

İki Boyutlu Yüz Tanıma Metodlarına Yeni Yaklaşımlar;  
Satır ve Sütun Vektörleri Arasındaki Değişimlerin Kullanılması

Ümit Çiğdem Turhal

**DOKTORA TEZİ**

Elektrik Elektronik Anabilim Dalı

Şubat 2008

New Approaches for Two Dimensional Face Recognition Methods;  
Using Variations Between Row and Column Vectors

Ümit Çiğdem Turhal

**DOCTORAL DISSERTATION**

Department of Electric and Electronics

February 2008

İki Boyutlu Yüz Tanıma Metodlarına Yeni Yaklaşımlar;  
Satır ve Sütun Vektörleri Arasındaki Değişimlerin Kullanılması

Ümit Çiğdem Turhal

Eskişehir Osmangazi Üniversitesi  
Fen Bilimleri Enstitüsü  
Lisansüstü Yönetmeliği Uyarınca  
Elektrik Elektronik Anabilim Dalı  
Elektronik Bilim Dalında  
DOKTORA TEZİ  
Olarak Hazırlanmıştır

Danışman: Yrd. Doç. Dr. Alpaslan Duysak

Şubat 2008

Ümit Çiğdem Turhal' ın DOKTORA tezi olarak hazırladığı “İki Boyutlu Yüz Tanıma Metodlarına Yeni Yaklaşımlar; Satır ve Sütun vektörleri arasındaki değişimlerin kullanılması ” başlıklı bu çalışma, jürimizce lisansüstü yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

Üye : Yrd. Doç. Dr. Nihat Adar

Üye : Yrd. Doç. Dr. Erol Seke

Üye : Yrd. Doç. Dr. Ahmet Özmen

Üye : Prof. Dr. İdris Dağ

Üye : Yrd. Doç. Dr. Alpaslan Duysak

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ..... tarih ve ..... sayılı kararıyla onaylanmıştır.

Prof. Dr. Abdurrahman KARAMANCIOĞLU

Enstitü Müdürü

## ÖZET

Örüntü tanıma alanı içerisinde gelişmiş, temel bir araştırma alanı olan otomatik yüz tanıma, kimlik doğrulama ve tespit amaçlı olarak sivil, askeri ve ticari pek çok alanda uygulanmaktadır. Tanıma işlemi, iki veya üç boyutlu görüntü kullanılarak, ya da yüzü temsil eden bir sıcaklık şablonu kullanılarak gerçekleştirilebilir. Yapılan araştırmalar, maliyet düşüklüğü, mevcut veritabanlarının kullanımı ve kolay adaptasyon gibi sebeplerden dolayı, tanıma işleminde iki boyutlu görüntü kullanımının yaygınlaştığını göstermektedir.

İki boyutlu yüz görüntülerini vektöre dönüştürerek tanıma işlemi yapan ilk çalışmalar, boyut artışı ve yüz görüntüsünde aslına göre bilgi kayıplarının oluşması problemleri ile karşılaşmışlardır. Son birkaç yıldır, yüz görüntüsünü vektöre dönüştürmeden iki boyutlu tanıma yapan algoritmalar geliştirilmeye başlanmıştır. Bu algoritmaların temel aldığı yaklaşım iki boyutlu Ana Bileşenler Analizi'dir. Ana Bileşenler Analizi temelli algoritmalar, sınıflandırma doğruluğundan ziyade iyi bir yüz temsili elde etmeyi amaçlandığından, yüz görüntü sınıfları birbirinden uzaklaştırılmakta ancak sınıflar kendi içinde birbirine yakınlaştırılmamaktadır.

Bu tez çalışmasında geliştirilen iki boyutlu yüz tanıma algoritmaları ile, mevcut iki boyutlu tanıma algoritmalarına aşağıda verilen katkılar sağlanmıştır:

- Yüz görüntü sınıfları birbirlerinden uzaklaştırılırken, sınıf içindeki görüntüler birbirlerine yaklaştırılmış böylece sınıflandırma doğruluğu arttırılmıştır;
- Yüzü temsil etmek için kullanılacak matris boyutu veri kaybının olmadığı orijinal yüz uzayı kullanılarak küçültülmüştür;
- Yüz matrisinin satır ve sütun vektörleri arasındaki değişimlerden yararlanan yeni bir yaklaşım geliştirilmiştir;
- Tanımadaki küçük örnek boyutu problemi ortadan kaldırılmıştır.

Geliştirilen algoritmalar AR-Face ve ORL veritabanları kullanılarak test edilmiştir. Karşılaştırma amaçlı olarak, çok bilinen yüz tanıma metodları aynı veri tabanı kullanılarak test edilmişlerdir. Deneysel sonuçlar göstermiştir ki, geliştirilen algoritmaların tanıma performansı çok bilinen algoritmalara göre daha yüksek olmuştur.

Anahtar Kelimeler: 2BABA, ABA, Gram-Schmidt Ortogonalleştirme, Ortak Matris

## SUMMARY

Automatic face recognition which is developed in pattern recognition is a basic research area and is used for identification and verification of individuals in many fields such as civil, military and commercial. Recognition can be made by using 2 or 3 dimensional image or an infrared template. But research showed that using 2 dimensional images for recognition is more common, more convenient with existing databases and easy adaptation.

Initial studies which transform face matrix into a vector for recognition are crossed with information loss and rise of dimensionality. For several years, algorithms have been developed for face recognition that doesn't require transformation of matrix into a vector are based on 2 dimensional Principal Component Analysis (2DPCA). But they provide a good representation rather than a good classification as they maximize the between class scatter only.

With the developed algorithms in this thesis following contributions are made to the existing algorithms:

- Minimization of the within class scatter is achieved while maximizing the total scatter;
- Matrix dimension which represents face image is reduced using original face space;
- A new approach is developed which uses variations between row and column vectors;
- Proposed algorithms overcomes the small sample size problem.

Proposed algorithms are tested using Ar-Face and ORL face databases. In addition for the comparison purpose well known algorithms are also tested using same databases. The experimental studies demonstrated that according to the well known algorithms, better recognition accuracies are achieved for each method which are proposed in this thesis.

Keywords: 2DPCA, PCA, Gram-Schmidt Orthogonalization, Common Matrix

## TEŐEKKÜR

Çalıőmalarımnda, bana danıőmanlık ederek, beni yönlendiren ve her türlü olanađı sađlayan danıőmanım Yrd. Doç. Dr. Alpaslan Duysak'a, çalıőmalarım süresince her türlü destek ve yardımını esirgemeyen sevgili annem ve babam Ayhan-Abdurrahman Erkopan'a, her zaman yanımda olan sevgili ođlum Buđra Turhal ve sevgili eőim Kutalmıő Turhal'a, deđerli hocam Prof. Selami Kılıçkaya'ya ve bugünlere gelmemde büyük emeđi olan çok deđerli hocam merhum Prof. Dr. Hamdi Atmaca'ya sonsuz teőekkürlerimi sunarım.

## İÇİNDEKİLER

<b>BÖLÜM 1 .....</b>	<b>1</b>
<b>1.1 Otomatik Yüz Tanıma Sistemleri.....</b>	<b>2</b>
1.1.1 Yüz görüntü örneği .....	3
1.1.2 Yüz bölgesinin belirlenmesi/ özellik çıkartımı .....	3
1.1.3 Özellik karşılaştırma/ Yüz veritabanı .....	4
<b>1.2 Otomatik Yüz Tanıma Uygulamaları .....</b>	<b>6</b>
<b>1.3 Otomatik Yüz Tanıma Araştırma Grupları.....</b>	<b>8</b>
<b>1.4 Otomatik Yüz Tanıma Sistemlerinde Kullanılan Temel Yaklaşımlar .....</b>	<b>9</b>
1.4.1 Özellik tabanlı yaklaşımlar .....	10
1.4.2 Görünüm tabanlı yaklaşımlar.....	12
1.4.3 Otomatik yüz tanıma için geliştirilen algoritmalar .....	15
<b>BÖLÜM 2 .....</b>	<b>18</b>
<b>2.1 Ana Bileşenler Analizi (ABA) Yöntemi ile Otomatik Yüz Tanıma.....</b>	<b>18</b>
<b>2.2 Orjinal Yüz Görüntüsünün Özüzele İzdüşümü .....</b>	<b>22</b>
<b>2.3 İki Görüntü Arasındaki Benzerliği Bulmak İçin Kullanılan Ölçütler.....</b>	<b>24</b>
<b>2.4 İki Boyutlu Ana Bileşenler Analizi (2BABA) ile Otomatik Yüz Tanıma .....</b>	<b>27</b>
2.4.1 2BABA yöntemindeki gelişmeler.....	30
2.4.2 2BABA yöntemi için önerilen gelişmeler .....	33
<b>BÖLÜM 3 .....</b>	<b>38</b>
<b>3.1 Görüntünün Tanımı .....</b>	<b>40</b>
<b>3.2 Görüntü Dönüşümü.....</b>	<b>44</b>



3.2.1 1-Boyutlu ortogonal ve birimsel görüntü dönüşümleri.....	45
3.2.2 2-Boyutlu ortogonal ve birimsel görüntü dönüşümleri.....	46
<b>BÖLÜM 4 .....</b>	<b>50</b>
<b>4.1 AR-Face Veritabanı.....</b>	<b>52</b>
<b>4.2 ORL Veritabanı .....</b>	<b>54</b>
<b>4.3 Görüntülere Uygulanan Ön İşlemler .....</b>	<b>54</b>
<b>4.4 Tez Çalışmasında Geliştirilen Algoritmalar.....</b>	<b>56</b>
4.4.1 Ortak matris yaklaşımı ile görüntü tanıma .....	56
4.4.2 Yüz tanıma için 2 aşamalı bir algoritma: 2BABA ve sınıf-içi dağılım minimizasyonu.....	64
4.4.3 Görüntünün her iki boyutundaki değişimlerin birlikte kullanımı ile özellik matris boyutunun küçültülerek tanıma performansının artırılması .....	69
4.4.4 Görüntü matrisinin satır ve sütun vektörleri arasındaki değişimleri kullanarak görüntü tanıma .....	75
<b>BÖLÜM 5 .....</b>	<b>83</b>
<b>KAYNAKLAR DİZİNİ .....</b>	<b>93</b>
<b>ÖZGEÇMİŞ .....</b>	<b>100</b>

## ŞEKİLLER DİZİNİ

Şekil 1.1 Genel bir örüntü tanıma sisteminin blok diyagramı .....	1
Şekil 1.2 Otomatik yüz tanıma sisteminin blok diyagramı.....	3
Şekil 1.3 256 seviye gri skala değerleri .....	11
Şekil 2.1 Bir dağılımın ABA dönüşümü ile elde edilen eksen koordinatları. Düz çizgi, orjinal eksen koordinatları (x1, x2); kesikli çizgi, ABA eksen koordinatları (y1,y2) ....	19
Şekil 2.2 Ar-Face veritabanından bir yüz görüntüsünün ABA ile elde edilmiş özyüzlerin lineer kombinasyonu ile yeniden elde edilmesi.....	24
Şekil 2.3. a) ORL veritabanından alınan orjinal bir yüz görüntüsü, b) Orjinal yüz görüntüsü için sırasıyla k=5, 10, 20, 30, 40 özyüz kullanılarak elde edilmiş yaklaşık yüz görüntüleri.....	25
Şekil 2.4 A ve B gibi iki nokta arasındaki L1, L2 mesafe ölçütleri ve kovaryans benzerlik ölçütü.....	26
Şekil 2.5 ORL veritabanından alınmış bir yüz görüntüsü için sırasıyla k=2, 4, 6, 8, 10 özvektör kullanılarak elde edilmiş yaklaşık yüz görüntüleri .....	31
Şekil 3.1 Analog/ sayısal dönüştürücü blok diyagramı .....	38
Şekil 3.2 Sayısal bir görüntü için kullanılan koordinat eksenini .....	40
Şekil 3.3 a)Orjinal bir yüz görüntüsü, b) Orjinal görüntünün pikselleştirilmiş görüntüsü, c) Orjinal bir gül görüntüsü, d) Orjinal gül görüntüsünün pikselleştirilmiş görüntüsü ..	43
Şekil 4.1 Ar-Face veritabanındaki görüntülerden bir kişiye ait görüntü örnekleri. a) Birinci bölümde çekilmiş görüntüler, b) İkinci bölümde çekilmiş görüntüler .....	53
Şekil 4.2 ORL veritabanındaki iki farklı kişiye ait yüz görüntü örnekleri .....	55
Şekil 4.3 Ar-Face veritabanındaki görüntülerin 50x40 piksel olarak küçültülmesi. a) Orjinal görüntüler, b) Küçültülmüş ve ölçeklendirilmiş normalize görüntüler .....	56
Şekil 4.4 Ortak matris yaklaşımı ile elde edilmiş iki farklı yüz sınıfına ait ortak matris görünümü. a) İki farklı sınıfa ait orjinal yüz görüntü örnekleri, b) Bu sınıflar için ortak matris yaklaşımı ile elde edilmiş ortak matris görünümü.....	59

## ÇİZELGELER DİZİNİ

Çizelge 1.1 Özellik tabanlı ve görünüm tabanlı sistemlerin karşılaştırması.....	16
Çizelge 3.1 Temel görüntü dönüşüm teknikleri ve uygulama domenleri.....	49
Çizelge 4.1 Ar-Face veritabanı için birinci testten elde edilen deneysel sonuçlar .....	64
Çizelge 4.2 Ar-Face veritabanı için ikinci testten elde edilen deneysel sonuçlar.....	64
Çizelge 4.3 Kullanılan veritabanları için elde edilen deneysel sonuçlar .....	69
Çizelge 4.4 Ar-face veritabanı üzerinde gerçekleştirilmiş deneysel sonuçlar .....	74
Çizelge 4.5 ORL veritabanı üzerinde gerçekleştirilmiş deneysel sonuçlar .....	75
Çizelge 4.6 Ar-Face veritabanında 1. ve 2. deneysel çalışmalar için elde edilen tanıma oranları .....	81
Çizelge 4.7 Ar-Face veritabanında 3. ve 4. deneysel çalışmalar için elde edilen tanıma oranları .....	81
Çizelge 4.8 ORL veritabanında yapılan deneysel çalışmalar için elde edilen tanıma oranları.....	82
Çizelge 5.1 Bölüm 4.4.2'de sunulan algoritmanın bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları.....	87
Çizelge 5.2 Bölüm 4.4.3'de sunulan algoritmanın bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları.....	89
Çizelge 5.3 Bölüm 4.4.3'de sunulan algoritmanın bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları.....	89
Çizelge 5.4 Bölüm 4.4.4'de sunulan algoritmanın Ar-Face veritabanı üzerinde bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları.....	91
Çizelge 5.5 Bölüm 4.4.4'de sunulan algoritmanın ORL veritabanı üzerinde bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları.....	91

## BÖLÜM 1

### SATIR VE SÜTUN DEĞİŞİMLERİNİ KULLANAN 2 BOYUTLU YÜZ TANIMA ALGORİTMALARI

Örüntü, ilgilenilen varlıklar ile ilgili gözlenebilir veya ölçülebilir bilgilere verilen addır. Ses, görüntü, kan örnekleri, karakter gibi yapılar örüntüye örnek olarak verilebilir. Bu örüntülerin tanınması, yapay zekanın alt dalı olan makina öğrenmesinin bir koludur.

Örüntü tanıma, aralarında ortak özellik bulunan ve aralarında bir ilişki kurulabilen karmaşık işaret örneklerini (ses sinyali gibi) veya nesnelere, bazı tespit edilmiş özellikler veya karakterler vasıtası ile tanımlama veya sınıflandırmadır. Bu bağlamda, örüntü tanımanın en önemli amaçları; bilinmeyen örüntü sınıflarına belirli bir şekil vermek ve bilinen bir sınıfa ait olan örüntüyü teşhis etmektir. Örüntü tanımanın günlük yaşamda mühendislik, tıp, askeri ve ticari pek çok alanda uygulaması mevcuttur. Bunlardan bazıları; ses tanıma, görüntü tanıma, radar hedef sınırlama, biyomedikal kontrol, DNA kimliklendirme, otomatik savunma sistemleri, fabrika üretim hata denetim sistemleridir. Genel bir örüntü tanıma sistemi Şekil 1.1’de blok diyagram olarak verilmiştir.



**Şekil 1.1 Genel bir örüntü tanıma sisteminin blok diyagramı**

Şekil 1.1’deki sistemde tanınması istenen örüntüler giriş uzayını oluşturur. Giriş uzayı insan sesi veya yüzü olabileceği gibi bir uçak veya DNA molekülü olabilir. Bu örüntüler farklı algılayıcılar kullanılarak algılandıktan sonra çeşitli algoritmalar ile örüntüyü tanımlayan ve örüntüye has olan bazı özellikler çıkartılır. Tanıma sisteminin performansı açısından örüntünün hangi özelliklerinin tanımada kullanılacağı çok

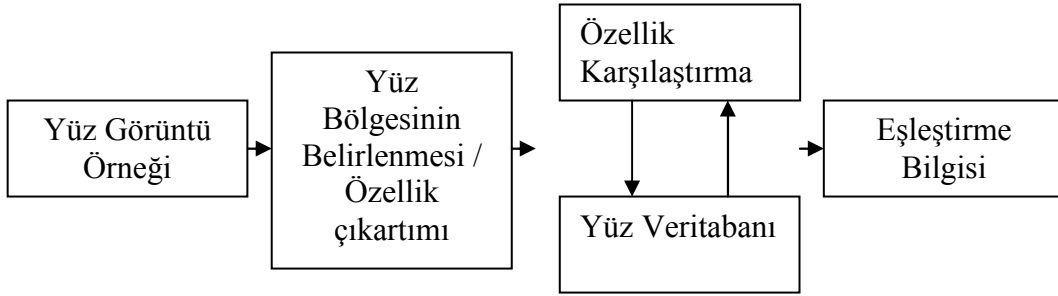
önemlidir. Bu özelliklerin örüntüyü en iyi şekilde temsil edebilecek özellikte olması gerekmektedir. Daha sonra bu özelliklerden yararlanılarak örüntünün sınıflandırılması yapılmaktadır. Sınıflandırma sonuçları ise sistemin çıkış uzayını oluşturmaktadır.

Örüntü tanıma sistemleri günlük hayatımızın birer parçası haline gelmiştir. İstanbul Valiliği'nin desteği ile 2005 yılında İstanbul Emniyet Müdürlüğü bünyesinde plaka algılama sistemi güzel bir örnek teşkil etmektedir (İstanbul Emniyet Müdürlüğü, 2005). Bu sistem ile trafikte seyir halinde bulunan araçların çalıntı olup olmadığının tespiti ve trafik ile ilgili pek çok istatistiki veri otomatik olarak değerlendirilmektedir. MOBESE adlı bu proje “Kent Bilgi ve Güvenlik Sistemi” projesi olarak faaliyete geçirilmiştir. Bu sistemde çalıntı otomobil plakaları ile ilgili bilgilerin ya da bu bilgilerden çıkartılmış olan bazı özneliklerin saklandığı bilgi bankaları yani veritabanları oluşturulmuştur. Bu proje sayesinde kamu hizmetlerinin iyileştirilmesi, trafik ile ilgili işlemlerin kolaylaştırılması ve suç sayısının düşürülmesi hedeflenmiştir.

Örüntü tanıma uygulamalarından biri olarak kimlik doğrulama ve kimlik tanıma amaçlı sivil, askeri, ticari ve sağlık gibi pek çok alanda uygulamaları olan otomatik yüz tanıma sistemleri bu tezin konusunu oluşturmaktadır. Aşağıdaki bölümlerde otomatik yüz tanıma sisteminin ne olduğu, nasıl çalıştığı, hangi alanlarda kullanıldığı ve tarihsel süreç içerisinde bu sistemlerde kullanılan algoritmaların gelişimi verilmiştir.

### **1.1 Otomatik Yüz Tanıma Sistemleri**

Örüntü tanımanın özel ve zor bir durumu olan Otomatik Yüz Tanıma, örüntü tanıma alanı içerisinde gelişmiş olan çok temel bir araştırma alanıdır. Otomatik yüz tanıma sistemi; yüzün karakteristik özelliklerini analiz ederek ya da çeşitli noktalarda yüzün ölçülebilir ve davranışsal karakteristiklerini ifade eden biyometrik ölçümler yaparak daha önceden oluşturulmuş bir veritabanı ile karşılaştırma yolu ile kişiyi tanımlar. Genel bir otomatik yüz tanıma sisteminin blok diyagramı Şekil 1.2'de gösterildiği gibidir.



Şekil 1.2 Otomatik yüz tanıma sisteminin blok diyagramı

### 1.1.1 Yüz görüntü örneği

Otomatik yüz tanıma sistemlerinde kullanılan yüz görüntü örnekleri, çeşitli sensörler kullanılarak elde edilmektedir. Bu sensörlerden elde edilen yüz görüntüleri, 2-boyutlu veya 3-boyutlu olabileceği gibi, yüz görüntüsünü temsil eden bir yüz sıcaklık şablonu da olabilir. Eğer 2-boyutlu tanıma yapılacaksa kullanılacak olan sensör bir kameradır. Standart kamera tarafından yakalanmış görüntüler kullanılarak 2-boyutlu yüz tanıma işlemi gerçekleştirilir. Bunun yanı sıra 3-boyutlu tanıma ya da yüz görüntüsü için oluşturulmuş yüz sıcaklık şablonu ile de tanıma yapılabilmektedir. Ancak 2-boyutlu tanıma metodları, diğer metodlar ile karşılaştırıldığında kolaylık ve sistem maliyeti açısından daha uygundur. Fakat buna rağmen 2-boyutlu yüz tanıma gerçekleştiren metodlar, diğer tanıma metodlarına göre değişen çevresel koşullara daha duyarlı olduğundan elde edilen tanıma doğrulukları daha düşüktür. Yapılan araştırmalar tanıma işleminde 3-boyutlu görüntü kullanımının, kullanılan tanıma yönteminin çevresel faktörlere olan duyarlılığı azalttığını göstermektedir. 3-boyutlu görüntü kullanımının dezavantajı ise görüntüyü elde etmek için kullanılacak tarayıcıların maliyetinin yüksek olması ve var olan veritabanları ile uyumlamasıdır. İşte bu sebepler tanıma işleminde 2-boyutlu görüntü kullanımının yaygınlaşmasına sebep olmuştur.

### 1.1.2 Yüz bölgesinin belirlenmesi/ özellik çıkartımı

Çeşitli sensörler kullanılarak elde edilen bir görünümde yüz bölgelerinin belirlenmesi işlemi sistemin en zor aşamalarından biridir. Çeşitli sebeplerden dolayı tanınması istenen yüz görüntüsünün yerinin ve boyutunun belirlenmesi o kadar da kolay

bir işlem değildir. Örneğin; tanınması istenen yüz görüntüsünün bulunduğu görünüm içerisinde birden fazla yüz görüntüsü olabilir. Görünümdeki ışıklandırmalar, yüz ifadeleri, pozisyonu ya da skalaları değişiyor olabilir. Görünümdeki yüz görüntüsü atkı ya da gözlük gibi bazı kapatıcı unsurlar ile kapatılmış olabilir. Bahsedilen sebepler verilen bir görünümde tanınması istenen yüz bölgesinin tespitini zorlaştırır.

Sensörler tarafından elde edilmiş görünümde tanınması istenen yüz bölgesinin bu aşamada çeşitli yöntemler kullanılarak tespiti yapıldıktan sonra o yüz görüntüsünü en iyi şekilde temsil edebilecek özelliklerin elde edilmesi gereklidir. Bu özellikler özellik çıkartım işlemi ile gerçekleştirilir. Özellik çıkartım işleminin temeli insan beyninin algılamasından yola çıkarak anlaşılabilir. Yapılan araştırmalarla insan beyninin özellik çıkartımı denilen bir yaklaşımla insan yüzlerini tanımladığı öğrenilmiştir. İnsan beyninin algılama yöntemi, insan yüzünü, kaş, göz, burun ve dudaklar gibi belirleyici organlara ayırıp vektörel biçimde tanımlama şeklindedir. İnsan beyninin belirli bir sesi veya görüntüyü tanımak için kullandığı kuralları tam olarak tanımlamak mümkün değildir. Ancak bu tanıma işlemini bilgisayar tabanlı otomatik yüz tanıma uygulamalarında belirli kriterlere oturtmak mümkündür. Böylece insan yüzlerinin birbirinden bağımsız ve belirli karakteristik niteliklerinin elde edilmesi özellik çıkartım süreci ile gerçekleştirilir. Sonuç olarak orijinal görüntüye göre daha düşük boyutlu ve orijinal görüntüyü en iyi şekilde temsil edebilen biyometrik bir şablon elde edilmiş olur. Literatürde yüz tanıma için geliştirilmiş otomatik yüz tanıma sistemlerinin birbinden farkı da özellik çıkartımı için kullanılan yöntemlerin farklılığından kaynaklanmaktadır.

### **1.1.3 Özellik karşılaştırma/ Yüz veritabanı**

Otomatik yüz tanıma sisteminde özellik çıkartımı işlemini çıkartılan bu özelliklerin eldeki veritabanı ile karşılaştırılması işlemi izler. Karşılaştırma işleminde kullanılacak veritabanı kimliği bilinen kişilere ait görüntülerin ya da bu görüntülere ait özellik çıkartımı işleminde kullanılan yöntemlerle çıkartılmış bazı özniteliklerin saklandığı bilgi bankasıdır. Veritabanında kullanılan bu yüz görüntüleri sistemin eğitim kümesini oluşturur. Bu şekilde sistem kimliği bilinen görüntüler ile eğitilmiş olur ve öğrenen bu sistem daha önceden görmediği yüzleri de doğru olarak tanıyabilir yani genelleme yapabilir. Sistemin iyi genelleme yapabilmesi yüz görüntüsü için çıkartılan özelliklerin yüzü en iyi şekilde temsil edebilmesine bağlıdır.

Veritabanındaki bir kişiye ait farklı görüntülerin oluşturduğu küme bir sınıf olarak adlandırılır. Bu adımda kimliği tespit edilmek istenen yüz görüntüsü için çıkartılmış özellikler ile veritabanındaki her bir sınıfa ait önceden çıkartılarak depolanmış özellikler karşılaştırılarak sınıflandırma işlemi yapılacaktır. Sınıflara ayırıştırma işleminde kullanılacak belirli bir yöntemin olması gerekmektedir. Kullanılan yöntemlerde gerçekleştirilecek olan işlemler, uygulamanın ne olduğuna bağlıdır. Örneğin, uygulama kimlik belirleme uygulaması ise, önceki adımda çıkartılmış olan özelliklerden yararlanılarak sınıflandırma yapılır. Bir diğer yaygın uygulama ise kimlik doğrulama işlemidir. Bu uygulamada yapılan işlem, kimliği doğrulanmak istenen yüz görüntüsü için elde edilmiş olan özellikler ile veritabanında o kişi için önceden elde edilip kaydedilmiş olan özellikler ile karşılaştırılarak kimliğin doğrulanması olacaktır. Kimliği belirlenmek ya da doğrulanmak istenen kişi için çıkartılmış özellikler ile veritabanında bulunan kimliği bilinen kişiler için çıkartılmış özelliklerin birbirlerine ne kadar benzediklerini belirlemek için kullanılacak çeşitli mesafe ve benzerlik ölçütleri mevcuttur (Yambor, 2000). Bu karşılaştırma mesafe ölçütü kullanılıyorsa özellikler arasında hesaplanan mesafelerin küçüklüğüne bakılarak, benzerlik ölçütü kullanılıyorsa da benzerliğin büyüklüğüne bakılarak yapılır.

Özelliklerin karşılaştırılması işleminden sonra sistemin çıktısı olarak eşleştirme sonuçları elde edilmiş olur. Gerçekleştirilen uygulamaya bağlı sistemin çıktısı tek bir eşleştirme bilgisi olabileceği gibi birden fazla muhtemel eşleştirmelere ait bilgi de olabilir. Bu durumda listeden en uygun olanı seçmek bir operatör yardımı ile yapılır.

Bazı zor yüz tanıma işlemlerinde tanınması istenen yüz görüntüsünün daha kolay tanınması için sisteme bir de ön işleme adımının eklenmesi gerekebilir. Yüz tanımda uygulanan ön işleme işlemleri; sistemi ışıklandırmanın ayarı, poz normalizasyonu, görüntünün standart bir büyüklüğe getirilmesi, yüzün ortalanması, arka fonun temizlenmesi, tanımayı zorlaştıracak saç, sakal ve gözlüklerin ortadan kaldırılması gibi işlemlerden oluşur. Bazı görüntülerde de sadece yüz bölgesi yer almaktadır. Bu durumda da yüz görüntüsünün verilen görünümünden elde edilmesi işleminin uygulanmasına gerek yoktur. Bu tez çalışmasında yapılan deneysel çalışmalarda kullanılan veritabanlarındaki görüntüler de sadece yüz bölgesini içerdiğinden görünümünden yüz bölgesinin belirlenmesi adımı uygulanmamıştır.



Otomatik yüz tanıma sisteminin genel özelliği sistemin tamamen temassız olarak kullanıcının herhangi bir fiziksel etkileşimine gerek duyulmadan çalışıyor olmasıdır. Sistemin kullanımı kolaydır ve özel bir uzmanlık gerektirmez. Mevcut yapıya kolay entegrasyon sağladığından kamera ya da görüntü almaya yarayan her türlü cihazla birlikte hiç problemsiz olarak çalışabilmektedir. Her bir kişiyi tekrar kaydetme zorunluluğu olmadan var olan görüntüler kullanılabilir. Herhangi bir ek tanıtıcı materyale gerek duyulmadan sadece yüz ile kimlik saptaması yapılabilir. İşte bu özellikler kimlik belirleme işleminde yüz kullanımını iris tanıma, damar tanıma ve parmak izi tanıma gibi kimlik belirlemede kullanılan diğer uygulamalardan üstün kılmaktadır. Otomatik yüz tanıma sisteminin (Bkz. Şekil 1.2) performansı sistemin tanıma doğruluklarına, çevresel faktörlere olan duyarlılığına, işlem karmaşıklığına ve süresine ayrıca sistemin maliyetine bakılarak değerlendirilmektedir.

## **1.2 Otomatik Yüz Tanıma Uygulamaları**

Otomatik yüz tanıma sisteminin günlük yaşamda pek çok uygulama alanı mevcuttur. Bunlardan bazıları; geçiş kontrol, personel devam kontrol, bankacılık ve finans, güvenlik ve emniyet, bilgi veri güvenliği, ulaşım ve pasaport ve sağlık sektöründeki uygulamaları olarak sıralanabilir.

Yüz tanımanın işyerlerinde personel devam kontrol işlemleri için kullanımı pek çok avantaj sağlamaktadır. Bu şekilde kişinin kendini tanımlayan bir karta ihtiyacı yoktur. Çünkü bu sistemde kişinin sadece yüzünü kullanarak tanımlanması yapılabilmektedir. Bunun için kimliği tanımlanmak istenen kişinin kameraya bakması yeterlidir. Kameradan alınan görüntü sistemde bulunan veritabanındaki görüntülerle karşılaştırılarak kimlik tespiti yapılmaktadır. Böylece, kart taşımaya gerek kalmadığı gibi kartın çalınması ya da kaybolması, kartı başkasının yerine okutma, sürekli kart basma maliyeti ve kopyalanabilirlik gibi problemlerin önüne geçilmiş olur. Otomatik yüz tanıma ile getirilen personel tanıma işlemlerinde örneğin parmak izi kullanılan tanıma işlemlerinde yaşanan bazı sorunlar da ortadan kaldırılabilir. Bunlardan bazıları; parmakta meydana gelen bazı yaralanmalar ya da başka sebeplerden dolayı parmak izini zor okuma ya da hiç okuyamama, ek kart veya şifreye gerek duyulması gibidir. Ayrıca otomatik yüz tanıma sistemi daha güvenilirdir. Unutulma, çalınma veya kaybedilme ihtimali yoktur. Maliyeti düşüktür, sarf ve işletme maliyeti yoktur.

Otomatik yüz tanıma sisteminin güvenlik alanında da çeşitli uygulamaları vardır. Başta A.B.D. olmak üzere pek çok ülke özellikle havalimanı gibi halka açık yerlerde insanların haberi olmadan otomatik yüz tanıma sistemleri ile kimlik belirleme konusundaki çalışmalara hız vermiştir. Otomatik yüz tanıma sisteminde muhtemel suçluya ait resim veya robot resim kullanılarak eldeki suçlulara ait veritabanları ile karşılaştırılarak muhtemel suçlunun kimliği tespit edilebilmektedir. Bu sayede suç oranları azaltılabilmekte, kayıt işlemlerinde kimlik sahteciliği riski azaltılabilmekte, zamandan ve paradan tasarruf sağlanabilmektedir.

Güvenlik alanındaki bir başka uygulama da elektronik devri NEC tarafından gerçekleştirilmiştir. NEC sınırlarda otomatik yüz tanıma teknolojisini kullanarak kişileri otomobilleri içerisindeyken tanıyan dünyanın ilk otomatik sınır kontrol sistemini geliştirmiştir (NEC, web sayfası) Bu sistem Hong Kong-Shenzhen sınırındaki kontrol noktalarında kullanılmaya başlanmıştır. Sistem şu şekilde çalışmaktadır: Araç sınır kapısına yaklaşırken plakası okunmaktadır. Basit bir otomatik veritabanı kontrolü ile kullanıcının kimliği belirlenmektedir. Daha sonra araç kullanıcısının yüzü kameralar ile taranarak kişinin veritabanından araştırılması yapılarak araç sahibi ile aynı kişi olup olmadığı saptanmaktadır. Eğer araç sahibi ile araç kullanıcısı aynı kişi ise sınır kapısı açılmakta ve geçişe izin verilmektedir. NEC tarafından geliştirilmiş olan bu sistem şu ana kadar sadece tır şöförleri için uygulanmaktadır. Sistemin yeni gelişmelerle araç içindeki sekiz yolcuya kadar tanıma yapabilmesine çalışılmaktadır.

