önemli ölçüde daha derin olmasını (ResNet-50'nin 50 katmanı vardır) sağlar. ResNet'in tasarımı, birçok katmanda gradyan akışı sağlayarak daha derin eğitimi kolaylaştırır ve çeşitli görevler için doğrulukta yeni rekorlar kırar (Bezdan & Bačanin Džakula, 2019; Li & Lima, 2021). Şekil 3.8 ResNet-50'nin mimarisini göstermektedir (Bezdan & Bačanin Džakula, 2019).



Şekil 3.8. ResNet-50'nin Temel Mimarisi (Bezdan & Bačanin Džakula, 2019)

Bu mimariler, CNN'lerin gelişimini ve karmaşıklığını toplu olarak vurgulamakta ve her biri derin öğrenmenin ilerlemesine farklı bir katkıda bulunmaktadır. CNN'lerin görsel bilgilerdeki kalıpları ve özellikleri tanımlama konusundaki yeteneklerini göstererek, bu alanda gelecekte yapılacak atılımların önünü açmaktadırlar.

Bu kritik mimarilerin farklılıkları ve etkileri hakkında daha net bir fikir edinmek için Tablo 3.1 ayrıntılı bir karşılaştırma sunmaktadır. Temel özellikleri, tasarım yaklaşımları ve derin öğrenme alanına getirdikleri yenilikler vurgulanmaktadır. (Alzubaidi et al., 2021; Katiyar & Borgohain, 2020; Shin et al., 2016)

Tablo 3.1. CNN Mimarilerine Karşılaştırmalı Genel Bakış: AlexNet, LeNet, GoogLeNet, VGG16 ve ResNet-50

Özellik	CNN (Genel)	AlexNet	LeNet	GoogLeNet	VGG16	ResNet-50
Giriş Yılı	1979	2012	1998	2014	2014	2015
Ana Fikir	Özellik çıkarma için konvolüsyonel katmanlar, boyut azaltma için havuzlama.	Derin mimari, ReLU, bırakma.	Erken CNN, basit mimari.	Başlangıç modülleri, derinlik ve genişlik.	Çok derin, basit ve homojen bir mimari.	Kalan bağlantılarla derin.
Katmanlar	Değişken	8	7	22	16	50
Parametreler	Tasarıma göre değişir	~60 milyon	~60k	~6 milyon	~138 milyon	~25 milyon
Verimlilik ve Hız	Değişir	Orta düzeyde	Yüksek	Dikkatli hesaplama yönetimi ile yüksek	Düşük, hesaplama açısından yoğun	Artık bloklar nedeniyle yüksek, verimli
Sağlamlık ve Genelleme	Mimariye göre değişir	İyi, ancak yeni modellere göre daha iyi performans gösterdi	Orta düzeyde, çoğunlukla basit görevlerde	Çok iyi, farklı görevlere uyarlanabilir	İyi, ancak küçük veri kümelerinde aşırı uyuma eğilimli	Mükemmel, görevler arasında iyi genelleme yapar
Kullanım Örnekleri ve Uygulamalar	Görüntü sınıflandırmadan tıbbi görüntü analizine kadar geniş bir yelpaze	Görüntü sınıflandırma, nesne algılama	El yazısı tanıma	Görüntü sınıflandırma, algılama ve segmentasyon	Görüntü sınıflandırma, ince taneli tanıma	Görüntü sınıflandırma, nesne algılama, segmentasyon

Sınırlamalar ve Zorluklar	Belirli bir mimariye bağlıdır	Önemli miktarda hesaplama kaynağı gerektirir, aşırı uyum	Sınırlı karmaşıklık ve derinlik	Karmaşık model tasarımı, dikkatli ayarlama gerektirir	Çok derin, çok fazla hesaplama gerektirir, eğitilmesi zordur	Artık bağlantılar karmaşıklığı artırır, potansiyel aşırı uyum
Önceden Eğitilmiş Modeller Mevcut	Evet, birçok mimari için	Evet	Evet	Evet	Evet	Evet
Sınıflandırıcı Tipi	Softmax (yaygın olarak kullanılır)	Softmax	Softmax	Softmax	Softmax	Softmax

3.4.2. Tekrarlayan sinir ağıları (RNN'ler):

Tekrarlayan Sinir Ağları (RNN'ler), sıralı verilerin işlenmesi için derin öğrenmede temel bir metodolojidir. Diğer sinir ağlarının aksine, RNN'ler döngüsel mimarileri sayesinde bir tür hafıza tutma gibi benzersiz bir yeteneğe sahiptir. Bu tasarım, önceki hesaplamaları girdi olarak kullanmalarını ve diziler boyunca bilgileri korumalarını sağlar. Bu özellik, RNN'leri zaman serisi analizi ve doğal dil işleme gibi sıra ve bağlamın anlaşılmasını gerektiren görevlerin yanı sıra zamansal dinamikleri içeren daha karmaşık senaryolar için özellikle uygun hale getirir (S. Das et al., 2023; X. Zhang et al., 2023).

3.4.3. Derin tekrarlayan öğrenme (DRL):

Derin Tekrarlayan Öğrenme (DRL), RNN'lerin sıralı veri işleme gücünü karmaşık örüntüleri modellemek için derin öğrenme kapasitesiyle birleştirir. DRL'nin derin öğrenmenin ayrı bir kategorisi olmadığını belirtmek önemlidir; RNN'lerin sıralı işleme yeteneklerini birden fazla katman ekleyerek elde edilen öğrenme derinliği ile birleştiren sofistike bir yaklaşımdır. Bu yöntem, Derin Tekrarlayan Sinir Ağlarının (DRNN'ler) karmaşık zamansal örüntüleri daha etkili bir şekilde modellemesini sağlar. DRNN'ler DRL'den yararlanarak dizileri yüksek hassasiyetle anlayabilir ve tahmin edebilir, öğrenmelerini dizideki her bir ögenin önemine ve bağlamına göre uyarlayabilir. Bu uyarlanabilir mekanizma, sistemin dizileri analiz etme yeteneğini önemli ölçüde geliştirerek DRL ile donatılmış DRNN'leri ayrıntılı dizi analizi ve uzun vadeli bağımlılıkların anlaşılmasını gerektiren çok çeşitli uygulamalar için güçlü bir araç haline getirir (S. Das et al., 2023; Y. Zhang & Wang, 2022).

3.5 Geleneksel Makine Öğrenmesi Teknikleri

Bir dizi geleneksel makine öğrenmesi tekniği (klasik sınıflandırıcılar) vardır. Bunlara örnek olarak şunlar verilebilir:

3.5.1 Destek vektör makinesi (SVM)

Destek Vektör Makinesi (SVM), öncelikle sınıflandırma ve regresyon görevleri için kullanılan geleneksel makine öğrenmesi teknikleri arasında bir köşe taşı olarak durmaktadır. Daha yeni derin öğrenme yaklaşımlarından farklı olarak SVM, yüksek boyutlu uzaylarda etkili bir şekilde çalışmak için geometri ve istatistik ilkelerine dayanır. Bu, onu inanılmaz derecede çok yönlü hale getirir ve görüntü tanımadan metin

sınıflandırmaya kadar çeşitli uygulamaların üstesinden gelebilir (Abdullah & Abdulazeez, 2021).

DVM'nin özü, farklı sınıflardaki veri noktaları arasında en iyi ayrımı yapan optimum ayırıcı hiper düzlemi belirleme stratejisinde yatmaktadır. Bir levhayı, sadece iki nokta kümesini ayırmakla kalmayıp aynı zamanda her iki taraftaki en yakın noktalara olan maksimum mesafeyi koruyacak şekilde konumlandırmaya çalıştığınızı düşünün. Hiper düzlemin konumunu belirlemek için kritik olan bu en yakın noktalar, destek vektörleri olarak bilinir (Huang et al., 2017).

DVM, hiper düzlem ile her sınıftan en yakın noktalar arasındaki mesafe olan marjı maksimize etmeye odaklanır. Mantık basittir: daha büyük bir marj, sınıflandırıcının genelleme hatasını azaltarak güvenilirliğini artırır. Doğrusal olarak ayrılamayan verilerle uğraşırken DVM, orijinal özellikleri doğrusal bir ayırımın uygulanabilir hale geldiği daha yüksek boyutlu bir uzaya eşleyen bir yöntem olan çekirdek hilesini kullanır. Bu uyarlama, doğrusal, polinom ve Radyal Taban Fonksiyonu (RBF) gibi farklı çekirdeklerin kullanımıyla birlikte DVM'nin esnekliğine katkıda bulunur (Çınar & Tuncer, 2021).

Ayrıca SVM, veri çakışmasını ve aykırı değerleri yönetmek için yumuşak marj sınıflandırması kavramını getirerek belirli bir maliyetle bazı yanlış sınıflandırmalara izin verir. Bu pragmatik yaklaşım, modelin sağlamlığını ve geliştirilebilirliğini artırır. Özünde, DVM'de optimum hiper düzlemin belirlenmesi, marj maksimizasyonu ve hata minimizasyonunu dengelemeyi amaçlayan karmaşık bir optimizasyon probleminin çözülmesine dayanır. DVM'nin faydası, görüntü ve metin sınıflandırması, kanser sınıflandırması ve gen ifadesi için biyoinformatik ve hatta spam tespiti dahil üzere çeşitli alanlara yayılmıştır. Hem doğrusal hem de doğrusal olmayan problemleri verimli bir şekilde ele alma yeteneği ve derin öğrenme modellerine kıyasla yorumlanabilirliği, SVM'nin makine öğrenmesi ortamındaki hayati bir algoritma olarak konumunu, özellikle veri hacimlerinin yönetilebilir olduğu ve model kararlarının netliğinin çok önemli olduğu görevler için güvence altına alır (Chandra & Bedi, 2021; Chauhan et al., 2019).

3.5.2. Rastgele orman

Rastgele Orman, geleneksel makine öğrenmesi tekniklerinin toplu öğrenme alanında çok yönlülüğün bir işareti olarak durmaktadır, özellikle sınıflandırma ve regresyon alanında başarılı sonuçlar vermektedir (Onesmus, 2020a). Bu algoritma gücünü, eğitim aşamasında çok sayıda karar ağacı oluşturarak, daha doğru ve istikrarlı tahminler yapmak için bu ağaçların kolektif gücünden yararlanmasından alır. Hatalara

veya aşırı uyuma eğilimli olabilecek tekil bir karar ağacına güvenmenin aksine, Rastgele Orman çok sayıda ağacın sonuçlarını bir araya getirir ve böylece sonuçların modu (sınıflandırma için) veya ortalaması (regresyon için) aracılığıyla tahminin güvenilirliğini artırır. Rastgele Orman algoritması özünde karar ağaçlarına, yani girdi alanını karar vermek için bölgelere ayıran basit modellere dayanır (Serrano, 2022). Sağlamlık sağlar ve iki temel strateji aracılığıyla aşırı uyum olasılığını azaltır: torbalama ve rastgele özellik seçimi. Bagging veya Bootstrap Aggregating, orijinal verilerin birden fazla alt kümesinin oluşturulmasını, her bir alt kümede bir karar ağacının eğitilmesini ve ardından sonuçların toplanmasını içerir. Bu yöntem, yanlılığı önemli ölçüde artırmadan varyansı azaltmaya yardımcı olur. Ayrıca, her düğümde bölme için rastgele bir özellik alt kümesi seçerek Rastgele Orman, ağaçların çeşitli olmasını ve birbirleriyle daha az ilişkili olmasını sağlayarak modelin performansını daha da artırır (Genuer & Poggi, 2020; Y. Liu et al., 2012).

Rastgele Orman algoritması aykırı değerleri ve doğrusal olmayan verileri verimli bir şekilde ele alma konusunda dikkate değer bir yetenek göstererek geniş bir problem yelpazesinde doğruluğu ile ünlüdür. Bu sağlamlık, hem kategorik hem de sürekli verilerle başa çıkma kabiliyeti ile birleştiğinde, onu hem sınıflandırma hem de regresyon görevleri için çok yönlü bir araç haline getirir. Dahası, Rastgele Orman eksik değerleri incelikte ele alabilir ve eksik veri setlerinde bile modelin performansından ödün verilmemesini sağlar. Bununla birlikte, algoritmanın dezavantajları da yok değildir. Modelin karmaşıklığı ve boyutu, daha fazla ağacın eklenmesiyle önemli ölçüde artabilir, bu da özellikle büyük veri kümelerini içeren senaryolarda performansını engelleyebilir. Ayrıca, bireysel karar ağaçları yorumlanabilirlik avantajı sunarken, çok sayıda ağaçtan oluşan bir orman, tahminlerin nasıl yapıldığının anlaşılmasını zorlaştırır (Gall et al., 2012; Mbaabu, 2020).

Rastgele Orman, kredi puanlama ve dolandırıcılık tespitine yardımcı olduğu bankacılıktan, hastalık teşhisi ve kritik prognostik faktörlerin belirlenmesi için tıbbi ve hatta uydu görüntüsü sınıflandırması için uzaktan algılamaya kadar çeşitli alanlarda kullanım alanı bulmuştur. Uygulama alanı, öneri sistemlerini ve müşteri segmentasyonunu geliştirdiği e-ticarete kadar uzanmaktadır.

Rastgele Orman, özünde karar ağaçlarının basitliğini temel alır ve torbalama ve rastgele özellik seçimi yoluyla çok sayıda ağacın tahmin yeteneklerini bir araya getirerek sınırlamalarını aşar. Bu sentez yalnızca yüksek doğruluk ve sağlamlığa sahip bir model ortaya çıkarmakla kalmaz, aynı zamanda çok çeşitli veri türlerine ve görevlere

uyarlanabilir, bu da onu geleneksel makine öğrenmesi tekniklerinin araç setinde tercih edilen bir seçenek haline getirir (Genuer & Poggi, 2020; Onesmus, 2020).

3.5.3. Çok katmanlı algılayıcı (MLP)

Bir YSA türü olarak MLP'ler, çıkarılan özellikler ile doğrulama sonuçları arasındaki karmaşık, doğrusal olmayan ilişkileri modellemek için kullanılır. Derin, birbirine bağlı yapıları, özelliklerin incelikli bir şekilde işlenmesine olanak tanıyarak doğrulama sürecinin doğruluğuna katkıda bulunur.

