

**T.C.  
ERCIYES ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**AYIRT EDİCİ ORTAK VEKTÖR KULLANARAK  
PARMAK BOĞUM TABANLI SINIFLANDIRMA**

**Hazırlayan  
Neslihan KURAT**

**Danışman  
Prof. Dr. Derviş KARABOĞA**

**(Yüksek Lisans Tezi)**

**Şubat 2016  
KAYSERİ**

**T.C.  
ERCIYES ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**AYIRT EDİCİ ORTAK VEKTÖR KULLANARAK  
PARMAK BOĞUM TABANLI SINIFLANDIRMA  
(Yüksek Lisans Tezi)**

**Hazırlayan  
Neslihan KURAT**


**Danışman  
Prof. Dr. Derviş KARABOĞA**

**Şubat 2016  
KAYSERİ**

## BİLİMSEL ETİĞE UYGUNLUK


Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Neslihan KURAT




## YÖNERGEYE UYGUNLUK

**“Ayırt Edici Ortak Vektör Kullanarak Parmak Boğum Tabanlı Sınıflandırma”** adlı yüksek lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.




Tezi Hazırlayan

Neslihan KURAT



Danışman

Prof. Dr. Derviş KARABOĞA



Bilgisayar Mühendisliği ABD Başkanı

Prof. Dr. Derviş KARABOĞA

Prof. Dr. Derviş KARABOĞA danışmanlığında Neslihan KURAT tarafından hazırlanan “Ayırt Edici Ortak Vektör Kullanarak Parmak Boğum Tabanlı Sınıflandırma” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

..10...../02../2016....

**JÜRİ:**

Danışman : Prof. Dr. Derviş KARABOĞA

Üye

: Doç. Dr. Bahriye Akay

Üye

: Yrd. Doç. Dr. A. Gürkan Yüksek

**ONAY:**

Bu tezin kabulü Enstitü Yönetim Kurulunun 12/02/2016 tarih ve 2016/10-07 sayılı kararı ile onaylanmıştır.

..12...../02../2016....

Prof. Dr. Kâzım KEŞLİOĞLU

Enstitü Müdürü

## TEŞEKKÜR

Tez çalışmam boyunca beni yönlendiren ve değerli yardımlarını esirgemeyen önceki danışman hocam Yrd. Doç. Dr. Necla ÖZKAYA'yı rahmetle anıyor, her konudaki engin yardımları için araştırma görevlisi arkadaşlarım Arş. Gör. Emrah HANÇER, ve Arş. Gör. Ahmet TOPRAK'a teşekkür ediyorum.

## **AYIRT EDİCİ ORTAK VEKTÖR KULLANARAK PARMAK BOĞUM TABANLI SINIFLANDIRMA**

**Neslihan KURAT**

**Erciyes Üniversitesi, Fen Bilimleri Enstitüsü**

**Yüksek Lisans Tezi, Şubat 2016**

**Danışman: Prof. Dr. Derviş KARABOĞA**

### **KISA ÖZET**

Bu çalışma parmak boğum izi (PBİ) ile kişi tanımlama üzerine yapılmıştır. Tanıma metodu, endüstriyel, askeri, güvenlik, adli durumlarda doğruluk en önemli konudur. Tanımlama yapabilmek için ayırt edici vektör (AOV) metodu kullanılarak benzersiz vektörler oluşturulmuştur. Bu vektörler AOV olarak isimlendirilir. Karşılaştırma yapma için öklid uzaklık yöntemi kullanılmıştır. Ayırt etme işlemi şu adımlardan oluşur; resimlerin çekilmesi, resimlerin işlenmesi ve vektörel işleme uygun hale getirilmesi, AOV'nin oluşturulması, karşılaştırmaların yapılması, karar verilmesi.

Bu çalışmada, linkinden edinilen genel kullanıma açık PBİ ve rastgele açılarla çekilmiş iki adet sayısal kamera ile oluşturulan kendi PBİ veri tabanından edinilen veriler kullanılmıştır. Deneylerde AOV temelli PBİ tanıma etkili sonuç vermiştir. Test ve daha önce kullanılmamış verilerinde %100 lük tanıma başarısı elde etmiştir.

**Anahtar Kelimeler:** Tanımlama, parmak boğum, ayırt edici, ortak vektör.

# **FINGER KNUCKLE BASED CLASSIFICATION USING DISCRIMINATIVE COMMON VECTOR**

**Neslihan KURAT**

**Erciyes University, Graduate School of Natural and Applied Sciences**

**M.Sc. Thesis, Şubat 2016**

**Supervisor: Prof. Dr. Derviş KARABOĞA**

## **ABSTRACT**

This working is dealing with identifying authentication via a finger knuckle print (FKP). In industrial, military, security or social applications in personal authentication systems, the most important thing is accuracy. Due to identification, the unique vectors are created by a discriminative common vectors (DCV) based method. They are called discriminative common vectors. For comparing strategy, the Euclidean distance was used. The following steps are defined to the recognition process: defining the image; pre-calculating; apply the discriminative common vectors; matching and lately, determine accuracy rate.

For testing and evaluating the method, the experiments were done with the FKP databases, getting from this link [18] and an established non-uniform FKP database, which are randomly taken by two different digital cameras. These experiments showed that the DCV-based FKP recognition approach worked effectively. For training and unseen test data, the recognition accuracy was %100.

**Keywords:** Finger Knuckle recognition, discriminative common vector.

## İÇİNDEKİLER

### AYIRT EDİCİ ORTAK VEKTÖR KULLANARAK PARMAK BOĞUM TABANLI SINIFLANDIRMA

|                                       |          |
|---------------------------------------|----------|
| BİLİMSEL ETİĞE UYGUNLUK SAYFASI ..... | ii       |
| YÖNERGEYE UYGUNLUK SAYFASI .....      | iii      |
| KABUL VE ONAY SAYFASI .....           | iv       |
| ÖNSÖZ .....                           | vii      |
| ABSTRACT .....                        | viii     |
| İÇİNDEKİLER .....                     | ix       |
| KISALTMA VE SİMGELER .....            | xi       |
| <b>GİRİŞ .....</b>                    | <b>1</b> |

## 1. BÖLÜM

### GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

|                                                     |          |
|-----------------------------------------------------|----------|
| <b>1.1. Giriş .....</b>                             | <b>1</b> |
| <b>1.2. Parmak Boğumu (knuckle) .....</b>           | <b>1</b> |
| <b>1.3. Parmak Boğum Ayırt Edici Özelliği .....</b> | <b>2</b> |

## 2. BÖLÜM

### YÖNTEM VE MATERYAL

|                                           |          |
|-------------------------------------------|----------|
| <b>2.1. Gereç ve Yöntem .....</b>         | <b>3</b> |
| <b>2.2. Ayırtedici Ortak Vektör .....</b> | <b>5</b> |

## 3. BÖLÜM

### BULGULAR

|                                                 |           |
|-------------------------------------------------|-----------|
| <b>3.1. Giriş .....</b>                         | <b>16</b> |
| <b>3.2. Önerilen Yöntemin Uygulanması .....</b> | <b>17</b> |
| <b>3.3. Parmak boğum İzi Görüntüleri .....</b>  | <b>17</b> |

|                                          |           |
|------------------------------------------|-----------|
| <b>3.4. Deneyin Test Sonuçları .....</b> | <b>18</b> |
| <b>3.5. Genel Değerlendirme .....</b>    | <b>25</b> |

#### **4. BÖLÜM**

##### **TARTIŞMA-SONUÇ ve ÖNERİLER**

|                                     |           |
|-------------------------------------|-----------|
| <b>4.1. Tartışma ve Sonuç .....</b> | <b>26</b> |
| <b>4.2. Öneriler .....</b>          | <b>27</b> |

|                        |           |
|------------------------|-----------|
| <b>KAYNAKLAR .....</b> | <b>38</b> |
| <b>ÖZGEÇMİŞ.....</b>   | <b>41</b> |

## KISALTMA VE SİMGELER

AOV: Ayırteıcı Ortak Vektör

PBİ: Parmak Boğum İzi

SOİP: Sol İşaret Parmağı

SOOP: Sol Orta Parmak

SAİP : Sağ İşaret Parmağı

SAOP: Sağ Orta Parmak

EEİK: Elde Edilen İşlem Karakteristik

HRO: Hatalı Red Oranı

HKO: Hatalı Kabul Oranı

# **1. BÖLÜM**

## **GENEL BİLGİLER**

### **1.1. Giriş**

Çalışmanın ilk giriş bölümünde parmak biyometrisi incelenerek, parmak boğum kısımlarının nasıl ayırt edici özellikte olabileceğine değinilmiştir. Sonraki gereç ve yöntemler bölümünde, Ayırtedici Ortak Vektör (AOV) methodunun ne olduğu, nasıl kullanıldığı, diğer algoritmalara göre üstünlükleri nelerdir, neden AOV methodu seçildi sorularına yanıt verilmiştir. Üçüncü bölümde sıradan bir digital kamera ile çekilmiş ve AXB boyutlarındaki 30 Adet kişiden alınmış 10'ar resimden oluşan veri tabanının nasıl oluşturulduğu anlatılmış, bu veri tabanının içeriği ve özellikleri belirtilmiş. Son bölümde de bu veri tabanının deneye sokulması, eğitim ve öğrenme aşamaları ve elde edilen sonuçlara değinilmiştir.