Bilgisayar ve internet teknolojisinde gelişmeler otomatik yüz tanıma sistemlerinin uygulama alanlarının artışına sebep olmuştur. Bu uygulamalar iletişim, ticari ve bankacılık işlemlerinin internet ortamında güvenilir ve hızlı bir şekilde gerçekleştirilmesini yaygınlaştırmıştır. Bu hızlı gelişim ile veri güvenliği ve bilgisayar erişim kontrolünün de önemini arttırmıştır. Bilgisayar sistemini ve veri güvenliğini korumak için daha önce uygulanan şifre ya da smart kart gibi bazı protokollerin güvenilirliği azalmıştır. Bu güvenliğin daha iyi bir şekilde sağlanması için geliştirilmiş yüz biyometriği ile sisteme girişe olanak veren teknolojiler geliştirilmiştir. Bu sayede gizli belgelere erişim engellenebilmekte ve sisteme izinsiz giriş yapmak isteyen kişilerin tespiti yapılarak güvenlik en üst düzeye çıkartılabilmektedir. Ayrıca bankacılık işlemlerinde kasa dairesi ve hazine dairesi gibi hassas alanlara girişte hızlı ve güvenilir kimlik doğrulanması sağlanabilmektedir.

Otomatik yüz tanıma sistemlerinin bu kullanım alanlarının dışında fotoğraf makineleri gibi teknolojik ürünlerde de kullanımına başlanmıştır. Fotoğraf makinelerinde bu teknoloji kullanımı ile çekilen görüntü kalitesinin artırılması amaçlanmıştır. Örneğin, çekilen fotoğraflardaki yüz bölgelerinin gölgeden arındırılması, giyilen kıyafet rengi ve arka plandan makineye düşen ışık gibi nedenlerle karanlık çekilebilen ten rengi, yüz tanıma özelliği ile aydınlık ve net bir şekilde fotoğraflanabilmektedir.

Otomatik yüz tanıma sistemin sağladığı hız, kolaylık ve güvenilirlik gibi çok önemli bu avantajlara rağmen sistemin performansı kimi zaman bazı sebeplerden dolayı çok da yüksek değildir. Bu sebeplerin başında, yüz görüntülerinin çok büyük boyutlu olması ve farklı insanların yüz görüntüleri arasında küçük farkların dışında yapısal olarak çok büyük benzerliklerin olması gelir. Bunların yanı sıra görüntülerde aydınlatma, ifade ve poz farklılıklarının bulunması ve atkı ya da gözlük kullanımı gibi kapatıcı unsurların bulunması da otomatik yüz tanıma işleminin performansında düşümlere sebep olmaktadır. Tanıma işlemindeki bütün bu zorluklara rağmen insan beyni farklı yüz görüntülerini zorluk çekmeden doğru bir şekilde tanıyabilmektedir. Ancak insan beyni ile aynı hassaslıkta tanıma yapabilecek güçlü bilgisayar programları hala geliştirilememiştir. Bu alanda yapılan çalışmalarda hata oranları uygulanan yöntemlerin pek çoğunun görüntülerdeki aydınlatma, ifade ve poz farklılıklarına olan duyarlılığından ötürü daha hala çok yüksek seviyelerdedir.

Otomatik yüz tanıma tekniklerinin günlük yaşamdaki önemi bahsedilen uygulamalar ile ortaya konabilmektedir. Bu sebepten bu alandaki araştırmalar artarak devam etmektedir. Bu alanda dünyada ve Türkiye’de araştırmalar yapan çok sayıda kurum ve kuruluş mevcuttur. Bir sonraki bölümde bu araştırma gruplarına değinilmiştir.

### **1.3 Otomatik Yüz Tanıma Araştırma Grupları**

Otomatik yüz tanıma sistemleri üzerinde araştırmalar yapan araştırma gruplarına, bunların yapmış oldukları ya da halen devam etmekte olan projelerine, yüz tanıma ile ilgili algoritmalar ve yapılan gelişmelere Yüz Tanıma web sayfasından erişilebilmektedir (Face Recognition Home Page). Ülkemizde bu konudaki araştırmalar Boğaziçi Üniversitesi Bilgisayar Mühendisliği Bölümü’nde kurulmuş olan Algısal Zeka

Laboratuvarı'nda (PILAB) yürütülmektedir. PI Laboratuvarı'nda çalışmalar yapan üç tane araştırma grubu mevcuttur. Bunlar; Görüntü İşleme ve Bilgisayar Vizyon Grubu, Makine Öğrenme Grubu ve Ses İşleme Grubu'dur. Grubun TÜBİTAK ile de yürüttüğü projelere ve diğer çalışmalara kendi web sayfasından ulaşılabilir (Bogaziçi University).

Uluslararası alanda otomatik yüz tanıma yöntemlerini kullanarak yazılım üreten ve birleştiren pek çok ticari firma mevcuttur. Bu alanda geliştirilen ticari ürünlerin bağımsız olarak değerlendirildiği tek ortam FRVT (Yüz Tanıma Satıcı Testi)'dir. Bu organizasyon FBI, NIST, Amerikan Gizli Servisi ve Adalet Bakanlığı gibi 15 kadar kuruluş tarafından desteklenmektedir. 2000 ve 2002 yıllarında yapılan FRVT testleri göstermiştir ki ön cepheden olmayan (yüzün sağa sola ve yukarı aşağıya doğru belli açılar yaptığı) görüntülerde sistemlerin tanımlama performanslarında gözle görülür bir düşüş olmaktadır. Resim görüntüleri yerine video görüntülerinin kullanılması tanımlama performanslarında gözle görülür bir düşüş olmaktadır. Erkeklerin tanımlanma performansı %6-9 oranında daha başarılıdır. Genç yaştakilerin tanımlanma performansı yaşlılara göre daha zordur. Performans her 10 yaş için %5 oranında artmaktadır. Dış mekanlar için yüz tanımlama performansının geliştirilmesine gerek vardır. Tanımlanma ve izlenme listesi performansı kullanılan veritabanı veya izleme listesi büyüklüğünün logaritmasıyla doğrusal olarak azalmaktadır (Kaptanoğlu, 2003). Amerika Birleşik Devletleri hükümeti yüz tanıma ile yapılabilir uygulamaların ve bunların sınırlarının belirlenmesi aynı zamanda da gelişimin desteklenmesi amacıyla çok sayıda değerlendirme gerçekleştirmektedir. Bu amaçla kurulan FERET (Yüz tanıma teknolojisi değerlendirmeleri), 1993'ten 1997'ye kadar DARPA (Koruma geliştirme Ürün Ajansı) sponsorluğunda çalışmıştır

Literatürde otomatik yüz tanıma sistemleri için geliştirilmiş pek çok algoritma mevcuttur. Bu algoritmalar temel olarak iki yaklaşım etrafında toplanabilir. Bu yaklaşımlar ve otomatik yüz tanıma sistemlerinde kullanılan algoritmaların tarihsel gelişimi sonraki bölümlerde incelenmiştir.

#### **1.4 Otomatik Yüz Tanıma Sistemlerinde Kullanılan Temel Yaklaşımlar**

Literatürde yayınlanmış çok çeşitli otomatik yüz tanıma yaklaşımı vardır. Bu yaklaşımların kategorizasyonu farklı kriterlere göre yapılabilir. Bu kriterlerden bazıları;

yüz görüntüsünün algılanma şekli, bakış açısı ve özellik çıkartımı için kullanılan yöntemlerdir. Literatürde bu konu üzerinde çalışan araştırmacıların başvurabileceği kaynaklar referanslarda bulunabilir (Samal and Iyengar,1992; Chellappa et. al.,1995; FG1, 1995; FG2, 1996; FG3, 1998).

Bu tez çalışmasında geliştirilen yüz tanıma algoritmaları için kullanılan yöntemler özellik çıkartımı kriterine göre kategorize edilebilir. Özellik çıkartımı yöntemlerinin farklılığı bağlamında literatürde otomatik yüz tanıma için kullanılan iki baskın yaklaşım vardır. Bunlardan birincisi özellik tabanlı yaklaşımlar ikincisi de görünüm tabanlı yaklaşımlardır.


#### **1.4.1 Özellik tabanlı yaklaşımlar**

Özellik tabanlı yaklaşımlarda, veritabanında varolan, kimliği bilinen yüz görüntüleri üzerinde bazı özellik noktaları tespit edilir ve bu özellik noktaları arasındaki mesafeler ya da açılar gibi değişmeyen özellikler hesaplanarak bir veritabanında saklanır. Daha sonra kimliği belirlenmek istenen bir yüz görüntüsü (test görüntüsü) geldiğinde bu yüz görüntüsü için de bu mesafe ya da açılar hesaplanıp veritabanındaki ölçüm değerleri ile karşılaştırılarak kişinin kimliği belirlenir. Hesaplanan bu ölçümler; kafa genişliği, göz köşeleri arasındaki mesafe, çene noktası ile göz köşeleri arasındaki açılar ve benzeri gibidir. Bu tür yöntemlerde özellik noktaları manuel olarak belirlenebileceği gibi tamamen otomatik olarak da belirlenebilir. Özellik çıkartımı için bölgesel yüz özellikleri kullanıldığından görünümde saç ya da arka plan etkisi hissedilmez. Ancak yüz görüntüsündeki ifade farklılıklarından dolayı tanıma performansı düşebilmektedir.

Bölgesel özellik tabanlı bu metodlarda, büyük boyutlu orjinal yüz görüntüsü daha düşük boyutlu özellik vektörleri ile temsil edildiğinden yüz tanımadaki büyük boyut problemi baştan çözümlenmiş olmaktadır. Boyut küçüldüğünden depolama gereksinimleri azdır. Yöntemin her sınıf için sadece bir yüz görüntü örneği olduğu durumda tanıma performansının daha yüksek olduğu görülmüştür (Tan et al., 2006). Sistemin tanıma performansının yüksekliği seçilen özellik noktalarının o kişiyi tanımlamada ne derecede etkin olduğuna bağlıdır.

Şu iki sebepten dolayı özellik tabanlı metodların eleştirildiği görülmektedir; birincisi, bazı kompleks durumlarda özellik çıkartımının zor olmasıdır. İkincisi ise

özelliik çıkartırken görüntünün gri seviye değeri gibi tanımada faydalı bazı bilgilerin hiç kullanılmamasından bu bilgilerin kaybolmasıdır. Gri seviye değeri renklerin siyahtan beyaza doğru değıştiđi bir renk skalasıdır (Şekil 1.3). Bu skaladaki renkler 0-255 arasındaki toplam 256 renk kodu ile gösterilir. Bu renk skalasında siyah renk 0 ile beyaz renk de 255 ile temsil edilir. Görüntünün temsilinde sadece geometrik özelliklerinin kullanılması tek başına yeterli olmayabilir. Bu nedenle görüntü temsilinde gri seviye değeri kullanımını gerekir.



Şekil 1.3 256 seviye gri skala değeri

Literatürde özellik tabanlı tanıma metodları üzerine yapılmış pek çok çalışma mevcuttur. Bu çalışmalara örnek olarak Cox ve arkadaşlarının (1996) yapmış olduđu çalışma verilebilir. Bu çalışmada yüz görüntüsü üzerinde manuel olarak belirlenmiş 30 farklı özellik noktası için özellikler çıkartılmıştır ve deneysel çalışmalarda %95 oranında doğru tanıma performansı elde edilmiştir. Yine yüz bölgesindeki özellik noktalarının manuel olarak belirlendiđi Kaya ve Kobayashi (1972) tarafından yapılmış çalışmada tanımlanmış özellik noktaları arasındaki mesafeler Öklid mesafeleri kullanılarak hesaplanmıştır (Yambor, 2000). Başka bir çalışmada Hjelmas ve Wrodlsen (1999) insanları tanımlamada kullanılan çok önemli yüz özelliklerinden biri olan gözleri kullanarak tanıma yapmışlardır. Çok popüler bir veritabanı üzerinde gerçekleştirilen deneysel çalışmalarda %85 oranında bir tanıma performansı elde etmişlerdir. Campedelli ve arkadaşları ise (2003) özellik tabanlı ve özellik noktalarının tamamen otomatik olarak belirlendiđi bir tanıma sistemi geliştirmişlerdir. Bu sistemde yüz

görüntüsü üzerinde 16 farklı özellik noktası tespit edilerek filtre kullanımı ile bu özellik noktaları etrafında ayrıcalıklı dokular oluşturulmuştur. Tanıma işlemi ise bu ayrıcalıklı dokular arasındaki benzerlik ölçüsünden yararlanılarak gerçekleştirilmiş ve %93 oranında tanıma performansı elde edilmiştir. Özellik noktalarının otomatik olarak belirlendiği bir başka çalışma da Kanade'nin (1977) yapmış olduğu çalışmadır. Bu çalışmada da tanıma için göz kenarları, ağız kenarları ve burun delikleri ile çene üst noktası arasındaki mesafe ve açılar kullanılmıştır.

#### **1.4.2 Görünüm tabanlı yaklaşımlar**

Sınıf başına çok sayıda görüntü örneğinin bulunduğu uygulamalarda yüzün işlenmesi için özellik tabanlı metodlara göre daha az zahmetli yollara ihtiyaç duyulmuştur. Bu durum görünüm tabanlı tekniklerin doğuşuna sebep olmuştur. Bilgisayar vizyonu, örüntü tanıma, makine öğrenmesi ve yapay ağlar gibi disiplinlerdeki gelişmeler, yüz görüntüsünü bir vektör ile temsil eden ve özellik tabanlı metodların zahmetli özellik çıkartım prosedürlerini önleyen görünüm tabanlı tekniklerin kullanımını öne çıkarmıştır. Görünüm tabanlı bu metodlarda özellik tabanlı metodlara nazaran tanıma sisteminin geçerliliği ve verimi büyük ölçüde geliştirilmiştir. Bu nedenle de görünüm tabanlı metodlar 90'lardan bu yana yüz tanıma alanında yaygın olarak uygulanan tekniklerden biri haline gelmiştir.

Görünüm tabanlı yaklaşımlarda yüz görüntüleri, görünümdeki bütün piksellerin gri seviye değerleri yani yoğunlukları, satırlar alt alta gelecek şekilde ya da sütunlar alt alta gelecek şekilde sıralanarak büyük boyutlu tek bir vektör ile temsil edilir. Yüz görüntülerinin bu şekilde temsilinin getirdiği iki avantaj vardır. Birincisi, yüz görüntülerini ayırmak için gerekli detaylı yapının ve şekil bilgisinin tümünün korunuyor olmasıdır. İkincisi ise, özellik tabanlı metodlara göre görünümdeki daha fazla bütünsel bilgiyi tutuyor olmasıdır (Tan et al., 2006). Görünüm tabanlı bu metodlarda görüntünün bütünü kullanıldığı için saç ve arka plan gibi çevresel faktörler tanıma performansını büyük ölçüde etkilemektedir. Ayrıca gözlük, atkı gibi kapatıcı unsurların bulunması, görüntülerdeki skala, duruş açısı ve poz farklılıkları, aydınlatma ve ifade farklılıkları, sakal bırakılması gibi faktörler de bu tip metodlarda tanıma performanslarının düşmesine sebep olmaktadır.

İyi bir görünüm tabanlı tanıma metodunun temelinde iyi bir öğrenme mekanizması yatar. Sistem önce eğitim kümesini oluşturan kimliği bilinen kişilerin görüntüleri kullanılarak eğitilir. Yani görüntülerden çeşitli yöntemler kullanılarak özellik çıkartılır ve bu özellikler bir veritabanında saklanır. Bu şekilde sistem eğitildikten sonra kimliği bilinmeyen bir yüz görüntüsü geldiğinde bu görüntü için de eğitim kümesindeki görüntüler için yapıldığı gibi aynı yolla özellikler çıkartılır. Sistem daha sonra kimliği belirsiz kişiye ait özelliklerin veritabanındaki eğitim sınıflarından hangisinin özelliklerine daha yakın olduğunu tespit ederek tanıma işlemini gerçekleştirir. Görünüm tabanlı metodların temeli olan öğrenme mekanizmasının iyi bir performans üretebilmesi için yeteri kadar büyük eğitim sınıflarına ihtiyaç duyulmaktadır (Jain and Chandrasekaran, 1982). Çünkü bu metodlarda yukarıda belirtildiği gibi görüntü matrisleri görüntü vektörlerine dönüştürülmekte böylece görüntüler büyük boyutlu tek bir vektör ile temsil edilmektedir. Teorik olarak ise her sınıf için eğitim kümesinde kullanılan görüntü sayısı ile görüntü vektör boyutu arasında olması gerek belirli bir oran vardır. Bu oran da şudur: Sınıf başına kullanılan görüntü sayısı en azından görüntü vektör boyutunun 10 katı kadar olmalıdır (Jain and Chandrasekaran, 1982). Bu da demektir ki bir kişiyi görünümüne bakarak tanıyabilmek için o kişinin çok sayıda fotoğrafına ihtiyaç duyulmaktadır.

Bu problem görünüm tabanlı metodlarda boyut indirgenmesi gerekliliğini ortaya koymaktadır. Görünüme dayalı bu metodlarda boyut indirgenmesi için altuzay yöntemleri kullanılır. Bu yöntem ile büyük boyutlu yüz görüntü matrisi orjinal uzayından daha düşük boyutlu bir özellik uzayına taşınır. Literatürde yüz tanıma için sunulmuş görünüm tabanlı metodlarda boyut indirgenmesi amacı ile kullanılan altuzay yöntemlerinin lineer ve lineer olmayan pek çok uygulaması vardır (Li et al., 2003; Zhao et al., 1998). Kirby ve Sirovich (1990) uyguladıkları görünüm tabanlı tanıma metodu ile bir yüz görüntüsünü ana bileşenler olarak adlandırılan vektörlerin lineer kombinasyonu şeklinde temsil etme fikrini ortaya atmışlardır. Daha sonraları Turk ve Petland (1991 a) bu tekniği yüz tanıma problemi için kullanmıştır. Ana Bileşenler Analizi (ABA) olarak adlandırılan bu istatistiksel metod daha sonraları 3 boyutlu nesne tanıma için genişletilmiştir (Murase and Nayar, 1995). Ana bileşenler analizi görüntünün iyi bir şekilde sınıflandırılmasından çok orjinal görüntüye göre daha düşük boyutlu bir görüntü temsili amaçlar. Bu nedenle tanıma doğrulukları çok yüksek



seviyelerde değildir. Yöntem eğitimde kullanılan sınıfların tüm görüntüleri arasındaki dağılımı en büyükleyen izdüşüm yönlerini verir (Turk and Petland, 1991 a). Görüntüler arasındaki toplam dağılımı maksimize eden izdüşüm yönlerini seçerken görüntüler arasındaki aydınlatma ve ifade farklılıkları gibi istenmeyen değişimler de tutulur (Belhumeur et al., 1997). Bu da bu metodun, aydınlatma ve ifade farklılıkları gibi sınıf içi değişimlere karşı etkili bir yöntem olmadığını gösterir.

Sınıflandırma doğruluğu açısından ABA'ne göre çok daha iyi sonuçlar veren görünüm tabanlı bir diğer lineer altuzay metodu da Doğrusal Ayırtaç Analizi'dir (DAA) (Belhumeur et al., 1997). Bu metod sınıflar arası dağılımı en büyüklerken sınıf içi dağılımı da en küçüklemeyi amaçlar. Ancak DAA'nin yüz görüntüsü gibi büyük boyutlu veriler için direk olarak kullanımının uygun olmadığı görülmüştür (Chen et al., 2000; Yu and Yang, 2001; Lu et al., 2003). Bu metodlarda yüz görüntülerindeki bakış açısı, aydınlatma ve ifade farklılıklarında meydana gelen değişimlerin tanıma performansını düşürdüğü görülmüştür. DAA'ndeki bu eksiklikleri gidermek amacıyla bazı çalışmalar yapılmıştır. Bu çalışmalardan bazıları; kuadratik DAA (Lu et al., 2003), Fisher's DAA (Belhumeur et al., 1997) ve Direk, Tam DAA (Yu and Yang, 2001) şeklinde sıralanabilir. Jing ve arkadaşları (2003), yüz tanıma işlemi için ABA+DAA metodunu kullanmışlardır. Jing ve arkadaşlarının yapmış olduğu bu çalışmada yüz görüntüleri daha düşük boyutlu bir yüz altuzayına izdüşürülmüş bundan sonra bu uzayda DAA uygulanmıştır. Bu çalışmadaki problem, ABA ile görüntü daha düşük boyutlu bir uzaya izdüşürülürken önemli olabilecek ayırıcı bilginin de atılmış olabileceği sorusudur (Yu and Yang, 2001). Bu durumu önlemek için ayrı bir ABA adımı olmayan Direk DAA (DDAA) metodu geliştirilmiştir.

Fisherfaces metodu da, görüntü tanıma popöler olarak kullanılan bir ABA+DAA metodudur (Zhao et al., 1998). Bu metodda düşük boyutlu özellik uzayı elde etmek için ABA kullanılmış ardından bu düşük boyutlu özellik altuzayında, Fisher ayırıcı vektörleri hesaplanmıştır. Bu metodda, sınıf içi dağılım matrisi, tekil olduğu zaman ortaya çıkan küçük örnek boyutu problemi vardır. Li ve arkadaşları (2003) çalışmalarında, altuzay analiz metodlarını karşılaştıran bir çalışma sunmuşlardır.

Son zamanlarda, lineer görüntü tanıma metodlarının uygulanabilirlik kısıtlarını ortadan kaldırmak için lineer olmayan görüntü tanıma metodları geliştirilmiştir. Yang ve arkadaşları (2005) çalışmalarında kernel ABA + Fisher lineer ayırıcı analizinden

oluşan iki aşamalı Kernel Fisher Ayırıcı (KFA) yapısı geliştirmişlerdir. Yine lineer olmayan bir çalışma olarak Kim ve arkadaşları (2005) Kernel Hebian Algoritması (KHA) olarak adlandırılan bir algoritma geliştirmişlerdir. Bu çalışmada genelleştirilmiş Hebian kullanılmış ve Kernel ABA iteratif olarak uygulanmıştır. Bu algoritma öğreticisi olmayan bir öğrenme tekniği olduğundan, elde edilen görüntü modeli farklı uygulamalar için de bir model teşkil etmektedir. Yang ve arkadaşları (2003), ABA'den elde edilen dönüşüm vektörleri ile Kernel ABA'den elde edilen dönüşüm vektörlerini birleştirerek kompleks dönüşüm vektörleri elde etmişlerdir. Elde edilen bu kompleks dönüşüm vektörleri üzerine izdüşüm alındıktan sonra ikinci bir özellik çıkarma işlemi olarak aynı şekilde kompleks Fisher lineer ayırıcı analizi (kompleks DAA) uygulaması yapmışlardır.

Görüntü örneklerinin ikinci derece korelasyonlarına dayanan izdüşüm yönlerini bulmayı amaçlayan Eigenface ve Fisherface metodlarının da, daha yüksek derecedeki görüntü korelasyonlarını hesaba katan kernel uygulamaları yapılmıştır. Yang (2002) kernel ve klasik metodların performanslarını karşılaştırdığı bir çalışma sunmuştur. Yapılan bu çalışmada, kernel metodların görüntüyü tanıma ve tanımlamada daha iyi sonuçlar verdiği görülmüştür.

Özet olarak otomatik yüz tanıma sistemleri için kullanılan özellik tabanlı ve görünüm tabanlı bu iki temel yaklaşımın kullanılan özellikler, hafıza gereksinimleri, performans gibi kriterler açısından karşılaştırılması Çizelge 1.1'de verildiği gibidir.

### **1.4.3 Otomatik yüz tanıma için geliştirilen algoritmalar**

Bu tez çalışmasında iki boyutlu yüz tanıma yapan dört farklı tanıma algoritması geliştirilmiştir. Geliştirilen algoritmalar, görünüm tabanlı yaklaşımlardan biri olan Ana Bileşenler Analizi (ABA) yöntemini ve bu yöntemin iki boyutlu uygulaması olan İki Boyutlu Ana Bileşenler Analizi (2BABA) (Yang et al., 2004) yöntemini temel almaktadır. ABA ve 2BABA yöntemleri görüntü sınıfları arasındaki mesafeyi arttırarak sınıflandırma yapan ve en küçük karesel hata ile orjinal görüntüyü yeniden elde edebilen bir görüntü dönüşüm yöntemleridir. Her iki yöntemin de ayrıntılı olarak açıklanması tarihsel gelişim süreci içerisinde bir sonraki bölümde verilmiştir.

Çizelge 1.1 Özellik tabanlı ve görünüm tabanlı sistemlerin karşılaştırması

Yaklaşım	Özellik Tabanlı	Görünüm Tabanlı
Özellikler	Bölgesel özellikler	Bütünsel özellikler
İşlem karmaşası	Pratik değerli, basit	Kompleks algoritmalar, uzun bir eğitim süreci
Kullanılan görüntü sayısı	Tek görüntü olsa bile iyi bir performans	Sınıf başına çok sayıda görüntü kullanımı gerekir
Boyut	Düşük boyutlu	Çeşitli yöntemlerle boyut azaltılmalıdır
Hafıza	Az	Çok
Çevresel faktörlere duyarlılık	Az	Çok
Performans	Daha düşük doğruluk	Daha yüksek doğruluk

Tez çalışması kapsamında geliştirilen algoritmalarından birincisi; ortak matris yaklaşımı ile yüz görüntülerinin tanınmasıdır. Bu algortmada görüntü sınıflarından her birini temsil eden ve tanımda kullanılan, sınıflar için değişmez ve tek olan ortak matris elde edilmiş ve bu matris daha sonra tanımda kullanılmıştır. Tanımda kullanılan ortak matris iki yolla elde edilmiştir; birincisi Gram-Schmidt Ortogonalleştirme prosedürü, ikincisi Sınıf içi dağılım matrisidir. Bu tanıma algoritmasında sınıf içi dağılımlar en küçüklenmek sureti ile tanıma gerçekleştirilmiştir.

Geliştirilen algoritmalarından ikincisinde; 2BABA yöntemi ile Gram-Schmidt ortogonalleştirme prosedürü birlikte kullanılarak sınıflar arası dağılımları en büyüklerken sınıf içi dağılımları en küçükleyen bir tanıma algoritması sunulmuştur. Geliştirilen bu algortmada görüntü sınıflarını temsil edecek olan özellik matrisi 2BABA yöntemi ile elde edilmiştir. Daha sonra aynı sınıftaki farklı görüntülere ait aynı özvektör yönündeki özellik vektörleri arasındaki farklılıklar Gram-Schmidt ortogonalleştirme prosedürü kullanılarak yok edilmiştir. Böylece sınıfları temsil eden ve tanımda kullanılacak olan ortak özellik matrisleri elde edilmiştir.

Geliştirilen algoritmalarından üçüncüsünde; görüntü matrisinin sütun vektörleri üzerinde 2BABA yöntemi gerçekleştirilmiş ve daha sonra yine Gram-Schmidt ortogonalleştirme prosedürü uygulanarak sınıfları temsil eden ortak özellik matrisi elde edilmiştir. Sonrasında elde edilmiş olan ortak özellik matrisinin boyutu görüntü satırları üzerinde gerçekleştirilen 2BABA'ndan elde edilen özvektörler kullanılarak indirgenmiştir.

Tez çalışmasında geliştirilen dördüncü ve son algortmada daha önce çalışılmamış olan ve tanıma için görüntü matrisinin satırları ile sütunları arasındaki değişimleri kullanan bir algoritma sunulmuştur. Bu algortmada sınıfları temsil edecek ve tanımada kullanılacak olan ortak özellik matrisi, görüntü satırları ile sütunları arasındaki değişimleri gösteren karşı-kovaryans matrisinin özvektörleri kullanılarak elde edilmiştir.

## BÖLÜM 2

### OTOMATİK YÜZ TANIMA SİSTEMLERİNİN TARİHSEL GELİŞİM SÜRECİ VE MATEMATİKSEL ALTYAPISI


İlk resmi yüz tanıma metodu 25 Mayıs 1888 yılında Sir Francis Galton tarafından gerçekleştirilmiştir. 1960'larda yüz tanıma için geliştirilmiş olan ilk yarı otomatik sistem ağız, burun, kulaklar ve gözler gibi özellikleri fotoğraf üzerinde belirlemede bir insana ihtiyaç duymaktaydı. Fotoğraf üzerinde bu özellikler belirlendikten sonra genel bir referans noktaya göre bu özellikler arası mesafeler ve oranlar hesaplanıp referans veri ile karşılaştırılmaktaydı. 1970'lerde Goldstein ve arkadaşları (1971), tanımayı otomatikleştirmek için saç rengi ve dudak kalınlığı gibi 21 özel öznel işaretleyici kullanmışlardır. Bu ilk çalışmalardaki ortak problem ölçümlerin hesaplanması ve özellik noktalarının yerlerinin belirlenmesi işlemlerinin manuel olarak yapılmasıydı. Yapılan bu ilk çalışmalar özellik tabanlı yaklaşımlardandır. Kirby ve Sirovich (1988) yüz tanıma problemlerine standart bir lineer cebir tekniği olan Ana Bileşenler Analizi'ni uygulamışlardır. Bu çalışma yüz görüntülerinin normalizasyonu ve diziliminin doğru bir şekilde kodlanabilmesi için çok sayıda değer gerekli olduğunu göstermesi açısından yüz tanıma araştırmalarında bir dönüm noktası olarak sayılabilir. Görünüm tabanlı bu yaklaşım bu tezde geliştirilen algoritmaların da temelini oluşturmaktadır.

1990'dan sonra bazı sebepler ve gereksinimlerden dolayı otomatik yüz tanımaya olan ilgi artmıştır. Bunun sebepleri arasında; sivil ve ticari araştırma projelerinin öneminin artması, yapay sinir ağları sınıflandırmasında gerçek zamanlı hesaplamaların ve adaptasyonun öneminin artması, gerçek zamanlı donanımların kullanılabilirliğinin sağlanması, uyuşturucu trafiği ve terörist aktiviteleri gibi hareketlerin artmasından dolayı bu faaliyetleri izleyebilecek ve olaylarla insanlar arasında bağlantı kurabilecek uygulamalara olan ihtiyacın artması sayılabilir.

#### 2.1 Ana Bileşenler Analizi (ABA) Yöntemi ile Otomatik Yüz Tanıma

Turk ve Petland (1991 a), yüz tanıma için özyüzler teknolojisini sunmuşlardır. Bu çalışma ile güvenli gerçek zamanlı otomatik yüz tanıma sistemlerine olan ilgi

artmıştır. Yayınlandığı tarihten bu yana iki binin üzerinde atıf alan bu çalışmada yüz tanıma için Ana Bileşenler Analizi önerilmiştir. Özyüzler teknolojisi olarak da adlandırılan bu çalışmada boyut indirgenmesi için Karhunen Loève dönüşümünü kullanılmıştır. Bu yöntem, büyük boyutlu orjinal yüz uzayından lineer olarak daha düşük boyutlu bir özellik altuzayına (özuzay) dönüşümü gerçekleştiren ve tanıma işlemini bu özuzay içerisinde gerçekleştiren bir yöntemdir. Bu özuzay görüntüler arasındaki dağılımın en büyük olduğu yönlerin belirlendiği bir altuzaydır. Şekil 2.1’de bir dağılımın orjinal eksen koordinatları ve ABA dönüşümü sonrasındaki eksen koordinatları görülmektedir.



**Şekil 2.1 Bir dağılımın ABA dönüşümü ile elde edilen eksen koordinatları. Düz çizgi, orjinal eksen koordinatları (x1, x2); kesikli çizgi, ABA eksen koordinatları (y1,y2)**

Özuzay aslında, içerisinde tanımlanan yüz görüntüleri arasındaki sınıflar arası dağılımın en büyüklendiği bir altuzaydır. Bu altuzay yüz görüntüleri arasındaki dağılımı ifade eden simetrik ve kare bir matris olan görüntü kovaryans matrisinden ( $S_1$ ) yararlanılarak oluşturulur.  $m$  adet satır ve  $n$  adet sütundan oluşan bir  $A$  yüz görüntü matrisi,  $d = mn$  olacak şekilde  $d$  boyutlu bir yüz görüntü uzayında bir  $\vec{a}$  vektörü ile gösterilebilir.

$$\vec{a} = [a_1 \ a_2 \ \dots \ a_d]^T \quad 2.1$$

İstatistiksel olarak her bir yüz görüntüsü bulunduğu uzayda bir rassal örnek olarak düşünülebilir. Özyüzler yöntemi ile orjinal görüntülerin yer aldığı uzaydan daha düşük boyutlu ve orjinal yüz görüntü uzayı tarafından kapsanan lineer bir özuzaya dönüşümü gerçekleştirecek ana bileşenler yani özvektörler hesaplanır. Bu vektörler eğitimde kullanılan yüz görüntü vektörlerinin kovaryans matrisinin özvektörleridir ve görüntü kovaryans matrisinin özdeğer- özvektör ayrışımından elde edilir.

Eğitim kümesindeki görüntü vektörlerinin ortalaması  $\bar{\mathbf{a}}$  hesaplanıp eğitim kümesindeki bütün görüntülerden çıkartılırsa ortalaması uzaklaştırılmış görüntü vektörü  $\left(\bar{\mathbf{a}}_i\right)$  elde edilir.

$$\bar{\mathbf{a}}_i = \mathbf{a}_i - \bar{\mathbf{a}}, \quad \bar{\mathbf{a}} = \frac{1}{M} \sum_{i=1}^M \mathbf{a}_i \quad 2.2$$

Bu eşitlikteki M, eğitim kümesinde kullanılan toplam görüntü sayısını göstermektedir. Eğitim kümesinde bulunan ortalama uzaklaştırılmış görüntü vektörleri  $\hat{\mathbf{A}}$  matrisinin sütunlarını oluşturacak şekilde birleştirilsin.

$$\hat{\mathbf{A}} = \begin{bmatrix} \bar{\mathbf{a}}^1 & \bar{\mathbf{a}}^2 & & \bar{\mathbf{a}}^M \\ \mathbf{a} & \mathbf{a} & \dots & \mathbf{a} \end{bmatrix} \quad 2.3$$

Bu durumda sütunları eğitim kümesinde bulunan ortalama uzaklaştırılmış görüntü vektörlerinden oluşan matrisin transpozu ile çarpımından görüntü sınıfları arasındaki dağılımı gösteren kovaryans matrisi ( $\mathbf{S}_I$ ) elde edilir. Bu matris simetrik ve kare bir matristir ve eğitimdeki görüntüler arasındaki değişimi ifade etmek için kullanılır.

$$\mathbf{S}_I = \hat{\mathbf{A}}\hat{\mathbf{A}}^T \quad 2.4$$

Kovaryans matrisi eğitim kümesindeki yüz görüntülerinin arasındaki dağılımı vermesi açısından önemlidir. Bu şekilde arasındaki dağılımın hangi yönde ne kadar değişim gösterdiği belirlenmiş olur bu da görüntülerin sınıflandırılması kolaylaştırır.

