



BİLECİK ÜNİVERSİTESİ
Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı

**TEK GÖRÜNTÜ PROBLEMİNDE TEKİL DEĞER
AYRIŞIMINA DAYALI ORTAK MATRİS YAKLAŞIMI
İLE YÜZ TANIMA**

Meltem APAYDIN
Yüksek Lisans Tezi

Tez Danışmanı
Yrd. Doç. Dr. Ümit Çiğdem TURHAL
BİLECİK, 2011

 BİLECİK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ	YÜKSEK LİSANS <u>JÜRİ ONAY FORMU</u>
--	---

Bilecik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
tarih ve sayılı kararıyla oluşturulan jüri tarafından
tarihinde tez savunma sınavı yapılan'ın
“ ”
başlıklı tez çalışması Anabilim Dalında
YÜKSEK LİSANS tezi olarak oy birliği/oy çokluğu ile kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI):

ÜYE:

ÜYE:

ONAY

Bilecik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun...../...../.....
tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Yüz tanıma sistemleri günümüzde bilgi güvenliği, akıllı kartlar, kredi kartı doğrulama, suçluların kimliğini tespit etme gibi gerçeğe dayalı uygulamalarda sıkça kullanılan biyometrik tanıma sistemlerinden biridir. Bu tip uygulamalarda son yıllarda birçok araştırmacının da ilgisini çeken önemli bir konu ise tek görüntü problemidir. Tek görüntü problemi ise eğitimde kişi başına sadece bir görüntünün olması durumudur. Eğitimde tek görüntü kullanılarak tanıma yapan yöntemler, kişilere ait çok sayıda görüntü elde etmenin zor olduğu durumlarda ve de depolama gereksinimleri açısından avantaj yaratmaktadır. Ancak bu avantajların yanında yüz tanımada çok yaygın olarak kullanılan birçok yöntemde ciddi performans düşüşleri yaşanırken sınıf-içi dağılım matrislerinin hesabını gerektiren yöntemlerde ise hiç kullanılamamaktadırlar.

Bu tez çalışması kapsamında tek görüntü problemi incelenmiş ve veritabanında çok sayıda eğitim görüntüsü olduğunda iyi tanıma sonuçları veren ve sınıf-içi dağılım matrisinin hesabını gerektiren Ortak Matris Yaklaşımının tek görüntü durumunda kullanımına yönelik bir algoritma geliştirilmeye çalışılmıştır. Bu kapsamda her sınıf için var olan tek görüntünün, sıfır-uzayını tarayan vektörler üzerine izdüşümü alınarak her sınıf için bir ortak matris elde eden tekil değer ayrışımı tabanlı bir algoritma geliştirilmiştir.

Tez çalışmasında ayrıca bu algoritmanın tanıma performansını artırmak için yüzün hem bütünsel hem de bölgesel bilgisinden yararlanan Birleştirilmiş Ortak Özellik Altuzayı yöntemi de sunulmuştur. Bu yöntemde yüzün tamamı kullanılarak bütünsel özellikler elde edilirken, piksel değişimlerinin en fazla olduğu göz, burun ve ağız bölgelerine ait görüntüler kullanılarak bölgesel özellikler elde edilmiştir.

Tekil Değer Ayrışımı'na dayalı Ortak Matris Yaklaşımında bulunan deneysel sonuçlar aynı yüz ifadelerinde ve farklı aydınlanma koşullarında yüksek performans oranları vermiştir. Bununla birlikte bu yöntemin performansının artırılması için sunulan Birleştirilmiş Ortak Özellik Altuzayı yönteminin, özellikle aralarında ifade farklarının olduğu görüntülerde, tanıma performansını büyük ölçüde artırdığı gözlenmiştir.

Anahtar Kelimeler

Yüz tanıma, tek görüntü problemi, ortak matris, tekil değer ayrışımı, alt uzay yöntemler

ABSTRACT

Face recognition system used in the real applications such as information security, smart cards, credit card authentication, identification of criminals and etc., is one of the most used biometric recognition systems. An important subject in these kinds of applications taking attention of researches is one sample problem. One sample problem is the situation of being one sample per person in the training set. The methods using one sample in the training set for recognition have advantageous in the situations that collecting many samples per person is difficult and for storage requirements. However, many common face recognition methods will suffer serious performance drop or even fail to work when the computation of within-class scatter matrix is required.

In this thesis, one sample problem is investigated and it is tried to develop an algorithm intended to use Common Matrix Approach, which has high recognition results and requires the computation of within-class scatter matrix, in the one sample situation. For this reason, an algorithm using singular value decomposition is developed in which the one sample for each class is projected on the vectors spanning the null space of the image and a common matrix is obtained for each class.

In addition, a method called Combined Common Feature Subspace is presented to increase the recognition performance of this algorithm. In this method, global features are obtained by using whole face image and local features are obtained using eye, nose and mouth regions of the face in which the most pixel changes occur.

Experimental results in the SVD based Common Matrix Approach show high recognition rates with same facial expressions and different illumination conditions. In addition, it is observed that Combined Common Feature Subspace Method presented to increase the performance of this algorithm increases the recognition rates especially when the images with different facial expressions are used.

Key Words

Face recognition, one sample problem, common matrix, singular value decomposition, subspace methods

TEŞEKKÜR

Yüksek lisans tez çalışmam boyunca beni yönlendiren, destekleyen ve bilgi birikimlerini paylaşan çok değerli danışman hocam Sayın Yrd. Doç. Dr. Ümit Çiğdem TURHAL'a sonsuz teşekkür ederim. Bu tezi yazarken desteklerini esirgemeyen Bilecik Üniversitesi Elektrik-Elektronik Mühendisliği hocalarına ve tüm çalışma arkadaşlarıma teşekkür ederim.

Çalışmalarımda ve karşılaştığım zorluklarda her zaman yanımda olan, beni destekleyen ve ayrıca bilgisiyle de beni yönlendiren meslektaşım ve çok sevgili hayat arkadaşım Arif Kıvanç ÜSTÜN'e sonsuz teşekkür ederim. Bu süreç boyunca manevi desteklerini benden esirgemeyen, bu günlere gelmemde çok büyük emekleri olan, çok sevdiğim değerli aileme teşekkürü bir borç bilirim. Son olarak, burada adını yazamadığım diğer kişilere çalışmalarım boyunca yanımda oldukları için teşekkür ederim.

İÇİNDEKİLER

TEZ ONAY SAYFASI

ÖZET	iii
ABSTRACT	iv
TEŞEKKÜR	v
İÇİNDEKİLER	vi
KISALTMALAR DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
ŞEKİLLER.....	x

1. YÜZ TANIMA SİSTEMİ	1
1.1.Yüz tanıma kullanılan temel yaklaşımlar	2
1.1.1. Geometrik tabanlı yüz tanıma yöntemleri.....	2
1.1.2. Görünüm tabanlı yüz tanıma yöntemleri.....	3
1.2.Yüz tanıma tek görüntü kullanımı	9
1.2.1. Tek görüntü problemi için geliştirilen yöntemler	10
2. SAYISAL GÖRÜNTÜ	16
3. TEZ KAPSAMINDA TEMEL ALINAN YAKLAŞIMLAR VE TEK GÖRÜNTÜ PROBLEMİNDE TEKİL DEĞER AYRIŞIMI TABANLI ORTAK MATRİS YAKLAŞIMI.....	21
3.1.Ortak vektör yaklaşımı	21
3.2.Ortak matris yaklaşımı.....	23
3.2.1. Gram-Schmidt ortogonalleştirme yöntemi ile OM elde edilmesi.....	24
3.2.2. Sınıf-içi dağılım matrisini kullanarak OM elde edilmesi.....	25
3.3.Tez kapsamında geliştirilen algoritma.....	26
3.3.1. Tekil değer ayrışımı	27
3.3.2. Geliştirilen algoritmalar	29
3.3.2.1.TDA tabanlı ortak matris yöntemi	30

3.3.2.2.Tek görüntü probleminde tanıma performansının artırılması: Birleştirilmiş ortak özellik altuzayı.....	32
4. DENEYSEL ÇALIŞMALAR.....	36
4.1.AR-Face veritabanı kullanılan deneysel çalışmalar	36
4.1.1. Bölüm 3.3.2.1’de geliştirilen algoritma için yapılan deneysel çalışmalar.....	36
4.1.2. Bölüm 3.3.2.2’de geliştirilen algoritma için yapılan deneysel çalışmalar.....	38
5. SONUÇ	42
KAYNAKLAR DİZİNİ	46
TEZ KAPSAMINDA YAYINLANAN BİLDİRİLER.....	52
ÖZGEÇMİŞ	53

KISALTMALAR DİZİNİ

ABA	: Ana Bileşenler Analizi
BBA	: Bağımsız Bileşenler Analizi
BMP	: Bitmap
CMYK	: Cyan Magenta Yellow Key
DAA	: Doğrusal Ayırıcı Analizi
FDA	: Fisher Doğrusal Ayırıcı Analizi
GIF	: Graphics Interchange Format
JPEG	: Joint Photographic Experts Group
KFA	: Kernel Fisher Ayırıcı
LZW	: Lempel-Ziv-Welch
OV	: Ortak Vektör
OM	: Ortak Matris
(PC)2A	: Projection Combined Principal Component Analysis
TDA	: Tekil Değer Ayrışımı

ÇİZELGELER DİZİNİ

Çizelge 4.1:	AR-Face Veritabanı İçin Tanıma Performansları	37
Çizelge 4.2:	I. Grup Ve II. Grup Deneysel Çalışma Sonuçları	40

ŞEKİLLER DİZİNİ

Sayfa No


Şekil 1.1:	Otomatik Yüz Tanımına Sistemi Blok Diyagramı	1
Şekil 1.2:	a) Üç Bandlı Görüntü Piksellerinin Üç Boyutlu Uzayda Ortak Dağılımı b) Ana Bileşenler Dönüşümü	4
Şekil 2.1:	Sayısal Bir Görüntü İçin Koordinat Eksenini	16
Şekil 2.2:	Uzaysal Çözünürlüğün Düşürülmesinin Etkisi a) 726x1024 Boyutunda Orijinal Görüntü b) 363x512 c) 182x256 d) 91x128 e) 46x64 Boyutundaki Görüntüsü	18
Şekil 2.3:	Gri Seviye Değerlerin Azaltılmasının Etkisi a) 300x300 Boyutundaki Orijinal Görüntü b) 300x300 Boyutundaki Ve Gri Seviye değerleri 256, 128, 64, 32, 16, 8, 4 Ve 2 Olan Görüntüler	19
Şekil 3.1:	TDA'ya dayalı OM Yaklaşımının kaba kodu	32
Şekil 3.2:	Birleştirilmiş Ortak Özellik Altuzayı Yöntemi'nin kaba kodu	35
Şekil 4.1:	AR-Face Veritabanına Ait Yüz Görüntü Örneklerinden Bazıları	36
Şekil 4.2:	AR-Face Veritabanından İki Kişiye Ait Gri Seviye, 50x40 Boyutunda Bazı Yüz Görüntü Örnekleri	36
Şekil 4.3:	AR-Face Veritabanından İki Kişinin 9 Adet Aynı Yüz İfadelerine Ve Farklı Aydınlatma Koşullarına Sahip Görüntüleri	37
Şekil 4.4:	ORL Veritabanından 2 Kişiye Ait 4'er Adet Yüz Görüntü Örnekleri	
Şekil 4.5:	Birinci Grup Görüntü Veritabanı İçin 4 Görüntü Örneği	38
Şekil 4.6:	İkinci Grup Görüntü Veritabanı İçin 3 Görüntü Örneği	38
Şekil 4.7:	Üçüncü Grup Görüntü Veritabanı İçin 3 Görüntü Örneği	38
Şekil 4.8:	Göz Bölgesi İçin (E): A) I.Grup Görüntü Örnekleri, B) II. Grup Görüntü Örnekleri, C) III. Grup Görüntü Örnekleri	39
Şekil 4.9:	Birleştirilmiş Ortak Özellik Altuzayı İçin Kullanılan Veritabanına Bir Örnek: A) F Bölgesi B) E Bölgesi, C) N Bölgesi, D) M Bölgesi Görüntü Örnekleri	39
Şekil 4.10:	III. Grup Veritabanı İçin Elde Edilen Birikimli Eşleştirme Skoru Sonuçları	40

1. YÜZ TANIMA SİSTEMİ

Yüzyıllardır insanlar birbirlerini yüzleri, sesleri ve yürüyüş biçimleri gibi vücut karakteristiklerinden tanıyabilmektedirler. Bu, insan beyninin algılama ve tanımadaki mükemmel işleyişinin bir sonucudur. Paris'teki polis departmanının suçluları tanıma bölümünün şefi Alphonse Bertillon, 19. yüzyılın ortalarında bir kısım vücut ölçümlerini kullanarak suçluları teşhis etme fikrini ortaya atmış ve devamını parmak izinin bu amaçla kullanılması izlemiştir (Jain vd., 2004).

Kişileri fiziksel ve davranışsal özellikleri yardımıyla tanımlamaya yarayan biyometrik tanıma sistemleri, kişilerden biyometrik bilginin elde edilmesi, bu verilerden özellik çıkarılması ve daha önceden oluşturulmuş bir veritabanı ile karşılaştırarak tanıma işlemlerini içerir (Prabhakar vd., 2003). Çok bilinen biyometrik tanıma sistemlerinden bazıları, yüz tanıma, iris ve retina tanıma, parmak izi tanıma, damar tanıma ve el yazısı tanımadır.

Biyometrik tanıma sistemlerinin bir alt dalı olan yüz tanıma, bazı yüzsel karakteristiklerin analizi ve bu karakteristik özelliklerin, daha önceden oluşturulmuş bir veritabanı ile karşılaştırılarak, yüzün tanınması olarak ifade edilebilir. Otomatik yüz tanıma sisteminin blok diyagramı şekil 1.1.' de verildiği gibidir.



Şekil 1.1. Otomatik yüz tanıma sistemi blok diyagramı.

Yüz tanıma sistemlerinin diğer biyometrik tanıma sistemlerine göre öne çıkan özelliği, temasa ihtiyaç duymaması, diğer bir deyişle kullanım kolaylığı yaratmasıdır. Günümüzde artan güvenlik ihtiyaçları nedeniyle bu sistemler bilgi güvenliği, akıllı kartlar, kredi kartı doğrulama, suçluların kimliğini tespit etme gibi alanlarda sıkça

kullanılmakta, hem akademik hem de endüstriyel çalışmalarda önemli bir yer edinmektedir (Chellappa vd., 1995; Daugman, 1997; Zhao vd., 2003).

1.1. Yüz Tanımda Kullanılan Temel Yaklaşımlar

Literatürde yayınlanmış birçok yüz tanıma yöntemi vardır, bu yöntemler farklı kriterlere göre sınıflandırılabilir. Örneğin, özellik çıkarımı açısından sınıflandırılacaksa, geometrik tabanlı ve görünüme tabanlı olarak ikiye ayrılabilir. Bu konuda yapılmış çeşitli çalışmalar referanslarda verilmiştir (Zhao vd., 2003; Chellappa vd., 1995; Zhao ve Chellappa, 2002; Tan vd., 2006). Bu tezin de tabanını oluşturulan görünüme dayalı yaklaşımlara bakıldığında, yüzün bütünsel bilgisinden yararlanmak adına görüntünün gri seviye piksel değerlerini satırlar ya da sütunlar alt alta gelecek şekilde vektöre dönüştürerek yüz görüntüsünün temsil edildiği görülür. Bu büyük boyutlu temsil, yöntemin iyi bir performans vermesi için geniş bir eğitim kümesini gerektirir. Bu yöntemlerde boyut problemini ortadan kaldırmak için boyut indirgeme tekniklerine başvurulur. Literatürde bu amaçla yapılan yaklaşımlara bakıldığında, temelini istatistiksel tabanlı bir yöntem olan Ana Bileşenler Analizi (ABA) oluşturmaktadır.

1.1.1. Geometrik Tabanlı Yüz Tanıma Yöntemleri

Literatürde geliştirilen yüz tanıma algoritmalarına bakıldığında özellik çıkarımı açısından temelde geometrik tabanlı ve görünüme dayalı yöntemler olarak iki gruba ayrıldığı görülür. Geometrik tabanlı yaklaşımlarda, yüz görüntüsü üzerindeki bazı özellik noktaları arasındaki açı, mesafe gibi değişmeyen ölçümler hesaplanarak, tanıma için kullanılmak üzere saklanır (Brunelli ve Poggio, 1993). Bu değişmeyen ölçümler, gözler arasındaki mesafe, kafa genişliği, göz köşeleri ve çene noktası arasındaki açı ölçümleri olabilir.

