

**T.C.**  
**GÜMÜŞHANE ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YAPAY ZEKA VE AKILLI SİSTEMLER ANABİLİM DALI**

**AVUÇ İZİ DOĞRULAMA İÇİN EN UYGUN İLGİ ALANI BÖLGESİNİN**  
**TESPİT EDİLMESİ**

**YÜKSEK LİSANS**

**Veysel Karani ÖZKAN**

**HAZİRAN-2024**  
**GÜMÜŞHANE**



**T.C.  
GÜMÜŞHANE ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YAPAY ZEKA VE AKILLI SİSTEMLER ANABİLİM DALI**

**AVUÇ İZİ DOĞRULAMA İÇİN EN UYGUN İLGİ ALANI BÖLGESİNİN  
TESPİT EDİLMESİ**

**DETECTION OF THE MOST SUITABLE ROI FOR PALMPRINT  
VERIFICATION**

**YÜKSEK LİSANS**

**Veysel Karani ÖZKAN**

**HAZİRAN-2024  
GÜMÜŞHANE**



**T.C.  
GÜMÜŞHANE ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**YAPAY ZEKA VE AKILLI SİSTEMLER ANABİLİM DALI**

**AVUÇ İZİ DOĞRULAMA İÇİN EN UYGUN İLGİ ALANI BÖLGESİNİN  
TESPİT EDİLMESİ**

**DETECTION OF THE MOST SUITABLE ROI FOR PALMPRINT  
VERIFICATION**

**YÜKSEK LİSANS**

**Veysel Karani ÖZKAN**

**Danışman: Dr. Öğr. Üyesi Özkan BİNGÖL**

**HAZİRAN-2024  
GÜMÜŞHANE**



## **BİLİMSEL ETİĞE UYGUNLUK BEYANI**

**Yüksek Lisans Tezi** olarak hazırlamış olduğum “**Avuç İzi Doğrulama İçin En Uygun İlgi Alanı Bölgesinin Tespit Edilmesi**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirttiğimi ve Gümüşhane Üniversitesi’nin lisanslı kullanıcısı olduğu intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü’nün belirlediği kısıtlara uygun olarak raporladığımı taahhüt ediyorum. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği’nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

**24/06/2024**

.....  
**Veysel Karani ÖZKAN**

## TEŞEKKÜR

“Avuç İzi Doğrulama İçin En Uygun İlgı Alanı Bölgesinin Tespit Edilmesi” adlı çalışmam süresince yapmış olduğum çalışmalarımı denetleyen, bilgi ve tecrübelerini benimle paylaşan tez danışmanım Dr. Öğr. Üyesi Özkan BİNGÖL’e teşekkür ederim.

Bu çalışma, TÜBİTAK 1001 - Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı tarafından desteklenen 122E402 nolu “Kısıtlamasız Ortamda Alınan El Görüntülerinden Biyometrik Doğrulama İçin Güvenilir Avuç İzi Bölgesinin Tespiti” isimli proje kapsamında gerçekleştirilmiştir. Bu desteklerinden dolayı TÜBİTAK’a teşekkürlerimi sunarım.

Tez çalışması boyunca beni maddi ve manevi olarak destekleyen aileme, dost vdadaşlarıma teşekkürlerimi bir borç bilirim.

**Veysel Karani ÖZKAN**  
**GÜMÜŞHANE – 2024**

## ÖZET

Bu çalışma, avuç içi biyometrik tanıma sistemlerinde ilgi alanı bölge seçiminin önemini ve performansa etkilerini derinlemesine incelemektedir. İlgin bölge seçimi, biyometrik verilerin doğruluğunu ve sistemin genel performansını belirleyen kritik bir faktördür ve biyometrik özelliklerin yoğun olduğu bölgelerin tespit edilmesi ve analiz edilmesini sağlamaktadır. Çalışmamızda, bölütlenmiş edilmiş el görüntülerinde parmak arası noktalar referans alınarak kare şeklinde ilgin alanları oluşturulmuştur. Bölütleme işlemi, avuç içi bölgesinin arka plandan ayrılması ve parmak arası noktaların belirlenmesini içermektedir. Bölütleme sonrası belirlenen parmak arası noktalar referans alınarak, bu merkez noktası etrafında kare şeklinde ilgin alanı tanımlanmıştır.

Bölgesel büyüklük farkları, bölütlenmiş el görüntülerinde ortaya çıkan farklı boyutlardaki ilgin alanların ortaya çıkmasına neden olmaktadır. Parmakların açık veya kapalı olması, elin açısı ve pozisyonu gibi değişkenler, ilgin alanının büyüklüğünde ve şeklinde farklılıklara neden olabilir. Bu çalışmada, farklı büyüklüklerde ve şekillerdeki ilgin alanlarının kimliklendirmedeki doğruluk oranları üzerindeki etkileri deneysel olarak analiz edilmiştir.

Elde edilen sonuçlar, farklı büyüklüklerdeki ilgin alanlarının biyometrik tanıma performansına olan etkilerini göstermektedir. Doğru bölge seçimi, biyometrik doğrulama sistemlerinin doğruluk oranlarını ve işlem hızını önemli ölçüde artırmaktadır. Elin pozisyonu gibi değişkenlerin avuç içi tanımaya olan etkileri de detaylı bir şekilde analiz edilmeye çalışılmıştır. Bu bulguların, biyometrik sistemlerin geliştirilmesine ve daha güvenilir doğrulama süreçlerinin oluşturulmasına katkı sunması beklenmektedir.

**Anahtar Kelimeler:** Avuçiçi biyometrik doğrulama, El bölütleme, Derin sinir ağları, İlgi alanı bölge seçimi.

## SUMMARY

This paper provides an in-depth study of the importance of region of interest selection in palm biometric recognition systems and its impact on performance. Region of interest selection is a critical factor that determines the accuracy of biometric data and the overall performance of the system, and it enables the detection and analysis of regions where biometric features are concentrated. In our study, square regions of interest are created in the segmented hand images with reference to the inter-finger points. The segmentation process involves separating the palm region from the background and identifying the inter-finger points. After segmentation, a square region of interest is defined around this center point with reference to the identified inter-finger points.

Regional size differences result in different sized regions of interest appearing in the segmented hand images. Variables such as whether the fingers are open or closed, the angle and position of the hand can cause differences in the size and shape of the region of interest. In this study, we experimentally analyzed the effects of different sized and shaped regions of interest on the accuracy of identification.

The results obtained show the effects of different sizes of interest areas on biometric recognition performance. Correct region selection significantly improves the accuracy and processing speed of biometric verification systems. The effects of variables such as hand position on palm recognition have also been analyzed in detail. These findings are expected to contribute to the development of biometric systems and the creation of more reliable verification processes.

**Keywords:** Palmprint biometric verification, Hand segmentation, Deep neural networks, Region of interest selection.

## İÇİNDEKİLER

|                                                                       |      |
|-----------------------------------------------------------------------|------|
| KABUL VE ONAY .....                                                   | III  |
| BİLİMSEL ETİĞE UYGUNLUK BEYANI.....                                   | IV   |
| TEŞEKKÜR.....                                                         | V    |
| ÖZET.....                                                             | VI   |
| SUMMARY .....                                                         | VII  |
| İÇİNDEKİLER .....                                                     | VIII |
| TABLolar DİZİNİ .....                                                 | X    |
| ŞEKİLLER DİZİNİ.....                                                  | XI   |
| SİMGELER VE KISALTMALAR DİZİNİ .....                                  | XII  |
| 1. GENEL BİLGİLER.....                                                | 1    |
| 1.1. Biyometrik Tanıma Sistemleri.....                                | 1    |
| 1.2. Avuç İzi Tanıma Sistemleri.....                                  | 2    |
| 1.3. ROI Seçimi ve Önemi.....                                         | 3    |
| 1.4. Tezin Amacı ve Kapsamı.....                                      | 4    |
| 1.5. ROI Seçiminin Temel İlkeleri .....                               | 6    |
| 1.6. Otomatik ROI Seçimi .....                                        | 6    |
| 1.7. Görüntü İşleme Teknikleri ve Algoritmalar .....                  | 8    |
| 2. MATERYAL VE METOT .....                                            | 13   |
| 2.1. ROI Çıkarma Yaklaşımları .....                                   | 14   |
| 2.2. Önerilen Yöntem .....                                            | 18   |
| 2.3. Aday Alt Bölgelerin Seçimi .....                                 | 19   |
| 2.4. Doğrulama Ağ Modeli.....                                         | 19   |
| 2.5. Ağ Kaybı ve Benzerlik Mesafesi.....                              | 20   |
| 2.6. Eğitim Verisi Seçimi.....                                        | 21   |
| 2.7. Dağınık Şablonların Eşleştirilmesi .....                         | 22   |
| 2.8. Eşleşme Skoru .....                                              | 23   |
| 2.9. Veri artırma.....                                                | 23   |
| 2.10. Görüntü Normalleştirme .....                                    | 23   |
| 3. YAPILAN ÇALIŞMALAR VE BULGULAR.....                                | 25   |
| 3.1. IITD Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar .....       | 25   |
| 3.2. PolyU-IITD Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar ..... | 28   |
| 3.3. CASIA Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar .....      | 30   |

|                                                                |    |
|----------------------------------------------------------------|----|
| 3.4. MPD Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar ..... | 32 |
| 4. SONUÇLAR VE TARTIŞMA .....                                  | 35 |
| 4.1. Hesaplama Açısından Verimli Özellik Çıkarma .....         | 35 |
| 4.2. Hesaplama Karmaşıklığı Üzerine Analiz .....               | 36 |
| 4.3. Derin Ağ Modellerinin Özellik Çıkarma Analizleri.....     | 37 |
| 4.4. Başarısız Örnek Durumları .....                           | 40 |
| 5. ÖNERİLER.....                                               | 42 |
| KAYNAKÇA.....                                                  | 44 |
| ÖZGEÇMİŞ .....                                                 | 50 |



## TABLÖLAR DİZİNİ

|                                                                                                        |    |
|--------------------------------------------------------------------------------------------------------|----|
| Tablo 1. IITD veri tabanından elde edilen EER ve doğruluk değerleri .....                              | 26 |
| Tablo 2. IITD veri tabanından hepsi bir arada protokolü ile elde edilen EER ve doğruluk oranları ..... | 28 |
| Tablo 3. PolyU-IITD veri tabanından elde edilen EER ve doğruluk oranları .....                         | 29 |
| Tablo 4. CASIA avuç içi veri tabanından elde edilen EER ve doğruluk oranları .....                     | 31 |
| Tablo 5. MPD veritabanından elde edilen EER ve doğruluk değerleri.....                                 | 33 |
| Tablo 6. IITD veri setinde ortalama özellik çıkarma ve eşleştirme süreleri .....                       | 36 |
| Tablo 7. Farklı derin öğrenme modellerinden elde edilen EER ve doğruluk değerleri ..                   | 39 |

## ŞEKİLLER DİZİNİ

|                                                                                                  |    |
|--------------------------------------------------------------------------------------------------|----|
| Şekil 1. Farklı ROI çıkarma yaklaşımları .....                                                   | 15 |
| Şekil 2. ROI çıkarmada yeni yaklaşımları .....                                                   | 16 |
| Şekil 3. Kullanılan ESA yapısı .....                                                             | 20 |
| Şekil 4. Eğitim görüntüsü oluşturma .....                                                        | 22 |
| Şekil 5. IITD veri tabanı üzerinde uygulanan yöntemler için ROC ve CMC eğrileri. .               | 26 |
| Şekil 7. IITD veri tabanından hepsi bir arada protokolü ile elde edilen ROC ve CMC eğrileri..... | 27 |
| Şekil 6. PolyU-IITD veritabanında farklı yöntemlerle edilen ROC ve CMC eğrileri..                | 29 |
| Şekil 7. CASIA avuç içi veri tabanında farklı yöntemlerden elde edilen ROC ve CMC eğrileri.....  | 30 |
| Şekil 8. MPD veritabanından elde edilen ROC ve CMC eğrileri.....                                 | 33 |
| Şekil 9. Farklı alt bölgelerden üretilen özellik vektörünün gösterimi .....                      | 35 |
| Şekil 11. Farklı derin öğrenme modellerinden elde edilen ROC ve CMC eğrisi .....                 | 38 |
| Şekil 12. IITD veri tabanlarındaki başarısızlık durumları (Yulin ve Kumar, 2023) .....           | 41 |

## SİMGELER VE KISALTMALAR DİZİNİ

|           |                                                                    |
|-----------|--------------------------------------------------------------------|
| AGM       | : Aktif Görünüm Modeli                                             |
| AŞM       | : Aktif Şekil Modeli                                               |
| CMC       | : Kümülatif Eşleşme Eğrisi (Cumulative Match Curve)                |
| DDR       | : Derin Ayrımcı Temsil (Deep Discriminative Representation)        |
| DVM       | : Destek Vektör Makinesi                                           |
| EER       | : Eşit Hata Oranı (Equal Error Rate)                               |
| ESA       | : Evrimsel Sinir Ağları                                            |
| FAR       | : Yanlış Kabul Oranı (False Acceptance Rate)                       |
| FERnet    | : Özellik Çıkarma ve Tanıma Ağı                                    |
| GAR       | : Gerçek Kabul Oranı (Genuine Accept Rate)                         |
| YGH       | : Yönlendirilmiş Gradyanların Histogramı                           |
| OAT       | : Optik Akış Tabanlı                                               |
| ROC       | : Alıcı İşletim Karakteristiği (Receiver Operating Characteristic) |
| ROI       | : İlgi Alanı Bölgesi (Region of Interest)                          |
| ROI-Lanet | : ROI Yerelleştirme ve Hizalama Ağı                                |
| TBA       | : Temel Bileşenler Analizi                                         |
| YGH       | : Yönlendirilmiş Gradyan Histogramı                                |

## 1. GENEL BİLGİLER

### 1.1. Biyometrik Tanıma Sistemleri

Güvenlik ve kimlik doğrulama konuları, modern toplumlarda giderek daha fazla önem kazanmaktadır. Bilgi güvenliği, fiziksel erişim kontrolü ve kimlik doğrulama gereksinimleri, bireylerin ve kurumların güvenlik önlemlerini artırmalarını gerektirmektedir. Bu bağlamda biyometrik doğrulama sistemleri, kimlik doğrulama süreçlerinde önemli bir çözüm sunmaktadır. Parmak izi, yüz tanıma, iris tarama ve avuç içi tanıma gibi biyometrik yöntemler, güvenlik teknolojilerinde devrim yaratmış ve çeşitli uygulama alanlarında yaygın olarak kullanılmaya başlanmıştır (Jain vd., 2004).

Biyometrik doğrulama sistemleri, bireylerin kimliklerini belirlemek ve doğrulamak için benzersiz biyometrik özelliklerden yararlanırlar. Bu özellikler, genetik olarak belirlenen ve zamanla değişmeyen fiziksel ve davranışsal karakteristiklerdir. Parmak izi, yüz şekli, retina ve iris desenleri gibi fiziksel biyometrik özellikler, kimlik doğrulamada yüksek doğruluk oranları sunmaktadırlar. Ayrıca, imza, yürüyüş şekli ve ses tanıma gibi davranışsal biyometrik özellikler de kimlik doğrulama süreçlerinde kullanılmaktadır (Maltoni vd., 2009).

Biyometrik doğrulama sistemleri, çeşitli sektörlerde geniş bir kullanım alanına sahiptir. Bankacılık, sağlık hizmetleri, havaalanları, devlet kurumları ve eğitim sektörü gibi alanlarda biyometrik sistemler, kimlik doğrulama ve erişim kontrolü için yaygın olarak kullanılmaktadır. Örneğin, bankacılık sektöründe parmak izi tanıma sistemleri, müşteri kimlik doğrulama süreçlerini hızlandırmak ve güvenliğini artırmak için kullanılmaktadır. Benzer şekilde, sağlık hizmetlerinde avuç içi tanıma sistemleri, hasta kimlik doğrulama ve erişim kontrolü için etkili bir çözüm sunmaktadır (Şeker vd., 2013).

Yüz tanıma sistemleri, bireylerin yüzlerindeki karakteristik özellikleri kullanarak kimlik doğrulaması gerçekleştirirler. Bu sistemler, yüz şekli, gözler, burun ve ağız gibi yüz bileşenlerinin geometrik ve ilişki özelliklerini analiz ederler. Yüz tanıma teknolojisi, özellikle kameralı güvenlik sistemlerinde ve mobil cihazlarda yaygın olarak kullanılmaktadır. Bu sistemlerin doğruluğu, görüntü kalitesine ve çevresel faktörlere bağlı olarak değişebilmektedir (Zhao vd., 2003).

İris ve retina tarama sistemleri, gözün iç yapılarındaki benzersiz desenleri kullanarak kimlik doğrulama yaparlar. İris tarama, gözün renkli kısmındaki desenleri analiz ederken, retina tarama, gözün arka kısmındaki damar yapısını inceler. Bu yöntemler, yüksek doğruluk oranlarına sahip olmaları nedeniyle güvenlik

uygulamalarında sıklıkla tercih edilir. Ancak, bu sistemlerin kullanımı genellikle daha pahalı ve karmaşıktır (Daugman, 2004).

Parmak izi tanıma, biyometrik doğrulama sistemlerinin en eski ve en yaygın kullanılan yöntemlerinden biridir. Parmak izleri, her birey için benzersiz olan ince deri sırtları ve vadilerinden oluşur. Bu benzersizlik, parmak izi tanıma sistemlerini son derece güvenilir kılmaktadır. Parmak izi tanıma sistemleri, genellikle parmak izlerini yüksek çözünürlüklü tarayıcılarla yakalar ve bu verileri dijital olarak karşılaştırırlar (Jain vd., 1999).

Avuç izi tanıma sistemleri, avuç içindeki damar desenleri ve kırışıklıklar gibi benzersiz özellikleri kullanarak kimlik doğrulama yapar. Bu sistemler, temassız veya düşük temaslı olmaları nedeniyle hijyenik bir çözüm sunarlar ve çeşitli güvenlik seviyelerine daha uygundur. Avuç içi biyometrik sistemleri, yüksek doğruluk oranları ve sahteciliğe karşı dayanıklılık gibi avantajlarıyla dikkat çekmektedir. Ayrıca, avuç içi yüzeyindeki geniş biyometrik bilgi alanı, doğrulama işlemlerinin yüksek doğrulukla gerçekleştirilmesine olanak tanımaktadır (Kumar ve Zhang, 2006).