### **1.2. Parmak Boğumu (knuckle)**

El temelli biyometrikler çok fazla ilgi çekmekte ve insan tanımda avuçiçi [2]-[3], [4]-[6], [14]-[15] el-şekli, [7]-[8], 3 boyutlu parmak-şekli [9]-[10], ve 2 el damarları [11]-[13] literatürde kullanılmaktadır. Önceki yaklaşımlar el duruşu ve pozisyonu ile ilgili çalışmalara dayanmaktadır [2], [8], [11]. Ancak, bu yaklaşımlar ellerin sabit durmasını gerektiren yaklaşımlar olduğundan, çocuklar ve yaşlılar söz sözkonusu olduğunda örnek almak sıkıntı verici ve zor olmaktadır. Bundan dolayı sonraki çalışmalar daha çok dokunmadan alınan örneklerle yapılmaya başlanmıştır. Parmak yüzey duruşu Woodard and Flynn [9] tarafından insan tanımda özgün pattern olarak kullanmıştır. Ayrıca, Malassiotis et al. [10] 3 boyutlu parmak geometri özelliklerini

kullanarak alıřmalar yapmıř ancak, sadece kk gruplarda bařarılı olmuřtur. Ribaric and Fratric [5], alıřmalarında parmak ve avu ii yzeyi grntlerini insan tanıma iin kullanmıřtır. Ancak, yazarlar alıřmalarında [5] ok yavaş bir tarayıcı kullanmıřlar ve online kullanıcılar iin uygun bir alıřma yapmamıřlardır. Olduka umut verici grnse de sadece parmak kenarlarındaki izlere dayalı bir alıřma olduėundan oldukça sınırlıdır.

### **1.3. Parmak Boėumunun Ayırt Edici zelliėi**

İnsan el anatomisi oldukça karmařıktır ve medikal, biyoloji dallarıyla yakından ilintilidir. Parmak yzeyi insan tanımlamada oldukça kullanıřlıdır ve arařtırmacıların ilgisini ekmektedir. Parmak boėumundan elde edilen grnt paterni yksek oranda kiřiye zg olduėundan, insan tanımlamada ayırıcı biyometrik tanımlayıcı olarak kullanılmaya uygundur. Ayrıca aynı grntden elde edilen parmak geometri zellikleri sistemler deėiřtirilse bile tekrar tekrar yeniden kullanılabilir. Ayrıca rastgele belgelenmiř parmak yzeyi grnts her kiři iin kolaylıkla elde edilebilir. Bu tr grntler online olarak da kolayca elde edilebilir ve iřlenebilir.

Bu alıřmada, kiři tanımlama aralarından olan parmak boėumunun grntleri arařtırılmıřtır.

## 2. BÖLÜM

### GEREÇ VE YÖNTEM

#### 2.1. Giriş

Bu bölümde ilk olarak, çalışmada önerilen yöntem anlatılmış, sonrasında çalışmada kullanılan parmak boğum görüntülerinden oluşan veri kümesi ile ilgili detaylı bilgiler verilerek, MATLAB de gösterilmiştir.

Öznitelik belirleme işlemi sınıflandırma alanındaki temel bölümlerden birisidir. Sınıflandırma konusunda birçok yöntem kullanılmıştır, biz çalışmamızda PCA [15], LDA[16], AOV[1] yöntemlerini araştırıp kullandık. Bu yöntemlerin kullandıkları görüntüler  $w \times h$  boyutunda olup  $wh$ -boyutlu uzaydaki noktalar olarak ifade edilirler [1]. Görüntülerin üzerinde çalışıldığı uzay örnek uzayı olarak adlandırılır. Çalışılan örnek uzayı çok büyüktür. Bu yöntemlerde, örnek uzayı çok büyük bir uzay olmasına karşın, görüntüler benzer içeriklerde olduklarından çok fazla veri kaybı yaşanmadan küçük uzaylar ile temsil edilebileceği gösterilmiştir.

PCA yönteminde, görüntülerin oluşturduğu örnek uzayda (1) ifadesi en yüksek değerine getirilerek en iyi izdüşüm yönü seti bulunur.

$$J_{PCA}(W_{opt}) = \arg \max_W |W^T S_T W| \quad (1)$$

Verilen (1) eşitliğinde, tüm örneklerle ait toplam saçılım matrisi  $S_T$  ile, ortonormal projeksiyon matrisi  $W$  ile ifade edilmektedir.

PCA yöntemi istatistiksel bir metoddur. Asıl görüntüyü elde etmek için ortogonal temel vektör uzayı kullanır. Bu yöntemde, görüntü en küçük kareler mantığı ile minimum kayıpla sıkıştırılır (2).

$$y = A^T x \quad (2)$$

(2) eşitliğinde elde edilen doğrusal transformu ifade eder, burada,  $y$  matrisi, orjinal vektörün ( $x$ )  $A$  domaini üzerine izdüşümünü ifade eden özellik vektörüdür. Oluşturulan özellik vektörleri birbirleriyle korelasyonsuz (uncorrelated) olduğu için bu modellerde sınıflandırıcı tanımlamaya gerek olmaksızın basitçe öklit mesafesi kullanılarak sınıflandırma yapılabilir. [20].

LDA ise PCA yönteminin eksikliklerinin Fisher'in Linear Discriminant Kriteri kullanılarak giderildiği bir başka yöntemdir. Bu kriter aşağıdaki oranı maksimum yapmaya çalışır.

$$J_{FLD}(W_{opt}) = \arg \max_W \left| \frac{W^T S_T W}{W^T S_W W} \right| \quad (3)$$

Verilen (3) eşitlikte,  $S_B$  sınıflar arası saçılım matrisini (7),  $S_W$  sınıflar içi saçılım matrisini (8) ifade etmektedir. Bu durum  $S_W$  tekil değilse geçerlidir.  $S_W$  tekil ise  $S_W$ 'nin tersi bulunamayacaktır. Bu durumda LDA yönteminde boyut indirgenmesinde PCA kullanılabilir [21].

$$W_{PCA} = \arg \max_W |W^T S_T W| \quad (4)$$

$$W_{PCA} = (w_{pca_1}, \dots, w_{pca_p}) \quad (5)$$

$$J_{FLD}(W_{opt}) = \arg \max_W \left| \frac{W^T \hat{S}_b W}{W^T \hat{S}_w W} \right| \quad (6)$$

$$\hat{S}_b = W_{pca}^T S_b W_{pca} \quad (7)$$

$$\hat{S}_w = W_{pca}^T S_w W_{pca} \quad (8)$$

Veri kümesinin optimal izdüşümünü oluşturan LDA metodu, izdüşümü alınan örneklerin sınıflar arası dağılım matrisinin determinantının, sınıf içi dağılım matrisinin

determinantına oranını maksimize eder. Bir başka deyişle LDA, farklı kişilerin resimleri arasındaki farklılıkların oranıyla ilgilenir. Sınıflar arası dağılım matrisi farklı kişilerden dolayı görünümdeki değişimleri ifade ederken, sınıf içi dağılım matrisi farklı ışıklandırma ve kamera açısından dolayı aynı kişinin görüntüsündeki değişimleri ifade eder [20]. LDA yöntemi PCA metoduna benzerdir, kapalı sistem sınıflandırmada başarılıdır, ancak farklı insanların görüntülerinde LDA ile sınıflandırma yapmak mümkündür.

Bu yöntemlerin temel olarak kullandığı metod, herbir verinin sınıflandırılması için ona özgü nitelikleri taşıyan bir vektörü oluşturmaktır.

Bu çalışmada, 2005 yılında yayımlanan AOV yöntemi olarak adlandırılan bir yöntem kullanılmıştır. Bu yöntemde farklılık gösteren matrisleri temsil eden ortak bir vektör bulunur, bu vektörlerin izdüşümler kullanarak elde edilen vektörler ile parmak boğumların sınıflandırılması sağlanmıştır. Bu yöntemde, her gruptaki örneği temsil eden bir AOV yaratılır.

## 2.2. Ayırteci Ortak Vektör (AOV))

AOV yöntemi, Cevikalp ve grubu tarafından, Fisher Lineer Diskrimant Analizi yönteminin geliştirilerek küçük boyutlu veritabanları için de başarılı sonuçlar üretecek şekilde geliştirilmesi ile oluşturulan bir yöntemdir [1]. AOV yöntemi Temel AOV ve Kernel AOV olarak 2 şekilde sunulmuştur.

### 2.2.1. Temel Ayırteci Ortak Vektör (TAOV)

TAOV yönteminde, kişileri temsil eden AOV vektörlerinin bulunması için 2 farklı yöntem sunulmuştur. İlk yöntem eğitim seti örneklerindeki within-class dağılım matrisini kullanırken diğer yöntem gram-schmidt ortogonalizasyon metodu ve altuzay metodunu kullanır.