Bunun yanısıra kovaryans matrisi değişkenlerin değişim yönlerinin, birbirlerine bağımlı olup olmadıkları gibi konularda da bilgi verir. Örneğin; herhangi iki değişken birlikte değişme eğilimindeyse yani biri ortalama değer üzerindeyken diğeri de ortalama değer üzerinde olma eğiliminde ise bu iki değişken arasındaki kovaryans pozitif olacaktır. Diğer yandan, değişkenlerden biri ortalama değer üstündeyken diğeri ortalama değer altındaysa bu iki değişken arasındaki kovaryans negatif olacaktır. Eğer iki değişken bağımsız ise bu iki değişkenin kovaryansı sıfır olur.

Buna rağmen tersi doğru değildir. Eğer iki değişken arasındaki kovaryans sıfır ise bu iki değişken bağımsız olmak zorunda değildir. Kovaryansları sıfır olan rassal değişkenler “ilişkisiz” olarak adlandırılır. Kovaryans kimi zaman iki rassal değişken arasındaki “lineer bağımsızlığın” bir ölçüsü olarak da adlandırılır.

Kovaryans matrisinin özdeğer- özvektör ayrışımı genelleştirilmiş özproblemler olarak adlandırılabilir. Genelleştirilmiş özproblemler, çözümlü olmaları ya da yaklaşık olarak iyi bir çözüm elde edebilmeleri ve analizde basit bir lineer cebir gerektiriyor olmalarından dolayı bir dizi değer fonksiyonun optimizasyonunda kullanılan etkin bir metoddur. Genelleştirilmiş özproblemler ile çözülebilen uygulamalar şu şekilde sıralanabilir: Görüntü verisindeki maksimum değişimi içeren veri uzayında bir izdüşüm yönü kümesinin bulunması (Ana Bileşenler Analizi), belirli bir değer fonksiyonunu minimize ederek iki farklı veri sınıfını ayıracak bir hiper düzlemin bulunması (Fisher Ayırıcı Analizi), ya da aynı verinin iki farklı temsili arasındaki karşılıklı bağıntının bulunması (Kanonik Bağntı Analizi) gibi. Bunların yanısıra bazı sınıflandırma algoritmaları da özproblemlerin çözümüne indirgenebilmektedir.

Simetrik bir matris olan yüz görüntüleri kovaryans matrisinin,  $(S_1)$  özdeğer-özvektör ayrışımı, öze analiz yolu ile aşağıdaki gibi yapılabilir:

$$\begin{aligned} S_1 \vec{e}_i &= \lambda_i \vec{e}_i \\ S_1 E &= LE \end{aligned} \tag{2.5}$$

Burada E; sütunları  $\vec{e}_i$  özvektörlerinden oluşan matris ve L; çapraz elemanları  $\lambda_i$  özdeğerlerinden oluşan ve diğer elemanları sıfır olan matrisi göstermektedir.



Eşitlik 2.5 genelleştirilmiş simetrik bir özdeğer problemidir. Farklı özdeğerlere ( $\lambda_i$ ) karşılık gelen özvektörler ( $\vec{e}_i$ ) birbirlerine ortogondur. Simetrik matrislerin özdeğerleri ve bu özdeğerlere karşılık gelen özvektörler gerçektir. Bu özdeğer probleminin çözümü ile hesaplanan  $\{\vec{e}_i\}$  özvektörler kümesi ve  $\{\lambda_i\}$  bu özvektörlere karşılık gelen özdeğerler kümesi olmak üzere ( $S_1$ ) matrisini köşegenleştiren bir koordinat uzayına dönüşümü gerçekleştirir. Bu yeni koordinat uzayında, ( $S_1$ ) matrisi köşegen olduğundan, bu uzaydaki değişim yönleri birbirinden ilişkisizdir. Bu dönüşümün gerçekleştirilmesi için kullanılan özvektörler, birbirleri ile ilişkisiz değişim yönlerini bu özvektörlere karşılık gelen özdeğerler ise bu yönlerdeki değişim miktarını göstermektedir.

Yüz görüntülerinin kovaryans matrisinin özdeğer-özvektör ayrışımı öze analiz yolu ile yapıldığında yüz görüntü vektörlerinin elemanları olan her bir pikselin birbiri ile ne şekilde değiştiğinin ölçüsü hesaplanmış olur. Böylece özuzayı tarayan özvektörler elde edilmiş olur. Özuzaydaki her bir özvektör yönü görüntüler arasındaki değişim yönlerini göstermektedir. Hesaplanan bu özvektörlerden en büyük özdeğere karşılık gelen yüz görüntüleri arasındaki değişimin en fazla olduğu boyutu, en küçük özdeğere karşılık gelen özvektör de yüz görüntüleri arasındaki değişimin en az olduğu boyutu verir. Görüntü kovaryans matrisinin sıfır olmayan özdeğerlerine karşılık gelen özvektörleri özuzay için yüz görüntülerinin küçük hatalar ile elde edilebileceği ortonormal bir taban oluşturur. Toplam değişimin %90'nı ilk %5 ile %10 boyut içinde yer alır. Özuzay için hesaplanan özvektörlerden her biri "özyüz" olarak adlandırılır. Bu şekilde eğitim kümesindeki yüz görüntülerinin hesaplanan özvektörler ile ifade edilen özuzaya izdüşümü alınarak orjinal görüntüler için düşük boyutlu bir temsil elde edilmiş olur (Turk and Petland, 1991 b).

## 2.2 Orjinal Yüz Görüntüsünün Özuzaya İzdüşümü

Yüz görüntülerinin kovaryans matrisinin  $P \times d$  olacak şekilde sıfır olmayan özdeğere karşılık gelen  $P$  tane özvektörü vardır. Yüz görüntülerinin kaç tane özvektör ile tanımlanacağı uygulamaya bağlı olarak değişse de pratik uygulamalarda kullanılacak özvektör sayısı  $k$ , eğitimde kullanılan görüntü sayısından çok daha küçük olacak şekilde seçilir. Daha sonra eğitimde kullanılan yüz görüntülerinin seçilen sayıdaki

özvektörler üzerine tek tek izdüşümü alınarak o boyutta yüz görüntüsünü temsil eden skalar bir sayı elde edilir ( $\mathbf{v}$ ). Yüz görüntü vektörünün her bir özvektör üzerine izdüşümü bir skalara karşılık gelmektedir (Turk and Petland, 1991 b).

$$\mathbf{v} = \mathbf{e}^T \mathbf{a} \quad 2.6$$

Buna göre bir  $\vec{\mathbf{a}}$  görüntü vektörü bu koordinatlar cinsinden aşağıdaki gibi yaklaşık bir şekilde ifade edilebilir (Turk and Petland, 1991 b):

$$\vec{\mathbf{a}} = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_k] \ \mathbf{k} \ll \mathbf{d} \quad 2.7$$

Bir kere özuzay hesaplandıktan sonra test görüntülerinin kimlik tespiti artık yapılabilir. Bunun için kimliği belirsiz yüz görüntülerinin bulunduğu test kümesinden alınan bir görüntü vektörü ( $\vec{\mathbf{a}}_t$ ), eğitim görüntülerinde yapıldığı gibi aynı şekilde özuzaya izdüşürülür ve bu test görüntüsünün özuzaydaki koordinatlar cinsinden ifadesi olan  $\vec{\mathbf{a}}'_t$  bulunur.

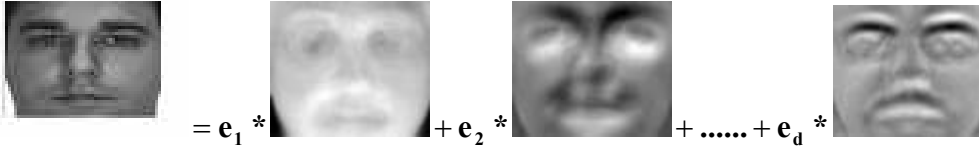
$$\vec{\mathbf{a}}'_t = [\mathbf{v}_{1,t} \ \mathbf{v}_{2,t} \ \dots \ \mathbf{v}_{k,t}] \ \mathbf{k} \ll \mathbf{d} \quad 2.8$$

Eğitimdeki hangi görüntü sınıfının bu test görüntüsünü en iyi şekilde tanımladığını bulmak için Öklid mesafesi kullanılır. L2 normu olarak da adlandırılan öklid mesafesi aşağıdaki gibi hesaplanır :

$$\mathbf{L}_2(\vec{\mathbf{a}}', \vec{\mathbf{a}}_t) = \sum_{i=1}^k (\mathbf{v}_i - \mathbf{v}_{i,t})^2 \quad 2.9$$

Yukarıdaki formülde hesaplanan öklid mesafesi eğitim kümesinde kullanılan hangi sınıf için en küçük değeri veriyorsa test görüntüsü o sınıfa aittir tanısı yapılarak tanıma işlemi gerçekleştirilmiş olur. ABA yöntemi ile orjinal bir yüz görüntüsü hesaplanan özyüzlerin lineer kombinasyonu ile yeniden elde edilebilir. Eğer sıfır

olmayan özdeğere sahip olan tüm özyüzler kullanılırsa orjinal görüntünün aynısı elde edilir. Ancak hepsi kullanılmazsa orjinal görüntünün bir yaklaşığı elde edilebilir. Şekil 2.2’de Ar-Face veritabanından alınan orjinal bir yüz görüntüsünün bütün özdeğerlerine karşılık gelen özyüzlerin lineer kombinasyonu ile nasıl elde edilebileceği görülmektedir.



$$= e_1 * \text{[Özyüz 1]} + e_2 * \text{[Özyüz 2]} + \dots + e_d * \text{[Özyüz d]}$$

**Şekil 2.2** Ar-Face veritabanından bir yüz görüntüsünün ABA ile elde edilmiş özyüzlerin lineer kombinasyonu ile yeniden elde edilmesi

Şekil 2.3’de ise ORL veritabanından alınan orjinal bir yüz görüntüsü ve orjinal yüz görüntüsünün sırasıyla  $k = 5,10;20;30;40$  özdeğer kullanılarak elde edilmiş yaklaşık görüntüleri görülmektedir.

### 2.3 İki Görüntü Arasındaki Benzerliği Bulmak İçin Kullanılan Ölçütler


İki farklı görüntünün birbirine ne kadar benzediğini bulmak için kullanılan iki genel yol vardır. Bunlardan birincisi görüntüler arasındaki mesafeyi ölçmektir (Yambor, 2000). İkicisi ise iki görüntünün ne kadar benzer olduğunu ölçmektir. Mesafe ölçülürken iki görüntü arasındaki mesafe en küçüklenmeye çalışılır böylece birbirine benzer iki görüntü küçük bir mesafe ölçütü üretir. Benzerlik ölçülürken ise, iki görüntü arasındaki benzerlik en büyüklenmeye çalışılır böylece benzer olan iki görüntü yüksek bir benzerlik değeri üretir. Pek çok muhtemel benzerlik ve mesafe ölçütü vardır. Bunlardan en yaygın olarak kullanılanları; L1 normu, L2 normu (Öklid normu), Kovaryans, Mahalonobis ve korelasyondur.

$L_1$  normu; aynı zamanda city block normu ya da toplam norm olarak da bilinir. Pikseller arasındaki mutlak değer farkının toplandığı bu ölçüt bir mesafe ölçütüdür. Herhangi bir A ve B görüntüleri arasındaki  $L_1$  normu:

$$L_1(\mathbf{A}, \mathbf{B}) = \sum_{i=1}^N |A_i - B_i| \quad 2.10$$

şeklinde hesaplanır.

Kovaryans; açı ölçüsü olarak da bilinir. İki normalize vektör arasındaki açıyı hesaplar. İki normalize vektörün nokta çarpımları alınarak hesaplanır. Herhangi bir A ve B görüntüsü arasındaki kovaryans benzerlik ölçütü:

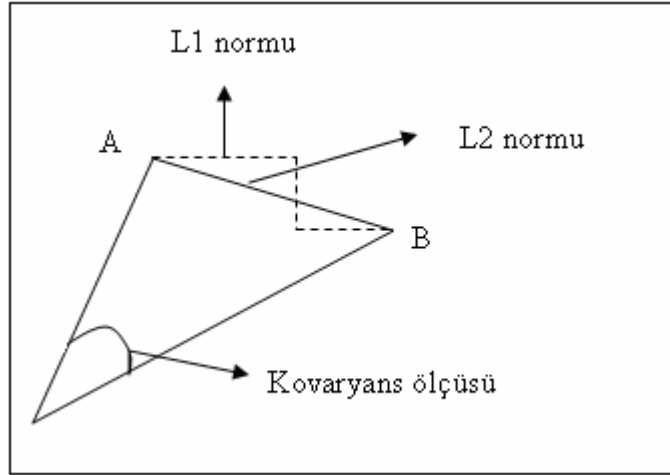


Şekil 2.3. a) ORL veritabanından alınan orjinal bir yüz görüntüsü, b) Orjinal yüz görüntüsü için sırasıyla k=5, 10, 20, 30, 40 özyüz kullanılarak elde edilmiş yaklaşık yüz görüntüleri

$$\text{cov}(\mathbf{A}, \mathbf{B}) = \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} \quad 2.11$$

şeklinde hesap edilir. Kovaryans bir benzerlik ölçütüdür. Kovaryans değeri etkisiz duruma getirilerek bu bir mesafe ölçütü haline gelir. Şekil 2.4'de  $\mathbf{A}$  ve  $\mathbf{B}$  gibi herhangi iki nokta arasındaki L1 normu, L2 normu gibi mesafe ölçütleri ile bu iki noktanın benzerlik ölçüsünü veren kovaryans benzerlik ölçütünün ölçümü verilmiştir.

**A** ve **B** gibi iki nokta arasındaki L1 normu noktalı olarak gösterilmiş ve L2 normu ise düz çizgi ile gösterilmiştir.



**Şekil 2.4 A ve B gibi iki nokta arasındaki L1, L2 mesafe ölçütleri ve kovaryans benzerlik ölçütü**

Mahalanobis Mesafesi; piksellerin ve belirli bir boyuttaki özdeğerlerin çarpımlarının toplamını hesaplar. Herhangi bir A ve B görüntüsü arasındaki Mahalanobis mesafesi:

$$\mathbf{Mah(A,B)} = -\sum_{i=1}^N \mathbf{A_i B_i C_i}, \quad \mathbf{C_i} = \frac{\mathbf{1}}{\lambda_i} \quad 2.12$$

şeklinde hesaplanır. Burada  $\lambda_i$ , i. Boyuttaki özdeğeri göstermektedir. Mahalanobis mesafesi bir mesafe ölçütüdür.

Korelasyon: Korelasyon ölçütü, iki görüntünün pikselleri arasındaki değişim oranını ölçer ve (-1) ile (1) arasında değişen değerler üretir. (-1) değeri görüntülerin birbirinin zıttı olduğunu gösterirken (1) değeri görüntülerin benzer olduğunu gösterir (Yambor, 2000). Herhangi bir A ve B görüntüsü arasındaki korelasyon ölçütü:

$$\text{corr}(\mathbf{A}, \mathbf{B}) = \sum_{i=1}^N \frac{(\mathbf{A}_i - \boldsymbol{\mu}_A)(\mathbf{B}_i - \boldsymbol{\mu}_B)}{\sigma_A \sigma_B} \quad 2.13$$

şeklinde hesaplanır.  $\boldsymbol{\mu}_A, \boldsymbol{\mu}_B$  sırasıyla A ve B görüntü sınıflarının ortalamasını,  $\sigma_A, \sigma_B$  sırasıyla A ve B görüntülerinin standart sapmasını göstermektedir.

Otomatik yüz tanıma için Turk ve Petland (1991 b) tarafından sunulmuş olan özyüzler teknolojisi görünüm tabanlı görüntü tanıma, temsil ve sıkıştırma amaçları için sıklıkla kullanılan bir yaklaşımdır. En az karesel hata cinsinden yüz görüntüsünü en iyi şekilde temsil eden bir metod olmasına rağmen kullanılan yüz görüntüsünün büyük boyutlu oluşu hesaplanan kovaryans matrisinin de boyutlarının çok büyük olması ancak bu büyük boyuta rağmen eğitimde kullanılan görüntü sayısının ise düşük olması kovaryans matrisinin değerlendirilmesini zorlaştırır (Penev and Sirovich, 2000). Aynı zamanda kovaryans matrisinin özvektörlerini elde etmek için de uzun bir zamana gerek duyulmaktadır. Eğitimde kullanılan görüntü sayısının görüntü boyutuna göre çok küçük olması küçük örnek boyutu probleminin ortaya çıkmasına sebep olur.

#### 2.4 İki Boyutlu Ana Bileşenler Analizi (2BABA) ile Otomatik Yüz Tanıma

Ana Bileşenler Analizinin bu dezavantajlarını ortadan kaldırabilmek amacı ile Yang ve arkadaşları (2004), görüntüden özellik çıkartmak için 2 Boyutlu Ana Bileşenler Analizi (2BABA) olarak adlandırılan yeni bir metod sunmuşlardır. Bu methodda yüz görüntü matrisinin işlem öncesinde bir vektöre dönüştürülmesi gerekmemektedir. Yüz görüntüleri için kovaryans matrisi direk olarak iki boyutlu görüntü matrisleri kullanılarak hesaplanır. 1 boyutlu ABA'ne göre üç önemli avantajı vardır. Bunlardan birincisi kovaryans matrisinin değerlendirilmesindeki kolaylıktır. İkincisi optimal izdüşüm eksenini olarak kullanılacak olan özvektörleri belirlemek için gerekli zamanın daha kısa olması üçüncüsü de küçük örnek boyutu problemi için daha uygun bir metod olmasıdır.

Bu algoritmanın ana fikri  $m \times n$  boyutlu bir  $\mathbf{A}$  yüz görüntü matrisinin aşağıdaki lineer dönüşümle  $n$ -boyutlu birimsel bir  $\mathbf{X}$  vektörü üzerine izdüşümünü alarak yüz görüntü matrisi için özellik çıkartmaya dayalıdır (Yang et al., 2004).

$$\mathbf{Y} = \mathbf{A}\mathbf{X} \quad 2.14$$

Bu dönüşüm ile  $\mathbf{A}$  görüntü matrisinin özellik vektörü olarak adlandırılan ve  $\mathbf{m}$  boyutlu olan  $\mathbf{Y}$  izdüşüm vektörü elde edilmiş olur. Buradaki sorun iyi bir izdüşüm vektörü olan  $\mathbf{X}$ 'in nasıl belirleneceğidir. Özellik vektörlerinin toplam dağılımı,  $\mathbf{X}$  izdüşüm vektörünün ayırıcılık ölçüsü olarak düşünülebilir. Şimdi çözülmesi gereken problem, izdüşüm sonucu elde edilen izdüşürülmüş görüntü temsilleri arasındaki dağılımı en büyükleyecek iyi bir  $\mathbf{X}$  izdüşüm yönü kümesinin bulunması problemidir.

Eğitim kümesinde toplam  $\mathbf{M}$  adet görüntü var ise bu görüntü matrislerinin ortalaması olan  $\bar{\mathbf{A}}$  matrisi aşağıdaki gibi hesaplanabilir.

$$\bar{\mathbf{A}} = \frac{\mathbf{1}}{\mathbf{M}} \sum_{i=1}^{\mathbf{M}} \mathbf{A}_i \quad 2.15$$

Eğitim kümesinde bulunan görüntü matrislerinin sınıflar arası dağılımını gösteren kovaryans matrisi ( $\mathbf{S}_1$ ) olsun.

$$\mathbf{S}_1 = \frac{\mathbf{1}}{\mathbf{M}} \sum_{j=1}^{\mathbf{M}} (\mathbf{A}_j - \bar{\mathbf{A}})^T (\mathbf{A}_j - \bar{\mathbf{A}}) \quad 2.16$$

Bu methoda, özuzaya dönüşüm için gerekli özvektörler kümesi aşağıdaki kriteri en büyükleyecek vektörler kümesi olarak seçilir ki bu özvektörler yüz görüntü için hesaplanan kovaryans matrisinin özvektörleridir.

$$\mathbf{J}(\mathbf{X}) = \mathbf{X}^T \mathbf{S}_1 \mathbf{X} \quad 2.17$$

Bu kriteri en büyükleyen özvektör  $\vec{\mathbf{e}}_{\text{opt}}$ ,  $\mathbf{S}_1$ 'nin en büyük özdeğerine karşılık gelen özvektördür. Genelde, sadece bir tane özvektör seçmek yeterli değildir.  $\vec{\mathbf{e}}_1, \dots, \vec{\mathbf{e}}_d$  şeklinde bir özvektör kümesi seçmek gerekir. Bu özvektörler aşağıdaki özelliklere sahiptir:

$$\left\{ \begin{array}{l} \{\vec{e}_1, \dots, \vec{e}_d\} = \text{argmax} J(\mathbf{X}) \\ (\vec{e}_i)^T \vec{e}_j = 0, \quad i \neq j, \quad i, j = 1, \dots, d \end{array} \right\} \quad 2.18$$

Yüz görüntü dönüşümü için kullanılacak olan bu özvektörler kümesi daha sonra özellik çıkartımı için kullanılacaktır.

Özuzaya dönüşüm için gerekli olan özvektörler belirlendikten sonra eğitim kümesindeki yüz görüntüleri için özellik vektörleri  $\vec{y}_k$  Eşitlik 2.19'da olduğu gibi hesaplanır.

$$\vec{y}_k = \mathbf{A} \vec{e}_k, \quad k = 1, \dots, d \quad 2.19$$

$\mathbf{A}$  görüntü matrisi için elde edilen özellik vektörleri bir  $\mathbf{B}$  matrisinin sütunlarını oluşturacak şekilde yan yana dizilerek  $\mathbf{A}$  görüntü matrisinin özellik matrisi olarak ve tanımada kullanılacak matris elde edilir.

$$\mathbf{B} = [\vec{y}_1, \dots, \vec{y}_d] \quad 2.20$$

2BABA kullanılarak görüntü dönüşümleri yapıldıktan sonra her görüntü matrisi için d tane özellik vektörü elde edilmiş olur. Şekil 2.5'de ORL veritabanından alınmış orjinal bir yüz görüntüsünün (Bkz. Şekil 2.3 a) sırasıyla  $k = 2, 4, 6, 8, 10$  tane özvektör kullanılarak elde edilmiş yaklaşık görüntüleri görülmektedir. Yöntemin test aşamasında bir test görüntüsü geldiğinde bu görüntüye ait özellik vektörü de eğitim kümesindeki görüntülerin özellik vektörleri gibi çıkartılır. Bundan sonra görüntülerin sınıflandırılması için en yakın komşu sınıflandırıcısı kullanılır. Örneğin eğitim kümesindeki herhangi bir görüntüye ait özellik matrisi  $\mathbf{B}^i = [\vec{y}_1^i, \vec{y}_2^i, \dots, \vec{y}_d^i]$  ve test görüntüsünün özellik matrisi  $\mathbf{B}^t = [\vec{y}_1^t, \vec{y}_2^t, \dots, \vec{y}_d^t]$  arasındaki mesafe aşağıdaki gibi tanımlanmıştır :



$$\text{dis}(\mathbf{B}^i, \mathbf{B}^t) = \sum_{k=1}^d \left\| \vec{\mathbf{y}}_k^i - \vec{\mathbf{y}}_k^t \right\|_2 \quad 2.21$$

$\left\| \vec{\mathbf{y}}_k^i - \vec{\mathbf{y}}_k^d \right\|_2$ ,  $\vec{\mathbf{y}}_k^i$  ve  $\vec{\mathbf{y}}_k^d$  iki özellik vektörü arasındaki öklid mesafesini göstermektedir.

Bir test görüntüsünün hangi sınıfa ait olduğu test görüntüsünün  $\mathbf{B}^t$  özellik matrisi ile eğitim kümesindeki sınıflara ait özellik matrisleri arasındaki Eşitlik 2.21’de tanımlanmış olan farklara bakılarak yapılır. Buna göre karar verme kriteri aşağıdaki gibidir:


$$\mathbf{w} = \underset{1 \leq i \leq \mathbf{M}}{\text{argmin}} \left\{ \left\| \mathbf{B}^i - \mathbf{B}^t \right\| \right\} \quad 2.22$$

Eğer test görüntüsü  $i$  sınıfına ait ise,  $\mathbf{B}^i$  ve  $\mathbf{B}^t$  arasındaki mesafe minimum olmalıdır.

#### 2.4.1 2BABA yöntemindeki gelişmeler

ABA merkezli iki boyutlu bu tanıma algoritmasının geliştirilmesi (Yang et. al., 2004) 2 boyutlu tanıma algoritmaları üzerine çalışma yapan pek çok araştırmacıya ışık tutmuştur (Xu et al., 2004 ;Xu et al., 2005 a,b;). Bu çalışmalarda geliştirilen yöntemler ile 2BABA’de cevap verilememiş sorulara çözüm bulmak amaçlanmıştır. Bu bağlamda Xu ve arkadaşları 2BABA’nde boyut indirgeyerek hafıza problemini ortadan kaldırmak aynı zamanda tanımada yüz görüntü matrisinin hem satır vektörleri arasındaki değişimlerin hem de sütun vektörleri arasındaki değişimlerin kullanıldığı bir dizi çalışma yapmışlardır. Bu çalışmalardan birinde (Xu et al., 2005 a) ilk olarak 2BABA’nin 1 boyutlu geleneksel ABA’nin sadece sütunlar üzerinde uygulanması ile oluşturulmuş olan bir yüz görüntü tanıma ve temsil yöntemi olduğunu ispatlamışlardır. Böylece Yang ve arkadaşlarının (2004) geliştirmiş olduğu 2BABA’de elde edilen özvektörlerin geleneksel ABA’de elde edilen özvektörler ile aynı manaya geldiğini göstermişlerdir. İkinci olarak 2BABA’nin geleneksel ABA’ne göre neden daha iyi tanıma doğruluğu verdiğini açıklamışlardır.

Buna göre 2BABA'nin eğitim kümesinde daha az sayıda örnek olduğu durumda tanıma performansı açısından daha iyi sonuçlar vermektedir.



**Şekil 2.5** ORL veritabanından alınmış bir yüz görüntüsü için sırasıyla  $k=2, 4, 6, 8, 10$  özvektör kullanılarak elde edilmiş yaklaşık yüz görüntüleri

Üçüncü olarak da hem satırlar arasındaki hem de sütunlar arasındaki değişimleri kullanarak geliştirdikleri bir paralel algoritma ile 2BABA'deki boyut problemine de çözüm önermişlerdir. Boyut indirmek için önce yüz görüntüleri üzerinde 2BABA'ni uygulamışlardır. Bu şekilde yüz matrisleri için hesaplanan özellik matrisinin bu sefer sütunları üzerinde 2BABA'ni uygulamışlar ve bu yolla boyut indirgenmesini başarmışlardır.

Xu ve arkadaşlarının (2004) yapmış olduğu başka bir çalışmada yüz görüntü matrislerinin temsili için kullanılacak olan özellik matrisi bu sefer hem satır vektörleri arasındaki hem de sütun vektörleri arasındaki değişimleri ifade eden ve özellik çıkartımı için kullanılacak olan özvektörlerin iteratif olarak elde edildiği bir yöntemdir. Bu çalışmada önce yüz görüntülerinin özuzaya izdüşümü için rassal bir dönüşüm matrisi kullanılmıştır. Daha sonra görüntü matrislerinin bu özuzaya izdüşümü alınarak yüz matrisleri için özellik matrisi elde edilmiştir. Bu ilk dönüşüm görüntü satırları üzerinde gerçekleştirilmiştir. Bu dönüşüm sonrasında yüz matrisleri için hesaplanan özellik matrisin sütunları üzerinde ikinci bir dönüşüm daha yapılmış ve görüntüleri tanımlayan bir önceki adımdaki özellik matrisinden daha düşük boyutlu ikinci bir özellik matrisi elde edilmiştir. İkinci dönüşüm için kullanılan vektörler bu ikinci özellik matrisine ait kovaryans matrisinin özvektörleridir. Böylece ilk dönüşüm ve ikinci dönüşüm için iki

farklı vektör kümesi kullanılmıştır. Yöntemdeki iterasyon iki ardışık adımda hesaplanan iki farklı özvektör kümesinin kendi aralarındaki frobenius normuna göre hesaplanan meafenin önceden belirlenmiş olan bir hata kriterinden küçük olup olmadığına bakılarak yapılır. Eğer aradaki mesafe hata kriterinden küçük ise iterasyon devam eder aksi takdirde iterasyon son bularak ikinci dönüşüm sonrasında elde edilmiş olan birinciye göre daha düşük boyutlu olan özellik matrisi tanıma için kullanılır. Böylece yüz görüntülerinin hem satır vektörleri arasındaki hem de sütun vektörleri arasındaki değişimlerin kullanıldığı ve tanıma için kullanılacak özellik matrisinin boyutunun 2BABA'ne göre iteratif olarak azaltıldığı bir çalışma sunulmuştur

Xu ve arkadaşlarının (2005 b) 2BABA'ni geliştirmek amacı ile yaptıkları başka bir çalışmada da yine öncekilerde olduğu gibi boyut azaltılmasını sağlayan bir çalışmadır. Boyut azaltılması ikinci dereceden tensörler kullanılarak yapılmış ve çalışmanın üçüncü dereceden tensörler için de genişletilmesi yapılmıştır. Ayrıca bu yöntemde 2BABA'nin bu çalışmada sunulan yöntemin özel bir durumu olduğu belirtilmektedir. Yapılan deneysel çalışmalar yöntemin yüz görüntülerinin hem temsili hem de sınıflandırma doğruluğu açısından geleneksel ABA'ne göre daha iyi sonuçlar verdiğini göstermiştir. Bu çalışmaya benzer bir başka çalışma Ye (2004) tarafından gerçekleştirilmiştir.

2BABA'de çözümlenmemiş boyut problemini ortadan kaldırabilmek için Nousath ve arkadaşları bir çalışma yapmıştır. Bu çalışmada boyut problemini yüz görüntüleri üzerinde önce 2BABA'ni uygulayarak elde edilen özellik matrisi üzerinde lineer ayırıcı analizi uygulanarak ortadan kaldırılmaya çalışılmıştır. Böylece sınıflandırma açısından 2BABA'ne göre daha iyi sonuçlar elde edilmiştir. Yine 2BABA'ne göre daha iyi sınıflandırma doğruluğu elde edilmek için bir çalışma yapılmıştır (Ye, 2004). Fakat bu çalışmada yüz görüntü matrisinin boyutunu otomatik olarak belirleyen bir kriter yoktur. Bunun otomatik olarak belirlendiği çalışma Liu ve Chen (2006) tarafından gerçekleştirilmiştir.

2BABA'i geleneksel ABA ile aynı özellikleri gösterdiğinden poz değişimlerine karşı hassas bir yöntemdir. Yönetimin poz değişimlerine olan duyarlılığını azaltmak için Rama ve Tarres (2005) eğitim kümesinde üç boyutlu görüntülerin test kümesinde ise iki boyutlu görüntülerin kullanıldığı bir 2BABA gerçekleştirmişlerdir. İki boyutlu görüntü matrislerinin iki boyutlu taban matrislerinin lineer kombinasyonu ile elde

edildiği bir çalışma sunulmuştur (Zhang et al., 2005 ). Bu çalışma sadece görüntülerin en az karesel hata ile iki boyutlu taban matrisleri kullanılarak yeniden nasıl elde edildiğini göstermektedir. Yüz görüntülerinin tanınması konusunda bir çalışma yapılmamıştır.

#### 2.4.2 2BABA yöntemi için önerilen gelişmeler

Bu tez çalışmasında da otomatik yüz tanıma için sunulmuş 2 boyutlu yüz tanıma algoritmaları mevcuttur. Bu algoritmalar geliştirilirken temel olarak yapılması istenen eğitim kümesinde kullanılan görüntü sınıfları arasındaki dağılımı en büyüklerken sınıf içi dağılımları da en küçükleme olmuştur. Böylece sınıflandırma doğruluğu arttırılmaya çalışılmıştır. Bunun yanısıra yüz görüntü matrisinin her iki boyutta (sıra vektörleri ve sütun vektörleri) ve bu boyutlar arasındaki fazlalık olan bilgileri olan bilgileri azaltarak yüz görüntüsünün en iyi şekilde temsili elde edilmeye çalışılmıştır. Bu çalışmalarda kullanılan temel yaklaşım görünüm tabanlı bir yaklaşım olan 2BABA'ı olmuştur.

İki boyutlu yüz tanıma için sunulan bir başka yöntem de daha önce bir boyutlu ses sinyallerinin tanınması için geliştirilmiş olan ortak vektör yaklaşımına (Senior, 2001; Martinez, 1999; Martinez and Kak, 2001) dayalı bir çalışmadır. Ortak matris yaklaşımı olarak adlandırılmış olan bu yöntem bir boyutlu ortak vektör yaklaşımının iki boyutlu yüz görüntü matrisleri için bir uyarlamasıdır. Bu çalışma ile bir boyutlu ortak vektör yaklaşımında ortaya çıkan küçük örnek boyutu çözümlenirken aynı zamanda sınıflandırma doğruluğu açısından da daha iyi sonuçlar elde edilmiştir. Geliştirilen bu algoritma da yine eğitim kümesindeki sınıflar arası dağılım en büyüklenirken sınıf içi dağılımlar da en küçükleme çalışılmıştır. Tanıma için kullanılan ortak matris aynı zamanda iki boyutlu tensörler yardımıyla ABA'nin sıfır özdeğerli özmatrisleri kullanılarak da elde edilmiştir. Bu çalışmanın merkezini oluşturan ortak vektör yaklaşımının matematiksel altyapısı aşağıda verildiği gibidir.

Ortak vektör yaklaşımı konuşmacıdan bağımsız olarak kelimelerin tanınması için kullanılan bir yöntem olarak ortaya çıkmıştır. Kelimeler vektörler ile ifade edilebilir.  $s$ ; ortogonalleştirilecek vektör sayısını ve  $t$ ; vektör boyutunu göstermek üzere  $\vec{a}_i$  herhangi bir kelimeyi gösteren vektör olsun.