3.5.4 Doğrusal ve lojistik regresyon

Bu algoritmalar sırasıyla sürekli değişkenlerin tahminini (örneğin parmak fotoğraflarından yaş tahmini) ve ikili sınıflandırmayı (örneğin cinsiyet doğrulama) gerektiren görevler için kullanılır. Basitlikleri ve verimlilikleri onları ilk analizler ve daha karmaşık modellere karşı kıyaslamalar için uygun hale getirmektedir.

3.6. Kombinasyon Teknikleri

Çeşitli özellik çıkarıcılar ve farklı sınıflandırıcılar arasındaki kombinasyon dikkate alınmaya değerdir. Son yıllarda, makine öğrenmesi alanı, verileri anlama ve işleme yaklaşımını temelden değiştirerek yenilik ve uygulamada kayda değer bir artışa tanık oldu. Bu devrimin merkezinde, her biri benzersiz güçler ve yetenekler sunan derin öğrenme ve geleneksel makine öğrenmesi teknikleri yer almaktadır. AlexNet GoogleNet(Muhammad et al., 2018)ve LeNet(Vimalarani & Ramachandraiah, 2022)özellekle görüntü ve konuşma tanıma gibi karmaşık, yüksek boyutlu verilerin işlenmesini gerektiren görevlerde yeni standartlar belirlemiştir. Eş zamanlı olarak, Destek Vektör Makineleri (SVM) gibi geleneksel makine öğrenmesi sınıflandırıcıları(Veisi, 2023), Rastgele Ormanlar(Genuer & Poggi, 2020)ve Karar Ağaçları(Quinlan, 1986) çeşitli alanlardaki örüntü tanıma ve sınıflandırma görevlerinde etkinliklerini kanıtlamışlardır. Sinir ağlarının sağlam temsil yeteneklerini geleneksel makine öğrenmesi sınıflandırıcılarının titiz doğruluğu ile birleştiren ayrıntılı bir araştırma, bu kombinasyonların etkinliğini önerilen bir yöntemle değerlendirmeyi ve karşılaştırmayı amaçlamaktadır.

Derin öğrenme modellerini geleneksel sınıflandırıcılarla entegre ederek, SVM, Rastgele Ormanlar ve Karar Ağaçlarının karar verme becerilerinin yanı sıra AlexNet, GoogleNet ve LeNet gibi ağların hiyerarşik özellik çıkarma yeteneklerinden

yararlanılması önerilmektedir. Bu yenilikçi yaklaşım, evrişimli sinir ağları (CNN'ler) tarafından öğrenilen derin, soyut temsillerden yararlanmayı ve bunları geleneksel sınıflandırıcılar için girdi olarak kullanmayı, böylece derin özellik öğrenimi ile hassas sınıflandırma görevleri arasındaki boşluğu kapatmayı amaçlamaktadır. Bu çalışmanın birincil odak noktası, seçilen algoritmaların güçlü yönlerini ve tamamlayıcılıklarını vurgulamak için titizlikle seçilen belirli bir veri kümesi olacaktır. Metodolojilerin bu stratejik birleşimi sayesinde, amaç yalnızca doğruluk ve verimliliği artırmak değil, aynı zamanda veri kümesinin altında yatan yapı ve dinamikler hakkında daha derin içgörüler sağlamaktır.

Karşılaştırmalı analiz, araştırmada önemli bir rol oynayacaktır. Bağımsız derin öğrenme modellerinin ve geleneksel sınıflandırıcıların performansını önerilen yaklaşımla kıyaslayarak doğruluk, genellenebilirlik ve hesaplama verimliliğindeki gelişmeleri ölçmek amaçlanmaktadır. Bu titiz karşılaştırma, yalnızca derin öğrenme mimarilerini klasik makine öğrenmesi teknikleriyle birleştirmenin etkinliğini doğrulamakla kalmayacak, aynı zamanda bunların uygulanması için en uygun konfigürasyonlara ve koşullara da ışık tutacaktır.

Bu çalışma, geleneksel makine öğrenmesi sınıflandırıcılarının analitik hassasiyeti ile derin öğrenmenin temsili gücünü sinerji haline getirmeye yönelik öncü bir çabayı temsil etmektedir. AlexNet, GoogleNet, LeNet ile SVM, Random Forests ve Decision Trees'in özenle seçilmiş bir veri kümesi üzerinde dikkatli bir şekilde bir araya getirilmesiyle, bu alanda yeni bir ölçüt oluşturulması beklenmektedir. Bulgular, gelecekteki araştırma ve uygulamalar için değerli içgörüler ve metodolojiler sunarak makine öğrenmesi üzerine daha geniş bir söyleme katkıda bulunmayı amaçlamaktadır.

3.7 Doğrulama Teknikleri

Doğrulama teknikleri, modellerin performansını ve geliştirilebilirliğini değerlendirmek için makine öğrenmesinde kritik öneme sahiptir. Bir modelin görünmeyen veriler üzerinde ne kadar iyi performans göstereceğini anlamaya yardımcı olurlar, bu da güvenilir ve sağlam makine öğrenmesi uygulamaları sağlamak için hayati önem taşır. Yaygın olarak kullanılan iki doğrulama tekniği çapraz doğrulama ve rastgele bölme yöntemleridir.

3.7.1 Çapraz doğrulama

Çapraz doğrulama, istatistiksel bir analizin sonuçlarının bağımsız bir veri kümesine nasıl genelleştirileceğini değerlendirmek için kullanılan bir tekniktir. Öncelikle amacın bir modelin görünmeyen veriler üzerindeki performansını tahmin etmek olduğu ortamlarda kullanılır. Prosedür, bir veri örneğinin tamamlayıcı alt kümelere bölünmesini, analizin bir alt küme (eğitim seti olarak adlandırılır) üzerinde gerçekleştirilmesini ve analizin diğer alt küme (doğrulama veya test seti olarak adlandırılır) üzerinde doğrulanmasını içerir. Bu yaklaşım, aşırı uyum gibi sorunların azaltılmasına yardımcı olur, modelin sadece eğitim verilerini ezberlemesini değil, daha önce karşılaşmadığı veriler üzerinde de iyi performans göstermesini sağlar (Arlot & Celisse, 2010; Tumen et al., 2010).

Çapraz doğrulamanın en yaygın şekli k-kat çapraz doğrulamadır. Bu doğrulamada, orijinal örnek rastgele k adet eşit büyüklükte alt örneğe bölünür; burada tek bir alt örnek modeli test etmek için doğrulama verisi olarak tutulur ve kalan k-1 alt örnek eğitim verisi olarak kullanılır. Çapraz doğrulama işlemi, veri doğrulaması için her zaman bir kat kullanılarak k kez (tüm katları kapsayacak şekilde) uygulanır. Daha sonra k sonucun ortalaması alınarak tek bir tahmin elde edilebilir. Bu yöntemin tekrarlanan alt örneklemeye göre avantajı, tüm gözlemlerin hem eğitim hem de test için kullanılmasıdır (Fushiki, 2011; X. Zhang & Liu, 2023).

Çapraz doğrulama, kullanılan tüm verileri kapsadığından modelin performansı için daha doğru bir ölçüm sağlar. Bu yöntem, modelin performansının eğitim ve test verilerinin belirli bir bölümüne bağlı olmamasını sağlamaya yardımcı olur. Hem eğitim hem de test için veri kümesinin tamamını kullanarak çapraz doğrulama, modelin aşırı uyum sağlama riskini azaltır ve bir modelin farklı veri alt kümelerinde ne kadar iyi performans göstereceğine dair kapsamlı bir görünüm sağlar (Wong & Yeh, 2020; X. Zhang & Liu, 2023).

3.7.2. Rastgele bölme yöntemi

Rastgele bölme yöntemi, verilerin iki parçaya bölünmesini içeren bir tür çapraz doğrulama tekniğidir. Bunlardan biri bir modeli eğitmek için kullanılırken diğeri modeli test etmek için kullanılır. Bu yöntemde, veri kümesi eğitim ve test olmak üzere iki kümeye ayrılır. Eğitim seti modeli eğitmek için, test seti ise modelin performansını değerlendirmek için kullanılır. Bu süreç, modelin daha önce görülmemiş veriler üzerinde performans gösterme yeteneğini simüle ederek genelleştirilebilirliğine ilişkin bir tahmin

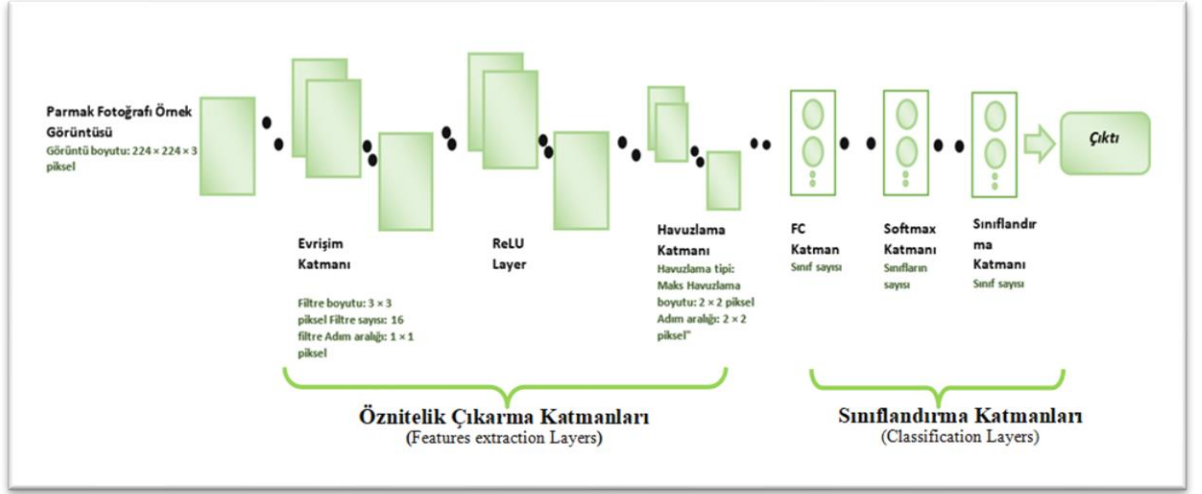
sağlar. Yaygın bir bölme oranı, veri kümesinin %70'inin eğitim ve %30'unun test için kullanılmasıdır, ancak belirli oran veri kümesi boyutuna ve sorunun niteliğine göre değişebilir (Yadav & Shukla, 2016).

Rastgele Bölme Yöntemi, büyük bir veri kümesi mevcut olduğunda en etkili şekilde kullanılır. Diğer karmaşık çapraz doğrulama tekniklerinden daha basit ve hızlıdır, bu da onu hesaplama kaynakları sınırlı olduğunda ilk model değerlendirmesi için pratik bir seçim haline getirir. Bununla birlikte, modelin farklı veri alt kümeleri üzerindeki performansını temsil etmeyebileceğinden, etkinliği verilerin bölünmesiyle sınırlanabilir.

Hem çapraz doğrulama hem de rastgele bölme yöntemlerinin bir makine öğrenmesi modelinin değerlendirme sürecinde yeri vardır. Doğru tekniğin seçilmesi, veri kümesinin boyutu, mevcut hesaplama kaynakları ve geliştirme hızına karşı model doğruluğu ihtiyacı dahil olmak üzere projenin özel gereksinimlerine bağlıdır (Bates et al., 2023; Kim, 2009).

3.8 Önerilen Derin Tekrarlayan Parmak Fotoğraf Ağı (DRFN)

Bu çalışmada, Derin Tekrarlayan Parmak Fotoğraf Ağı (DRFN) adında bir Derin Tekrarlayan Öğrenme (DRL) yaklaşımı önerilmiştir. Bu yaklaşım, parmak fotoğrafı görüntüleri temel alınarak bireylerin kimliğini, yaşını ve cinsiyetini belirlemek için kullanılabilir. Önerilen DRFN, giriş katmanı, öznetelik çıkarma katmanları (içinde konvolüsyon, doğrusallaştırılmış doğrusal birim (ReLU) ve havuzlama bulunur), sınıflandırma katmanları (tam bağlı (FC), softmax ve sınıflandırma içerir) ve çıkış katmanı olarak kategorize edilen çoklu katmanlar içermektedir. Önerilen DRFN modelinin mimarisi Şekil 3.9'da gösterilmiştir. İlerleyen alt başlıklarda DRFN'nin bileşenleri detaylandırılmıştır.



Şekil 3.9. Önerilen DRFN modelinin mimarisi

3.8.1 Girdi katmanı

Bu özel katman, bir parmak fotoğrafı giriş görüntüsünün işlenmesinden sorumludur. Her görüntü örneği piksel boyutlarında (yükseklik×genişlik×3) Kırmızı, Yeşil ve Mavi (RGB) tipindedir. Daha basit bir ifadeyle, bu katmandaki girdiler, her görüntünün üç RGB kanalından oluştuğu parmak fotoğraflarının renkli görüntüleri olarak temsil edilir. Parmak izi görüntüsü $IMF(x, y)$ olarak adlandırılır.

3.8.2 Öznitelik çıkarma katmanları

3.8.2.1 Konvolüsyon katmanı

Bu katman, girdi görüntüsünü filtrelerle (veya çekirdeklerle) evrişerek kenarlar, dokular, renkler gibi belirli özellikleri tespit etmeye yardımcı olur. Ağın daha derinlerine indikçe genellikle daha karmaşık özellikleri yakalar.