Bu yöntemlerde ortak ve sınıflara ait belirli özellikler kolaylıkla çıkarılabilir ve yüz görüntüsünün farklı özellikleri tanımaya yardımcı olur (Villela ve Azuela, 2002). Literatürde yüzün çeşitli geometrik ölçümlerini kullanan özellik tabanlı yaklaşımlar mevcuttur (Kaya ve Kobayashi, 1972; Kanade, 1973; Brunelli ve Poggio, 1993; Hjelm ve Wrodsen, 1999). Brunelli ve Poggio sundukları yöntemde görüntüdeki gözün yerini tespit etmeye çalışmışlar ve bunun için bir şablonlar kümesi kullanmışlardır. Cox ve arkadaşlarının sundukları çalışmada ise yüz görüntüsü üzerinde belirlenen 30 farklı nokta için özellik çıkarılmıştır (Cox vd., 1996). Bir başka çalışma da

Wu ve arkadaşları tarafından gerçekleştirilmiştir (Wu vd., 2004). Araştırmacılar bu çalışmalarında gözlük bölgesinin yerini otomatik olarak saptamaya çalışan bir yöntem sunmuşlardır. Manjunath ve arkadaşları da, yüz özelliklerini belirleme ve temsili için Gabor dalgacık dönüşümünü kullandıkları bir yöntem sunmuşlardır (Manjunath vd., 1992).

Bu yöntemlerde, bütünsel özellikler kullanılmadığı için, tanımda önemli rol oynayabilecek bilgi kaybedilebilir. Örneğin, görüntünün gri seviye piksel değerleri gibi tanımda faydalı bilgiler kaybolur (Tan vd., 2006). Ayrıca karmaşık durumlarda da özelliklerin çıkarımındaki zorluk diğer bir dezavantajdır. Bu dezavantajlar yüz tanımda bütünsel bilgilerin kullanımını gerektiren görünüm tabanlı yöntemlerin gelişmesine sebep olmuştur.

1.1.2. Görünüm Tabanlı Yüz Tanıma Yöntemleri


Suçluların tespiti gibi çok sayıda yüz görüntü örneğini barındırması gereken uygulamalarda ise geometrik tabanlı yöntemler yerini yüz görüntü örneklerini işlemede daha az zahmetli ve yüz tanıma sisteminin etkinliğini artıran görünüme dayalı yöntemlere bırakacaklardır. Bu yöntemlerde, yüz görüntüleri, bütün piksellerin gri seviye değerleri satırlar ya da sütunlar alt alta gelecek şekilde sıralanarak tek bir vektörle temsil edilir. Böylece doku ve şekil bilgisi korunurken, yüzün bütünü kullanılarak özellik çıkarım işlemi gerçekleştirilmiş olur. Fakat bu yöntemlere baktığımızda ise performanslarının, her yüz için var olan eğitim görüntülerinin sayısına büyük ölçüde bağlı olduğunu görürüz (Jain ve Chandrasekaran, 1982).

Bu tip yöntemlerde öncelikle kimliği belirlenen yüz görüntüleri kullanılarak çeşitli yöntemlerle özellik çıkartımı yapılır. Çıkartılan bu özellikler bir veritabanında saklanarak daha sonra tanımda kullanılır. Burada kullanılan kimliği bilinen yüz görüntüleri eğitim kümesini oluşturmuş olur. Görünüm tabanlı yöntemlerde tanıma performansı eğitim sınıfının büyüklüğü ile orantılıdır. Teorik olarak her sınıf için eğitim kümesinde kullanılan görüntü sayısı görüntü vektör boyutunun 10 katı kadar olmalıdır (Jain ve Chandrasekaran, 1982). Bu da bir kişiyi fotoğrafına bakarak tanıyabilmek için eğitim aşamasında o kişinin çok sayıda fotoğrafına ihtiyaç duyulduğunu göstermektedir. Diğer bir deyişle yöntemin iyi bir performans vermesi için geniş bir eğitim kümesi gerekir. Bu problem görünüm tabanlı yöntemlerde boyut indirgenmesi gerekliliğini ortaya çıkarır. Görünüm tabanlı yöntemlerde bu gerekliliğe karşılık olarak altuzay

yöntemleri kullanılır. Altuzay yöntemlerinde, büyük boyutlu yüz görüntü vektörü daha düşük boyutlu bir özellik altuzayında temsil edilmekte ve orijinal görüntüye göre daha düşük boyutlu bu temsili görüntü tanımda kullanılmaktadır.

Yüz tanımda altuzay yöntemlerini kullanan yaklaşımların başında, ABA'nın yüz görüntüleri üzerine uygulanmış hali olan ve literatürde Özyüzler (Turk ve Pentland, 1991) olarak bilinen yöntem gelir.

ABA, bir değişkenler kümesinin varyans-kovaryans yapısını bu değişkenlerin doğrusal birleşimleri vasıtasıyla açıklayarak boyut indirgemesi ve yorumlamasını sağlayan çok değişkenli bir istatistiksel yöntemdir. Ana bileşenler dönüşümünün temel ilkesi; multispektral vektör uzayında, verileri bağımsız olarak ifade edebilen, diğer bir ifadeyle yeni sistemde kovaryans matrisi köşegen olan bir koordinat sisteminin araştırılmasıdır. Şekil 1.2.'de ana bileşenler dönüşümünün, $(x_1-x_2-x_3)$ koordinat sisteminin, üç uzaysal dönüklük açısıyla, $(y_1-y_2-y_3)$ koordinat sistemine dönüştürülmesi verilmiştir (Akça ve Doğan, 2002). Dönüşümden sonra diklik koşulu korunacağından, dönüşüm matrisi ortogonal bir matristir ve dönüşümden sonra yeni koordinat sisteminin eksenleri, elipsoidin eksenlerine paraleldir. Elipsoidin en büyük eksen, veri kümesinin birinci ana bileşenidir. Birinci ana bileşenin yönüne, birinci özvektör ve uzunluğuna da birinci özdeğer denir.



Şekil 1.2. (a) Üç bandlı (RGB) görüntü piksellerinin üç boyutlu uzayda ortak dağılımı (b) Ana bileşenler dönüşümü (Akça ve Doğan, 2002).

Turk ve Pentland'ın öncülük ettiği bu çalışma, bundan sonra gelecek birçok görünüm tabanlı yaklaşımın temelini oluşturmuş, yapılan çalışmalar bu yöntem üzerine geliştirilmiştir.

Bu yöntem, büyük boyutlu orijinal yüz uzayından lineer olarak daha düşük boyutlu bir özellik alt uzayına (özuzay) dönüşümü gerçekleştiren ve tanıma işlemini bu

özuzay içerisinde gerçekleştiren bir yöntemdir. Bu altuzay yüz görüntüleri arasındaki dağılımı ifade eden görüntü kovaryans matrisinden yararlanılarak oluşturulur.

Öncelikle sınıf başına birden fazla sayıda görüntünün olduğu bir eğitim kümesi gereklidir. Her bir yüz görüntüsün boyutu aynıdır ve siyah beyaz bir görüntü için 0 ile 255 sayıları arasında değişen gri seviye piksel değerlerinden oluşur. Eğitim kümesindeki her görüntü matrisi $m \times n$ boyutunda ise, her yüz görüntüsü $d = m \times n$ olacak şekilde $d \times 1$ boyutunda $\vec{\Gamma}_n$ vektörüne dönüştürülür.

$$\Gamma = [\vec{\Gamma}_1 \vec{\Gamma}_2 \vec{\Gamma}_3 \dots \vec{\Gamma}_M] \quad (\text{E.1.1})$$

M = eğitim kümesindeki görüntü sayısı

Oluşan Γ matrisi, görüntü vektörlerinin eğitim kümesini temsil eder ve $(d \times M)$ boyutundadır.

Eğitim kümesindeki görüntü vektörlerinin aritmetik olarak ortalaması Ψ hesaplanıp, eğitim kümesindeki bütün görüntü vektörlerinden çıkartılırsa, $(d \times M)$ boyutundaki fark görüntü matrisi Φ elde edilir.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (\text{E.1.2})$$

Burada Ψ 'nin boyutu $d \times 1$ 'dir.

$$\Phi_n = \Gamma_n - \Psi \quad (\text{E.1.3})$$

$$\Phi = [\vec{\Phi}_1 \vec{\Phi}_2 \vec{\Phi}_3 \dots \vec{\Phi}_M] \quad (\text{E.1.4})$$

Sütunları eğitim kümesindeki görüntü vektörleri ile ortalama görüntü vektörü arasındaki farktan oluşan fark görüntü matrisinin, transpozu ile çarpımından, görüntü sınıfları arasındaki dağılımı gösteren $(d \times d)$ boyutundaki kovaryans matrisi C elde edilir.

$$C = \Phi \cdot \Phi^T = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T \quad (\text{E.1.5})$$

Kovaryans matrisinin oluşturulmasından sonraki adım ise bu matrisin özvektörlerinin hesabıdır. ABA olarak bilinen bu istatistiksel yöntemde, kovaryans matrisin d (görüntüdeki piksel sayısı, $d = m \times n$) adet özvektör sayısı, M (eğitim kümesindeki görüntü sayısı) adet özvektör sayısına düşürülür. Kovaryans matrisinin boyutu $(d \times d)$ oldukça büyük olduğundan ve bu da işlem zamanını artıracığından, $(M \times M)$ boyutunda yeni bir matrisin özvektörlerini alarak bu problem çözülebilir (Krueger vd., 2004).

Kovaryans matrisi, eğitim kümesindeki yüz görüntüleri arasındaki dağılımı verir. Kovaryans matrisin özvektörleri, özuzayı tarayan vektörlerdir. Özuzaydaki, her bir özvektör, değişimin yönünü verirken, bu özvektörlere karşılık gelen özdeğerler de bu yöndeki değişimin büyüklüğünü verir. Bulunan bu özvektörlerden, en büyük özdeğere karşılık geleni, yüz görüntüleri arasındaki değişimin en büyük, en küçük özdeğere karşılık gelen özvektör ise, bu değişimin en az olduğu yönü verir.

Görüntü temsili için ABA yönteminin 2-boyutlu versiyonu Yang ve arkadaşları tarafından geliştirilmiştir. ABA'nın aksine, bu yöntemde 1-boyutlu vektörler yerine 2-boyutlu görüntü matrisleri kullanılır. Böylece görüntü matrisinin özellik çıkarma işleminden önce tek boyuta dönüştürülmesine gerek yoktur (Yang vd., 2004). Burada, kovaryans matrisi, orijinal görüntü matrislerinden direk olarak oluşturulabilir ve ABA yöntemine kıyasla kovaryans matrisinin boyutu nispeten küçüktür. Bu da, yöntemde kovaryans matrisinin değerlendirilmesi açısından kolaylık ve özvektörlerin hesaplanması açısından işlem zamanının kısalması gibi üstünlükler katmaktadır. ABA'nın 2 boyuta uyarlanması birçok araştırmacıya ışık tutmuş, bu çalışmanın temel alındığı ve bu yöntemdeki eksiklikleri gidermesi amacıyla birçok yöntem geliştirilmiştir.

Yüz tanımda sıkça kullanılan ve en çok bilinen boyut indirgeme yöntemlerinden biri olan ABA'da, verilerin dağılımındaki en büyük değişikliğin yönü aranır ve verilerin bu en büyük varyansa izdüşümü alınır. Verilerin dağılımını maksimize etmeyi amaçlayan bu yöntem, aydınlatma ve yüz ifadelerinde meydana gelebilecek büyük değişimlerde iyi sonuçlar vermez. Çünkü sınıflar-arası dağılım maksimize edilirken, sınıflandırma açısından hiç de istenmeyen sınıf-içi dağılım da artar. Böylece görüntüler arasındaki aydınlatma ve ifade farklılıkları gibi istenmeyen değişimler de tutulur, bu da izdüşüm uzayında sınıfları iyi bir şekilde birbirlerinden ayrılmamasına neden olur ve sınıflandırma için faydalı bilgi de zarar görür (Welling, 2010).

Sınıflandırma açısından, aydınlatma ve ifade farklılıkları gibi değişimlerde ABA'ya göre daha iyi sonuç veren bir yöntem de Fisher Doğrusal Ayrıcı Analizi'dir (FDA). Bu yöntem sınıflar-arası dağılım matrisinin sınıf-içi dağılım matrisine oranının maksimize edilmesine dayanır, diğer bir deyişle sınıflar-arası dağılım maksimize edilmeye çalışılırken, sınıf-içi dağılım da minimize edilmeye çalışılır.

Sınıflar-arası dağılım matrisi S_B ve sınıf-içi dağılım matrisi S_W aşağıda verildiği şekilde tanımlanır.

$$S_B = \sum_{i=1}^C N_i (\mu_i - \mu) (\mu_i - \mu)^T \quad (E.1.6)$$

$$S_W = \sum_{i=1}^C \sum_{x_k \in i.sınıf} (x_k - \mu_i) (x_k - \mu_i)^T \quad (E.1.7)$$

Burada μ_i ve N_i , sırasıyla i . sınıfa ait ortalama vektörü ve o sınıftaki görüntü sayısını; μ , tüm görüntülerin ortalamasını ifade etmektedir. Ortonormal sütunlara sahip optimum izdüşüm matrisi W_{opt} , izdüşürülen örneklerin sınıflar-arası dağılım matrisinin determinantını sınıf-içi dağılım matrisinin determinantına oranını maksimum yapacak şekilde seçilir.

$$W_{opt} = \arg \max_W \frac{|W^T S_B W|}{|W^T S_W W|} = [w_1 \ w_2 \ \dots \ w_m] \quad (E.1.8)$$

Burada $\{w_i | i = 1, 2, \dots, m\}$ S_B ve S_W 'nin en yüksek m adet özdeğerine $\{\lambda_i | i = 1, 2, \dots, m\}$ karşılık gelen özvektörlerdir.

$$S_B w_i = \lambda_i S_W w_i \quad (E.1.9)$$

S_B , rank1 $(C - 1)$ ya da daha az olan bir matristir. Dolayısıyla en fazla $(C - 1)$ tane sıfır olmayan özdeğer vardır ve m 'nin bir üst sınırı $(C - 1)$ olur (Duda vd., 2001).

Bu yöntemde ortaya çıkabilecek önemli bir problem ise sınıf-içi dağılım matrisinin $S_W \in R^{n \times n}$ tekil olmasıdır. Buna küçük örnek boyutu problemi adı verilir. Bu problem S_W 'nin rankının en fazla $N - C$ olmasından, yani eğitim kümesindeki N adet görüntü sayısının, her görüntüdeki piksel sayısı n 'den çok küçük olmasından kaynaklanmaktadır. Bu tekillik problemine çözüm olarak Fisherface olarak adlandırılan yöntem sunulmuştur (Belhumeur vd., 1997). Tekil olmayan sınıf-içi dağılım matrisi S_W elde etmek için, görüntü verileri en başta daha düşük boyutlu bir altuzaya izdüşürülmüştür. Bu boyut indirgeme işlemi de ABA uygulanarak başarılmıştır. Böylece elde edilen optimum izdüşüm matrisi aşağıda verilen eşitlikle elde edilir.

$$W_{opt}^T = W_{FDA}^T W_{ABA}^T \quad (E.1.10)$$

Fisherface yöntemi ışık değişimlerine karşı ABA yöntemine göre daha iyi sonuçlar vermiştir. ABA+DAA yöntemlerinin uygulandığı bu çalışmada DAA ile ayırıcı vektörleri elde etmeden önceki aşamada, ABA ile görüntülerin daha düşük boyutlu bir altuzaya izdüşürülmesi tekillik problemini çözerken, ayırışım için çok önemli bilgiler taşıyan S_W 'nin sıfır alt uzayını yok etmektedir (Yu and Yang, 2001). Bu yüzden,

öncesinde bir ABA adımı olmayan Direkt-DAA ve sıfır uzay temelli DAA yöntemleri ortaya atılmıştır.

Geliştirilen DAA-tabanlı algoritmaların çoğunda amaç, sınıflar-arası değişimlerin sınıf-içi değişimlere oranını maksimize etmeye çalışarak, özuzayda en ayırt edici izdüşüm yönlerini bulmaktır.