#### 2.2.1.1. AOV'nin Bulunmasında $S_w$ nin erim uzayını (range space) kullanmak

Eğitim seti  $N$  sayıda örneklerle ve  $C$  adet birbirine benzemeyen sınıftan oluşmaktadır. Toplam olarak  $M=NC$  kadar örnek eğitim setinde bulunacaktır. Buradan yola çıkarak,  $t$ 'inci resim örneği,  $j$  sınıfından olduğunda,  $d$ -boyutlu uzayda  $x_t^j$  ile ifade edilir ise;

sınıflar arası dağılım matrisi  $S_B$ , sınıf içi dağılım matrisi  $S_W$  ve toplam dağılım matrisi  $S_T$  (9-11) eşitlikleri kullanılarak bulunabilir.

$$S_W = \sum_{i=1}^C \sum_{m=1}^N (x_m^i - \mu_i)(x_m^i - \mu_i)^T \quad (9)$$

$$S_B = \sum_{i=1}^C (\mu_i - \mu)(\mu_i - \mu)^T \quad (10)$$

$$S_T = \sum_{i=1}^C \sum_{m=1}^N (x_m^i - \mu)(x_m^i - \mu)^T = S_W + S_B \quad (11)$$

Eşitliklerde; eğitim için kullanılan setin averaj vektörü  $\mu$  ile gösterilirken,  $i$ 'nci sınıfa ait averaj vektörü  $\mu_i$  göstermektedir.  $AA^T$  ifadesi (9) eşitliği için kullanılırsa, A matrisinin boyutu  $dxM$  olup, (12) eşitliğinde verildiği gibi yazılabilir.

$$A = [x_1^1 - \mu_1 \dots x_N^1 - \mu_1, x_1^2 - \mu_2 \dots x_N^C - \mu_C] \quad (12)$$

$d$ 'nin büyük olduğu durumlarda  $dx d$  boyutlu  $S_W$  matrisinin sıfır altuzayını doğuran birim dik vektör setini bulmak oldukça güçtür[1].  $S_W$  matrisinin erim altuzayını doğuran vektör seti yardımıyla, eğitim setindeki örneklerin  $S_W$  matrisinin sıfır altuzayındaki izdüşümleri bulunabilir.

$S_W$  matrisinin erim altuzayını gösteren matris  $\nu$  (13), sıfır altuzayını temsil eden matris  $\nu^\perp$  (14) olsun.

$$\nu = \text{span}\{\alpha_k \mid S_W \alpha_k \neq 0, k = 1, \dots, r, \alpha_k \in R^d\} \quad (13)$$

$$\nu^\perp = \text{span}\{\alpha_k \mid S_W \alpha_k = 0, k = r + 1, \dots, d, \alpha_k \in R^d\} \quad (14)$$

Bu eşitliklerde  $r < d$  dür ve  $S_W$  matrisinin rankıdır.  $\{\alpha_1 \dots \alpha_d\}$  ortonormal set,  $\{\alpha_1 \dots \alpha_r\}$  ortonormal vektörlerdir.

$Q = [\alpha_1 \dots \alpha_r]$  ve  $\bar{Q} = [\alpha_{r+1} \dots \alpha_d]$  matrislerini düşünelim.  $P = QQ^T$  ve  $\bar{P} = \bar{Q}\bar{Q}^T$  olsun bu durumda bu iki matrisin toplamı örnek uzayını ( $d$ -boyutlu) verir (15).

$$\nu \oplus \nu^\perp = R^d \quad (15)$$

Verilen (15) eşitliğindeki  $\nu$  ve  $\nu^\perp$  matrislerinin izdüşümleri  $P$  ve  $\bar{P}$  olursa, eğitim setindeki örneklerin  $\nu^\perp$  uzayındaki izdüşümleri (16) eşitliğindeki gibi olacaktır.

$$x_{com}^i = x_m^i - Px_m^i = Px_m^i, m=1,...,N, i=1,...,C \quad (16)$$

Sonuç olarak, herbir sınıfı temsil eden ortak bir vektörün üretilmesi gerçekleşir [1].

$$J(W_{opt}) = \arg \max_{|W^T S_w W|=0} |W^T S_B W| = \arg \max |W^T S_{com} W| \quad (16)$$

Verilen (16) eşitliğinde  $S_{com}$  (17) deki gibi bulunur:

$$S_{com} = \sum_{i=1}^C (x_{com}^i - \mu_{com})(x_{com}^i - \mu_{com})^T, i=1,...,C \quad (17)$$

Ortak vektörlerin ortalama vektörü  $\mu_{com}$  olarak gösterilmiştir.

$$\Omega_i = \left[ \langle x_m^i, w_1 \rangle \dots \langle x_m^i, w_r \rangle \right]^T \quad (18)$$

$m$  indisi  $\Omega_i = W^T x_m^i (m=1,...,N; i=1,...,C)$  vektöründen bağımsızdır. Bundan dolayı sınıflandırmada %100 doğruluk sağlanır. Bu vektörler Ayırtedici Ortak Vektörler olarak bilinir.

Test için kullanılan görüntüleri ayrıştırmak amacıyla setteki örneklerin ayırt edici vektörleri (19) eşitliği ile hesaplanır:

$$\Omega_{test} = W^T x_{test} \quad (19)$$

Hesaplanan  $\Omega_{test}$  ile eğitim için kullanılan örneklerden elde edilen ayırtedici ortak vektörlerin Öklid mesafesi bulunur. Test için kullanılan örnek, en yakın mesafedeki uzaklığı veren gruba ait olduğu düşünülür.

TAOV yöntem şu şekilde özetlenirse:

**Adım 1:**  $S_w$  matrisinin izdüşüm değerleri  $A^T A$  matrisi kullanılarak bulunur.  $S_w = AA^T$  dir ve A matrisi (12)'de verilmiştir. Bunlar,  $S_w$  matrisinin erim altuzayını oluşturan vektörlerdir.  $Q = [\alpha_1 \dots \alpha_r]$  matrisi, bu vektörler kullanılarak bulunur. Verilen denklemde  $\alpha$  erim altuzayını temsil eden matrisin satırlarını,  $r$  ise  $S_w$  nin rankını gösterir.

**Adım 2:** Bu noktada, rastgele bir test ögesi seçilir ve bu ögenin  $S_w$  nin altuzayında temsil edecek matrisi satırları bulunur. Bu satırlar temelde sınıfları temsil edecek olan matris satırını oluşturur(20).

$$x_{com}^i = x_m^i - QQ^T x_m^i, m=1, \dots, N, i=1, \dots, C \quad (20)$$

**Adım 3:**  $S_{com}$  matrisi, kesişim vektörleri kullanılarak bulunur.  $A_{com}^T A_{com}$  matrisleri kullanılarak  $S_{com}$  'ün sıfırdan farklı olan değerlerinin oluşturduğu temel vektörler bulunur. Buradaki vektörler yardımıyla izdüşüm matrisi (W) (21) oluşturulur.

$$W = [w_1 \dots w_{C-1}] \quad (21)$$

Yukardaki denklemde  $r$ ,  $S_{com}$  'nin rankını verir.  $r$  maksimum  $C-1$  olabilir

#### 2.2.1.2. Altuzay Teknikleri ve Gram-Schmidt Ortogonalizasyon Prosedüründen Yararlanılarak Ayırtedici Ortak Vektörlerin Oluşturulması

Bu amaçla  $A^T A$  matrisi kullanılmıştır. Bu matris  $M \times M$  boyutludur. Eğitim esnasında kullanılan örneklerin sayısı (M) arttırılırsa buna bağlı olarak işlemin tutarlılığı bozulur. İlk olarak her örnek grubunun farklılık vektörleri (22) denklemi yardımıyla oluşturulur.

$$x_k^i = x_{k+1}^i - x_1^i, k=1, \dots, N-1 \quad (22)$$

$B_i = span\{b_1^i, \dots, b_{N-1}^i\}$   $i$  numaralı örneğin farklılık uzayı ise, bu vektörlerin toplamı bütün eğitim grubunun farklılık uzayını oluşturur. (23)

$$B = B_1 + \dots + B_C = span\{b_1^i, \dots, b_{N-1}^i, b_1^{2i}, \dots, b_{N-1}^{2i}\} \quad (23)$$

Farklılık uzayı (linearly independent) vektörlerin sayısı  $S_w$  'nin rankı,  $B$  matrisini oluşturan bağımsız vektörlerin sayısını verir.  $B$  matrisinin tümleyeni ise eğitim vektörlerinin farksızlık boyutunu  $B^\perp$  oluşturur [1].  $S_w$  'nin erim uzayını oluşturan vektör seti, Gram-Schmidt eşitliği ile kullanılarak bulunur.  $Q = [\beta_1 \dots \beta_k]$  matrisi, sözü edilen vektör seti yardımıyla oluşturulur ve her sınıfa ait ortak vektörler (24) eşitliği kullanılarak bulunur.

$$x_{com}^i = x_m^i - QQ^T x_m^i, m=1, \dots, N, i=1, \dots, C \quad (24)$$

$S_w$  kullanılarak oluşturulan kesişim vektörleri ile bu vektörler eşittirler. [1]. Kesişim vektörlerinin yarımıyla, minimum izdüşüm vektörleri  $S_{com}$  'nin sıfırdan farklı özvektörleri baz alınarak tespit edilir.