Çoklu biyometrik sistemler, birden fazla biyometrik doğrulama yönteminin entegrasyonu ile oluşturulan sistemlerdir. Bu sistemler, doğrulama süreçlerinin güvenliğini ve doğruluğunu artırmak amacıyla geliştirilmiştir. Örneğin, parmak izi tanıma ve yüz tanıma sistemlerinin bir arada kullanılması, sahteciliğe karşı daha dayanıklı ve yüksek doğruluk oranlarına sahip bir doğrulama süreci sağlar. Çoklu biyometrik sistemler, farklı biyometrik özelliklerin birlikte analiz edilmesiyle daha güvenilir kimlik doğrulama sonuçları sunmaktadır (Ross ve Jain, 2004).

## **1.2. Avuç İzi Tanıma Sistemleri**

Avuç izi biyometrik tanıma sistemleri, güvenlik ve kimlik doğrulama teknolojilerinde önemli bir rol oynayan ve giderek daha fazla popülerlik kazanan bir yöntemdir. Bu sistemler, avuç içi yüzeyindeki benzersiz biyometrik özellikleri, özellikle damar desenleri, kırışıklıklar ve avuç içi geometrisini kullanarak bireylerin kimliklerini doğrulamaktadırlar. Avuç izi biyometrik sistemleri, yüksek doğruluk oranları, sahteciliğe karşı dayanıklılık ve kullanıcı dostu olmaları nedeniyle geniş bir uygulama yelpazesinde kullanılmaktadır (Jain vd., 2004).

Avuç izi biyometrik tanıma sistemlerinin temel özelliklerinden biri, avuç içerisindeki parmak izine benzer çizgilerin benzersiz ve karmaşık yapısıdır. Çizgi desenleri, her birey için farklıdır ve bu desenlerin bir çoğu düşük çözünürlüklü kameralarla bile görünebilir. Bu nedenle, avuç içi biyometrik sistemleri, diğer biyometrik

yöntemlere göre daha güvenlidir. Ayrıca, avuç içi tanıma işlemi temassız veya düşük temaslı olarak gerçekleştirildiğinden, hijyenik bir çözüm sunmakta ve kullanıcılar için rahat bir deneyim sağlamaktadır (Zhang vd., 2003; Kumar ve Zhang, 2006).

Avuç izi biyometrik tanıma sistemleri, genellikle bir görüntüleme cihazı ve yazılım bileşenlerinden oluşur. Görüntüleme cihazı, avuç içi yüzeyinin yüksek çözünürlüklü görüntülerini yakalar ve bu görüntülerdeki kırıksıklık ve çizgileri ortaya çıkarır. Yazılım bileşenleri ise bu görüntüleri analiz ederek bireyin kimliğini doğrular. Görüntü işleme ve desen tanıma algoritmaları kullanılarak gerçekleştirilen bu süreç, doğrulama işlemlerinin yüksek doğrulukla gerçekleştirilmesini sağlar (Wang ver ark., 2011).

Avuç izi biyometrik sistemleri üzerine yapılan çalışmalar, bu teknolojinin doğruluğunu artırmak ve çeşitli zorlukların üstesinden gelmek için çeşitli yöntemler ve algoritmalar önermektedir. Zhang vd. (2003), avuç içi damar desenlerini çıkarma ve tanıma üzerine yaptıkları çalışmada, düşük frekanslı bir filtreleme tekniği kullanarak damar desenlerini daha belirgin hale getirmiştir. Bu yöntem, damar desenlerinin yüksek doğrulukla tespit edilmesini sağlamıştır. Kumar vd. (2009) ise ikili desen tanıma algoritmalarının, avuç içi damar desenlerini yüksek doğruluk oranlarıyla tanıyabildiğini ve sahteciliğe karşı dayanıklı olduğunu göstermiştir.

Avuç içi biyometrik sistemleri, çeşitli sektörlerde geniş bir kullanım alanına sahip olmaya başlamıştır. Bankacılık, sağlık hizmetleri, havaalanları, devlet kurumları ve eğitim sektörü gibi alanlarda avuç içi biyometrik sistemler, kimlik doğrulama ve erişim kontrolü için yaygın olarak kullanılmaktadır. Örneğin, bankacılık sektöründe avuç içi biyometrik sistemler, müşteri kimlik doğrulama süreçlerini hızlandırmak ve güvenliği artırmak için kullanılmaktadır (Şeker vd., 2013). Benzer şekilde, sağlık hizmetlerinde bu sistemler, hasta kimlik doğrulama ve erişim kontrolü için etkili bir çözüm sunmaktadır.

### **1.3. ROI Seçimi ve Önemi**

Avuç içi biyometrik tanıma sistemlerinde İlgi Alanı Bölgesi (Region of Interest - ROI) seçimi, sistemin performansını ve doğruluğunu belirleyen kritik bir faktördür. Avuç izi biyometrik tanıma sistemlerinde doğru ROI seçimi, sistem performansını belirleyen kritik bir unsurdur. ROI, biyometrik özelliklerin yoğunlaştığı ve analiz için en uygun bölgeyi ifade etmektedir. Wang vd. (2011), otomatik ROI seçim yöntemlerini geliştirmiş ve bu yöntemlerin doğrulama performansını artırdığını göstermişlerdir. Otomatik ROI seçim yöntemleri, manuel yöntemlere kıyasla daha hızlı ve tutarlı sonuçlar vermektedir.

ROI seçimi, avuç içi biyometrik sistemlerinin temel bir bileşenidir ve doğru seçim yapılmadığında sistemin doğruluk oranları düşebilir ve işlem süreleri uzayabilir. Avuç

içindeki çizgiler, kırışıklıklar ve diğer benzersiz özelliklerin en yoğun ve belirgin olduğu bölgelerin belirlenmesi, ROI seçiminde kritik öneme sahiptir (Kumar ve Zhang, 2006). Yanlış ROI seçimi, biyometrik doğrulama süreçlerinde hatalara ve güvenlik açıklarına neden olabilmektedir.

Görüntü işleme teknikleri ve desen tanıma algoritmaları, ROI seçiminde önemli rol oynamaktadır. Zhang vd. (2003), avuç içi desenlerini çıkarma ve tanıma üzerine yaptıkları çalışmada, düşük frekanslı bir filtreleme tekniği kullanarak çizgileri daha belirgin hale getirmiştir. Bu yöntem, çizgi desenlerinin yüksek doğrulukla tespit edilmesini sağlamıştır. Kumar vd. (2009) ise ikili desen tanıma algoritmalarının, avuç içi damar desenlerini yüksek doğruluk oranlarıyla tanıyabildiğini ve sahteciliğe karşı dayanıklı olduğunu göstermişlerdir.

Otomatik ROI seçim yöntemleri, manuel yöntemlere kıyasla daha hızlı ve tutarlı sonuçlar sunmaktadırlar. Wang vd. (2011), avuç içi görüntülerinde otomatik ROI seçim yöntemlerini geliştirmiş ve bu yöntemlerin doğrulama performansını artırdığını göstermişlerdir. Bu çalışmada, otomatik ROI seçim yöntemlerinin biyometrik verilerin daha doğru ve hızlı işlenmesini sağladığı belirlenmiştir. Otomatik yöntemler, özellikle büyük veri setlerinde ve gerçek zamanlı uygulamalarda önemli avantajlar sunmaktadır.

Doğru ROI seçimi, biyometrik doğrulama sistemlerinin doğruluk oranlarını önemli ölçüde artırmaktadır. Ross ve Jain (2004), çoklu biyometrik sistemler üzerine yaptıkları çalışmada, doğru ROI seçimlerinin biyometrik özelliklerin daha iyi analiz edilmesine olanak tanıdığını ve dolayısıyla doğrulama sürecinin daha doğru olmasına katkı sağladığını göstermişlerdir. Ayrıca, doğru ROI seçimleri işlem süresini kısaltarak sistemin genel verimliliğini artırmaktadır.

#### **1.4. Tezin Amacı ve Kapsamı**

Bu tez çalışmasının merkezinde, avuç içi doğrulama sistemlerinde en uygun ROI'lerin belirlenmesi ve bu seçimlerin doğrulama performansı üzerindeki etkilerinin incelenmesi yer almaktadır. Avuç içi görüntülerinde doğru ROI'lerin seçilmesi, biyometrik verilerin daha doğru ve hızlı işlenmesine olanak tanımaktadır. Ancak, bu süreç karmaşıktır ve çeşitli zorluklar içermektedir. Avuç içi yüzeyinde farklı bölgelerde yoğunlaşan biyometrik özellikler, farklı ışık koşulları ve avuç içinin çeşitli açılardan çekilmiş görüntüleri gibi faktörler, doğru ROI seçimlerini zorlaştırmaktadır.

Bu çalışma, avuç içi doğrulama sistemlerinde kullanılan mevcut ROI seçim yöntemlerinin yetersizliklerini ve bu yöntemlerin iyileştirilmesi gerekliliğini ele almaktadır. Mevcut literatürde, avuç içi biyometrisi üzerine yapılan çalışmaların çoğu,

genel doğrulama algoritmalarına odaklanmış olup, ROI seçimi konusundaki çalışmalar sınırlıdır. ROI seçiminin doğrulama sürecine etkileri yeterince incelenmemiştir ve bu alanda sistematik bir yaklaşım eksikliği bulunmaktadır.

Bu bağlamda, araştırma probleminin tanımı şu şekilde özetlenebilir: Avuç izi doğrulama sistemlerinde en uygun ROI'lerin belirlenmesi ve bu seçimlerin doğrulama performansı üzerindeki etkilerinin incelenmesi. Bu problemin çözümü, avuç izi biyometrik sistemlerinin genel performansını ve kullanıcı memnuniyetini artırmak için kritik öneme sahiptir. Özellikle, yüksek güvenlik gerektiren uygulamalarda, doğru ROI seçimleri, sistemin sahteciliğe karşı dayanıklılığını ve doğruluk oranını artırarak, biyometrik doğrulama süreçlerinin daha güvenilir ve verimli olmasını sağlayacaktır.

Çalışma kapsamında farklı ROI seçim yöntemlerinin karşılaştırmalı analizi yapılarak, en uygun yöntemleri belirlenmesi ve bu yöntemlerin doğrulama performansına olan etkilerini değerlendirilmesi amaçlanmaktadır. Bu kapsamda, çeşitli görüntü işleme teknikleri ve makine öğrenmesi algoritmaları kullanılmıştır. Ayrıca, deneysel sonuçlar ve istatistiksel analizler ile elde edilen bulgular, literatürdeki mevcut çalışmalarla karşılaştırılması ve bu alanda yeni katkılar sunulması hedeflenmiştir.

Sonuç olarak, bu tez çalışması, avuç içi doğrulama sistemlerinde en uygun ROI'lerin seçimi üzerine odaklanarak, biyometrik doğrulama teknolojilerinin geliştirilmesine yönelik önemli bir adım atmaya odaklanmaktadır. Bu araştırma, hem akademik literatüre hem de pratik uygulamalara değerli bilgiler sunarak, güvenlik ve doğrulama sistemlerinin gelecekteki gelişimine katkıda bulunmayı amaçlamaktadır.

Bu çalışmada, aşağıdaki hipotezlerin test edilmesi planlanmıştır:

- **H1:** En uygun ROI seçimi, avuç içi doğrulama sistemlerinin doğruluk oranını önemli ölçüde artırır.

Bu hipotez, doğru ROI seçimlerinin biyometrik özelliklerin daha iyi analiz edilmesine ve dolayısıyla doğrulama sürecinin daha doğru olmasına katkı sağlayacağını öne sürmektedir.

- **H2:** Farklı ROI seçme yöntemleri arasında doğruluk ve verimlilik açısından istatistiksel olarak anlamlı farklar bulunmaktadır.

Bu hipotez, çeşitli ROI seçim tekniklerinin performanslarının karşılaştırılmasında önemli farklılıklar olduğunu ve bazı yöntemlerin diğerlerinden üstün olabileceğini varsaymaktadır.

- **H3:** En uygun ROI seçim yöntemi, işlem süresini kısaltarak sistemin genel verimliliğini artırır.

Bu hipotez, doğru ROI seçiminin sadece doğruluk oranını değil, aynı zamanda işlem süresini de olumlu yönde etkileyeceğini öngörmektedir.

### **1.5. ROI Seçiminin Temel İlkeleri**

ROI seçiminin temel ilkeleri, biyometrik özelliklerin en yoğun olduğu bölgelerin belirlenmesini ve bu bölgelerin sistematik bir şekilde analiz edilmesini içerir. Bu ilkeler, çeşitli görüntü işleme teknikleri ve desen tanıma algoritmaları kullanılarak uygulanır. Zhang vd (2003), avuç içi damar desenlerini çıkarma ve tanıma üzerine yaptıkları çalışmada, düşük frekanslı bir filtreleme tekniği kullanarak damar desenlerini daha belirgin hale getirmişlerdir. Bu yöntem, biyometrik özelliklerin tespit edilmesinde yüksek doğruluk sağlamıştır. Kumar vd. (2009), ikili desen tanıma algoritmalarının, avuç içi damar desenlerini yüksek doğruluk oranlarıyla tanıyabildiğini ve sahteciliğe karşı dayanıklı olduğunu göstermiştir.

ROI seçimi, genellikle manuel veya otomatik yöntemlerle gerçekleştirilir. Manuel yöntemler, uzmanların avuç içi görüntülerini inceleyerek en uygun bölgeleri belirlenmesini gerektirir. Bu yöntem, yüksek doğruluk sağlayabilir ancak zaman alıcı ve subjektif olabilmektedir. Otomatik yöntemler ise, görüntü işleme algoritmaları kullanarak ROI'yi belirler ve genellikle daha hızlı ve tutarlı sonuçlar sunar (Wang vd., 2011). Wang vd. (2011) otomatik ROI seçim yöntemlerinin doğrulama performansını artırdığını göstermişlerdir. Bu çalışmada, otomatik yöntemlerin, biyometrik verilerin daha doğru ve hızlı işlenmesini sağladığı belirlenmiştir.

Doğru ROI seçiminin biyometrik doğrulama üzerindeki etkisi, doğruluk oranları ve işlem süreleri açısından da kritiktir. Ross ve Jain (2004), çoklu biyometrik sistemler üzerine yaptıkları çalışmada, doğru ROI seçimlerinin biyometrik özelliklerin daha iyi analiz edilmesine olanak tanıdığını ve dolayısıyla doğrulama sürecinin daha doğru olmasına katkı sağladığını belirtmiştir. Ayrıca, doğru ROI seçimleri işlem süresini kısaltarak sistemin genel verimliliğini artırdığı gösterilmiştir.

### **1.6. Otomatik ROI Seçimi**

Otomatik ROI seçimi, genellikle avuç içi görüntüsünün ön işlenmesi ile başlar. Bu aşamada, görüntü gürültüsünün azaltılması ve kontrastın artırılması gibi adımlar gerçekleştirilir. En sık kullanılan ön işleme teknikleri arasında histogram eşitleme, Gauss bulanıklığı ve kenar tespiti bulunmaktadır (Jain ve Feng, 2011). Bu işlemler, ROI seçiminin daha hassas ve doğru yapılmasına olanak sağlamaktadır.

Kenar algılama, ROI seçiminde önemli bir adımdır. Bu teknik, avuç içindeki hatların ve çizgilerin belirginleştirilmektedir. Canny ve Sobel gibi yaygın kenar algılama algoritmaları, avuç izindeki belirgin hatları tespit etmek için kullanılır. Kenar algılama, avuç içindeki belirli bölgelerin (örneğin parmak arası boşluklar) daha kolay tanımlanmasını sağlamaktadır (Zhang ve Yan, 2006).

Geometrik dönüşüm ve normalizasyon teknikleri, avuç izinin boyut ve pozisyon açısından standart bir forma getirilmesi için kullanılmaktadır. Bu yöntemler, ROI'nin her avuç izi için tutarlı bir şekilde seçilmesini sağlamaktadır. Genellikle, avuç izinin merkezi referans alınarak döndürme ve ölçeklendirme işlemleri yapılmaktadır (Kim vd., 2009).

Öznitelik tabanlı yaklaşımlar, avuç izindeki belirli özniteliklerin (örneğin çizgiler, girinti ve çıkıntılar) tespit edilmesine dayanır. Bu yöntemler, önceden tanımlanmış özniteliklerin avuç içi üzerinde bulunması ile ROI seçimini gerçekleştirirler. Yapay zeka ve makine öğrenimi algoritmaları, bu özniteliklerin otomatik olarak tanımlanmasını sağlamaktadır (Wang ve Li, 2012).

Son yıllarda, derin öğrenme teknikleri avuç izi doğrulama sistemlerinde de kullanılmaya başlanmıştır. Özellikle Evrişimsel Sinir Ağları (ESA), avuç içindeki karmaşık desenlerin tespit edilmesinde etkilidir. ESA tabanlı yöntemler, geniş veri kümeleri üzerinde eğitilerek ROI'nin otomatik ve doğru bir şekilde seçilmesini sağlar (Liang vd., 2017).

Bölütleme teknikleri, avuç izini farklı bölgelere ayırarak ROI seçimini yaparlar. Bu yöntemler, genellikle gri seviye eşikleme veya k-ortalama algoritmaları kullanılarak gerçekleştirilir. Bölütleme, avuç içindeki belirli alanların (örneğin merkez bölge) daha kolay tanımlanmasına olanak sağlar (Kumar ve Zhang, 2010).

Bazı sistemler, birden fazla yöntemi birleştirerek daha yüksek doğrulukta ROI seçimi yapar. Örneğin, kenar algılama ve öznitelik tabanlı yaklaşımlar birlikte kullanılarak hem hatların hem de belirli özniteliklerin tespit edilmesi sağlanır. Bu tür karma yöntemler, daha karmaşık avuç izi desenlerinin tanınmasında etkilidir (Sun vd., 2013).

Optik Akış Tabanlı (OAT) yöntemler, avuç içindeki hareketi ve desen değişikliklerini analiz eder. Bu yöntemler, özellikle dinamik avuç izi doğrulama sistemlerinde kullanılır. OAT yöntemler, avuç içindeki hareketli bölgelerin tespit edilmesini ve bu bölgelerin ROI olarak seçilmesini sağlar (Xu vd., 2015).