Yüz tanımda kullanılan bir diğer yöntem de Bağımsız Bileşenler Analizi (BBA) tabanlı yaklaşımlardır (Bartlett vd., 1998). ABA yöntemi veri kümesi normal dağılıma yaklaştıkça, BBA ise normal dağılımdan uzaklaştıkça en iyi performansa yaklaşırlar. BBA algoritması öyle bir doğrusal koordinat sistemi bulur ki elde edilen işaretler istatistiksel olarak birbirinden bağımsız olur ve ayrıca yüksek derece istatistiksel bağımlılığı da azaltır. Bu açıdan bakıldığında BBA'ne dayalı yöntemlerin ABA'ne dayalı yöntemlere göre daha başarılı olması beklenir. Bununla birlikte, klasik Özyüzler ve Fisheryüzler yöntemleri, iki ya da daha çok pikselin ilişkileri gibi yüksek derece istatistiksel bağımlılıklarından ziyade görüntü kümesinin ikinci dereceden istatistiğine dayanır.

Yukarıda bahsedilen bu doğrusal görüntü tanıma yöntemlerinin doğrusal-olmayan dağılıma sahip verileri sınıflandırmada yetersiz kalmasından dolayı, kernel yöntemleri olarak da adlandırılan doğrusal-olmayan yöntemler geliştirilmiştir. Yang kernel ve klasik yöntemlerin karşılaştırıldığı bir çalışma sunmuş ve kernel yöntemlerin tanımda daha başarılı olduğunu göstermiştir (Yang, 2002).

Liu ve arkadaşları geliştirdikleri sıfır-uzayı temelli kernel DAA yönteminde başarılı sonuçlar elde etmişlerdir (Liu vd., 2004). Bu yöntemde tanımda sıradan Fisherfaces sistemlerinde kullanılmayan düşük varyanslı bilgilerden de faydalanılmasını amaçlamıştır. Bir başka çalışmada da kernel ABA + Fisher doğrusal ayırıcı analizinden oluşan iki aşamalı Kernel Fisher Ayırıcı (KFA) yapısı geliştirilmiştir (Yang vd., 2005).

Yang ve arkadaşları ABA'dan elde edilen dönüşüm vektörleri ile Kernel ABA'den elde edilen dönüşüm vektörlerini birleştirerek karmaşık dönüşüm vektörleri elde etmişlerdir (Yang vd., 2003). Elde edilen bu karmaşık dönüşüm vektörleri üzerine izdüşüm alındıktan sonra ikinci bir özellik çıkarma işlemi olarak aynı şekilde karmaşık Fisher doğrusal ayırıcı analizi (karmaşık DAA) uygulaması yapmışlardır.

1.2.Yüz Tanımda Tek Görüntü Kullanımı

Geliştirilen çoğu yüz tanıma algoritmasında tanıma sisteminin doğruluğu üzerinde durulurken var olan veritabanından çıkabilecek olası tek görüntü problemine değinilmemiştir (Zhao vd., 2003). Pratikteki çoğu uygulamada, var olan veritabanlarında olduğu gibi bir kişiye ait birden fazla görüntü elde etmek oldukça güçtür. Bu problem, kişiye ait birden fazla görüntüyü elde etmenin zorluğundan ya da hafıza kapasitesinin kısıtlamalarından ortaya çıkabilir (Tan vd., 2006). Örneğin suçlu teşhis etmede kullanılabilecek bir veritabanında suçluya ait tek bir görüntünün olma olasılığı oldukça yüksektir, ya da havaalanlarında kişileri tespit etmede, pasaport üzerindeki tek bir fotoğraf kullanılır. Yüz tanıma algoritmalarından en çok bilinen birçok yöntemde, örneğin Eigenface (Sirovich ve Kirby, 1987; Turk ve Pentland, 1991) ve Fisherface (Belhumeur vd., 1997) algoritmaları gibi, veritabanında kişi başına tek görüntü olduğu durumlarda ciddi performans düşüşleri yaşanır hatta bazıları eğitimde tek görüntü durumunda hiç kullanılamazlar. Tek görüntü problemi olarak bilinen bu problem, kişi başına sadece tek görüntünün olduğu bir veritabanından, kişileri daha ileri bir zamanda, farklı ve beklenmedik poz ve aydınlatma koşullarında tanımayı amaçlama olarak tanımlanır (Tan vd., 2006).

Gerçeğe dayalı senaryolarda, kişilere ait tek görüntünün olması, var olan yüz tanıma algoritmalarında tek görüntü problemine yol açacağı gerçeğinin yanında, tanıma için tek görüntünün kullanılmasının getireceği birçok avantajı da vardır. Öncelikle kişilere ait görüntü örneklerini doğrudan ya da dolaylı olarak elde etme konusunda kolaylık yaratır. Geliştirilen yüz tanıma algoritmalarının ortak özelliği, veritabanlarında, şablon olarak depolanmış yüz görüntülerinin olmasıdır (Tan vd., 2006). Bu veritabanlarını oluşturmak da oldukça zahmetli ve zaman alıcı bir iştir. Kişileri tanımda onlara ait tek görüntüyü kullanmak ise, bu zorluğu önemli ölçüde azaltır. Ayrıca pratikteki uygulamalarda, kişilere ait tek görüntülerden oluşan veritabanını oluşturmak da oldukça kolaydır. Örneğin, güvenlik açısından birçok kişinin tanınmasını gerektiren bir havaalanı sisteminde, kişilere ait görüntüleri, pasaport ya da kimliklerindeki tek fotoğrafları taranarak elde edilebilir. Diğer bir avantajı da, veritabanında sadece kişilere ait tek görüntü depolanacağı için, depolama kısıtları da önemli ölçüde azaltılmış olur. Ayrıca eğitim kümesinde kişi başına görüntü sayısı, önışleme, özellik çıkarımı, tanıma gibi işlemlerin maliyetlerini de etkileyeceğinden, veritabanında kişi başına tek görüntünün olması bu maliyeti de oldukça azaltır.

1.2.1. Tek Görüntü Problemi İçin Geliştirilen Yöntemler

Veritabanında kişi başına tek görüntü olduğunda, eğitim kümesindeki yüz görüntüsünün tek bir büyük boyutlu vektör ile temsili küçük örnek boyutu problemini (Duin, 1995; Jain ve Chandrasekaran, 1987; Raudys ve Jain, 1991) daha önemli hale getirirken, her sınıf için sadece tek bir vektör olacağından sınıf içi değişimlerin direkt olarak hesabı yapılamaz. Örneğin, yüz tanımda sıkça kullanılan ve sınıflar-arası değişimlerin sınıf-içi değişimlere oranını maksimize etmeye çalışarak, özuzayda en ayırt edici izdüşüm yönlerinin bulmayı amaçlayan DAA-tabanlı algoritmaların çoğu veritabanında kişi başına sadece tek eğitim görüntüsü olduğu durumlarda, sınıf-içi değişimler elde edilemediğinden, hiç çalışmazlar. DAA-tabanlı bu yöntemler ancak eğitim kümesinde her bir birey için çok sayıda eğitim görüntüsü olduğunda iyi sonuçlar vermekte, hatta aksi durumda performansı Özyüzler yönteminden daha düşük olmaktadır (Tan vd., 2006).

Bu sonuçların ışığında, tek görüntü problemi için ya büyük boyutlu yüz görüntü uzayında ya da daha yaygın olan alt uzay yöntemleri kullanılarak boyutu azaltılmış alt uzayda, var olan tek görüntüden mümkün olan en çok bilgiyi çıkarmaya çalışan çalışmalar ve her görüntü için çeşitli yöntemlerle yeni temsiller üreten diğer bir deyişle veritabanını genişleten çalışmalar geliştirilmiştir (Tan, 2006).

Wu ve Zhou standart Eigenface tekniğinin genişletilmiş bir versiyonu olan $(PC)^2A$ tekniğini sunmuş ve tek görüntü problemine uygulamışlardır (Wu ve Zhou, 2002). Çalışmalarında, veritabanında tek görüntü olduğunda geliştirdikleri yöntemin standart Eigenface yöntemine göre daha iyi sonuç verdiğini ve işlem miktarlarının da azaldığını göstermişlerdir. Bu yöntemde, yüz görüntüsünün dikey ve yatay izdüşümlerini orijinal görüntü örneği ile birleştiren önışleme tekniği geliştirmişler ve bu önışlemin sonucunda düzgünleştirilmiş yüz görüntü örneği elde etmişlerdir. Bu da, standart Eigenface tekniğinin, belirginleşmiş önemli özellikler üzerine uygulanmasını sağlamıştır. Bu çalışmalarının sonucu olarak birleştirme parametresi α 'yı tanımlayıp, iyi bir tanıma performansı elde etmek için α değerinin en uygun şekilde seçilmesi gerektiğini öne sürmüşlerdir.

Bu çalışmanın ışığında Chen ve arkadaşları $(PC)^2A$ yöntemini genelleyen ve buna ilaveten n-dereceden görüntüleri baz alarak genişleten genişletilmiş $(PC)^2A$ yöntemini sunmuşlardır (Chen vd., 2004). $(PC)^2A$ yönteminde, orijinal görüntü onun birinci

dereceden izdüşümü ile birleştirilirken sunulan bu yöntemde görüntünün daha yüksek dereceden izdüşümleri tanıma işlemini genişletmek için kullanılmıştır. Bu çalışmanın ilk kısmında orijinal görüntü, birinci dereceden izdüşüm görüntülerinin yanı sıra, ikinci derece izdüşüm görüntüleriyle de birleştirilir ve bu birleştirilmiş görüntüye ABA uygulanır. İkinci kısmında ise, orijinal görüntüyü izdüşüm görüntüleriyle birleştirmek yerine bu görüntüler veritabanını genişletmek için kullanılırlar. Yani veritabanında M adet yüz görüntü örneği varsa ve n-dereceden izdüşüm görüntüsü elde edildiyse, genişletilmiş veritabanında toplam $(n+1)M$ görüntü oluşur. FERET (Phillips vd., 1998) veritabanı üzerinde yaptıkları deneysel çalışmanın sonucunda, öne sürdükleri genişletilmiş $(PC)^2A$ yönteminde, baz aldıkları $(PC)^2A$ yönteminde kullanılan özyüz sayısının yarısı kadar kullanılmasına rağmen daha iyi tanıma doğruluğu elde ettiklerini göstermişlerdir.

Yapılan bu iki çalışmada da araştırmacılar (Wu ve Zhou, 2002; Chen vd., 2004) tek görüntü problemine çözüm olarak, ABA yöntemi genişletilerek mümkün olan en iyi bilgiyi çıkarmaya çalışmışlardır. Benzer bir çalışma olarak, veritabanında tek görüntü olduğu durumlar için Tekil Değer Ayrışımı (TDA) (Golub ve Loan, 1983) pertürbasyonu tabanlı bir tanıma yöntemi ve iki adet genelleştirilmiş Eigenface algoritması, Zhang ve arkadaşları tarafından sunulmuştur (Zhang vd., 2005). İlk algoritmada, görüntü matrisinin tekil değerleri üzerine pertürbasyon uygulanarak elde edilmiş görüntü, orijinal görüntü ile doğrusal olarak birleştirilmiş ve sonrasında birleştirilmiş görüntülere ABA uygulanmıştır. İkinci algoritmada ise TDA pertürbasyonu ile elde edilen görüntüler bağımsız birer görüntü olarak değerlendirilmiş, diğer bir deyişle veritabanı genişletilmiş ve oluşturulan bu yeni veritabanı üzerine ABA uygulanmıştır. İlk algoritmada en çok bilgiyi elde etmeye çalışarak tek görüntü ile tanıma için önemli olabilecek özellikleri çıkarmayı amaçlamışlar ve bu özelliklerin her sınıf için örnek görüntüler üretmek için kullanabileceğini ve böylece tek görüntü probleminin geleneksel yüz tanıma problemine dönüştüğünü söyleyerek ikinci algoritmayı sunmuşlardır. FERET veritabanında yaptıkları deneysel çalışmalar sonucunda, geliştirilen iki algoritmanın da standart Eigenface ve $(PC)^2A$ yöntemlerine kıyasla daha az özyüz kullanmasına rağmen tanıma doğruluğunu artırdığı görülmüştür (Zhang vd., 2005).

Veritabanında kişi başına tek eğitim görüntüsü olduğu durumlar için geliştirilen bir başka yöntem de, görüntülerin izdüşüm haritası ve TDA tabanlıdır (He ve Du, 2005). Yüz görüntüsüne ait tekil değerlerin özellik vektörlerinin, yüz tanıma için çok az önemli bilgi içerdiği ve en önemli bilgilerin TDA'nın iki ortogonal matrisinde kodlandığı (Tian vd., 2003) bilgisinden yola çıkılarak sunulan bu yöntemde önışleme aşaması olarak, tek görüntüden daha fazla bilgi çıkarmak için yüz görüntüsü, izdüşüm haritası ile doğrusal olarak birleştirilir. Birleştirilen görüntüye Fourier dönüşümü uygulanır ve birleştirilmiş yeni eğitim kümesini temsil etmek üzere Fourier dönüşüm katsayıları kullanılır. Tüm spektrum temsillerinin ortalaması alınarak elde edilen standart yüz görüntüsüne TDA uygulanarak ortogonal iki matris elde edilir. Bu iki matris ile taranan uzaya tek öz-uzay denir (He ve Du, 2005). Her birleştirilmiş yüz görüntüsünün spektrum temsiliinin öz-uzaya izdüşümü alınarak oluşturulan katsayı matrisi tanıma için yüz görüntüsünün özelliği olarak kullanılır.

Tek görüntü problemi için veritabanını genişleten, bunu da eldeki yüz görüntüsünden daha fazla bilgi çıkarmayı amaçlayıp yeni temsiller oluşturarak yapan bir diğer yöntem de Temsili Tabanlı Bileşen Analizidir (Torre vd., 2005). Yüz görüntüsüne ait farklı temsiller birleştirilerek, bu temsillerin önemli ayırt edici bilgilerinden yararlanılır (Tan vd., 2006). Bu bilginin ışığında sunulan bu yöntemde, yüz görüntülerine bazı doğrusal ve doğrusal olmayan filtreler uygulanarak görüntülerin farklı temsilleri elde edilir. Her temsile dayandırılan sınıflandırıcılar ağırlıklı doğrusal toplamalarına göre birleştirildiklerinde, en iyi ayrık sınıflandırıcıdan %20 daha iyi tanıma performansı gösterdiği görülmüştür (Torre vd., 2005).

Eğitim kümesinde kişi başına tek görüntü olduğunda, özellik çıkarımı ve öğrenme evrelerinden ziyade görüntü temsiline ve yüz tanıma sisteminin benzerlik ölçütlerine dikkat çeken bir çalışmada, Gabor-tabanlı ABA için Beyazlatılmış Kosinüs Benzerlik Ölçütü yöntemi sunulmuştur (Deng vd., 2005). Yöntemin, eğitim kümesi ve farklı aydınlatma koşullarına, yönüne ve yüz ifadelerine göre oluşturulmuş iki test kümesi şeklinde üçe bölünmüş CAS-PEAL veritabanında (Gao vd., 2004) test edildiğinde ABA özellikleri, Öklid ve Mahalanobis mesafelerine göre daha iyi sonuç verdiği görülmüştür. Kullanılan veritabanındaki eğitim görüntüleri, doğal ifade ve kontrollü aydınlatma koşullarında alındığından, veritabanında tek görüntü olduğunda, ABA sınıf-ıçi dağılım matrisinin elde edilememesinden etkilenmez. ABA tarafından elde edilen varyasyon

sınıflar-arası dağılımı verir, bu da TDA' nın ayırt edici özellikleri çıkarabileceğinin göstergesidir (Deng vd., 2005).

Tek görüntü problemine çözüm olarak her eğitim görüntüsü için yeni temsiller oluşturmaya dayalı görüntü pertürbasyonu tabanlı bir yöntem de Martinez tarafından sunulmuştur (Martinez, 2002). Yüz görüntülerine ait özellik vektörlerini ait olmadıkları sınıfa yakınsatan küçük lokalizasyon hatalarına, yüz görüntülerinin kısmen kapalı olması ve yüz ifadelerinin farklılık göstermesi problemlerine çözüm olarak geniş ve bu farklılıkları içeren eğitim veri kümeleri kullanılır. Diğer bir ifadeyle, eğitimde kullanılacak sınıf başına düşen örnek sayısı, özellik uzayının boyutuyla doğru orantılıdır. Bu oran, eğitimde kullanılan sınıf başına görüntü sayısının, görüntü vektör boyutunun en az 10 katı olmasını gerektirir (Jain ve Chandrasekaran, 1982). Tek görüntü problemine çözüm olarak yeni temsiller üretilmesi, aslında yüzün ön işleme aşamasında kesin olmayan lokalizasyon problemine çözüm olarak farklı temsiller oluşturulmasıdır (Tan vd., 2006). Bunu da yüz görüntüsüne 2-boyutlu uzayda pertürbasyon uygulayarak yani yatayda ve dikeyde koordinat değerlerinin her değişiminde yeni bir yüz görüntüsü temsili üreterek yani bu pozisyondaki lokalizasyon hatasını hesaba katarak yaparlar. Bu ön işleme aşamasından sonra da özellik çıkarımı ve tanıma için standart özyüz tekniği kullanılır. Sunulan bu yöntemin, veritabanında kişi başına tek görüntü olduğu durumlarda, tam olmayan lokalizasyon, kısmen kapalı ve ifade farklılıklarına sahip yüz görüntüleri için standart ABA yöntemine göre daha iyi sonuç verdiği görülmüştür (Martinez, 2002).