AOV metodunun YALE ve AR yüz veritabanı için tanıma başarısı Tablo 2.1. ve Tablo2.2.'de; yüz tanıma sistemlerinin performans, eğitim zamanı, test zamanı ve hafıza gereksinimi açısından karşılaştırılması ise Tablo 2.3.'te verildiği şekildedir [1].

Tablo 2.1. Yüz tanıma yöntemlerinin karşılaştırılması.

| Yöntem     | Tanıma Oranı |
|------------|--------------|
| Eigenface  | %76          |
| Fisherface | %96          |
| Direct-LDA | %92          |
| DCV        | %97.33       |

Tablo 2.2. Yüz tanıma yöntemlerinin tanıma başarısı.

| Yöntem     | Tanıma Oranı |
|------------|--------------|
| Eigenface  | %79.14       |
| Fisherface | %98.85       |
| Direct-LDA | %98.64       |
| DCV        | %99.35       |

Tablo 2.3 Yüz tanıma yöntemlerinin çeşitli yönlerden karşılaştırılması.

| Performance | Doğruluk              | Eğitim Zamanı | Test Zamanı               | Hafıza Gereksinimi     |
|-------------|-----------------------|---------------|---------------------------|------------------------|
| 1           | DCV,<br>PCA+Nullspace | Direct-LDA    | DCV,<br>PCA+Nullspace     | DCV,<br>PCA+Nullspace  |
| 2           | Fisherface            | DCV           | Fisherface,<br>Direct-LDA | Fisherface, Direct-LDA |
| 3           | Direct-LDA            | Eigenface     | Eigenface                 | Eigenface              |
| 4           | Eigenface             | Fisherface    |                           |                        |
| 5           |                       | PCA+Nullspace |                           |                        |

### 2.2.2. Kernel Ayırt Edici Ortak Vektör Yöntemi (KAOV)

Tanıma algoritmalarında özellik bulma kritik bir adımdır. Özellik bulmaya yönelik çeşitli yöntemler geliştirilmiştir. Bunlardan en önemlisi lineer altuzay analizidir. Lineer altuzay analizi konusunda en iyi bilinen yöntemler PCA ve FLDA (Fisher LDA)'dır.

PCA normalizasyona çok bağımlıdır. FLDA, sınıfları birbirinden ayırmak için sınıflararası dağılımı maksimize eder ve sınıfiçi dağılımı minimize edecek lineer bir transformasyon arar. Dolayısıyla FLDA lineer diskriminant vektörlerini bulabilir. Buna

rağmen Small Sample Size (SSS) problemi vardır. Yani bir görüntünün boyutu görüntü örneklerinden fazladır. Bu sınıfıçi dağılım matrisini tekil yapar ve FLDA da hesaplama zorluğu çıkarır. FLDA'nın bu SSS problemini aşmak için bir çok yöntem sunulmuştur.

PCA+ FLDA (FISHERFACE), Direct LDA, NULL SPACE ve PCA+ NULL SPACE bunlardan bazılarıdır. PCA+ FLDA ve Direct LDA'da önemli diskriminatif bilgi kaybı olmakta; NULL SPACE ve PCA+ NULL SPACE'de ise eğitim seti büyükse hesaplama zamanı çok yüksek olmaktadır.

Ancak AOV yaklaşımı diğer metotların düştüğü darboğazlara düşmeden SSS problemini aşmaktadır. AOV metodu her görüntü sınıfı için bir ortak vektör hesaplamaktadır. Sonra bu ortak vektörler yardımıyla, fisher diskriminant kriterini optimize eden optimal lineer transformasyon matrisi hesaplanmaktadır. Sonuçlar AOV'nin doğruluk, gerçek zamanlı performans ve hesaplama açısından diğer yöntemlerden üstün olduğunu göstermektedir.

DCV ise lineerdir ve yüz görüntüleri için kullanılırken, aydınlatma, poz değişimleri ve yüz ifadesi farklılıklarında yetersiz kalmaktadır [22] .

DCV'nin bu yetersizliğini gidermek için yapılan ilk çalışma [23] nolu referansta verilmiştir. İlgili çalışmada Kernel Ayırt Edici Ortak Vektör (KAOV) metodu olarak adlandırılan son zamanlarda sıkça kullanılan bir sistem kullanılmıştır. Birinci adımda test uzayı yöntemin fonksiyonları kullanılarak d-boyutlu doğrusal olmayan diğer bir uzaya eşlenmiştir. İkinci adımda, oluşturulan d-boyutlu bu uzaya, doğrusal AOV metodu dikte edilmiştir. Bu yöntemle her bir spesifik sınıftaki örnek, kendi sınıfını tanımlayan ayırt edici ortak vektörü oluşturmaktadır. Sonuç olarak elimizdeki tüm örnekler için ayırt edici sınıflandırma sağlanmış olur. Bu yöntemle yapılan testler sonucunda, AOV metodunun diğer doğrusal olmayan yöntemlere göre, deney setindeki örneklemeleri daha yüksek doğrulukla sınıflandırdığını göstermektedir.

Doğrusal öznitelik bulma yöntemlerinin çalışma alanı, spesifik özellikler bularak eldeki sınıflandırılacak verileri tanımlamaktır. Bu amaç doğrultusunda, veri uzayı çeşitli yöntemler (PCA, Direct-LDA, FLDA, AOV gibi) kullanılarak yüksek boyuttaki bir uzay bilgisini daha küçültür. Bahsi geçen yöntemlerin kullanılması durumunda zararlı olgu etkilerinin azaltılması gerekmektedir “curse of dimensionality”.[24]. Ancak, bu

yöntemlerd de eğer verileriniz belirli bir sınıflandırma içermiyorsa başarısız olmaktadır. Bundan dolayıdır ki; çoğu zaman doğrusal olmayan Kernel yöntemler sınıflandırma da daha başarılıdır.

Kernel PCA [25], Kernel FDA [26] ve Kernel GDA [27] bu yöntemlerden bazılarıdır.

Kernel Ayırt Edici Ortak Vektör (Kernel Discriminative Common Vector), basitçe doğrusal-olmayan uzaya doğrusal Ayırt Edici Ortak Vektör yöntemini uygular. Aşağıda verilen Değiştirilmiş Fisher ölçütü ile, en iyi temel nitelik matrisleri oluşturulur ve 1 sayısı elde edilir.

$$J_{MFLDA}(W_{opt}) = \arg \max_W \left| \frac{W^T S_B W}{W^T S_T W} \right|$$

Yukarıda verilen formülde,  $S_B$  saçılım matrisini,  $S_T$  bütün örneklemi tanımlayan sonuç matrisini gösterir. Bu metod test verileri için minimum izdüşüm vektörlerini üretir. Bu vektörler yardımıyla test setindeki tüm veriler uygun sınıflara bölünür.

### 2.2.2.1. Optimal Ayırtedici Altuzay Kavramı:

İzdüşüm vektörleri, sınıflar içi saçılım matrisinin sıfır altuzayından seçilirse değiştirilmiş Fisher ölçütü, 1 sayısı elde edilir.

$$J(W_{opt}) = \arg \max \left| \frac{W^T S_B W}{W^T S_T W} \right|$$

Ancak, sınıflar içi saçılım matrisi  $S_w$  tekil bir matris olduğu varsayılırsa (eğitim setindeki örnek sayısı örnek uzayın boyutundan az ise)  $w^T S_w w = 0$  ve  $w^T S_B w \neq 0$  eşitliğine denk düşen vektörler üretilebilir. Ancak vektörlerin çoğunluğu başarılı sınıflandırmalar yapmak için yeterli olmaz [1]. Bu nedenle örnek uzayı boyutunun eğitim için kullanılan örnek sayısından fazla olması halinde şu eşitlikten yararlanılır [1,4].

$$J(W_{opt}) = \arg \max_{|W^T S_w W|=0} |W^T S_T W| = \arg \max |W^T S_{com} W|$$

Minimal izdüşüm vektörlerini elde edebilme için, eğitim için kullanılan örneklerin sınıflar için olan saçılım matrisinin altuzayındaki izdüşümlerinin bulunması gerekir. Ardından, eğitim örneklerinin son haline PCA metodu uygulanarak minimum izdüşüm matrisleri bulunur. Sonuçta elde edilen bu vektörler, sınıflar içi saçılım matrisinin sıfır altuzayı  $N(S_w)$  ile toplam saçılım matrisinin erim uzayının  $R(S_T)$  kesişim uzayını oluştururlar [1].  $R(S_T) \cap N(S_w)$  kesişim uzayı öznelik belirleme için gereken minimum özellikleri oluşturur, ve *optimal ayırt edici altuzayı* olarak tanımlanır.

Minimum ayırt edici vektörleri iki yöntemler bulunur. Birincisinde, Ayırt Edici Ortak Vektör yönteminin kullandığı bu yöntemde, örneklerin eğitim setinde olanlarının  $N(S_w)$  sıfır uzayındaki izdüşüm matrisi elde edilir ve ardından PCA yöntemi implement edilirse en minimal izdüşüm vektörleri oluşturulur. PCA+Null Space yöntemi [28] nin kullanıldığı diğer yöntemde ise, eğitim grubundaki veriler PCA'dan geçirilir ve ardından, oluşan yeni uzaydaki bilgilerin sıfır uzayına izdüşümleri bulunur.