Statik ROI seçimi, avuç izinin belirli sabit bölgelerinin tanımlanmasına dayanmaktadır. Dinamik ROI seçimi ise, avuç izinin gerçek zamanlı analiz edilerek

değişken bölgelerin tespit edilmesini içermektedir. Dinamik yöntemler, daha esnek ve adaptif bir yaklaşım sunmaktadırlar (Gao ve Wang, 2016).

### 1.7. Görüntü İşleme Teknikleri ve Algoritmalar

En yaygın kullanılan ROI tespit yöntemi Zhang vd. (2003) tarafından önerilmiştir. Ana fikir, ilk olarak parmak vadilerinin ana noktalarını tespit etmek ve ardından tespit edilen ana noktalara dayalı olarak yerel bir koordinat sistemi kurmaktır. Böylece, avuç içi yönü ve konumuna göre ROI koordinatları belirlenmektedir. Mevcut ROI yerleştirme yöntemlerinin çoğu bu stratejiye dayanmaktadır (Franzgrote vd. 2011, Chai vd. 2017, Bingöl ve Ekinci, 2017, Liang vd. 2019, Genovese vd. 2019, Leng vd. 2014).

ROI yerleştirmenin ana sorunu işaret noktalarının tespitidir. İşaret noktalarını yerleştirmenin iki yaklaşımı vardır: İlki, önce avuç içi bölgesini bölütleyip ardından tespit edilen kenarlara dayalı olarak dijital görüntü işleme tekniklerini kullanarak işaret noktalarını aramaktır. Diğeri ise, hem el şekli hem de doku bilgilerini kullanarak doğrudan işaret noktalarını belirlemektir.

İlk yaklaşımın önemli bir amacı arka planı sadeleştirmektir. Bunun için de üç farklı yöntem kullanılmaktadır:

- Tek renkli bir arka plan tahtası kullanarak avuç içini yakalamak (Zhang vd. 2003, Sun vd. 2005, Kumar, 2008, Zhang vd. 2017, Jia vd. 2012).
- Avuç içi bölütlemeyi desteklemek için bir Kızılötesi (Infrared – IR) kamera veya derinlik kamerası kullanmak (Han vd. 2007, Hao vd. 2008, Liang vd. 2019, Michael vd. 2008).
- Güçlü bir ışık kaynağı yoğunluğu ve kısa bir pozlama süresi ayarlayarak ön planın kontrastını artırmak. Bu yöntemlerin hedefi, avuç içi bölgesi ile arka planın kontrastını artırmaktır. Örneğin, Chai vd. (2016) çalışmalarında, avuç içi bölütlemesi için cep telefonunun yerleşik LED flaşı kullanılmaktadır. Flaş açıldığında, avuç içi yüzeyi arka plana göre çok daha parlaktır, çünkü avuç içi kamera lensine arka plandan çok daha yakındır. Kamera çipindeki görüntü sinyali işlemcisinin yerleşik otomatik pozlama kontrol işlevi, uygun avuç içi görüntülerini yakalamak için otomatik olarak pozlama süresini azaltacaktır; bu durumda, avuç içi bölgesi uygun gri tonlama aralığına düşmelidir. Sonuç olarak, yakalanan arka plan çok karanlık olacaktır.

Donanım ve görüntüleme modu optimizasyonundan sonra, avuç içi bölgesi deri rengi eşikleme veya Otsu tabanlı yöntemlerle bölütlenebilir (Otsu, 1979; Rother vd. 2004). Maksimum bağlantılı bölge tespiti, arka plan gürültüsünü silmek için faydalıdır.

Avuç içi bölge görüntüsü elde edildikten sonra, vadi noktalarını tespit etmek için de dört yaklaşım bulunmaktadır:

- Rekabetçi vadi tespit algoritması, her kontur pikselini komşu piksellerin gri tonlama değerlerini test ederek ve karşılaştırarak tarar (Michael vd. 2007). Avuç içi bölütlemesinden sonra, ikili bir avuç içi görüntüsü elde edilir. Avuç içi konturundaki pikseller test edilir, mevcut kontur pikseli merkez noktası olarak alınır ve etrafına sırasıyla 4, 8 ve 16 test noktası yerleştirilir. Üç testte de piksellerin değerleri önceden tanımlanmış koşulları karşılıyorsa, merkez noktadan el dışı bölgeye doğru bir çizgi çizilir. Bu çizgi herhangi bir el bölgesini geçmezse, bu merkez piksel bir vadi noktası olarak kabul edilir. Aynı şekilde, diğer aday vadi noktaları da bulunabilir.

- Çizgi tarama tabanlı yöntemler: Döndürme normalizasyonundan sonra, pikseller belirli el yönüne göre bir sıra veya sütun boyunca test edilir. Bölütlenmiş el görüntüsünde, el bölgesi pikselleri beyaz, arka plan pikselleri ise sıfır olarak ayarlanır. Piksel değeri beyazdan siyaha veya siyahtan beyaza değiştiğinde, parmak konturunun ana noktaları tespit edilir. Ardından, kenar takibi ile parmak vadileri elde edilebilir (Zhang vd. 2003; Franzgrote vd. 2011; Jia vd. 2012).

- Yerel-ekstremum tabanlı yöntemler bir noktayı başlangıç noktası olarak seçerek, başlangıç noktası ile tüm avuç içi kontur noktaları arasındaki mesafeleri hesaplayarak bir mesafe eğrisi oluşturulur (Genovese vd. 2019; Jia vd 2012; Yörük vd. 2006; Lin vd. 2005; Ito vd. 2015; Bao vd. 2016). Mesafe eğrisinde, yerel maksimum noktalar parmak uçlarına; yerel minimum noktalar ise parmak vadi noktalarına karşılık gelir. Parmak vadileri, tespit edilen vadi noktaları etrafındaki avuç içi konturundan bölütlenebilir. Ardından, iki parmak vadisinin teğet çizgisi referans çizgisi olarak tespit edilebilir.

- Konveks gövde tabanlı yöntemler. Avuç içi konturunu kapsayan en küçük çokgen tespit edilir (Chai vd. 2017; Moço 2004; Sun vd. 2017). Genellikle, parmak uçları konveks gövdenin köşeleridir. Ardından, yukarıda belirtilen yöntemlerle parmak vadileri ve vadi noktaları elde edilebilir.

Genel olarak, dört parmak vadi noktası elde edildikten sonra, bu elin sol mu yoksa sağ mı olduğunun belirlenmesi gerekir, böylece istenen iki vadi noktası tespit edilebilir. Sol ve sağ eli nasıl ayırt edileceği konusunda, Michael vd. (2008) çalışmasında koordinatların geometrik kurallarını kullanırken; Liang vd. (2019) çalışmasında vadi alanlarını kullanır, genellikle baş parmak ve işaret parmağı arasındaki vadi alanı, serçe parmak ve yüzük parmağı arasındakinden daha büyüktür; Bao ve Guo (2016), bir ESA eğiterek sınıflandırmayı yapar; Aykut ve Ekinci (2013) önerilen yöntem ise sol veya sağ el bilgisine ihtiyaç duymaz.

Avuç içi ön işleminde, döndürme normalizasyonu ve ölçek normalizasyonu iki önemli sorundur. Jia vd. (2012) çalışmalarında mevcut yöntemleri analiz etmiş ve avuç içi genişliği tespiti ve merkez noktası oluşturma konularında optimize edilmiş çözümler sunmuşlardır. Döndürme normalizasyonu, tüm avuç içlerini standart bir yöne döndürmeyi amaçlar. Avuç içinin ana yönünü belirlemek için birçok yöntem önerilmiştir. Ito vd. (2015)'ta, avuç içinin döndürme açısını tahmin etmek için temel bileşen analizi kullanılmıştır. Aykut ve Ekinci (2015) ise işaret noktalarının koordinatlarını avuç içinin ana yönüne haritalayabilen bir regresyon modeli öğrenmek için eğitim seti kullanmışlardır. Dolayısıyla, işaret noktası tespit edildikten sonra, avuç içi yönü regresyon modeli ile elde edilebilmektedir. Liang vd. (2019), orta parmak ucu ile avuç içi merkez noktasını geçen çizgi, avuç içinin merkez çizgisi olarak kabul edilir; avuç içinin yönü, çizginin eğimi ile tahmin edilir.

Avuç içi merkez noktası, avuç içi bölgesinin ağırlık merkezi (Ito vd. 2015), avuç içinin maksimum iç teğet çemberinin merkez noktası (Liang vd. 2019), mesafe dönüşümünden sonra maksimum mesafe değerine ulaşan nokta (Lee ve Höllerer, 2007; Borgefors, 1986) veya kalp çizgisine dayalı olarak tespit edilen avuç içi genişlik çizgisinin orta noktasından sapma (Jia vd. 2012) gibi farklı yöntemlerle de belirlenebilir.

Elin döndürme açısı bilgisi ile avuç içi görüntüsü standart yöne normalize edilebilir. Ardından yapılması gereken ölçek normalizasyonudur, bu da ROI'nin kenar uzunluğunu belirlemek anlamına gelir. Hao vd. (2008), Zhang vd. (2017) ve Shao e ark (2019) çalışmalarında, ROI'nin boyutunu belirlemek için avuç içi genişliğini kullanırken, Zhang vd (2003), Franzgrote vd (2011) ve Bingöl ve Ekinci (2017)'deki çalışmalar, ROI'nin boyutunu belirlemek için teğet çizgisinin uzunluğunu kullanmıştır. Liang vd (2019), büyük ROI'lerin daha iyi performans gösterdiğini bulmuştur.

Franzgrote vd. (2011)'de, görüntünün orta bloğu ( $13 \times 13$  piksel) deri rengi modelini eğitmek için kullanılmıştır ve ardından avuç içi bölgesi deri rengi eşikleme ile bölütlenmiştir. Aday işaret noktaları, Michael vd. (2008)'te önerilen yöntem kullanılarak elde edilmiştir. Yazar, çok büyük döndürmelere sahip veya mükemmel olmayan el bölütlemelerine sahip avuç içleri için yüksek dayanıklılık sağlamak amacıyla iki aşamalı bir strateji önermiştir. İlk aşamada, kaba avuç içi yönü tespit edilir. Her aday vadi noktası kendi yön açısını oluşturacak ve açılar dört kaba yönde bölünecektir: yukarı, aşağı, sol ve sağ. Kaba ana yön, en çok destekçiye sahip olan yöndür ve uyumsuz açılar silinmektedir. Daha sonra, kalan açılardan avuç içi yönü hesaplanır. İkinci aşamada, avuç içi görüntüsü döndürülür, böylece dört parmak standart yöne işaret eder ve ardından çizgi tarama tabanlı yöntem kullanılarak parmak vadileri takip edilir. Benzer şekilde, vadi noktaları

tespit edildikten sonra, ROI, iki vadi noktası tarafından oluşturulan referans çizgisine göre türetilir.

Avuç içi, IR ışığı avuç içi görüntüsünden Otsu ve maksimum bağlantılı alan algoritmaları ile bölütlenir. Daha sonra, avuç içinin merkez noktası maksimum iç teğet çemberi ile belirlenir. Merkez noktanın sağında bir başlangıç noktası ayarlanabilir. Ardından, iki aşamalı ana nokta tespit yöntemi, parmak uçlarını ve vadilerini tespit etmek için kullanılır. İlk olarak, başlangıç noktası ve avuç içi kontur noktaları ile bir mesafe eğrisi oluşturulur ve orta parmağın parmak ucu elde edilir. Parmak ucu ve merkez noktasına dayanarak, ilk aşamada kullanılan başlangıç noktasının yerini almak üzere yeni bir referans noktası oluşturulabilir. Daha sonra, avuç içi yönü bilgisi ile yeni bir mesafe eğrisi oluşturulur. Bu yeni mesafe eğrisinin ekstremum noktaları ile kesin parmak uçları ve vadi noktaları tespit edilir. İki tespit edilen vadi noktası etrafındaki vadilerin teğet çizgisi elde edilir; avuç içi bölgesini teğet çizgiye paralel çizgilerle tararız. Her çizgi bir avuç içi genişliği değeri sağlar ve son avuç içi genişliği, bu değerlerin medyanı ile belirlenir. Son olarak, ROI, referans çizgisine ve avuç içi genişliğine göre türetilir.

### 2.2.2 Yeni Nesil Yöntemler

Yukarıda bahsedilen yöntemlerin tümü geleneksel dijital görüntü işleme tekniklerine dayanmaktadır. Çoğu sadece avuç içi kenar bilgilerini kullanır. Ancak bu yeterli değildir ve algoritmaların avuç içi duruşlarına karşı duyarlı olmasına yol açar. Son yıllarda, Aktif Şekil Modeli (AŞM) tabanlı yöntemler (Gao vd., 2018), Aktif Görünüm Modeli (AGM) tabanlı yöntemler (Aykut ve Ekinci, 2015; Bingöl ve Ekinci, 2017), regresyon ağaçları tabanlı yöntemler (Shao vd. 2019) ve derin öğrenme tabanlı yöntemler (Matkowski vd., 2020; Bao ve Guo, 2016) gibi birçok yeni yöntem önerilmiştir. Yeni nesil yöntemler hem kenar hem de doku bilgilerini kullanarak işaret noktalarını regresyon yapmak için çok daha dayanıklı modeller öğrenirler. Avuç içi ROI yerleştirme işleminin ana aşamaları, tüm görüntüden avuç içi bölgesini tespit etmek, işaret noktalarını regresyon yapmak, avuç içi yönünü ve genişliğini belirlemek, yerel koordinat sistemi kurmak ve ROI konumlarını hesaplamaktır.

Aykut ve Ekinci (2015) 'te, 10 uç nokta ve 15 parmak vadisi ve avuç içi sınır işaret noktası dahil olmak üzere bir şekil oluşturmak için 25 el işaret noktası seçilmiştir. Bu şekil, parmak köklerini ve avuç içinin parmak arası bölgelerini kapsar. AGM algoritması ile hem el şekli hem de avuç içi doku bilgileri kullanılır, şekil ve ilgili işaret noktaları otomatik olarak gerçek el konturuna uyacak şekilde yeniden şekillendirilebilir. Yerleştirme performansını değerlendirmek için yazarlar, değiştirilmiş bir nokta-eğri

mesafesi ve bir kenar genişliği metriği önermişlerdir. Şekil modelinin başlangıç pozisyonu regresyon performansı için kritik olduğundan, uygunluk süreci iki aşamaya bölünmüştür. İlk aşamada beş dönüş ve beş ölçek faktörü kullanılarak 25 başlangıç şekli oluşturulur. Regresyondan sonra, sadece 15 optimal yeniden yapılandırma hatasını elde eden şekil modelleri ikinci aşamaya geçer ve ince detaylı regresyon yapılır.

Moço (2014) parmak vadi noktalarını tespit etmek için LeNet (Lee vd., 1998) tabanlı bir ESA çerçevesi önermiştir. Önerilen ağ, evrişimli katmanlar ve tam bağlı katmanlar içerir; çıktı, baş parmak hariç parmaklar arasındaki üç vadi noktasına karşılık gelen altı boyutlu bir vektördür. Çalışmalarında, biri elin sol veya sağ olduğunu belirlemek için, diğeri ise işaret noktası yerleştirme için olmak üzere iki sinir ağı tasarlanmıştır. Deney sonuçlarına göre, ilk ağ elin sol veya sağ olduğunu mükemmel bir şekilde belirleyebilir ve işaret noktası yerleştirme performansı, Otsu bölütlemesi ve Zhang'ın ROI yerleştirme algoritmasına dayalı klasik yöntemden daha iyidir.

Shao vd. (2019)'da, avuç içi konumu, kayan pencere, Yönlendirilmiş Gradyan Histogramı (YGH) ve Destek Vektör Makinesi (DVM) teknikleri ile tespit etmişlerdir. Eğitim setinde 14 işaret noktası belirlenmiş ve işaret noktası regresyonundan sonra, referans çizgisi iki vadi noktası ile oluşturulmuştur. Merkez noktasının konumu ve ROI'nin kenar uzunluğu, avuç içi genişliği ile belirlenir.

## 2. MATERYAL VE METOT

Avuç içi biyometrik tanıma sistemlerinde doğru ROI seçimi, biyometrik verilerin doğruluğunu ve sistemin genel performansını belirleyen kritik bir faktördür. Bu çalışmanın amacı, bölütlenmiş el görüntülerinde parmaklar arası noktalar referans alınarak kare şeklinde bir ROI alanı oluşturmak ve bu yöntemin doğrulama performansına etkilerini incelemektir. Görüntü bölütlemesi bu çalışma kapsamına alınmamış ve bölütlemeden sonraki süreçler incelenmiştir. Bölütlenmiş el görüntülerinde bölgesel büyüklük farkları ortaya çıkabilir. Bu farklar, parmakların açık veya kapalı olması, elin açısı ve pozisyonu gibi değişkenlere bağlıdır. Farklı boyutlarda ve şekillerde ROI alanlarının seçimi, biyometrik doğrulama performansını etkileyebilir.

Bu çalışmada, bölütlenmiş el görüntülerinde parmak arası noktalar referans alınarak farklı büyüklüklerde kare şeklinde ROI alanları oluşturulmuştur. Farklı pozisyonlarda ve açılarda çekilen avuç içi görüntüleri, parmakların açık veya kapalı olduğu durumlarda ROI değişeceğinden biyometrik tanıma için etkiler incelenmeye çalışılmıştır. Bölütleme sonrası belirlenen parmak arası noktalar referans alınarak, çeşitli büyüklüklerde ROI alanları tanımlanmış ve bu alanlar üzerinde biyometrik tanıma performansı değerlendirilmiştir.