Bahsedilen görünüme dayalı yöntemlerde, yüz görüntülerini temsil etmek üzere görüntünün piksel değerlerinin sıralanmasıyla oluşan bir tane özellik vektörü kullanılır ve test görüntüsünü sınıflandırmak üzere genelde Öklid mesafe ölçütü kullanılır. Bu yüzden, bu yöntemler, yüz görüntülerinde meydana gelebilecek ifade biçimlerine, aydınlatmaya, poza ve kısmen kapalılığa dayalı görünüm değişikliklerine büyük ölçüde duyarlıdır. Bu hassasiyeti azaltmak için metrik olmayan mesafe ölçümleri kullanılır (Jacobs vd., 2000). Bu problemi çözmek için başka bir yol da, görünümdeki değişimlere bütünsel özellikler kadar duyarlı olmayan bölgesel yüz özelliklerinin kullanılmasıdır (Tan vd., 2006).

Daha sonra geliştirilen yöntemlerde bölgesel kısımlardan bütünsel bilgiyi de elde etmeye çalışan algoritmalar geliştirilmeye başlanmıştır. Martinez tarafından sunulan

(Martinez, 2002) yeni temsiller oluşturmaya dayalı görüntü pertürbasyonu tabanlı yöntemde, görüntü pertürbasyonu yöntemi ile oluşturulan yeni temsiller bölgelere ayrılır ve her yüzün aynı pozisyonundaki bölgesel alanlar, yüz alt uzaylarına gruptandırılır. Bu bölgesel olasılıklı yöntemde, her bir altuzay, ayrı Gaussian dağılımıyla temsil edilmiştir. Bu yöntemin genişletilmiş bir versiyonu ise Tan ve arkadaşları tarafından sunulmuştur (Tan vd., 2005). Bu yöntemde, her yüz altuzayı, Özdüzenleyici Haritalar (Kohonen, 1997) ile temsil edilmiştir. Özdüzenleyici haritalar kullanıldığında, orijinal yüz görüntüsü üzerindeki gürültü elimine edilebilmiş ve algoritmanın gözetimsiz karakteristiğinden ötürü, örnek boyutunun çok küçük olduğu durumlarda bile, bölgesel yüz özelliklerinden önemli bilgiler çıkartılabilmektedir.

Bölgesel özelliklerin kullanıldığı başka bir algoritma da tek görüntü durumu için sınıf-içi dağılımının hesaplanmadığı DAA yöntemi üzerine geliştirilmiştir (Huang vd., 2003). Beş bölgeye ayrılan yüz görüntüsü dört yönde hareket ettirilir; böylece tek görüntü problemine çözüm olarak daha çok örnek üretilirken, yüz algılamadaki lokalizasyon problemi (Martinez, 2002) de çözülür. Veritabanında tek görüntü olduğu durumlarda benzer bir yöntem de Chen ve arkadaşları tarafından sunulmuştur (Chen vd., 2004). Yüz görüntüsü, boyutları aynı olmak üzere alt görüntü bloklarına ayrılır; böylece her sınıfın birden fazla eğitim görüntüsü olduğu bir küme elde edilir ve FDAA uygulanabilir hale gelir. Literatüre bakıldığında FDAA yöntemini uygulanabilir hale getirmek için tek yüz görüntüsünü bloklara ayırma tekniğini kullanan bir yöntem de Yin ve arkadaşları tarafından sunulmuştur (Yin vd., 2006). Çalışmalarının sonucunda geliştirilen algoritmanın, genişletilmiş $(PC)^2A$ ve TDA pertürbasyonuna göre daha iyi sonuç verdiği görülmüştür.

Li ve arkadaşları eğitim için kullanılan tek görüntüyü alt görüntülere bölüp, bunlardan özellik çıkarma işlemini gerçekleştirmişlerdir. Özellik çıkarımı için Ortak Vektör Yaklaşımına (Gülmezoğlu vd., 1999) izomorfik görüntülemeye yola çıkarak yeni bir formül sunmuşlardır. Her bir tek yüz görüntüsü için, o yüze ait alt yüzlerden elde ettikleri ortak vektörleri, ortak alt yüzler olarak nitelendirmişlerdir. (Li vd., 2007).

Veritabanında tek görüntü olduğu durumlarda, sınıf-içi ve sınıflar-arası dağılım matrislerini oluşturmak için eldeki görüntü matrisini bloklara ayırmak yerine, görüntüyü TDA ile taban görüntülerine ayrıştırıp FDAA uygulayan bir yöntem Gao ve arkadaşları tarafından geliştirilmiştir. Burada yüz görüntüsü, genel görünümünü veren kısım ile fark


kısmı olmak üzere TDA ile ikiye ayrıştırılmıştır. TDA sonucundaki büyük tekil değerlere karşılık gelen yüksek-enerjili taban görüntüleri, görüntünün genel görünümü hakkında daha çok bilgi verir. Geriye kalan daha az-enerjili taban görüntüleri ise orijinal görüntü ile bu yüksek-enerjili taban görüntüleri arasındaki farktan oluşan kenarlardaki görüntülerdir (Gao vd., 2008). Sınıf-içi farklılıklar daha çok görüntünün kenar bölgelerinde öne çıktıklarından, bu az-enerjili taban görüntüleri sınıf-içi varyasyonları yansıtmak için kullanılırken, genel görünüm hakkında bilgi veren taban görüntüleri de sınıflar-arası dağılım matrisinin hesabında kullanılmıştır.

Bölgesel yöntemlere bakıldığında bunların aydınlatma, kısmen kapalılık, ifade farklılıkları gibi görüntü varyasyonlarından bazılarını karşı gürbüz olurken, diğerlerine çözüm üretmedikleri görülür. Örneğin Kanan ve Moin yüzün bütünsel bilgisi yerine bölgesel bilgisini içeren bölümlere ayrılmış yüz görüntüsünden faydalanarak tek görüntüden kısmen kapalı yüzleri tanıyan bir yöntem sunmuşlardır (Kanan ve Moin, 2009). Yöntemlere bakıldığında, bölgesel ve bütünsel özelliklerin ayrı değişim faktörlerine duyarlı olduğu görülür, örneğin aydınlatma koşullarındaki değişimler bütünsel özellikleri daha çok etkilerken, ifadedeki değişimler daha çok bölgesel özellikleri etkiler (Tan vd., 2006). Kim ve arkadaşları ise sınıf başına ancak birden fazla görüntü olduğu durumlar için birleştirilmiş altuzay yöntemini sunmuşlardır. Yüzün bütününe ya da bir kısmına DDA uygulayarak, tanıma için bütünsel ve bölgesel özellikleri elde etmişlerdir. Birleştirilmiş alt uzay, yüz ve yüzün bölümlerine ait özdeğerler arasından seçilen büyük özdeğerlere karşılık gelen izdüşüm vektörleriyle oluşturulmuştur (Kim vd., 2005).

2. SAYISAL GÖRÜNTÜ

Görüntünün genel olarak tanımı yapılacak olursa, $f(x,y)$ olarak adlandırılan 2-boyutlu bir ışık-yoğunluk fonksiyonuna karşılık gelir (Gonzalez ve Woods, 1992). Bu f fonksiyonunun değeri ya da büyüklüğü, uzaysal koordinatlar olan (x,y) deki görüntünün yoğunluğunu diğer bir ifadeyle de görüntünün bu noktadaki parlaklığını verir. Işık da enerjinin bir formu olmasından dolayı, $f(x,y)$ fonksiyonunun değeri sonlu ve sıfır olmayan bir değerdir. Şekil 2.1.'de sayısal bir görüntü için koordinat eksenleri verilmiştir.

$$0 < f(x,y) < \infty \quad (E.2.1)$$



Şekil 2.1. Sayısal bir görüntü için koordinat eksenleri.

Aslında her gün algıladığımız görüntüler, nesnelerden yansıyan ışığın bir sonucudur. $f(x,y)$ fonksiyonunun temel yapısı aydınlanma ve yansımaya bileşenleri ile yani yüzeye düşen ışık miktarı ve yüzeydeki nesnelerden yansıyan ışık miktarı ile nitelendirilir. Aydınlanma bileşeni $i(x,y)$ ve yansımaya bileşeni $r(x,y)$ ile gösterilirse, $f(x,y)$ bu iki fonksiyonun çarpımı şeklinde tanımlanır.

$$f(x,y) = i(x,y)r(x,y) \quad (E.2.2)$$

Aydınlanma ve yansımaya bileşenlerinin teorik sınırları aşağıda belirtildiği gibidir.

$$0 < i(x,y) < \infty \quad (E.2.3)$$

$$0 < r(x,y) < 1 \quad (E.2.4)$$

Aydınlanma bileşeninin yapısı ışık kaynağı tarafından belirlenirken, yansımaya bileşeninin yapısı ise yüzeydeki nesnelerin özellikleri tarafından belirlenir.

Monokrom bir görüntünün (x,y) koordinatlarındaki yoğunluk fonksiyonu olan f' 'e, görüntünün bu noktadaki gri seviyesi (l) denirse, l aşağıda verilen aralıktadır.

$$L_{min} \leq l \leq L_{max} \quad (E.2.5)$$

Teoride, L_{min} pozitif ve L_{max} sonlu olmalıdır. Pratikte ise $L_{min} = i_{min}r_{min}$ ve $L_{max} = i_{max}r_{max}$ olur. $[L_{min}, L_{max}]$ aralığı gri skala olarak adlandırılır. Pratikte ise bu aralık sayısal olarak $[0, L]$ aralığına kaydırılmıştır ve $l=0$ siyah, $l=L$ ise beyaz olarak değerlendirilir. Bu aralıkta diğer tüm ara değerler ise siyahtan beyaza sürekli olarak değişen grinin tonlarıdır.

Analog bir görüntüyü sayısal olarak ifade edebilmek için çözünürlük kavramı kullanılır. Sayısal görüntü piksellerden diğer bir deyişle noktalardan oluşur. Bir resim $m \times n$ şeklinde bir çözünürlükle ifade ediliyorsa, m yataydaki, n de düşeydeki piksel sayısıdır ve görüntüde toplam $m*n$ adet piksel vardır. Görüntüdeki her piksel, bir sayıyı ya da bir parlaklık değerini gösterir.

Görüntüdeki, her piksel için kullanılan bit sayısı b olarak ifade edilirse, sayısallaştırılmış görüntüyü depolamak için gerekli bit sayısı B aşağıda verildiği gibidir.


$$B = m \times n \times b \quad (E.2.6)$$

Örneğin, 128×128 çözünürlükte, 64 gri seviyeye sahip bir görüntüyü depolamak için $128 \times 128 \times 6 = 98304$ bit gerekir.

Şekil 2.2(a)'da bir film aktrisinin 726×1024 çözünürlükteki ve her pikselin alabileceği değer 0-256 arasında olan bir resmi verilmiştir. Şekil 2.2(b)-(e)'de ise bu resmin uzaysal çözünürlükleri azaltılmış halleri verilmiştir. Resmin uzaysal çözünürlüğü, $n = 1024$ 'ten $n = 512, 256, 128$ ve 64 olacak şekilde 1:2 oranında azaltılmıştır. Bütün durumlarda gri seviyelerin sayısı 256 olarak sabit tutulmuştur. Şekil 2.2(b) resmin uzaysal çözünürlüğü 363×512 boyutuna düşürülmüş şeklidir. Orijinal görüntü ile olan farkı görmek görsel olarak imkânsızdır. İki resim karşılaştırılırsa, fotoğrafın grenliğinde görülemeyecek derecede bir azalma ve özellikle arka plan ve çene çizgisinde netlikte ufak bir azalma meydana gelmiştir. Uzaysal boyutun azaltılması sonucundaki etkiler, boyut Şekil 2.2(d)-(e) görüntülerinde daha gözle görülebilir biçimdedir.



(a)




Şekil 2.2. Uzaysal çözünürlüğün düşürülmesinin etkisi (a) 726×1024 boyutunda orijinal görüntü (b) 363×512 (c) 182×256 (d) 91×128 (e) 46×64 boyutundaki görüntüsü.

Uzaysal çözünürlük yakınlaştırma ve daraltma yolu ile değiştirilebilir. Uzaysal çözünürlüğü değiştirme biyomedikal görüntü işleme, sayısal kameralar ve astronomik görüntüler gibi birçok alanda uygulamaya sahiptirler. Yakınlaştırma ve daraltma, sayısal görüntüyü üst-örnekleme ve alt-örnekleme işlemidir. Yakınlaştırma işlemi, yakınlaştırılmış görüntüdeki her piksele, orijinal görüntüdeki en yakın pikselin gri seviye değerini atayan en yakın komşu interpolasyonu yöntemi ya da orijinal görüntünün en yakın 2'ye 2 komşuluğundaki piksellerin gri seviye değerlerinin ağırlıklı ortalamasını atayan bilineer interpolasyon yöntemi ile yapılabilir. Şekil 2.2(b)-(e)'deki görüntüler en yakın komşu interpolasyonu yöntemi ile oluşturulmuştur.

Piksel başına düşen bit sayısının artması, gri-seviye görüntülerinin daha iyi bir kalitede olmasını sağlar. Görüntüdeki pikseller, ne kadar çok bit ile temsil edilirse, yani görüntünün gri-seviyesi ne kadar yüksek olursa, görüntüdeki detaylar arasındaki geçiş o kadar düzgün olur. Bu sayede gözün algıladığı görüntü o kadar gerçeğe yakındır.

Şekil 2.3(a) bir aktörün 300×300 çözünürlükteki 8-bit orijinal görüntüsüdür. Şekil 2.3(b)'de bir görüntüdeki gri seviyelerin sayısını temsil etmek için kullanılan bit sayısının azaltılmasının etkisini göstermek için orijinal görüntünün farklı seviyelerdeki

görüntüleri verilmiştir. Bu görüntülerde uzaysal çözünürlük 300×300 boyutunda sabit tutulurken, gri-seviye çözünürlüğü 256'dan 2'ye 1:2 oranında, diğer bir deyişle piksel başına düşen bit sayısı 8'den 1'e azaltılmıştır.



Şekil 2.3. Gri seviye değerlerinin azaltılmasının etkisi (a) 300×300 boyutundaki orijinal görüntü (b) 300×300 boyutundaki ve gri seviye değerleri 256, 128, 64, 32, 16, 8, 4 ve 2 olan görüntüler.

Görüntüyü oluşturan pikseller basitçe 0 ve 1 değerlerinden oluşabilir. Bu tür bir resme ikili resim denir. Görüntüyü oluşturan her bir piksel değerinin alabileceği renk aralığı vardır. Örneğin görüntüdeki her piksel için 1 bit kullanılırsa, bu piksel $2^1 = 2$ adet renk yani siyah ve beyaz renklerini alabilir.

Renkli sayısal görüntülerde ise, her bir piksel için 24 bit kullanılır, böylece ana renkler olan kırmızı, yeşil ve mavi için 8'er parçalı (8 bitlik) 3 bölüm oluşturulur. 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.

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

Sayısallaştırılmış 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. Görüntünün bilgisayar ortamına uygun bir hale dönüştürülmesi için yaygın olarak kullanılan bazı görüntü formatları vardır. Bunlardan bazıları BMP, JPEG, GIF ve TIFF görüntü formatlarıdır.

BMP (bitmap) en temel resim formatıdır ve birbirinden farklı bir kaç türü vardır. Bu formatta, MS-Windows ve X-Windows kullanıcıları için belirgin farklar vardır. X-Windows üzerindeki BMP formatı sadece 2 rengi desteklerken, MS-Windows üzerinde BMP, 16 ya da daha çok renk kaydedebilen ve herhangi bir sıkıştırma yapmayan oldukça hızlı bir formattır.

GIF formatı, internet üzerinde yaygın olarak kullanılan bir format olup, az sayıda renk içeren (1 ile 8 bitlik) dokümanlarda oldukça iyi sıkıştırma sağlar. Telefon hatları üzerinden iletiyi hızlı sağlamak için Lempel-Ziv-Welch (LZW) sıkıştırma yöntemini kullanmaktadır.