Konvolüsyon katmanı, c_{in} giriş katmanının her kanalından türetilen özellik haritaları oluşturur. Her özellik haritası, çekirdeğin bir ağırlık koleksiyonu olduğu bir çekirdeğe sahip bir konvolüsyonel kanal olarak hizmet eder. Tipik olarak, çekirdeğin boyutları genişlik w ve yükseklik h olarak ifade edilir, bu da $w \times h$ piksel boyutunda bir sonuç verir. Bir konvolüsyon katmanı için temel denklem aşağıdaki gibi ifade edilir (Yan et al., 2020):

$$V_{z,t,q} = D_q + \sum_{i=1}^{c_{in}} \sum_{j=1}^{k_h} \sum_{k=1}^{k_w} IMF_{z_s+j,t_{s+k},i} \times W_{j,k,i,q} \quad (3.2)$$

Yukarıdaki formülde $V_{z,t,q}$ konvolüsyon özellik haritasındaki bir değeri temsil eder, (z, t) bir uzamsal koordinatı temsil eder, q kanal endeksini ifade eder D_q ile ilişkili önyargıyı temsil eder. q^{th} konvolüsyonel katmandaki özellik haritası, $IMF_{z_{S+j}, t_{S+k}, i}$ önceki değerlerin bir değerini belirtir. Bu ifade, i^{th} kanalın uzamsal koordinatlar $(z_{(S+j)}, t_{(S+k)})$ üzerinde belirlenen bir kanal ile q^{th} uzamsal konumdaki konvolüsyonel özellik haritasının (j, k, i, q) (Ardakani et al., 2018).kanalı arasındaki ilişkiyi ifade eden $W_{j,k,i,q}$ ağırlığını temsil eder. Bu ilişki, bir atlama mekanizmasının uygulanması sonucu oluşabilir ve böylece bir girişin i^{th} kanalı ilgili konumdaki bir konvolüsyonel özellik haritası kanalı ile bağlantılı hale gelir (Ardakani et al., 2018).

Daha fazla analiz için birden fazla evrimsel katman gerektiren biyometrikler olduğunu belirtmek gerekir. Ancak, burada önerilen DRFN modeline daha fazla katman (veya katmanlar) eklemek uygun görülmemiştir. Bunun sebebi, özellikle bir sonraki bölümde gösterileceği gibi en yüksek doğruluğa ulaşabildiğinde karmaşıklığını artıracaktır. Bu nedenle, mümkün olduğunca basit tutmak tercih edilmiştir.

3.8.2.2. ReLU katmanı

Bu özel katmanın model mimarisine dahil edilmesinin birincil avantajı ve amacı doğrusal olmayan hesaplamaları kolaylaştırmak ve mümkün kılmaktır. Bu, özellik haritalarında yalnızca pozitif değerlerin tutulması ve korunması, aynı zamanda negatif değerlerin atılması ve elenmesi ile gerçekleştirilir. ReLU aktivasyon fonksiyonunun bu özelliği, modelin özellikleri işleme ve analiz etme kabiliyetini artırmada çok önemli bir rol oynamaktadır. ReLU aktivasyon fonksiyonunun hesaplanması için matematiksel ifade aşağıda gösterilen denklem ile kısaca özetlenebilir (Agarap, 2018):

$$L_{z,t,q} = f(V_{z,t,q}) = \max(0, V_{z,t,q}) \quad (3.3)$$

Yukarıdaki denklemde $L_{z,t,q}$ ReLU katmanındaki sonucu, max verilen giriş üzerinde gerçekleştirilen maksimum işlemi göstermektedir (Krizhevsky et al., 2012).

3.8.2.3. Havuzlama katmanı

Havuzlama katmanı, alınan kanalların boyutunun azaltılmasında önemli bir rol oynamaktadır. Elde edilen ReLU çıktılarından seçici olarak maksimum veya ortalama değerleri alır. Burada, maksimum değerleri havuzlayarak çıkarılan özelliklerin boyutunu

azaltır. Maksimum havuzlama katmanı için kapsayıcı formül aşağıdaki gibi ifade edilebilir(Gholamalinezhad & Khosravi, n.d.).

$$k_{a^l,b^l,c} = \max_{0 \leq a < h_p, 0 \leq b < w_p} y_{a^l \times h_p + a, b^l \times w_p + b, c} \quad (3.4)$$

Denklem 3.4' te $k_{a^l,b^l,c}$ bir havuzlama katmanının sonucu, $0 \leq a^l < h_p^l, h_p^l$ havuzlanmış bir kanalın yüksekliği, $0 \leq b^l < w_p^l, w_p^l$ havuzlanmış bir kanalın genişliği, $0 \leq c < c^l = c^{l-1}l$ ve $l-1$ sırasıyla mevcut katmanı ve bir önceki katmanı ifade etmektedir. w_p ve h_p ise sırasıyla ReLU sonuçlarından havuzlanması gereken bir alt bölgenin genişliğini ve yüksekliğini temsil etmektedir (J. Wu, 2017).

3.8.3. Sınıflandırma katmanları

3.8.3.1. FC katmanı

Bu katmanın amacı, bir önceki katman ile belirli sayıda nöron arasında iyi bir eşleşme sağlamaktır. Hem havuzlama katmanı hem de istenen sınıf veya denek sayısı (çıktılar) arasında etkili bir eşleşme sağlama yeteneğine sahiptir. Tam bağlı (FC) katmanının işleyişi matematiksel olarak aşağıdaki denklem ile açıklanmaktadır(K. Liu et al., 2018):

$$FL_r = \sum_{a=1}^{mc_1^{l-1}} \sum_{b=1}^{mc_2^{l-1}} \sum_{c=1}^{mc_3^{l-1}} W_{a,b,c,r}^l (\mathbf{K})_{a,b} \quad \forall 1 \leq r \leq mc^l \quad (3.5)$$

Denklem 3.5'de FL_r FC katmanının bir çıktısını, mc_1^{l-1} kenetlenme katmanı içindeki bir kanalın yüksekliğini, mc_2^{l-1} havuzlama katmanı içindeki bir kanalın genişliğini, mc_3^{l-1} havuzlama katmanı içinde oluşturulan kanal sayısını ifade eder. $W_{a,b,c,r}^l$ havuzlama katmanını FC katmanına bağlayan bağlantı ağırlıkları anlamına gelirken, \mathbf{K} havuzlama katmanının çıktılarını temsil eder. mc^l FC katmanında gerekli olan nöron sayısını ifade eder, bu da istenen sınıfların veya çıktılarının sayısına eşdeğer olabilir (J. Wu, 2017).

3.8.3.2. Softmax katmanı

Softmax katmanı, her bir giriş görüntüsü için sınıflandırma olasılıklarını hesaplamak için kullanılan softmax aktivasyon fonksiyonunu içerir. Söz konusu katmanın matematiksel gösterimi aşağıdaki denklem ile ifade edilebilir:

$$SL_r = \frac{e^{FC_r}}{\sum_{s=1}^{mc^l} e^{FC_s}}, r=1, 2, \dots, mc^l \quad (3.6)$$

Denklem 3.6' da SL_r softmax katmanının bir sonucunu ifade eder (J. Wu, 2017).

3.8.3.3. Sınıflandırma katmanları

Bu katmanın kullanımı, tanıma veya sınıflandırma nihai kararına ulaşmak için çok önemlidir. Bu katman, kazanan hepsini alır kuralını takip eder. Bu katmanın işlevselliğinin matematiksel gösterimi kısaca aşağıdaki gibi ifade edilebilir (Alzubaidi et al., 2021):

$$FC_r = \begin{cases} 1 & \text{if } SL_r = \text{Max} \\ 0 & \text{otherwise} \end{cases}, r=1, 2, \dots, mc^l \quad (3.7)$$

Denklem 3.7' de FC_r sınıflandırma katmanının bir çıktısını, Max ise softmax katmanından elde edilen maksimum değeri ifade eder.

3.9 Performans Değerlendirme Ölçütleri

Biyometrik doğrulama sistemleri alanında, sahtekarları etkili bir şekilde engellerken gerçek kullanıcıları tanıma hassasiyeti çok önemlidir. Bu, bu tür sistemlerin etkinliğini eleştirel bir şekilde değerlendirmek için performans ölçütlerinin incelikli bir şekilde anlaşılmasını gerektirir. Burada, biyometrik doğrulama modellerinin performansını değerlendirmek için birkaç temel ölçüt kullanılmaktadır.

1. Yanlış Kabul Oranı (FAR): Biyometrik sistemin sahtekarlara yanlışlıkla erişim izni verme oranını ifade eder. FAR aşağıdaki denklemde gösterildiği gibi hesaplanabilir (Tariq et al., 2023):

$$FAR = \frac{\text{Number of impostors accepted}}{\text{Total number of impostor attempts}} \quad (3.8)$$

2. Yanlış Reddetme Oranı (FRR): Biyometrik sistemin gerçek kullanıcılara erişimi hatalı bir şekilde reddetme sıklığını ifade eder. Matematiksel olarak aşağıdaki gibi ifade edilebilir(Tariq et al., 2023):

$$FRR = \frac{\text{Number of genuine users rejected}}{\text{Total number of genuine users}} \quad (3.9)$$

3. Eşit Hata Oranı (EER): Temel bir ölçümdür. FAR ve FRR'nin eşdeğer olduğu noktadır. Aşağıdaki gibi ifade edilebilir(Tariq et al., 2023):

$$EER = \frac{FAR+FRR}{2} \quad (3.10)$$

Hem FAR hem de FRR'nin en aza indirilmesi son derece önemlidir. Burada EER'nin yanı sıra doğruluğa da odaklanılmaktadır.

Ayrıca, geri çağırma, kesinlik, özgüllük ve f1-skoru gibi önemli ölçütler, uygulanan çeşitli modeller arasındaki karşılaştırmaları desteklemek için dikkate alınmaktadır. Analizler ayrıca, parmak fotoğrafı tanımanın belirli yönlerini ne kadar iyi ele aldıklarının daha iyi anlaşılmasını sağlayarak, etkinliklerine ilişkin daha bilinçli değerlendirmelere katkıda bulunur.

Duyarlılık, kesinlik, doğruluk ve f1-skor, sınıflandırma çıktılarının performansını değerlendirmek için yaygın olarak kullanılan metriklerdir ve bu çıktılar doğrulama ve tanıma için kullanılabilir (R. R. O. Al-Nima et al., 2017). Bu metrikler, bir sınıflandırma yönteminin sonuçlarını özetleyen bir karışıklık matrisi için hesaplanır. Karmaşıklık matrislerini anlayabilmek için ilk olarak, temel terimlerin tanımlanması gerekmektedir:

- Doğru Pozitif (TP): Gerçekten pozitif olan ve doğru şekilde pozitif olarak sınıflandırılan örnek sayısı.
- Doğru Negatif (TN): Gerçekten negatif olan ve doğru şekilde negatif olarak sınıflandırılan numune sayısı.
- Yanlış Pozitif (FP): Aslında negatif olan ancak yanlışlıkla pozitif olarak sınıflandırılan örneklerin sayısı.
- Yanlış Negatif (FN): Gerçekte pozitif olan ancak yanlışlıkla negatif olarak sınıflandırılan örneklerin sayısı.

Ardından, aşağıdaki ölçütler hesaplanabilir:

3.9.1. Duyarlılık (recall)

Model tarafından doęru tespit edilen gerek pozitif vakaların oranıdır. Őu soruya cevap verir: "Tüm gerek pozitiflerden kaç tanesini doęru tespit ettik?" Bu ifade matematiksel olarak Őu Őekilde gösterilebilir(Feng et al., 2020):

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3.11)$$

Yukarıdaki denklemde, TP doęru pozitiflerin (doęru tanımlanmış pozitifler) sayısı, FN ise yanlış negatiflerin sayısıdır (yanlışlıkla negatif olarak tanımlanan pozitifler).

3.9.2. Kesinlik (Precision)

Gerekten doęru olan pozitif tanımlamaların oranıdır. Őu soruya cevap verir: "Tahmin ettięimiz tüm pozitiflerden kaç tanesi gerekten pozitif?" Bu ifade denklem ile gösterilebilir(Maman et al., 2023):

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3.12)$$

Yukarıdaki denklemde, FP yanlış pozitifleri (yanlışlıkla pozitif olarak tanımlanan negatif vakalar) temsil eder.

3.9.3. Özgüllük (gerek negatif oranı)

Model tarafından doęru Őekilde tanımlanan gerek negatif vakaların oranıdır. Őu soruya cevap verir: "Tüm gerek negatiflerden kaç tanesini doęru tespit ettik?" Özgüllük için formül Őöyledir(Oyeranmi et al., 2020):

$$\text{Specificity} = \frac{TN}{TN+FP} \quad (3.13)$$

Yukarıdaki denklemde TN doęru negatiflerin (doęru tanımlanmış negatifler) sayısıdır.

3.9.4. F1-skoru

Kesinlik ve geri aęırmanın harmonik bir ortalamasıdır ve aralarındaki dengeyi deęerlendirmek için tek bir metrik sağlar. Özellikle sınıf etiketlerinin dağılımı eŐit olmadığında kullanışlıdır. F1-skoru için formül Őöyledir(Maman et al., 2023):

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3.14)$$

Yukarıdaki denklem, bir modelin yüksek bir F1 puanı elde etmek için her iki metrikte de (hassasiyet ve geri çağırma) iyi performans göstermesi gerektiğini gösterir.

4. BULGULAR VE TARTIŞMA

Bu tez çalışması, özgün bir parmak görüntüsü veri setinin elde edilmesi ve söz konusu veri seti üzerinde çeşitli sınıflandırma metotlarının test edilmesine odaklanmaktadır. Toplanan veri seti, her biri RGB (renk) tipinde ve Joint Photographic Experts Group (JPG) formatında kategorize edilmiş bir dizi parmak görüntüsü içerir. Veri seti, yaşları 16 ile 75 arasında değişen 100 kişinin parmak görüntülerini içermektedir. Bu katılımcılar 58 erkek ve 42 kadın olarak kategorize edilerek dengeli bir cinsiyet temsili sağlanmıştır. Her katılımcı, her iki elinin sağ ve solundaki tüm parmaklar için 10 parmak fotoğrafı sağlamış ve sonuçta FITF veri kümesinde toplam 10.000 görüntü elde edilmiştir. Veri setine ait detaylı bilgiler Ek-1'de bulunabilir. Ham veri kümesinin toplam boyutu 18,8 GB'tır ve elde etme işlemi sırasında basit bir beyaz arka plan ve çeşitli döndürme açıları dikkate alınmıştır. Söz konusu veri setinin toplanması ve kullanılması için Kırşehir Ahi Evran Üniversitesi Fen ve Mühendislik Bilimleri Bilimsel Araştırma ve Yayın Etiği Kurulu'ndan izin alınmıştır.