Herhangi bir sınıfa ait ortak vektör, o sınıfı temsil eden değişmez ve tek bir vektördür (Senior, 2001; Martinez,1999). Aynı sınıfa ait verileri temsil eden vektörler arasında bazı farklar vardır. Bu fark vektörleri hesaplanıp ortogonalleştirilerek, o sınıf için bir farklılık alt uzayı yaratılır (Martinez, 1999). Sınıf içerisinde herhangi bir vektörün (referans vektörü), ortonormalleştirilmiş farklılık alt uzayına olan izdüşümlerinin kendisinden çıkarılmasıyla elde edilen değişmez özellikleri içeren tek bir vektör elde edilir ve bu vektöre de "Ortak Vektör" adı verilir. Bu sınıf için referans vektör değiştirilse de sonuçta bulunan ortak vektör tektir. Hangi sınıfa ait olduğu belirlenecek olan bir test vektörünün de yani sınıflandırılacak olan vektörün de benzer şekilde ortonormalleştirilen farklılık alt uzayına olan iz düşümlerinin kendisinden çıkarılmasıyla elde edilen vektör "Kalan Vektör" olarak adlandırılır. Yapılan deneysel çalışmalara göre sınıflandırılacak olan test vektörünün kalan vektörü, ait olduğu sınıfın ortak vektörüne diğer sınıfların ortak vektörlerinden daha yakındır (Martinez, 1999) (uzaklık için Öklid mesafesi kullanılmıştır). Ortak vektör yaklaşımını da yüz ya da ses tanımada kullanılabilir yapan da bu özelliğidir. Bir test vektörü için her sınıfın kendi ortonormal taban vektörleri kullanılarak elde edilen test vektörünün sözü edilen sınıf için kalan vektörü ile yine sözü edilen sınıfa ait ortak vektör arasındaki öklid uzaklığına bakılır. Bu işlem bütün sınıflar için uygulanır ve her sınıf için bulunan uzaklıklar elde edildikten sonra bu uzaklıklarının hangisinin en küçük olduğuna bakılarak test vektörünün sınıflandırması yapılır. Bu mesafe hangisinde en küçük ise o test vektörü o sınıfa aittir denir (Martinez, 1999). Bu kavramlar ses sinyallerinde olduğu gibi yüz görüntüleri için de kabul edilebilirdir.

Ortak vektör yaklaşımında iki durum söz konusu olabilir: Yeterli veri durumu, yetersiz veri durumu. Yeterli veri durumu kullanılacak olan ortogonalleştirilecek vektör boyutunun ( $t$ ) yine ortogonalleştirilecek vektör sayısından ( $s$ ) küçük olması durumudur ( $t < s$ ). Yetersiz veri durumu ise toplam vektör sayısının ( $s$ ) vektör boyutundan ( $t$ ) daha küçük ya da eşit olması ( $s \leq t$ ) durumudur. Bu çalışmada yetersiz veri durumunu üzerinde çalışmalar yapılmıştır.

Bir sınıfa ait eğitim kümesindeki vektörler  $\vec{a}_1^c, \vec{a}_2^c, \dots, \vec{a}_s^c$  ile; sınıfın ortak vektörü  $\vec{a}_{com}^c$  ile; her vektörde bulunan farklar da  $\vec{a}_{i,fark}^c$  ile ifade edilirse, her bir vektör ortak ve fark vektörlerinin toplamları şeklinde aşağıdaki gibi gösterilebilir:

$$\begin{aligned}
\vec{a}_1 &= \vec{a}_{1,\text{fark}} + \vec{a}_{\text{com}} \\
\vec{a}_2 &= \vec{a}_{2,\text{fark}} + \vec{a}_{\text{com}} \\
&\cdot \\
&\cdot \\
&\cdot \\
\vec{a}_s &= \vec{a}_{s,\text{fark}} + \vec{a}_{\text{com}}
\end{aligned}$$

2.23

Daha önce de belirtildiği gibi bir sınıfın vektörleri arasında çeşitli sebeplerden kaynaklanan farklar bulunmaktadır. Bu farklar aşağıdaki gibi tanımlansın.

$$\begin{aligned}
\vec{b}_1 &= \vec{a}_2 - \vec{a}_1 \\
\vec{b}_2 &= \vec{a}_3 - \vec{a}_1 \\
&\cdot \\
&\cdot \\
&\cdot \\
\vec{b}_{s-1} &= \vec{a}_{(s-1)} - \vec{a}_1^c
\end{aligned}$$

2.24

$\mathbf{A} = \{\vec{b}_1, \vec{b}_2, \dots, \vec{b}_{(s-1)}\}$  kümesi tarafından taranan alt uzay  $\mathbf{B}$  ile gösterilirse,  $\mathbf{B} = \text{span}\mathbf{A} = \text{span}\{\vec{b}_1, \vec{b}_2, \dots, \vec{b}_{(s-1)}\}$  olur. Burada “span” ifadesi tarama, kapsama anlamındadır. Bu durumda  $\mathbf{A}$  kümesi  $\mathbf{B}$  uzayı için bir taban oluşturur ve  $\mathbf{B}$  alt uzayı,  $\vec{b}_1, \vec{b}_2, \dots, \vec{b}_{(s-1)}$  vektörlerinin olası tüm lineer kombinasyonlarından elde edilebilir (Senior, 2001). Buradaki  $\mathbf{B}$  uzayına,  $\vec{a}_1, \vec{a}_2, \dots, \vec{a}_{(s-1)}$  vektörlerinin “Farklılık Alt Uzayı” denir. Lineer cebirden de bilindiği gibi  $\{\vec{z}_1, \vec{z}_2, \dots, \vec{z}_{(s-1)}\}$  ortonormal vektör kümesi,

$$\langle \vec{z}_i, \vec{z}_j \rangle = \delta_{ij} = 1 \text{ eğer } i=j \text{ ise,} \quad 2.25$$

$$\langle \vec{z}_i, \vec{z}_j \rangle = \delta_{ij} = 0 \text{ eğer } i \neq j \text{ ise.} \quad 2.26$$

özelliğini sağlamak şartıyla Gram-Schmidt yöntemi kullanılarak bu tabandan bulunabilir (Senior, 2001) ( $\langle \vec{z}_i, \vec{z}_j \rangle$  işlemi  $\vec{z}_i, \vec{z}_j$  vektörlerinin iç çarpımını göstermektedir):

$$\begin{aligned} \mathbf{d}_{1k}^c &= \mathbf{b}_{1k}^c \rightarrow \mathbf{z}_{1k}^c = \frac{\mathbf{d}_{1k}^c}{\|\mathbf{d}_{1k}^c\|} \\ \mathbf{d}_{2k}^c &= \mathbf{b}_{2k}^c - \langle \mathbf{b}_{2k}^c, \mathbf{z}_{1k}^c \rangle \mathbf{z}_{1k}^c \rightarrow \mathbf{z}_{2k}^c = \frac{\mathbf{d}_{2k}^c}{\|\mathbf{d}_{2k}^c\|} \\ &\cdot \\ \mathbf{d}_{(l-1)k}^c &= \mathbf{b}_{(l-1)k}^c - \langle \mathbf{b}_{(l-1)k}^c, \mathbf{z}_{(l-2)k}^c \rangle \mathbf{z}_{(l-2)k}^c \rightarrow \mathbf{z}_{(l-1)k}^c = \frac{\mathbf{d}_{(l-1)k}^c}{\|\mathbf{d}_{(l-1)k}^c\|} \end{aligned} \quad 2.27$$

Eğitim kümesindeki herhangi bir  $\vec{\mathbf{a}}_i^c$  vektörünün  $\mathbf{B}$  alt uzayına olan izdüşümünün toplamını  $\vec{\hat{\mathbf{a}}}_i^c$  ile gösterelim

$$\vec{\hat{\mathbf{a}}}_i^c = \langle \vec{\mathbf{a}}_i^c, \mathbf{z}_1^c \rangle \mathbf{z}_1^c + \langle \vec{\mathbf{a}}_i^c, \mathbf{z}_2^c \rangle \mathbf{z}_2^c + \dots + \langle \vec{\mathbf{a}}_i^c, \mathbf{z}_{(s-1)}^c \rangle \mathbf{z}_{(s-1)}^c \quad \mathbf{i} = 1, 2, \dots, \mathbf{s} \quad 2.28$$

Bu durumda, Eşitlik 2.23'de belirtilen  $\vec{\mathbf{a}}_{\text{com}}^c$

$$\vec{\mathbf{a}}_{\text{com}}^c = \vec{\mathbf{a}}_i^c - \vec{\hat{\mathbf{a}}}_i^c \quad 2.29$$

olarak ifade edilebilir ve  $\vec{\mathbf{a}}_{\text{com}}^c, \vec{\mathbf{a}}_1^c, \vec{\mathbf{a}}_2^c, \dots, \vec{\mathbf{a}}_s^c$  vektörlerinin ait olduğu sınıfın "Ortak Vektörü" olarak adlandırılır ve "i" indeksinden bağımsız olarak değişmez ve tektir (Senior, 2001). Benzer şekilde sınıflandırılacak olan test kümesinden alınmış herhangi bir  $\vec{\mathbf{a}}^{\text{test}}$  test vektörünün de aynı  $\mathbf{B}$  alt uzayı üzerindeki izdüşümü kendisinden çıkarıldığında elde edilen vektör "Kalan Vektör" ( $\vec{\mathbf{a}}_{\text{rem}}^{\text{test}, c}$ ) olarak adlandırılır ve ait olduğu sınıfın Ortak Vektörüne daha yakın olmalıdır (Senior, 2001).

Eđitim ařamasında her sınıfın ortak vektörü bulunduktan sonra, bir test vektörünün sınıflandırma işlemleri, her sınıf için hesaplanan kalan vektör ile, karşılık geldikleri sınıfın ortak vektörleri arasındaki Öklid uzaklıkları hesaplanarak yapılır.

$$\mathbf{w} = \mathbf{argmin} \left\{ \left\| \begin{matrix} \vec{a}_{rem} \\ \vec{a}_{com} \end{matrix} - \vec{a}_{c} \right\|^2 \right\} \quad 2.30$$

Hangi sınıf için minimum uzaklık elde edilirse, test vektörü o sınıfa aittir (Senior, 2001).

Bu tez çalışmasında iki boyutlu yüz görüntülerinin tanınması için geliştirilmiş iki boyutlu algoritmalar sunulmuştur. İki boyutlu çalışıldığından yüz görüntü matrisleri vektöre dönüştürülmeden direk olarak kullanılmıştır. Bu şekilde işlem karmaşası azaltıldığı gibi işlem zamanları da kısaltılmıştır. Aynı zamanda tanımadaki küçük örnek boyutu problemi de ortadan kaldırılmıştır. Geliştirilen algoritmalar ile sınıflandırmada; sınıflar arası dağılımlar en büyüklenirken sınıf içi dağılımlar da en küçüklenmiş ve böylece sınıflandırma doğruluklarının artırılması sağlanmıştır. Bölüm 3’de sayısal görüntü işleme temelleri üzerinde durularak sayısal görüntü nedir nasıl oluşur ve bu görüntünün bilgisayar ortamında işlenmesi ile ilgili matematiksel altyapı açıklanmıştır. Bölüm 4’de tez kapsamında geliştirilen algoritmalar detaylı olarak açıklanmış ve Ar-Face ve ORL veritabanları üzerinde gerçekleştirilen deneysel çalışma sonuçları bilinen yöntemlerle birlikte karşılaştırmalı olarak verilmiştir. Bölüm 5’de ise gelecek çalışmalar ile ilgili tartışma ve öneriler verilmiştir.




## BÖLÜM 3

### SAYISAL GÖRÜNTÜ İŞLEME

Elektronik sistemler temelde analog ve sayısal olmak üzere ikiye ayrılırlar. Analog sistemlerde elektrik sinyalleri zamanla sürekli olarak değişir ve bir en büyük değer ile bir en küçük değer arasında her değeri alabilirler. Günlük hayatta duyulabilir (ses) ya da görülebilir (görüntü) olarak ortaya çıkan, çoğu bir ya da iki boyutlu işaretler analog işaretler şeklindedir. Optik görüntüleme sistemleri ya da elektriksel şebekeler bu bilgileri analog teknikler kullanarak işlerler. Analog işaret işleme teknikleri uygulama hızı açısından mükemmeldir. Buna rağmen daha kompleks analog işaretler olduğunda bu işaretleri işlemek için kullanılacak olan algoritmalar da daha karmaşık olacağından analog yöntemler kullanılarak bu işaretlerin işlenmesi zorlaşır, hatta kimi zaman imkansızdır.

Elektronik sistemlerde genel olarak giriş ve çıkış sinyalleri analog yapıdadır. Bu sinyallerin işlenmesi ve iletimi, sayısal sistemlerin hızlı gelişimiyle birlikte zaman içerisinde analog devrelerin yerini alan sayısal devrelerle yapılmaya başlanmıştır. Sayısal sistemlerin, analog sistemlerin yerini almasının bazı önemli sebepleri vardır. Bunlardan bazıları; sayısal sistemlerin daha güvenilir, daha kaliteli, daha ucuz ve gürültü ve dış etkenlerden daha az etkilenen sistemler olmalarıdır.

Analog yapıda olan sinyallerin, örneğin görüntü gibi, sayısal sistemler ile işlenebilmesi için analog/sayısal dönüştürücüler kullanılmaktadır. Bu şekilde zamanla sürekli olarak değişen değerler alabilen analog sinyaller, rakamlar gibi ayrık sayısal değerler ile gösterilebilirler. Bir analog/sayısal dönüştürücü yapısı Şekil 3.1'deki gibidir.



Şekil 3.1 Analog/ sayısal dönüştürücü blok diyagramı

Şekil 3.1’de görüldüğü gibi görüntü işleme sisteminin ilk adımı örnekleme işlemidir. Örnekleme işlemi; zamanla sürekli olarak değişen analog sinyalden belli aralıklar ile örnekler almaktan ibarettir. Örnekleme sıklığı sayısallaştırılmak istenen sinyalde bulunan en yüksek frekans bileşeninin en az iki katı olmalıdır (Shannon, 1949). Aksi halde spektrum örtüşmesi olarak adlandırılan bozulma meydana gelir ve sinyalin yeniden elde edilmesi imkansız hale gelir.

Alınan örneklerin genlik değerlerinin belirli bir sınır değeri vardır. Bu değer örnekleri kodlamak için kullanılacak bit sayısı tarafından belirlenir. Örneğin; kodlama 8 bit kullanılarak yapılacaksa 256 seviye , 3 bit kullanılarak yapılacaksa 8 seviye kullanılabilir. Genelleme yapılacak olursa kodlama için kullanılacak bit sayısı  $n$  ile gösterilecek olursa bu durumda kullanılacak seviye sayısı  $2^n$  şeklinde belirlenecektir. Seviye sayısının artışı sayısallaştırıldıktan sonra sinyalin tekrardan duyulabilir ya da görülebilir bir hale dönüştürüldüğündeki kaliteyi de artırmış olacaktır.


Analog sinyalin sayısallaştırılması süreci kodlama işlemi ile son bulur. Kodlama işlemini gerçekleştirmek için ise alınan örneğin genlik değerine bakılır. Bu genliğe en yakın seviye hangisi ise o seviyenin kodu o genlik değerini temsil etmek için kullanılır.

Günümüzde, sayısal işleme sistemlerinin gelişmesi ile bir boyutlu işaretler sayısal işaret işleme, iki boyutlu işaretler de görüntü işleme teknikleri kullanılarak işlenebilmektedirler. Sayısal görüntü işleme teknikleri son 20 yıldır gelişmekte olan bir teknolojidir. Bu teknoloji, görüntü verilerinin bilgisayar kullanılarak işlenmesi anlamına gelmektedir. Sayısal görüntü işleme işlemi ile sayısal bir resim haline getirilmiş olan gerçek görüntüler işlenerek özellikleri ve görünümü farklı, gerçek görüntüyü temsil eden yeni bir resim oluşturulur. Bu sayede görüntülerin daha kolay anlaşılabilir bir hale getirilebilmesi sağlanmış olur. Kullanılan çeşitli görüntü işleme teknikleri ile görüntünün belirli bölgeleri daha belirgin bir hale getirilebilirken, bazı bölgeleri bastırılarak görüntüye karışmış olan gürültü de yok edilebilmektedir. Görüntü zenginleştirme teknikleri olarak bilinen bu uygulamaların görüntünün anlaşılabilirliğini arttırmak açısından avantajları olduğu gibi dezavantajları da vardır. Bu tekniklerden bazıları; komşusal işlemler, katlama, fourier dönüşümü, orta değer süzmesi ve renk zenginleştirilmesi (Jain,1988) şeklinde sıralanabilir. Bu sayede görüntü özellikleri

arttırılarak görüntü üzerinden uygulama için gerekli faydalı bilgilerin çıkartılması kolaylaştırılmış olacaktır.

### 3.1 Görüntünün Tanımı

Sayısal olarak depolanmış ve bilgisayar ekranı ya da yazıcı gibi çıkış devrelerinden görüntülenebilen fotoğraf ve grafikler için kullanılan bir kelime olan görüntü; iki boyutlu bir ışık yoğunluk fonksiyonuna karşılık gelir,  $f(x,y)$ . Bu ışık yoğunluk fonksiyonundaki  $x$  ve  $y$ ; görüntüdeki uzaysal (gerçek) koordinatları, herhangi bir  $(x,y)$  noktasındaki “ $f$ ” fonksiyonunun değeri de görüntünün o noktadaki parlaklık değerini ifade eden gri seviye değerini göstermektedir (Şekil 3.2).



Şekil 3.2 Sayısal bir görüntü için kullanılan koordinat eksenleri

Işık bir çeşit enerji olduğundan  $f(x,y)$ 'nin değeri, sıfırdan farklı ve sonlu bir değer almalıdır;  $0 < f(x,y) < \infty$ . İnsanın bir nesneyi görebilmesi, o nesneden insan gözüne yansıyan ışıkla gerçekleşir.  $f(x,y)$  fonksiyonunun temel yapısı aşağıdaki iki bileşenle karakterize edilebilir:

1. Görünümdeki nesnelere düşen ışık miktarı (Aydınlatma),
2. Görünümdeki nesnelere yansıyan ışık miktarı (Yansıma)

Aydınlatma ve Yansıma bileşenleri olarak adlandırılan bu bileşenler sırasıyla  $\mathbf{i}(\mathbf{x},\mathbf{y})$  ve  $\mathbf{r}(\mathbf{x},\mathbf{y})$  fonksiyonları ile gösterilir.  $\mathbf{f}(\mathbf{x},\mathbf{y})$  ışık yoğunluk fonksiyonu, bu iki fonksiyonun çarpımı şeklinde ifade edilebilir (Gonzalez,1987):

$$\mathbf{f}(\mathbf{x},\mathbf{y}) = \mathbf{i}(\mathbf{x},\mathbf{y})\mathbf{r}(\mathbf{x},\mathbf{y}) \quad 3.1$$

Aydınlatma ve Yansıma fonksiyonları için aşağıdaki kısıtlar mevcuttur:

$$0 < \mathbf{i}(\mathbf{x},\mathbf{y}) < \infty \quad 3.2$$

$$0 < \mathbf{r}(\mathbf{x},\mathbf{y}) < 1 \quad 3.3$$

Eşitlik 3.3'ten de anlaşılacağı gibi yansımanın "0" ve "1" değerleri ile yani toplam soğurma ve tam yansıma ile sınırlandırılmış olduğu görülmektedir.  $\mathbf{i}(\mathbf{x},\mathbf{y})$ , Aydınlatma bileşeninin yapısı ışık kaynağı tarafından belirlenirken  $\mathbf{r}(\mathbf{x},\mathbf{y})$ , yansıma bileşeninin yapısı ise, görünüm içindeki nesnelere tarafından belirlenir.

Görüntünün herhangi bir noktasındaki gri seviye değeri " $l$ " ile gösterilirse, " $l$ "'nin alabileceği değerler aşağıdaki aralık içerisinde değişmektedir:

$$\mathbf{L}_{\min} \leq l \leq \mathbf{L}_{\max} \quad 3.4$$

Teorik olarak  $\mathbf{L}_{\min}$  üzerindeki tek kısıtlama pozitif bir değer olması gerektiği ve  $\mathbf{L}_{\max}$  üzerindeki tek kısıtlamanın ise sonlu bir değer olması gerektiğidir. Pratikte ise bu değerler aşağıdaki gibi hesaplanır

$$\mathbf{L}_{\min} = \mathbf{i}_{\min} \mathbf{r}_{\min} , \mathbf{L}_{\max} = \mathbf{i}_{\max} \mathbf{r}_{\max} \quad 3.5$$

$[\mathbf{L}_{\min}, \mathbf{L}_{\max}]$  aralığı gri skala olarak adlandırılır. Pratikte genellikle bu aralık sayısal olarak  $[0, \mathbf{L}]$  aralığına kaydırılmıştır.  $l = 0$ ; siyah renk ve  $l = \mathbf{L}$  beyaz renk olarak düşünülür. Bu renkler arasındaki tüm diğer renkler siyahtan beyaza sürekli olarak değişen grinin tonları şeklindedir.

Bir resim renkli veya siyah-beyaz olabilir. Siyah-beyaz bir resim tek bir spektral banttaki görüntüyü gösterir. Renkli resim ise üç spektral bant içerir. Siyah-beyaz resimlerde insan gözü yaklaşık olarak 10-16 arasında bir sayıda farklı gri seviye rengi ayırabilir, sayısal resimlerde ise pratik bir sınırlama olmamasına karşın genellikle 256 farklı gri seviye değeri kullanılmaktadır (Bkz. Şekil 1.3). Üç spektral bantlı bir görüntüde bu durumda  $256^3$  değişik değer gösterilebilir (İnce, 1986). Renkli görüntülerde her piksel için üç farklı renk uzayı ve bu uzaylardaki renk değerlerini temsilen üç farklı renk bileşeni vardır. Bu bileşenler RGB bileşenleri olarak adlandırılır, RedGreenBlue (kırmızı-yeşil-mavi). Renk uzaylarının her biri 0-255 sayısal değerleri arasında değişen tonlamalardan oluşur.


İkili görüntülerde iki muhtemel piksel değeri vardır. Bu değerler siyah ya da beyaz şeklindedir. “0” sayısı, siyah renge karşılık gelirken “1” ya da “255” sayısı beyaz renge karşılık gelir.

Çoklu-spektral görüntülerde her bir piksel renkli görüntülerdeki üç bileşenden daha fazla renk içerir. Her bir renge ait 0-255 arasında değişen ton değerleri mevcuttur.

Sayılaştırılmış bir görüntüyü bilgisayar ortamında depolarken her bir pikselin renk değeri direkt olarak kaydedilmez. Bunun yerine bilgisayarda renk uzaylarına ait renk tonları kodları belirlenmiştir. O nedenle görüntüdeki piksellerin renklerini kaydetmek yerine o renge ait kodlar bilgisayara kaydedilir ve görüntü bu şekilde kodlanarak bilgisayarda depolanır.

Görüntü üzerinde bilgisayar ile çeşitli işlemlerin yapılabilmesi için öncelikle görüntünün bilgisayar programları tarafından kullanılacak uygun bir formata dönüştürülmesi gereklidir. Görüntünün bilgisayar ortamına uygun bir hale dönüştürülmesi için çok yaygın olarak kullanılan görüntü formatlarından bazıları; GIF, JPEG, TIFF ve PS formatlarıdır. GIF; 8 bit’lik (256 renk) kayıpsız olarak sıkıştırılmış bitharita formatıdır. Bu format daha çok web ortamında kullanılan görüntüler için kullanılmaktadır. JPEG; çok etkili, kayıplı olarak sıkıştırılmış, 24 bit’lik (16 milyon renk) bitharita formatıdır. Bu format da daha çok web ve internet ortamında kullanılacak görüntülerde tercih edilmektedir. TIFF; standart 24 bit’lik bitharita formatıdır. Bu formatta görüntüler Lempel-Ziv-Welch (LZW) sıkıştırma metodu kullanılarak kayıpsız olarak sıkıştırılmaktadır. PS; postscript, standart bir vektör formatıdır ve çok sayıda alt standart içerir.

Görüntünün bahsedilen formatlar ile bilgisayar ortamında işlenebilecek hale dönüştürülmesine görüntünün sayısallaştırılması, işlem sonunda elde edilen görüntüye de Sayısal Görüntü adı verilir. Sayısal görüntü ifadesi hem gerçek koordinat değerleri hem de parlaklık değerleri sayısallaştırılmış bir  $f(x,y)$  görüntüsüne karşılık gelir. Matematiksel açıdan sayısal bir görüntü,  $m$  ; satır sayısını,  $n$  ; sütun sayısını göstermek üzere  $m \times n$  boyutlu ve her bir elemanı o noktadaki gri seviye değerini gösteren bir matris olarak ele alınabilir. Bu matrisin satır ve sütunlarının kesiştiği her bölgeye bir piksel adı verilir. Piksel bir sayısal görüntünün en küçük parçasıdır ve genellikle kare biçimindedir. Bir piksel bölgesine karşılık gelen gri seviye değeri o bölge içerisindeki görüntünün siyah renk ile beyaz renk arasındaki ortalama renk değerini göstermektedir. Şekil 3.3’de orjinal bir yüz görüntüsü ve bu görüntünün pikselleştirilmiş görüntüsü aynı zamanda orjinal bir günc görüntüsü ve bu görüntünün pikselleştirilmiş görüntüsü verilmiştir.



**Şekil 3.3 a)Orjinal bir yüz görüntüsü, b) Orjinal görüntünün pikselleştirilmiş görüntüsü, c) Orjinal bir gül görüntüsü, d) Orjinal gül görüntüsünün pikselleştirilmiş görüntüsü**

Bir piksel bölgesi içinde kalan tüm alan görüntünün tekrar elde edilmesi sırasında tek bir renkle temsil edileceğinden, görüntü sayısallaştırıldıktan sonra o piksel bölgesinde gerçekte varolan tüm renk çeşitliliği kaybedilmiş olacaktır. Bu nedenle orjinal görüntüdeki renk çeşitliliğinin doğru bir şekilde depolanabilmesi için piksel bölgeleri yeteri kadar küçük seçilmelidir. Bir piksel bölgesinin fiziksel olarak büyüklüğü o görüntünün uzaysal çözünürlüğünü belirler. Bir görüntü ne kadar fazla

piksel ile gösteriliyorsa uzaysal çözünürlüğü de o kadar artacak ve böylece sayısal görüntüden orjinal görüntüye yeniden dönüldüğünde görüntünün aslına uygun bir yapı elde edilmiş olacaktır. Sayısallaştırılan görüntünün piksel bölgeleri ile ifade edilmesi görüntünün insan gözü tarafından bir bütün olarak algılanmasını etkilemez.

Sayısallaştırılmış olan görüntü üzerindeki işlemler, görüntünün kişiler tarafından işlenebilecek şekilde iyileştirilmesi ve otomatik bir sistemin görüntüyü işleyerek sonuç üretebileceği bir forma dönüştürmesi işlemlerini kapsamaktadır. Başka bir deyişle görüntünün otomatik sistemin algoritmaları tarafından işlenebileceği daha uygun bir forma dönüştürmektir. Daha uygun bir forma dönüştürmekten kasıt ise uygulamanın içeriğine bağlı olarak görüntüdeki istenilen özelliklerin daha fazla ön plana çıktığı yeni bir görüntünün oluşturulması işlemidir. Görüntü dönüşüm teknikleri olarak adlandırılan bu yöntem, görüntüye uygulanan basit aritmetik işlemlerden ibarettir. Bir sonraki bölümde görüntü dönüşüm yöntemleri ve bu dönüşüm sonrasında orjinal görüntünün yeniden ne şekilde elde edilebileceği tartışılmıştır.

### 3.2 Görüntü Dönüşümü

Çeşitli matematiksel formüller ya da algoritmalar kullanarak işlenmemiş görüntüden tamamıyla yeni bir görüntü elde etmek anlamına gelen görüntü dönüşümleri çok çeşitli alanlardaki uygulamalarından dolayı görüntü işleme alanında önemli yeri olan bir alandır. Görüntü dönüşümlerinin kullanım amaçlarından bazıları; görüntü zenginleştirme, restoration, kodlama ve tanımlama gibi sayılabilir.

Görüntü dönüşümlerini uyguladıkları uzaya göre iki ana bölüme ayırmak mümkündür: Uzaysal domen ve frekans domeni metodları. Uzaysal domenden kasıt görüntüdeki piksellerle doğrudan işlem yapmaktır. Frekans domeninde ise görüntünün Fourier dönüşümüne dayalı teknikler kullanılır. Bu iki tekniğin birlikte kullanıldığı görüntü dönüşüm uygulamaları da mevcuttur.

Görüntüler dönüşüm yolu ile orjinal görüntü uzayının kapsadığı bir altuzaya izdüşürülür. Bu izdüşüm işlemi ise görüntü altuzayında tanımlanan bir dizi birimsel matris kümesi kullanılarak gerçekleştirilir. Böylece iki boyutlu orjinal görüntü matrisi oluşturulan altuzayda yine iki boyutlu olan taban matrisleri ile temsil edilir. Görüntü dönüşümü ile aslında görüntünün istenilen özelliklerini ön plana çıkartabilecek yeni bir koordinat sistemi oluşturulmuş olur.

Görüntü dönüşümü ile görüntünün tanımlandığı bir altuzay elde etmenin görüntü yapısı açısından temel olarak iki yolu vardır. Birincisi;  $m \times n$  boyutlu bir görüntü matrisinin  $m \times n \times 1$  boyutlu bir vektöre dönüştürüldüğü bir boyutlu görüntü dönüşüm yöntemi, ikincisi;  $m \times n$  boyutlu görüntü matrisinin matris olarak kullanıldığı iki boyutlu görüntü dönüşüm yöntemleridir. Bir boyutlu dönüşüm yapılırken görüntü vektörleri oluşturulan altuzayda, birimsel vektörler ile tanımlanırken iki boyutlu dönüşüm yapıldığında görüntü matrisleri oluşturulan altuzayda, birimsel matrisler ile tanımlanırlar (Jain, 1998).

### 3.2.1 1-Boyutlu ortogonal ve birimsel görüntü dönüşümleri

$\vec{a}$  görüntü vektörü,  $m \times n$  boyutlu bir  $A$  görüntü matrisinin  $1 \times mn$  boyutlu vektöre dönüştürülmüş hali olsun. Bir boyutlu görüntü vektörü için bir altuzaya dönüşümde kullanılan dönüşüm matrisi  $T$  ve orjinal görüntünün altuzaydaki izdüşüm vektörü  $\vec{a}'$  ile gösterilirse, bu dönüşüm Eşitlik 3.6 olduğu gibi yapılabilir (Jain):

$$\vec{a}' = T \vec{a} \quad 3.6$$

$1 \times mn$  boyutlu  $\vec{a}$  görüntü vektörünün elemanları  $a(s)$ ,  $s = 1, \dots, mn$ ,  $\vec{a}'$  dönüştürülmüş görüntünün elemanları da  $a'(z)$ ,  $z = 1, \dots, d$  ( $d \leq s$ ) ve  $T$  dönüşüm matrisinin elemanları  $T(z, s)$  şeklinde gösterilirse, Eşitlik 3.6 yeniden aşağıdaki gibi yazılabilir:

$$a'(z) = \sum_{s=1}^{mn} T(z, s) a(s) \quad 3.7$$

$T$  dönüşüm matrisinin her sütunu, oluşturulan altuzayda bir koordinat vektörüne karşılık gelmektedir.  $T$  matrisi birimsel bir matristir ve tersi konjuge transpozuna eşittir.

$$T^{-1} = T^{*T} \quad 3.8$$



Orjinal görüntü, altuzaydaki izdüşüm görüntüsü ve dönüşüm matrisi cinsinden Eşitlik 3.8’de olduğu gibi yeniden elde edilebilir:

$$\vec{\mathbf{a}} = \mathbf{T}^{*T} \vec{\mathbf{a}'} \quad \Rightarrow \quad \mathbf{a}(\mathbf{s}) = \sum_{z=1}^{mn} \mathbf{a}'(\mathbf{z}) \mathbf{T}^*(\mathbf{z}, \mathbf{s}) \quad 3.9$$

Dönüşüm matrisinin konjuge transpozu olan  $\mathbf{T}^{*T}$  matrisinin sütunları, hesaplanan altuzayın taban vektörleri olarak adlandırılır. Orjinal görüntünün bu altuzaydaki izdüşümü olan ve orjinal görüntü vektörüne göre daha düşük boyutlu  $\vec{\mathbf{a}'}$  izdüşüm vektörü filtreleme, veri sıkıştırma, özellik çıkartma gibi çeşitli görüntü analizleri için kullanılır.