JPEG formatı gerçek renk değerlerini içeren bir resim formatıdır. Bu format ayarlanabilir kayıplı sıkıştırma kullanır, dolayısıyla JPEG verisinden okunan görüntü ile veriyi yaratmak için kullanılan görüntü aynı değildir. Ancak, kayıplar insan görme sisteminin daha az önem verdiği detaylarda gerçekleştiği için çoğu zaman fark edilmez.

TIFF formatı ise, farklı işletim sistemleri ve uygulamalar arasında kayıpsız ve esnek bir dosya değiş tokuşu sağlaması nedeniyle tüm çalışmalar için uygun bir format olarak bilinir. TIFF formatı, RGB, CMYK, LAB gibi neredeyse tüm renk birimlerini destekler. TIFF'in desteklediği pek çok sıkıştırma programı olmasına karşın en çok kullanılanı LZW sıkıştırma yöntemidir.

3. TEZ KAPSAMINDA TEMEL ALINAN YAKLAŞIMLAR VE TEK GÖRÜNTÜ PROBLEMİNDE TEKİL DEĞER AYRIŞIMINA DAYALI ORTAK MATRİS YAKLAŞIMI

Bu tez çalışmasında son yıllarda yüz tanıma konusunda araştırmacıların dikkatini çeken tek görüntü problemi üzerine gidilmiş ve tek görüntü kullanılarak yüz tanıma yöntemleri çalışılmıştır. Önceki bölümlerde bahsedildiği gibi eğitimde tek görüntü olduğu durumlarda bazı çok bilinen yöntemlerde ciddi performans düşüşleri yaşanırken sınıf-içi dağılım matrisinin hesabını gerektiren yöntemler ise hiç kullanılamamaktadır.

Bu tez çalışmasında sınıf-içi dağılım matrisinin hesabını gerektiren Ortak Vektör (OV) Yaklaşımının (Gülmezoğlu vd., 1999) iki boyuta genişletilmesi ile elde edilen Ortak Matris (OM) Yaklaşımı (Turhal vd., 2005) yönteminin eğitimde tek görüntü durumunda çalışabilmesine yönelik bir algoritma geliştirilmiştir. Aşağıdaki bölümlerde öncelikle geliştirilen algoritmaya temel olan yöntemler açıklanmış ve daha sonra geliştirilen algoritma verilmiştir.

3.1.Ortak Vektör Yaklaşımı

Ortak Vektör Yaklaşımı ilk olarak Gülmezoğlu ve arkadaşları tarafından bir boyutlu ses sinyallerinin tanınması üzerine geliştirilmiştir (Gülmezoğlu vd., 1999). Bu yöntemde, her sınıftaki örnekler arası farklılıklar kaldırılarak eğitim kümesindeki kelimelere ait tüm vektörlerin ortak özelliklerinin çıkarılması üzerine çalışılmıştır. Bu çalışmada, çevresel etkiler, kişisel farklılıklar, faz farkları gibi istenmeyen bilgilerin kaldırılması amaçlanmıştır. Sundukları bu yöntemde bireysel farklar, bir referans vektörünün diğer vektörlerden çıkartılmasıyla elde edilmiş ve fark vektörleri Gram-Schmidt ortogonalleştirme yöntemi ile ortogonal vektör bazı elde etmek üzere kullanılmıştır. Ortak vektör ise, eğitim kümesinden bir vektörün, ortogonal vektörlere izdüşümünün kendisinden çıkarılması ile elde edilmiş ve her eğitim kümesi için elde edilen ortak vektörün tek olduğu yani çıkartılan referans vektörü değişse de ortak vektörün değişmeyeceği gösterilmiştir. Hangi sınıfa ait olduğu belirlenecek olan bir test vektörü geldiğinde ise benzer şekilde bu vektörün ortonormalleştirilen farklılık alt uzayına olan iz düşümleri kendisinden çıkarılır ve elde edilen bu vektör "Kalan Vektör"

olarak adlandırılır. Sınıflandırmaya sınıflara ait ortak vektörler ile test görüntüsüne ait kalan vektör karşılaştırarak karar verilir.

Bu tezde kullanılan, aynı zamanda bu yaklaşımın 2-boyuta genişletilmiş hali olan Ortak Matris Yaklaşımının da temelini oluşturan bu yöntemin matematiksel yapısı aşağıda verildiği gibidir.

Kelimeler $\mathbf{R}^n$ 'de n -boyutlu vektörler ile ifade edilebilir. n -boyutlu lineer bağımsız vektörler $a_1, a_2, \dots, a_m \in \mathbf{R}^n, m < n$ olsun. Burada eğitim kümesini de oluşturacak olan her a_i ($i = 1, \dots, m$), kelimelerden birinin sınıfına aittir ve (m) de konuşmacı yani sınıf sayısını gösterir (Gülmezoğlu vd., 1999).

Her a_i , kelimelerden birinin ait olduğu sınıf ortak özelliklerini temsil eden bir ortak vektör (x) ile i 'inci konuşmacının özelliklerini temsil eden fark vektörünün ($a_{i,fark}$) toplamı şeklinde ifade edilir.

$$\begin{aligned} a_1 &= x + a_{1,fark} \\ a_2 &= x + a_{2,fark} \\ &\vdots \\ a_m &= x + a_{m,fark} \end{aligned} \tag{E.3.1}$$

Daha önce belirtildiği gibi bir sınıfa ait vektörler arasında farklar bulunmaktadır ve her sınıfa ait bu farklar aşağıda verildiği şekilde gösterilir. Her sınıfa ait ilk vektör olan a_1 çıkartılan referans vektörü olarak seçilirse;

$$\begin{aligned} b_1 &= a_2 - a_1 \\ b_2 &= a_3 - a_1 \\ &\vdots \\ b_{m-1} &= a_m - a_1 \end{aligned} \tag{E.3.2}$$

elde edilir. Burada b_i ($i = 1, \dots, m - 1$) fark vektörleri de lineer bağımsızdır (Gülmezoğlu vd., 1999).

$A = \{b_1, b_2, \dots, b_{m-1}\}$ kümesi tarafından taranan altuzay B ile gösterilirse, $B = \text{span } A = \text{span } \{b_1, b_2, \dots, b_{m-1}\}$ olur. Bu durumda A kümesi B uzayı için bir taban oluşturur ve B altuzayı, $\{b_1, b_2, \dots, b_{m-1}\}$ 'in olası tüm lineer kombinasyonlarından elde edilebilir. B uzayı, $a_1, a_2, \dots, a_m$ vektörlerinin farklılık altuzayı olarak adlandırılır.

$$\langle z_i, z_j \rangle = \delta_{ij} = 1 \text{ eğer } i = j \text{ ise} \quad (\text{E.3.3})$$

$$\langle z_i, z_j \rangle = \delta_{ij} = 0 \text{ eğer } i \neq j \text{ ise} \quad (\text{E.3.4})$$

Yukarıda verilen ifadeleri sağlayan $\{z_1, z_2, \dots, z_{m-1}\}$ ortonormal vektör kümesi Gram-Schmidt yöntemi kullanılarak bu tabandan elde edilebilir.

a_i 'nin farklılık altuzayı B 'nin ortonormal bazına izdüşümlerinin toplamı $\bar{a}_i$ olarak gösterilirse;

$$\bar{a}_i = \langle a_i, z_1 \rangle z_1 + \langle a_i, z_2 \rangle z_2 + \dots + \langle a_i, z_{m-1} \rangle z_{m-1} \quad (i = 1, 2, \dots, m) \quad (\text{E.3.5})$$

Formülü ile elde edilir. E.3.1'de verildiği üzere ortak vektör,

$$\tilde{a}_i = \tilde{a}_{ortak} = a_i - \bar{a}_i \quad (\text{E.3.6})$$

elde edilir. Aynı kelimeye ait vektörler kümesi $a_1, a_2, \dots, a_m$ 'nin ortak vektörü olarak adlandırılan $\tilde{a}_{ortak}$ 'ın i indeksinden bağımsız ve her sınıf için tek olduğu çalışmalarında ispatlanmıştır (Gülmezoğlu vd., 1999).

Test kümesinden bir vektör (a^{test}) geldiğinde, yukarıdaki işlemlerin aynısı bu vektöre de uygulanır. a^{test} vektörünün aynı B farklılık altuzayı üzerindeki izdüşümü kendisinden çıkarılarak kalan vektör olarak adlandırdıkları a_{kalan}^{test} vektörü elde edilir. Bu vektörün diğer sınıflara ait ortak vektörlere olan Öklid uzaklığına bakılarak, hangi sınıfta en küçük uzaklığı veriyorsa o sınıfa aittir yorumu yapılır.

$$w = \operatorname{argmin}\{\|a_{kalan}^{test} - \tilde{a}_{ortak}\|^2\} \quad (\text{E.3.7})$$

Ortak vektör yaklaşımını, yüz tanımaya uyarlayan, Ayırt Edici Ortak Vektör yaklaşımı da Çevikalp ve arkadaşları tarafından sunulmuştur (Çevikalp vd., 2005). Bu çalışmada, ortak vektörleri elde etmek için her sınıfın kendi dağılım matrisini kullanmak yerine, tüm sınıfların sınıf-içi dağılım matrisi kullanılmıştır. Ayrıca altuzay yöntemlerine dayalı alternatif bir algoritma da sunmuşlar ve Gram-Schmidt ortogonalleştirme prosedürü ile ortak vektörleri elde etmişlerdir. Bu çalışmada her bir sınıfa ait ortak vektörün, o sınıftaki her görüntü için aynı ve tek bir ortak vektör olduğu da gösterilmiş ve bu yöntemin eğitim kümesindeki görüntü sayısının artmasıyla beraber, Fisherface, Özyüzler, Direkt-DAA gibi yöntemlere nispeten daha etkin olduğu gösterilmiştir.

3.2. Ortak Matris Yaklaşımı

İşlem karmaşasının azaltılması, işlem zamanının kısaltılması gibi avantajlar sağlaması nedeniyle ve küçük örnek boyutu problemi ve yüz tanımadaki boyut

problemini çözmek amacıyla, ortak vektör yaklaşımının iki boyutlu görüntü matrisleri için genişletilmiş bir versiyonu olan Ortak Matris yaklaşımının kullanıldığı bir yüz tanıma algoritması sunulmuştur (Turhal vd., 2005).

Bir kişiye ait yüz görüntüleri arasında, aydınlatma, farklı poz ifadeleri, yüzde gözlük, atkı takılması, sakallı olma gibi durumlar nedeniyle farklılıklar oluşur. Ne tür farklılıklar olursa olsun, bu yüz görüntüleri aynı kişiye ait olduklarından, hepsinde ortak olan özellikler de vardır. Bu fikirden yola çıkarak Ortak Matris Yaklaşımında amaç, her sınıfı temsil etmek üzere, yüz görüntüleri arasındaki benzerlikleri gösteren bir matris bulmaktır. Sınıfları temsil edecek ortak matris, iki şekilde hesaplanır. İlkinde Gram-Schmidt ortogonalleştirme prosedürü uygulanarak, ikincisinde ise sınıf-içi dağılım matrisi kullanılarak ortak matris hesaplanır.

3.2.1. Gram-Schmidt ortogonalleştirme yöntemi ile OM elde edilmesi

Bu algorithmada, bir sınıf için oluşturulan farklılık altuzayında, Gram-Schmidt ortogonalleştirme prosedürü matrisler üzerine uygulanır. Her sınıfı temsil edecek ortak matrisin hesaplanmasında o sınıfa ait yüz görüntü matrisleri kullanılır. O sınıfa ait görüntülerden herhangi biri referans görüntüsü olarak seçilir ve sınıftaki diğer yüz görüntülerinden çıkarılarak bir farklılık altuzayı oluşturulur.

A_i^c , bir kişiye ait $m \times n$ boyutlu görüntü matrislerinden biri olsun. Burada c , eğitim kümesindeki sınıfları, i de o sınıftaki görüntünün indisini gösterir. A_i^c matrisi aşağıda verildiği şekliyle gösterilebilir.

$$A_i^c = \begin{bmatrix} a_{(11)i}^c & \cdots & a_{(1n)i}^c \\ \vdots & \ddots & \vdots \\ a_{(m1)i}^c & \cdots & a_{(mn)i}^c \end{bmatrix} \quad (E.3.8)$$

Eğitim kümesinde C adet sınıf ve her sınıfta da l adet yüz görüntüsü varsa, B_i^c fark matrisleri aşağıda verilen formülle hesaplanır.

$$B_i^c = A_{i+1}^c - A_1^c, \quad i = 1, 2, \dots, l - 1 \quad (E.3.9)$$

Oluşturulan bu farklılık altuzayına Gram-Schmidt ortogonalleştirme prosedürü (Edwards ve Penny, 1988) uygulanarak, ortonormal taban matrisleri kümesi $\{Z_1^c, \dots, Z_{l-1}^c\}$ elde edilir. Bu sınıfa ait bir yüz görüntü matrisi, bu taban matrislerinin lineer birleşimleri şeklinde ifade edilebilir. Sınıfları temsil edecek ortak matrisler A_{com}^c , o sınıftaki herhangi bir yüz görüntüsünün bu tabanlar üzerine izdüşümünün, kendisinden çıkarılmasıyla elde edilir.

$$A_{com}^c = A_i^c - \langle A_i^c, Z_1^c \rangle Z_1^c - \dots - \langle A_i^c, Z_{l-1}^c \rangle Z_{l-1}^c \quad (E.3.10)$$

Boyutu $m \times n$ olan A matrisi ile Z matrisinin iç çarpımı aşağıda verildiği gibidir.

$$\langle A, Z \rangle = \sum_{i=1}^m \sum_{j=1}^n a_{ij} z_{ij} \quad (E.3.11)$$

Test görüntüsü A_{test} geldiğinde ise, her sınıf için hesaplanan taban matrisleri üzerine izdüşürülüp, kendisinden çıkarılır ve bu test görüntüsünün, o sınıf içindeki kalan matrisi A_{kalan}^c elde edilir. Bu işlem her sınıf için tekrarlanır.

$$A_{kalan}^c = A_{test} - \langle A_{test}, Z_1^c \rangle Z_1^c - \dots - \langle A_{test}, Z_{l-1}^c \rangle Z_{l-1}^c \quad (E.3.12)$$

Sınıflandırma için, Öklid mesafe ölçütüne bakılır. Test görüntüsünün o sınıf içindeki kalan matrisi ile o sınıfı temsil eden ortak matris arasındaki Öklid mesafesi, hangi sınıfta en küçük ise, test görüntüsü o sınıfa aittir yorumu yapılır.

$$w = \arg \min_{1 \leq c \leq C} \{\|A_{kalan}^c - A_{com}^c\|^2\} \quad (E.3.13)$$

3.2.2. Sınıf-içi dağılım matrisini kullanarak OM elde edilmesi

Bu algorithmada, her sınıf için elde edilen sınıf-içi dağılım matrisinin (S_W^c) özdeğer ve özvektörleri hesaplanarak, bu özvektörler tensor'lerin düzleştirilmesi yöntemi ile orijinal görüntü ile aynı boyutta matrisler haline getirilirler. Bir sınıfa ait olan ve içlerinde sıfır özdeğerlere karşılık gelen bu özmatrisler üzerine, o sınıftaki herhangi bir görüntü izdüşürülerek, o sınıf için ortak matris elde edilir. Bu yol ile hesaplanan ortak matris, görüntü farklılık altuzayında Gram-Schmidt ortogonalleştirme prosedürü uygulanarak elde edilen ortak matris ile aynıdır.