Önerilen DRFN modelinin parametreleri; Bir parmak görüntüsünün giriş boyutu için $224 \times 224 \times 3$ piksel, konvolüsyon katmanının filtre boyutu için 3×3 piksel, konvolüsyon katmanındaki filtre sayısı için 16 filtre, adım değeri 1, bir konvolüsyon kanal boyutunun aynı giriş kanal boyutuna sahip olmasını sağlamak için sıfır dolgu, havuzlama katmanı için maksimum tip, havuzlama katmanının filtre boyutu için 2×2 piksel, havuzlama katmanındaki yatay ve dikey adımlar için 2×2 piksel ve son katmanlar için 100 sınıf (FC, softmax ve sınıflandırma) şeklinde ayarlanmıştır ve bu aşamadan sonra gerçekleştirilen sınıflandırma işlemleri, bu parametreler ile gerçekleştirilmiştir.

Tüm uygulamalar MATLAB ortamında, Intel Core i7-7600U işlemci ve 16 GB belleğe sahip bilgisayar üzerinde gerçekleştirilmiştir.

Bu tez kapsamında gerçekleştirilen tüm deneylerde, 10-fold çapraz doğrulama kullanılmıştır. Bu teknik, tüm mevcut verilerin eğitimde kullanılmasını sağlayarak modelin performansının daha doğru bir şekilde değerlendirilmesine yardımcı olur. K-kat çapraz doğrulama kullanılarak modelin sağlamlığı artırılır, aşırı uyum riski azaltılır ve farklı veri alt kümeleri arasında daha genelleştirilmiş bir performans sağlanır. Ayrıca, bu yöntem modelin sınıflandırma doğruluğu ve çeşitli senaryolar arasındaki performans istikrarı hakkında bilgiler sunar. Bu sayede karmaşık modellerin değerlendirilmesi için güvenilir sonuçlar elde edilir.

Toplanan veri seti ve önerilen model ile gerçekleştirilen sınıflandırma testleri ilerleyen başlıklarda ayrı ayrı sunulmuştur.

4.1 Bireysel Doğrulama

Bu başlık altında sunulan işlem ve sonuçlar, Derin Tekrarlayan Parmak Fotoğrafi Ağı (DRFN)'nin verilen parmak fotoğrafları üzerinden bir bireyi tanımasına olanak sağlamak için tasarlanmıştır. Modelin eğitimi, k'nın 10 olarak belirlendiği k-kat çapraz doğrulama yöntemi kullanılarak gerçekleştirilmiştir. Test aşamasında, her sınıf için doğru bir değerlendirme sağlamak amacıyla, test verilerinin %50'si (100 fotoğraf) değerlendirilen sınıfa aitken, kalan %50'si diğer sınıflardan rastgele seçilen verilerden (diğer tüm sınıflardan ek 100 fotoğraf) oluşmaktadır. Bu sayede oluşturulan veri setinin dengeli yapısı, modelin gerçek dünya senaryolarını taklit eden koşullar altında test edilmesini ve hedef sınıf ile diğer çeşitli sınıfları doğru bir şekilde ayırt etmesini sağlamıştır. Tablo 4.1' de tüm sınıflar için doğruluk metrikleri detaylı bir şekilde sunulmaktadır.

Tablo 4.1. Dengeli Sınıflandırma Testinde Her Sınıf İçin Doğruluk Metrikleri


Sınıf no.	Duyarlılık (%)	Kesinlik (%)	F1-Skoru (%)	Sınıfa Özel Doğruluk (%)
1	80	100	89	87
2	100	100	100	100
3	88	92	90	88
4	96	92	94	96
5	92	88	90	92
6	96	96	96	96
7	96	100	98	96
8	96	100	98	96
9	100	93	96	100
10	100	93	96	100
11	100	100	100	100
12	100	96	98	100
13	96	96	96	96
14	100	100	100	100
15	100	100	100	100
16	92	100	96	92
17	100	100	100	100
18	100	100	100	100
19	92	100	96	92
20	96	100	98	96
21	92	100	96	92

22	96	86	91	96
23	92	100	96	92
24	84	100	91	84
25	100	96	98	100
26	96	96	96	96
27	100	96	98	100
28	96	100	98	96
29	92	100	96	92
30	100	86	93	100
31	96	89	92	96
32	100	89	94	100
33	100	93	96	100
34	100	96	98	100
35	100	100	100	100
36	92	88	90	92
37	100	93	96	100
38	92	100	96	92
39	96	86	91	96
40	84	100	91	84
41	100	100	100	100
42	100	100	100	100
43	100	100	100	100
44	100	100	100	100
45	96	96	96	96
46	100	100	100	100
47	96	100	98	96
48	84	88	86	84
49	92	77	84	92
50	96	100	98	97
51	96	92	94	96
52	100	100	100	100
53	96	92	94	96
54	100	100	100	100
55	100	96	98	100
56	96	100	98	96
57	100	78	88	100
58	80	100	89	80
59	88	100	94	88
60	100	96	98	100

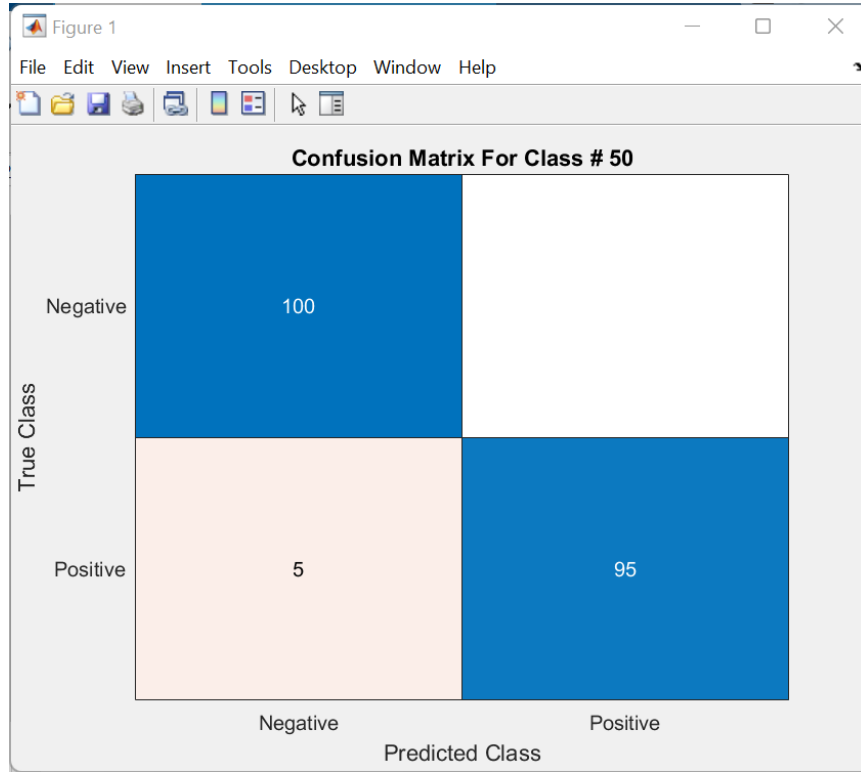
61	88	100	94	88
62	92	88	90	92
63	100	100	100	100
64	96	100	98	96
65	100	100	100	100
66	96	92	94	96
67	88	100	94	88
68	100	93	96	100
69	100	93	96	100
70	80	50	62	80
71	100	100	100	100
72	96	100	98	96
73	96	100	98	96
74	64	44	52	64
75	88	100	94	88
76	100	58	74	100
77	32	100	48	32
78	24	33	28	24
79	24	55	33	24
80	100	100	100	100
81	100	100	100	100
82	100	93	96	100
83	96	92	94	96
84	60	58	59	60
85	36	56	44	36
86	76	86	81	76
87	84	100	91	84
88	80	87	83	80
89	88	100	94	88
90	100	96	98	100
91	100	66	79	100
92	96	96	96	96
93	100	96	98	100
94	100	100	100	100
95	92	100	96	92
96	96	92	94	96
97	88	81	85	88
98	100	100	100	100
99	88	69	77	88

100	56	93	70	58
Genel doğruluk	91.4	92.2	91.2	92

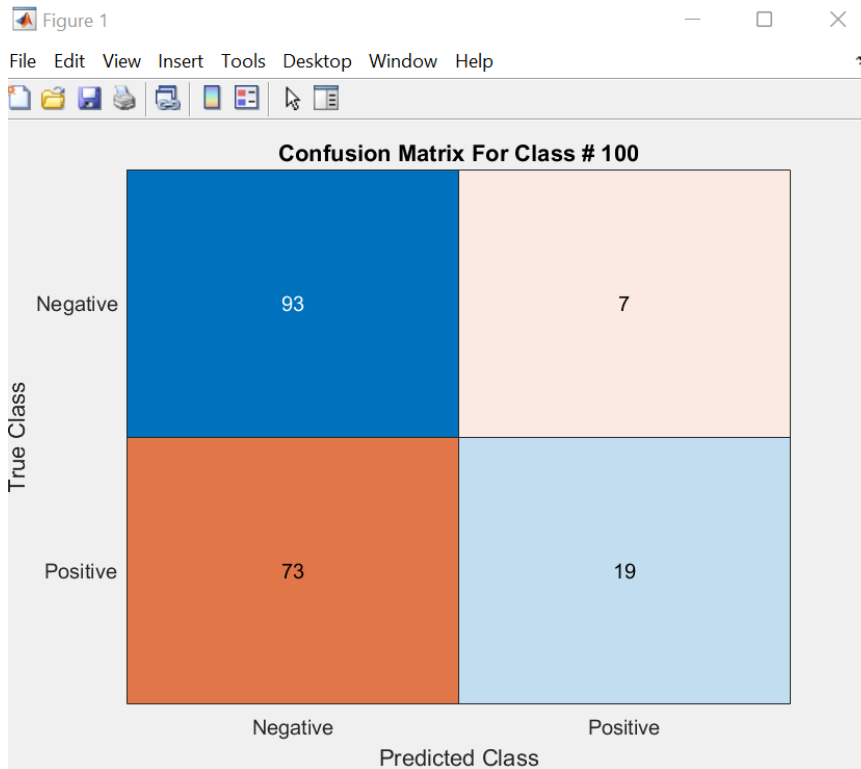
Tablo 4.1'de sunulan verilerin daha net anlaşılabilmesi amacıyla, örnek olarak seçilen üç sınıf (Sınıf 1, 50 ve 100) için karmaşıklık matrisleri oluşturulmuştur. Şekil 4.1, 4.2 ve 4.3, sırasıyla bu seçilen sınıflar için karmaşıklık matrislerini göstermekte ve böylece her bir sınıf için sınıflandırma sonuçlarını görsel olarak açıklamaktadır.



Şekil 4.1. Sınıf 1 İçin Karmaşıklık Matrisi



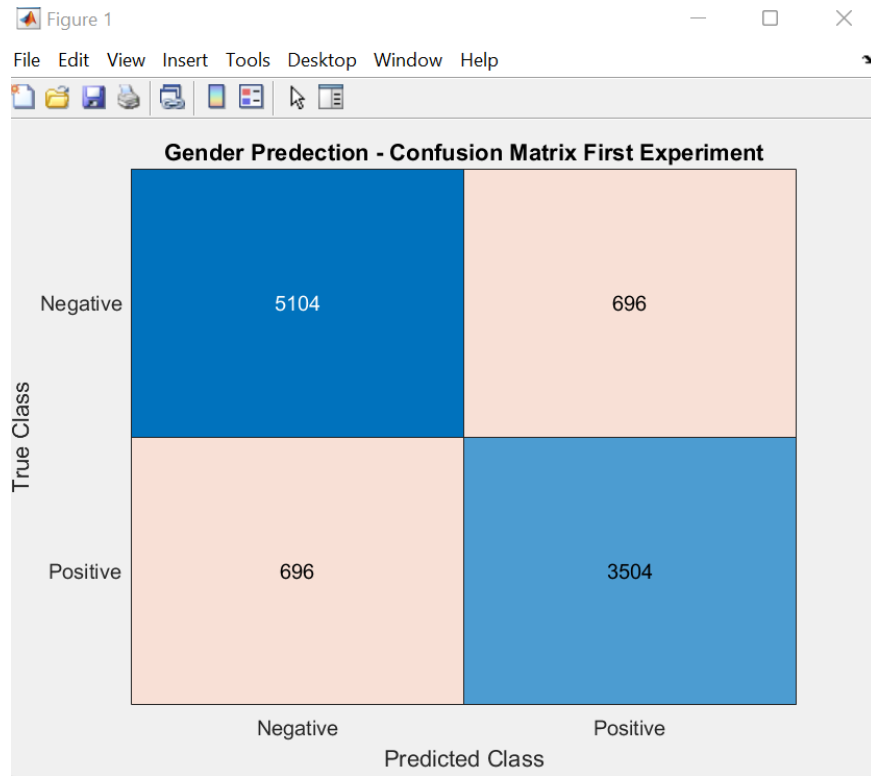
Şekil 4.2. Sınıf 50 İçin Karmaşıklık Matrisi



Şekil 4.3. Sınıf 100 İçin Karmaşıklık Matrisi

4.2 Cinsiyet Tahmini

Bu bölümün temel amacı, parmak fotoğrafları üzerinden cinsiyet tahmini yapmaktır. FIFT veri seti kullanılarak cinsiyet tahmini yapmak için için iki ana deney gerçekleştirilmiştir. İlk deney, 42 kadın ve 58 erkekten oluşan, her bireyin 100 parmak fotoğrafıyla katkıda bulunduğu toplam 10.000 parmak fotoğrafını içeren tüm veri setinin sınıflandırılmasını içermektedir. Şekil 4.4, bu sınıflandırmaların doğruluğunu gösteren bir karmaşıklık matrisi sunmaktadır. Ayrıca, Tablo 4.2 her bir cinsiyet kategorisi için ve modelin genel doğruluğu için ayrıntılı doğruluk metriklerini sağlamaktadır.