### 3.2.2 2-Boyutlu ortogonal ve birimsel görüntü dönüşümleri

Görüntü işlemede  $\mathbf{N} \times \mathbf{N}$  boyutlu bir  $\mathbf{A}$  görüntü matrisinin vektöre dönüştürülmeden matris olarak bir altuzaya izdüşümü 2-boyutlu ortogonal ve birimsel görüntü dönüşüm teknikleri ile yapılabilir. Bu dönüşüm için kullanılan dönüşüm matrisi  $\mathbf{T}$  ile gösterilecek olursa altuzaya izdüşüm Eşitlik 3.10’da olduğu gibi yapılabilir.

$$\mathbf{A}' = \mathbf{T} \mathbf{A} \quad 3.10$$

Yukarıdaki eşitlikte  $\mathbf{A}'$  matrisi orjinal görüntünün altuzaydaki izdüşüm görüntüsünü göstermektedir.  $\mathbf{A}$  görüntü matrisinin elemanları  $\mathbf{A}(\mathbf{m}, \mathbf{n})$  ile, altuzaydaki izdüşürülmüş görüntü matrisinin elemanları  $\mathbf{A}'(\mathbf{m}', \mathbf{n}')$  ile ve  $\mathbf{T}$  dönüşüm matrisinin elemanları  $\mathbf{T}(\mathbf{m}, \mathbf{n})$  gösterilirse  $\mathbf{A}'(\mathbf{m}', \mathbf{n}')$  izdüşüm matris elemanları Eşitlik 3.11’de gösterildiği hesaplanabilir:

$$\mathbf{A}'(\mathbf{m}', \mathbf{n}') = \sum_{\mathbf{m}, \mathbf{n}=1}^{\mathbf{N}} \mathbf{A}(\mathbf{m}, \mathbf{n}) \mathbf{T}_{\mathbf{m}', \mathbf{n}'}(\mathbf{m}, \mathbf{n}), \quad \mathbf{1} \leq \mathbf{m}', \mathbf{n}' \leq \mathbf{N} \quad 3.11$$

Orjinal görüntü matrisi  $\mathbf{A}$ , altuzaydaki izdüşüm görüntü matrisi ve  $\mathbf{T}$  görüntü matrisi cinsinden yeniden Eşitlik 3.12’de olduğu gibi elde edilebilir:

$$\mathbf{A}(\mathbf{m}, \mathbf{n}) = \sum_{\mathbf{m}', \mathbf{n}'=1}^N \mathbf{A}'(\mathbf{m}', \mathbf{n}') \mathbf{T}_{\mathbf{m}', \mathbf{n}'}^*(\mathbf{m}, \mathbf{n}), \quad 1 \leq \mathbf{m}, \mathbf{n} \leq N \quad 3.12$$

Bu eşitliklerdeki  $\{\mathbf{T}_{\mathbf{m}', \mathbf{n}'}(\mathbf{m}, \mathbf{n})\}$  görüntü dönüşüm matrisleri olarak adlandırılır. Bu dönüşüm matrisleri  $\mathbf{T}$  dönüşüm matrisinin sütun vektörlerinin dış çarpımından elde edilen matrislerdir aynı zamanda oluşturulan altuzay için taban matrislerini oluştururlar.  $\mathbf{T}_{\mathbf{k}}^*$ ,  $\mathbf{T}^{*T}$  matrisinin  $\mathbf{k}$ 'inci sütununu ve  $\mathbf{T}_{\mathbf{l}}$  de  $\mathbf{T}^{*T}$  matrisinin  $\mathbf{l}$ 'inci sütununu gösteriyorsa  $\mathbf{T}_{\mathbf{k}, \mathbf{l}}^*$  taban matrisi aşağıdaki gibi tanımlanabilir (Jain, 1998)

$$\mathbf{T}_{\mathbf{k}, \mathbf{l}}^* = \mathbf{T}_{\mathbf{k}}^* \mathbf{T}_{\mathbf{l}}^{*T} \quad 3.13$$

$\mathbf{T}$  dönüşüm matrisinin sütun vektörleri görüntü tanımada özellik çıkartımı için kullanılabilir. Bu tez çalışmasında dönüşüm yöntemi olarak görüntü verisinin istatistiksel özelliklerine dayalı olarak dönüşüm yapan 2BABA kullanılmıştır. Bu yöntemde özellik çıkartımı için kullanılacak olan vektörler görüntü matrislerinin özvektörleri olarak seçilmiştir (Bkz. Bölüm 2)

$\mathbf{A}$  ve  $\mathbf{B}$  gibi  $N \times N$  boyutlu iki matrisin iç çarpımı da aşağıdaki eşitlikte olduğu gibi tanımlanabilir:

$$\langle \mathbf{A}, \mathbf{B} \rangle = \sum_{\mathbf{m}=1}^N \sum_{\mathbf{n}=1}^N \mathbf{A}(\mathbf{m}, \mathbf{n}) \mathbf{B}^*(\mathbf{m}, \mathbf{n}) \quad 3.14$$

Eşitlik 3.12'yi, Eşitlik 3.13'de hesaplanan taban matrisleri cinsinden tanımlarsak

$$\mathbf{A} = \sum_{\mathbf{m}', \mathbf{n}'=1}^N \langle \mathbf{A}, \mathbf{T}_{\mathbf{m}', \mathbf{n}'}^* \rangle \mathbf{T}_{\mathbf{m}', \mathbf{n}'}^* \quad 3.15$$

Yukarıdaki eşitlik orjinal görüntü matrisinin ( $\mathbf{A}$ ), taban matrislerinin lineer kombinasyonu şeklinde ifade edilebileceğini gösterir. Hesaplanan taban matrisleri aşağıdaki ortonormalite ve bütünlük özelliklerini sağlayan bir tam ortonormal ayırık

temel fonksiyonlar kümesidir. Eşitlik 3.16'da  $T_{m',n'}$  ve  $T_{p,q}$  gibi iki farklı taban matrisinin ortonormalite özelliği gösterilmektedir. Bu eşitliğe göre bu iki taban matrisinin birbirleri ile dik olduklarını gösterilmektedir. Eşitlik 3.17'de  $T_{m',n'}$  ile ifade edilen bir taban matrisinin elemanlarının birbirleri ile dik olduğunu gösteren bütünlük özelliği gösterilmektedir.

$$\text{Ortonormalite : } \sum_{m,n=1}^N T_{m',n'}(\mathbf{m}, \mathbf{n}) T_{p,q}^*(\mathbf{m}, \mathbf{n}) = \delta(\mathbf{m}' - \mathbf{p}, \mathbf{n}' - \mathbf{q}) \quad 3.16$$

$$\text{Bütünlük : } \sum_{m',n'=0}^{N-1} T_{m',n'}(\mathbf{m}, \mathbf{n}) T_{m',n'}^*(\mathbf{p}', \mathbf{q}') = \delta(\mathbf{m} - \mathbf{p}', \mathbf{n} - \mathbf{q}') \quad 3.17$$

Ortonormalite özelliği, taban matrislerinin hepsini değil de sadece bir kısmını kullanarak orjinal görüntünün yaklaşığı olan bir  $\bar{A}$  görüntüsü elde ettiğimizde orjinal görüntü ile yaklaşık görüntü arasındaki karesel hata toplamını minimize edeceğini garantiler:

$$\bar{A}(\mathbf{m}, \mathbf{n}) = \sum_{m'=1}^P \sum_{n'=1}^{Q-1} A'(\mathbf{m}', \mathbf{n}') T_{m',n'}^*(\mathbf{m}, \mathbf{n}), \quad P \leq N, Q \leq N \quad 3.18$$

$$\sigma_e^2 = \sum_{m,n=1}^N [A(\mathbf{m}, \mathbf{n}) - \bar{A}(\mathbf{m}, \mathbf{n})]^2 \quad 3.19$$

Bütünlük özelliği ise  $P = Q = N$  olduğu durumda bu hatanın sıfır olacağını garantilemektedir.

Eğer kullanılan görüntü matrisleri yukarıda anlatıldığı gibi  $N \times N$  boyutlu bir kare matris değil de  $M \times N$  boyutlu bir dikdörtgen görüntü matrisi olursa kullanılacak altuzayda tanımlanan izdüşüm görüntüsü Eşitlik 3.20'de olduğu gibi tanımlanır. Dönüşüm matrisi ve izdüşüm görüntüsü cinsinden orjinal görüntü matrisi ise Eşitlik 3.21'de olduğu gibi tanımlanabilir.

$$A' = T_M A T_N \quad 3.20$$

$$\mathbf{A} = \mathbf{T}_M^{*T} \mathbf{A}' \mathbf{T}_N^{*T} \quad 3.21$$

$\mathbf{T}_M$  ve  $\mathbf{T}_N$  matrisleri sırasıyla  $\mathbf{M} \times \mathbf{M}$  ve  $\mathbf{N} \times \mathbf{N}$  boyutlu birimsel dönüşüm matrisleridir.  $\mathbf{T}_M$  matrisi görüntünün satırları üzerinde dönüşüm yaparken  $\mathbf{T}_N$  matrisi ise görüntünün sütunları üzerinde bir dönüşümü gerçekleştirmektedir. Her iki matris de iki boyutlu ayrık dönüşümler olarak adlandırılır.

Görüntü dönüşümü için kullanılan temel dönüşüm teknikleri Çizelge 3.1'de verildiği gibidir.

**Çizelge 3.1 Temel görüntü dönüşüm teknikleri ve uygulama domenleri**

Dönüşüm yöntemi	Frekans Domeni	Uzaysal Domen
AFD (Ayrık Fourier Dönüşümü)	✓	
AKD (Ayrık Kosinüs dönüşümü)	✓	
ASD (Ayrık Sinüs Dönüşümü)	✓	
Hadamard Dönüşümü	✓	
Haar Dönüşümü	✓	
KLT (Karhunen-Loève Dönüşümü)		✓

## BÖLÜM 4

### İKİ BOYUTLU YÜZ GÖRÜNTÜLERİ İÇİN GELİŞTİRİLEN İKİ BOYUTLU TANIMA ALGORİTMALARI

2004 yılına kadar geliştirilen yüz tanıma algoritmalarında iki boyutlu yüz görüntü matrisleri, satırları ya da sütunları alt alta gelecek şekilde bir vektöre dönüştürülmüştür. Bu dönüşümün bazı sakıncaları vardır. Bunlardan birincisi, bu dönüşüm sonucunda orjinal veri uzayındaki bazı önemli bilgilerin kaybedilmesi, ikincisi ise vektöre dönüştürülen görüntü boyutunun çok artmasıdır. Bu artış sebebi ile de altuzaya izdüşüm için gerekli özdeğer ve özvektörlerin bulunması için gereken zaman artmaktadır. İşlem karmaşıklığında artış meydana gelmektedir. Aynı zamanda küçük örnek boyutu problemi ile karşılaşılacaktır. Tanımda bir boyutlu yüz görüntü vektörü kullanmak yerine iki boyutlu yüz görüntülerinin kullanımı ile bu sakıncalar ortadan kaldırılabilmektedir. Son yıllarda yapılan çalışmalar göstermiştir ki, iki boyutlu yüz görüntü kullanımı ile tanıma oranlarında bir boyutlu yüz görüntü vektörleri kullanıldığı durumlara göre artış meydana geldiği saptanmıştır.

Yang ve arkadaşları (2004) tanımda, bir boyutlu yüz görüntü vektörü kullanımının sakıncalarını ortadan kaldırabilmek amacı ile 2 Boyutlu Ana Bileşenler Analizi yöntemini (2BABA) sunmuşlardır. Yüz görüntü matrislerinin satır vektörleri arasındaki ilişkiden yararlanarak tanıma yapan bu yöntemi tanıma performansı açısından 1 boyutlu geleneksel ABA ile karşılaştırmışlar. Karşılaştırma sonucunda 2BABA'nin geleneksel ABA'ne göre daha yüksek doğrulukta tanıma oranları verdiğini göstermişlerdir. 2BABA'nin geleneksel ABA'ne göre avantajları belirtmiş olmalarına rağmen önerilen bu metodun bazı dezavantajları da vardır. Bunlardan bir tanesi tanıma doğrulukları açısından neden daha iyi sonuçlar verdiği sorusudur. Bir diğeri yüz görüntüleri için elde edilen ve tanıma için hafızada saklanması gerekli olan özellik vektörlerinin boyutunun nasıl indirgeneceği sorusudur. Çünkü geleneksel ABA'de yüz görüntü vektörünün özuzay için hesaplanan özvektörler üzerine izdüşümü bir skalar iken 2BABA'de yüz görüntü matrisinin özuzay için hesaplanan özvektörler üzerine izdüşümü bir vektördür.

Yakın zamanda, 2BABA'ndeki boyut problemini ortadan kaldırmak için yapılan çeşitli çalışmalar yapılmıştır (Xu et al., 2004; Xu et al., 2005a). Yapılan bu çalışmaların hepsinde de boyut indirgenmesi için orjinal görüntü uzayından yararlanılarak oluşturulan özellik altuzayı kullanılmıştır. Ancak boyut indirgeme işleminin orjinal görüntü uzayına göre kayıpları olan bir özellik altuzayında gerçekleştirilmiş olması veri kaybına dolayısıyla da düşük boyutlu yüz görüntü matrislerinin orjinal görüntüyü yeteri kadar iyi bir şekilde temsil edilememesine sebep olur.

Geleneksel ABA'i yöntemi görüntü temsili açısından optimal bir yöntem olmasına rağmen görüntünün sınıflandırma doğruluğu açısından çok da iyi sonuçlar vermez. Bunun sebebi yöntemde sınıflar arası dağılımın en büyüklenirken sınıf içi dağılımın en küçüklenmesi için herhangi bir işlem yapılmamasıdır. 2BABA'nin de bölgesel bir geleneksel ABA'i olduğu ve onun özelliklerini gösterdiği ispatlanmıştır (Xu et al.,2005). Bu demektir ki 2BABA'i geleneksel ABA'i gibi iyi bir görüntü temsili verirken sınıflandırma doğruluğu açısından iyi sonuçlar vermemektedir. 2BABA'i merkezli yapılan çalışmalarda da sınıflar arası dağılım en büyüklenirken sınıf içi dağılımın en küçüklenmesi işlemi yapılmamıştır.

Literatürde iki boyutlu olarak sunulmuş olan algoritmalarda yüz görüntü matrisinin ya sadece satırları arasındaki ilişkiden ya sadece sütunları arasındaki ilişkiden ya da hem satırları arasındaki ve hem de sütunları arasındaki ilişkilerden yararlanılarak tanıma yapılmıştır. Ancak görüntü matrisinin iki boyutu arasındaki ilişki yani satır vektörleri ile sütun vektörleri arasındaki ilişki hiç dikkate alınmamıştır.

Bu tez çalışmasında literatürde yüz tanıma için sunulmuş olan bu iki boyutlu tanıma algoritmalarında belirtilen bu eksikleri giderecek yönde algoritmalar geliştirilmiştir. Tez çalışmasında geliştirilen algoritmaların literatürde sunulmuş olan algoritmalara katkısı aşağıdaki maddeler ile verilebilir:

- Bir boyutlu tanıma için sunulmuş olan ortak vektör yaklaşımının iki boyutlu uygulaması ile görüntü tanımadaki boyut problemine ve küçük örnek boyutu problemine çözüm amaçlanmıştır (Turhal et al., 2005).
- Eğitim kümesini oluşturan yüz görüntü sınıfları arasındaki dağılım en büyüklenirken sınıf içi dağılımların en küçüklenmesi de başarılabilmiştir. Bu sayede sınıflandırma doğrulukları arttırılabilmektedir (Turhal et al., 2007).

- İki boyutlu tanıma algoritmalarındaki boyut problemine çözüm bulunurken literatürde bunu çalışmış olan araştırmacıların tersine boyut indirgenmesi işlememi özellik altuzayında değil de orjinal görüntü uzayında gerçekleştirilmiştir. Bu sayede tanıma için kullanılacak olan ve orjinal görüntünün özellik altuzayındaki temsili olan özellik matrisinin, orjinal uzaydaki verilere göre en az bilgi kaybı ile hesaplanması sağlanmıştır (yayına hazırlanıyor).
- Yüz görüntü matrisi iki boyutlu bir yapıya sahiptir. Tanıma işlemi için de bu boyutlar arasındaki ilişki önemlidir. Tanımda, görüntü matrisinin bu iki boyutu arasındaki değişimleri gösteren altuzay özellik altuzayı olarak kullanılmış ve yapılan deneysel çalışmalar ile bu iki boyut arasındaki ilişkinin boyutların kendi aralarındaki ilişkiden daha ayırt edici olduğunu göstermiştir (yayına hazırlanıyor ).

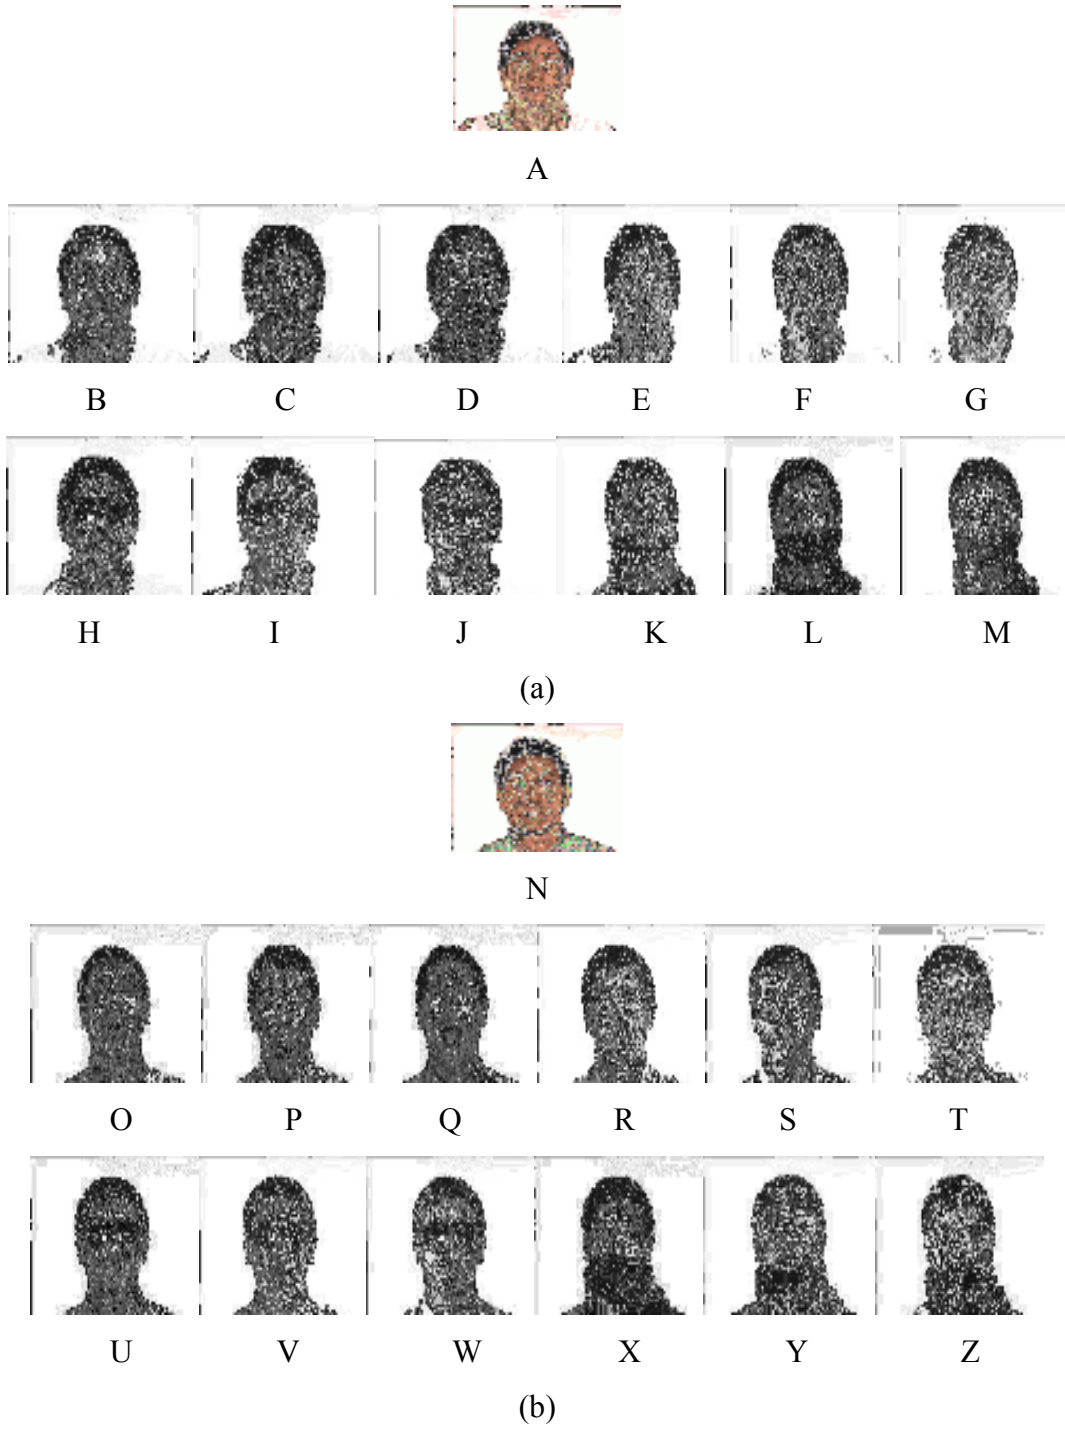
Yapılan deneysel çalışmalarda iki farklı veritabanı kullanılmıştır. Bunlardan biri AR-Face Veritabanı diğeri de ORL Veritabanıdır. Deneysel çalışmalarda kullanılmak üzere bu iki veritabanından yararlanarak çeşitli eğitim kümeleri ve test kümeleri oluşturulmuştur. Görüntüler kullanılmadan önce bazı ön işlemler uygulanmıştır.

#### 4.1 AR-Face Veritabanı

Ar-Face veri tabanı Aleix Martinez ve Robert Benavente tarafından oluşturulmuş bir veri tabanıdır (Martinez and Benavente, 1998). Veri tabanı içerisinde 126 kişiye ait (70 erkek, 56 kadın) 4000'nin üzerinde renkli yüz görüntüsü bulunmaktadır. Yüz görüntülerinin hepsi önden çekilmiş; fakat farklı yüz ifadeleri, farklı aydınlatma koşulları ve kapatılmış (gözlük, atkı kullanımı ile) yüz görüntüleri gibi değişik pozlardan oluşmaktadır. Veri tabanında yer alan her kişi 14 gün arayla iki kez poz vermiştir. Bu nedenle veritabanı iki hafta ara ile çekilmiş iki ayrı bölümden oluşur. Her iki bölümde de aynı kişiye ait aynı pozlar bulunmaktadır.

Kişilere ait görüntüler sırasıyla aşağıdaki durumlardan birine karşılık gelir: Normal ifade, Gülen, Kızgın, Haykıran, Sol ışık açık, Sağ ışık açık, Her iki taraftaki ışık da açık, Güneş gözlüğü var, Güneş gözlüğü varken sol ışık açık, Güneş gözlüğü varken sağ ışık açık, Atkı var, Atkı varken sol ışık açık, Atkı varken sağ ışık açık. İkinci bölümde çekilmiş olan görüntüler de birinci bölümdeki koşullar altında

çekilmiştir. Şekil 4.1’de veri tabanındaki görüntülerden örnek olmak üzere bir kişiye ait iki bölüm olarak çekilmiş yüz görüntü grupları görülmektedir. Görüntülerin ilki normal ifadeyi, diğerleri de sırasıyla diğer ifadelerle karşılık gelmektedir.



Şekil 4.1 Ar-Face veritabanındaki görüntülerden bir kişiye ait görüntü örnekleri. a) Birinci bölümde çekilmiş görüntüler, b) İkinci bölümde çekilmiş görüntüler



## 4.2 ORL Veritabanı

ORL veritabanı 40 kişiye ait 10'ar adet farklı görüntüyü içeren toplam 400 adet görüntüden oluşur (ORL). Bu 40 kişiden 4 tanesi kadın geriye kalanları ise erkeklere ait görüntülerdir. Bazı sınıflarda görüntülerin bazıları arasında çekim zamanı açısından farklılıklar vardır. Bunun yanısıra veritabanındaki görüntülerde açık ya da kapalı göz, gülümseme ya da gülümsememe gibi kişisel ifadelerde ve gözlük olması ya da olmaması gibi kişisel detaylarda farklılıklar vardır.

Görüntüler çekilirken  $20^{\circ}$  'ye kadar varan dönme ve eğim toleransı ile çekilmiştir. Ayrıca görüntü skalasında %10'a varan bir değişim söz konusu olabilmektedir. Bu veritabanındaki tüm görüntüler gri seviyeli ve 112x92 piksel boyutundadır. Bu veri tabanındaki görüntü sınıfından iki tanesine ait görüntü örnekleri Şekil 4.2'de gösterildiği gibidir.

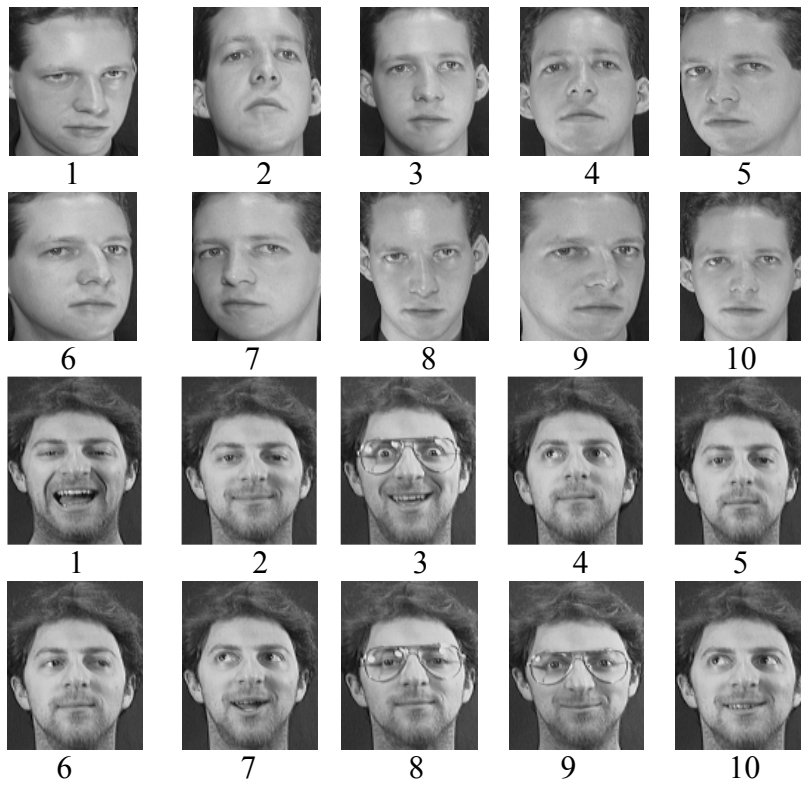
## 4.3 Görüntülere Uygulanan Ön İşlemler

Deneysel çalışmalarda kullanılan AR-Face Veritabanındaki yüzler RGB bileşenlidir. Bu çalışmada kullanılacak olan yüz görüntü matrisleri öncelikle RGB bileşenlerinden arındırılmışlar ve 0-255 değerleri arasında aydınlık seviyelerine sahip iki boyutlu matrisler haline getirilmişlerdir. Yüz görüntüleri üzerinde çalışılan yöntemler uygulanmadan önce gözbebekleri arasındaki mesafenin orta noktası referans alınmak üzere arka plan yok edilecek şekilde resim çeşitli boyutlarda küçültülmüştür.


Görüntüleri küçültmede bir standart oluşturulabilmesi için gözbebeklerinden biri referans alınarak görüntüler üzerinde yapılan istatistiksel bilgiler doğrultusunda yatayda ve dikeyde belirlenen bazı satır ve sütunlar atılarak küçültme işlemi yapılmıştır. Bu küçültme işlemi yine tek tek görüntüler üzerinde yapılmış ve eğer yatayda istenen bölge görüntü içerisine girememiş ise sağa ya da sola kaydırmalar, dikeyde aynı şekilde istenen bölgenin elde edilebilmesi için aşağı ya da yukarı kaydırmalar yapılmıştır. Gözbebeği referans alınarak yapılan bu küçültme işlemi sonrasında elde edilen görüntüde hala istenen bölge elde edilememiş ise görüntüyü küçültmeden önce ölçeklendirmede değişiklik yapılarak yapılarak farklı kişilere ait bütün görüntüler arasında bir standart oluşturmaya çalışılmıştır. Ölçeklendirme için kişinin fiziksel yapısı diğerlerine göre daha küçük ise ölçeklendirme katsayısı 1'den büyük bir sayı seçilmiş, kişinin fiziksel yapısı diğerlerine göre daha büyük ise 1'den daha küçük bir sayı

seçilmiştir. Şekil 4.3’de AR-Face veritabanındaki ölçeklendirmeleri farklı üç adet görüntünün 50x40 olacak şekilde küçültülmüş hali görülmektedir. olarak kullanılan gerçek ve küçültülmüş yüz görüntüleri görülmektedir.

ORL Veritabanındaki görüntüler gri seviyeli görüntülerdir. Bu veritabanındaki görüntülere herhangi bir ön işlem uygulanmaksızın orjinal görüntü boyutları kullanılarak çalışma yapılmıştır.



Şekil 4.2 ORL veritabanındaki iki farklı kişiye ait yüz görüntü örnekleri



**Şekil 4.3 Ar-Face veritabanındaki görüntülerin 50x40 piksel olarak küçültülmesi. a) Orjinal görüntüler, b) Küçültülmüş ve ölçeklendirilmiş normalize görüntüler**

#### 4.4 Tez Çalışmasında Geliştirilen Algoritmalar

Bu tez çalışmasında, iki boyutlu yüz görüntü matrisleri için geliştirilmiş olan dört farklı iki boyutlu tanıma algoritması vardır. Bu bölümde bu algoritmaların açıklaması, pseudocode olarak algoritmaları ve yapılan deneysel çalışmaların sonuçları verilmiştir.

##### 4.4.1 Ortak matris yaklaşımı ile görüntü tanıma

Ortak matris yaklaşımı (Turhal et al., 2005) temelde, daha önce bir boyutlu ses sinyallerinin tanınması için geliştirilmiş olan ortak vektör yaklaşımının iki boyutlu görüntü matrisleri için genişletilmesidir. Ortak vektör yaklaşımında görüntü matrisleri daha önce vektöre dönüştürülmektedir. Ortak matris yaklaşımında ise görüntüler vektöre dönüştürülmeden direk matris olarak kullanılmaktadır. Önce görüntüler için fark matrisleri hesaplanıp bir fark altuzayı oluşturulmakta ve bu fark altuzayında Gram-Schmidt ortogonalleştirme prosedürü ile fark matrisleri ortogonalleştirilmektedir.

Geliştirilen bu yaklaşım küçük örnek boyutu problemi ve yüz tanımadaki boyut probleminin çözümünü amaçlamaktadır. Bir sınıfa ait yüz görüntüleri arasında bazı

farklar vardır. Bu farklar aydınlatma koşullarındaki değişim, yüz ifade farklılıkları, yüz de gözlük ve atkı kullanımı gibi kapatacıcı unsurların bulunması gibi farklardır. Bütün bu farklara rağmen aslında tüm görüntüler aynı kişiye ait olduğu için bu görüntüler arasında hepsinde ortak olan özellikler de vardır. Bu yöntemdeki amaç bir sınıfa ait olan farklı yüz görüntüleri arasındaki benzerlikleri tespit edip bunu o sınıfı temsil etmek için kullanarak tanıma işlemini gerçekleştirmektir. Ortak matris yaklaşımı ile bir sınıftaki yüz görüntüleri arasındaki benzerlikleri ifade eden ve ortak matris olarak adlandırılan bir matris bulunur ve bu matris tanıma işlemi için kullanılır. Bu matris bir sınıfı temsil eden değişmez ve tek bir matristir.

Ortak matris hesabı iki şekilde yapılabilir. Birincisi; bir sınıf için farklılık altuzayı oluşturup bu altuzayda Gram-Schmidt ortogonalleştirme prosedürünü matrisler üzerinde uygulamaktır. Herhangi bir sınıf için ortak matris hesaplanırken eğitim aşamasında sadece o sınıfa ait olan yüz görüntüleri kullanılır. O nedenle bu yaklaşım sınıf içi dağılımı en küçükleyen bir yaklaşımdır. Öncelikle bir sınıf içindeki yüz görüntülerinden bir tanesi referans olarak seçilir. Referans olarak seçilen görüntünün önemi yoktur. Çünkü bir herhangi bir sınıftaki ortak özellikleri ifade eden ortak matris referans olarak seçilen yüz görüntüsünden bağımsızdır. Referans olarak seçilen yüz görüntüsü diğer görüntülerden çıkartılarak orjinal yüz görüntüleri için bir farklılık altuzayı oluşturulur.

Bir sınıftaki  $m \times n$  boyutlu görüntü matrisi  $A_i^c$  ile gösterilsin. Bu notasyondaki " $c$ " indisi görüntünün ait olduğu sınıfı, " $i$ " indisi de görüntünün sınıf içerisindeki numarasını gösterebilir. Bu durumda  $A_i^c$  görüntü matrisi aşağıdaki gibi tanımlanabilir

$$A_i^c = \begin{bmatrix} a_{11i}^c & a_{12i}^c & \cdot & a_{1ni}^c \\ a_{21i}^c & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ a_{m1i}^c & a_{m2i}^c & \cdot & a_{mni}^c \end{bmatrix} \quad 4.1$$

Eğitim kümesinde toplam  $C$  adet sınıf, ve her sınıfta  $l$  adet görüntü matrisi olsun. Fark matrisleri de  $B_i^c$  ile gösterilirse, farklılık altuzayı aşağıdaki gibi oluşturulabilir:

$$\mathbf{B}_i^c = \mathbf{A}_{i+1}^c - \mathbf{A}_i^c, \quad i = 1, \dots, l \quad 4.2$$

Oluşturulan bu farklılık altuzayında Gram-Schmidt ortogonalleştirme prosedürü uygulanarak farklılık altuzayını tarayan, lineer bağımsız ve ortonormal bir taban matrisleri kümesi elde edilir  $(\mathbf{Z}_1^c, \dots, \mathbf{Z}_{l-1}^c)$ . Bu sınıftaki herhangi bir yüz görüntü matrisi bu ortonormal ve lineer bağımsız taban matrislerinin bir lineer kombinasyonu ile tanımlanabilir. Daha sonra ortak matrisin hesaplanması için sınıftaki herhangi bir yüz görüntüsünün hesaplanan lineer bağımsız ve ortonormal tabanlar üzerine izdüşümü Eşitlik 3.15’de olduğu gibi alınarak kendisinden çıkartılır. Bu şekilde o sınıf için ortak matris elde edilmiş olur  $(\mathbf{A}_{\text{com}}^c)$ . Ortak matrisin hesabında sınıftaki hangi görüntünün tabanlar üzerine izdüşümünün alınacağına önemi yoktur çünkü ortak matris izdüşüm için seçilen bu matristen de bağımsızdır.

$$\mathbf{A}_{\text{com}}^c = \mathbf{A}_i^c - \langle \mathbf{A}_i^c, \mathbf{Z}_1^c \rangle \mathbf{Z}_1^c - \dots - \langle \mathbf{A}_i^c, \mathbf{Z}_{l-1}^c \rangle \mathbf{Z}_{l-1}^c \quad 4.3$$

Eşitlik 4.3’de kullanılan ve  $\mathbf{m} \times \mathbf{n}$  boyutlu  $\mathbf{A}$  görüntü matrisi ile  $\mathbf{Z}$  taban matrisinin iç çarpımı Eşitlik 4.4’de verilmiştir.

$$\langle \mathbf{A}, \mathbf{Z} \rangle = \sum_m \sum_n \mathbf{A}_{mn} \mathbf{Z}_{mn} = \text{trace}(\mathbf{A}^T \mathbf{Z}) = \text{trace}(\mathbf{A} \mathbf{Z}^T) \quad 4.4$$

Ar-Face veritabanından alınmış, biri kadın diğeri erkek iki farklı yüz görüntüsü için ortak matris yaklaşımı ile tanıma yapılırken elde edilmiş olan ortak matrisler bilgisayar ortamında Matlab (Matlab, 1994-2008) ile görüntülenmiştir (Şekil 4.4). Şekil 4.4 (a)’da orjinal yüz görüntü örnekleri Şekil 4.4. (b)’de orjinal görüntülerin temsil ettiği sınıflara ait ortak matris görünümüleri verilmiştir.