Herhangi bir c sınıfına ait $m \times n$ boyutlu görüntü matrisi A_i^c ve $(\vec{a}_{ji}^c, j = 1, \dots, m)$ A_i^c görüntü matrisinin $1 \times n$ boyutundaki satır vektörleri ile gösterilsin.

$$A_i^c = \begin{bmatrix} \vec{a}_{1i}^c \\ \vdots \\ \vec{a}_{mi}^c \end{bmatrix} \quad (E.3.14)$$

Daha sonraki aşamada her sınıf için $\bar{A}^c$ ortalama matrisi bulunur ve o sınıftaki bütün görüntü matrislerinden çıkarılır ve yine $m \times n$ boyutundaki ortalama uzaklaştırılmış $\bar{\bar{A}}_i^c$ görüntü matrisi elde edilir.

$$\bar{\bar{A}}_i^c = \begin{bmatrix} \vec{a}_{1i}^c \\ \vdots \\ \vec{a}_{mi}^c \end{bmatrix} - \bar{A}^c = \begin{bmatrix} \vec{a}_{1i}^c \\ \vdots \\ \vec{a}_{mi}^c \end{bmatrix} \quad (E.3.15)$$

Sınıf-içi dağılım matrisi S_W^c ise aşağıda verildiği şekilde oluşturulur.

$$S_W^c = \begin{bmatrix} \sum_{i=1}^m [(\vec{a}_{1i}^c)'(\vec{a}_{1i}^c)]_{n \times n} & \cdots & \sum_{i=1}^m [(\vec{a}_{1i}^c)'(\vec{a}_{mi}^c)]_{n \times n} \\ \vdots & \ddots & \vdots \\ \sum_{i=1}^m [(\vec{a}_{mi}^c)'(\vec{a}_{1i}^c)]_{n \times n} & \cdots & \sum_{i=1}^m [(\vec{a}_{mi}^c)'(\vec{a}_{mi}^c)]_{n \times n} \end{bmatrix} \quad (E.3.16)$$

Daha sonra her sınıf için S_W^c dağılım matrisine ait özdeğer ve özvektörler elde edilir. Sınıf içindeki herhangi bir görüntünün o sınıf için elde edilen sıfır özdeğerlerine ait özvektörler tarafından taranan altuzaya izdüşümü alınarak bölüm 3.2.1’de elde edilen ortak matris elde edilir.

Test görüntüsü geldiğinde ise test görüntü matrisinin her sınıf için kalan matrisi test matrisinin sınıflara ait sıfır özdeğerlere karşılık gelen özvektörler üzerine izdüşürülmesi ile elde edilir. Her sınıf için test görüntüsünün o sınıfa ait kalan matrisi ile o sınıf için bulunan ortak matris arasındaki Öklid mesafesi hangi sınıf için en az ise, test görüntüsünün o sınıfa ait olduğu söylenir.

Söz edilen iki algoritmada da, bir sınıftaki görüntüler arasındaki farklar, oluşturulan altuzayda en aza indirgenerek, sınıf-içi dağılım matrisinin minimize edilmesi amaçlanmıştır.

Ortak vektör yaklaşımından yola çıkarak 2-boyuta genişletilmiş olan Ortak Matris yönteminde, farklılık altuzayının hesaplanması için eğitim kümesinde kişi başına en az iki görüntü bulunması gerekir. Veritabanında kişi başına tek görüntü olduğu durumlarda ise farklılık altuzayının oluşturulamaması ve sınıf-içi dağılım matrisinin elde edilememesinden ötürü, bu yöntemler çalışmazlar. Bu tez çalışmasında geliştirilen algoritma ile kişi başına tek görüntü durumunda bile OM yönteminin çalıştırılması amaçlanmıştır.

3.3. Tez Kapsamında Geliştirilen Algoritma

Bu tez çalışmasının bir kısmında, eğitim kümesinde sınıf başına tek görüntü olması durumunda sınıf-içi dağılım matrisi hesaplanamadığından yüz tanımda başarısız olan ortak matris yöntemi üzerine çalışılmış ve ortak matris hesabında TDA yöntemi kullanılarak tek görüntü problemine çözüm sunulmuştur. Her sınıfta en az iki görüntü olmasını gerektiren ve sınıf-içi dağılım matrisini elde etmede farklılık altuzayını kullanan ortak matris yöntemi, yüz görüntülerinin TDA uygulanarak elde edilmiş sıfır tekil değerlere karşılık gelen vektörler üzerine izdüşürülüp her sınıf için ortak matris elde edilmesi şeklinde geliştirilmiştir.

Aşağıda öncelikle tekil değer ayrışımı açıklanmış arkasından tek görüntü problemi için bu tez çalışmasında geliştirilen algoritma detaylı olarak verilmiştir.

3.3.1. Tekil Değer Ayrışımı

Tekil değer ayrışımı (TDA), birbiriyle uyumlu 3 açıdan değerlendirilebilir (Baker, 2005). Bunlardan ilki, korelasyonlu verileri, orijinal veri parçaları arasındaki çeşitli ilişkileri daha iyi ortaya çıkaran korelasyonsuz veri kümesine dönüştürme yöntemi olarak görülür. İkincisi, TDA hangi verilerin en çok değişim gösterdiği boyutu tanımlama ve sıralama yöntemi olarak kullanılabilir. Üçüncü olarak da, TDA kullanılmasıyla daha az boyut ile orijinal veri noktalarının en iyi tahmininin yapılması mümkündür.

A , $m \times n$ tipinde reel bir matris olsun. Bu koşulda,

$$A = USV^T \quad (\text{E.3.17})$$

Olacak şekilde $m \times m$ tipinde U ve $n \times n$ tipinde V ortogonal matrisleri vardır. Burada S , köşegende olmayan bütün elemanları sıfır ve $s_{11} \geq s_{22} \geq \dots \geq s_{pp} \geq 0$, $p = \min(m, n)$ olan $m \times n$ tipinde bir matristir.

$$U^T U = I_{n \times n} \quad (\text{E.3.18})$$

$$V^T V = I_{p \times p} \quad (\text{E.3.19})$$

S 'nin köşegen elemanları A 'nın tekil değerleri, U 'un sütunları A 'nın sol tekil vektörleri, V^T 'un satırları A 'nın sağ tekil vektörleri olarak adlandırılır. A 'nın tekil değer ayrışımı aşağıdaki lineer birleşim olarak yazılabilir.

$$A = \text{sütun}_1(U)s_{11}\text{sütun}_1(V)^T + \text{sütun}_2(U)s_{22}\text{sütun}_2(V)^T + \dots + \text{sütun}_p(U)s_{pp}\text{sütun}_p(V)^T \quad (\text{E.3.20})$$

A ile ilgili simetrik bir $n \times n$ matris, $A^T A$ matrisidir ve,

$$V(A^T A)V^T = D \quad (\text{E.3.21})$$

olacak şekilde $n \times n$ tipinde ortogonal bir V matrisi vardır. Burada D , $\lambda_1, \lambda_2, \dots, \lambda_n$ köşegen elemanları $A^T A$ matrisinin özdeğerleri olan bir köşegen matristir. Eğer v_j , V 'nin j . sütununu gösterirse,

$$(A^T A)v_j = \lambda_j v_j \quad (\text{E.3.22})$$

olur. Bu ifadenin her iki tarafı soldan v_j^T ile çarpılırsa,

$$v_j^T (A^T A)v_j = \lambda_j v_j^T v_j \quad (\text{E.3.23})$$

olur.

Bu ifade,

$$(Av_j)^T(Av_j) = \lambda_j v_j^T v_j \text{ veya } \|Av_j\|^2 = \lambda_j \|v_j\|^2 \quad (\text{E.3.24})$$

şekli ile yeniden düzenlenebilir. Bir vektörün boyu negatif olmayacağı için $\lambda_j \geq 0$ olduğu elde edilir. $s_{jj} = \sqrt{\lambda_j}$ olarak tanımlanır. V ortogonal bir matris olduğundan sütunlarının her biri birim vektördür.

$$\|v_j\| = 1 \text{ dir. Böylece } s_{jj} = \|Av_j\| \text{ olur.}$$

Aynı şekilde, $A = USV^T$ ise A^T aşağıda verilen eşitlikte belirtildiği gibi olur.

$$A^T = VSU^T \quad (\text{E.3.25})$$

E.3.25'teki ifadenin her iki tarafı da A ile çarpılırsa, aşağıdaki eşitlik elde edilir.

$$A^T A = VSU^T USV^T = VS^2 V^T \quad (\text{E.3.26})$$

Bu eşitliğin iki tarafı da V ile çarpıldığında, $A^T AV = VS^2$ elde edilir. Bu ifadeden de anlaşıldığı üzere, $A^T A$ matrisinin özvektörleri V matrisinin sütun vektörlerini oluşturur. Benzer olarak,

$$AA^T = USV^T VSU^T = US^2 U^T \quad (\text{E.3.27})$$

elde edilir. Bu ifadeden de AA^T matrisinin özvektörlerinin, U matrisinin sütun vektörlerini oluşturduğu açıktır. Bu ifadelerden, S 'deki tekil değerler, AA^T ya da $A^T A$ matrislerinin özdeğerlerinin karekökleridir.

A , $m \times n$ tipinde matris ve B , C de sırasıyla $m \times m$ ve $n \times n$ tipinde tekil olmayan matrisler ise,

$$\text{rank } BA = \text{rank } A = \text{rank } AC \quad (\text{E.3.28})$$

sağlanır. Bu ifadeye dayanarak, A 'nın rankı, A 'nın sıfırdan farklı tekil değerlerinin sayısıdır sonucuna ulaşılır (Kolman ve Hill, 2000). Eğer $\text{rank } A = r$ ise, tekil değer ayrışımını aşağıda verildiği şekilde, indirgenmiş formda yazmak mümkündür.

$$A = U_+ S_+ V_+^T \quad (\text{E.3.29})$$

Bu eşitlikte, S_+ A 'nın r tane sıfır olmayan özdeğerinin olduğu $r \times r$ boyutunda köşegen bir matris olup U_+ ve V_+ matrisleri de U ve V 'nin ilk r sütunlarını içerir. Ayrıca, A 'nın rankı ve sıfırlığı arasında

$$\text{rank } A + \text{sıfırlık } A = n \quad (\text{E.3.30})$$

şeklinde tanımlanan bir esas ilişki vardır. Buradan;

- U 'un ilk r sütunu A 'nın sütun uzayı için ortonormal bir baz,

$$\text{range}(A) = \langle u_1, \dots, u_r \rangle \quad (\text{E.3.31})$$

- V 'nin ilk r sütunu A 'nın satır uzayı için ortonormal bir baz,
- U 'nun kalan $m - r$ sütunu A 'nın sol sıfır-uzayı için ortonormal bir baz,
- V 'nin kalan $n - r$ sütunu da A 'nın sıfır-uzayı için ortonormal bir baz oluşturur.

$$\text{null}(A) = \langle v_{r+1}, \dots, v_n \rangle \quad (\text{E.3.32})$$

Bu ifadelerden yararlanarak aşağıda verilen önemli sonuçlara ulaşılır (Muller vd., 2004).

- A 'nın sütun ve satır uzaylarının her ikisi de r boyutuna sahiptir. A 'nın sıfır-uzayının boyutu $n - r$, sol sıfır-uzayının boyutu da $m - r$ 'dir.
- A 'nın sıfır uzayı, R^n 'de satır uzayının ortogonal tümleyeni ve A 'nın sol sıfır-uzayı da, R^m 'de sütun uzayının ortogonal tümleyenidir.

Tekil değerler, bir çok araştırmada, yüz tanıma ve diğer uygulamaları için özellik vektörü olarak sunulmuştur (Klema, 1980; Wang vd., 2000). Tian ve arkadaşları ise yüz tanıma kullanılan tekil değerlerin uygunluğunu sorgulamış ve yaptıkları çalışmada tekil değerlerin yüz tanıma için çok az kullanışlı bilgi içerdiğini, en önemli bilginin ise TDA'nın iki ortogonal matrisinde kodlandığını göstermişlerdir (Tian vd., 2003). Yaptıkları deneylerin ilkinde A ve B olmak üzere iki görüntü matrisini TDA yöntemi ile ayrıştırıp $A = U_A S_A V_A^T$ ve $B = U_B S_B V_B^T$, S_A ve S_B matrislerini yer değiştirmişlerdir. Bu aşamadan sonra görüntüleri $\hat{A} = U_A S_B V_A^T$ ve $\hat{B} = U_B S_A V_B^T$ ifadelerine göre tekrar oluşturmuşlardır. Bu işlemin sonunda A ve B 'in, oluşan $\hat{A}$ ve $\hat{B}$ görüntülerine aynı kişi olarak algılayacak şekilde çok benzediklerini görmüşlerdir. Bu deneylerini ORL (Samaria ve Harter, 1994) veritabanına uygulamışlar ve tüm durumlarda hemen hemen aynı gözlem sonuçlarını elde etmişlerdir. İkinci olarak ise ORL veritabanı görüntülerine TDA uygulanmış ve tekil değerleri sabit bit tekil değer ile değiştirilerek yeni yüz görüntüleri elde edilmiştir. Tekrar oluşturulan yüz görüntülerinin orijinalleriyle hemen hemen aynı olduğu görülmüş ve bu deneylerin ışığında tekil değerlerin yüz tanıma için uygun bilgiyi içermediği sonucuna varılmıştır.

3.3.2. Geliştirilen Algoritmalar

Bu tez çalışmasında sınıf-içi dağılım matrisinin hesabını gerektiren Ortak Matris Yaklaşımı yönteminin TDA yöntemi kullanılarak eğitimde kişi başına tek görüntü olması durumunda kullanılabilmesini sağlayan bir algoritma geliştirilmiştir. Aşağıdaki

bölmelerde öncelikle geliştirilen algoritma verilmiş daha sonra geliştirilen algoritmanın performansını artırmak için bir yöntem sunulmuştur.

3.3.2.1.TDA tabanlı ortak matris yöntemi

Bir yüz görüntüsü olan $X \in R^{m \times n}$ ve $m \geq n$ olmak üzere aşağıda verildiği şekilde TDA ile ayrıştırılabilir.

$$X = \sum_{i=1}^n \sigma_i u_i v_i^T \quad (E.3.33)$$

Burada u_i ve v_i , sırasıyla sol ve sağ tekil matrisler olarak adlandırılan $U \in R^{m \times m}$ ve $V \in R^{n \times n}$ matrislerinin i 'inci sütunlarıdır. σ_i ise görüntü matrisinin azalan sırada dizilmiş tekil değerleridir ($\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$). Görüntü matrisi X 'in rankı $r = \text{rank}(X)$ ise, X 'in sol sıfır-uzayı, U matrisinin son $(m - r)$ sütunu tarafından ve X 'in sıfır-uzayı da V matrisinin son $(n - r)$ sütunu tarafından taranır.

Yüz görüntü örneklerinin, görüntü matrisinin sıfır uzayına izdüşümü, sıfır tekil değerlere karşılık gelen vektörler üzerine yapıldığından görüntünün genel görünümünü etkilemez ve bu durumda sıfır-uzayı bir sınıfın ortak özelliklerini yansıttığı sınıf-içi dağılım matrisi şeklinde düşünülebilir (Apaydın vd., 2010). Tezde sunulan bu yöntemin adımları özetlenecek olursa:

Adım 1: TDA kullanılarak her sınıfa ait tek eğitim görüntülerinin sıfır-uzayları bulunur.

Adım 2: O sınıfa ait görüntü matrisi X^i , bu sıfır-uzayı üzerine aşağıda verilen eşitliğe göre izdüşürülür ve bu matris i 'inci sınıfa ait ortak matris X_{com}^i olarak adlandırılır.

$$X_{com}^i = X^i - X^i Q Q^T = \bar{Q} \bar{Q}^T X^i \quad (E.3.34)$$

Burada $\bar{Q}$, görüntü matrisinin sıfır-uzayını tarayan ve sıfır tekil değerlere karşılık gelen tekil vektör sütunlarından oluşmuş matris, Q ise sütunları, sıfır olmayan tekil değerlere karşılık gelen ve görüntü matrisinin sütun uzayını tarayan sol tekil vektörleri olan matristir.

Adım 3: Her sınıf için X_{com}^i elde edildikten sonra, toplam dağılım matrisi S_{com} 'u maksimize eden en uygun izdüşüm vektörleri bulunur.

$$S_{com} = \sum_{i=1}^C (X_{com}^i - \varphi_i)(X_{com}^i - \varphi_i)^T \quad (E.3.35)$$

Ortak matrislerin ortalaması φ_i aşağıdaki eşitlikte verildiği gibidir.

$$\varphi_i = \frac{1}{C} \sum_{i=1}^C X_{com}^i \quad (E.3.36)$$

Sonrasında ise ortak matrisler, bulunan vektörler üzerine izdüşürülerek her sınıf için ayırt edici özellik matrisleri elde edilir.

Adım 4: Test görüntüsü geldiğinde ise, E.3.34'te verilen formülü uygulayarak test görüntüsü için kalan matris olarak adlandırılan bir matris elde edilir. Eğitim görüntülerine uygulandığı gibi, bu kalan matris E.3.35'te bulunan en uygun izdüşüm vektörlerine izdüşürülerek test görüntü matrisi için ayırt edici bir özellik matrisi oluşturulur. Test görüntüsü için elde edilen bu ayırt edici matris, sınıflar için aynı yolla bulunan matrislerle Öklid normlarına göre karşılaştırılır ve en yakın olan sınıfa aittir yorumu yapılır.