Son yıllarda, derin öğrenme biyometri alanında yaygın olarak kullanılmıştır. Örneğin, PalmNet yaklaşımı üç katmanlı bir ESA kullanır ve avuç izine özgü filtreleri, Gabor filtresi yanıtlarına ve Temel Bileşenler Analizi (TBA)'ya dayanan denetimsiz bir prosedür aracılığıyla ayarlamaktadır (Genovese vd., 2019). İlk iki evrişim katmanını özellik çıkarmak için kullanılmış ve son evrişim katmanını birçok ikili şablon oluşturmak için kullanılmıştır. Sonunda 12.288.000 boyutunda çok büyük ikili özellik şablonları üretilmiştir. Bu şablonlar yığın depolama gerektirir ve eşleştirme açısından da hesaplama açısından pahalıdır. Ayrıca, özellik şablonlarının çıkarılması da oldukça hesaplama gerektiren bir işlemdir. Derin Ayrımcı Temsil (Deep Discriminative Representation - DDR) Algoritması avuç izi görüntülerinden genel özellikleri çıkarmak için VGG-face algoritmasını kullanmaktadır ve yerel kompakt özellikleri çıkarmak için başka bir ESA kullanılmıştır (Zhao ve Zhang, 2020). Daha sonra küresel özellikler ile yerel özellikleri birleştirilmiş ve eşleştirme yapmak için sözlük öğrenmeye dayalı yöntemleri kullanılmıştır. Bu algoritmanın bariz sorunlarından biri, eşleşen puanları elde etmek için özellikleri doğrudan karşılaştıramamasıdır. Öncelikle farklı konulardaki birden fazla görseli kullanarak bir sözlük oluşturması gerekmektedir. Bu nedenle, kayıt işlemi


sırasında ilk olarak bir sınıflandırıcıyı eğitmesi gerektiğinden, gerçek dünyadaki temassız avuç içi izi doğrulaması için uygun değildir. Ayrıca, sınıflandırıcıyı eğitmek için birçok sahte avuç içi görüntüsü kullanması gerekir. Buna karşılık, pek çok temassız avuç içi tanıma yöntemi, önce bir özellik şablonu oluşturur ve ardından eşleşen puanı oluşturmak için galeri ve sonda görüntüsünün özellik şablonlarını doğrudan karşılaştırır. Sonuç olarak, yöntem yalnızca temassız avuç izi tanımlama için uygundur.

Yerel avuç içi bölgelerinde yeterince benzersiz özelliklerin bulunmaması ve bu tür yerel avuç içi özellikleri arasındaki sınıflar arası benzerlik, avuç içi görüntülerinin doğru bir şekilde tanınmasında zorluklar oluşturmaktadır. Çeşitli halka açık veritabanlarındaki temassız avuç içi görüntüleri üzerinde yapılan analizler, eşleşmeyen temassız görüntülere yönelik asıl zorluğun, ilgilenilen görüntülerle doğrudan örtüşmeyen yerel avuç içi izi bölgelerinin doğru bir şekilde kurtarılması ve eşleştirilmesinde yattığını ortaya koymaktadır (Yulin ve Kumar, 2023).

## **2.1. ROI Çıkarma Yaklaşımları**

Çalışma kapsamında öncelikle literatürde kullanılan ROI çıkarma yöntemleri incelenmiştir. Harun vd. (2017) çalışmalarında ROI çıkarmak için yeni bir algoritma geliştirmişlerdir. Bu algoritma, mevcut yöntemlerden farklı olarak avuç içi baskısının daha geniş bir bölgesini çıkararak daha fazla biyometrik özelliğin elde edilmesini sağlamaktadır. Algoritma, üç ana adımdan oluşmaktadır: görüntü filtreleme, sınır takibi ve avuç içi ROI'sinin çıkarılması. Görüntü filtreleme aşamasında, avuç içi görüntüsü arka plandan ayrılırken, sınır takibi adımı avuç içi sınırlarının belirlenmesini sağlamaktadır. Son olarak, önerilen algoritma, belirlenen sınırlar ve parmaklar arasındaki vadilere dayanarak avuç içi ROI'sini çıkarmaktadır.

Harun vd. (2017) çalışmalarında iki farklı yöntemle kendi çalışmalarını karşılaştırmışlardır. Bu çalışmada önerilen ve karşılaştırılan diğer iki yöntemle çıkarılan ROI'ler Şekil 1'de gösterilmiştir. Önerilen algoritma, mevcut iki algoritma ile karşılaştırıldığında, daha büyük bir ROI çıkarma kapasitesine sahiptir. Bu genişletilmiş ROI, daha fazla biyometrik bilginin toplanmasına ve bu bilgilerin kimlik doğrulama süreçlerinde daha etkin kullanılmasına olanak tanır.




Şekil 1. Farklı ROI çıkarma yaklaşımları. a) Harun vd. (2017), b) Han vd. (2003), c) Badrinath vd. (2011)

Han vd. (2003) tarafından geliştirilen algoritma, avuç içi baskısının ROI'sini çıkarmak için sabit bir merkez bölgesi yaklaşımı kullanmaktadır. Bu yöntemde, avuç içi baskısının belirli bir merkez bölgesi (genellikle 128x128 piksel boyutunda) çıkarılır ve ROI olarak kullanılır. Bu sabit boyutlu ROI, tüm avuç içi baskıları için aynı alana odaklanmakta, ancak bu da avuç içinin daha geniş bir bölümünde bulunan biyometrik özelliklerin göz ardı edilmesine neden olmaktadır. Bu yöntemin avantajı, basit ve hızlı olmasıdır, çünkü ROI'nin çıkarılması sabit bir merkez bölgesine dayandığı için işlem süresi oldukça kısadır. Ancak, dezavantajı, sabit bir ROI boyutunun, farklı bireylerdeki avuç içi boyut ve şekillerindeki çeşitliliği göz ardı etmesidir. Bu durum, kimlik doğrulama ve tanımlama süreçlerinde daha az bilgi elde edilmesine ve dolayısıyla doğruluğun düşmesine neden olabilir. Han vd. (2003)'ün yöntemi, avuç içi baskısının sadece merkezi bir bölümünü ele aldığı için, daha geniş bir ROI'nin gerektirdiği durumlarda yetersiz kalabilmektedir.

Badrinath vd. (2011) tarafından geliştirilen yöntem, dört anahtar noktaya dayanarak avuç içi baskısının ROI'sini çıkarmaktadır. Bu dört anahtar nokta, iki parmak arasındaki vadilerin belirlenmesiyle elde edilmekte ve daha sonra bu noktalar arasında belirli açılarla çizgiler çizilerek ROI'nin sınırları belirlenmektedir. Badrinath ve arkadaşlarının yöntemi, avuç içi baskısının daha geniş bir bölümünü kapsayarak, daha fazla biyometrik özelliğin elde edilmesini sağlamaktadır. Ancak, bu yöntemin de bazı sınırlamaları vardır. Her ne kadar sabit merkez bölgesi yerine daha geniş bir ROI çıkarma kapasitesine sahip olsa da, bu yöntem de ROI'nin sınırlarını belirlerken bazı özellikleri göz ardı edebilir. Ayrıca, ROI'nin çıkarılmasında kullanılan dört anahtar noktanın belirlenmesi ve açılarının hesaplanması, yöntemin karmaşıklığını artırır ve işlem süresini uzatabilir. Bu da, büyük veri setlerinde veya gerçek zamanlı uygulamalarda zorluklara yol açabilir.

Bu çalışmalara ek olarak son yıllarda çok daha farklı yaklaşımlar ele alınmış olup, bu çalışmalardan ROI elde etme sürecine ilişkin temel gösterimler Şekil 2’de gösterilmiştir. Şekil 2a’da gösterilen yöntem Matkowski vd. (2020) tarafından geliştirilmiştir. Matkowski vd. (2020) ROI bölgelerinden özellikleri çıkarmak için ROI Yerleştirme ve Hizalama Ağı (ROI-LANet) adlı değiştirilmiş bir VGG-16 derin ağı kullanarak ROI bölgesini orijinal avuç içi görüntülerinden ayırmışlar ve Özellik Çıkarma ve Tanıma Ağı (FERnet) adı verilen başka bir budanmış VGG-16 ağını kullanmışlardır. El bölgesi orijinal internet görüntüsünden çıkarılır ve ardından  $227 \times 227$  piksele yeniden boyutlandırılır. Normalize edilmiş avuç içi görüntüsü, hizalanmış ROI yerleştirme, özellik çıkarımı ve sınıflandırma için tasarlanan ESA’ya yerleştirilmektedir. Özellik çıkarımından sonra eşleştirme yapmak için kısmi en küçük kareler regresyonunu kullanmışlardır. Bu yöntem ayrıca eşleştirmeyi gerçekleştirmek için ayrı bir sınıflandırıcı gerektirir; bu nedenle DDR ile benzer sorunları vardır.



Şekil 2. ROI çıkarmada yeni yaklaşımları (Ma vd., 2024). a) Matkowski vd. (2019), b) Zhang vd. (2003), c) Zhao ve Zhang (2019), d) Liambas ve Tsouros, (2007) e) Shao vd. (2019) f) Zhang vd. (2020)

Zhao ve Zhang (2019), ROI çıkarmak önerdikleri yöntemde, hiperspektral görüntülerin farklı dalga boylarındaki aydınlatma farklılıklarını ve dengesiz gölgeleri dikkate alarak, ROI çıkarımını doğru ve etkili bir şekilde gerçekleştirmişlerdir (Şekil 2c). Algoritma, dört ana aşamadan oluşmaktadır: İlk aşamada, düşük aydınlatma ve düşük kontrast gibi sorunları gidermek için avuç içi görüntüsünün kalitesi artırılmıştır.

Ardından, Niblack algoritması kullanılarak avuç içi görüntüsü ikili bir görüntüye dönüştürülür, ancak bu aşamada yalnızca kabaca bir avuç içi şekli elde edilmiştir. Üçüncü aşamada, avuç içi tespiti yapılmış ve DVM tabanlı bir yöntem kullanılarak avuç içi pikselleri arka plandan ayrılmıştır. Bu aşamada, her bir görüntü için yeni eğitim verileri kullanılarak dinamik bir sınıflandırma gerçekleştirilmiştir. Son aşamada, avuç içi görüntüsünde kilit noktalar belirlenmiş ve bu noktalar kullanılarak bir koordinat sistemi oluşturulmuştur. Bu koordinat sistemi, avuç içinin farklı pozisyonlarda olmasına rağmen her seferinde aynı konumdan ROI çıkarılmasına olanak sağlamıştır. Bu yöntemin temel avantajı, farklı dalga boylarındaki hiperspektral avuç içi görüntülerinden doğru bir şekilde ROI çıkarabilmesidir. Bu yaklaşım, hiperspektral verilerde düşük aydınlatma, gölgelenme ve parmaklarda takı gibi etkilerden kaynaklanan zorlukların üstesinden gelmekte başarılıdır. Makalede sunulan deneysel sonuçlar, önerilen algoritmanın ROI çıkarımında etkili olduğunu ve tanıma süreçlerinde yüksek doğruluk sağladığını göstermektedir.

Shao vd. (2019) çalışmalarında farklı açılardan ve doğal veya flaş aydınlatması altında çekilen görüntülerde, avuç içinin stabil ve doğru bir şekilde tespit edilebilmesi için manuel olarak 14 anahtar nokta işaretlemişlerdir (Şekil 2e). Bu noktalar arasında parmakların arasındaki vadiler, parmakların tabanları ve avuç içinin kenar noktaları bulunmuştur. Bu noktalar, avuç içi baskısının ROI'sini çıkarmak için bir çerçeve oluşturmuştur. ROI çıkarma işleminin ilk adımında, avuç içi görüntüsü Yönlendirilmiş Gradyanların Histogramı (YGH) özellikleri kullanılarak tespit edilmiştir. Daha sonra, regresyon ağaçları algoritması kullanılarak belirlenen anahtar noktalar işaretlenmiştir. Son olarak, bu anahtar noktalar arasında mesafe hesaplanarak kare şeklinde bir ROI çıkarılmıştır.

Zhang vd. (2020) çalışmalarındaki ROI çıkarma yöntemi, mobil cihazlarda avuç içi baskısı doğrulaması için optimize edilmiş ve DeepMPV+ adlı bir sistemin parçası olarak önermişlerdir (Şekil 2e). Bu yöntem, iki ana adımı içerir: çift parmak aralığı ve avuç içi merkezi noktalarının tespiti. İlk olarak, Tiny-YOLOv3 tabanlı bir dedektör kullanılarak parmaklar arasındaki vadiler ve avuç içi merkezi tespit edilmiştir. Bu noktalar, avuç içi üzerindeki yerel bir koordinat sistemi oluşturmak için kullanılmıştır. ROI'nin merkez noktası ve boyutu, tespit edilen parmak aralıkları ve avuç içi merkezi ile belirlenmiştir. Bu yöntemin karmaşık arka planlar ve farklı avuç içi pozisyonlarına karşı oldukça dayanıklı olduğu bildirilmiştir.

## 2.2. Önerilen Yöntem

Karmaşık bir derin sinir ağı kullanarak doğrudan derin özellikler çıkarmak ve ardından bir sınıflandırıcıyla bu özellikleri eşleştirmek yerine, daha hafif bir sinir ağı kullanılarak küçük boyutlu veriler çıkartılmıştır. Bu yaklaşım, el görüntüsündeki çeşitli alt bölgelerden gelen özellikleri hesaplayarak, galeri görüntüsündeki alt bölgelerle olan minimum mesafeyi belirlemiştir. Bu mesafeler daha sonra uyarlanabilir bir şekilde birleştirilmiş ve bu sayede daha güvenilir ve doğru bir eşleşme puanı oluşturulmuştur. Bu yeni yöntem, verimlilik ve doğruluk açısından aşağıda sıralanan bazı avantajlar sağlamıştır:

a) Sınırlı eğitim verilerinden kaynaklanan zorlukların giderilmesi: Derin öğrenme modellerinin başarılı olabilmesi için geniş çaplı eğitim verilerine ihtiyaç duyulduğu bilinmektedir. Ancak, temassız avuç içi görüntülerinde bu denli büyük veriler mevcut olmadığından, derin sinir ağlarının biyometrik uygulamalara entegrasyonu zorlaşmaktadır. Yulin ve Kumar (2023) çalışmasına benzer bir şekilde, bu zorlukların üstesinden gelmek için piksel düzeyinde bir yaklaşımla orijinal görüntü alt parçalara ayrılmıştır.

b) Deformasyonlar ve ötelemelerle ilgili zorlukların giderilmesi: Temassız avuç içi görüntülerinde sıkça rastlanan istemsiz deformasyonlar ve ötelemeler, geliştirilen yaklaşımda dikkate alınmıştır. Bu yöntemde, görüntüdeki tüm potansiyel eşleşmelere odaklanarak, yerel bölgelerin bu tür bozulmalardan en az etkilenmesi sağlanmıştır. Bu, daha doğru ve güvenilir bir eşleşme süreci oluşturarak, genel tanıma doğruluğunu artırmayı hedeflemiştir.

c) Tanıma doğruluğunun artırılması: Temassız avuç içi görüntüleri farklı parçalara ayrılarak, birden fazla kanıt elde edilmiştir. Bu kanıtların birleştirilmesiyle, geleneksel yöntemlere kıyasla daha güvenilir tanıma sonuçları elde edilmesi beklenmektedir. Bu yaklaşım, yanlış sonuçların olasılığını azaltarak, genel tanıma performansını iyileştirmeyi amaçlamaktadır.

d) Daha doğru özellik temsili sağlanması: Küçük boyutlu görüntüler, derin sinir ağlarıyla daha güvenilir özellikler üretebilmektedir. Bu, büyük miktarda ayırt edici bilginin, ağ tarafından 1 boyutlu vektörlere dönüştürülmesi sırasında kaybedilebileceği gerçeğiyle ilişkilidir. Küçük boyutlu görüntüler, bu bilgilerin daha güvenilir bir şekilde temsil edilmesini sağlamaktadır.

e) Belirli alt bölgelere odaklanması: Temassız avuç içi görüntülerinin bölütlenmesi, insan görsel sistemine benzer şekilde, önemli görüntü bölgelerine

odaklanmayı mümkün kılmaktadır. Bu yaklaşım, temassız avuç içi görüntülerinin tanıma yeteneğini ve ayırt ediciliğini artırmayı hedeflemektedir.

### 2.3. Aday Alt Bölgelerin Seçimi

Öncelikle, orijinal temassız avuç içi görüntüleri, piksel düzeyinde ilişkilerin değerlendirilebilmesi amacıyla birçok küçük parçaya veya alt bölgeye bölünmüştür. Herhangi bir temassız avuç içi görüntüsü, daha küçük boyutlu parçalara ayrılmıştır. Temassız avuç içi tanıma probleminde, ROI görüntüleri genellikle kare şeklinde kırpılır ve bu çalışmada da kare alt görüntüler tercih edilmiştir. Normalleştirilmiş avuç içi görüntülerinin boyutu dikkate alındığında, daha küçük alt görüntüler oluşturulmuştur. Bu parçaların sayısı çok fazla olabileceği için eğitim ve test aşamalarında kaynak tüketimini optimize etmek amacıyla, tüm alt bölgeler yerine yalnızca belirli bir kısmı kullanılmaktadır. Alt parçaların seçimi için iki yöntem geliştirilmiştir.

İlk yöntem olan Rastgele Seçim, tüm alt görüntüler arasından belirli bir yüzdeyle (%10) rastgele seçim yapılmasını önerir. İkinci yöntem olan Adım Seçimi ise, tek piksellik atlamalar yerine belirli adımlar atlanarak alt görüntülerin seçilmesini sağlar. Bu yaklaşımla,  $w \times l$  boyutlarındaki bir görüntüden, formül kullanılarak belirlenen sayıda alt parça üretilebilir. Bu yöntemler, kaynak kullanımını optimize ederken, doğruluğu korumayı amaçlamaktadır. Adım seçimi yaklaşımı ile Eşitlik – 1’deki gibi hesaplanan sayıda yeni görüntü oluşturulmaktadır.

$$N = \left( \frac{w - x}{atlama} + 1 \right) \cdot \left( \frac{l - y}{atlama} + 1 \right) \quad (\text{Eşitlik 1})$$


Eşitlik – 1’de  $x$  ve  $y$  yeni oluşturulacak görüntü parçasının boyutunu, atlama değeri ise piksellerin ne kadar atlama ile bir sonraki parçayı seçeceğini göstermektedir.