#### 2.2.2.2. Kernel Ayırt Edici Ortak Vektör Yöntemi:

Sınıflandırma yapılacak C adet sınıf, her bir sınıfta da  $N_i$  örnek olduğunu düşünelim. Toplam örnek sayısı  $M=NC$  kadar olur ve şöyle hesaplanır:

$$M = \sum_{i=1}^C N_i$$

Kernel fonksiyonları kullanan yöntemlerde yapılan ilk iş; eğitim uzayının yüksek boyutlu başka bir uzaya izdüşürülmesidir.

Bu uzayı temsil eden örnekler  $\phi(x_1^1), \phi(x_2^1), \dots, \phi(x_{N_1}^1), \phi(x_1^2), \dots, \phi(x_{N_C}^C)$  dir. Yeni uzaya  $\mathfrak{Z}$  ile temsil edelim. Bu durumda aşağıdaki denklemler oluşur.

$$\phi(x_1^1), \phi(x_2^1), \dots, \phi(x_{N_1}^1), \phi(x_1^2), \dots, \phi(x_{N_C}^C)$$

$$S_w^\phi = \sum_{i=1}^C \sum_{m=1}^{N_i} (\phi(x_m^i) - \mu_i^\phi)(\phi(x_m^i) - \mu_i^\phi)^T$$

$$= (\phi - \phi G)(\phi - \phi G)^T,$$

$$S_B^\phi = \sum_{i=1}^C N_i (\mu_i^\phi - \mu^\phi)(\mu_i^\phi - \mu^\phi)^T$$

$$= (\phi U - \phi L)(\phi U - \phi L)^T,$$

$$S_T^\phi = \sum_{i=1}^C \sum_{m=1}^{N_i} (\phi(x_m^i) - \mu^\phi)(\phi(x_m^i) - \mu^\phi)^T$$

$$= (\phi - \phi I_m)(\phi - \phi I_m)^T = S_w^\phi + S_B^\phi$$

Bu eşitliklerde  $\mu^\phi$ ,  $\mathfrak{Z}$ 'daki örneklerin ortalama vektörünü, bütün sütunları  $\mathfrak{Z}$  uzayına ilişkilendirilmiş eğitim seti verilerinden oluşan matris  $\phi$  ile gösterilmiştir.

$G = \text{diag}[G_1, \dots, G_c] \in R^{M \times M}$  köşegen matrisidir. Bütün matrisler  $G_i \in R^{N_i \times N_i}$ 'nin tüm elemanlarının  $\frac{1}{N_i}$  oranına denktir. İkinci eşitlikte sunulan

$U = \text{diag}[u_1, \dots, u_c] \in R^{M \times C}$  matrisi blok köşegen matrisi olup her bir vektör  $u_i \in R^{N_i \times 1}$ 'nin eleman sayısı  $\frac{1}{N_i}$ 'dir. İkinci eşitlikte verilen  $I_i \in R^{M \times 1}$ 'nin  $\frac{\sqrt{N_i}}{M}$  elemanlı vektörleri  $L = [I_1, \dots, I_c] \in R^{M \times C}$  matrisini oluşturur.  $I_M \in R^{M \times M_i}$  matrisi  $\frac{1}{M}$  sayısında elemanları olan matristir.

Algoritmanın detayları aşağıda sırasıyla verilmektedir.

**Adım 1:** Eğitimdeki örneklerin  $R(S_T^\phi)$  uzayındaki izdüşümlerini Kernel PCA ile hesapla;

$$\tilde{K} = K - I_M K - K I_M + I_M K I_M \in R^{M \times M_i} = P \Lambda P^T$$

Bu hesaplamada oluşan matris köşegen matrisidir. Buradaki köşegen matrisinin elemanları sıfırdan farklıdır.

$K \in R^{M \times M_i}$  matrisi,  $K = \phi^T \phi = (K^{ij})_{\substack{i=1,\dots,C \\ j=1,\dots,C}}$  eşitliğiyle bulunabilir. Burada,

$K^{ij} = (k_{mn}^{ij})_{\substack{m=1,\dots,N_i \\ n=1,\dots,N_j}} = \langle \phi(x_m^i), \phi(x_n^j) \rangle = k(x_m^i, x_n^j)_{\substack{m=1,\dots,N_i \\ n=1,\dots,N_j}}$  şeklinde tanımlanır. Bu durumda

eğitim setindeki örnekleri  $R(S_T^\phi)$  uzayına eşlemleyen matris  $(\phi - \phi I_M) P \Lambda^{-1/2}$  olacaktır. Örneklerin buradaki yeni uzay için oluşan toplam saçılım matrisi ve sınıflar arası saçılım matrisi şu şekildedir ;

$$\begin{aligned} \tilde{S}_T^\phi &= ((\phi - \phi I_M) P \Lambda^{-1/2})^T S_T^\phi (\phi - \phi I_M) P \Lambda^{-1/2} \\ &= \Lambda^{-1/2} P^T P \Lambda P^T P \Lambda P^T P \Lambda^{-1/2} = \Lambda, \end{aligned}$$

$$\begin{aligned} \tilde{S}_w^\phi &= ((\phi - \phi I_M) P \Lambda^{-1/2})^T S_w^\phi (\phi - \phi I_M) P \Lambda^{-1/2} \\ &= \Lambda^{-1/2} P^T \tilde{K}_w \tilde{K}_w^T P \Lambda^{-1/2} \end{aligned}$$

Bu Eşitlikteki  $K_w$  aşağıda tanımlandığı şekildedir.

$$\tilde{K}_w = K - KG - I_M K + I_M KG = (K - I_M K)(I - G)$$

**Adım 2:**  $\tilde{S}_w^\phi \in R^{M \times M}$  'nın düşey eksene izdüşümünü oluşturacak olan matris bulunur. Bu adım ayrıştırma işlemi yapılan adımdır. Birim vektör grubu,  $\tilde{S}_w^\phi \in R^{M \times M}$  matrisinin sıfır uzayına izdüşümünden oluşan matris ile oluşur.  $V$  matrisinin sütunları;  $\tilde{S}_w^\phi \in R^{M \times M}$  matrisinin sıfır altuzayını oluşturan vektörlerden oluşursa;

$$V^T \tilde{S}_w^\phi V = 0$$

**Adım 3 (isteğe bağlı):** Eğer  $V^T \tilde{S}_B^\phi V$  matrisinin sıfır altuzayı varsa bu altuzayı çıkar.

$$V^T \tilde{S}_B^\phi V = V^T \tilde{S}_T^\phi V = V^T \Lambda V = L \tilde{\Lambda} L^T$$

$W = (\phi - \phi I_M) P \Lambda^{-1/2} V L$  optimal izdüşüm matrisidir. Bu matris öz nitelik vektörlerinin oluşturulmasında kullanılır. Bu vektörlerin sayısı maksimum  $C-1$  olur. Bu matris her sınıf için aynı öz nitelik vektörü oluşmasını sağlar. Bu da gösterir ki örnekler güvenilir oranda sınıflandırılmıştır. Kernel Yöntemleri kullanılarak elde edilen tanıma oranları Tablo 2.4.'te verilmektedir [8].

Tablo 2.4. Kernel Yöntemleri Kullanılarak Elde Edilen Tanıma Oranları

| Kernel Yöntemleri | Eğitim Setindeki Sınıfların Örnek Sayısı |                            |                           |                            |                           |                            |
|-------------------|------------------------------------------|----------------------------|---------------------------|----------------------------|---------------------------|----------------------------|
|                   | N=3                                      |                            | N=5                       |                            | N=7                       |                            |
|                   | Polinom Kernel Fonksiyonu                | Gaussian Kernel Fonksiyonu | Polinom Kernel Fonksiyonu | Gaussian Kernel Fonksiyonu | Polinom Kernel Fonksiyonu | Gaussian Kernel Fonksiyonu |
| Kernel PCA        | 86.20                                    | 86.25                      | 93.33                     | 93.75                      | 96.94                     | 97.08                      |
| Kernel FDA        | 90.05                                    | 89.99                      | 96.33                     | 96.50                      | 97.49                     | 98.47                      |
| Kernel GDA        | 87.60                                    | 91.31                      | 94.16                     | 96.66                      | 96.66                     | 98.19                      |
| Kernel DCV        | 91.38                                    | 91.60                      | 97                        | 97.50                      | 98.61                     | 98.75                      |

Minimal kesişim vektörlerinin sayısı en fazla  $C-1$  olabilmektedir. Öznitelik vektörleri ilzdeşüm vektörleri kullanılarak elde edilir ve bütün sınıflar için aynıdır. Bu da demektir ki örneklerin hepsi doğru olarak sınıflandırılabilmiştir.

### **3. BÖLÜM**

#### **DENEYLER VE BULGULAR**

##### **3.1. Giriş**

Bu bölümde öncelikle iyi bilinen klasik yöntemlerine ait görsel sonuçlar verilmiştir. Daha sonra, tez çalışması kapsamında önerilen yönteme ait parametrelerin yöntemin başarımını nasıl etkilediği araştırılmıştır. Son olarak, önerilen yöntem literatürde iyi bilinen yöntemlerle sayısal ve görsel açıdan karşılaştırılmıştır.