TDA'ya dayalı Ortak Matris Yaklaşımının geliştirildiği bu çalışmada kodlar MATLAB 2009 programında yazılmış olup, kaba kodu aşağıda verildiği biçimdedir.

```

% Her sınıf için ortak matrisin hesabı, AR-Face veritabanından 37 kişiye ait 50x40
boyutundaki yüz görüntüleri
for i=1:C
    Her bir sınıf için bir yüz görüntüsünü eğitim için kullan
    Sol sıfır-altuzayı için ortonormal baz bul
    Yüz görüntüsünün bu altuzaya izdüşümünü al (E.3.34'ü kullanarak her kişi
    için ortak matris hesapla)
    Toplam ortak matrisi hesapla
end
Ortak matrislerin ortalamasını E.3.36'ya göre hesapla
for i=1:C
    E.3.35'e göre toplam dağılım matrisini hesapla
end
Toplam dağılım matrisinin sıfır-uzayı için TDA ile elde edilen ortonormal baz bul
% T adet test görüntüsü
for i=1:T
    for i=1:C
        Test görüntüsünü al
        for i=1:C
            Eğitim görüntüsünü al
            Ortak matris hesapla
            Ortak matrisin, toplam dağılım matrisini maksimize eden
            vektörlere (sıfır-uzayı için ortonormal baz vektörlerine) izdüşümünü
            al
            İzdüşümden kendisini çıkar ve eğitim görüntüsü için ayırt
            edici özellik matrisini elde et
            Test görüntüsü için E.3.34'ü kullanarak kalan matris hesapla

            Test görüntüsünün toplam dağılım matrisinin sıfır-uzayının
            ortonormal bazına izdüşümünü al
            İzdüşümünden kendisini çıkar ve test görüntüsü için ayırt
            edici özellik matrisini elde et
            Ayırt edici özellik matrisi ile test görüntüsüne ait ayırt edici
            özellik matrisi arasındaki Öklid mesafesini hesapla
        end
    end
    Saklanan öklid uzaklıklarından en küçük olanı bul

    Test görüntüsü o sınıfa aittir şeklinde sınıflandır
end

```

Şekil 3.1. TDA'ya dayalı OM Yaklaşımının kaba kodu.

3.3.2.2. Tek görüntü probleminde tanıma performansının artırılması: birleştirilmiş ortak özellik altuzayı

Yüz tanımada yüzün bütünsel özelliklerinin yanında çeşitli bölgesel özelliklerinin de tanımda etkili olabileceği üzerine bazı çalışmalar yapılmıştır. Pentland ve arkadaşlarının sundukları çalışma bunlardan biridir. Bu çalışmada yüzün göz, burun ve

ağız bölgelerine Karhunen-Loeve dönüşümü uygulayarak bölgesel özellikler elde etmişlerdir (Pentland vd., 1994). Kim ve arkadaşları ise yüzün tüm bütünsel ve bölgesel özelliklerini içeren birleştirilmiş bir altuzay oluşturmuşlardır (Kim vd., 2005). Yüzün ya bütününe ya da bir bölümüne DAA uygulayarak bütünsel ve bölgesel özellikler elde edilmiştir. Bütünsel özellikler, yüzün tümünden bütünsel izdüşüm vektörleriyle, bölgesel özellikler ise göz, burun ve ağız bölgelerine altuzay yöntemlerini uygulayarak oluşturulmuştur. Sınıf başına ancak ikiden fazla sayıda görüntü olduğu durumlar için sunulan bu çalışmalarının Bayes hata analizi çerçevesinde, daha iyi tanıma oranı verdiğini göstermişlerdir.

Bu çalışmadan yola çıkarak, bir önceki bölümde anlatılan TDA tabanlı Ortak Matris Yaklaşımının tek görüntü olduğu durumlarda tanıma performansı artırılması üzerine yüzün hem bütünsel hem de bölgesel bilgisini kullanmaya yönelik bir çalışma yapılmıştır (Apaydın ve Turhal, 2011). Yüz görüntüsünün tümü kullanılarak yüzün bütünsel özellikleri edilmiştir. Bölgesel özellikler ise piksel değişimlerinin en fazla olduğu göz, burun ve ağız bölgelerine ait görüntüler kullanılarak elde edilmiştir. Elde edilen bu özellikler birleştirilerek her sınıf için ortak özellik altuzayı elde edilmiş ve bu altuzay tanımda kullanılmıştır.

Bu bölgelerden yüz görüntüsünün tamamının (**F**-Bölgesi) kullanılması ile bütünsel özellikler (Y_1) elde edilmektedir. Benzer şekilde göz (**E**-Bölgesi), burun (**N**-Bölgesi) ve ağız (**M**-Bölgesi) görüntülerinin kullanımı ile sırasıyla (Y_2), (Y_3) ve (Y_4) özellikleri elde edilir. Yüzün bütünü ve diğer bölgeleri için elde edilen özelliklerin birleştirilmesiyle oluşturulan ortak özellik altuzayında bir görüntü, $\{Y_1, Y_2, Y_3, Y_4\}$ özellik kümesi ile temsil edilmektedir.

Bu altuzaya geçiş, $X = (X_1, X_2, X_3, X_4)$ optimum izdüşüm vektörleri kümesi ile gerçekleştirilmektedir. X kümesinin elemanları sırasıyla **F**, **E**, **N** ve **M** bölgelerinin sıfır uzaylarını geren tekil vektörlerden oluşmaktadır.

A matrisi $m \times n$ boyutlu **F**, **E**, **N**, **M** yüz bölgelerinden herhangi birine ait olan bir görüntü matrisi olsun. Bu görüntüye karşılık gelen optimum izdüşüm vektörleri kümesi X_i 'nin boyutu:

$$m > n \rightarrow m \times (m - n) \quad (E.3.37)$$

$$n > m \rightarrow n \times (n - m) \quad (E.3.38)$$

Şeklinde olur.

Bir test görüntüsünü tanımak için, toplam sınıf sayısı C olmak üzere, öncelikle test görüntüsünün c 'inci ($c = 1, \dots, C$) sınıfa ait ortak özellik kümesi oluşturulur $\{Y_{test,1}^c, Y_{test,2}^c, Y_{test,3}^c, Y_{test,4}^c\}$. Daha sonra test görüntüsünün her bir ortak özelliği ile c 'inci sınıfın karşılık gelen ortak özelliği arasındaki mesafe aşağıdaki formülde verilen D_i^c Öklid normuna göre hesaplanır.

$$D_i^c = \|Y_i^c - Y_{test,i}^c\|_2, \quad i = 1, \dots, 4 \quad (\text{E.3.39})$$

Test görüntüsü için bu şekilde elde edilen mesafe değerleri bir vektör oluşturacak şekilde birleştirilerek test görüntüsünün c 'inci sınıf için ortak mesafe matrisi D^c elde edilir.

$$D^c = \{D_1^c, \dots, D_4^c\} \quad (\text{E.3.40})$$

Test görüntüsünün sınıflandırılması ise görüntünün ortak mesafe matris normunun en küçük olduğu sınıfa atanması şeklinde gerçekleştirilir.

```

% AR-Face veritabanından 37 kişiye ait 50x40 boyutundaki yüz görüntüleri

% F-Bölgesi: Yüzün tamamı, E-Bölgesi: Göz bölgesi, N-Bölgesi: Burun Bölgesi, M-
Bölgesi: Ağız Bölgesi

for i=1:C

    Yüz görüntüsünü E,N,M bölgeleri olarak 15x30, 20x15 ve 15x20
    boyutlarında kes

end

for i=1:C

    F,E,N,M bölgelerine sırasıyla tekil değer ayrışımı uygula

    Bu bölgelerin sıfır alt uzaylarını geren tekil vektörleri bul

    for i=1:4

        F,E,N,M bölgelerine ait tekil vektörler kümesini sırasıyla en uygun
        izdüşüm vektörlerinden oluşan  $X_i$  'ye ata

    end

    Yüz, göz, burun ve ağız bölgelerine ait görüntüleri  $X = (X_1, X_2, X_3, X_4)$ 

    En uygun izdüşüm vektörleri kümesine izdüşürerek  $\{Y_1, Y_2, Y_3, Y_4\}$  ortak özellik
    kümesini elde et

End

% T adet test görüntüsü

for i=1:T

    for i=1:C

        Test görüntüsünün c. sınıfa ilişkin ortak özellik kümesi
         $\{Y_{test,1}^c, Y_{test,2}^c, Y_{test,3}^c, Y_{test,4}^c\}$  'ni elde et

        Test görüntüsünün her bir ortak özelliği ile c. sınıfa karşılık gelen
        ortak özelliği arasındaki Öklid mesafesini E.3.39'da verilen formüle
        göre hesapla

        c. sınıf için E.3.40'da verildiği gibi ortak mesafe matrisi  $D^c$  elde et

    end

    Ortak mesafe matris normunun en küçüğünü bul

    Test görüntüsü o sınıfa aittir şeklinde sınıflandır

end

```

Şekil 3.2. Birleştirilmiş Ortak Özellik Altuzayı Yöntemi'nin kaba kodu.

4. DENEYSEL ÇALIŞMALAR

Geliştirilen algoritmaların tanıma performanslarını değerlendirmek için yapılan deneysel çalışmalarda AR-Face (Martinez ve Benavente, 1998) ve ORL (Samaria ve Harter, 1994) veritabanları kullanılmıştır.

4.1.AR-Face Veritabanı Kullanılan Deneysel Çalışmalar

Martinez ve Benavente'nin hazırladıkları AR-Face veritabanında, 70'i erkek ve 56'sı bayan toplam 126 kişi olmak üzere her kişiye ait toplam 26 adet önden çekilmiş fotoğrafları bulunmaktadır. Ön cepheden alınmış bu yüz görüntüleri; ifade farklılıklarını, farklı aydınlatma koşullarını, farklı kapalılık durumlarını (gözlük, atkı vs.) içeren 24-bit renkli 576×768 piksel boyutunda fotoğraflardan oluşmuştur. Şekil 4.1.'de AR-Face veritabanına ait bazı yüz görüntü örnekleri verilmiştir.



Şekil 4.1. AR-Face veritabanına ait yüz görüntü örneklerinden bazıları.

4.1.1. Bölüm 3.3.2.1'de Geliştirilen Algoritma İçin Yapılan Deneysel Çalışmalar

Bu çalışmanın AR-Face ile çalışılan test aşamasında, AR-Face veritabanından 20'si erkek ve 17'si bayan olmak üzere toplam 37 kişinin görüntüleri kullanılmıştır. Ön işlem olarak ise bu yüz görüntüleri, RGB bileşenlerinden arındırılarak 0-255 arasında aydınlık değerlerine sahip 2-boyutlu matrisler haline dönüştürülmüşler ve boyutları 50×40 piksel olacak şekilde küçültülmüştür. Şekil 4.2.'de AR-Face veritabanından ön işleme sonrasında kullanılan iki kişiye ait bazı yüz görüntü örnekleri verilmiştir.



Şekil 4.2. AR-Face veritabanından iki kişiye ait gri seviye, 50×40 boyutunda bazı yüz görüntü örnekleri.

Bu tez çalışmasının ilk deneysel kısmında, AR-Face veritabanından 37 kişinin aydınlatma ve yüz ifade farklılıklarını içeren 27’şer adet fotoğrafları kullanılmıştır. Her bir kişinin fotoğrafları arasından rastgele seçilen bir görüntü eğitim kümesini, kalan 26 görüntü test kümesini oluşturmaktadır. Bu deney 10 defa tekrarlanmış olup, 10 deney sonucunun ortalaması çizelge 4.1.’de verilmiştir.

İkinci ve üçüncü deneylerde ise AR-Face veritabanından yeni veri setleri oluşturulmuştur. Bu veri kümesi aynı yüz ifadelerine ve farklı aydınlatma koşullarına sahip, 37 kişi için 9’ar adet yüz görüntüsünden oluşmuştur. Şekil 4.3.’te iki kişiye ait AR-Face veritabanından 9 adet yüz görüntüsü verilmiştir.



Şekil 4.3. AR-Face veritabanından iki kişinin 9 adet aynı yüz ifadelerine ve farklı aydınlatma koşullarına sahip görüntüleri.

İkinci ve üçüncü deneyin her ikisinde de 9 görüntüden 1’i eğitim, kalan 8’i de test görüntü kümesini oluşturmaktadır. İkinci deneyde, yüz görüntüleri farklı aydınlatma koşulları altında normal ifadelere sahipken, üçüncü deneyde ise yüz görüntüleri yine farklı aydınlatma şartları altında gülen ifadelere sahiptir. İkinci ve üçüncü deneylerin sonuçları da çizelge 4.1.’de verildiği gibidir.

Çizelge 4.1. AR-Face veritabanı için tanıma performansları.

<i>Deney No.</i>	<i>Tanıma Performansı TDA’ya dayalı OM Yaklaşımı (%)</i>	<i>Tanıma Performansı FLDA+SVD, (Gao vd., 2008) (%)</i>
1.	77.28	68.42
2.	99.68	81.75
3.	99.39	79.73

ORL veritabanı ise 4’ü kadın olmak üzere 40 kişiye ait 10’ar adet farklı görüntüyü içeren toplam 400 adet yüz görüntüsünden oluşmaktadır. Bazı sınıflara ait görüntüler arasında çekim zamanı açısından farklılıklar vardır. Bunun yanında veritabanındaki görüntülerde açık ya da kapalı göz, gülümseme ya da gülümsememe gibi kişisel yüz

ifadelerde ve gözlük olması ya da olmaması gibi kapalılık durumlarında farklılıklar vardır.

Bu veritabanındaki tüm görüntüler gri seviyeli ve piksel boyutundadır. Bu veritabanından bir kişiye ait bazı yüz fotoğrafları şekil 4.4.'de verildiği gibidir.



Şekil 4.4. ORL veritabanından 2 kişiye ait 4'er adet yüz görüntü örnekleri.

Çalışmanın ORL veritabanı ile test edilen kısmında ise, bu veritabanından 40 kişinin 4'er yüz görüntüleri kullanılmıştır. Bu yüz görüntülerinden her kişiye ait ilk 3 görüntü test, dördüncü görüntü ise eğitim amaçlı kullanılmıştır. Tanıma işleminden önce yüz görüntülerine histogram eşitlemesi ön işlemleri uygulanmış olup, deneyin tanıma performansı %80.83'tür.

4.1.2. Bölüm 3.3.2.2'de Geliştirilen Algoritma İçin Yapılan Deneysel Çalışmalar

Yapılan deneysel çalışmalarda, sunulan yöntemin tanıma performansını değerlendirmek için AR-Face veritabanı kullanılmıştır. Deneysel çalışmalar için oluşturulan veri tabanı toplam 37 kişinin (20 erkek, 17 kadın) görüntülerinden oluşmaktadır. Bu görüntüler, aralarında aydınlatma farkı, yüz ifade farkı olan kapatılmamış ve önden çekilmiş yüz görüntülerini içermektedir.

Sunulan yöntemin tanıma performansı üç grup görüntü üzerinde denenmiştir. Birinci grup görüntüler arasında hem aydınlatma hem de yüz ifade farklılıkları bulunmaktadır. Bu grupta yer alan görüntülere bir örnek şekil 4.5.'te verilmiştir. Bir kişi için toplam 27 adet görüntünün kullanıldığı bu çalışmada her seferinde rastgele bir tanesinin eğitim görüntüsü kalan 26 tanesinin test görüntüsü olarak kullanıldığı 10 deney yapılmıştır. Elde edilen bu 10 deney sonucunun ortalaması çizelge 4.2.'de verilmiştir.



Şekil 4.5. Birinci grup görüntü veritabanı için 4 görüntü örneği.

İkinci grup görüntüler arasında sadece aydınlatma farkının olduğu kişi başına toplam 9 görüntü bulunmaktadır. Bu grupta yer alan görüntülere örnek şekil 4.6’da verilmiştir. Bu çalışmada her seferinde biri eğitimde kullanılıp kalan 8 tanesinin test amaçlı olarak kullanıldığı toplam 9 deney gerçekleştirilmiş ve elde edilen sonuçların ortalaması çizelge 4.2.’de verilmiştir.




Şekil 4.6. İkinci grup görüntü veritabanı için 3 görüntü örneği.

Üçüncü grup görüntüler arasında ise aralarında sadece ifade farkı olan kişi başına toplam 3 görüntü bulunmaktadır. Bu gruptaki görüntülere örnek şekil 4.7.’de verilmiştir. Bu gruptaki görüntülerden her biri bir kez eğitimde kullanılmak üzere her seferinde tek görüntü ile eğitim yapılmış kalan iki görüntü ile test yapılmıştır. Elde edilen sonuçlar Birikimli Eşleştirme Skoru (Cumulative Match Score) cinsinden şekil 4.9.’da verilmiştir.