### 2.4. Doğrulama Ağ Modeli

Derin ağ modelleri, avuç izi gibi karmaşık desenleri ve ayrıntılı özellikleri daha iyi analiz edebilme yeteneğine sahiptir. Bu modeller, geleneksel yöntemlere kıyasla daha yüksek doğruluk oranları sunarak, kimlik doğrulama süreçlerinin güvenilirliğini artırır. Basit bir derin ağ modelinin avuç izi tanımda kullanılmasının ana gerekçesi, karmaşık ve büyük modellerin getirdiği yüksek hesaplama maliyetlerini minimize etmektir. Özellikle mobil cihazlar gibi sınırlı işlem gücüne sahip platformlarda, basit derin ağ modelleri, hem yeterli doğruluk sağlamakta hem de enerji ve işlem süresi açısından

verimli çalışmaktadır. Bu tür modeller, düşük kaynak gereksinimleri ile pratik kullanım alanları sunmaktadır.

Birçok biyometrik yöntemin, el yapımı özelliklerin yerini derin sinir ağları tarafından öğrenilen özellik temsilleri aldığında üstün eşleştirme doğruluğu sunduğu gösterilmiştir. Ancak bu tür özellik temsilleri avuç içi literatüründe çok az ilgi görmüştür. Gerçek temassız avuç içi uygulaması için herhangi bir özellik çıkarma yöntemi, yalnızca hesaplama açısından ekonomik olmakla kalmamalı, aynı zamanda bu tür el yapımı özelliklere göre sağlam ve nispeten daha yüksek performans sunmalıdır. Bu bağlamda, birkaç popüler derin sinir ağı modelini değerlendirilmiş ve Şekil 3'de gösterildiği gibi bir ESA modeli seçilmiştir.



Şekil 3. Kullanılan ESA yapısı

Çok karmaşık bir derin öğrenme modeli yerine Şekil 3'de gösterildiği gibi hafif bir ESA ağı seçilmiştir. Bu ağın seçilmesinin asıl gerekçesi halka açık temassız avuç içi veritabanlarındaki görüntü sayısı nispeten azdır ve görüntü çözünürlüğü de düşüktür; bu nedenlerle çok sayıda parametreye sahip derin bir ağın bu verilerle eğitilmesi zordur. Çok karmaşık bir modelin bu tür özellik çıkarımına yardımcı olmaması beklenmektedir. Diğer taraftan hafif bir ağı, karmaşık bir modele göre çok daha hızlı olabilir ve daha az hesaplama kaynağı gerektirir ve gerçek uygulamalara daha uygundur.

## 2.5. Ağ Kaybı ve Benzerlik Mesafesi

Üçlü kayıp fonksiyonu (triplet loss), derin öğrenme modellerinde özellikle yüz tanıma, avuç izi tanıma gibi biyometrik doğrulama alanlarında kullanılan bir yöntemdir. Bu fonksiyon, modelin örnekler arasındaki mesafeyi öğrenmesine yardımcı olur. Üçlü

kayıp fonksiyonu, üç temel bileşenle çalışır: "çapa" (temel), "pozitif" (benzer) ve "negatif" (farklı) örnekler.

a) Çapa: Bu, modelin tanımlamak istediği ana örnektir.

b) Pozitif: Çapa ile aynı sınıfa ait, yani aynı kişiye ait olan bir diğer örnektir.

Modelin bu iki örnek arasındaki mesafeyi minimize etmesi beklenir.

c) Negatif: Çapa ile farklı sınıfa ait, yani başka bir kişiye ait olan bir örnektir.

Modelin, çapa ile bu örnek arasındaki mesafeyi maksimize etmesi amaçlanır.

Ağ eğitimi sırasında üçlü kayıp fonksiyonu kosinüs mesafesiyle birleştirilmiştir. Bu kayıp fonksiyonu Eşitlik – 2’deki gibi tanımlanabilir:

$$\mathcal{L}_{triplet} = \sum_{i=1}^n (\max[\|F(c_i) - F(p_i)\|^2 - \|F(c_i) - F(n_i)\|^2 + \alpha, 0]) \quad (\text{Eşitlik 2})$$

Bu denklemde, F Eşitlik – 3’de tanımlandığı gibi iki özellik vektörü arasındaki kosinüs mesafe fonksiyonudur.  $\|.$   $\|$  iki örnek arasındaki mesafeyi temsil eder (genellikle L2 normu kullanılır).  $\alpha$ , modelin çapa ile pozitif örnek arasındaki mesafenin, çapa ile negatif örnek arasındaki mesafeden en az  $\alpha$  kadar daha küçük olmasını sağlayan bir marj parametresidir.


$$F(x, y) = \frac{\sum_{i=1}^n (x_i \cdot y_i)}{\sqrt{\sum_{i=1}^n (x_i^2)} \sqrt{\sum_{i=1}^n (y_i^2)}} \quad (\text{Eşitlik 3})$$

Popüler Öklid mesafesi yerine kosinüs mesafesini kullanılması nedeni, Öklid mesafesi sınırsız iken marj ne kadar büyük ayarlanırsa ayarlanırsa kayıp her zaman küçük bir değere düşebilir. Buna karşılık, kosinüs mesafeleri sınırlıdır ve uygun marjın seçimi, ağ eğitimi sırasındaki kaybı önemli ölçüde azaltabilir ve yüksek boyutlu özellik uzayında özellik vektörlerinin daha iyi ayrılmasını sağlayabilir.

## 2.6. Eğitim Verisi Seçimi

Birçok popüler biyometrik uygulamanın aksine, temassız avuç içi verileri için mevcut eğitim verileri çok sınırlıdır. Bu nedenle önerilen yaklaşım aynı zamanda ağ eğitimi için eğitim verilerinin akıllıca seçilmesine yönelik yeni bir bakış açısını da içermektedir. Üçlü kaybı kullanıldığından eğitim için üç tür görüntü seçilmesi gerekmektedir: çapa görüntüsü, pozitif görüntü ve negatif görüntü. Genel tanıma problemlerinde, aynı konudan iki görüntüyü çapa verisi ve pozitif veri olarak rastgele

seçilebilir, ardından başka bir konudaki görüntüleri negatif görüntü olarak seçilebilir. Ancak orijinal avuç izi görüntüleri birçok alt görüntüye bölündüğünden, aynı nesnenin görüntülerinden alınan alt görüntüleri pozitif veri olarak doğrudan kullanılamaz çünkü bu tür iki alt görüntü arasında üç tür ilişki vardır. Şekil 4 bu ilişkileri göstermektedir. İki farklı konudaki alt görüntüleri sahte çiftler olarak etiketlemek oldukça basittir. Ancak gerçek alt görüntü çiftlerinin seçimi zordur. Bunun temel nedeni aynı görüntülerin veya konunun alt görüntülerinin çok farklı olabilmesidir.



Şekil 4. Eğitim görüntüsü oluşturma

İki alt görüntü arasındaki mekansal ötelemenin boyutunu hesaplamak için basit ama hızlı bir yaklaşım kullanmıştır. Bir görüntü yinelemeli olarak tüm yönlere çevrilir ve bu iki görüntü arasındaki en küçük mesafeye sahip konumu bulunur. İki alt görüntü arasındaki uzamsal gri seviye benzerliğini hesaplamak için, sonda görüntülerini her yöne hareket ettiren ve iki görüntü arasındaki mesafenin en küçük olduğu uzamsal konumu bulan etkili bir yaklaşım kullanmıştır.

## 2.7. Dağılık Şablonların Eşleştirilmesi

Bir avuç içi izi için birden fazla kayıtlı şablon varsa genel eşleştirme yöntemi, test görüntüsünü her kayıtlı görüntüyle karşılaştırmak ve ardından minimum olanı almaktır. Burada eşleştirme puanını oluşturmak için de bu yolu kullanılmıştır. Ancak eşleştirme puanını oluşturmak için farklı bir yol tercih edilmiştir: özellik vektörlerini hesaplanmış ve kayıtlı her görüntüden seçilen alt görüntülerin her birini seçilmiştir. Ardından test görüntüsündeki her alt görüntünün en yakın mesafesi bulunmuştur. Bu nedenle birçok eşleşen puanı hesaplayıp en iyi olanı seçmek yerine doğrudan tek bir eşleştirme puanı alınmıştır. Eşleştirme hızını ve doğruluğunu artırabileceği için bu yöntemi tercih edilmiştir.

## 2.8. Eşleşme Skoru

Eşleşme skorlarını birleştirmeye yönelik çeşitli yöntemler arasında en basit olanı, ortalama mesafeyi hesaplamaktır. Burada dikkat mekanizmalarının eklenmesi veya eğitim verilerinden öğrenilebilecek farklı bir önem verisinin üretilmesi düşünülmüştür. Bir dikkat modeli, örneğin farklı mekansal konumlardan kaynaklanan eşleşmelere farklı güven verebilir. Çeşitli bölümlerden veya alt görüntülerden eşleştirme mesafeleri oluşturduğumuzdan, bu mesafelerin veya puanların önemi hepsi için aynı değildir. Bu nedenle, farklı mekansal konumlardan farklı puanlar için bir ağırlık seti dahil edilebilir. Bu ağırlıklar ampirik olarak seçilebilir veya doğrusal bir sınıflandırıcı kullanılarak öğrenilerek elde edilebilir. Modeli eğittikten sonra özellik vektörlerini hesaplıyoruz ve tüm eğitim verileri için eşleştirme puanları üretiyoruz. Bu eşleştirme puanlarını doğrusal bir sınıflandırıcı modelini eğitmek ve atanan ağırlıkları almak için kullanılmıştır.

Eşleştirme aşamasında iki avuç içi görüntüsü arasındaki en yakın özellik vektörlerinin hesaplanması, yüksek hesaplama süresi ve hesaplama kaynakları gerektirebilir. Ancak en yakın vektörü aramak için hesaplama açısından verimli birkaç yöntem vardır. En kolay fakat en yavaş olanı, geri alma vektörü arasındaki mesafeyi hesaplayacak olan doğrusal aramadır. Bu nedenle yaklaşık en yakın komşular arama algoritmasını tercih edilmiştir. Yaklaşık en yakın algoritmalar genellikle sorguya olan mesafesi en yakın mesafeye çok yakın olan galeri vektörünü döndürebilir. Pek çok durumda, yaklaşık en yakın komşu neredeyse kesin olan kadar iyidir, ancak geleneksel en yakın komşu arama algoritmalarından çok daha hızlıdır.

## 2.9. Veri artırma

Sağlamlığı ve doğruluğu artırmak için denememizde bazı veri artırma teknikleri kullanılmıştır. Öncelikle orijinal eğitim görüntüleri üzerinde veri büyütme işlemi yapılmış ve ardından bu artırılmış görüntülerden alt görüntüler seçilmiştir. Kullanılan veri artırma yaklaşımları şunlardır: rastgele parlaklık, rastgele kontrast, bulanıklık, Gauss gürültüsü ve kaydırma ölçeği döndürme.

## 2.10. Görüntü Normalleştirme

Avuç içi görüntülemenin temassız doğası, elde edilen görüntülerin aydınlatmasında ve görüntü kalitesinde önemli değişikliklere neden olabilir. Ayrıca, kamuya açık alanda mevcut olan çeşitli temassız avuç içi veri kümeleri çok farklıdır ve bu nedenle, eğitim için ağ girişi olarak orijinal avuç içi görüntüleri kullanıldığında, veri tabanları arası

eşleştirme performansında önemli bir bozulma beklenmektedir. Bu nedenle, tüm avuç izi görüntüleri ilk olarak aşağıdaki eşitlikte elde edilen görüntü normalleştirmesine tabi tutulur:

$$x_s = \frac{x - \mu}{\max(\sigma, \frac{1}{\sqrt{N}})} \quad (\text{Eşitlik 4})$$



### 3. YAPILAN ÇALIŞMALAR VE BULGULAR

Çalışmada öncelikle veritabanının bir kısmı eğitim, diğer bir kısmını da performans değerlendirmesi için kullanılmak üzere düzenlenmiştir. Test performansında halka açık veritabanlarını kullanarak raporlayan, halka açık bir veritabanı kullanarak çapraz veri kümesi performansını da sunulmuştur. Performansı kıyaslamak için literatürde sunulan çeşitli son teknoloji yöntemleri kullanarak karşılaştırmalı deneysel sonuçlar gerçekleştirilmiştir.

Deneylerde, tüm temassız avuç izi görüntülerini yeniden 128x128 boyutlandırılmıştır. Alt görüntüler ise 64x64 boyutunda olacak şekilde belirlenmiştir. Eğitim aşamasında Adam optimizör kullanılmıştır ve öğrenme oranı 0,001 olarak ayarlanmıştır. Test aşamasında, aday alt görüntüler oluşturmak için 289 adet alt görsel kullanılmıştır. Önceden eğitilmiş herhangi bir model kullanılmamıştır ve tüm ağ modelleri sıfırdan eğitilmiştir.


#### 3.1. IITD Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar

IITD temassız avuç içi veri seti 235 farklı denekten alınan sol ve sağ avuç izi görüntülerini içermektedir (URL-1). Bu veri seti aynı zamanda tekrarlanabilirliği sağlamak için bölütlenmiş ROI görüntüleri de sağlamaktadır.

Deneylerde sol elden alınan görüntüler eğitim için, sağ elden alınan görüntüler ise test performansının değerlendirilmesi için kullanılmıştır. Doğrulamada hem hepsi bir arada protokolünü hem de bir-birini dışarıda bırakma protokolü kullanılmıştır. IITD veri setinde her ne kadar farklı kişiler farklı sayıda görüntüye sahip olsa da galeri seti olarak yalnızca ilk beş görüntü seçilmiştir. Deneylerden elde edilen Alıcı İşletim Karakteristiği (Receiver Operating Characteristic – ROC) eğrisi ve Kümülatif Eşleşme Eğrisi (Cumulative Match Curve – CMC) Şekil 5’de gösterilmiştir. Benzeri şekilde de Tablo 1, Yanlış Kabul Oranı (False Acceptance Rate – FAR), Eşit Hata Oranı (Equal Error Rate – EER) ve Gerçek Kabul Oranı (Genuine Accept Rate – GAR) 'ın karşılaştırmalı bir özetini sunmaktadır.

Tablo ve şekil analiz edildiğinde, önerilen yöntemin diğer çalışmalara kıyasla daha yüksek bir doğruluk oranına (%98.19) sahip olduğu görülmektedir. Bu yöntem, en düşük EER değerlerinden birine de (%2.09) sahiptir, bu da yöntemin hataları en aza indirme yeteneğini gösterir. GAR açısından da önerilen yöntem %96.23 ile en yüksek

performansa sahiptir. Diğer yöntemlerle karşılaştırıldığında, bu sonuçlar önerilen yöntemin avuç izi tanıma alanında daha güvenilir ve etkili olduğunu ortaya koymaktadır.




Şekil 5. IITD veri tabanı üzerinde uygulanan yöntemler için ROC ve CMC eğrileri.

Tablo 1. IITD veri tabanından elde edilen EER ve doğruluk değerleri

| Yöntem                    | Doğruluk(%) | EER(%) | GAR (FAR=10 <sup>-3</sup> )(%) |
|---------------------------|-------------|--------|--------------------------------|
| Önerilen Yöntem           | 98.19       | 2.09   | 96.23                          |
| Harun vd. (2017)          | 94.13       | 4.92   | 92.25                          |
| Han vd. (2003)            | 92.16       | 5.90   | 90.32                          |
| Badrinath vd. (2011)      | 95.96       | 3.56   | 94.04                          |
| Matkowski vd. (2019)      | 91.46       | 5,75   | 89.63                          |
| Zhang vd. (2003)          | 89.76       | 5.94   | 87.96                          |
| Zhao ve Zhang (2019)      | 94.02       | 4.31   | 92.14                          |
| Liambas ve Tsouros (2007) | 93.61       | 4.74   | 91,74                          |
| Shao vd. (2019)           | 93.14       | 4.47   | 91.28                          |
| Zhang vd. (2020)          | 96.82       | 3.49   | 94.88                          |

IITD veritabanı üzerinde birini dışarda bırak yaklaşımına göre yapılan deneylere ilişkin sonuçlar Şekil 7 ve Tablo 2 de sunulmuştur. Şekildeki ROC eğrisinden görüldüğü üzere, önerilen yöntem yine en iyi performansı göstermektedir. Eğri, hem düşük FAR değerlerinde hem de yüksek GAR değerlerinde diğer yöntemlerden daha üstün bir performans sergilemektedir. Özellikle %0.1'in altında FAR değerlerine ulaştığında bile GAR değeri %97'nin üzerinde kalmaktadır, bu da modelin güçlü bir doğrulama yeteneği olduğunu göstermektedir. Diğer yöntemlerle kıyaslandığında, Harun vd. (2017) ve Matkowski vd. (2019) yöntemleri de ROC eğrisinde nispeten iyi performans

sergilemekte, ancak bu yöntemler Önerilen Yöntem'in gerisinde kalmaktadır. Han vd. (2003) ve Liambas ve Tsouros (2007) yöntemleri, ROC eğrilerinde en düşük performansı göstermektedir, bu da bu yöntemlerin daha yüksek bir yanlış kabul oranı ile sonuçlandığını işaret etmektedir.



a) ROC Eğrisi

b) CMC Eğrisi

Şekil 6. IITD veri tabanından hepsi bir arada protokolü ile elde edilen ROC ve CMC eğrileri

CMC grafiğinde de yine Önerilen Yöntem öne çıkmaktadır. Rank 1'de bile %99.57 doğruluk oranı yakalayan bu yöntem, Rank arttıkça diğer yöntemlere göre daha yüksek bir performans göstermeye devam etmektedir. Bu sonuç, Önerilen Yöntem'in hem erken hem de geç aşamalarda doğru sınıflandırma yapabilme yeteneğinin oldukça güçlü olduğunu ortaya koymaktadır. Diğer yöntemlerden Matkowski vd. (2019) ve Shao vd. (2019) da nispeten yüksek doğruluk oranları sergilemekte, ancak özellikle Rank 1'de bu yöntemlerin doğruluk oranı Önerilen Yöntem kadar yüksek değildir. Han vd. (2003) ve Liambas ve Tsouros (2007) ise CMC eğrisinde en düşük doğruluk oranlarını göstermekte, bu da bu yöntemlerin daha az güvenilir olduğunu işaret etmektedir.