##### **3.2. Önerilen Yöntemin Uygulanması**

Bu bölümde, tez kapsamında önerilen yöntemle kıyaslanacak klasik yöntemlerin, objektif ve referans tabanlı metriklerle yapılan değerlendirmelerine yer verilmektedir. Çalışmada, iki farklı veri tabanı kullanılmıştır. Birisi, yayınlanmış 115 kişiden alınmış 660 parmaktan oluşan 2.640 adet görüntü içeren yayınlanmış bir veri tabanı[18]dir. Diğeri, bizim tarafımızdan oluşturulan veri tabanıdır. Bu veri tabanı ile yapılan deneylerde, 30 kişiden alının sağ ve sol el görüntülerinden sol işaret parmağı (SOİP) sol orta parmak (SOOP), sağ işaret parmağı (SAİP) ve sağ orta parmak( SAOP) kullanılmıştır.

Kullanılan her iki veri tabanının deneyleri ve testleri ayrı ayrı yapılmıştır. Doğrulama aracı olarak, bir sınır değeri belirlenmiş, ve sistemin karar vermesi bu değerlerle sağlanmıştır. Eğer iki biyometrik örnek sınır değerinde yüksek veya eşitse sistem iki örneğin aynı insana ait olduğuna karar verir.

Genuine dağılımı, aynı kişiye ait örnek çiftinin dağılımını gösterirken, imposter dağılımı ise farklı kişilere ait örnek çiftlerinin dağılım değerlerini gösterir. Elde Edilen İşlem Karakteristik (EEİK- The Receiver Operating Characteristic (ROC)) eğrisi, genellikle literatürde biyometrik temelli tanıma sistemlerinde performansı

karşılaştırmak için kullanılır. Hatalı Red Oranı ( (HRO) -False Reject Rate (FRR)) na karşılık, Hatalı Kabul Oranı ((HKO)- False Accept Rate (FAR)) mümkün olan tüm sınır değerleri için çizilmesini sağlar. Önerilen çalışmada, EEİK eğrileri bütün parmak tipleri için çizilmiştir.



Şekil 1. Sistem yapısı.

### 3.3. Parmak Boğum İzi (PBİ - knuckle) Görüntüleri

Biyometrik temelli sistemler insan tanımlama için, tanımlama testleri kullanır. Elde edilen ve seçilen en yüksek değerler karar verme mekanizmasını oluşturmayı sağlar. Bundan dolayı, biyometrik örnekler, bütün veri tabanı ile karşılaştırılır, ve eşleştirme sonucunda benzerlik listesi meydana gelir. En yüksek değerlikli benzerlik değeri eşleştirmeyi belirler.

Bizim çalışmamızda, önerilen yöntemle kapalı-sistem tanımlama yapılmıştır. Bu da demektir ki, teste verilen örneklerin veri tabanındaki kişilere ait olduğu varsayılır.

İleriki çalışmalarda, önerilen yöntem, açık-sistem tanımlama yapacak şekilde değiştirilebileceği düşünülmektedir.

Literatürde [19], PBI tanıma sistemlerine görüntü sağlamak için beyaz arka planı olan sayısal bir kamera ile sabit açıdan çekim sağlayacak özel olarak tasarlanmış bir düzenek kullanılmıştır. Bu yaklaşımın tersine, bizim çalışmamızda özel bir düzenek kullanmadan, gün ışığında, mesafe ve açı ayarı yapılmadan, extra ışık kullanmadan, 2 farklı özellikli sayısal kamera ile görüntüler elde edilmiştir. Görüntüler sabit bir kamera ile değil, elle yaklaşık 15-25cm.S uzaklıktan rastgele açılardan çekilmiştir. Böylece deneyimiz, özel bir araçtan ve ortamdan bağımsız olarak gerçekleştirilmiştir. Çevresel şartların değişmesi, gölge ve yansımalarla rağmen, sistem %100 doğrulukla çalışmaktadır.

Halbuki bu gibi çevresel faktörlerin, literatürdeki çalışmada[4], PBI temelli biyometric sistemlerin performansını düşürdüğü belirtilmiş, bunun için çevresel etmenleri yok etmeye yardımcı bir araca ihtiyaç duyulduğu belirtilmiştir. Bizim çalışmamızda, herhangi bir görüntü iyileştirici cihaz kullanılmadan, sıradan sayısal bir kamera ile, tanımlama ve doğrulama için gerekli veriler elde edilmiştir.

### **3.4. Deneyin Test Sonuçları**

Bu bölümde, önceki bölümlerde görsel olarak değerlendirilen yöntemler birbirleriyle karşılaştırılmaktadır. Üretilen birleşik görüntüler üzerinden de subjektif bir görsel değerlendirme yapılmaktadır.

Deneyin sonuçlarının karşılaştırılmasında görsel verileri kullanarak, subjektif bir değerlendirme yapma gereksinimi ortaya çıkmaktadır.

#### **3.1. PolyU Parmak Boğum İzi Veri Tabanı ile Yapılan Deney**

Önerilen sistemin performansını değerlendirmek için öncelikle, [19] çalışmasında kullanılan, PolyU Finger Knuckle[18] veri tabanı kullanılmıştır. Bu veri tabanında PBI görüntüleri 125 erkek, 40 kadın olmak üzere, 165 kişiden alınmıştır. 143 tanesi 20-30 yaşları arasında, geri kalanlar 30-50 yaşları arasındadır. Görüntü büyüklükleri 220x110dır. Bu veri tabanının deneyinde, her kişiden 8 rastgele seçilmiş görüntü eğitim için, kalan 2 resim test için kullanılmıştır. Seçim yapıldıktan sonra, 30 kere işlem tekrarlanmış ve ortalama hata oranları çıkarılmıştır.

Küçük parçalara ayrılmış PolyU veri tabanı için, Tablo 3.1. Tanıma Oranını, Tablo3.2.(t) sınır değeri için HEO değerini göstermektedir.


Table 3.1. PolyU veri tabanının AOV temelli PBİ tanıma şeması.

| Performans değerlendirmesi yapılacak PolyU Sınıflandırmaları | Tanıma Oranı (TO%) |      |      |      |
|--------------------------------------------------------------|--------------------|------|------|------|
|                                                              | SOİP               | SAİP | SOOP | SAOP |
| PolyU_DB_1 (1-15)                                            | 100                | 100  | 100  | 100  |
| PolyU_DB_2 (16-30)                                           | 100                | 100  | 100  | 100  |
| PolyU_DB_3 (31-45)                                           | 100                | 100  | 100  | 100  |
| PolyU_DB_4 (46-60)                                           | 100                | 100  | 100  | 100  |
| PolyU_DB_5 (61-75)                                           | 100                | 100  | 100  | 100  |
| PolyU_DB_6 (76-90)                                           | 100                | 100  | 100  | 100  |
| PolyU_DB_7 (91-105)                                          | 100                | 100  | 100  | 100  |
| PolyU_DB_8 (106-120)                                         | 100                | 100  | 100  | 100  |
| PolyU_DB_9 (121-135)                                         | 100                | 100  | 100  | 100  |
| PolyU_DB_10 (136-150)                                        | 100                | 100  | 100  | 100  |
| PolyU_DB_11 (151-165)                                        | 100                | 100  | 100  | 100  |


Table 3.2. PolyU veri tabanı için hata eşitlik oranı (HEO%) değerlerinin şeması.

|                    | Hata Eşitlik Oranı (HEO%) |       |       |      |       |     |      |       |       |      |       |     |
|--------------------|---------------------------|-------|-------|------|-------|-----|------|-------|-------|------|-------|-----|
|                    | SOİP                      |       |       | SAOP |       |     | SOİP |       |       | SOOP |       |     |
|                    | t                         | HKO   | HRO   | t    | HKO   | HRO | t    | HKO   | HRO   | t    | HKO   | HRO |
| PolyU_DB_1 (1-15)  | 81                        | 0.026 | 0     | 83   | 0.023 | 0   | 88   | 0.002 | 0     | 82   | 0.002 | 0   |
|                    | 82                        | 0.023 | 0.033 | 84   | 0     | 0   | 89   | 0     | 0.033 | 83   | 0     | 0   |
| PolyU_DB_2 (16-30) | 81                        | 0.002 | 0     | 91   | 0.004 | 0   | 83   | 0.002 | 0     | 90   | 0.004 | 0   |