(a)



(b)

**Şekil 4.4 Ortak matris yaklaşımı ile elde edilmiş iki farklı yüz sınıfına ait ortak matris görünümü. a) İki farklı sınıfa ait orjinal yüz görüntü örnekleri, b) Bu sınıflar için ortak matris yaklaşımı ile elde edilmiş ortak matris görünümü**

Bu yaklaşımın test aşamasında kimliği bilinmeyen bir yüz görüntüsünün kimlik tespiti yapılmaktadır. Bunun için test görüntüsünün ( $A_t$ ) bir sınıf için hesaplanmış olan taban matrisleri üzerine izdüşümü alınıp o test matrisinden çıkartılır. Böylece test görüntüsünün o sınıf içindeki kalan matrisi ( $A_{rem}$ ) elde edilmiş olur.

$$\mathbf{A}_{\text{rem}} = \mathbf{A}_t - \langle \mathbf{A}_t^c, \mathbf{Z}_1^c \rangle \mathbf{Z}_1^c - \dots - \langle \mathbf{A}_t^c, \mathbf{Z}_{l-1}^c \rangle \mathbf{Z}_{l-1}^c \quad 4.5$$

Sınıflandırma için yapılacak olan işlem o sınıfın ortak matrisi ile test görüntüsününün o sınıfa ait olan kalan matrisi arasındaki öklid uzaklığına bakılarak yapılır. Bu işlem eğitim kümesindeki tüm sınıflar için uygulanır. Bulunan öklid uzaklıklarından hangisi en küçük ise test görüntüsü o sınıfa aittir denilir.

Ortak matrisi bulmanın ikinci yolu ise görüntü sınıflarının sınıf içi dağılım matrisini kullanmaktır.  $\mathbf{m} \times \mathbf{m} \times \mathbf{m}$  boyutlu sınıf içi dağılım matrisi ( $\mathbf{S}_w^c$ ) elde edildikten sonra bu matrisin özdeğer ve özvektörleri hesaplanır. Elde edilen özvektörler tensor'lerin düzleştirilmesi yolu ile tekrar matris haline getirilir. Özmatris olarak adlandırılan bu matrisler orjinal görüntü ile aynı boyutta olup görüntü matrisleri için bir taban oluştururlar. Bir sınıf için elde edilen özmatrislerden sıfır özdeğere karşılık gelenler üzerine, o sınıftaki herhangi bir görüntü matrisinin izdüşümü alınırsa o sınıf için özmatris elde edilir. Yapılan izdüşümde sıfır özdeğere karşılık gelen özmatrisler kullanıldığından elde edilen izdüşüm matrisi o sınıf içindeki benzer olan özellikleri temsil eden bir matris olur bu da ortak matristir. Bu ikinci yol ile hesaplanan ortak matris görüntü farklılık altuzayında uygulanan Gram-Schmidt ortogonalleştirme prosedürü ile elde edilen ortak matris ile aynıdır.

Herhangi bir c sınıfındaki bir  $\mathbf{A}_i^c$  görüntüsü aşağıdaki gibi tanımlanabilir:

$$\mathbf{A}_i^c = \begin{bmatrix} \vec{\mathbf{a}}_{1i}^c \\ \cdot \\ \vec{\mathbf{a}}_{mi}^c \end{bmatrix} \quad 4.6$$

Burada  $\vec{\mathbf{a}}_{ji}^c$   $\mathbf{j} = 1, \dots, \mathbf{M}$ ,  $\mathbf{A}_i^c$  görüntü matrisinin  $\mathbf{n}$ -boyutlu satır vektörlerini göstermektedir. Eğer her sınıf için ortalama matris bulunur,  $\overline{\mathbf{A}}^c$  ve o sınıftaki bütün görüntü matrislerinden çıkartılırsa sınıf ortalaması uzaklaştırılmış  $\overline{\overline{\mathbf{A}}}_i^c$  matrisleri bulunabilir.

$$\overline{\mathbf{A}}_i^c = \begin{bmatrix} \rightarrow c \\ \mathbf{a}_{1i} \\ \cdot \\ \rightarrow c \\ \mathbf{a}_{mi} \end{bmatrix} - \overline{\mathbf{A}}^c = \begin{bmatrix} \rightarrow c \\ \mathbf{a}_{1i} \\ \cdot \\ \rightarrow c \\ \mathbf{a}_{mi} \end{bmatrix} \quad 4.7$$

Sınıf içi dağılım matrisi  $\mathbf{S}_w^c$  aşağıdaki gibi elde edilebilir:

$$\mathbf{S}_w^c = \begin{bmatrix} \sum_{i=1}^M \left[ (\mathbf{a}_{1i})' (\mathbf{a}_{1i}) \right]_{n \times n} & \cdot & \sum_{i=1}^M \left[ (\mathbf{a}_{1i})' (\mathbf{a}_{mi}) \right]_{n \times n} \\ \sum_{i=1}^M \left[ (\mathbf{a}_{mi})' (\mathbf{a}_{1i}) \right]_{n \times n} & \cdot & \sum_{i=1}^M \left[ (\mathbf{a}_{mi})' (\mathbf{a}_{mi}) \right]_{n \times n} \end{bmatrix} \quad 4.8$$

Test aşamasında ilk önce test kümesindeki görüntü matrisinin sınıfların sıfır özdeğerlerine karşılık gelen özmatrisleri tarafından taranan alt uzay üzerine izdüşümü alınır. Bu izdüşüm matrisi ile o sınıf için bulunan ortak matris arasındaki öklid uzaklığı hesaplanır. Bu işlem tüm sınıflar için tekrarlanır. En az mesafe hangi sınıf için elde ediliyorsa test görüntüsü o sınıfa aittir şeklinde tanıma gerçekleştirilmiş olur.

Gram-Schmidt ortogonalleştirme yöntemi ile ortak matris hesabı için yazılan pseudocode aşağıdadır:

```
%Verilenler:
%C adet sınıf
%Her sınıf için mxn boyutlu l adet eğitim yüz görüntü matrisi
%Kimliği belirlenmek istenen mxn boyutlu test yüz görüntü matrisi  $\mathbf{A}_t$ 
T=1 olarak ata
Ortak matrisin elde edilmesi:
For c=1:C
    % referans olarak o sınıftaki herhangi bir görüntü seçilebilir
     $\mathbf{A}_1^c$  görüntü matrisini referans olarak al
    Fark matrislerini Eşitlik 4.2'de olduğu gibi hesapla
    % Fark matrislerine Gram-Schmidt Ortogonalleştirme prosedürü uygula
    Lineer bağımsız, ortonormal taban matrislerini  $\mathbf{Z}_1^c, \dots, \mathbf{Z}_{l-1}^c$  hesapla
```



Ortak matris ( $\mathbf{A}_{\text{com}}^c$ ) hesabını Eşitlik 4.3'de olduğu gibi hesapla

*%Test Prosedürü:*

Kimliği belirlenmek istenen test görüntüsünün kalan matrisi  $\mathbf{A}_{\text{rem}}$  (Eşitlik 4.5) hesapla

$\mathbf{A}_{\text{com}}^c$  matrisi ile  $\mathbf{A}_{\text{rem}}$  matrisi arasındaki mesafeyi öklid uzaklığı ile hesapla

Bulunan uzaklığı  $T=1$  indisi ile sakla

$T$ 'yi 1 arttır

End

Sınıflandırma Sonucu:

Saklanan öklid uzaklıklarından en küçük olanı bul

Test görüntüsü o sınıfa aittir şeklinde sınıflandır

Sınıf içi dağılım matrisini kullanarak ortak matris hesabı için yazılan pseudocode aşağıdaki gibidir:

*%Verilenler:*

*%C adet görüntü sınıfı*

*%Her sınıf için  $m \times n$  boyutlu  $l$  adet eğitim yüz görüntü matrisi*

*%Kimliği belirlenmek istenen  $m \times n$  boyutlu test yüz görüntü matrisi  $\mathbf{A}_t$*

*%P: sıfır özdeğer sayısı*

$T=1$

*% $E_i^c$  : c sınıfının i'inci özmatrisi*

*%Ortak Matrisin Elde Edilmesi:*

For  $c=1$ : C

Ortak\_matris=0

$m \times n \times l$  boyutlu  $\mathbf{S}_w^c$  dağılım matrisini hesapla (Eşitlik 4.8)

$\mathbf{S}_w^c$  sınıf içi dağılım matrisinin özdeğer ve özvektörlerini hesapla

Sıfır özdeğere karşılık gelen  $m \times l$  boyutlu özvektörleri  $m \times n$  boyutlu matrise dönüştür

Sınıftaki herhangi bir yüz matrisinin  $P$  tane sıfır özdeğere karşılık gelen özmatris üzerine izdüşümünü al (Eşitlik 3.15) ve o sınıfa ait ortak matrisi hesapla ( $\mathbf{A}_{\text{com}}^c$ )

End

*%Test Prosedürü:*

$\mathbf{A}_t$  matrisinin  $P$  tane sıfır özdeğere karşılık gelen özmatris üzerine izdüşümünü hesapla

*Ortak matris ile test matrisinin izdüşüm matrisi arasındaki öklid mesafesini hesapla*

*Bulunan uzaklığı  $T=1$  indisi ile sakla*

*T'yi 1 arttır*

*End*

*%Sınıflandırma Sonucu:*

*Saklanan öklid uzaklıklarından en küçük olanı bul*

*Test görüntüsü o sınıfa aittir şeklinde sınıflandır*

Ortak matris yaklaşımı ile yüz tanıma yöntemi Ar-Face veritabanı üzerinde oluşturulmuş iki farklı veritabanı kullanılarak test edilmiştir.

Birinci testte; bir sınıf için eğitim ve test kümelerinden alınan 63'er görüntü seçilmiş ve elde edilen bu 126 görüntüden rastgele seçilen 100 tane görüntü algoritmanın eğitim aşamasında kullanılmış, geri kalan 26 görüntü de test aşamasında kullanılmıştır. Eğitim için seçilen 100 adet görüntü matrisinden 99 tane ortonormal matris bulunmuştur. Her sınıf için eğitim kümesinden alınan herhangi bir matrisin bu ortonormal taban matrisleri üzerine izdüşümü alınıp kendisinden çıkartıldığında o sınıf için ortak matris elde edilmiştir. Eşitlik 2.9'da olduğu gibi hesaplanan Öklid mesafelerinin değerine göre yapılan sınıflandırmalar sonucu %99.1 oranında tanıma doğruluğu elde edilmiştir.

Ortak matrisin sınıf içi dağılım matrisi kullanılarak hesabında, sıfır özdeğerler tarafından taranan farksızlık alt uzayı kullanılmış ve hem eğitim kümesindeki görüntü matrislerinin hem de test görüntü matrisinin bu alt uzay üzerine izdüşümü alınmıştır. Bu izdüşümler arasındaki uzaklıklar Öklid normuna göre hesaplanmış ve bu uzaklıklara bakılarak test görüntü matrisinin sınıfların farksızlık altuzaylarına izdüşümü hangi sınıfta en küçük değer veriyorsa o test matrisi o sınıfa aittir şeklinde sınıflandırma yapılmıştır. Elde edilen tanıma oranı sonuçları Gram-Schmidt ortogonalleştirme yönteminde bulunan tanıma sonuçları ile aynı olup %99.1 dir.

İkinci testte Şekil 4.1'den A-G ve N-T görüntüleri olmak üzere her sınıf için toplam 14 tane görüntü seçilmiştir. Tanıma oranları eğitim kümesinin boyutu oldukça küçük olduğu için "leave one out" yöntemi ile hesaplanmıştır. Ortak matris hem Gram-Schmidt ortogonalleştirme yöntemi hemde sınıf içi dağılım matrisi kullanılarak hesaplanmış ve bu matris tanımada kullanılarak %97.7 oranında tanıma doğruluğu elde edilmiştir.

Eđitimde kullanılan yüz görüntü sayısı birbirinden farklı olan bu iki deneysel çalışma eđitimdeki görüntü sayısı arttıkça tanıma oranlarının da arttığı görülmüştür.

**Çizelge 4.1 Ar-Face veritabanı için birinci testten elde edilen deneysel sonuçlar**

Eđitim Kümesi	Test Kümesi
%100	%99.1

**Çizelge 4.2 Ar-Face veritabanı için ikinci testten elde edilen deneysel sonuçlar**

Eđitim Kümesi	Test Kümesi
%100	%97.7

#### **4.4.2 Yüz tanıma için 2 aşamalı bir algoritma: 2BABA ve sınıf-içi dağılım minimizasyonu**

2BABA'nde, görüntü satırları arasındaki fazlalık bilgileri yok edilerek tanıma işlemi gerçekleştirilmiştir. Bu yapılırken sadece sınıflar arası dağılım en büyüklenirken sınıf içi dağılımlar en küçüklenmemiştir. Tez kapsamında geliştirilen bu ikinci algorithmada 2BABA kullanılarak sınıflar arası dağılım en büyüklenirken aynı zamanda sınıf içi dağılımları da en küçükleyen bu nedenle sınıflandırma doğruluğu açısından 2BABA'ne göre daha iyi sonuçlar veren bir çalışma sunulmuştur (Turhal et al., 2007).

Geliştirilen bu algoritma iki aşamalı bir algoritmadır. İlk aşamada 2BABA kullanılarak eğitim kümesindeki yüz görüntülerine ait özellik vektörleri Eşitlik 2.19

kullanılarak hesaplanabilir. Bir yüz sınıfı için  $\mathbf{d}$  adet en büyük özvektör yönü için hesaplanan özellik vektörleri bir matrisin sütunlarını oluşturacak şekilde bir araya getirilirse o yüz sınıfının oluşturulan altuzaydaki izdüşüm matrisi elde edilmiş olur.

$$\mathbf{Y}_i^c = [\mathbf{y}_{i1}^c, \dots, \mathbf{y}_{id}^c] \quad 4.9$$

Bu ilk aşama ile sınıflar arası dağılımlar en büyüklenmiş olur. Algoritmanın, sınıf içi dağılımların en küçüklendiği ikinci aşamasında her sınıf için o sınıftaki  $l$  farklı yüz görüntüsünün aynı özvektör yönündeki özellik vektörleri bir matrisin sütunlarını oluşturacak şekilde bir araya getirilir.

$$\mathbf{y}_k^c = [\mathbf{y}_{1,k}^c, \mathbf{y}_{2,k}^c, \dots, \mathbf{y}_{l,k}^c] \quad \mathbf{k} = 1, \dots, \mathbf{d} \quad 4.10$$

Bir sınıfın aynı özvektör yönündeki farklı görüntülerine ait özellik vektörleri arasında farkların yanısıra benzerlikler de vardır. Bir özvektör yönündeki farklı özellik vektörleri arasındaki farklar Gram-Schmidt ortogonalleştirme yöntemi ile yok edilerek o sınıfın aynı özvektör yönündeki ortak özellik vektörü elde edilebilir. Böylece sınıf içi dağılımlar en küçüklenerek tanıma doğrulukları artırılabilir. Bunun için Eşitlik 4.10'da tanımlanmış olan özellik altuzayındaki özellik vektörlerinin fark altuzayı Eşitlik 2.24'de olduğu gibi oluşturulur. Daha sonra fark altuzayında Gram-Schmidt ortogonalleştirme yöntemi Eşitlik 2.27'de olduğu gibi uygulanarak bir sınıftaki farklı görüntülerin aynı özvektör yönündeki farklarını ifade eden ve lineer bağımsız ortonormal taban vektörleri kümesi

$$\vec{\mathbf{z}}_{1k}^c, \dots, \vec{\mathbf{z}}_{(l-1)k}^c, \quad \mathbf{k} = 1, \dots, \mathbf{d} \quad 4.11$$

elde edilir. O sınıftaki herhangi bir yüz görüntü matrisinin  $\mathbf{k}$ 'nci özvektör yönündeki herhangi bir özellik vektörünün hesaplanan lineer bağımsız ve ortonormal taban vektörleri üzerine izdüşümü alınıp kendisinden çıkartılırsa o özvektör yönündeki altuzay için ortak özellik vektörü  $\mathbf{y}_{\text{com},k}^c$  Eşitlik 2.28 ve 2.29 kullanılarak hesaplanır. Bu işlem bir sınıf içindeki  $\mathbf{d}$  tane özvektör yönü için tekrarlanır ve her özvektör yönü için

ortak özellik vektörleri bulunur. Bu özvektörler bir matrisin sütunlarını oluşturacak şekilde dizilirse o sınıfı temsil eden ortak özellik matrisi  $\mathbf{B}_{\text{com}}^c$  elde edilir (Eşitlik 4.12). Bu işlem  $C$  adet yüz görüntü sınıfı için tekrarlanır ve bulunan özellik matrisleri tanıma için kullanılır.

$$\mathbf{B}_{\text{com}}^c = [\mathbf{y}_{\text{com},1}^c \cdot \cdot \cdot \mathbf{y}_{\text{com},d}^c] \quad c = 1, \dots, C \quad 4.12$$

Test aşamasında ilk olarak test görüntüsünün  $d$  adet özellik vektörleri Eşitlik 2.19'da olduğu gibi hesaplanır. İkinci olarak test görüntüsünün bir sınıftaki bir özvektör yönündeki özellik vektörünün o yön için hesaplanmış olan lineer bağımsız ve ortonormal tabanlar üzerine izdüşümü alınıp kendisinden çıkartılırsa Eşitlik 2.28 ve 2.29 kullanılarak o yöndeki test kalan vektörü  $\mathbf{y}_{\text{rem},k}^c$  elde edilir. Bu işlem o sınıftaki  $d$  farklı özvektör yönü için tekrarlanır.  $d$  farklı yön için hesaplanan kalan vektörleri bir araya getirilerek test görüntüsünün o sınıfa ait kalan matrisi  $\mathbf{B}_{\text{rem}}^{\text{test},c}$  elde edilir (Eşitlik 4.13). Bu işlem  $C$  adet sınıf için tekrarlanır.

$$\mathbf{B}_{\text{rem}}^{\text{test},c} = [\mathbf{y}_{\text{rem},1}^{c,\text{test}}, \dots, \mathbf{y}_{\text{rem},d}^{c,\text{test}}] \quad c = 1, \dots, C \quad 4.13$$

Sınıflandırma için en yakın komşu sınıflandırması kullanılır. Bunun için test görüntüsünün her sınıf için hesaplanan kalan özellik matrisi ile sınıfların ortak özellik matrisleri arasındaki öklid uzaklıkları Eşitlik 2.21'de olduğu gibi hesaplanır. Eğer test görüntüsü  $c$ 'inci sınıfa ait ise  $\mathbf{B}_{\text{com}}^c$ ,  $\mathbf{B}_{\text{rem}}^{\text{test},c}$  arasındaki mesafe minimum olmalıdır.

Geliştirilen bu algoritmanın pseudocode'u aşağıdaki gibidir :

```
%Verilenler:
%C adet sınıf için toplam M adet yüz görüntüsü
%Her sınıf için mxn boyutlu l adet eğitim yüz görüntü matrisi  $\mathbf{A}_i^c$ 
%Kimliği belirlenmek istenen mxn boyutlu test yüz görüntü matrisi  $\mathbf{A}_t$ 
%d: İzdüşüm için seçilen özdeğer sayısı
T=1
%Özellik Çıkartımı:
1. % Aşama: Sınıflar arası dağılımın en büyüklenmesi
```

```

For c=1:C
  For i=1:l
    Eğitim kümesindeki tüm görüntüler için ortalama görüntü Eşitlik 2.15'de olduğu
    gibi hesaplanır
  End
End
% M adet ortalama uzaklaştırılmış görüntüye 2BABA'ni uygula
For c=1:C
  For i=1:l
    Sınıflar arası dağılım matrisi Eşitlik 2.16'dan yararlanılarak hesapla
  End
End
% S1 sınıflar arası dağılım matrisinin özdeğer ve özvektörlerini hesapla
% n tane özvektörü özdeğerlerinin büyüklüğüne göre büyükten küçüğe sırala
For c=1:C
  For i=1:l
    For k=1:d
      Eşitlik 2.19'dan yararlanarak özellik vektörlerini hesapla
    End
  End
End

% 2.Aşama: Sınıf içi dağılımların en küçüklenmesi
For k=1:d
  c sınıfındaki aynı özvektör yönündeki farklı görüntülere ait özellik
  vektörlerinden oluşan bir veri kümesi oluşturulur
  For i=1:l
    Eşitlik 2.24'den yararlanarak fark özellik vektörlerini hesapla
  End
  k'ncü özvektör yönündeki ortak özellik vektörünü Eşitlik 2.28 ve 2.29'dan yararlanarak
  hesapla
End
c sınıfının d farklı özvektör yönü için hesaplanan ortak özellik vektörleri bir matriste bir araya
getirilerek o sınıfa ait ortak özellik matrisi oluştur
%Test Prosedürü:
Test görüntüsü için Eşitlik 2.19'dan yararlanarak özellik vektörlerini hesapla
For k=1:d

```

*Test özellik vektörünün k'inci özvektör yönündeki kalan özellik vektörünü Eşitlik 2.28 ve 2.29'dan yararlanarak hesaplar*

*End*

*d adet özvektör yönü için hesaplanan test kalan vektörleri bir matriste birleştirilerek test kalan matrisi elde et*

*Ortak özellik matrisi ile testkalan özellik matrisinin arasındaki öklid mesafesini hesapla*

*Bulunan uzaklığı  $T=1$  indisi ile sakla*

*T'yi 1 arttır*

*End*

*%Sınıflandırma Sonucu:*

*Saklanan öklid uzaklıklarından en küçük olanı bul*

*Test görüntüsü o sınıfa aittir şeklinde sınıflandır*

Bu çalışmada AR-Face veritabanından rastgele seçilmiş, 20 erkek 17 kadın görüntüsünden oluşan 37 tane sınıf üzerinde çalışılmıştır. Veritabanında sadece kapatılmamış görüntüler kullanılmıştır. Oluşturulan bu veritabanında üç farklı deneysel çalışma yapılmıştır. Yapılan çalışmaların hepsi Eigenface, Fisherface ve 2BABA algoritmaları için de karşılaştırma amacıyla uygulanmıştır. Karşılaştırmalı sonuçlar Çizelge 4.3'de verildiği gibidir.

Birinci deneysel çalışmada (A,N) görüntüleri eğitim kümesi ve (B-D), (O-Q) görüntüleri de test kümesi olarak kullanılmıştır (Bkz. Şekil 4.1). Kullanılan eğitim kümesi 74 görüntüden oluşmaktadır.

İkinci deneysel çalışmada (A-G) görüntüleri eğitim kümesi, (N-T) görüntüleri test kümesi olarak kullanılmıştır (Bkz. Şekil 4.1). Eğitim kümesi 259 görüntüden oluşmaktadır.

Üçüncü deneysel çalışmada ise (A-G) ve (N-T) görüntüleri olmak üzere toplam 14 adet görüntü için leave-one-out yöntemi kullanılmıştır (Bkz. Şekil 4.1). Eğitim kümesi 481 görüntüden oluşmaktadır.

Geliştirilen bu yöntem ile ilgili uygulama sonuçları, bilinen diğer yöntemlerle karşılaştırmalı olarak Çizelge 4.3'de verilmiştir. Bu sonuçlar analiz edilecek olursa her üç uygulama için de en yüksek tanıma doğruluklarının bu bölümde sunulan yöntem ile elde edildiği görülmektedir. Birinci uygulamada sadece normal yüz görüntüleri ile eğitilmiş olan sistem sadece yüz ifade farklılıkları olan görüntüler ile test edilmiştir. Bu

uygulama için 2BABA ile sunulan yöntemin tanıma performansı arasındaki çok fazla değildir. Ancak ikinci uygulamada eğitim ve test kümelerine aralarında aydınlatma farkı olan görüntüler de katılınca sunulan yöntemin tanıma performansı ile 2BABA yönteminin tanıma performansı arasındaki fark çok artmaktadır. Dolayısıyla aralarında aydınlatma farkı olan görüntüler kullanıldığında sunulan yöntemin tanıma performansının 2BABA yöntemine göre çok daha iyi olduğu söylenebilir. İkinci uygulamada eğitim ve test kümesi olarak kullanılan görüntüler için birini dışarıda bırakma tekniği uygulanmış ve böylece ikinci uygulamaya göre eğitim kümesindeki görüntü sayısı artırılmıştır. Bu durumda sunulan yöntemin tanıma performansı ile 2BABA yönteminin tanıma performansı arasındaki fark ikinci uygulamadakinine göre daha da artmıştır. Bu durumda eğitim görüntü sayılarındaki artışın tanıma performanslarında artışa sebep olduğu söylenebilir.

**Çizelge 4.3 Kullanılan veritabanları için elde edilen deneysel sonuçlar**

Metodlar	1. Uygulama Sonuçları (%)	2.Uygulama Sonuçları (%)	3.Uygulama Sonuçları (%)
ABA	77.47	57.91	88.22
Fisherfaces	77.92	64.09	95.17
2BABA	79.72	52.12	72.58
Sunulan yöntem	80.63	66.40	95.94

#### **4.4.3 Görüntünün her iki boyutundaki değişimlerin birlikte kullanımı ile özellik matris boyutunun küçültülerek tanıma performansının artırılması**

Bilindiği gibi ABA, sınıflar arası dağılımı en büyüklemeyi amaçlayan bir tanıma metodudur. Burada sınıflar arası dağılım En büyüklenirken sınıf içi dağılımların en küçüklenmesi yapılmamaktadır. Bu da yöntemin sınıflandırma açısından çok da iyi sonuçlar vermemesi sonucunu doğurur. Bu yöntem sınıflandırmadan daha çok görüntünün iyi bir temsilini elde etmekte daha etkilidir. Bunun yanısıra ABA'nin boyut büyüklüğü, özvektörlerin hesaplanması için gerekli işlem zamanının uzunluğu ve işlem karmaşıklığı gibi başka dezavantajları da vardır.



ABA'nin işlem uzunluğu ve işlem karmaşıklığı gibi problemlerini ortadan kaldırmak için bu yöntemin 2-boyutlu uygulaması olan 2BABA yöntemi geliştirilmiştir. Fakat 2BABA de ABA'de olduğu gibi sınıflar arası dağılımı en büyükleyen fakat sınıf içi dağılımı en küçüklemeyen bir metod olduğundan o da sınıflandırma açısından çok verimli olmayan bir metoddur. Ayrıca 2BABA hafıza gereksinimleri açısından ABA'ne göre daha fazla yere ihtiyaç duymaktadır.

Bu çalışmada özellik çıkartımı için 2BABA'den yararlanan, 2BABA'deki boyut probleminin çözümünü amaçlayan bir algoritma sunulmuştur. Sunulan bu algoritma ile aynı zamanda sınıflar arası dağılım en büyüklenirken sınıf içi dağılım da en küçülenmektedir. Bölüm 4.4.2'de geliştirilen algoritma da sınıflar arası dağılımı en büyükleyen ve sınıf içi dağılımı da en küçükleyen bir algoritma idi. Bu bölümde detayları verilecek olan algoritmada bir adım daha ileri gidilerek sınıfları temsil etmek için kullanılan ortak özellik matrisinin boyutları küçültülmüş ve 2BABA'ndeki hafıza problemine çözüm önerilmiştir. Bunun için önce yüz görüntü matrislerinin sütunları ve de satırları üzerinde 2BABA yöntemi uygulanmıştır. Sütunlar üzerinde gerçekleştirilen dönüşüm ile özellik çıkartımı yapılmıştır. Daha sonra her sınıf için elde edilen ortak özellik matrislerinin, satırlar üzerinde uygulanan 2BABA yönteminden elde edilen özvektörler üzerine izdüşümü alınarak ortak özellik matris boyutu küçültülmüştür. Boyut indirgemek için Xu ve arkadaşlarının (2005, a) çalışmasında olduğu gibi orjinal görüntü uzayına göre bilgi kaybı olan özellik uzayı yerine herhangi bir bilgi kaybının olmadığı orjinal görüntü uzayında gerçekleştirilmiştir.

Sunulan algoritmada sınıflar arası dağılımın en büyüklenmesini görüntünün sütunları üzerinde 2BABA uygulanarak gerçekleştirilmiştir. Görüntü matrisinin sütunlarını bir nesne olarak kabul ederek görüntü kovaryans matrisi  $S_{1c}$  (Eşitlik 4.14), hesaplanmıştır. Eşitlikteki  $\bar{A}$ , eğitimde kullanılan yüz atrislerinin ortalama matrisidir (Eşitlik 4.15).

$$S_{1c} = \frac{1}{M} \sum_{c=1}^c \sum_{i=1}^l (A_i^c - \bar{A})(A_i^c - \bar{A}) \quad 4.14$$

$$\bar{\mathbf{A}} = \frac{\mathbf{1}}{\mathbf{M}} \sum_{c=1}^c \sum_{i=1}^l \mathbf{A}_i^c \quad 4.15$$

Sütun kovaryans matrisine özdeğer-özvektör ayrışımı uygulanmıştır Sütun değişimlerini temsil eden kovaryans matrisinin özdeğer-özvektör ayrışımından elde edilen  $\mathbf{d}$  tane özvektör izdüşüm yönü olarak kullanılarak o sınıftaki her görüntü matrisi için  $\mathbf{d}$  tane özellik vektörü  $\vec{\mathbf{y}}_{ik}^c$  ;

$$\vec{\mathbf{y}}_k = \mathbf{A}^T \vec{\mathbf{e}}_k, \quad \mathbf{k} = 1, \dots, \mathbf{d} \quad 4.16$$

Eşitlik 2.19’da olduğu gibi elde edilir. Bir sınıfa ait aynı özvektör yönündeki farklı görüntüler için elde edilen ortak özellikler, o izdüşüm yönünde aynı sınıftaki farklı görüntülere ait özellik vektörleri arasındaki farkların Gram-Schmidt Ortogonalleştirme yöntemini kullanarak uzaklaştırılması ile elde edilir. Böylece sınıf içi dağılımlar en küçüklenmiş olur. Dolayısıyla bir sınıfta  $\mathbf{d}$  tane özvektör yönüne karşı gelen  $\mathbf{d}$  tane ortak özellik vektörü elde edilmiş olur. Sonuç olarak bulunan  $\mathbf{d}$  farklı özvektör yönüne ait  $\mathbf{d}$  adet ortak özellik vektörü bir matrisin sütunlarını oluşturacak şekilde bir araya getirilirse o sınıf için ortak özellik matrisi  $\mathbf{B}_{\text{com}}^c$ , Eşitlik 4.12’de olduğu gibi hesaplanır.

Bulunan bu ortak özellik matrisinin boyutunu azaltmak için her bir görüntü satırının bir nesne olarak kabul edildiği satır kovaryans matrisi  $\mathbf{S}_{1r}$ , hesaplanır.

$$\mathbf{S}_{1r} = \frac{\mathbf{1}}{\mathbf{M}} \sum_{c=1}^c \sum_{i=1}^l (\mathbf{A}_i^c - \bar{\mathbf{A}})^T (\mathbf{A}_i^c - \bar{\mathbf{A}}) \quad 4.17$$

Satır kovaryans matrisine özdeğer-özvektör ayrışımı uygulanır. Sütun kovaryans matrisinin özdeğer-özvektör ayrışımında olduğu gibi  $\mathbf{d}$  adet en büyük özdeğere karşılık gelen özvektör optimal izdüşüm yönü olarak kullanılır. Her bir sınıf için hesaplanan ortak özellik matrisinin özdeğer-özvektör ayrışımından elde edilen optimal  $\mathbf{d}$  izdüşüm yönü üzerine izdüşümü alınır. Bu izdüşüm sonucunda her sınıf için elde edilen yeni ortak özellik matrisi  $\mathbf{R}_{\text{com}}^c$  ile gösterilirse

$$\mathbf{R}_{\text{com}}^c = (\mathbf{B}_{\text{com}}^c)^T \mathbf{V} \quad 4.18$$

$$\mathbf{V} = [\vec{\mathbf{v}}_1, \dots, \vec{\mathbf{v}}_d] \quad 4.19$$

Eşitlik 4.19'daki  $\mathbf{V}$  matrisinin sütunlarını oluşturan  $\vec{\mathbf{v}}_k$ , ( $k = 1, \dots, d$ ) vektörleri, Eşitlik 4.17'de hesaplanan satır kovaryans matrisinin,  $d$  adet en büyük özdeğerine karşılık gelen özvektörlerini göstermektedir. Sonuç olarak her sınıf için elde edilen ortak özellik matrisinin boyutu  $d \times d$ 'ye, yani izdüşüm için seçilen özvektör boyutuna indirgenmiş olur.

Test aşamasında test görüntüsü için Eşitlik 2.19'da olduğu gibi  $d$  adet  $\vec{\mathbf{y}}_k^{\text{test}}$  özellik vektörleri hesaplanır. Test özellik vektörünün her sınıf için bulunan  $d$  adet özellik altuzayına karşılık gelen ortonormal tabanlar üzerine izdüşümü alınıp test özellik vektörünün kendisinden çıkartılırsa test görüntüsü için  $d$  adet kalan özellik vektörü  $\vec{\mathbf{y}}_{\text{rem},k}^{\text{test},c}$  elde edilir. Kalan özellik vektörleri bir matriste bir araya getirilerek test görüntüsü için kalan özellik matrisi  $\mathbf{B}_{\text{rem}}^{\text{test},c}$  eşitlik 4.13'de olduğu gibi elde edilir.