Tablo 2, önerilen yöntem'in diğer yöntemlerle karşılaştırıldığında hem EER hem de doğruluk oranı açısından en iyi performansı gösterdiğini ortaya koymaktadır. Önerilen Yöntem'in EER değeri %0.35 gibi oldukça düşük bir seviyededir, bu da sistemin hem yanlış kabul hem de yanlış reddetme oranlarının minimize edildiğini göstermektedir. Doğruluk oranlarına bakıldığında, Önerilen Yöntem %99.57 ile en yüksek başarı oranına sahiptir, bu da sistemin doğru kararlar verme kabiliyetinin çok yüksek olduğunu ortaya koymaktadır. Benzer şekilde,  $FAR = 10^{-3}$  seviyesinde %97.58'lik bir GAR değeri elde edilmiş olması, sistemin bu eşik değerinde dahi yüksek bir doğruluk sunduğunu göstermektedir. Diğer yöntemlerden Matkowski vd. (2019) ve Shao vd. (2019) da benzer

şekilde yüksek doğruluk oranları sergilemekte, ancak EER değerleri Önerilen Yöntem'e kıyasla daha yüksek kalmaktadır. Bu durum, bu yöntemlerin yanlış kabul ve reddetme oranlarını dengeleme konusunda daha az etkili olduğunu gösterir. Han vd. (2003) ve Liambas ve Tsouros (2007) ise en düşük performansı göstermekte, bu da bu yöntemlerin daha eski ve belki de güncel veri işleme tekniklerine kıyasla yetersiz kaldığını işaret etmektedir.

Tablo 2. IITD veri tabanından hepsi bir arada protokolü ile elde edilen EER ve doğruluk oranları

|                           | Doğruluk(%) | EER(%) | GAR (FAR=10 <sup>-3</sup> )(%) |
|---------------------------|-------------|--------|--------------------------------|
| Önerilen Yöntem           | 99.57       | 0.35   | 97.58                          |
| Harun vd. (2017)          | 98.36       | 2.10   | 96.39                          |
| Han vd. (2003)            | 96.87       | 3.27   | 94.93                          |
| Badrinath vd. (2011)      | 98.18       | 1.81   | 96.22                          |
| Matkowski vd. (2019)      | 99.26       | 1.27   | 97.27                          |
| Zhang vd. (2003)          | 97.16       | 2.96   | 95.22                          |
| Zhao ve Zhang (2019)      | 98.13       | 1.50   | 96.17                          |
| Liambas ve Tsouros (2007) | 97.45       | 3.16   | 95.50                          |
| Shao vd. (2019)           | 98.92       | 1.62   | 96.94                          |
| Zhang vd. (2020)          | 97.22       | 2.17   | 95.28                          |

### 3.2. PolyU-IITD Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar

PolyU-IITD temassız avuç içi veri seti, 600 farklı denekten elde edilen en büyük halka açık temassız avuç izi veri setidir (URL – 2). Sağ ve sol ellerin her birinden, farklı kameralarla iç ve dış ortam ortamlarında elde edilen on farklı avuç izi görüntüsü sunulmaktadır. Değerlendirmede model tüm sol avuç içi görüntülerini kullanarak eğitilmiştir ve model sağ avuç içi ile test edilmiştir. Karşılaştırmalı sonuçlar Şekil 6'da gösterilmiş ve ayrıca Tablo 3'te özetlenmiştir.


Bu tabloda görüldüğü üzere önerilen yöntem %2.48 EER değeri ile diğer yöntemlere kıyasla en düşük hata oranına sahiptir. Aynı zamanda %98.48 doğruluk oranı ile diğer yöntemlerden daha iyi bir genel performans sergilemektedir. GAR (FAR=10<sup>-3</sup>) değeri de %96.51 olarak oldukça yüksek bir seviyededir, bu da yöntemin düşük FAR seviyelerinde bile güvenilirliğini koruduğunu göstermektedir. Diğer yöntemler arasında Shao vd. (2019) ve Harun vd. (2017) de dikkat çekmektedir. Shao vd. (2019) %3.03 EER

değeri ve %96.39 doğruluk oranı ile iyi bir performans sergilemekte, ancak Önerilen Yöntem'in gerisinde kalmaktadır. Harun vd. (2017) %2.09 EER değeri ile oldukça düşük bir hata oranına sahiptir, ancak doğruluk oranı %97.31 ile Önerilen Yöntem'den daha düşüktür.

Tablo 3. PolyU-IITD veri tabanından elde edilen EER ve doğruluk oranları

| Yöntem                    | Doğruluk(%) | EER(%) | GAR (FAR=10 <sup>-3</sup> )(%) |
|---------------------------|-------------|--------|--------------------------------|
| Önerilen Yöntem           | 98.48       | 2.48   | 96.51                          |
| Harun vd. (2017)          | 97.31       | 2.09   | 95.36                          |
| Han vd. (2003)            | 93.26       | 4.75   | 91.39                          |
| Badrinath vd. (2011)      | 92.18       | 4.33   | 90.34                          |
| Matkowski vd. (2019)      | 93.36       | 4.84   | 91.49                          |
| Zhang vd. (2003)          | 91.27       | 5.17   | 89.44                          |
| Zhao ve Zhang (2019)      | 93.36       | 3.98   | 91.49                          |
| Liambas ve Tsouros (2007) | 93.73       | 4.42   | 91.86                          |
| Shao vd. (2019)           | 96.39       | 3.03   | 94.46                          |
| Zhang vd. (2020)          | 93.27       | 4.43   | 91.40                          |

Diğer yandan, Han vd. (2003), Badrinath vd. (2011) ve Zhang vd. (2003) en düşük performansı sergileyen yöntemlerdir. Bu yöntemler %4.75, %4.33 ve %5.17 gibi yüksek EER değerlerine sahip olup, doğruluk oranları da sırasıyla %93.26, %92.18 ve %91.27'dir. Bu sonuçlar, bu yöntemlerin hem yüksek hata oranları hem de düşük doğruluk oranları ile güvenilirlik konusunda yetersiz kaldığını göstermektedir.



a) ROC Eğrisi

b) CMC Eğrisi


Şekil 7. PolyU-IITD veritabanında farklı yöntemlerle edilen ROC ve CMC eğrileri.

Şekil 6’da sunulan verilere bakıldığında da Önerilen Yöntem ROC eğrisinde en iyi performansı göstermektedir. Bu yöntem, düşük FAR değerlerinde bile yüksek GAR değerlerini koruyarak, diğer yöntemlere göre üstün bir doğrulama yeteneğine sahip olduğunu kanıtlamaktadır. Özellikle FAR değerleri %10 ve altında olduğunda, GAR değeri %96’nın üzerinde kalmakta ve bu da yöntemin güvenilirliğini pekiştirmektedir.

### 3.3. CASIA Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar

CASIA temassız avuç içi izi veri seti 301 kişiden elde edilmiştir ve kamuya açık en büyük veri setlerinden biridir (Sun vd., 2005). Bu veri seti, özel bir cihaz kullanılarak kontrollü aydınlatma altında elde edilmiştir. Adil karşılaştırmalar sağlamak amacıyla, hepsi-hepsi protokollerini kullanan 300 farklı denekten gelen benzersiz görüntüler de kullanılmıştır. Karşılaştırmalı ROC eğrileri Şekil 7’de sunulurken Tablo 4, çalışmada dikkate alınan diğer rakip yöntemlerden elde edilen EER değerini özetlemektedir.

Grafikte görüldüğü üzere, Önerilen Yöntem ROC eğrisinde en iyi performansı sergilemektedir. Bu yöntem, düşük FAR değerlerinde bile yüksek GAR değerlerini koruyarak, diğer yöntemlere kıyasla üstün bir doğrulama yeteneğine sahip olduğunu kanıtlamaktadır. Özellikle FAR değerleri %10’un altında olduğunda, GAR değeri %95’in üzerinde kalmakta, bu da yöntemin güvenilirliğini göstermektedir. Harun vd. (2017) ve Shao vd. (2019) yöntemleri de ROC eğrisinde oldukça iyi performans göstermektedir. Bu yöntemler, FAR değerleri %20’nin altındayken %93 ve üzerinde GAR değerleri sunmaktadır. Ancak bu yöntemler, Önerilen Yöntem’e göre biraz daha düşük performans sergilemektedir.



Şekil 8. CASIA avuç içi veri tabanında farklı yöntemlerden elde edilen ROC ve CMC eğrileri.

CMC grafiğinde de yine Önerilen Yöntem Rank 1’de bile %97.28 doğruluk oranı ile en yüksek performansı göstermektedir. Rank değeri arttıkça doğruluk oranı da artmakta ve %98’e kadar ulaşmaktadır. Bu, yöntemin hem düşük hem de yüksek Rank değerlerinde güçlü bir performans sergilediğini göstermektedir. Harun vd. (2017) ve Shao vd. (2019) yöntemleri, CMC eğrisinde %95-96 doğruluk oranlarıyla diğer yöntemlere göre iyi performans göstermektedir. Ancak, bu yöntemlerin Rank 1’deki performansları Önerilen Yöntem’e göre daha düşüktür.

Tabloya bakıldığında ise Han vd. (2003) ve Zhao ve Zhang (2019) yöntemleri ise en düşük doğruluk oranlarını sergileyen yöntemlerdir. Bu yöntemlerin Rank 1’deki doğruluk oranları %92 civarında olup, diğer yöntemlerle karşılaştırıldığında daha düşük performans sergiledikleri görülmektedir.

Tablo 4. CASIA avuç içi veri tabanından elde edilen EER ve doğruluk oranları

| Yöntem                    | Doğruluk(%) | EER(%) | GAR (FAR=10 <sup>-3</sup> )(%) |
|---------------------------|-------------|--------|--------------------------------|
| Önerilen Yöntem           | 97.28       | 2.82   | 95.33                          |
| Harun vd. (2017)          | 95.56       | 3.74   | 93.65                          |
| Han vd. (2003)            | 92.07       | 4.85   | 90.23                          |
| Badrinath vd. (2011)      | 92.67       | 4.55   | 90.82                          |
| Matkowski vd. (2019)      | 92.96       | 4.80   | 91.10                          |
| Zhang vd. (2003)          | 93.54       | 4.03   | 91.67                          |
| Zhao ve Zhang (2019)      | 92.23       | 5.41   | 90.39                          |
| Liambas ve Tsouros (2007) | 94.46       | 4.15   | 92.57                          |
| Shao vd. (2019)           | 95.83       | 4.05   | 93.91                          |
| Zhang vd. (2020)          | 94.73       | 4.64   | 92.84                          |

Önerilen Yöntem, %2.82 EER değeri ile diğer yöntemlere kıyasla en düşük hata oranına sahiptir. Ayrıca %97.28 doğruluk oranı ile en yüksek performansı sergilemektedir. FAR = 10<sup>-3</sup> seviyesinde %95.33 GAR değeri elde edilmiş olup, bu da yöntemin düşük FAR seviyelerinde dahi yüksek doğruluk sunduğunu göstermektedir. Harun vd. (2017) ve Shao vd. (2019) yöntemleri de nispeten yüksek performans sergilemektedir. Harun vd. (2017) %3.74 EER değeri ile düşük hata oranı sunarken, doğruluk oranı %95.56’dır. Shao vd. (2019) ise %4.05 EER değeri ile biraz daha yüksek bir hata oranına sahipken, %95.83 doğruluk oranı sunmaktadır. En düşük performansı sergileyen yöntemler ise Han vd. (2003), Badrinath vd. (2011) ve Zhao ve Zhang (2019)


olmuştur. Bu yöntemlerin EER değerleri %4.85, %4.55 ve %5.41 olarak en yüksek seviyelerde olup, doğruluk oranları da %92 civarındadır. Bu sonuçlar, bu yöntemlerin güvenilirlik açısından daha düşük performans sergilediğini göstermektedir.

### 3.4. MPD Temassız Avuç İçi Veri Seti Üzerinde Çalışmalar

MPD veri seti, görüntüleri akıllı telefonlar kullanılarak elde edilen, iki oturumlu, çapraz sensörlü bir avuç içi izi veri setidir (Zhang vd. 2019). Hem sol hem de sağ elle 200 farklı kişiden toplam 16.000 görüntü barındırmaktadır ve her elden H (Huawei cep telefonu) ve M (Xiaomi cep telefonu) olarak adlandırılan iki tür akıllı telefon kullanarak 20 görüntü alınmıştır.

Çapraz sensör eşleştirme yeteneklerini belirlemek amacıyla, eğitim ve test için farklı cihazlardan ve farklı ellerden (eğitim için sol el ve test için sağ el) alınan görüntüleri kullanılmıştır. İlk olarak model H cihazından ilk oturumun soldaki görüntülerini kullanarak eğitilmiştir ve ardından ilk oturumun görüntülerinin H cihazından alındığı iki oturumlu protokolü kullanarak ikinci oturumun M cihazından alınan sağ görüntülerinde model test edilmiştir. Tablo 5 ve Şekil 8'deki grafiklerde özetlenen göstergeler, çapraz sensörlü temassız avuç içi görüntülerinin eşleştirilmesinde doğrulukta önemli bir iyileşme olduğunu göstermektedir.

Şekil 5'te görüldüğü gibi, Önerilen Yöntem ROC eğrisinde en iyi performansı sergilemektedir. FAR değerlerinin düşük olduğu durumlarda bile GAR değerlerinin yüksek kalması, bu yöntemin doğruluk ve güvenilirlik açısından üstün olduğunu göstermektedir. Özellikle FAR %10 civarındayken bile GAR değerinin %90'ın üzerinde kalması, yöntemin etkinliğini vurgulamaktadır. Shao vd. (2019) ve Matkowski vd. (2019) yöntemleri de iyi performans göstermektedir. Bu yöntemler de %20'nin altında FAR değerlerine ulaştıklarında GAR değerlerini %85'in üzerinde tutmaktadır. Ancak bu yöntemlerin eğrileri, Önerilen Yöntem'in eğrisinin altında kalmakta ve daha düşük doğruluk oranları sergilemektedir. Han vd. (2003) ve Zhao ve Zhang (2019) gibi yöntemler ROC eğrisinde en düşük performansı sergileyen yöntemlerdir. Bu yöntemlerin eğrileri, düşük FAR değerlerinde bile GAR değerlerinin düşük kaldığını, yani yanlış kabul oranlarının yüksek olduğunu göstermektedir. Bu da bu yöntemlerin düşük doğruluk oranlarına sahip olduğunu gösterir.



a) ROC Eğrisi

b) CMC Eğrisi

Şekil 9. MPD veritabanından elde edilen ROC ve CMC eğrileri.

CMC grafiğinde ise Rank 1'de %93.86 doğruluk oranı elde eden bu yöntem, Rank arttıkça performansını %94 seviyelerine kadar çıkarabilmektedir. Bu, yöntemin yüksek doğruluk oranları ile diğer yöntemlere kıyasla daha üstün olduğunu göstermektedir. Shao vd. (2019) yöntemi de %91.41 doğruluk oranı ile dikkat çekmektedir ve Rank arttıkça doğruluk oranı da artmaktadır. Ancak bu yöntem, Rank 1'de Önerilen Yöntem'in gerisinde kalmaktadır. Matkowski vd. (2019) yöntemi de benzer şekilde iyi performans sergilemekte ancak doğruluk oranı %90.47 seviyesindedir.

Tablo 5'te gösterilen EER ve doğruluk oranlarına göre önerilen yöntem, %4.95 EER değeri ile en düşük hata oranına sahiptir ve %93.86 doğruluk oranı ile diğer yöntemlerden daha iyi bir performans sergilemektedir.

Tablo 5. MPD veritabanından elde edilen EER ve doğruluk değerleri

| Yöntem                    | Doğruluk(%) | EER(%) | GAR (FAR=10 <sup>-3</sup> )(%) |
|---------------------------|-------------|--------|--------------------------------|
| Önerilen Yöntem           | 93.86       | 4.95   | 91.98                          |
| Harun vd. (2017)          | 88.18       | 6.91   | 86.42                          |
| Han vd. (2003)            | 77.56       | 11.90  | 76.01                          |
| Badrinath vd. (2011)      | 88.36       | 6.52   | 86.59                          |
| Matkowski vd. (2019)      | 90.47       | 4.99   | 88.66                          |
| Zhang vd. (2003)          | 85.43       | 7.63   | 83.72                          |
| Zhao ve Zhang (2019)      | 87.61       | 8.16   | 85.86                          |
| Liambas ve Tsouros (2007) | 89.66       | 5.31   | 87.87                          |
| Shao vd. (2019)           | 91.41       | 4.46   | 89.58                          |
| Zhang vd. (2020)          | 87.38       | 7.69   | 85.63                          |


Tablodan görüldüğü üzere yine GAR ( $FAR=10^{-3}$ ) değeri de %91.98 olarak oldukça yüksektir, bu da yöntemin düşük FAR seviyelerinde bile yüksek doğruluk sunduğunu göstermektedir. Shao vd. (2019) yöntemi %4.46 EER değeri ile oldukça iyi bir hata oranı sunmakta ve %91.41 doğruluk oranı ile yüksek bir başarı sergilemektedir. Matkowski vd. (2019) da %4.99 EER ve %90.47 doğruluk oranı ile iyi bir performans göstermektedir. En düşük performansı sergileyen yöntemler ise Han vd. (2003) ve Zhao ve Zhang (2019) olmuştur. Han vd. (2003), %11.90 EER değeri ile en yüksek hata oranına sahip olup, doğruluk oranı da %77.56 ile oldukça düşük seviyededir. Bu sonuçlar, bu yöntemin güvenilirlik açısından diğer yöntemlerden oldukça geride kaldığını göstermektedir.



## 4. SONUÇLAR VE TARTIŞMA

### 4.1. Hesaplama Açısından Verimli Özellik Çıkarma

Bu tez çalışması Yulin ve Kumar (2023) çalışmasındaki metodoloji kullanılarak gerçekleştirilmiştir. Dolayısıyla deneyler ve sonuçlar benzer şekilde ele alınarak irdelenmiştir. Deneyler sırasında, 4 adım bir süreç kullanılmıştır ve basit ağ modelinde, ilk dört katman giriş görüntüsünü orijinal boyutun 1/4 'üne indirilmektedir. Bu nedenle, tam görüntü ağı girdi olarak verilmiştir ve 4. evrişim katmanından çıktı hesaplanmıştır. Böylece seçilen tüm alt bölgelerin özellikleri üretilebilmiştir. Şekil 9 bu gösterimi sunmaktadır. Orijinal avuç içi görüntüsünden (mavi kare) alt bölge A (kırmızı kare) seçilmiştir, ardından 4 piksel sağa ve 4 piksel aşağı kaydırarak alt bölge B (yeşil kare) seçilmiştir. Katman – 1 ve katman – 2 için evrişim adımını sırasıyla 2 ve 1 olarak ayarlandığında, özellik boyutunu orijinal boyutun 1/2'sine indirilmiştir ve ardından alt bölge A ve B'nin özelliklerini aynı anda hesaplanabilmiştir. Alt bölge A ve B'nin özellikleri arasında yatay ve dikey olarak 2 piksel kayma vardır. Sonraki, üçüncü ve dördüncü evrişim katmanları katman – 3 ve katman – 4'ten sonra, özellik boyutunu orijinal boyutu 1/4' 'üne indirilmiştir; bu nedenle, alt bölge A ve B'nin özellikleri arasında yatay ve dikey olarak 1 piksel kayma olacaktır.