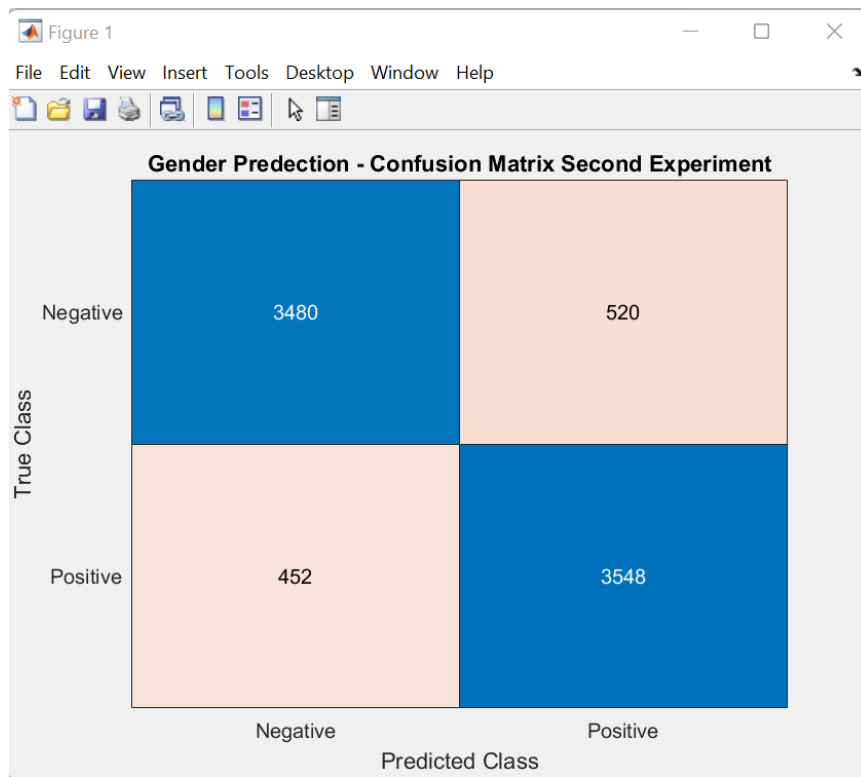


Şekil 4.4. Parmak Fotoğraflarıyla Cinsiyet Sınıflandırması İçin Karmaşıklık Matrisi

Tablo 4.2. Parmak Fotoğraflarıyla Cinsiyet Sınıflandırması İçin Ayrıntılı Doğruluk Metrikleri

Değerlendirme metrikleriYüzde			
Sınıf	Kesinlik %	Duyarlılık %	F1-skor %
Dişi	85.4	89.0	87.2
Erkek	88.5	84.8	86.6
Genel Doğruluk	86.9	%	

Cinsiyet tanıma kapsamında gerçekleştirilen ikinci deneyde, daha iyi sonuçlar elde etmek için FIFT veri setinden dengeli bir alt küme kullanmıştır. Bu kontrollü ayar, her cinsiyet kategorisinden eşit sayıda örnek seçilmesini içerir; özellikle her cinsiyetten 40 kişi, toplamda 8,000 parmak fotoğrafı ile sonuçlanmıştır. Dengeli bir veri seti kullanmanın amacı, eşit olmayan örnek boyutlarından kaynaklanabilecek olası yanlılıkları ortadan kaldırmak ve böylece modelin farklı cinsiyetler arasındaki performansının daha doğru bir şekilde değerlendirilmesini sağlamaktır. Şekil 4.5’ de gerçekleştirilen işleme ait karmaşıklık matrisi gösterilmektedir.. Tablo 4.3’ de ise elde edilen metrikler gösterilmektedir..



Şekil 4.5. Dengeli Veri Seti ile Cinsiyet Sınıflandırması İçin Karmaşıklık Matrisi

Tablo 4.3. Dengeli Veri Seti Kullanılarak Cinsiyet Sınıflandırması İçin Doğruluk Metrikleri

Değerlendirme metrikleriYüzde			
Sınıf	Kesinlik %	Duyarlılık %	F1-skor %
Dişi	88.2	87.4	87.8

Erkek	87.5	88.3	87.9
Genel Doğruluk	87.8 %		

Gerçekleştirilen iki deneyden sırasıyla, Tablo 4.2 ve Tablo 4.3'te gösterildiği gibi %86,9 ve %87,8 doğruluk oranları elde edilmiştir. Bu sonuçlar, modelin hem orijinal hem de dengeli veri kümelerini kullanarak cinsiyeti doğru bir şekilde tespit edebilme kapasitesini doğrulamaktadır. Özellikle, ilk deneyde erkek ve kadın katılımcıların dengesiz sayıları, dengeli veri seti kullanılan ikinci deney ile karşılaştırıldığında genel doğruluğu önemli ölçüde etkilememektedir. Bu gözlem, modelin örnek bileşimindeki varyasyonlara rağmen yüksek performansını sürdürebilecek kadar sağlam olduğunu öne sürmektedir. Özetle, model, farklı deney koşullarında cinsiyet tahmini konusunda başarılı sayılabilecek sonuçlar elde etmiştir.

Adil değerlendirmeleri sağlamak amacıyla, cinsiyet tahmini için önerilen Derin Yinelemeli Parmak Fotoğrafı Ağı (DRFN) modeli, biyometri alanında parmak görüntüleri üzerinden sınıflandırma amacıyla geliştirilmiş çeşitli Derin Öğrenme (DL) ağlarıyla karşılaştırılmıştır. (R. R. Al-Nima et al., 2020)(Omar Al-Nima et al., 2023b)(Omar et al., 2019)(Ibrahim et al., 2021)

Karşılaştırmalı değerlendirme, bu ağların simüle edilmesi ve 40 erkek ile 40 kadından oluşan dengeli bir veri kümesi olan On Parmak Fotoğrafları (FITF) üzerinde uygulanmasıyla gerçekleştirilmiştir. Bu metodolojiyi kullanmak, tüm karşılaştırmaların tutarlı deneysel koşullar altında yapılması ve her modelin göreceli etkinliğinin adil bir şekilde değerlendirilmesi amaçlanmıştır.

Bu karşılaştırmaya ait detaylı metrik sonuçlar, test edilen her ağ için Tablo 4.4' de gösterilmektedir. Söz konusu metrikler incelendiğinde, önerilen DRFN modelinin, literatürdeki diğer modellerden daha başarılı sonuçlar ürettiğini göstermektedir.

Tablo 4.4. Çeşitli DL Ağlarının Performans Metriklerinin Karşılaştırmalı Analizi

DL modeli	Kesinlik (%)	Duyarlılık %	F1-Skoru (%)	Doğruluk
DFTL (Omar et al., 2019)	68	69	68	68.4
DFL2	74	73.7	73.4	73.7

(Omar Al-Nima et al., 2023b)	DFCN	75.6	75.5	74.6	75.5
(Ibrahim et al., 2021)	DFL1	77.9	77.2	77	77.2
(R. R. Al-Nima et al., 2020)	DRFN	88.3	88	87.9	87.8

Değerlendirilen modeller arasında, DRFN modeli, en yüksek hassasiyeti %88.3, duyarlılığı %88, F1-skorunu %87.9 ve doğruluğu %87.8 göstermiştir. Bu sonuçlar, DRFN'nin tutarlı ve doğru sınıflandırmalar üretme konusundaki güvenilirliğini göstermektedir.

Literatürde önerilen modellere ek olarak, DRFN modeli çeşitli öznelik çıkarma ve sınıflandırıcı kombinasyonlarına karşı da test edilmiştir. Bu testlerde, çeşitli sınıflandırıcılar bir araya getirerek onların toplu etkinliğini değerlendirilmiştir. Tablo 4.5, her modele ait değerlendirme metriklerini içermektedir. Söz konusu metrikler, rakipleriyle karşılaştırıldığında, DRFN'nin sınıflandırma görevlerindeki performans sonuçlarını anlamayı kolaylaştırmaktadır.

Tablo 4.5. Karşılaştırmalı Analiz: DRFN ve Öznelik Çıkarma Modelleri ve Sınıflandırıcılara Ait Performans Metrikleri

Özellik	Çıkarma (Derin Öğrenme Ağından)	İstihdam Edilen Sınıflandırıcı	Performanslar			
			Keskinlik%	Duyarlılık %	F1-Skor %	Doğruluk %
		SVM	85	88	80	86
Alexnet		Rastgele Orman	84	86	79	85
		MLP	33	43	36	28
LeNet		SVM	85	86	83	85.5

	Rastgele Orman	82	88	82	84.5
	MLP	37	35	33	37.5
	SVM	85	85	82	85
GoogLeNet	Rastgele Orman	79	85	84	81
	Doğrusal Regresyon	76	86	80	79
VGG16	SVM	86	86	90	86
	Rastgele Orman	77	85	82	80
	Lojistik Regresyon	84	83	90	83.5
DRFN (Önerilen yöntem)		88.3	88	87.9	87.8

Elde edilen sonuçlara göre, DRFN modeli bilinen derin öğrenme modelleri ve klasik sınıflandırıcı kombinasyonlarına karşı başarılı sonuçlar elde etmiştir.

Örneğin, öznelik çıkarımı için AlexNet ile sınıflandırma için SVM birleşiminden, %85 hassasiyet, %88 duyarlılık, %80 F1 puanı ve %86 doğruluk elde edilmiştir. Benzer analizler LeNet, GoogLeNet ve VGG16 gibi diğer öznelik çıkarma metotları için de yapılmıştır; her biri SVM, Rastgele Orman, Lojistik Regresyon ve sınıflandırıcılarla eşleştirilmiştir.

Sonuç olarak, tabloda gösterildiği gibi önerilen DRFN yöntemi, %88.3 hassasiyet, %88 duyarlılık, %87.9 F1 puanı ve %87.8 doğruluk ile öne çıkmaktadır. Bu sonuçlar, DRFN'nin sağlam performansını vurgular ve onu sınıflandırma görevleri için etkili bir model olarak konumlandırır. Bu detaylı analiz, sadece DRFN'nin yeteneklerini sergilemekle kalmaz, aynı zamanda farklı derin öğrenme mimarileri ve sınıflandırıcıların çeşitli uygulamalarda nasıl optimize edilebileceğini anlamada yardımcı olur.

4.3 Yaş Tahmini

Bu bölümün temel amacı, DRFN modelinin bireylerin parmak fotoğraflarından yaşlarını tahmin etme yeteneğini değerlendirmektir. Bu değerlendirmede kullanılan metodoloji, belirli ve önceden tanımlanmış yaş kategorilerine göre bireyleri sınıflandırmak üzere tasarlanmış iki ayrı deneysel kurulumu içerir. Analizin ilk

aşamasında, veriler Tablo 4.6'da gösterildiği gibi, her kategori 15 birey içerecek şekilde altı farklı yaş aralığına ayrılmış ve sınıflandırma işlemi gerçekleştirilmiştir.

Tablo 4.6. 6 Sınıfın Dikkate Alındığı İlk Ana Deney İçin Yaş Sınıfları

Sınıf	Yaş Grubu	Veri Setindeki Kişisel Sınıfların ID' leri	Her Bir Sınıftaki Kişi Sayısı
1	16-18	8,9,23,26,27,56,66,68,81,85,91,95,97,98,99	15 birey
2	19- 21	2,11,25,30,35,37,43,61,64,67,88,89,94,96,100	15 birey
3	22- 27	5,6,7,12,19,24,32,42,55,60,72,77,84,86,90	15 birey
4	28-33	1,4,10,36,39,41,54,59,62,71,76,78,80,92,93	15 birey
5	35-41	3,17,18,22,31,34,40,44,45,46,52,53,69,74,75	15 birey
6	42- 55	14,15,20,28,33,38, 47,49, 50,63,70,79,82,83,87	15 birey


Tablo 4.7, modelin parmak fotoğraflarını, belirlenen yaş gruplarına göre doğru şekilde sınıflandırma yeteneğini her grup için gösteren metrikleri sunmaktadır. Söz konusu metrikler, modelin her bir görüntüyü doğru yaş kategorisine sınıflandırma hassasiyetini değerlendirmeye yardımcı olur, bu da sınıflandırma sisteminin etkin uygulanması ve daha da iyileştirilmesi için hayati önem taşır.

Tablo 4.7. Parmak Fotoğraflarının Yaşa Özgü Sınıflandırma Doğruluğu İçin Değerlendirme Metrikleri

Yaş grubu	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)	Sınıfa Özel Doğruluk (%)
1	83	87	85	87.5
2	83	80	81	79.7
3	84	78	81	77.8
4	84	87	85	86.7
5	84	83	84	83.1
6	83	87	85	87.1
Genel Doğruluk		83.64 %		

Tablo 4.7'de sunulan verilere göre, model mevcut deney düzeninde %83.64 doğruluk oranı elde etmiştir. Modelin her sınıf için yaptığı doğru ve yanlış tahminleri daha iyi anlayabilmek için, karmaşıklık matrisi Şekil 4.6'da gösterilmektedir. Bu görsel temsiller, modelin belirli yaş kategorilerindeki hassasiyet ve güvenilirliğinin detaylı bir analizini sağlamakta önemli bir role sahiptir. Karışıklık matrisinin dahil edilmesi,

modelin bireyleri kendi yaş kategorilerine doğru bir şekilde sınıflandırma yeteneğini anlamaya yardımcı olur ve yaşa dayalı sınıflandırma alanında hem güçlü yönlerini hem de potansiyel iyileştirme alanlarını vurgular.



Şekil 4.6. İlk Yaş Grubu İçin Karışıklık Matrisi

Sınıflandırma metodolojisinin ikinci aşaması, her biri 25 birey içeren üç farklı yaş aralığı kategorisinde gerçekleştirilmiştir. Bu segmentasyona ait detaylar, Tablo 4.8'de gösterilmektedir. Bu yaklaşım, bireyleri söz konusu yaş aralıklarında doğru şekilde kategorize etme konusunda, modelin başarısını test etme şansı sunmaktadır.