Test görüntüsünün kalan özellik matrisinin sınıfların satır kovaryans matrisinden elde edilen  $d$  adet izdüşüm yönü üzerine izdüşümü alınarak test görüntüsü için boyutu indirgenmiş kalan matris  $\mathbf{R}_{\text{rem}}^{\text{test},c}$ , elde edilir.

$$\mathbf{R}_{\text{rem}}^{\text{test},c} = (\mathbf{B}_{\text{rem}}^{\text{test},c})^T \mathbf{V} \quad 4.20$$

Sınıflandırma için en yakın komşu sınıflandırması kullanılır. Bunun için  $\mathbf{R}_{\text{com}}^c$  ve  $\mathbf{R}_{\text{rem}}^{\text{test},c}$  matrislerinin sütun vektörleri arasındaki öklid uzaklığı hesaplanır. Eğer test görüntüsü  $c$  sınıfına ait ise  $\mathbf{R}_{\text{com}}^c$  ve  $\mathbf{R}_{\text{rem}}^{\text{test},c}$  arasındaki mesafe minimum olmalıdır.

Bu bölümde geliştirilen algoritmanın pseudocode yazılımı aşağıdaki gibidir :

```
%Verilenler:
%C adet sınıf için toplam M adet yüz görüntüsü
%Her sınıf için mxn boyutlu l adet eğitim yüz görüntü matrisi  $\mathbf{A}_i^c$ 
```

```

%Kimliği belirlenmek istenen mxn boyutlu test yüz görüntü matrisi  $A_t$ 
%d: İzdüşüm için seçilen özdeğer sayısı
T=1
%Özellik çıkartımı
Eşitlik 4.14'den yararlanarak sınıflar arası dağılım matrisini  $S_{1c}$  hesapla
%Ortak matris hesabı
For c=1: C
    Eşitlik 4.13'de olduğu gibi ortak matris hesaplanır
    %Boyut indirgenmesi:
    Eşitlik 4.19'da hesaplanan özvektörleri kullanarak ortak matrisinin boyut indirgenmesi yapılır
    %Test Prosedürü:
    Eşitlik 4.13'de olduğu gibi test matrisinin d adet kalan sütun vektöründen oluşan kalan özellik
    matrisi elde edilir
    Ortak özellik matrisi ile test kalan özellik matrisinin sütun vektörleri arasındaki öklid
    mesafesini hesapla
    Bulunan uzaklığı T=1 indisi ile sakla
    T'yi 1 arttır
End
%Sınıflandırma Sonucu:
Saklanan öklid uzaklıklarından en küçük olanı bul
Test görüntüsü o sınıfa aittir şeklinde sınıflandır

```

Bu çalışmanın test aşamasında AR-Face ve ORL veritabanları üzerinde çalışılmıştır. AR-Face veritabanı kullanılarak yapılan çalışma için AR-Face veritabanından toplam 37 (20 erkek, 17 kadın) görüntü kullanılmıştır. Her sınıf için veritabanından sadece kapatılmamış görüntüler seçilmiştir. Görüntülerdeki yüz bölümü 50x40 piksel olacak şekilde arka plan atılarak küçültülmüştür.

AR-Face veritabanından oluşturulan üç veritabanı kullanılarak üç farklı deneysel çalışma yapılmıştır. Her deney, sunulan yöntemin tanıma performansını karşılaştırmak amacıyla çok bilinen Eigenface, Fisherface ve 2BABA metodları için de yapılmıştır. Deneysel çalışmada, toplam enerjinin %95'ini içeren ilk en büyük  $d$  özdeğere karşı gelen  $d$  özvektör kullanılmıştır (Xu et al., 2005 a). Deneysel çalışmalarda Ar-Face veritabanı için oluşturulmuş veritabanları Bölüm 4.4.2'de kullanılan veritabanları ile aynıdır. Sunulan yöntem için elde edilen deneysel çalışma sonuçları Çizelge 4. 4'de verilmiştir.

Sunulan yöntemin sonuçları analiz edilecek olursa her üç uygulama için de en yüksek tanıma doğruluklarının bu bölümde sunulan yöntem ile elde edildiği görülmektedir. Bu bölümde sunulan algoritmanın deneysel sonuçları Bölüm 4.4.2’de sunulan algoritma ile de karşılaştırılmış ve her üç deneysel çalışmada da daha iyi tanıma doğrulukları elde edilmiştir. Birinci uygulamada sadece normal yüz görüntüleri ile eğitilmiş olan sistem sadece yüz ifade farklılıkları olan görüntüler ile test edilmiştir. Bu uygulama için 2BABA ile sunulan yöntemin tanıma performansı arasındaki çok fazla değildir. Ancak ikinci uygulamada eğitim ve test kümelerine aralarında aydınlatma farkı olan görüntüler de katılınca sunulan yöntemin tanıma performansı ile 2BABA yönteminin tanıma performansı arasındaki fark çok artmaktadır. Dolayısıyla aralarında aydınlatma farkı olan görüntüler kullanıldığında sunulan yöntemin tanıma performansının 2BABA yöntemine göre çok daha iyi olduğu söylenebilir. İkinci uygulamada eğitim ve test kümesi olarak kullanılan görüntüler için birini dışarıda bırakma tekniği uygulanmış ve böylece ikinci uygulamaya göre eğitim kümesindeki görüntü sayısı artırılmıştır. Bu durumda sunulan yöntemin tanıma performansı ile 2BABA yönteminin tanıma performansı arasındaki fark ikinci uygulamadakine göre daha da artmıştır. Bu durumda eğitim görüntü sayılarındaki artışın tanıma performanslarında artışa sebep olduğu söylenebilir.

**Çizelge 4.4 Ar-face veritabanı üzerinde gerçekleştirilmiş deneysel sonuçlar**

Metodlar	1. Sonuçlar (%)	2. Sonuçlar (%)	3. Sonuçlar (%)
ABA	77.47	57.91	88.22
Fisherfaces	77.92	64.09	95.17
2BABA	79.72	52.12	72.58
Turhal et al., 2007	80.63	66.40	95.94
Sunulan Metod	82.43	68.72	97.29

ORL veritabanı kullanılarak (Bkz. Şekil 4.2) yapılan çalışmada toplam 40 kişiye ait 10 farklı poz kullanılarak çalışılmıştır. Görüntüler üzerinde herhangi bir ön işlem yapılmaksızın direk orjinal halleri ile kullanılmıştır. Bu veritabanı kullanılarak iki farklı deneysel çalışma yapılmıştır. İlk çalışmada, her sınıftan ilk beş görüntü eğitim kümesi

kalan görüntüler de test kümesi olarak kullanılmıştır. Böylece eğitim kümesi toplam 200 görüntüden oluşmaktadır.

İkinci deneysel çalışmada ise leave-one-out stratejisi uygulanmıştır. Böylece bu ikinci deneyde eğitim kümesi toplam 360 görüntüden oluşmaktadır. Her iki deneyde de oluşturulan veritabanları 2BABA algoritması için de uygulanmıştır. Yapılan deneylerde kullanılan özvektör sayısı toplam enerjinin %95'ini içeren ilk  $d$  özdeğere karşılık gelen  $d$  özvektör sayısı kadardır. ORL veritabanı (Bkz. Şekil 4.2) üzerinde gerçekleştirilen bu iki deneysel çalışmanın sonucu Çizelge 4. 5'de verildiği gibidir.

ORL veritabanı üzerinde yapılan bu deneysel çalışmanın tanıma doğrulukları veritabanında kullanılan yüz görüntü sayıları açısından yapılmış ve sonuçlar 2BABA yöntemi sonuçları ile karşılaştırmalı olarak verilmiştir. Yapılan çalışmaların her ikisinde de sunulan algoritmanın daha yüksek tanıma doğrulukları verdiği görülmüştür.

**Çizelge 4.5 ORL veritabanı üzerinde gerçekleştirilmiş deneysel sonuçlar**

Metodlar	1. Sonuçlar (%)	2. Sonuçlar (%)
2BABA	84.5	94.33
Sunulan Metod	89.5	98

#### **4.4.4 Görüntü matrisinin satır ve sütun vektörleri arasındaki değişimleri kullanarak görüntü tanıma**

Geleneksel ABA'de görüntü tanıma için görüntü pikselleri arasındaki değişimler kullanılmıştır. Böylece görüntü vektörlerinin pikselleri arasındaki farklar en büyüklükten görüntü sınıfları birbirlerinden ayrılmaya çalışılmıştır. 2BABA'de ise, görüntü matrisinin satır vektörleri arasındaki değişimleri kullanır. Bu yöntemde de görüntü matrislerinin satır vektörleri arasındaki farklar en büyüklükten görüntü sınıfları birbirlerinden ayrılmaya çalışılır. Ancak şimdiye kadar yapılan çalışmalarda görüntü matrisinin iki boyutunu temsil eden satır vektörleri ile sütun vektörleri arasındaki değişimleri kullanan yani satır vektörleri ile sütun vektörleri arasındaki farkların en büyüklükten yolu ile görüntü sınıflarını birbirlerinden ayırmaya çalışan bir

algoritma geliştirilmemiştir. Oysa görüntü matrisinin iki boyutunu oluşturan satır ve sütun vektörleri arasındaki değişimler de tanımada etkili olabilecek bilgiye sahiptir. Bu noktadan yola çıkarak tez çalışmasının bu bölümünde görüntü matrisinin satır ve sütunları arasındaki farkların en büyüklükten yüz görüntü matrislerinin sınıflandırıldığı yeni bir algoritma sunulmuştur.

Bu bölümde sunulan algoritmada görüntü matrislerinin satır vektörleri ile sütun vektörleri arasındaki değişimleri gösteren sınıflar arası dağılım matrisi görüntü matrislerinin sütun ve satır vektörlerinin dış çarpımlarının toplamlarından oluşturulmuş görüntü karşı-kovaryans matrisi  $S_{Irc}$  kullanılarak oluşturulmuştur. Bu matris, orjinal görüntü matrisi ile aynı boyuttadır. Eğitim setindeki tüm görüntü matrislerinden Eşitlik 1.15'deki gibi hesaplanan ortalama görüntü ortalama çıkartılırsa  $\bar{A}_i$  ile gösterilen ortalama uzaklaştırılmış görüntüleri aşağıdaki gibi elde edebiliriz:

$$\bar{A}_i = A_i - \bar{A} = \begin{bmatrix} \bar{a}_{11} & \bar{a}_{12} & \cdot & \bar{a}_{1n} \\ \bar{a}_{21} & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \bar{a}_{m1} & \cdot & \cdot & \bar{a}_{mn} \end{bmatrix} \begin{matrix} \rightarrow \\ \rightarrow \\ \cdot \\ \rightarrow \end{matrix} \begin{matrix} \bar{r}_{i1} \\ \bar{r}_{i2} \\ \cdot \\ \bar{r}_{im} \end{matrix} \\ \downarrow \quad \downarrow \quad \cdot \quad \downarrow \\ \bar{c}_{i1} \quad \bar{c}_{i2} \quad \cdot \quad \bar{c}_{in}$$
4.21

Burada  $\bar{r}_{ij}$ ,  $j = 1, \dots, m$ ,  $\bar{A}_i$ 'nin satır vektörlerini ve  $\bar{c}_{ig}$ ,  $g = 1, \dots, n$  ise  $\bar{A}_i$ 'nin sütun vektörlerini göstermektedir.  $m \times n$  boyutlu görüntü karşı-kovaryans matrisi  $S_{Irc}$ , aşağıdaki formül ile hesaplanır:

$$S_{Irc} = \frac{1}{M} \sum_{i=1}^M \sum_{j=1}^m \sum_{g=1}^n (\bar{c}_{ig}) \circ (\bar{r}_{ij})$$
4.22

Burada “ $\circ$ ” operatörü sütun ve satır vektörlerinin dış çarpımını göstermektedir.

Görüntü karşı-kovaryans matrisinin özdeğer ve özvektörlerini hesaplayabilmek için bu matrise TDA uygulanır. Böylece aşağıda tanımlandığı gibi sağ ve sol tek matrisleri oluşturulur (Jain, 1988):

$\mathbf{S}_{\text{Irc}}\mathbf{S}_{\text{Irc}}^T$  : mxm boyutlu sağ tek matrisi;

$\mathbf{S}_{\text{Irc}}^T\mathbf{S}_{\text{Irc}}$  : nxn boyutlu sol tek matrisi.

Görüntü karşı-kovaryans matrisi reel ve  $\mathbf{n} \leq \mathbf{m}$  olsun. O zaman  $\mathbf{S}_{\text{Irc}}\mathbf{S}_{\text{Irc}}^T$  ve  $\mathbf{S}_{\text{Irc}}^T\mathbf{S}_{\text{Irc}}$  matrisleri negatif olmayan, simetrik ve aynı özdeğerlere sahiptir.  $\mathbf{n} \leq \mathbf{m}$  olduğu için en fazla  $\mathbf{R} \leq \mathbf{n}$  tane sıfır olmayan özdeğer vardır. Bu durumda  $\mathbf{S}_{\text{Irc}}^T\mathbf{S}_{\text{Irc}}$  'nin  $\mathbf{nx1}$  boyutlu  $\mathbf{R}$  tane muhtemel ortogonal sol tek vektörleri  $\{\vec{\varphi}_s\}$  ve  $\mathbf{S}_{\text{Irc}}\mathbf{S}_{\text{Irc}}^T$  'nin  $\mathbf{mx1}$  boyutlu  $\mathbf{R}$  tane muhtemel sağ tek vektörleri  $\{\vec{\psi}_s\}$  olacaktır.

$$\begin{aligned} \mathbf{S}_{\text{Irc}}^T\mathbf{S}_{\text{Irc}}\vec{\varphi}_s &= \lambda_s\vec{\varphi}_s & \mathbf{s} &= \mathbf{1}, \dots, \mathbf{R} \\ \mathbf{S}_{\text{Irc}}\mathbf{S}_{\text{Irc}}^T\vec{\psi}_s &= \lambda_s\vec{\psi}_s & \mathbf{s} &= \mathbf{1}, \dots, \mathbf{R} \end{aligned} \quad 4.23$$

Bu durumda  $\mathbf{S}_{\text{Irc}}$  görüntü karşı-kovaryans matrisi aşağıdaki gibi temsil edilir:

$$\begin{aligned} \mathbf{S}_{\text{Irc}} &= \boldsymbol{\Psi} \boldsymbol{\Lambda}^{\frac{1}{2}} \boldsymbol{\Phi}^T \\ &= \sum_{s=1}^{\mathbf{R}} \sqrt{\lambda_s} \boldsymbol{\Psi}_s \boldsymbol{\Phi}_s^T \end{aligned} \quad 4.24$$

Elde edilmiş olan sağ ve sol tek vektörleri özellik çıkartmak için optimal izdüşüm vektörleri olarak kullanılır.

Özellik çıkartılırken görüntü karşı-kovaryans matrisinin TDA'dan elde edilen sağ ve sol tek matrislerinin özvektörleri görüntü matrisinin sütun ve satır vektörleri arasındaki değişim bilgilerini verir. Özellik çıkartmak için en büyük  $\mathbf{d}$  özdeğere karşılık gelen  $\mathbf{d}$  özvektör ( $\mathbf{d}(\mathbf{R})$ ) optimal izdüşüm vektörü olarak kullanılmıştır. Verilen bir  $\mathbf{A}$  görüntü matrisi için iki adet özellik vektör kümesi (sağ ve sol özellik vektör kümesi) aşağıdaki lineer dönüşüm ile hesaplanır:



$$\begin{aligned}\vec{y}_k^{-1} &= \mathbf{A} \vec{\phi}_k \\ \vec{y}_k^{-2} &= \mathbf{A}^T \vec{\psi}_k\end{aligned}\quad \mathbf{k}=1,\dots,\mathbf{d}\quad 4.25$$

$\{ \vec{y}_k^{-1}, \vec{y}_k^{-2} \}$   $\mathbf{k}=1,\dots,\mathbf{d}$  özellik vektör kümesinin elemanları sırasıyla  $\mathbf{m}\times\mathbf{1}$  boyutlu sol özellik vektörleri ve  $\mathbf{n}\times\mathbf{1}$  boyutlu sağ özellik vektörleridir. Sınıflandırma yöntemi olarak en yakın komşu sınıflandırması kullanılmıştır.

Test aşamasında gelen test görüntüsü için  $\mathbf{A}^{test}$  görüntüsü için  $\{ \vec{y}_k^{-1test}, \vec{y}_k^{-2test} \}$   $\mathbf{k}=1,\dots,\mathbf{d}$ , sağ ve sol özellik vektörleri eğitim kümesindeki görüntüler için elde edildiği gibi elde edilir. Test görüntüsü için elde edilen iki özellik vektör kümesi ile sınıflara ait özellik vektör kümeleri arasındaki  $\mathbf{D}^c$  mesafesi aşağıdaki formülle hesaplanır:

$$\mathbf{D}^c = \sum_{k=1}^{\mathbf{d}} \left\| \vec{y}_k^{-1c} - \vec{y}_k^{-1test} \right\| + \sum_{k=1}^{\mathbf{d}} \left\| \vec{y}_k^{-2c} - \vec{y}_k^{-2test} \right\| \quad 4.26$$

$\mathbf{c} = 1,\dots,\mathbf{C}$ ,  $\mathbf{C}$ : Eğitim kümesindeki sınıf sayısı.

Test görüntüsü  $\mathbf{c}$  sınıfına ait ise  $\mathbf{D}^c$  mesafesi minimum olmalıdır.

$\mathbf{A}$  görüntü matrisinin yaklaşığı olan görüntü matrisi  $\tilde{\mathbf{A}}$ , görüntü kovaryans matrisinin TDA'nın  $\mathbf{d}$  tane en büyük özdeğerine karşılık gelen sağ özvektörler  $\{ \vec{\psi}_s \}$  ve sol özvektörlerin  $\{ \vec{\phi}_s \}$  dış çarpımlarının ağırlıklı toplamından elde edilebilir. Bu dış çarpımlardan her biri bir özgörüntüye karşılık gelir ( $\mathbf{E}_{ij} = \vec{\psi}_i \vec{\phi}_j^T$   $1 \leq i \leq \mathbf{d}$ ,  $1 \leq j \leq \mathbf{d}$ ).

$$\begin{aligned}\tilde{\mathbf{A}} &= \sum_{i=1}^{\mathbf{d}} \sum_{j=1}^{\mathbf{d}} \mathbf{D}_{ij} \mathbf{E}_{ij} \\ \mathbf{D}_{ij} &= \langle \mathbf{A}, \mathbf{E}_{ij} \rangle\end{aligned}\quad 4.27$$

$D_{ij}$ ; bir  $A$  görüntüsünün  $E_{ij}$ .inci özgörüntü ile iç çarpımından elde edilen katsayıdır. Eğer orjinal görüntü yeniden elde edilmek isteniyorsa yukarıda hesaplanmış olan sağ ve sol özvektörlerin hepsinin kullanılması gereklidir.

$$A = \sum_{i=1}^m \sum_{j=1}^n D_{ij} E_{ij} \quad 4.28$$

$$D_{ij} = \langle A, E_{ij} \rangle$$

Görüntü karşı kovaryans matrisinin kullanılması ile geliştirilen tanıma algoritması için geliştirilmiş olan pseudocode aşağıdaki gibidir :

```

%Verilenler:
%C adet sınıf için toplam M adet yüz görüntüsü
%Her sınıf için mxn boyutlu l adet eğitim yüz görüntü matrisi  $A_i^c$ 
%Kimliği belirlenmek istenen mxn boyutlu test yüz görüntü matrisi  $A_t$ 
%d: İzdüşüm için seçilen özdeğer sayısı
T=1
%Özellik çıkartımı:
Eğitim kümesindeki ortalama görüntü matrisi Eğitim görüntülerinden çıkartılarak Eşitlik 4.20'de
olduğu gibi ortalama uzaklaştırılmış yüz matrisleri bulunur
Eşitlik 4.22'de olduğu gibi görüntü karşı-kovaryans matrisi hesaplanır
For c=1: C
    For k=1: d
        Görüntü karşı kovaryans matrisinin TDA uygulamasından elde edilen izdüşüm vektörleri
        kullanılarak Eşitlik 4.25'deki gibi özellik vektörleri elde edilir
    End
    % Test Prosedürü
     $A^{test}$  görüntüsü için özellik vektörleri Eşitlik 4.25 kullanılarak elde edilir
    Test özellik vektörleri ile o sınıfa ait özellik vektörleri arasındaki öklid uzaklıkları hesaplanır
    Eşitlik 4.26'yı kullanarak hesapla
    Bulunan uzaklığı T=1 indisi ile sakla
    T'yi 1 arttır
End
%Sınıflandırma Sonucu:
Saklanan öklid uzaklıklarından en küçük olanı bul

```

*Test görüntüsü o sınıfa aittir şeklinde sınıflandır*

*%Görüntü matrisinin yeniden elde edilmesi:*

*Görüntü karşı kovaryans matrisinin TDA uygulamasından elde edilen izdüşüm vektörlerinin dış çarpımlarından elde edilen özgörüntüleri kullanarak Eşitlik 4.27'deki gibi yüz görüntüleri yeniden elde edilir*

Bu bölümde geliştirilen algoritmanın tanıma performansını değerlendirmek için hem Ar-Face hem de ORL veritabanı üzerinde oluşturulmuş veritabanları kullanılmıştır. Ar-Face veritabanı kullanılarak yapılan çalışmada görüntüler ile çalışılmadan önce görüntüler 50x40 piksel boyutunda olacak şekilde kırılmıştır. Yapılan çalışmalarda bu veritabanından yararlanılarak dört farklı veritabanı oluşturulmuştur:

Birinci deneysel çalışmada; her sınıf için sadece tek bir görüntü varken sunulan yöntemin performansı denenmiştir. Bunun için her sınıftan (A) görüntüsü (normal yüz ifadesi) eğitim kümesi içinde yer almış (B)-(G) görüntüleri ise test kümesi olarak kullanılmıştır (Bkz. Şekil 4.1).

İkinci deneysel çalışmada görüntüler arasında ifade farklılıkları varken yöntemin performansını değerlendirmek için yapılmıştır. Bunun için her sınıftan (B)-(D) görüntüleri eğitim kümesi olarak kullanılırken (O)-(Q) görüntüleri test kümesi olarak kullanılmıştır (Bkz. Şekil 4.1).

Üçüncü deneysel çalışmada görüntüler arasında aydınlatma farklılıkları varken yöntemin performansının değerlendirilmesini amaçlamıştır. Bunun için her sınıftan (A) ve (N) görüntüleri eğitim kümesi için kullanılırken (E)-(G) ve (R)-(T) görüntüleri test kümesi olarak kullanılmıştır (Bkz. Şekil 4.1).

Dördüncü deneysel çalışmada ise çekilen görüntüler arasında zaman farkı varken yöntemin performansının değerlendirilmesi için yapılmıştır. Bunun için her sınıftan (A)-(G) görüntüleri eğitim kümesi olarak kullanılırken (N)-(Q) görüntüleri test kümesi olarak kullanılmıştır. Karşılaştırma amaçlı olarak oluşturulan veritabanları ABA ve 2BABA gibi bilinen yöntemler için de uygulanmıştır (Bkz. Şekil 4.1).

Çizelge 4. 6'da ilk iki deneye ait en yüksek tanıma doğrulukları, Çizelge 4.7'de ise 3. ve 4. deneylere ait en yüksek tanıma doğrulukları verilmiştir. Tanıma oranlarının yanındaki parantez içindeki rakamlar en yüksek tanıma oranının elde edildiği özvektör sayısını göstermektedir.

Sunulan yöntemin sonuçları analiz edilecek olursa Ar-Face veritabanı üzerinde gerçekleştirilmiş dört uygulamada da en yüksek tanıma doğruluklarının bu bölümde

sunulan yöntem ile elde edildiği görülmektedir. Birinci uygulamada sınıf başına sadece bir normal yüz görüntüsü ile eğitilmiş olan sistem yüz ifade farklılıkları ve aydınlatma farklılıkları olan görüntüler ile test edilmiştir. İkinci uygulamada sadece yüz ifade farklılıklarının olduğu görüntüler eğitim test küesi olarak kullanılmıştır. Sadece ifade farklılıkları varken 2BABA ile sunulan yöntemin tanıma performansı arasındaki fark birinci uygulamadaki farktan daha düşüktür. Dolayısıyla aralarında aydınlatma farkı olan görüntüler kullanıldığında sunulan yöntemin tanıma performansının 2BABA yöntemine göre çok daha iyi olduğu söylenebilir. Üçüncü uygulamada birinci uygulamada olduğu gibi yine aralarında aydınlatma farkı olan görüntüler üzerinde çalışılmıştır. Ancak üçüncü uygulamada eğitimde kullanılan görüntü sayısı arttırılmıştır. Bu durumda 2BABA ile sunulan yöntem arasındaki tanıma performansı birinci uygulamaya göre çok daha fazla artış göstermiştir. Dördüncü uygulamada ise Şekil 4.1 (a)'daki görüntüler eğitim için Şekil 4.1 (b)'deki görüntüler test için kullanılmıştır. Yani eğitimde kullanılan görüntü sayısı en fazla dördüncü uygulamadadır. Bu durumda diğer üç uygulamaya göre en yüksek tanıma doğrulukları elde edilmiştir.

**Çizelge 4.6 Ar-Face veritabanında 1. ve 2. deneysel çalışmalar için elde edilen tanıma oranları**

	1. deney (%)	2. deney (%)
ABA	84.68 (24)	77.47 (26)
2BABA	87.39 (4)	79.72 (5)
Sunulan yöntem	91.89 (2)	81.53 (2)

**Çizelge 4.7 Ar-Face veritabanında 3. ve 4. deneysel çalışmalar için elde edilen tanıma oranları**

	3. deney (%)	4. deney (%)
ABA	79.28 (61)	57.91 (32)
2BABA	58.55 (39)	52.90 (16)
Sunulan Yöntem	81.98 (31)	61 (13)

ORL veritabanı kullanılarak yapılan çalışmada tüm görüntüler gri seviyeli ve 112x92 piksel boyutundadır. ORL veritabanı kullanılarak (Bkz. Şekil 4.2) yapılan deneysel çalışmada eğitim kümesindeki görüntü sayılarının giderek arttırılmış ve sınıf başına eğitim kümesinde kullanılan görüntü sayısının arttırılması ile yöntemin performansının ne şekilde değiştiği araştırılmıştır. Bunun için sırasıyla eğitim kümesinde sınıf başına ilk 1. görüntü, ilk 5 görüntü ve son olarak da ilk 9 görüntünün kullanıldığı üç farklı deneysel çalışma yapılmıştır. Her çalışmada geriye kalan görüntüler test görüntüsü olarak kullanılmıştır. Her üç deneysel çalışma için elde edilen en yüksek tanıma doğrulukları Çizelge 4. 8'de verildiği gibidir. Sunulan yöntemin performansını karşılaştırmak amacı ile aynı veritabanları 2BABA yöntemi için de denenmiştir. Tanıma oranlarının yanındaki parantez içindeki rakamlar en yüksek tanıma oranının elde edildiği özvektör sayısını göstermektedir.

**Çizelge 4.8 ORL veritabanında yapılan deneysel çalışmalar için elde edilen tanıma oranları**

Metodlar	1. Sonuçlar (%)	2. Sonuçlar (%)	3. Sonuçlar (%)
2BABA	73.05 (2)	85 (15)	90 (5)
Sunulan Yöntem	74.72 (6)	85.5 (11)	95 (25)

## BÖLÜM 5

### SONUÇ VE ÖNERİLER

Bu tez çalışmasında iki boyutlu yüz görüntüleri için geliştirilmiş iki boyutlu tanıma yapan dört yeni algoritma sunulmuştur. Çalışmalarda temel alınan yaklaşım görünüm tabanlı altuzay yaklaşımıdır. Geliştirilen bu algoritmalarda özellik çıkartımı için 2BABA ve Gram-Schmidt Ortogonalleştirme prosedürü kullanılmıştır. Algoritmaların sınıflandırma aşamasında en yakın komşu sınıflandırıcısı kullanılmıştır.

Tanımaya iki boyutlu, üç boyutlu görüntü ile ya da bir sıcaklık şablonu kullanılarak yapılabilir. Ancak yapılan araştırmalar düşük maliyet ve mevcut olan veritabanları ile kolay uyuşabilirlik gibi sebeplerden dolayı tanımada iki boyutlu görüntü kullanımının yaygınlaştığını göstermektedir. İki boyutlu yüz görüntüleri kullanılarak tanıma yapıldığında karşılaşılan en büyük problem küçük örnek boyutu problemidir. Bunun sebebi ise iki boyutlu yüz matrislerinin bir boyutlu vektörlere dönüştürülmesi sonucu yüz görüntüsü boyutunun çok fazla büyüyor olmasıdır. Yüz matrisinin yüz vektörüne dönüştürülmesi matris satırlarının alt alta getirilmesi ya da matris sütunlarının alt alta getirilmesi şeklinde iki yolla yapılabilir. Hangi yolla yapılırsa yapılsın elde edilen yüz vektörünün boyutu çok büyümektedir, örneğin; 50x40 boyutundaki bir yüz görüntü matrisi dönüşüm sonucunda 2000x1 boyutlu bir vektörle temsil edilebilmektedir.

Teorik olarak tanıma işleminde her sınıf için eğitim aşamasında kullanılan görüntü sayısı, görüntü vektör boyutunun en az 10 katı kadar olmalıdır. Bu da bir kişiyi fotoğrafına bakarak tanıyabilmek için eğitim aşamasında o kişinin çok sayıda fotoğrafına ihtiyaç duyulduğunu göstermektedir. Bu problem görünüm tabanlı bu metodlarda boyut indirgenmesi gerekliliğini ortaya koymaktadır. Görünüm tabanlı metodlarda boyut indirgenmesi için altuzay yöntemleri kullanılır. Bu tez çalışmasında da özellik çıkartımı için kullanılan yaklaşımlar altuzay yöntemlerindedir. Altuzay yöntemlerinde, büyük boyutlu yüz görüntü vektörü daha düşük boyutlu bir özellik altuzayında temsil edilmekte ve orjinal görüntüye göre daha düşük boyutlu bu temsili görüntü tanımada kullanılmaktadır.

Ancak yüz görüntü matrisinin vektöre dönüştürülmesinin bazı sakıncaları vardır. Bunlardan birincisi vektöre dönüşüm ile orjinal veride var olan piksel komşuluklarının kaybolmasıdır. Böylece orjinal görüntü uzayında bulunan bilginin bir kısmı kaybedilmiş olacaktır. Bu sakıncalardan ikincisi altuzaya izdüşüm için kullanılacak olan vektörleri (özvektörleri) belirlemek için gerekli zamanın uzun olması ve işlem karmaşıklığının artmasıdır. Üçüncü olarak ise kullanılan yöntemle göre küçük örnek boyutu problemi ile karşılaşma olasılığıdır. Bahsedilen bu sakıncalardan dolayı son birkaç yıldır yüz görüntülerinin tanınması için yüz görüntü matrislerini yüz vektörüne dönüştürmeden tanıma yapan iki boyutlu tanıma algoritmaları geliştirilmeye başlanmıştır.

Bu tez çalışmasında geliştirilen iki boyutlu yüz tanıma algoritmalarından ilki Ortak Matris Yaklaşımı ile yüz tanımadır (Bölüm 4.4.1). Bu çalışma daha önceleri bir boyutlu vektör verilerinin tanınması için kullanılmış olan ortak vektör yaklaşımının iki boyutlu görüntü matrisleri için geliştirilmesi şeklinde düşünülebilir. Ortak matris yaklaşımında yüz görüntülerinin tanınması, her sınıfa ait ve o sınıf için değişmez ve tek olan ortak matrisin hesaplanması ile yapılır. Bir sınıf için ortak matris iki şekilde hesaplanabilir. Bunlardan birincisi; bir sınıftaki farklı görüntüler arasındaki farkların Gram-Schmidt Ortogonalleştirme prosedürü ile uzaklaştırılması yolu ile ikincisi de sınıf içi dağılım matrisinin kullanılması şeklindedir. Her iki yolda da aslında bir sınıftaki görüntüler arasındaki farklar, oluşturulan altuzayda en aza indirgenerek sınıf içi dağılımların en küçüklenmesi yönünde bir çalışma yapılmaktadır. Ar-Face veritabanı üzerinde yapılan deneysel çalışmalarda iki farklı veritabanı kullanılarak geliştirilen yöntemin tanıma performansı incelenmiştir. Bu iki veritabanı arasındaki fark her sınıf için eğitimde kullanılan görüntü sayıları arasındaki farktan kaynaklanmaktadır. Elde edilen deneysel çalışmalar eğitimde kullanılan görüntü sayısı arttıkça tanıma oranlarının da arttığını görülmektedir.

Ortak matris yaklaşımı ile yüz tanıma yöntemi, yüz tanımadaki küçük örnek boyutu problemi ve boyut probleminde çözüm getirilmiştir. Bu yöntem ile elde edilen ve bir sınıfı özellik altuzayında tanımlayan özellik matrisi olan ortak matris orjinal yüz görüntü matrisi ile aynı boyuttadır. Ancak bu yöntemde sadece sınıf içindeki yüz görüntüleri arasındaki farklar uzaklaştırılırken sınıflar arası yüz görüntüleri arasındaki farklar arttırılmamıştır. Bu çalışmadan sonra geliştirilen algoritmalar ile sınıfları

tanımlayacak olan özellik matrisinin boyutunun orjinal yüz görüntüsüne göre daha küçültülmesi ve sınıflar arası uzaklıkları arttırırken sınıflandırma doğruluğunu arttırmak için sınıf içi görüntü farklarının da azaltılması amaçlanmıştır.