Şekil 10. Farklı alt bölgelerden üretilen özellik vektörünün gösterimi (Yulin ve Kumar, 2023)

Sonuç olarak, tüm seçilen alt bölgelerin özelliklerini aynı anda hesaplanabilmektedir. Daha sonra tüm alt bölgelerin özellikleri seçilip doğrudan son üç katmana besleyerek, avuç içi görüntüsündeki her seçilen alt bölge için nihai özellik vektörleri elde edilmiştir.

Daha spesifik olarak, deneyler sırasında tüm avuç içi görüntüleri yeniden boyutlandırılmış ve tüm deneylerde tüm alt bölgelerin boyutu ampirik olarak

sabitlenmiştir. Tanıma veya eşleştirme sırasında, orijinal avuç içi görüntüsü girilmiştir ve ilk dört evrişim katmanından sonra bir özellik elde edilmiştir, ardından tüm alt bölge özelliklerini oluşturmak için pencere kaydırması yapılmıştır. Diğer yandan, seçilen alt bölgeler ayrı ayrı hesaplanırsa, her seferinde 289 kez hesaplama yapılması gerekmektedir.

#### 4.2. Hesaplama Karmaşıklığı Üzerine Analiz

Hesaplama karmaşıklığı, biyometrik doğrulama sistemlerinin gerçek zamanlı uygulanabilirliğini ve kullanıcı memnuniyetini doğrudan etkileyen bir faktördür. Tablo 6'ya göre, Önerilen Yöntem hem özellik çıkarımı hem de eşleştirme süresi açısından açık ara en verimli yöntemdir. Bu düşük süreler, Önerilen Yöntem'in düşük hesaplama karmaşıklığına sahip olduğunu ve büyük veri setleri ile çalışırken dahi yüksek hız ve verimlilik sunduğunu göstermektedir.

Tablo 6. IITD veri setinde ortalama özellik çıkarma ve eşleştirme süreleri

| Yöntem                    | Özellik Çıkarımı (ms) | Eşleştirme (ms) |
|---------------------------|-----------------------|-----------------|
| Önerilen Yöntem           | 0.31                  | 0.015           |
| Harun vd. (2017)          | 2.30                  | 0.137           |
| Han vd. (2003)            | 1.20                  | 0.055           |
| Badrinath vd. (2011)      | 1.18                  | 0.041           |
| Matkowski vd. (2019)      | 1.23                  | 0.061           |
| Zhang vd. (2003)          | 2.01                  | 0.315           |
| Zhao ve Zhang (2019)      | 1.21                  | 0.248           |
| Liambas ve Tsouros (2007) | 1.71                  | 0.153           |
| Shao vd. (2019)           | 7.30                  | 0.885           |
| Zhang vd. (2020)          | 0.87                  | 0.072           |

Tablo 6'da yer alan IITD veri setinde ortalama özellik çıkarma ve eşleştirme süreleri, farklı yöntemlerin hesaplama karmaşıklığı ve verimliliği üzerine önemli bilgiler sunmaktadır. Özellik çıkarımı ve eşleştirme süreleri, biyometrik doğrulama sistemlerinde işlem hızını ve dolayısıyla gerçek zamanlı uygulamalardaki uygunluğunu etkileyen temel faktörlerdir. Özellik çıkarımı süresi, biyometrik verilerden anlamlı özelliklerin elde edilmesi için harcanan zamanı ifade eder. Bu süre ne kadar kısa olursa, sistemin genel performansı ve kullanıcı deneyimi o kadar iyi olacaktır. Tabloya göre, Önerilen Yöntem özellik çıkarımı açısından en verimli yöntemdir ve yalnızca 0.31 milisaniye (ms) süre ile

diğer yöntemlere kıyasla belirgin bir şekilde daha hızlıdır. Bu sonuç, Önerilen Yöntem'in düşük hesaplama karmaşıklığına sahip olduğunu ve büyük veri setlerinde bile yüksek hızda çalışabildiğini göstermektedir. Diğer yöntemlerle karşılaştırıldığında, Harun vd. (2017) ve Zhang vd. (2003) yöntemleri sırasıyla 2.30 ms ve 2.01 ms ile en yavaş özellik çıkarımı sürelerine sahiptir. Bu yöntemlerin daha uzun süre gerektirmesi, özellik çıkarma aşamasında daha yüksek hesaplama karmaşıklığına ve dolayısıyla daha fazla işlem yüküne işaret eder. Shao vd. (2019) yöntemi ise 7.30 ms ile en yavaş özellik çıkarımı süresine sahip olup, bu da bu yöntemin gerçek zamanlı uygulamalar için uygun olmadığını ve yüksek hesaplama kaynaklarına ihtiyaç duyduğunu göstermektedir.


Eşleştirme süresi, çıkarılan özelliklerin veri tabanındaki diğer örneklerle karşılaştırılması için harcanan zamanı ifade eder. Düşük eşleştirme süreleri, sistemin hızlı ve verimli bir şekilde çalışmasını sağlar. Tabloda, Önerilen Yöntem aynı zamanda en hızlı eşleştirme süresine sahip olup, 0.015 ms ile diğer yöntemlere kıyasla belirgin bir üstünlük göstermektedir. Bu, Önerilen Yöntem'in sadece özellik çıkarımında değil, aynı zamanda eşleştirme aşamasında da düşük hesaplama karmaşıklığına sahip olduğunu ortaya koyar. Buna karşın, Zhang vd. (2003) ve Shao vd. (2019) yöntemleri sırasıyla 0.315 ms ve 0.885 ms eşleştirme süreleri ile en yavaş yöntemlerdir. Bu yöntemlerin yüksek eşleştirme süreleri, özellikle büyük veri tabanlarında performansın önemli ölçüde düşebileceğini ve işlem süresinin uzayabileceğini gösterir.

Sonuç olarak, Önerilen Yöntem'in düşük hesaplama karmaşıklığı sayesinde hem işlem hızını artırarak hem de sistem performansını iyileştirerek biyometrik doğrulama sistemlerinde kullanılmak üzere güçlü bir aday olduğu anlaşılmaktadır. Diğer yöntemler ise çeşitli derecelerde başarılı olmasına rağmen, hesaplama karmaşıklığı ve hız açısından Önerilen Yöntem'in gerisinde kalmaktadır. Bu durum, Önerilen Yöntem'in özellikle yüksek performans gerektiren uygulamalarda tercih edilmesi gerektiğini göstermektedir.

#### **4.3. Derin Ağ Modellerinin Özellik Çıkarma Analizleri**

Deneylerde birkaç popüler derin sinir ağı kullanılmış ve sonunda basitleştirilmiş veya temel bir ESA mimarisi seçilmiştir. Bu yöntemlerle karşılaştırmalı performans değerlendirmeleri gerçekleştirilmiştir. Özellik çıkarma modelleri bazı popüler ağ modelleriyle karşılaştırılmıştır: Tamamen Evrişimli Ağ (FCN), Artık Ağ (ResNet), MobileNetv3 ve DenseNet. Bu modellerden elde edilen değerler Şekil 11 ve Tablo 7'de sunulmuştur.

Şekil 11'deki ROC eğrisi, modellerin performansını FAR ile GAR arasındaki ilişkiye göre değerlendirir. Grafikte görüldüğü gibi, Önerilen Yöntem eğrisi en üstte yer almakta ve diğer modellerden daha iyi bir performans sergilemektedir. MobileNetv3 (large) modeli de bu grafikte Önerilen Yöntem'e yakın bir performans sergileyerek öne çıkmaktadır. CMC eğrisi ise Rank bazında modellerin doğruluk performansını gösterir. Burada da Önerilen Yöntem en yüksek doğruluk oranını sergilemekte olup, diğer tüm modellerden daha iyi sonuçlar elde etmektedir. Bu durum, Önerilen Yöntem'in yüksek doğruluk oranı ile birlikte istikrarlı bir şekilde doğru kararlar verebildiğini göstermektedir.



Şekil 11. Farklı derin öğrenme modellerinden elde edilen ROC ve CMC eğrisi

Tablo 7'deki verilere göre, Önerilen Yöntem yalnızca 0.10 milyon (M) parametre ile diğer tüm modellerden daha az parametreye sahiptir. Bu, modelin hesaplama açısından oldukça verimli olduğunu ve düşük kaynak gereksinimi ile yüksek performans sunduğunu göstermektedir. Önerilen Yöntem, bu kadar az parametre ile %99.57 doğruluk oranına ve %0.35 EER değerine ulaşarak dikkate değer bir başarı göstermektedir. Diğer taraftan, ResNet34 ve DenseNet169 modelleri sırasıyla 21.8 M ve 14.15 M parametreye sahiptir. Bu modeller daha fazla hesaplama kaynağı gerektirmekte, ancak parametre sayılarının artmasına rağmen Önerilen Yöntem'in doğruluk oranına ulaşamamaktadır. Özellikle DenseNet121 ve DenseNet169 modelleri, yüksek parametre sayılarına rağmen doğruluk oranlarında ve GAR değerlerinde Önerilen Yöntem'e kıyasla daha düşük performans sergilemektedirler. MobileNetv3 (small) ve MobileNetv3 (large) modelleri, sırasıyla 2.54 M ve 5.48 M parametre ile orta seviyede bir hesaplama karmaşıklığına sahiptir. Ancak, bu modeller yüksek doğruluk ve düşük EER değerleri sunarak, özellikle MobileNetv3

(large) modelinin %95.72 doğruluk oranı ve %1.23 EER değeri ile oldukça başarılı bir performans sergilediği görülmektedir. FCN (Fully Convolutional Network) modeli ise 1.64 M parametre ile orta düzey bir karmaşıklığa sahiptir, ancak doğruluk oranı %94.41 ve EER değeri %3.66 olarak, Önerilen Yöntem'e kıyasla daha düşük performans göstermektedir.

Tablo 7. Farklı derin öğrenme modellerinden elde edilen EER ve doğruluk değerleri

| Modeller            | Parametre Sayısı | Doğruluk(%) | EER(%) | GAR (FAR=10 <sup>-3</sup> )(%) |
|---------------------|------------------|-------------|--------|--------------------------------|
| Önerilen Yöntem     | 0.10 M           | 99.57       | 0.35   | 97.58                          |
| ResNet18            | 11.7 M           | 93.53       | 3.21   | 76.79                          |
| ResNet34            | 21.8 M           | 94.88       | 3.02   | 81.06                          |
| DenseNet121         | 7.98 M           | 91.17       | 4.12   | 64.15                          |
| DenseNet169         | 14.15 M          | 94.28       | 1.56   | 77.12                          |
| Mobilenetv3 (small) | 2.54 M           | 92.45       | 1.89   | 83.65                          |
| Mobilenetv3 (large) | 5.48 M           | 95.72       | 1.23   | 88.26                          |
| FCN                 | 1.64 M           | 94.41       | 3.66   | 70.02                          |

Önerilen Yöntem en yüksek doğruluk oranına (%99.57) ve en düşük EER değerine (%0.35) sahip olup, düşük FAR seviyelerinde bile %97.58 gibi yüksek bir GAR değeri sunmaktadır. Bu, modelin doğru karar verme kabiliyetinin çok yüksek olduğunu ve yanlış kabul oranını minimum seviyede tuttuğunu göstermektedir. MobileNetv3 (large) modeli, %95.72 doğruluk oranı ve %1.23 EER değeri ile Önerilen Yöntem'den sonra en başarılı model olarak öne çıkmaktadır. Bu model, nispeten düşük parametre sayısı ile hem yüksek doğruluk hem de düşük hata oranı sunarak, hesaplama kaynaklarının etkin bir şekilde kullanılabilmesini göstermektedir. ResNet34 ve DenseNet169 modelleri, diğer modellere göre daha yüksek parametre sayılarına sahip olmalarına rağmen, doğruluk oranlarında sadece orta düzeyde bir artış sağlamak ve EER değerleri Önerilen Yöntem'e göre daha yüksektir. Bu durum, daha fazla parametre eklemenin her zaman daha iyi performans sağlamadığını ve hesaplama karmaşıklığının artmasıyla birlikte verimliliğin de düşebileceğini göstermektedir. DenseNet121 ve ResNet18 modelleri, en düşük doğruluk oranlarına (%91.17 ve %93.53) sahip olup, EER değerleri sırasıyla %4.12 ve %3.21 olarak hesaplanmıştır. Bu, bu modellerin yüksek hesaplama kapasitesine rağmen,

daha düşük performans gösterdiğini ve belki de bu görev için fazla optimize edilmemiş olduğunu göstermektedir.

Derin öğrenme modellerinin özellik çıkarım analizi sonucunda, Önerilen Yöntem hem düşük parametre sayısı ile düşük hesaplama karmaşıklığı sunmakta hem de yüksek doğruluk oranı ve düşük EER değeri ile performans açısından diğer modellerden üstün olduğu görülmektedir. Özellikle, MobileNetv3 (large) modeli, düşük parametre sayısı ve yüksek doğruluk oranı ile hesaplama kaynaklarının etkin bir şekilde kullanılabileceğini göstermekte ve Önerilen Yöntem'den sonra en güçlü aday olarak öne çıkmaktadır. Diğer modeller ise daha fazla parametreye sahip olmalarına rağmen, verimlilik ve performans açısından Önerilen Yöntem'e kıyasla daha düşük kalmaktadırlar. Bu durum, derin öğrenme modellerinde parametre sayısının artırılmasının her zaman performans artışı ile sonuçlanmayacağını ve modellerin spesifik görevler için optimize edilmesinin önemini vurgulamaktadır.

#### **4.4. Başarısız Örnek Durumları**


IITD veri seti üzerinde uygulanan birini dışarıda bırak protokolü ile elde edilen ortalama doğruluk %99.57 olarak tespit edilmiştir. Bu doğruluk oranı, veri setindeki beş görüntünün doğru bir şekilde tanımlanamadığı anlamına gelmektedir. Bu beş görüntü, özellikle tanımlanamayan görüntüler olarak belirlenmiş ve Şekil 12'de görsel olarak sunulmuştur. Bu görüntülerin her biri için, ilgili deneğin beş farklı görüntüsü yeniden üretilmiş ve bu görüntülerden elde edilen veriler analiz edilmiştir. Görsel olarak incelendiğinde, tüm bu başarısız tanıma durumlarının, görüntülerin yanlış bölütlenmesinden kaynaklandığı anlaşılmaktadır. Yanlış bölütleme, bu görüntülerin doğru bir şekilde tanımlanmasını engellemiştir.

Bu noktada önemli olan bir başka husus, halka açık bu veri tabanındaki söz konusu beş ROI (Region of Interest) görüntüsü dışında, önerilen yaklaşımın diğer tüm avuç içi görüntülerini doğru bir şekilde tanımlayabilmesidir. Bu, modelin genel performansının oldukça yüksek olduğunu ve yalnızca belirli hatalı veri örneklerinde sorun yaşadığını ortaya koymaktadır.

DeneySEL sonuçlara ek olarak, önceki çalışmaların sonuçları da gözlemlenmiş ve bu çalışmaların da aynı beş görüntüyü yanlış tanımladığı belirlenmiştir. Bu durum, önceki yöntemlerin sınırlamalarını ortaya koymaktadır. Tüm bu yöntemler, avuç içi görüntülerinin tanınmasında önce ikili özellik örnek şablonları oluşturmuş ve ardından bu şablonları kayıtlı şablonlarla karşılaştırmıştır. Ancak, yanlış kesilmiş bu görüntüler,

önceki yöntemlerle de doğru bir şekilde tanımlanamamıştır. Sonuç olarak, bu hatalı kesimlerin sebep olduğu tanıma zorlukları, hem mevcut çalışmada hem de önceki yöntemlerde ortak bir sorun olarak karşımıza çıkmaktadır.

Özetle, önerilen model, IITD veri setinde neredeyse en yüksek doğruluk oranına ulaşmış ve avuç içi görüntülerinin büyük çoğunluğunu doğru bir şekilde tanımlayabilmiştir. Bu sonuçlar, önerilen modelin genel doğruluk açısından oldukça başarılı olduğunu ve sadece belirli hatalı veri örneklerinde performans düşüklüğü yaşadığını göstermektedir. Dolayısıyla, önerilen model, özellikle bu tür hatalı bölütleme sorunları giderildiğinde, daha da yüksek performans potansiyeline sahip olabilir.



Şekil 12. IITD veri tabanlarındaki başarısızlık durumları (Yulin ve Kumar, 2023)

## 5. ÖNERİLER

Bu tez çalışmasında, önerilen yöntemin etkinliğini doğrulamak amacıyla dört halka açık veri tabanı kullanılarak hem veri tabanı içi hem de veri tabanları arası deney sonuçları sunulmuştur. Önerilen yöntem, sınırlı sayıda avuç içi verisinin mevcut olduğu durumlarda ve temassız görüntüleme sürecinde meydana gelen istemsiz görüntü değişikliklerinin yol açtığı zorlukları başarılı bir şekilde ele alabilmektedir. Çalışmada sunulan deney sonuçları, özellikle zorlu tümünden tümüne protokoller kullanılarak gerçekleştirilen testlerde, önerilen yöntemin mevcut temassız avuç içi eşleştirme yöntemlerine kıyasla çok daha doğru sonuçlar verdiğini ve önemli ölçüde daha hızlı çalıştığını ortaya koymaktadır. Bu bulgular, yöntemin temassız avuç içi biyometrisi alanında dikkate değer bir alternatif sunduğunu göstermektedir.