Tablo 4.8. Parmak Fotoğraflarının Yaşa Özgü Sınıflandırma Doğruluğu İçin Değerlendirme Metrikleri

Sınıf	Yaş Grubu	Veri Setindeki Kişisel Sınıfların ID'leri	Her Bir Sınıftaki Kişi Sayısı
1	16 -22	2,5,8,9,11,23,25,26,27,30,35,37,43,56, 61,64,66,67,68,77,81,85, 88, 89,91	25 birey
2	23-35	1,4,6,7,10,13,17,18,19,24,29,32,36,39,41,42,54,55,59,60,62,65, 71,72,76	25 birey

3	36-53	3,14,15,16,20,21,22,28,31,33,34,38,40,44,45,46,47,48,49,50,52, 53,57,58,63	25 birey
----------	-------	---	----------


Tablo 4.8' de gösterilen sınıflar üzerinde, önerilen DFRN modeli kullanılarak gerçekleştirilmiş sınıflandırma işleminin metrikleri Tablo 4.9'te sunulmaktadır.

Tablo 4.9. Deney 2'deki Dengeli Yaş Grupları için Performans

Metriklerinin Değerlendirilmesi

Yaş grubu	Kesinlik (%)	Duyarlılık (%)	F1-Skoru (%)	Sınıfa Özel Doğruluk (%)
1	89	84	87	87
2	81	88	85	83.5
3	90	88	89	89
Genel Doğruluk		86.5%		

Önerilen DRFN modelinin, gerçekleştirilen sınıflandırma işlemindeki performansı daha iyi anlamak için, söz konusu işleme ait karmaşıklık matrisi Şekil 4.7' de gösterilmektedir.



Şekil 4.7. 2. Yaş Gruplandırması için Karışıklık Matrisi

İkinci deneyde gözlemlenen %86,5'lik genel doğruluk oranı, ilk deneyde elde edilen %83,64'lük orana kıyasla daha iyi bir oran olarak görülmüştür. Bu gelişme, yaş gruplarının sayısının azaltılmasına bağlanabilir; bu durum doğruluğu olumlu yönde etkilemiştir. Bu sonuçlar, veri setinin yaş gruplarını başarılı bir şekilde sınıflandırma kapasitesini ortaya koymakta ve doğru yaşa özgü veri analizi gerektiren uygulamalar için kullanılabilirliğini teyit etmektedir. Bu ilerleme, veri seti kompozisyonunun model sonuçlarını iyileştirmedeki önemini ve optimize edilmiş grup sınıflandırmalarının bu tür modellerin genel tahmin doğruluğunu artırma potansiyelini vurgulamaktadır.

Parmak görüntüleri üzerinde önerilen DRFN modelinin test edilmesi sonrasında, aynı veriler üzerinde bilinen öznetelik çıkarıcıların ve sınıflandırıcıların çeşitli kombinasyonları test edilmiştir. Gerçekleştirilen testlerde, AlexNet, LeNet, GoogleNet ve ResNet-50 gibi derin öğrenme tabanlı öznetelik çıkarma algoritmaları kullanılmıştır. Her bir öznetelik çıkarma algoritması, çeşitli sınıflandırıcılar—Destek Vektör Makineleri (SVM), Rastgele Orman, ve Çok Katmanlı Algılayıcı (MLP) ile birleştirilmiştir.

Tablo 4.10, bu çalışmadan elde edilen değerlendirme metriklerini göstermektedir. Bu metrikler, seçilen bir yaş grubu için sınıflandırma doğruluğunu yansıtarak, farklı öznetelik çıkarıcıların çeşitli sınıflandırıcılarla birleştirilmesinin

etkinliğine dair görüş sağlamaktadır. Bu yaklaşım, her ağ ve sınıflandırıcı kombinasyonunun bireysel güçlü ve zayıf yönlerini vurgulamanın yanı sıra, demografik özelliklere dayalı çözümler geliştirme potansiyelini de ortaya koyar.

Tablo 4.10. DRFN ile Çeşitli Öznitelik Çıkarıcı- Sınıflandırıcı Kombinasyonlarının Karşılaştırmalı Performans Metrikleri

Özellik	Çıkarma (Derin Öğrenme Ağından)	İstihdam Edilen Sınıflandırıcı	Performanslar			
			Kesinlik	Duyarlılık	F1-Skor	Doğruluk
			%	%	%	%
		SVM	86	85	86	85.5
Alexnet		Rastgele Orman	82	87	84	84
		MLP	37	34	45	38
		SVM	82	84	80	83
LeNet		Rastgele Orman	78	76	79	77.5
		MLP	36	38	33	35
		SVM	79	77	80	78.5
GoogLeNet		Rastgele Orman	77	75	82	76.5
		SVM	76	75	77	75
ResNet-50		Rastgele Orman	77	78	79	77.5
		DRFN (Önerilen yöntem)	89	84	87	86.6

Performans metriklerinin incelendiğinde, önerilen DRFN modelinin, parmak fotoğraflarına dayanarak bireylerin yaşlarını sınıflandırma ve tahmin etme yeteneğine ilişkin net bir anlayış sunar. Sunulan verilere göre, DRFN modeli hassasiyet, duyarlılık, F1-puanı ve doğruluk gibi metrikler yönünden, algoritmalara göre daha iyi performans göstermektedir. Bu durum, DRFN'nin biyometrik uygulamalarda yaş sınıflandırma görevleri için uygun bir seçim olduğunu göstermektedir.

5. SONUÇ VE ÖNERİLER

Bu tez çalışması, insan doğrulama süreçlerinde önemli bir yeri olan parmak fotoğrafı biyometrisine odaklanarak, bu alandaki araştırmaları genişletmeyi amaçlamaktadır. Ayrıca, kişi tanıma, cinsiyet ve yaş tahminleri için özel olarak tasarlanmış olan Derin Tekrarlayan Parmak Fotoğrafları Ağı (DRFN) modeli tanıtılmaktadır.

Çalışmanın öne çıkan yeniliklerinden biri, her bir katılımcının on parmağının farklı açılardan çekilmiş onar fotoğrafını içeren On Parmak için Parmak Fotoğrafları Görüntü Veri Seti'nin (FITF) oluşturulmasıdır. Bu veri seti, toplamda 100 katılımcının her iki elinden alınan toplam 10.000 parmak fotoğrafını içermektedir ve DRFN modelinin eğitilmesi, değerlendirilmesi ve diğer algoritmalar ile karşılaştırılması için kullanılmıştır.

Önerilen DRFN modeli, parmak fotoğraflarına dayanarak bireysel kimlikleri tahmin etme konusunda %92 gibi yüksek bir başarı oranına ulaşmıştır. Her bir kategori için yapılan sistematik sınıflandırmalar, geri çağırma, F1 puanı ve doğruluk gibi metrikler detaylı bir şekilde sunulmuştur. Seçilen sınıflar için hazırlanan karmaşıklık matrisleri de modelin performansını desteklemektedir.

Bu tezin dikkat çekici bir diğer yönü ise, bireylerin parmak fotoğrafları üzerinden cinsiyet ve yaş tahminleri yapılmasıdır; DRFN modeli bu tahminlerde sırasıyla ortalama %87.8 ve %86.6 başarı oranı göstermiştir. Önerilen model, AlexNet, LeNet, GoogleNet, VGG16 ve ResNet-50 gibi tanınmış öznetelik çıkarma modelleri ile ve SVM, Random Forest, MLP, Doğrusal Regresyon gibi çeşitli sınıflandırıcıların kombinasyonları ile karşılaştırılmış, elde edilen metrikler ve karmaşıklık matrisleri ile derinlemesine analiz edilmiştir. Genel olarak, önerilen model tüm karşılaştırmalarda umut verici sonuçlar elde etmiştir.

Kapsamlı literatür taraması, büyük sayıda bireyin on parmağının tümünden alınan parmak fotoğraflarını içeren bir veri setinin toplanmasına yönelik bir araştırmayla karşılaşılmadığını göstermiştir. Bu parmak fotoğraflarını kullanarak bir bireyin kimliğini, cinsiyetini ve yaşını aynı anda tahmin eden bir çalışma ile de karşılaşılmamıştır. Bu durum, tez çalışmasının özgün yönlerini vurgulamakta ve diğer biyometrik araştırmalardan ayrılmasını sağlamaktadır.

Gelecek çalışmalarda, DRFN modelinin parmak eklemleri ve dokuları gibi yeni biyometrik verilere uygulanması, çok faktörlü kimlik doğrulama sistemlerine entegrasyonu ve sürekli öğrenme yoluyla uyum kabiliyetinin artırılması planlanmaktadır. Ayrıca, gerçek zamanlı işleme iyileştirmeleri ve artırılmış çevresel sağlamlık, geniş

uygulamalar için kritik öneme sahiptir. Bu adımlar, önerilen modelin değerini artıracak ve biyometrik güvenliğin geleceğindeki yerini daha da sağlamlaştıracaktır.

6. KAYNAKLAR

- Abaza, A., & Ross, A. (2010). Towards understanding the symmetry of human ears: A biometric perspective. *IEEE 4th International Conference on Biometrics: Theory, Applications and Systems, BTAS 2010*.
<https://doi.org/10.1109/BTAS.2010.5634535>
- Abdullah, D. M., & Abdulazeez, A. M. (2021). Machine Learning Applications based on SVM Classification: A Review. *Qubahan Academic Journal*, 1(2).
<https://doi.org/10.48161/qaj.v1n2a50>
- Agarap, A. F. (2018). *Deep Learning using Rectified Linear Units (ReLU)*.
<http://arxiv.org/abs/1803.08375>
- Alghamdi, J., Alharthi, R., Alghamdi, R., Alsubaie, W., Alsubaie, R., Alqahtani, D., Ramadan, R. Al, Alqarni, L., & Alshammari, R. (2020). A Survey on Face Recognition Algorithms. *ICCAIS 2020 - 3rd International Conference on Computer Applications and Information Security*.
<https://doi.org/10.1109/ICCAIS48893.2020.9096726>
- Al-Kaltakchi, M. T., Omar, R. R., Abdullah, H. N., Han, T., & Chambers, J. A. (2019). Finger Texture Verification Systems Based on multiple spectrum Lighting Sensors with Four Fusion Levels. *Iraqi Journal of Information & Communications Technology*, 1(3). <https://doi.org/10.31987/ijict.1.3.28>
- Al-Nima, R. R., Hasan, S., Mahmood, S., Hasan, S. Q., & Esmail, S. (2020). Exploiting the Deep Learning with Fingerphotos to Recognize People. *International Journal of Advanced Science and Technology*, 29(7), 13035–13046.
<https://www.researchgate.net/publication/345236222>
- Al-Nima, R. R. O., Abdullah, M. A. M., Al-Kaltakchi, M. T. S., Dlay, S. S., Woo, W. L., & Chambers, J. A. (2017). Finger texture biometric verification exploiting Multi-scale Sobel Angles Local Binary Pattern features and score-based fusion. *Digital Signal Processing: A Review Journal*, 70. <https://doi.org/10.1016/j.dsp.2017.08.002>
- Al-Nima, R. R. O., Jarjes, M. K., Kasim, A. W., & Sheet, S. S. M. (2020). Human Identification using Local Binary Patterns for Finger Outer Knuckle. *Proceeding - 2020 IEEE 8th Conference on Systems, Process and Control, ICSPC 2020*.
<https://doi.org/10.1109/ICSPC50992.2020.9305779>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep

- learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1). <https://doi.org/10.1186/s40537-021-00444-8>
- Ardakani, A., Condo, C., Ahmadi, M., & Gross, W. J. (2018). An Architecture to Accelerate Convolution in Deep Neural Networks. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 65(4). <https://doi.org/10.1109/TCSI.2017.2757036>
- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4. <https://doi.org/10.1214/09-SS054>
- Ayurzana, O., Pumbuurei, B., & Kim, H. (2013). A study of hand-geometry recognition system. *8th International Forum on Strategic Technology 2013, IFOST 2013 - Proceedings*, 2. <https://doi.org/10.1109/IFOST.2013.6616871>
- Bača, M., Schatten, M., & Ševa, J. (2009). Behavioral and Physical Biometric Characteristics Modeling Used for Its Security Improvement. *Transport Problems*, 4(4).
- Badillo, S., Banfai, B., Birzele, F., Davydov, I. I., Hutchinson, L., Kam-Thong, T., Siebourg-Polster, J., Steiert, B., & Zhang, J. D. (2020). An Introduction to Machine Learning. *Clinical Pharmacology and Therapeutics*, 107(4). <https://doi.org/10.1002/cpt.1796>
- Bahmed, F., Mammari, M. O., & Ouamri, A. (2019). A Multimodal Hand Recognition System Based on Finger Inner-Knuckle Print and Finger Geometry. *Journal of Applied Security Research*. <https://doi.org/10.1080/19361610.2019.1545271>
- Baştanlar, Y., & Özuysal, M. (2014). Introduction to machine learning. *Methods in Molecular Biology*, 1107. https://doi.org/10.1007/978-1-62703-748-8_7
- Bates, S., Hastie, T., & Tibshirani, R. (2023). Cross-Validation: What Does It Estimate and How Well Does It Do It? *Journal of the American Statistical Association*. <https://doi.org/10.1080/01621459.2023.2197686>
- Bernardi, M. L., Cimitile, M., Martinelli, F., & Mercaldo, F. (2019). Keystroke Analysis for User Identification using Deep Neural Networks. *Proceedings of the International Joint Conference on Neural Networks, 2019-July*. <https://doi.org/10.1109/IJCNN.2019.8852068>
- Bertsimas, D., & King, A. (2017). Logistic regression: From art to science. *Statistical Science*, 32(3), 367–384. <https://doi.org/10.1214/16-STS602>
- Bezdan, T., & Bačanin Džakula, N. (2019). *Convolutional Neural Network Layers and Architectures*. <https://doi.org/10.15308/sinteza-2019-445-451>