|                       |    |       |       |    |       |       |    |       |       |    |        |       |
|-----------------------|----|-------|-------|----|-------|-------|----|-------|-------|----|--------|-------|
|                       | 82 | 0     | 0.033 | 92 | 0     | 0.066 | 84 | 0     | 0.033 | 91 | 0.004  | 0.033 |
| PolyU_DB_3 (31-45)    | 82 | 0.009 | 0     | 92 | 0.002 | 0     | 92 | 0.002 | 0     | 90 | 0.009  | 0     |
|                       | 83 | 0.007 | 0.033 | 93 | 0     | 0     | 93 | 0.002 | 0.033 | 91 | 0      | 0     |
| PolyU_DB_4 (46-60)    | 83 | 0.004 | 0     | 83 | 0.002 | 0     | 88 | 0.002 | 0     | 77 | 0.004  | 0     |
|                       | 84 | 0     | 0     | 84 | 0     | 0     | 89 | 0     | 0     | 78 | 0.002  | 0.033 |
| PolyU_DB_5 (61-75)    | 85 | 0.002 | 0     | 85 | 0.002 | 0     | 89 | 0.004 | 0     | 80 | 0.016  | 0     |
|                       | 86 | 0     | 0.033 | 86 | 0     | 0     | 90 | 0     | 0.033 | 81 | 0.009  | 0.033 |
| PolyU_DB_6 (76-90)    | 86 | 0.002 | 0     | 86 | 0.002 | 0     | 88 | 0.002 | 0     | 84 | 0.021  | 0     |
|                       | 87 | 0     | 0     | 87 | 0     | 0     | 89 | 0     | 0     | 85 | 0.016  | 0.033 |
| PolyU_DB_7 (91-105)   | 83 | 0.009 | 0     | 87 | 0.002 | 0     | 90 | 0.002 | 0     | 89 | 0.004  | 0     |
|                       | 84 | 0.009 | 0.033 | 88 | 0     | 0     | 91 | 0     | 0     | 90 | 0      | 0     |
| PolyU_DB_8 (106-120)  | 92 | 0.002 | 0     | 88 | 0.002 | 0     | 87 | 0.002 | 0     | 90 | 0.002  | 0     |
|                       | 93 | 0     | 0.066 | 89 | 0     | 0     | 88 | 0     | 0     | 91 | 0      | 0     |
| PolyU_DB_9 (121-135)  | 84 | 0.002 | 0     | 89 | 0.007 | 0     | 88 | 0.002 | 0     | 85 | 0.016  | 0     |
|                       | 85 | 0     | 0     | 90 | 0.004 | 0.033 | 89 | 0     | 0     | 86 | 0.011  | 0.033 |
| PolyU_DB_10 (136-150) | 86 | 0.002 | 0     | 89 | 0.004 | 0     | 82 | 0.009 | 0     | 88 | 0.002  | 0     |
|                       | 87 | 0     | 0     | 90 | 0     | 0     | 83 | 0     | 0     | 89 | 0      | 0     |
| PolyU_DB_11 (151-165) | 90 | 0.002 | 0     | 89 | 0.002 | 0.033 | 89 | 0.002 | 0.033 | 94 | 0.0047 | 0     |
|                       | 91 | 0     | 0.033 | 90 | 0     | 0.066 | 90 | 0     | 0.033 | 95 | 0      | 0     |



Şekil 3.1. 15 lik sınıflara ayrılan PolyU veri tabanı için AOV temelli PBİ tanımlama için kullanılan genuine ve impostor dağılımı (GID)



Şekil 3.2. 15 lik sınıflara ayrılan PolyU veri tabanı için AOV temelli PBİ tanımlamada SAİP için HKO\_HRO sonuçları

Verilen bir sınır değerinde (t) HKO ve HRO değerleri genuine ve impostor dağılımları gösterilmektedir. HKO eşleşme oranı t değerine eşit veya t değerinden büyük olan impostor çiftlerin oranlarını verir. HRO ise, eşleşme oranı t değerinden düşük olan genuine çiftlerinin oranlarını içerir. HKO ve HRO Şekil 3.1. de görünmektedir. 11 ayrı küçük sınıfa ayrılan PolyU veri tabanının HKO-HRO değerleri Şekil 3.2. de verilmiştir.

Literatürde, bütün işleme noktalarının sistem performansının gösterilmesinde t sınır değerinin Elde Edilen İşlem Karakteristik (EEİK- Receiver Operating Characteristic ROC) eğrisinin kullanılması oldukça yaygındır. EEİK eğrisi, Hatalı Kabul Oranı (HKO) ve Hatalı Ret Oranı (HRO) larının gösterilmesi ile oluşturulur. SAMP için genuine ve impostor dağılımı (GID) algoritması Şekil 3.1.de ve HKO ve HRO dağılımları Şekil 3.2. de verilmiştir.

#### 3.4.2. Kendi Parmak Boğum İzi Veri Tabanımız ile Yapılan Deney

Bu kısımdaki deneyde, belirli bir standartta olmadan rastgele çekilmiş görüntülerde önerilen sistemin performansından bahsedilecektir.

Tablo 3.3. Kendi Parmak Boğum İzi Veri Tabanımızın (KPBI\_VT) performans değerlendirmesi.

|                       | Parmaklar | KPBI_VT_1<br>(sınıf sayısı:15) | KPBI_VT_2<br>(sınıf sayısı:15) |
|-----------------------|-----------|--------------------------------|--------------------------------|
| Tanıma<br>Oranı (TO%) | SOİP      | 100                            | 100                            |
|                       | SAİP      | 100                            | 100                            |
|                       | SOOP      | 100                            | 100                            |
|                       | SAOP      | 100                            | 100                            |
|                       | SOYP      | 100                            | 100                            |
|                       | SAYP      | 100                            | 100                            |
|                       | SOKP      | 100                            | 100                            |
|                       | SAKP      | 100                            | 100                            |

Tablo 3.4. Kendi Parmak Boğum İzi Veri Tabanımızın (KPBI\_VT) Hata Eşitlik Oranı değerleri (t: sınır değeri)

|                      | Hata Eşitlik Oranı (HEO%) |       |       |      |        |       |      |       |       |      |        |       |
|----------------------|---------------------------|-------|-------|------|--------|-------|------|-------|-------|------|--------|-------|
|                      | SOİP                      |       |       | SOOP |        |       | SOYP |       |       | SOKP |        |       |
|                      | t                         | HKO   | HRO   | t    | HKO    | HRO   | t    | HKO   | HRO   | t    | HKO    | HRO   |
| KPBI_VT_1<br>(1-15)  | 91                        | 0.121 | 0     | 96   | 0.016  | 0     | 95   | 0.045 | 0     | 96   | 0.0642 | 0     |
|                      | 92                        | 0.073 | 0.033 | 97   | 0.004  | 0.033 | 96   | 0.019 | 0.033 | 97   | 0.026  | 0.033 |
| KPBI_VT_2<br>(16-30) | 94                        | 0.002 | 0     | 92   | 0.011  | 0.033 | 92   | 0.021 | 0     | 87   | 0.083  | 0     |
|                      | 95                        | 0     | 0     | 93   | 0.0095 | 0.033 | 93   | 0.19  | 0.033 | 88   | 0.07   | 0.033 |
|                      | Hata Eşitlik Oranı (HEO%) |       |       |      |        |       |      |       |       |      |        |       |
|                      | SAİP                      |       |       | SAOP |        |       | SAYP |       |       | SAKP |        |       |
|                      | t                         | HKO   | HRO   | t    | HKO    | HRO   | t    | HKO   | HRO   | t    | HKO    | HRO   |
| KPBI_VT_1<br>(1-15)  | 89                        | 0.021 | 0     | 90   | 0.014  | 0     | 93   | 0.011 | 0     | 94   | 0.095  | 0     |
|                      | 90                        | 0.014 | 0.033 | 91   | 0.004  | 0.066 | 94   | 0     | 0     | 95   | 0.002  | 0.1   |
| KPBI_VT_2<br>(16-30) | 89                        | 0.021 | 0     | 90   | 0.014  | 0     | 93   | 0.011 | 0     | 94   | 0.009  | 0     |
|                      | 90                        | 0.014 | 0.033 | 91   | 0.047  | 0.066 | 94   | 0     | 0.033 | 95   | 0.002  | 0.1   |

Kullanılan veri tabanındaki görüntüler, çeşitli yaşlardaki kadın ve erkeklerden elde edilmiştir. TO: Tanıma Oranı, SOİPP: Sol İşaret Parmağı SAİP: Sağ İşaret Parmağı, SOOP: Sol Orta Parmak, SAOP: Sağ Orta Parmak, SOYP : Sol Yüzük Parmağı, SAYP: Sağ Yüzük Parmağı, SOKP: Sol Küçük Parmak, SAKP: Sağ Küçük Parmak, Tablo 3.3. ve Tablo 3.4’de her bir parmak için elde edilen tanıma oranları gösterilmiştir.

### 3.5. Genel Değerlendirme

Önerilen sistem, doğruluk açısından en iyi sonucu üreten yöntem olarak öne çıkmaktadır. Sistemin %100 başarı performansının; değişen çevre koşullarında, değişik

el pozisyonlarında, herhangi extra bir ışık kullanmadan gün ışığında rastgele kamera açıları ile çekilen görüntülerle bile değişmemesi sistemin başarısını göstermektedir.

Önerilen sistem, hem eğitilmiş, hem de daha önce gösterilmemiş test verilerinde % 100 başarı sağlamıştır.

## 4. BÖLÜM

### TARTIŞMA, SONUÇ VE ÖNERİLER

#### 4.1. Tartışma ve Sonuç

Bu bölüm, tez çalışması sonucunda elde edilen temel sonuçları özetlemekte ve gelecekte bu konuyla ilgili yapılması mümkün çalışmaları sunmaktadır.