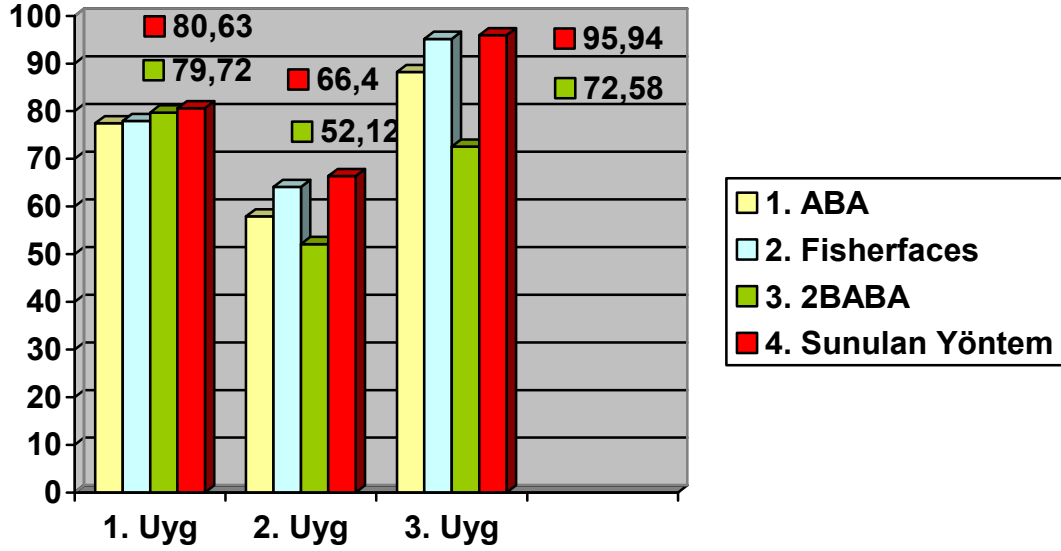
ABA'nde özuzay olarak adlandırılan özellik altuzayında büyük boyutlu yüz vektörü en az karesel hata ile en iyi şekilde temsil edilmektedir. Bu yöntemde yüz görüntü vektörlerinin özuzaya izdüşümü için kullanılacak olan izdüşüm eksenleri yüz görüntü sınıfları arasındaki dağılımı en büyükleyecek şekilde seçilmiş eksenlerdir. Bu eksenler kullanılarak görüntülerin özuzaya izdüşümü alındığında yüz görüntü sınıfları birbirinden uzaklaştırılmaktadır. Yüz görüntüleri elde edilen bu izdüşüm eksenler kullanılarak en az karesel hata ile temsil edilebilmektedir. Ancak sınıf başına birden fazla görüntü kullanıldığı durumlarda sınıf içi yüz vektörleri arasındaki mesafeler bu özuzayda azaltılmadığından ABA yöntemi sınıflandırma problemlerinde çok iyi sonuçlar vermez. Bu yöntem sınıflandırmadan çok görüntü temsili için iyi bir yöntemdir.

Yüz görüntü matrisinin her bir satırını bir nesne olarak kabul edip satır vektörleri üzerinde ABA'ni uygulayan ve bölgesel ABA olarak ortaya çıkan 2BABA yöntemi de ABA yöntemi gibi oluşturulan özuzayda yüz görüntü sınıflarını birbirinden uzaklaştırırken sınıf içindeki yüz görüntülerini birbirine yaklaştırmayan bir yöntemdir. O nednele iki boyutlu yüz görüntülerinin tanınması için iki boyutlu tanıma gerçekleştiren bu yöntem de sınıflandırmadan çok görüntülerin iyi bir şekilde temsilini vermektedir. Bir sınıfı temsil eden ve tanımda kullanılan özellik matrisinin boyutunun düşürülmesi için bu tez çalışmasında geliştirilmiş olan ikinci algoritma yüz tanıma için geliştirilmiş 2 aşamalı bir algoritmadır: 2BABA ve sınıf-içi dağılım minimizasyonudur (Bölüm 4.4.2). Bu çalışmada özellik çıkartımı için temel alınan yöntem 2BABA yöntemidir. Sunulan bu yöntemde 2BABA yöntemine göre daha iyi bir sınıflandırma doğruluğu elde edebilmek için özellik altuzayına izdüşürülmüş yüz görüntüleri arasındaki uzaklıklar arttırılırken 2BABA'nde yapılmamış olan sınıf içindeki yüz görüntüleri arasındaki mesafeler de azaltılmıştır. Geliştirilen bu algoritma ile aynı zamanda ortak matris yaklaşımında elde edilen ve bir sınıfı tanımlayan özellik matrisinin (ortak matris) de boyutu küçültülebilmektedir. Ar-Face veritabanı üzerinde yapılan deneysel çalışmalar da bu teorik bulguları desteklemiş ve 2BABA'ne göre çok daha iyi tanıma oranları elde edilebilmiştir. Deneysel çalışmalarda Ar-Face



veritabanından oluşturulan üç farklı veritabanı üzerinde çalışılmıştır. Bu veritabanları arasında hem görüntü sayıları arasında hem de aydınlatma ve yüz ifadeleri arasında farklar bulunmaktadır. Her sınıfta sınıf başına sadece bir görüntü olduğu durumda sistem kişilerin normal yüz görüntüleri ile eğitilmiş ve sadece ifade farklılıkları olan görüntüler ile de test edilmiştir. Deneysel çalışmalar bu veritabanı için sunulan yöntemin 2BABA'ne göre daha iyi tanıma performansı sağladığını ancak arada %1.11'lik bir farkın olduğunu göstermiştir. Eğitim kümesine her sınıf için aralarında aydınlatma farkının olduğu görüntüler alındığında hem 2BABA hem de sunulan yöntemin tanıma performansında bir önceki veritabanına göre bir düşüşün olduğu görülmüştür. Ancak burada dikkat çeken durum aralarında aydınlatma farkı olan görüntüler kullanıldığı durumda sunulan yöntemin tanıma performansının 2BABA'nin tanıma performansından %14.28 kadar daha iyi olduğudur. Bu deneysel bulgular sunulan yöntemin değişen aydınlatma koşullarına olan duyarlılığının 2BABA yöntemine göre çok daha düşük olduğunu bu nedenle de sunulan yöntemin 2BABA'ne göre çok daha doğru sonuç verdiğini göstermektedir. Bu algoritma için gerçekleştirilen üçüncü deneyde oluşturulan veritabanında ise ikinci deneydeki veritabanına göre sadece eğitimdeki görüntü sayısı arttırılmıştır. Bu artış da tanıma oranlarını hem 2BABA için hem de sunulan yöntem için ilk iki deneye göre çok arttırmıştır. Bir ikinci ve önemli sonuç da sunulan yöntem ile 2BABA yönteminin tanıma performansları arasındaki farkın eğitimde kullanılan görüntü sayısı ile doğru orantılı olarak artmış olmasıdır. Bu sonuçlara göre sunulan yöntem 2BABA yöntemine göre %23.36'lık bir farkla daha doğru tanıma yapılmasını sağlamıştır. Burada da bir kez daha eğitimde kullanılan görüntü sayısı arttıkça tanıma oranlarının da arttığı görülmektedir. Sunulan yöntemin çok bilinen ABA ve fisherfaces yöntemleri ile de karşılaştırması yapılmıştır. Bu sonuçlara göre 2BABA yöntemi eğitimde sınıf başına iki görüntü kullanılarak uygulandığında ABA ve fisherfaces yöntemlerine göre daha iyi sonuçlar vermektedir. Ancak eğitim görüntülerinin sayısı arttıkça 2BABA yönteminin tanıma performansı ABA ve fisherfaces yöntemlerine göre daha da düşmektedir. Oysa sunulan yöntemin performansı her üç veritabanı için de ABA ve fisherfaces yöntemlerine göre çok daha iyi sonuçlar vermiştir. Bölüm 4.4.2'de sunulan algoritmanın deneysel çalışma sonuçları Çizelge 5.1'de verilmiştir.

**Çizelge 5.1 Bölüm 4.4.2'de sunulan algoritmanın bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları**



Sunulan bu ikinci yöntemde yüz görüntüleri için elde edilen özellikler birer vektörken ABA'nde elde edilen özellikler birer skalardır. Bu da 2BABA'nde olduğu gibi ABA'ne göre özelliklerin saklanması için daha fazla hafıza gerektiğini göstermektedir. Bu hafıza problemine çözüm olarak tez çalışmasında üçüncü bir algoritma geliştirilmiştir.

Tez çalışmasında geliştirilen üçüncü algoritmada özellik çıkartımı için yine 2BABA yöntemi temel alınmıştır. Burada iki farklı altuzay hesaplanmıştır. Bu altuzaylardan bir tanesi yüz görüntü matrisinin sütunları arasındaki değişim yönlerini gösteren bir altuzay ikincisi de satırları arasındaki değişimleri gösteren bir altuzaydır. Bu uzaylardan ilki yüz görüntü matrisleri için özellik çıkarmak amacı ile kullanılırken ikinci altuzayda ise boyut indirgenmesi yapılmıştır. Boyut indirgenmesi işlemi literatürde bulunan yöntemlerdeki gibi özellik altuzayından değilde orijinal yüz görüntü uzayından yararlanarak yapılmış böylece olabilecek veri kayıplarının önüne geçilmiştir. Geliştirilen yöntemle bir sınıfı temsil etmek için kullanılan özellik matrisinin boyutları orijinal yüz görüntü matrisine göre çok fazla küçültülebilmektedir.

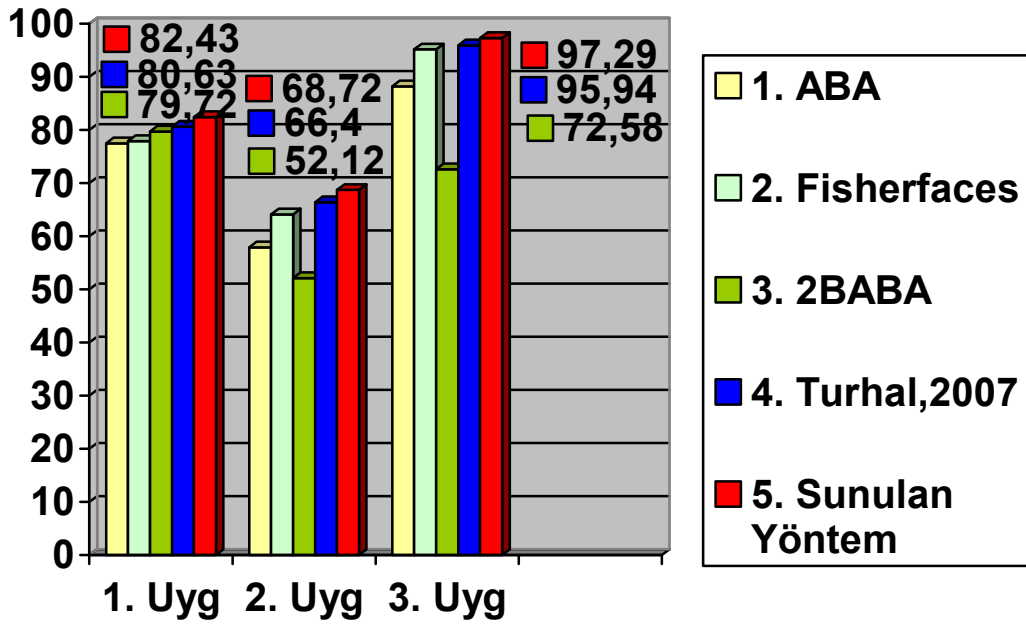
Üçüncü algoritmanın tanıma performansı Ar-Face ve ORL veritabanları kullanılarak incelenmiştir. Ar-Face veritabanı üzerinde yapılan çalışmalarda bir önceki

yöntemde oluşturulan veritabanları üzerinde çalışılmıştır. Buna göre ilk olarak her sınıftan sadece normal yüz ifadesine karşılık gelen ikişer görüntü alınarak sistem eğitilmiş ve sabit aydınlatma koşulları altında değişen yüz ifadelerinden oluşan görüntüler ile test edilmiştir. Buna göre sunulan yöntem için 2BABA'ne göre %2.71 oranında bir farkla daha fazla tanıma oranı elde edilmiştir. Bu çalışmanın sonuçları bir önce sunulan algoritma ile de karşılaştırılmış ve bu çalışmanın sonuçları %1.80 oranında daha iyileştirilmiştir. İkinci olarak ilk bölümden seçilen aydınlatma farkı ve yüz ifade farkları içeren sınıf başına 7 görüntü kullanılarak sistem eğitilmiştir. Test için de ikinci bölümdeki görüntüler seçilmiş ve yöntemin görüntüler arasındaki zaman farkına olan duyarlılığı test edilmiştir. Bu veritabanı ile 2BABA ve sunulan yöntem karşılaştırıldığında sunulan yöntem %16.60 oranında daha yüksek tanıma elde edilmiştir. Bu sonuca göre sunulan yöntemin görüntüler arasındaki aydınlatma farklarına daha az duyarlı olduğu sonucunu vermiştir. Oluşturulan üçüncü veritabanı ile eğitimde her sınıf için her iki bölümdeki bütün görümler üzerinde birini dışarıda bırakma yöntemi uygulanmıştır. Bu veritabanının diğerlerinden farkı kullanılan görüntü sayısının daha fazla olmasıdır. Bu çalışma sonucunda da sunulan yöntemin tanıma oranı 2BABA'ne göre %24.71 oranında daha yüksek çıkmıştır. Eğitimde kullanılan görüntü sayısı arttıkça sunulan yöntemin tanıma performansı da artmaktadır. Sunulan yöntemin çok bilinen ABA ve fisherfaces yöntemleri ile de karşılaştırması yapılmıştır. Bu sonuçlara göre 2BABA yöntemi eğitimde sınıf başına iki görüntü kullanılarak uygulandığında ABA ve fisherfaces yöntemlerine göre daha iyi sonuçlar vermektedir. Ancak eğitim görüntülerinin sayısı arttıkça 2BABA yönteminin tanıma performansı ABA ve fisherfaces yöntemlerine göre daha da düşmektedir. Oysa sunulan yöntemin performansı her üç veritabanı için de ABA ve fisherfaces yöntemlerine göre çok daha iyi sonuçlar vermiştir. Bölüm 4.4.3'de sunulan algoritmanın Ar-Face veritabanı üzerinde yapılan deneysel çalışma sonuçları Çizelge 5.2'de verilmiştir.


Sunulan bu yöntem ORL veritabanı kullanılarak oluşturulmuş iki farklı veritabanı için de uygulanmıştır. Oluşturulan veritabanları arasında eğitimde kullanılan görüntü sayıları arasında fark bulunmaktadır. Elde edilen deneysel sonuçlar eğitimdeki görüntü sayısı arttıkça tanıma performanslarının da arttığını göstermektedir. Her iki veritabanı içinde sunulan yöntemin performansı 2BABA yöntemi ile karşılaştırılmış ve bu sonuçlara göre eğitimde sınıf başına beş görüntü kullanıldığında sunulan yöntem

performansının 2BABA yöntemine göre %5 oranında eğitimde sınıf başına 9 görüntü kullanıldığında ise %3.67 oranında daha yüksek olduğunu göstermiştir. Bölüm 4.4.3'de sunulan algoritmanın ORL veritabanı üzerinde yapılan deneysel çalışma sonuçları Çizelge 5.3'de verilmiştir.

Çizelge 5.2 Bölüm 4.4.3'de sunulan algoritmanın bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları



Çizelge 5.3 Bölüm 4.4.3'de sunulan algoritmanın bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları




Literatürde bulunan iki boyutlu tanıma yapan algortimaların bir kısmında yüz matrisinin sadece satır vektörleri arasındaki değişimlerden yararlanılarak ya da hem satır vektörleri hem de sütun vektörleri arasındaki değişimlerden yararlanarak tanıma işlemi gerçekleştirilmektedir. Bu çalışmalarda yüz matrisinin sütun vektörleri ile satır vektörleri arasındaki değişimler hiç hesaba katılmamıştır. Tez çalışmasında sunulan en son tanıma yöntemi ile daha önce çalışılmamış olan yüz matrisinin satır vektörleri ile sütun vektörleri arasındaki değişimlerden yararlanarak tanıma yapan yeni bir algoritma sunulmuştur.

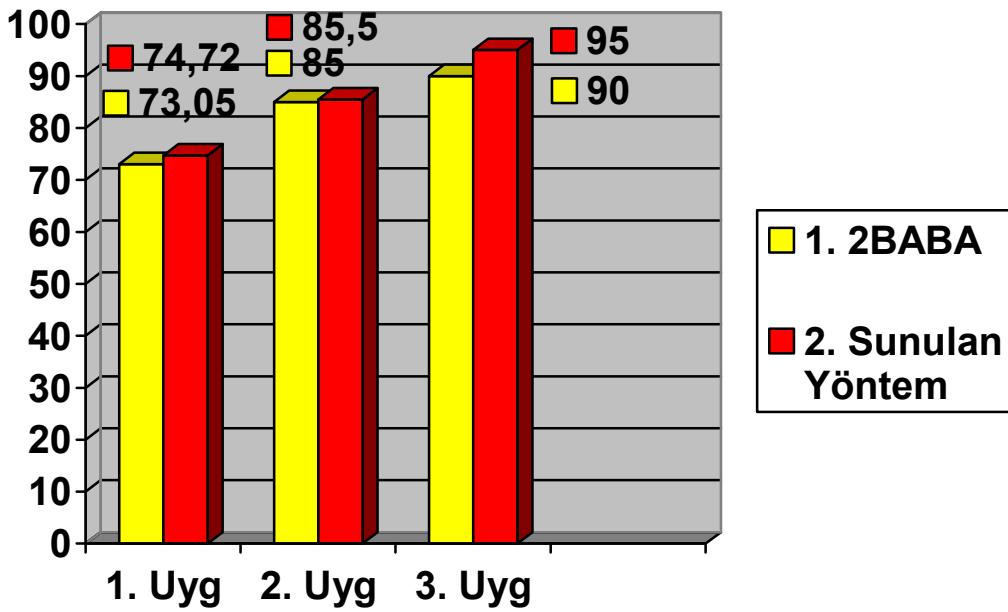
Bu algoritmanın tanıma performansı Ar-Face ve ORL veritabanları kullanılarak test edilmiş ve karşılaştırma amacı ile hazırlanan veritabanları ABA ve 2BABA yöntemleri için de denenmiştir. İlk deneysel çalışmada eğitim kümesinde sınıf başına sadece normal görünüm olan bir örnek kullanılmıştır. Buna göre sunulan yöntem 2BABA yöntemine göre daha düşük sayıda özvektör kullanılarak %4.50 oranında daha iyi tanıma oranı elde edilmiştir. İkinci deneysel çalışmada görüntüler arasındaki zaman farkının tanıma performansına etkisi incelenmiştir. Bu çalışmanın sonucunda da sunulan yöntem 2BABA yöntemine göre daha düşük özvektör sayısında %1.81 oranında daha iyi tanıma oranı elde edilmiştir. Üçüncü çalışmada sistem her sınıftaki normal olan ikişer görüntü ile eğitilmiş ve ifade farkı olan görüntülerle test edilmiştir. Buna göre sunulan yöntemde 2BABA yöntemine göre %23.43 oranında daha iyi tanıma oranında daha iyi tanıma doğrulukları elde edilmiştir. Dördüncü test çalışmasında ise eğitimde kullanılan görüntü sayısı artırılmış ve sonuç olarak yine sunulan yöntem %8.1 oranında daha iyi tanıma gerçekleştirmiştir. Bölüm 4.4.4'de sunulan algoritmanın Ar-Face veritabanı üzerinde yapılan deneysel çalışma sonuçları Çizelge 5.4'de verilmiştir.

ORL veritabanı üzerinde de üç farklı deneysel çalışma yapılmıştır. Bu çalışmalarda eğitimde kullanılan görüntü sayıları değiştirilerek kullanılan görüntü sayısının tanıma performansına etkisi incelenmiştir. Çalışmalarda önce her sınıf için tek görüntü sonra beşer görüntü sonra da dokuzar görüntü kullanılarak yöntem performansları incelenmiştir. Elde edilen deneysel çalışma sonuçlarına göre sunulan yöntem her üç durumda da 2BABA yöntemine göre daha iyi tanıma oranları vermiştir. Bölüm 4.4.4'de sunulan algoritmanın ORL veritabanı üzerinde yapılan deneysel çalışma sonuçları Çizelge 5.5'de verilmiştir.

Çizelge 5.4 Bölüm 4.4.4'de sunulan algoritmanın Ar-Face veritabanı üzerinde bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları



Çizelge 5.5 Bölüm 4.4.4'de sunulan algoritmanın ORL veritabanı üzerinde bilinen yöntemlerle karşılaştırmalı deneysel çalışma sonuçları



Bundan sonra yapılacak alıřmalarda sunulan algoritmaların aydınlatma, yüz ifade farklılıkları ve kullanılan görüntü sayılarına olan duyarlılıkları daha farklı veritabanları üzerinde de denenerek sunulan yöntemlerin performansları daha ayrıntılı olarak incelenecektir.

## KAYNAKLAR DİZİNİ

- Belhumeur, P., Hespanha, J. and Kreigman, D. J., 1997 a, Discriminant eigenfeatures for image retrieval, PAMI, 19 (7), 711-720.
- Belhumeur, P.N., Hespanha, J. P. and Kreigman, D. J., 1997 b, Eigenfaces vs. fisherfaces: Recognition using class specific linear projection, IEEE Trans. Pattern Analysis and Machine Intelligence, 19 (7).
- Bogaziçi University Computer Engineering Department, PILAB, Perceptual Intelligence Laboratory.
- Campadelli, P., Lanzarotti, R. and Savazzi, C., 2003, A feature-based face recognition system, Proceedings of the 12<sup>th</sup> International Conference on Image Analysis and Processing (ICIAP'03).
- Chellappa, R., Wilson, C. L. and Sirohey, S., 1995, Human and machine recognition of faces: A survey, Proceedings of the IEEE, 83, 705-740.
- Chen, L. F., Liao, H. Y. M., Ko, M. T., Lin, J. C. and Yu, G. J., 2000, A new LDA-based face recognition system which can solve the small sample size problem, Pattern Recognition, 33, 1713-1726.
- Comon, P., 1994, Independent component analysis- a new concept?, Signal Processing, 36, 287-314.
- Cottrell, G. W. and Fleming, M. K., 1990, Face recognition using unsupervised feature extraction, Proc. Int'l Neural Network Conf., 322-325.
- Cox, I. J., Ghosn, J. and Yianilos, P. N., 1996, Feature based face recognition using mixture distance, In Proceedings, IEEE Conference on Computer Vision and Pattern Recognition, 209-216
- Face Recognition Home Page, [www.face-rec.org](http://www.face-rec.org).



### KAYNAKLAR DİZİNİ (devam ediyor)

- FG1, 1995, Proceedings of International Workshop on Automatic Face and Gesture Recognition, Multimedia Lab., Department of Computer Science, University of Zurich, Zurich, Switzerland.
- FG2, 1998, Proc. 2<sup>nd</sup> International Conference on Automatic Face and Gesture Recognition, IEEE Computer Society Press, Los Alamitos, CA.
- FG3, 1998, Proceedings 3<sup>rd</sup> International Conference on Automatic Face and Gesture Recognition, IEEE Computer Society Press, Los, Alamitos, CA.
- Goldstein, A. J., Harmon, L. D. and Lesk A. B., 1971, Identificatio of human faces, Proc. IEEE, 59, 748 s.
- Gonzalez, R. C., 1987, Digital Image Processing, Second Edition.
- Grudin,, M. A., 2000, On international representations in face recognition systems, Pattern Recognition, 33 (7), 1161-1177.
- Gülmezoğlu, M. B., Dzhafarov, V., Keskin, M., Künkçü, Ş. E. ve Barkana A., 1997, Ayrık kelime tanımada yeni bir yaklaşım, 5. Sinyal İşleme ve Uygulama Kurultayı, 461 s.
- Gülmezoğlu, M. B., Dzhafarov, V., Keskin, M. and Barkana A., 1999, A novel approach to isolated word recognition, IEEE Transactions on Speech and Audio Processing.
- Hjelmas, E. and Wroldsen, J., 1999, Recognizing faces from the eyes only, Proceedings of the 11<sup>th</sup> Scandinavian Conference on Image Analysis.
- Horn, R. and Johson, C., 1985, Matrix analysis, New York Cambridge University Press. İnce, F., 1986, Uzaktan algılamada sayısal görüntü işleme, TÜBİTAK Elektronik Araştırma Ünitesi Ünite İçi Rapor, Gebze.
- İstanbul Emniyet Müdürlüğü, 2005, Kent Bilgi ve Güvenlik Sistemi (MOBESE), [www.iem.gov.tr](http://www.iem.gov.tr).

**KAYNAKLAR DİZİNİ (devam ediyor)**

- Jain, A. K. and Chandrasekaran, B., 1982, Dimensionality and sample size considerations in pattern recognition practice, In Handbook of Statistics, Krishnaiah and Kanal, L. N., Eds., 2, 835-855.
- Jain, A. K., 1988, Fundamentals of dijital image processing, Prentice Hall Information and System Science Series.
- Jing, X. Y., Zhang, D. and Yao, Y. F., 2003, Improvements on the linear discrimination technique with application to face recognition, Pattern Recognition Letters, 24, 2695-2701.
- Kanade, T., 1977 Computer Recognition of human faces, Interdisciplinary System Research 47.
- Kaptanoğlu, C., Yüz tanıma, 2003, [http://dergi.tbd.org.tr/yazarlar/09062003/cuneyt\\_kaptanoğlu.htm](http://dergi.tbd.org.tr/yazarlar/09062003/cuneyt_kaptanoğlu.htm)
- Kaya, Y. and Kobayashi, K., 1972, A basic study on human face recognition, Frontiers of Pattern Recognition, 265-289.
- Kim,, K. I., Franz, M. O. and Schölkopf, B., 2005, Iterative kernel principal component analysis for image modelling, IEEE Transactions on Pattern Analysis and Machine Intelligence, 27 (9).
- Kirby, M. and Sirovich, L., 1990, Application of the Karhunen- Loeve procedure for the characterization of human faces, IEEE Trans. PAMI, 12 (11), 103-108.
- Kirby, M., 2000, Dimensionally of reduction and pattern analysis: An empirical approach, Under Contract with Wiley.
- Li, J., Zhou, S., Shekhar, C., 2003, A comparision of subspace analysis for face recognition, ICASSP.
- Liu, C., Wechsler, H., 2000, Evaluationary pursuit and its application to face recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence.

**KAYNAKLAR DİZİNİ (devam ediyor)**

- Liu, J., Chen, S., 2006, Non- iterative generalized low rank approximation of matrices, *Pattern Recognition Letters*, 27 (9), 1002-1008.
- Lu, J., Plataniotis, K. N. and Venetsanopoulos, A. N., 2003, Regularized discriminant analysis for the small sample size problem in face recognition, *Pattern Recognition Letters*, 24, 3079-3087.
- Martinez, A. M. and Benavente, R., 1998, The AR face database, CVC Tech. Report # 24.
- Martinez, A. M., 1999, Face image retrievals using HMM's, *Proceeding of IEEE Computer Vision and Pattern Recognition*.
- Martinez, A. M., 2000, Recognition of partially occluded and/or imprecisely localized faces using a probabilistic approach, *Proceedings of IEEE Computer Vision and Pattern Recognition, CVPR*.
- Martinez, A. M., Kak, A. C., 2001, PCA versus LDA, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23.
- Matlab, 1994-2008, The Math Works, Inc.
- Mika, S., Rätsch, G., Wetson, J., Schölkopf, B., Müller, K. R., 1999, Fisher discriminant analysis with kernels, *IEEE Int. Workshop on Neural Networks for Signal Processing IX. Madison, WI, USA*, 41-48.
- Moon, H. and Phillips, J., 1998, analysis of PCA-based faced recognition algorithms, In Boyer, K. and Phillips, J., editors, *emperical Evolution Techniques In Computer Vision*, IEEE Computer Society Press, Los Alamitos, CA.
- Murase, H. and Nayar, S. K., 1995, Visual learning and recognition of 3-D objects from appearance, *International Journal of Computer Vision*, 14 (1), 5-24.
- NEC (Nippon Electronic Company), web sayfası, [www.nec.com](http://www.nec.com).

**KAYNAKLAR DİZİNİ (devam ediyor)**

- Noushath, S., Kumar, G. H., Shivakumara, P., A new hybrid approach for efficient face representation and recognition based on 2DPCA and IMLDA techniques, Proceedings of the International Conference on Cognition and Recognition.
- Öz, O., Gülmezoğlu, M. B., Dzhafarov, V. and Barkana A., 2000, The common vector approach in image recognition, Proceedings of the BRAIN- MACHINE Workshop, IFT; Metu, TÜBİTAK, 45-50.
- Penev, P. S. and Sirovich, L., 2000, The global dimensionality of face space, Proc. Fourth IEEE Int'l Conf. Automatic Face and Gesture Recognition, 264-270.
- Petland, A., 2000, Looking at people: Sensing for ubiquitous and wearable computing, IEEE Trans. Pattern Analysis and Machine Intelligence, 22 (1), 107-119.
- Rama, A., Tarres, F., 2005, P2CA: A new recognition scheme combining 2D and 3D information, IEEE International Conference on Image Processing, Genova Italy, September 11-14.
- Samal and Iyengar, P., 1992, Automatic recognition and analysis of human faces and facial expressions: A survey, Pattern Recognition, 25, 65-77.
- Schelkopf, B., Smola, A. and Müller, K., 1998, Nonlinear component analysis as a kernel eigenvalue problem, Neural Computation, 10, 1299-1319.
- Senior, A., October 2001, A combination fingerprint classifier, IEEE Transactions on Pattern Analysis and Machine Intelligence.
- Shannon, C. E., 1949, Communication in the presence of noise, Proc. Institute of Radio Engineers, 37 (1), 10-21. [Reprint as classic paper in: Proc. IEEE, Vol. 86, No. 2, \(Feb 1998\)](#)
- Sirovich, L. and Kirby, M., 1987, A low-dimensional procedure for the characterization of human faces, The Journal of the Optical Society of America, 4, 519-524.

**KAYNAKLAR DİZİNİ (devam ediyor)**

- Tan, X., Chen, S., Zhou, Z. H., Zhang, F., 2006, Face recognition from a single image per person: A survey, *Pattern Recognition* 39 (9), 1725-1745.
- Turhal, Ü. Ç., Gülmezoğlu, M. B., Barkana A., 2005, A face recognition algorithm using common matrix approach, *EUSIPCO*, Antalya, on September 4-8.
- Turhal, Ü. Ç., Duysak, A., Gülmezoğlu, M. B., 2007, A two stage algorithm for face recognition: 2DPCA and within-class scatter minimization, (554) *Signal Processing, Pattern Recognition and Applications*.
- Turk, M. and Petland, A., 1991 a, Eigenfaces for recognition, *Journal of Cognitive Neuroscience*, 3, 72-86.
- Turk, M. and Petland A., 1991 b, Face recognition using eigenfaces, In *Proc. IEEE Int. Conf. Acoust. Speech, Signal Processing*, 586-591.
- Valentin, D., abdi, H., O'Toole, A. J. and Cottrell, G. W., 1994, Connectionist models of face processing: A survey *pattern recognition*, 27 (9), 1209-1230.
- Xu, D., Yan, S., Zhang, L., Liu, Z. and Zhang, H., 2004, Coupled subspaces analysis, *Microsoft Research Technical Report, MSR-TR-2004-106*, Oct.
- Xu, D., Yan, S., Zhang, L., Li, M., ma, W., Liu, Z., Zhang, H., 2005 (a), Parallel image matrix compression for face recognition, 11<sup>th</sup> *International Multimedia Modelling Conference (MMM'05)*, 232-238.
- Xu, D., Yan, S., Zhang, L., Zhang, H-J., Liu, Z., Shum, H-Y., 2005 (b), Concurrent Subspaces Analysis, *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)* 2 (02)
- Yambor, W. S., 2000, Analysis of PCA-based and Fisher discriminant-based image recognition algorithms, *Colorado State University Computer Science Technical Report CS-00-103*.

**KAYNAKLAR DİZİNİ (devam ediyor)**

- Yang, J., Yang, J. Y. and Frangi, A. F., 2003, Combined fisherfaces framework, *Image and Vision Computing*, 21, 1037-1044.
- Yang, J., Davis, Z. Frangi A. F. and Yang, J. Y., 2004, Two-dimensional PCA: A new approach to appearance-based face representation and recognition, *Pattern Analysis and Machine Intelligence, IEEE Transactions*, 26 (1).
- Yang, J., Frangi, A. F., Yang, J. Y., Zhang, D., 2005, KPCA plus LDA: A complete kernel fisher discriminant framework for feature extraction and recognition, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27 (2).
- Yang, M., 2002, kernel eigenfaces v.s. kernel fisherfaces: Face recognition using kernel methods, *Proceedings of the fifth IEEE International Conference on Automatic Face and Gesture Recognition*.
- Ye, J., 2004, Generalized low rank approximation of matrices, *The Twenty- First International Conference on Machine Learning (ICML)*, 887-894.
- Yu, H. and Yang, J., 2001, a direct LDA algorithm for high-dimensional data-with application to face recognition, *Pattern Recognition*, 34, 2067-2070.
- Zhang, D., Chen, S., Liu, J., 2005, Representing image matrices: Eigenimages vs. eigenvectors, *Proceedings of the 2st International Symposium on Neural Networks (ISNN'05)*.
- Zhao, W., Chellappa, R., Krishnaswamy, A., 1998, Discriminant analysis of principal components for face recognition, 3<sup>rd</sup>. *International Conference on Face & Gesture Recognition*, 336 p.
- Zhao, W., Chellappa, R., Rosenfeld, A. and Phillips, P., 2000, A literature survey, *Technical Report*.

## ÖZGEÇMİŞ

1972 yılında Eskişehir’de doğdum. İlk ve orta öğretimimi Eskişehir’de tamamladıktan sonra 1989-1990 öğretim yılında İstanbul Teknik Üniversitesi Elektrik-Elektronik Fakültesi Elektronik ve Haberleşme Mühendisliği Bölümü’ne kayıt yaptırđım. 1992-1993 öğretim yılında iyi derece ile bölümümden mezun oldum. 1994 yılında Eskişehir Anadolu Üniversitesi Bilecik Meslek Yüksekokulu Haberleşme Programı’nda Öğretim Görevlisi olarak işe başladım. 1994 yılında Meslek Yüksekokullarının Dünya Bankası ile projesi kapsamında Amerika’nın Delaware Eyaleti’ndeki Dower şehrinde Delaware Technical Collage’da yedi ay süre ile eğitim aldım. 1999 yılında Osmangazi Üniversitesi Fen Bilimleri Enstitüsü’nde Elektronik Anabilim Dalı’nda yüksek lisans programına kayıt yaptım. Yüksek lisans programı bittikten sonra 2001 yılında aynı üniversitede doktora programına başladım. Halen Bilecik Üniversitesi Meslek Yüksekokulu Elektronik Haberleşme Programı Bölümü’nde Öğretim Görevlisi olarak çalışmaktayım.

**Ümit Çiğdem Turhal**