- Birajadar, P., Gupta, S., Shirvalkar, P., Patidar, V., Sharma, U., Naik, A., & Gadre, V. (2017a). Touch-less fingerphoto feature extraction, analysis and matching using monogenic wavelets. *2016 International Conference on Signal and Information Processing, IConSIP 2016*. <https://doi.org/10.1109/ICONSIP.2016.7857436>
- Birajadar, P., Gupta, S., Shirvalkar, P., Patidar, V., Sharma, U., Naik, A., & Gadre, V. (2017b). Touch-less fingerphoto feature extraction, analysis and matching using monogenic wavelets. *2016 International Conference on Signal and Information Processing, IConSIP 2016*. <https://doi.org/10.1109/ICONSIP.2016.7857436>
- Birajadar, P., Haria, M., Kulkarni, P., Gupta, S., Joshi, P., Singh, B., & Gadre, V. (2019). Towards smartphone-based touchless fingerprint recognition. *Sadhana - Academy Proceedings in Engineering Sciences*, 44(7). <https://doi.org/10.1007/s12046-019-1138-5>
- Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2). <https://doi.org/10.1023/A:1009715923555>
- Carney, L. A., Kane, J., Mather, J. F., Othman, A., Simpson, A. G., Tavanai, A., Tyson, R. A., & Xue, Y. (2017a). A multi-finger touchless fingerprinting system: Mobile fingerphoto and legacy database interoperability. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3168776.3168800>
- Carney, L. A., Kane, J., Mather, J. F., Othman, A., Simpson, A. G., Tavanai, A., Tyson, R. A., & Xue, Y. (2017b). A multi-finger touchless fingerprinting system: Mobile fingerphoto and legacy database interoperability. *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3168776.3168800>
- Chandra, M. A., & Bedi, S. S. (2021). Survey on SVM and their application in image classification. *International Journal of Information Technology (Singapore)*, 13(5). <https://doi.org/10.1007/s41870-017-0080-1>
- Chauhan, V. K., Dahiya, K., & Sharma, A. (2019). Problem formulations and solvers in linear SVM: a review. In *Artificial Intelligence Review* (Vol. 52, Issue 2). <https://doi.org/10.1007/s10462-018-9614-6>
- Chiu, C. C., Wu, C. M., Chien, T. N., Kao, L. J., Li, C., & Chu, C. M. (2023). Integrating Structured and Unstructured EHR Data for Predicting Mortality by Machine Learning and Latent Dirichlet Allocation Method. *International Journal of Environmental Research and Public Health*, 20(5). <https://doi.org/10.3390/ijerph20054340>

- Chowdhury, A. M. M., & Imtiaz, M. H. (2022). Contactless Fingerprint Recognition Using Deep Learning—A Systematic Review. *Journal of Cybersecurity and Privacy*, 2(3), 714–730. <https://doi.org/10.3390/jcp2030036>
- Çınar, A., & Tuncer, S. A. (2021). Classification of lymphocytes, monocytes, eosinophils, and neutrophils on white blood cells using hybrid Alexnet-GoogleNet-SVM. *SN Applied Sciences*, 3(4). <https://doi.org/10.1007/s42452-021-04485-9>
- Corizzo, R., & Rosen, J. (2024). Stock market prediction with time series data and news headlines: a stacking ensemble approach. *Journal of Intelligent Information Systems*, 62(1). <https://doi.org/10.1007/s10844-023-00804-1>
- Cuomo, S., Di Cola, V. S., Giampaolo, F., Rozza, G., Raissi, M., & Piccialli, F. (2022). Scientific Machine Learning Through Physics-Informed Neural Networks: Where we are and What's Next. *Journal of Scientific Computing*, 92. <https://doi.org/10.1007/s10915-022-01939-z>
- Das, R. K., Mukhopadhyay, S., & Bhattacharya, P. (2014). User authentication based on keystroke dynamics. *IETE Journal of Research*, 60(3). <https://doi.org/10.1080/03772063.2014.914686>
- Das, S., Tariq, A., Santos, T., Kantareddy, S. S., & Banerjee, I. (2023). Recurrent Neural Networks (RNNs): Architectures, Training Tricks, and Introduction to Influential Research. In *Neuromethods* (Vol. 197). https://doi.org/10.1007/978-1-0716-3195-9_4
- Deb, D., Chugh, T., Engelsma, J., Cao, K., Nain, N., Kendall, J., & Jain, A. K. (2018a). *Matching Fingerphotos to Slap Fingerprint Images*.
- Deb, D., Chugh, T., Engelsma, J., Cao, K., Nain, N., Kendall, J., & Jain, A. K. (2018b). *Matching Fingerphotos to Slap Fingerprint Images*. <http://arxiv.org/abs/1804.08122>
- Deepanshi, K., Gupta, K., & Sendhil, R. (2023). Review on Age and Gender Detection: Diverse approach and Algorithmic Insights. *2023 6th International Conference on Recent Trends in Advance Computing (ICRTAC)*, 672–677. <https://doi.org/10.1109/ICRTAC59277.2023.10480778>
- DeVries, T., & Taylor, G. W. (2017). Dataset augmentation in feature space. *5th International Conference on Learning Representations, ICLR 2017 - Workshop Track Proceedings*.
- Dorizzi, B. (2013). Introduction to Biometrics. In *Signal and Image Processing for Biometrics*. <https://doi.org/10.1002/9781118561911.ch1>

- Ewe, E. L. R., Lee, C. P., Kwek, L. C., & Lim, K. M. (2022). Hand Gesture Recognition via Lightweight VGG16 and Ensemble Classifier. *Applied Sciences (Switzerland)*, *12*(15). <https://doi.org/10.3390/app12157643>
- Feng, C., Zhao, H., Tian, M., Lu, M., & Wen, J. (2020). Erratum: Detecting focal cortical dysplasia lesions from FLAIR-negative images based on cortical thickness (BioMedical Engineering Online (2020) 19 (13) DOI: 10.1186/s12938-020-0757-8). In *BioMedical Engineering Online* (Vol. 19, Issue 1). <https://doi.org/10.1186/s12938-020-00760-9>
- Fosdick, R. B. (1915). The Passing of the Bertillon System of Identification. *Journal of the American Institute of Criminal Law and Criminology*, *6*(3). <https://doi.org/10.2307/1132744>
- Fukushima, K. (2019). Recent advances in the deep CNN neocognitron. *Nonlinear Theory and Its Applications, IEICE*, *10*(4). <https://doi.org/10.1587/nolta.10.304>
- Fukushima, K. (2021). Artificial Vision by Deep CNN Neocognitron. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, *51*(1). <https://doi.org/10.1109/TSMC.2020.3042785>
- Fushiki, T. (2011). Estimation of prediction error by using K-fold cross-validation. *Statistics and Computing*, *21*(2). <https://doi.org/10.1007/s11222-009-9153-8>
- Gall, J., Razavi, N., & Van Gool, L. (2012). An introduction to random forests for multi-class object detection. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *7474 LNCS*. https://doi.org/10.1007/978-3-642-34091-8_11
- Genuer, R., & Poggi, J.-M. (2020). *Introduction to Random Forests with R*. https://doi.org/10.1007/978-3-030-56485-8_1
- Geyer, P., & Singaravel, S. (2018). Component-based machine learning for performance prediction in building design. *Applied Energy*, *228*. <https://doi.org/10.1016/j.apenergy.2018.07.011>
- Gholamalinezhad, H., & Khosravi, H. (n.d.). *Pooling Methods in Deep Neural Networks, a Review*.
- González-Castro, L., Chávez, M., Dufлот, P., Bleret, V., Martin, A. G., Zobel, M., Nateqi, J., Lin, S., Pazos-Arias, J. J., Del Fiol, G., & López-Nores, M. (2023). Machine Learning Algorithms to Predict Breast Cancer Recurrence Using Structured and Unstructured Sources from Electronic Health Records. *Cancers*, *15*(10). <https://doi.org/10.3390/cancers15102741>

- Grandini, M., Bagli, E., & Visani, G. (2020). *Metrics for Multi-Class Classification: an Overview*. <http://arxiv.org/abs/2008.05756>
- Hopkins, D., Rickwood, D. J., Hallford, D. J., & Watsford, C. (2022). Structured data vs. unstructured data in machine learning prediction models for suicidal behaviors: A systematic review and meta-analysis. In *Frontiers in Digital Health* (Vol. 4). <https://doi.org/10.3389/fdgth.2022.945006>
- Huang, M. W., Chen, C. W., Lin, W. C., Ke, S. W., & Tsai, C. F. (2017). SVM and SVM ensembles in breast cancer prediction. *PLoS ONE*, *12*(1). <https://doi.org/10.1371/journal.pone.0161501>
- Ibrahim, A. M., Eesee, A. K., & Al-Nima, R. R. O. (2021). Deep fingerprint classification network. *Telkomnika (Telecommunication Computing Electronics and Control)*, *19*(3). <https://doi.org/10.12928/TELKOMNIKA.v19i3.18771>
- Jain, A. K., Ross, A., & Prabhakar, S. (2004). An Introduction to Biometric Recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, *14*(1). <https://doi.org/10.1109/TCSVT.2003.818349>
- Jhang, K., & Cho, J. (2019). CNN Training for Face Photo based Gender and Age Group Prediction with Camera. *1st International Conference on Artificial Intelligence in Information and Communication, ICAIIC 2019*. <https://doi.org/10.1109/ICAIIC.2019.8669039>
- Jiang, Z. P., Liu, Y. Y., Shao, Z. E., & Huang, K. W. (2021). An improved VGG16 model for pneumonia image classification. *Applied Sciences (Switzerland)*, *11*(23). <https://doi.org/10.3390/app112311185>
- Katiyar, S., & Borgohain, S. K. (2020). Comparative evaluation of CNN architectures for image caption generation. *International Journal of Advanced Computer Science and Applications*, *11*(12). <https://doi.org/10.14569/IJACSA.2020.0111291>
- Kauba, C., Söllinger, D., Kirchgasser, S., Weissenfeld, A., Fernández Domínguez, G., Strobl, B., & Uhl, A. (2021). Towards using police officers' business smartphones for contactless fingerprint acquisition and enabling fingerprint comparison against contact-based datasets. *Sensors*, *21*(7). <https://doi.org/10.3390/s21072248>
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, *53*(8). <https://doi.org/10.1007/s10462-020-09825-6>
- Khanam, R., Khan, R., & Ranjan, R. (2019). Analysis of Finger Vein Feature Extraction and Recognition using da and KNN Methods. *Proceedings - 2019 Amity*

- International Conference on Artificial Intelligence, AICAI 2019*, 477–483.
<https://doi.org/10.1109/AICAI.2019.8701253>
- Kim, J. H. (2009). Estimating classification error rate: Repeated cross-validation, repeated hold-out and bootstrap. *Computational Statistics and Data Analysis*, 53(11). <https://doi.org/10.1016/j.csda.2009.04.009>
- Kiran, B. R., Sobh, I., Talpaert, V., Mannion, P., Sallab, A. A. A., Yogamani, S., & Perez, P. (2022). Deep Reinforcement Learning for Autonomous Driving: A Survey. *IEEE Transactions on Intelligent Transportation Systems*, 23(6). <https://doi.org/10.1109/TITS.2021.3054625>
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, 151. <https://doi.org/10.1016/j.ymssp.2020.107398>
- Kotsiantis, S. B. (2007). Supervised machine learning: A review of classification techniques. In *Informatica (Ljubljana)* (Vol. 31, Issue 3, pp. 249–268).
- Krish, R. P., Fierrez, J., Ramos, D., Alonso-Fernandez, F., & Bigun, J. (2019). Improving automated latent fingerprint identification using extended minutia types. *Information Fusion*, 50. <https://doi.org/10.1016/j.inffus.2018.10.001>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (n.d.). *ImageNet Classification with Deep Convolutional Neural Networks*. <http://code.google.com/p/cuda-convnet/>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 2, 1097–1105.
- Lahmer, H., Oueslati, A. E., & Lachiri, Z. (2020). Classification of DNA Microarrays Using Deep Learning to identify Cell Cycle Regulated Genes. *2020 International Conference on Advanced Technologies for Signal and Image Processing, ATSIP 2020*. <https://doi.org/10.1109/ATSIP49331.2020.9231888>
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11). <https://doi.org/10.1109/5.726791>
- Li, B., & Lima, D. (2021). Facial expression recognition via ResNet-50. *International Journal of Cognitive Computing in Engineering*, 2. <https://doi.org/10.1016/j.ijcce.2021.02.002>

- Liu, K., Kang, G., Zhang, N., & Hou, B. (2018). Breast Cancer Classification Based on Fully-Connected Layer First Convolutional Neural Networks. *IEEE Access*, 6. <https://doi.org/10.1109/ACCESS.2018.2817593>
- Liu, M., & Yan, J. (2013). Inner-knuckle-print verification based on guided image filtering. *Lecture Notes in Electrical Engineering*, 256 LNEE. https://doi.org/10.1007/978-3-642-38466-0_53
- Liu, Y., Wang, Y., & Zhang, J. (2012). New machine learning algorithm: Random forest. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7473 LNCS. https://doi.org/10.1007/978-3-642-34062-8_32
- Malik, J., Elhayek, A., Guha, S., Ahmed, S., Gillani, A., & Stricker, D. (2020). Deepairsig: End-to-end deep learning based in-air signature verification. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2020.3033848>
- Maman, E., Reuveny, S., Luz, A., Hourvitz, R., Moran, E., Youngster, M., Baum, M., & Hourvitz, A. (2023). ESTIMATION OF RETRIEVAL DATE IN ANTAGONIST PROTOCOL CYCLES AT DIFFERENT STAGES OF THE CYCLE, USING ARTIFICIAL INTELLIGENCE ALGORITHM. *Fertility and Sterility*, 120(4). <https://doi.org/10.1016/j.fertnstert.2023.08.232>
- Mbaabu, O. (2020). *Introduction to Random Forest in Machine Learning*. Section.Io.
- Meyer, W., & Rosmus, P. (1975). PNO-CI and CEPA studies of electron correlation effects. III. Spectroscopic constants and dipole moment functions for the ground states of the first-row and second-row diatomic hydrides. *The Journal of Chemical Physics*, 63(6). <https://doi.org/10.1063/1.431665>
- Michalski, B., & Plechawska-Wójcik, M. (2022). Comparison of LeNet-5, AlexNet and GoogLeNet models in handwriting recognition. *Journal of Computer Sciences Institute*, 23. <https://doi.org/10.35784/jcsi.2919>
- Muhammad, N. A., Nasir, A. A., Ibrahim, Z., & Sabri, N. (2018). Evaluation of CNN, alexnet and GoogleNet for fruit recognition. *Indonesian Journal of Electrical Engineering and Computer Science*, 12(2). <https://doi.org/10.11591/ijeecs.v12.i2.pp468-475>
- Mukundan, R., & Ramakrishnan, K. R. (2011). Moment Functions in Image Analysis — Theory and Applications. In *Moment Functions in Image Analysis — Theory and Applications*. <https://doi.org/10.1142/9789812816092>