Bu çalışma, temassız avuç içi biyometrisi alanında önemli katkılar sağlamış olsa da, gelecekteki araştırmalar için önerilebilecek birkaç ileriye dönük düşünce ve öneri sunulabilir:

a) Veri Setlerinin Çeşitlendirilmesi ve Artırılması: Çalışmada kullanılan veri setleri dört halka açık veri tabanı ile sınırlı kalmıştır. Gelecek araştırmalarda, daha geniş bir veri seti yelpazesi kullanılarak yöntemin farklı koşullarda ve farklı popülasyonlar üzerindeki performansı değerlendirilebilir. Ayrıca, veri setlerine farklı etnik kökenler, yaş grupları ve cinsiyetler eklenerek, yöntemin genelleme kabiliyeti test edilebilir.

b) Gerçek Zamanlı Uygulama ve Entegrasyon: Bu çalışmada önerilen yöntem, doğruluk ve hız açısından üstün performans sergilese de, gerçek zamanlı uygulamalarda nasıl entegre edilebileceği ve performansının ne olacağı konusunda daha fazla araştırma yapılabilir. Örneğin, yöntemin mobil cihazlar veya giyilebilir teknolojilerle entegrasyonu üzerinde durulabilir. Gerçek zamanlı sistemlerde işlem süresinin ve enerji verimliliğinin optimize edilmesi, yöntemin pratik kullanıma daha uygun hale gelmesini sağlayabilir.

c) Diğer Biyometrik Modlarla Entegrasyon: Çalışmanın ileriye dönük bir parçası olarak, önerilen yöntemin diğer temassız biyometrik modlarla, örneğin göz, iris, veya yüz tanıma sistemleriyle entegrasyonunun araştırılması önerilebilir. Multimodal biyometrik sistemlerin geliştirilmesi, güvenlik ve doğruluk açısından daha güçlü çözümler sunabilir. Bu bağlamda, yöntemlerin kombinasyonu ile elde edilecek performans artışları ve potansiyel zorluklar incelenmelidir.

d) Yapay Zeka ve Makine Öğrenimi Tekniklerinin İyileştirilmesi: Bu çalışma, derin öğrenme modellerinin biyometrik tanımadaki rolünü vurgulamaktadır. Gelecek

alışmalar, daha gelişmiş yapay zeka ve makine öğrenimi algoritmaları kullanarak önerilen yöntemin performansını daha da artırmayı hedefleyebilir. Özellikle, transfer öğrenme, evrişimsel sinir ağıları (CNN) ve attention mekanizmaları gibi ileri teknikler kullanılarak yöntemin doğruluğı ve verimliliğı artırılabilir.

e) Güvenlik ve Gizlilik İyileştirmeleri: Temassız biyometrik sistemlerde güvenlik ve gizlilik konuları önemlidir. Gelecek alışmalar, önerilen yöntemin güvenlik açısından nasıl daha sağlam hale getirilebileceğini araştırabilir. Özellikle, biyometrik şablonların güvenli bir şekilde saklanması, veri koruma mekanizmalarının geliştirilmesi ve sahteciliğe karşı koruma yöntemlerinin entegrasyonu, gelecekteki araştırmalar için önemli bir odak noktası olabilir.

f) Kullanıcı Deneyimi ve Ergonomi Araştırmaları: Yöntemin kullanıcı dostu olup olmadığını değerlendirmek için, kullanıcı deneyimi ve ergonomi alışmaları yapılabilir. Kullanıcı geri bildirimleri toplanarak, yöntemin pratik uygulamalar sırasında ne kadar kolay kullanılabil-diğı, doğruluk ve hız açısından kullanıcı beklentilerini ne derece karşıladığı incelenebilir. Bu araştırmalar, yöntemin son kullanıcılar için optimize edilmesine katkı sağlayabilir.

g) Farklı Aydınlatma ve Çevresel Koşullarda Performans Testi: Önerilen yöntem, temassız avuç içi görüntülerini işlediğı için, farklı aydınlatma koşulları ve çevresel faktörlerin yöntemin performansını nasıl etkilediğı araştırılabilir. Örneğin, düşük ışııkta veya yüksek parlaklıkta çekilen görüntülerin tanınma oranları incelenebilir. Bu tür alışmalar, yöntemin daha dayanıklı ve çevresel koşullardan bağımsız hale getirilmesine yardımcı olabilir.

## KAYNAKÇA

- Aykut, M. ve Ekinçi, M. (2013). AAM-based palm segmentation in unrestricted backgrounds and various postures for palmprint recognition. *Pattern Recognition Letters*, 34(9), 955-962
- Aykut, M. ve Ekinçi, M. (2015). Developing a contactless palmprint authentication system by introducing a novel ROI extraction method. *Image and Vision Computing*, 40, 65-74
- Badrinath, G. ve Gupta, P. (2012). Palmprint based recognition system using phase-difference information. *Future Generation Computer Systems*, 28(1), 287-305.
- Badrinath, G., Kachhi, N. K., ve Gupta, P. (2011). Verification system robust to occlusion using low-order Zernike moments of palmprint sub-images. *Telecommunication Systems*, 47, 275-290.
- Bao, X., ve Guo, Z. (2016). Extracting region of interest for palmprint by convolutional neural networks. In *Proceedings of the International Conference on Image Processing Theory, Tools and Applications (IPTA'16)*, New York.
- Bingöl, Ö., ve Ekinçi, M. (2017). Stereo-based palmprint recognition in various 3D postures. *Expert Systems with Applications*, 78, 74-88.
- Borgefors, G. (1986). Distance transformations in digital images. *Computer Vision, Graphics and Image Processing*, 34, 344-371.
- Chai, T., Wang, S. ve Sun, D. (2017). A palmprint ROI extraction method for mobile devices in complex environment. In *Proceedings of IEEE 13th International Conference on Signal Processing (ICSP'16)*.
- Connie, T., Jin, A. T. B., Ong, M. G. K., ve Ling, D. N. C. (2005). An automated palmprint recognition system. *Image and Vision Computing*, 23(5), 501-515.
- Cootes TF, Edwards G. ve Taylor C. (2001). Active appearance models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 23(6), 681-685.
- Daugman, J. (2004). How iris recognition works. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1), 21-30.
- Franzgrote, M., Borg, C., Ries, B. J. T. ve Büsselmeier, S. (2011). Palmprint verification on mobile phones using accelerated competitive code. In *Proceedings of 2011 International Conference on Hand-Based Biometrics (ICHB'11)*, New York, IEEE.

- Gao, X. ve Wang, Y. (2016). Dynamic ROI selection for palmprint recognition. *Pattern Recognition*, 58, 87-96.
- Gao F, Cao K, Lu L. ve Yuan Y. (2018). Mobile palmprint segmentation based on improved active shape model. *Journal of Multimedia Information System*. 5(4), 221-228,
- Genovese, A., Piuri, V., Plataniotis, K. ve Scotti, F. (2019). PalmNet: Gabor-PCA convolutional networks for touchless palmprint recognition. *IEEE Transactions on Information Forensics and Security*, 14(12), 3160-3174.
- Han, C. C., Cheng, H. L., Lin, C. L. ve Fan, K. C. (2003). Personal authentication using palm-print features. *Pattern recognition*, 36(2), 371-381
- Han, Y., Sun, Z., Wang, F. ve Tan, T. (2007). Palmprint recognition under unconstrained scenes. In *Lecture Notes in Computer Science (ACCV'07)* (pp. 1-11). Berlin, Springer.
- Hao Y, Sun Z, Tan T. ve Ren C. (2008) Multispectral palm image fusion for accurate contact-free palmprint recognition. In: *Proceedings of the IEEE International Conference on Image Processing (ICIP'08)*, 12-15 October, 2008, San Diego, California, USA. , ss. 281-284.
- Harun, N., Abd Rahman, W. E. Z. W., Abidin, S. Z. Z. ve Othman, P. J. (2017, September). New algorithm of extraction of palmprint region of interest (ROI). In *Journal of Physics: Conference Series*, 890(1), IOP Publishing.
- Ito K, Sato T, Aoyama S, Sakai S, Yusa S. ve Aoki T. (2015). Palm region extraction for contactless palmprint recognition. In: *International Conference on Biometrics (ICB'15)*, 19-22 May 2015, Phuket, Thailand. ss. 334-340.
- Jain, A. K. ve Feng, J. (2011). Latent palmprint matching. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 33(1), 137-143.
- Jain, A. K., Bolle, R. ve Pankanti, S. (1999). *Biometrics: Personal identification in networked society*. Springer Science ve Business Media.
- Jain, A. K., Ross, A. ve Prabhakar, S. (2004). An introduction to biometric recognition. *IEEE Transactions on Circuits and Systems for Video Technology*, 14(1), 4-20.
- Jia, W., Hu, R. X., Gui, J., Zhao, Y., ve Ren, X. M. (2012). Palmprint recognition across different devices. *Sensors* ,12(6), 7938-7964.
- Jiang, X., ve Yau, W. Y. (2000). Fingerprint minutiae matching based on the local and global structures. *Proceedings of the International Conference on Pattern Recognition*, ss. 1042-1045.

- Kim, H., Park, H. ve Kim, J. (2009). Geometric transformation and normalization techniques in palmprint recognition. *Image and Vision Computing*, 27(9), 1243-1251.
- Kumar, A. (2008). Incorporating cohort information for reliable palmprint authentication. In Proceedings of the Indian Conference on Computer Vision, Graphics ve Image Processing (ICVGIP'08) New York, ss. 583-590.
- Kumar, A. ve Zhang, D. (2006). Hand-geometry recognition using entropy-based discretization. *IEEE Transactions on Information Forensics and Security*, 1(2), 181-187.
- Kumar, A., Wong, D. C. M., Shen, H. C. ve Jain, A. K. (2009). Personal authentication using hand vein triangulation and knuckle shape. *IEEE Transactions on Image Processing*, 18(9), 2127-2136.
- LeCun Y, Bottou L, Bengio Y. ve Haffner P. (1998) Gradient-based learning applied to document recognition. Proceedings of the IEEE. 86(11), ss. 2278-2324
- Lee, T. ve Höllerer, T. (2007). Handy AR: Markerless inspection of augmented reality objects using fingertip tracking. In Proceedings of the 11th IEEE International Symposium on Wearable Computers (ISWC '07), New York: IEEE, ss. 83-90.
- Leng, L., Liu, G., Li, M., Khan, K. M. ve Al-Khoury, M. A. (2014). Logical conjunction of triple-perpendicular-directional translation residual for contactless palmprint preprocessing. In Proceedings of International Conference on Information Technology: New Generations (ITNG'14), New York.
- Li, W., Zhang, B., Zhang, L. ve Yan, J. (2012). Principal line-based alignment refinement for palmprint recognition. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 42(6), 1491-1499.
- Liambas, C. ve Tsouros, C. (2007). An algorithm for detecting hand orientation and palmprint location from a highly noisy image. In 2007 IEEE International Symposium on Intelligent Signal Processing, ss. 1-6.
- Liang, L., Gao, X. ve Wang, Y. (2017). Deep learning for palmprint recognition: A survey. *IEEE Access*, 5, 21741-21747.
- Liang, X., Zhang, D., Lu, G., Guo, Z. ve Luo, N. (2019). A novel multicamera system for high-speed touchless palm recognition. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. <http://doi.org/10.1109/TSMC.2019.2898684>
- Lin, C.-L., Chuang, T. C. ve Fan, K.C. (2005). Palmprint verification using hierarchical decomposition. *Pattern Recognition*, 38(12), 2639-2652.

- Liu, F., Zhang, D. ve Shen, L. (2019). Towards robust palmprint verification: A review. *Pattern Recognition*, 93, 30-42.
- Ma, S., Hu, Q., Zhao, S., Chen, S. ve Jiang, L. (2024). SYEnet: Simple yet effective network for palmprint recognition. *Information Sciences*, 669, 120518.
- Maltoni, D., Maio, D., Jain, A. K. ve Prabhakar, S. (2009). Handbook of fingerprint recognition. Springer Science ve Business Media.
- Matkowski W., M., Chai, T. ve Kong W.,K.,A. (2020). Palmprint recognition in uncontrolled and uncooperative environment. *IEEE Transactions on Information Forensics and Security*. 15, ss. 1601-1615
- Michael, G. K. O., Connie, T., ve Jin, A. T. B. (2008). Touch-less palmprint biometrics: Novel design and implementation. *Image and Vision Computing*, 26(12), 1551-1560.
- Moço, N. F. (2014). Smartphone-based palmprint recognition system. In Proceedings of International Conference on Telecommunications (ICT'14), New York, (ss. 457-461).
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-9(1), 62-66.
- Ross, A., ve Jain, A. K. (2004). Multimodal biometrics: An overview. Proceedings of 12th European Signal Processing Conference (EUSIPCO), 4, 1221-1224.
- Rother, C., Kolmogorov, V. ve Blake, A. (2004). "GrabCut" interactive foreground extraction using iterated graph cuts. *ACM Transactions on Graphics*, 23(3), 309-314.
- Shang, L., Chen, J., Su, P.G. ve Zhou, Y. (2012). ROI extraction of palmprint images using modified Harris corner point detection algorithm. In Proceedings of the 8th International Conference on Intelligent Computing Theories and Applications (ICIC'12), Berlin, Heidelberg, ss. 479-486.
- Shao, H., Zhong, D. ve Du, X. (2019). Efficient deep palmprint recognition via distilled hashing coding. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPR Workshops'19), New York, ss. 714-723.
- Sun, X., Xu, Q., Wang, C., Dong, W. ve Zhu, Z. (2017). ROI extraction for online touchless palm vein based on concavity analysis. In Proceedings of Youth Academic Annual Conference of Chinese Association of Automation (YAC'17) New York, ss. 1123-1126.

- Sun, Z., Tan, T. ve Wang, Y. (2005). Ordinal palmprint representation for personal identification. *IEEE Computer Society Conf. Xplore Computer Vision and Pattern Recognition (CVPR 2005)*, vol. 1, ss. 279–284.
- Sun, Z., Tan, T., Wang, Y. ve Li, S. Z. (2013). Ordinal feature selection for palmprint authentication. *IEEE Transactions on Image Processing*, 21(8), 3834-3845.
- Şeker, H., Topcu, A. ve Çavuşoğlu, A. (2013). Use of biometric systems in banking: A study of commercial banks in Turkey. *Journal of Internet Banking and Commerce*, 18(2), 1-18.
- Tian, C., Xu, Y., Fei, L. ve Yan, K. (2018). Deep learning for image denoising: A survey. In *International Conference on Genetic and Evolutionary Computing (ICGEC'18)*, Singapore, Springer ss. 563-572.
- URL–1, [https://www4.comp.polyu.edu.hk/~csajaykr/IITD/Database\\_Palm.htm](https://www4.comp.polyu.edu.hk/~csajaykr/IITD/Database_Palm.htm), Erişim: 15.10.2023.
- URL–2, <http://www4.comp.polyu.edu.hk/~biometrics/2D-3D-Palmprint.htm>, Erişim: 12.11.2023.
- Wang, L. ve Li, Y. (2012). Feature extraction and matching for palmprint recognition. *Journal of Biomedical Informatics*, 45(4), 706-714.
- Wang, L., Zhang, Y. ve Feng, J. (2011). On the Euclidean distance of images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27(8), 1334-1339.
- Xu, Y., Zuo, W. ve Zhang, D. (2015). A comprehensive review of methods and techniques for palmprint recognition. *Pattern Recognition*, 62, 120-135.
- Yörük, E., Konukoğlu, E., Sankur, B. ve Darbon, J. (2006). Shape-based hand recognition. *IEEE Transactions on Image Processing*, 15(7), 1803-1815.
- Yulin, F. ve Kumar, A. (2023). Best: Building evidences from scattered templates for accurate contactless palmprint recognition. *Pattern Recognition*, 138, 109422.
- Zhang, D. ve Yan, W. Q. (2006). Palmprint authentication. *Handbook of Biometric Recognition*, 135-154.
- Zhang, D., Guo, Z., Lu, G., Zhang, L. ve Zuo, W. (2010). An online system of multi-spectral palmprint verification. *IEEE Transactions on Instrumentation and Measurement*, 59(2), 480-490.
- Zhang, D., Kong, W. K., You, J. ve Wong, M. (2003). Online palmprint identification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 25(9), 1041-1050.

- Zhang, L., Yang, A., Shen, Y. ve Yang, M. (2017). Towards contactless palmprint recognition: A novel device, a new benchmark, and a collaborative representation based identification approach. *Pattern Recognition*, 69, 199-212.
- Zhang, Y., Zhang, L., Liu, X., Zhao, S., Shen, Y. ve Yang, Y. (2019). Pay by showing your palm: A study of palmprint verification on mobile platforms. In Proceedings of the IEEE International Conference on Multimedia and Expo, ss. 862-867.
- Zhao, S. ve Zhang, B. (2019). Robust and adaptive algorithm for hyperspectral palmprint region of interest extraction. *IET Biometrics*, 8(6), 391-400.
- Zhao, S. ve Zhang, B. (2020). Deep discriminative representation for generic palmprint recognition. *Pattern Recognition*, 98.
- Zhang, Y., Zhang, L., Zhang, R., Li, S., Li, J. ve Huang, F. (2020). Towards palmprint verification on smartphones. arXiv preprint arXiv:2003.13266.
- Zhao, W., Chellappa, R., Phillips, P. J. ve Rosenfeld, A. (2003). Face recognition: A literature survey. *ACM Computing Surveys*, 35(4), 399-458.

## ÖZGEÇMİŞ

Veysel Karani ÖZKAN, Lise eğitimini Erzurum Lisesinde tamamladı. 2020 yılında Gümüşhane Üniversitesi Matematik Mühendisliği Bölümünde mezun oldu. Gümüşhane Üniversitesi Yapay Zeka ve Akıllı Sistemler ABD’da yüksek lisans eğitimini sürdürmekte olup, TÜBİTAK 1001 - Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı tarafından desteklenen 122E402 nolu “Kısıtlamasız Ortamda Alınan El Görüntülerinden Biyometrik Doğrulama İçin Güvenilir Avuç İzi Bölgesinin Tespiti” isimli projede bursiyer olarak görev aldı. 2022 yılına kadar MEB’e bağlı bazı okullarda sözleşmeli öğretmen olarak çalıştı. 2022 yılında itibaren de HalkBankası’nda BT Uzman Yardımcı olarak görev yapmaktadır.