Önerilen sistemin veri tabanı, diğer biyometrik özellikteki (avuç içi, el geometrisi) veri tabanları ile karşılaştırıldığında, oldukça küçük boyutta kalmaktadır. Önerilen yöntem, AOV temelli algoritmaya bağımlıdır, bu algoritma küçük ölçekli veri tabanları için kullanılmakta olduğundan bizim veri tabanımız da küçük seçilmiştir. [1] de geçen bu özellik bizimki gibi küçük ölçekli veri tabanlarında yüksek performans elde edilmesini sağlamaktadır. Bizim çalışmamızda da, veri tabanı büyüdükçe performansın düştüğü gözlemlenmiştir. Bu yaklaşım gelecek çalışmalarda geliştirilmeye açıktır. Bir sonraki adımda, sistemi büyük ölçekli veri tabanları için nasıl aynı performans sonuçları sağlanabileceği araştırılabilir.

Herbir kişinin iki elinden toplam sekiz parmak görüntüsü (her iki elin işaret parmağından, küçük parmağına kadarki bütün parmakları) analiz edilmiş ve Tablo3.1., Tablo 3.2., Tablo 3.3., Tablo 3.4.'de sistem performansı gözlemlenmiştir. Bu tablolardaki değerler, önerilen sistemin performansının %100 olduğunu ve AOV kullanılarak PBİ tanımlama yaklaşımının bütün parmaklar için en iyi sonucu verdiğini göstermektedir.

Bütün değerlendirme tabloları ve şekiller önerilen sistemin her iki PloyU ve kendi veri tabanımız için mükemmel sonuçlar verdiğini göstermektedir.

Sonuç olarak, önerilen PBİ temelli tanımlama sistemi, yüksek doğruluk değerleri ile, küçük ölçekli veri tabanları için mükemmel bir çözüm sunmaktadır.

## 4.2. Öneriler

Tezin hazırlanması esnasında yapılan çalışmalarda, tez konusunun gelişmeye açık olduğu ve değişik metodlar kullanılabileceği görülmüştür. Bu bölümde gelecekte yapılması planlanan çalışmalara yer verilmiştir.

Tez kapsamında önerilen yöntem küçük ölçekli veri tabanları için tanımlanmıştır, ancak büyük ölçekli veri tabanları için de bir takım değişiklikler ile uygulanabileceği düşünülmektedir.

Kullanılan görüntüler veri tabanında olan görüntülerdir, yani kapalı sistem tanıma sistemi kullanılmıştır, ufak değişiklikler ile açık-sistem tanıma sistemine geçişin sağlanabileceği düşünülmektedir.

## KAYNAKLAR

1. Cevikalp, H., Neamtu, M., Wilkes, M., Barkana, A.: 2005. Discriminative Common Vectors for Face Recognition. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, **27**: 4-13.
2. P. H. Hennings-Yeomans, B. V. K. Kumar, and M. Savvides: 2007. Palmprint classification using multiple advanced correlation filters and palm-specific segmentation. **IEEE Transactions on Information Forensics and Security**, **2**: (3): 613-622.
3. D. Zhang, W. K. Kong, J. You, and M. Wong : 2003. On-line palmprint identification. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, **25**: 1041-1050.
4. A. Kumar and D. Zhang: 2006. Personal recognition using hand shape and texture. **IEEE Transactions on Image Processing**, **15**: (8): 2454- 2461.
5. S. Ribaric, and I. Fratric. 2005. A Biometric Identification Sistem Based on Eigenpalm and Eigenfinger Features. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, **27**: 11.
6. X. Lu, D. Zhang, and K. Wang: 2003. Fisherpalms based palmprint recognition. **Pattern Recognition Letters**, **24**: 2829–2838.
7. A. Kumar and D. Zhang: 2007. Hand geometry recognition using entropy-based discretization. **IEEE Transactions on Information Forensics and Security**, **2**: 181-187.
8. Sanchez Paper HG R. Sanchez-Reillo, C. Sanchez-Avila, and A. Gonzalez-Macros: 2000. Biometric Identification through Hand Geometry Measurements”, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, **22**: (10): 1168-1171.
9. D. L. Woodard, P. J. Flynn: 2005. Finger surface as a biometric identifier. **Computer Vision and Image Understanding**, **100** : 357-384.
10. S. Malassiotis, N. Aifanti, and M. G. Strintzis: 2006. Personal Authentication using 3-D finger geometry. **IEEE Transactions on Information Forensics and Security**, **1**: (1): 12-21.

11. J.-G. Wang, W.-Y. Yau, A. Suwandy, and E. Sung: 2008. Person recognition by fusing palmprint and palm vein images based on Lapacianpalm representation. **Pattern Recognition**, **41**: 1531-1544.
12. A. Kumar and K. V. Prathyusha. 2008: Personal authentication using hand vein triangulation. **IEEE Transactions on Image Processing** **18**: (9): 2127-2137.
13. C.-L. Lin and K.-C. Fan: 2004. Biometric Verification Using Thermal Images of Palm-Dorsa Vein Patterns. **IEEE Transactions on Circuits & Sys. for Video Technology**, **14**: 199 – 213.
14. A. Kumar and D. Zhang: 2005. Personal Authentication using multiple palmprint representation. **Pattern Recognition**, **38**: 1695-1704.
15. Z. Sun, T. Tan, Y. Yang, and S. Z. Li: 2005. Ordinal palmprint representation for personal identification. **Computer Vision and Pattern Recognition**, (1): 279-284.
16. C.M. Bishop: 1995. Neural Networks for Pattern Recognition. Oxford University Press.
17. H. Yu and J. Yang: 2001. A direct LDA algorithm for highdimensional data with application to face recognition. **Pattern Recognition**, **34** : 2067-2070.
18. The PolyU Palmprint Database, Hong Kong Polytechnic University. ( Web page: [http:// www. Comp. polyu. edu.hk/biometrics](http://www.Comp.polyu.edu.hk/biometrics).(Date Access :January 2014).
19. Kumar, A., Ravikanth, C.: 2009. Personal Authentication Using Finger Knuckle Surface. **IEEE Transactions on Information Forensics and Security**, **4**: (1): 98-110.
20. Hyung-Ji Lee; Wan-Su Lee; Jae-Ho Chung: 2001. Face recognition using fisherface algorithm and elastic graph matching, pp. 998 - 1001. *International Conference on Image Processing*, October 7-10, 2001, Thessaloniki.
21. Wei-Shi Zheng; Jian-Huang Lai; Yuen, P.C, GA-fisher: 2005 A New LDA-based face recognition algorithm with selection of principal components. **IEEE Transactions on Systems, Man and Cybernetics**, **35**: (5): 1065 - 1078.
22. Y. HE, L. ZHAO, C. ZOU: 2005. Kernel discriminative common vectors for face recognition, pp. 239-244. *Proceedings of the Fourth International Conference on Machine Learning and Cybernetics*, March 6-7, 2009, Patiala.

23. H. Cevikalp, M. Neamtu: 2005. Nonlinear Discriminant Common Vectors, pp 292 – 295. *Signal Processing and Communications Applications Conference*, May 16-17, 2005, Kayseri.
24. C.M. Bishop: 1995. *Neural Networks for Pattern Recognition*. Oxford University Press.
25. Schölkopf, B., 1997. *Support Vector Learning*, Informatik der Technischen Universität, Ph. D. thesis, Berlin, 205 s.
26. S. Mika, G. Rätsch, J. Weston, B. Schölkopf, and K.-R. Müller: 1999. Fisher discriminant analysis with kernels. **IEEE Transactions on Neural Networks for Signal Processing IX**, 41-48 pp.
27. G. Baudat and F. Anouar: 2000. Generalized discriminant analysis using a kernel approach. **Neural Comput**, **12**: (10): 2385-2404 pp.
28. R. Huang, Q. Liu, H. Lu, and S. Ma.: 2002. Solving the small size problem of LDA, pp 29-32. *Proceedings of 16th International Conference on Pattern Recognition*, August 11-15, Canada.

# ÖZGEÇMİŞ

## KİŞİSEL BİLGİLER

Adı, Soyadı: Neslihan KURAT

Uyruğu: Türkiye (TC)

Doğum Tarihi ve Yeri: 13 Şubat 1977, Malatya

email: [n\\_kurat@yahoo.com](mailto:n_kurat@yahoo.com)

Yazışma Adresi: Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği  
Bölümü 38039 Melikgazi/KAYSERİ

## EĞİTİM

| Derece        | Kurum                                                    | Mezuniyet Tarihi |
|---------------|----------------------------------------------------------|------------------|
| Yüksek Lisans | Erciyes Üniversitesi Fen Bilimleri<br>Enstitüsü          |                  |
| Lisans        | Karadeniz Teknik Üniversitesi<br>Bilgisayar Mühendisliği | 1997             |

## İŞ DENEYİMİ

| Yıl       | Kurum                       | Görev                                         |
|-----------|-----------------------------|-----------------------------------------------|
| 2002-2013 | Hava Kuvvetleri Komutanlığı | SAP Danışmanı /<br>İşletim Sistemi Yöneticisi |
| 1997-2002 | Gaziosmanpaşa Üniversitesi  | Öğretim Görevlisi                             |

## YABANCI DİL

İngilizce (KPDS:87)