- Omar Al-Nima, R. R., Hasan, S. Q., & Mahmood, S. E. (2023a). Utilizing Fingerphotos with Deep Learning Techniques to Recognize Individuals. *NTU Journal of Engineering and Technology*, 2(1). <https://doi.org/10.56286/ntujet.v2i1.318>
- Omar Al-Nima, R. R., Hasan, S. Q., & Mahmood, S. E. (2023b). Utilizing Fingerphotos with Deep Learning Techniques to Recognize Individuals. *NTU Journal of Engineering and Technology*, 2(1). <https://doi.org/10.56286/ntujet.v2i1.318>
- Omar, R. R., Han, T., Al-Sumaidae, S. A. M., & Chen, T. (2019). Deep finger texture learning for verifying people. *IET Biometrics*, 8(1). <https://doi.org/10.1049/iet-bmt.2018.5066>
- Onesmus, M. (2020a). Introduction to Random Forest in Machine Learning. *Section.Io*.
- Onesmus, M. (2020b). Introduction to Random Forest in Machine Learning | Engineering Education (EngEd) Program | Section. In *Geeks for Geeks*.
- Oyeranmi, A., Ronke, B., Mohammed, R., & Edwin, A. (2020). Detection of Fracture Bones in X-ray Images Categorization. *Journal of Advances in Mathematics and Computer Science*. <https://doi.org/10.9734/jamcs/2020/v35i430265>
- Pentakalos, O. (2019). Introduction to machine learning. *CMG IMPACT 2019*. <https://doi.org/10.4018/978-1-7998-0414-7.ch003>
- Priesnitz, J., Huesmann, R., Rathgeb, C., Buchmann, N., & Busch, C. (2022). Mobile Contactless Fingerprint Recognition: Implementation, Performance and Usability Aspects. *Sensors*, 22(3). <https://doi.org/10.3390/s22030792>
- Quinlan, J. R. (1986). Induction of Decision Trees. *Machine Learning*, 1(1). <https://doi.org/10.1023/A:1022643204877>
- Rafique, I., Hamid, A., Naseer, S., Asad, M., Awais, M., & Yasir, T. (2019). Age and Gender Prediction using Deep Convolutional Neural Networks. *3rd International Conference on Innovative Computing, ICIC 2019*. <https://doi.org/10.1109/ICIC48496.2019.8966704>
- Raid Rafi Omar Al-Nima. (2017). *Signal Processing and Machine Learning Techniques for Human Verification Based on Finger Textures* (Issue November, pp. 1–195).
- Richter, A. N., & Khoshgoftaar, T. M. (2018). A review of statistical and machine learning methods for modeling cancer risk using structured clinical data. In *Artificial Intelligence in Medicine* (Vol. 90). <https://doi.org/10.1016/j.artmed.2018.06.002>
- Sadat, M., & Caragea, C. (2022). *Hierarchical Multi-Label Classification of Scientific Documents*. <http://arxiv.org/abs/2211.02810>

- Sanchez-Reillo, R., Sanchez-Avila, C., & Gonzalez-Marcos, A. (2000a). Biometric identification through hand geometry measurements. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(10). <https://doi.org/10.1109/34.879796>
- Sanchez-Reillo, R., Sanchez-Avila, C., & Gonzalez-Marcos, A. (2000b). Biometric identification through hand geometry measurements. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(10). <https://doi.org/10.1109/34.879796>
- Saradhi, M. V. V., Rao, P. V., Krishnan, V. G., Sathyamoorthy, K., & Vijayaraja, V. (2023). Prediction of Alzheimer's Disease Using LeNet-CNN Model with Optimal Adaptive Bilateral Filtering. *International Journal of Communication Networks and Information Security*, 15(1). <https://doi.org/10.17762/ijcnis.v15i1.5706>
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. In *SN Computer Science* (Vol. 2, Issue 6). <https://doi.org/10.1007/s42979-021-00815-1>
- Sen, R., & Das, S. (2023). Unsupervised Learning. In *Indian Statistical Institute Series*. https://doi.org/10.1007/978-981-19-2008-0_21
- Serrano, W. (2022). Deep Reinforcement Learning with the Random Neural Network. *Engineering Applications of Artificial Intelligence*, 110. <https://doi.org/10.1016/j.engappai.2022.104751>
- Shin, H. C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D., & Summers, R. M. (2016). Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning. *IEEE Transactions on Medical Imaging*, 35(5). <https://doi.org/10.1109/TMI.2016.2528162>
- Shirke, S. D., & Rajabhushnam, C. (2019). Biometric personal iris recognition from an image at long distance. *Proceedings of the International Conference on Trends in Electronics and Informatics, ICOEI 2019, 2019-April*. <https://doi.org/10.1109/ICOEI.2019.8862640>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Shukla, S., Badal, N., & Thakur, B. K. (2023). Introduction to Deep Learning. In *Sustainable Computing: Transforming Industry 4.0 to Society 5.0*. https://doi.org/10.1007/978-3-031-13577-4_15

- Stein, C., Bouatou, V., & Busch, C. (2013). Video-based Fingerphoto Recognition with Anti-spoofing Techniques with Smartphone Cameras. *BIOSIG 2013 - Proceedings of the 12th International Conference of the Biometrics Special Interest Group*.
- Stein, C., Nickel, C., & Busch, C. (2012a). Fingerphoto recognition with smartphone cameras. *Proceedings of the International Conference of the Biometrics Special Interest Group, BIOSIG 2012*.
- Stein, C., Nickel, C., & Busch, C. (2012b). Fingerphoto recognition with smartphone cameras. *Proceedings of the International Conference of the Biometrics Special Interest Group, BIOSIG 2012*.
- Stewart, L., Bach, F., Berthet, Q., & Vert, J. P. (2023). Regression as Classification: Influence of Task Formulation on Neural Network Features. *Proceedings of Machine Learning Research, 206*.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 07-12-June-2015*.
<https://doi.org/10.1109/CVPR.2015.7298594>
- Tariq, U., Hu, Z., Tariq, R., Iqbal, M. S., & Sadiq, M. (2023). High-Performance Embedded System for Offline Signature Verification Problem Using Machine Learning. *Electronics (Switzerland), 12(5)*.
<https://doi.org/10.3390/electronics12051243>
- Tiwari, K., & Gupta, P. (2015a). A touch-less fingerphoto recognition system for mobile hand-held devices. *Proceedings of 2015 International Conference on Biometrics, ICB 2015, 151–156*. <https://doi.org/10.1109/ICB.2015.7139045>
- Tiwari, K., & Gupta, P. (2015b). A touch-less fingerphoto recognition system for mobile hand-held devices. *Proceedings of 2015 International Conference on Biometrics, ICB 2015, 151–156*. <https://doi.org/10.1109/ICB.2015.7139045>
- Tumen, R. S., Acer, M. E., & Sezgin, T. M. (2010). Feature Extraction and Classifier Combination for Image-based Sketch Recognition. *Interfaces*.
- van Engelen, J. E., & Hoos, H. H. (2020). A survey on semi-supervised learning. *Machine Learning, 109(2)*. <https://doi.org/10.1007/s10994-019-05855-6>
- Veisi, H. (2023). Introduction to SVM. In *Industrial and Applied Mathematics: Vol. Part F2110*. https://doi.org/10.1007/978-981-19-6553-1_1

- Venkatesh, S. (2022). Multi-spectral Finger based User Verification using Off-the-Shelf Deep Features. *IST 2022 - IEEE International Conference on Imaging Systems and Techniques, Proceedings, ii*. <https://doi.org/10.1109/IST55454.2022.9827724>
- Vimalarani, G., & Ramachandraiah, U. (2022). Automatic diagnosis and detection of dental caries in bitewing radiographs using pervasive deep gradient based LeNet classifier model. *Microprocessors and Microsystems, 94*. <https://doi.org/10.1016/j.micpro.2022.104654>
- Wang, P. Y., Chen, C. T., Su, J. W., Wang, T. Y., & Huang, S. H. (2021). Deep learning model for house price prediction using heterogeneous data analysis along with joint self-attention mechanism. *IEEE Access, 9*. <https://doi.org/10.1109/ACCESS.2021.3071306>
- Wang, W., Feng, L., Jiang, Y., Niu, G., Zhang, M.-L., & Sugiyama, M. (2023). *Binary Classification with Confidence Difference*. <http://arxiv.org/abs/2310.05632>
- Wasnik, P., Ramachandra, R., Stokkenes, M., Raja, K., & Busch, C. (2018). Improved Fingerphoto Verification System Using Multi-scale Second Order Local Structures. *2018 International Conference of the Biometrics Special Interest Group, BIOSIG 2018*. <https://doi.org/10.23919/BIOSIG.2018.8553577>
- Wong, T. T., & Yeh, P. Y. (2020). Reliable Accuracy Estimates from k-Fold Cross Validation. *IEEE Transactions on Knowledge and Data Engineering, 32*(8). <https://doi.org/10.1109/TKDE.2019.2912815>
- Wu, J. (2017). Introduction to Convolutional Neural Networks. *Introduction to Convolutional Neural Networks*.
- Wu, X., Liu, X., & Zhou, Y. (2022). Review of Unsupervised Learning Techniques. *Lecture Notes in Electrical Engineering, 804 LNEE*. https://doi.org/10.1007/978-981-16-6324-6_59
- Yadav, S., & Shukla, S. (2016). Analysis of k-Fold Cross-Validation over Hold-Out Validation on Colossal Datasets for Quality Classification. *Proceedings - 6th International Advanced Computing Conference, IACC 2016*. <https://doi.org/10.1109/IACC.2016.25>
- Yan, Z., Zhang, X., Gao, L., Yuan, K., & Tang, Z. (2020). ConvMath: A convolutional sequence network for mathematical expression recognition. *Proceedings - International Conference on Pattern Recognition*. <https://doi.org/10.1109/ICPR48806.2021.9412913>

- Zhang, X., & Liu, C. A. (2023). Model averaging prediction by K-fold cross-validation. *Journal of Econometrics*, 235(1). <https://doi.org/10.1016/j.jeconom.2022.04.007>
- Zhang, X., Zhong, C., Zhang, J., Wang, T., & Ng, W. W. Y. (2023). Robust recurrent neural networks for time series forecasting. *Neurocomputing*, 526. <https://doi.org/10.1016/j.neucom.2023.01.037>
- Zhang, Y., & Wang, T. (2022). Applying Value-Based Deep Reinforcement Learning on KPI Time Series Anomaly Detection. *IEEE International Conference on Cloud Computing, CLOUD*, 2022-July. <https://doi.org/10.1109/CLOUD55607.2022.00039>

EKLER

EK-1

FITF veri kümesi için, katılımcılar için toplanan parmak fotoğrafı görüntülerine ilişkin ayrıntılı bilgiler dikkate alınmıştır. Tablo A.1, toplanan FITF veri kümesi görüntüleri için ayrıntılı bilgileri göstermektedir.

Tablo A.1. Toplanan FITF veri seti görüntüleri için ayrıntılı bilgiler

Kişisel İndeks	Yaş	Cinsiyet	Toplanan Parmak Fotoğrafi
			Sayısı (10 parmağın tamamı için)
1	28	F	100
2	19	F	100
3	40	M	100
4	33	F	100
5	22	F	100
6	24	M	100
7	27	F	100
8	16	F	100
9	17	F	100
10	33	F	100
11	21	F	100
12	23	M	100
13	33	M	100
14	45	M	100
15	54	M	100
16	57	M	100
17	35	M	100
18	35	F	100
19	24	F	100
20	42	M	100
21	73	M	100
22	36	F	100
23	18	M	100
24	25	M	100
25	20	F	100
26	16	F	100
27	18	M	100

28	45	M	100
29	27	F	100
30	21	F	100
31	39	M	100
32	24	F	100
33	52	M	100
34	37	F	100
35	19	M	100
36	29	M	100
37	20	F	100
38	44	M	100
39	29	F	100
40	41	F	100
41	31	M	100
42	23	M	100
43	20	M	100
44	40	M	100
45	37	M	100
46	36	F	100
47	55	M	100
48	68	M	100
49	50	M	100
50	48	M	100
51	75	M	100
52	38	M	100
53	40	M	100
54	29	M	100
55	25	M	100
56	16	M	100
57	74	F	100
58	70	M	100
59	30	M	100
60	23	F	100
61	20	M	100
62	30	F	100
63	53	F	100
64	20	M	100
65	27	M	100
66	18	F	100

67	21	M	100
68	17	M	100
69	40	M	100
70	45	F	100
71	30	F	100
72	25	F	100
73	56	M	100
74	35	M	100
75	38	F	100
76	28	F	100
77	22	M	100
78	30	M	100
79	43	F	100
80	28	F	100
81	18	F	100
82	51	F	100
83	55	F	100
84	25	M	100
85	17	M	100
86	26	F	100
87	44	M	100
88	19	M	100
89	19	M	100
90	25	F	100
91	16	M	100
92	30	M	100
93	32	M	100
94	20	M	100
95	17	M	100
96	20	F	100
97	16	F	100
98	18	M	100
99	16	F	100
100	21	M	100

ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Islam Nahedh Fadhil ALABDOO
Uyruğu:	Iraklı
Orcid Numarası:	0009-0006-7532-9013

Eğitim Bilgileri	
Lisans	
Üniversite	Al Musul Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Bilgisayar Mühendisliği Bölümü
Mezuniyet Yılı	2007
Yüksek Lisans	
Üniversite	Kırşehir Ahi Evran Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	İleri Teknoloji Anabilim Dalı
Programı	İleri Teknolojiler (Bilgisayar Mühendisliği)
Mezuniyet Tarihi	2024

Tezden Üretilen Makaleler ve Bildiriler
Alabdo ve Yalçinkaya, 2023. (10-12 Aralık 2023) Humans Verification by Adopting Deep Recurrent Fingerphotos Network, <i>International Conference on Computing and Data Analytics (ICCD)</i> , Ibri, Sultanate of Oman