Şekil 4.7. Üçüncü grup görüntü veritabanı için 3 görüntü örneği.

Deneysel çalışmalarda yüzün bölgesel özelliklerinin elde edilmesi için yüz görüntüsünün sırasıyla 15×30 , 20×15 ve 15×20 boyutlarında kesilmiş, göz bölgesi, burun bölgesi ve ağız bölgesi görüntüleri kullanılmıştır. Yukarıda verilen I. grup, II. grup ve III. grup görüntülerde sadece **F** bölgesi için örnekler görülmektedir. Bu deneysel çalışmalarda kullanılan yüzün **E**, **N** ve **M** bölgelerine ait görüntüler için bir örnek (**E** bölgesi örneği) şekil 4.8.’de verilmiştir.




(a)






Şekil 4.8. Göz bölgesi için (*E*): a) I.Grup görüntü örnekleri, b) II. Grup görüntü örnekleri, c) III. Grup görüntü örnekleri.

TDA' ya dayalı Ortak Matris Yaklaşımında tanıma performansını artırmak için sunulmuş olan birleştirilmiş ortak özellik altuzayında tanıma için kullanılan bir kişiye ait örnek görüntüler şekil 4.9.'da verilmiştir.



Şekil 4.9. Birleştirilmiş ortak özellik altuzayı için kullanılan veritabanına bir örnek: a) *F* bölgesi b) *E* bölgesi, c) *N* bölgesi, d) *M* bölgesi görüntü örnekleri.

Deneysel çalışmalarda ilk olarak Birleştirilmiş Ortak Özellik Altuzayı yöntemindeki tanıma sonuçları ile TDA'ya dayalı Ortak Matris Yaklaşımı'nın yüzün *F, E, N, M* bölgelerine ayrı ayrı uygulanması ile elde edilen tanıma sonuçları karşılaştırılmıştır. Çizelge 4.2'de *F, E, N, M* bölgelerine TDA'ya dayalı Ortak Matris Yaklaşımı uygulanarak elde edilmiş tanıma oranları verilmiştir. Çizelge 4.2.'de verilen sonuçlara göre sunulan yöntemin uygulanması ile TDA'ya dayalı OMY'de üç grup veritabanında da tanıma performansları açısından artış gözlenmiştir. Üç grup veritabanı arasında en büyük artış görüntüler aralarında sadece ifade farkının olduğu III. grup veritabanında daha sonra da aralarında hem ifade farklarının hem de aydınlatma farklarının olduğu I. grup veritabanında elde edilmiştir. Aralarında sadece aydınlatma farkları olan görüntülerin bulunduğu veritabanı için elde edilen artış diğerlerine göre çok az olmuştur. III. grup veri ile yapılan deneysel çalışmanın sonuçları Birikimli Eşleştirme Skoru cinsinden şekil 4.10.'da verilmiştir.



Şekil 4.10. III. Grup veritabanı için elde edilen Birikimli Eşleştirme Skoru sonuçları.

Çizelge 4.2 ve şekil 4.10 incelenecek olursa sunulan yöntemle en yakın bölge sonuçları **F-Bölgesinin** yani yüzün bütününün tanıma için kullanıldığı çalışmalardır. En düşük bölgesel tanıma sonuçları ise **N-Bölgesinin** yani sadece burun bölgesinin kullanıldığı sonuçlar olmuştur. Sadece **E-Bölgesi** için elde edilen sonuçların, sadece **F-Bölgesi** için elde edilen sonuçlara oldukça yakın olduğu görülmektedir.

Çizelge 4.2. I. grup ve II. grup deneysel çalışma sonuçları.

Deney	Tanıma Oranları (%)				
	F Bölgesine TDA'ya dayalı OM Yaklaşımı uygulanması	E Bölgesine TDA'ya dayalı OM Yaklaşımı uygulanması	N Bölgesine TDA'ya dayalı OM Yaklaşımı uygulanması	M Bölgesine TDA'ya dayalı OM Yaklaşımı uygulanması	Sunulan Yöntem Birleştirilmiş Ortak Özellik Altuzayı
I. Grup Veritabanı ile	77.28	77.10	62.98	71.22	84.51
II. Grup Veritabanı ile	99.68	98.99	87.34	96.56	99.85

5. SONUÇ

Biyometrik tanıma sistemlerinin bir alt dalı olan otomatik yüz tanıma, temel bir araştırma alanı olarak kimlik doğrulama ve tespit amaçlı olarak ticari, sivil ve askeri alanlarda birçok uygulamaya sahiptir. Son yıllarda özellikle gerçeğe dayalı senaryolarda araştırmacıların dikkatini çeken önemli bir konu tek görüntü problemidir. Bu tip senaryolarda tanıma sisteminin eğitiminde kullanılmak üzere eğitim kümesinde kişi başına sadece tek görüntü bulunmaktadır. Eğitimde tek görüntünün olduğu durumlarda tanıma yapmak çok yaygın kullanılan pek çok sistem için performans düşüşlerine sebep olurken bazıları ise hiç kullanılamamaktadır. Çoğu gerçek senaryoda bir kişi için çok sayıda görüntü elde etmek kolay değildir. Ayrıca hafıza gereksinimlerinden dolayı tek görüntü kullanımı daha avantajlı bir hale gelebilmektedir. Örneğin havaalanlarında kimlik tespitlerinde pasaport üzerindeki tek bir fotoğraf kullanıldığı gibi, kişiye ait birden çok fotoğraf elde etmek de çok zordur. Bu ve bunun gibi durumlar, literatürde tek görüntü problemi olarak adlandırılan konunun altını önemle çizmektedir.

Bu tez çalışmasında yüz tanıma eğitimi kümesinde kişi başına tek görüntü olması durumu incelenmiş ve veritabanında kişi başına birden fazla görüntü olduğunda iyi tanıma sonuçları veren ve eğitimde en az iki görüntü olduğu durumda uygulanabilen Ortak Matris Yaklaşımının, tek görüntü problemine ilişkin uygulanmasına yönelik bir algoritma geliştirilmiştir. Ayrıca algoritmanın performansını artırmak için de bir yöntem sunulmuştur.

Ortak Matris Yaklaşımında özellik çıkarımı için sınıf-içi dağılım matrisi kullanıldığından, veritabanında kişi başına en az iki görüntü olması gerekir. Veritabanında kişi başına tek görüntü olduğu durumlarda farklılık altuzayının oluşturulamaması ve sınıf-içi dağılım matrisinin elde edilememesinden ötürü bu yöntem çalışmaz. Sunulan algoritmada, eğitim kümesindeki her sınıf için var olan tek görüntüye tekil değer ayrışımı uygulayarak sıfır tekil değerlere karşılık gelen vektörler bulunmuş ve bu vektörler üzerine izdüşümü alınarak her sınıf için bir ortak matris elde edilmiştir. Görüntünün sıfır tekil değerlere karşılık gelen sıfır-uzayını tarayan vektörler üzerine izdüşümü, görüntünün genel görünümüne bir katkı sağlamayacağından her sınıf için elde edilen ortak matrisin, o sınıfa ait ortak özellikleri yansıttığı düşünülebilir.

Bu algoritmanın test aşamasında AR-Face veritabanından 37 kişinin görüntüleri kullanılmış ve bu veritabanından oluşturulan üç farklı veritabanı üzerinde çalışılmıştır. İlk veritabanında 37 kişinin aydınlatma ve yüz ifade farklılıklarını içeren 27'şer adet fotoğrafı kullanılmıştır. Her bir kişinin fotoğrafları arasından rastgele seçilen bir görüntü eğitim kümesini, kalan 26 görüntü test kümesini oluşturmaktadır. İkinci veritabanı ise normal yüz ifadelerine ve farklı aydınlatma koşullarına sahip, 37 kişi için 9'ar adet yüz görüntüsü kullanılmıştır. Bu veritabanındaki görüntülerden biri eğitimde kullanılıp kalan 8 tanesi test amaçlı olarak kullanılmıştır. Üçüncü veritabanında ise yine 37 kişinin 9'ar adet görüntüsü, biri eğitim kümesini kalan 8'i test kümesini oluşturmak üzere, farklı aydınlatma koşulları altında ve gülen ifadelerine sahip yüz görüntüleri kullanılmıştır. Oluşturulan ilk veritabanı ile yapılan deney 10 defa tekrarlanmış ve 10 deneyin ortalaması %77.28 tanıma performansı olarak verilmiştir. İkinci veritabanı ile yapılan deneyde 8 test görüntüsü kullanılmış ve bunların ortalaması %99.68 tanıma performansı olarak verilmiştir. Üçüncü veritabanı ile yapılan deneyde de 8 test görüntüsü kullanılmış ve bunların ortalaması %99.39 tanıma performansı olarak verilmiştir. Bu tanıma performanslarından, algoritmanın aynı yüz ifadelerine sahip fakat farklı aydınlatma koşullarında iyi tanıma performansı verdiği görülmüştür. Algoritma ORL veritabanı üzerinde de test edilmiştir. Bu deneysel çalışmalarda ORL veritabanından 40 kişiye ait 4'er tane görüntüden ilki eğitim kümesini, kalan 3 tanesi ise test kümesini oluşturacak şekilde elde edilen bir veritabanı üzerinde deneysel çalışma yapılmıştır. Bu çalışma veritabanındaki 4 görüntüden her biri bir kez eğitimde kullanılmak üzere 4 kez tekrarlanarak bu deneylerin ortalaması olarak %80.83 oranında bir tanıma performansı elde edilmiştir.

Tez çalışmasında eğitimde tek görüntü problemi için TDA'ya dayalı Ortak Matris Yaklaşımının tanıma performansını arttırmak amacıyla yüzün hem bütünsel hem de bölgesel özelliklerinin bir arada kullanıldığı bir yöntem sunulmuştur. Bu yöntemde yüzün tamamı kullanılarak bütünsel özellikler elde edilirken, piksel değişimlerinin en fazla olduğu göz, burun ve ağız bölgelerine ait görüntüler kullanılarak bölgesel özellikler elde edilmiştir. Tüm bu özellikler birleştirilerek birleştirilmiş ortak özellik altuzayı oluşturulmuş ve tanımda kullanılmıştır.

Deneysel çalışmalarda, yüzün bütünsel bilgisinden yararlanıp bütünsel özelliklerinin elde edilmesi için yüzün tamamı, yüzün bölgesel özelliklerinin elde

edilmesi için yüz görüntüsünün sırasıyla 15×30 , 20×15 ve 15×20 boyutlarında kesilmiş, göz bölgesi, burun bölgesi ve ağız bölgesi görüntüleri kullanılmıştır. Geliştirilen bu yöntemin TDA'ya dayalı Ortak Matris Yaklaşımı'nda tanıma performansını nasıl etkilediğini görmek amacıyla, AR-Face veritabanı üzerinde oluşturulan üç ayrı veritabanı üzerinde deneysel çalışmalar yapılmıştır. Oluşturulan ilk veritabanında aralarında hem aydınlatma hem de yüz ifade farklılıklarının bulunduğu görüntüler yer almaktadır. Bir kişi için toplam 27 adet görüntünün kullanıldığı bu çalışmada her seferinde rastgele bir tanesinin eğitim görüntüsü kalan 26 tanesinin test görüntüsü olarak kullanıldığı 10 deney yapılmıştır. Elde edilen bu 10 deney sonucunun ortalaması bölüm 4.1.2.'deki çizelge 4.2.'de verilmiştir. İkinci veritabanında aralarında sadece aydınlatma farkının olduğu kişi başına toplam 9 görüntü kullanılmıştır. Bu çalışmada her seferinde biri eğitimde kullanılıp kalan 8 tanesinin test amaçlı olarak kullanıldığı toplam 9 deney gerçekleştirilmiş ve elde edilen sonuçların ortalaması çizelge 4.2.'de tanıma performansı olarak verilmiştir. Üçüncü veritabanında ise aralarında sadece ifade farkı olan kişi başına toplam 3 görüntü kullanılmıştır. Bu gruptaki görüntülerden her biri bir kez eğitimde kullanılmak üzere her seferinde tek görüntü ile eğitim yapılmış kalan iki görüntü ile test yapılmıştır. Elde edilen sonuçlar bölüm 4.1.2.'deki şekil 4.10.'da verilmiştir.

Bu çalışmada Birleştirilmiş Ortak Özellik Altuzayı yönteminde elde edilen sonuçlar ile TDA'ya dayalı Ortak Matris Yaklaşımının yüz, göz, burun ve ağız bölgesine ayrı ayrı uygulanmasıyla elde edilen sonuçlar karşılaştırılmıştır. Geliştirilen bu yöntem ile en fazla performans artışı aralarında sadece ifade farkının olduğu III. grup veritabanında daha sonra da aralarında hem ifade farklarının hem de aydınlatma farklarının olduğu I. grup veritabanında elde edildiği görülmüştür. Aralarında sadece aydınlatma farkları olan görüntülerin bulunduğu veritabanı için elde edilen artış ise diğerlerine göre çok az olmuştur.

TDA'ya dayalı Ortak Matris Yaklaşımında yapılan deneysel çalışmalar geliştirilen algoritmanın aynı yüz ifadelerinde ve farklı aydınlatma koşullarında iyi performans oranları verdiğini, bu yöntemin performansının artırılması için sunulan Birleştirilmiş Ortak Özellik Altuzayı yönteminin ise, özellikle aralarında ifade farklarının olduğu görüntülerde tanıma performansını büyük ölçüde artırdığı gözlemlenmiştir.

Geleceğe yönelik yapılan çalışmalarda tek görüntü problemi üzerine geliştirilen bu algoritmanın, yüz ifadelerinde farklılık, aydınlatma koşullarının değişimi, yüzde kapalılık ve farklı yönlerden çekim gibi çeşitlilikleri de içeren farklı veritabanları üzerinde denenmesi, geliştirilmesi ve araştırmalar yapılması planlanmaktadır.

KAYNAKLAR DİZİNİ

- Akça, M. D. ve Doğan, S., “Sayısal Görüntülerde Ana Bileşenler Dönüşümü”, *Harita Dergisi*, 128: 1-15, Ankara, (2002).
- Apaydın, M., Turhal, Ü. Ç. ve Duysak, A., “An SVD Based Common Matrix Method for Face Recognition: Single Image per Person”, *25th International Symposium on Computer and Information Sciences*, London, 289-292, (2010).
- Apaydın, M. ve Turhal, Ü. Ç., “Tek Görüntü Probleminde Tanıma Performansının Artırılması: Birleştirilmiş Ortak Öznitelik Altuzayı”, *IEEE 19. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Antalya, (2011).
- Baker, K., “Singular Value Decomposition Tutorial”, http://web.ics.purdue.edu/~park283/wp-content/uploads/2010/10/Singular_Value_Decomposition_Tutorial.pdf, 2005
- Belhumeur, P., Hespanha, J. ve Kriegman, D., “Eigenfaces vs. Fisherfaces: recognition using class specific linear projection”, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 19(7): 711-720 (1997).
- Brunelli, R. ve Poggio, T., “Face recognition: Features versus templates”, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 15(10): 1042-1062 (1993).
- Cevikalp, H., Neamtu, M., Wilkes, M. ve Barkana, A., “Discriminative common vectors for face recognition”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27: 4-13 (2005).
- Chellappa, R., Wilson, C. L. ve Sirohey, S., “Human and machine recognition of faces: a survey”, *Proceedings of the IEEE*, 83(5): 705-740 (1995).
- Chen, S. C., Zhang D.Q., ve Zhou Z.-H., “Enhanced (PC)2A for face recognition with one training image per person”, *Pattern Recognition Letters*, 25(10): 1173-1181 (2004) a.
- Chen, S.C., Liu J., ve Zhou, Z.-H., “Making FLDA applicable to face recognition with one sample per person”, *Pattern Recognition*, 37(7): 1553-1555 (2004) b.
- Cox, I. J., Ghosn, J. ve Yianilos, P. N., “Feature based face recognition using mixture distance”, *IEEE Conference on Computer Vision and Pattern Recognition*, 209-216 (1996)
- Daugman, J., “Face and gesture recognition: Overview”, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 19(7): 675-676 (1997).
- Deng, W., Hu, J. ve Guo, J., “Robust Face Recognition from One Training Sample per Person”, *Proceedings of ICNC (I)*, (3610) 419: 915-924 (2005).

KAYNAKLAR DİZİNİ (devam ediyor)

- Duin, R. P.W., “Small sample size generalization”, *9th Scandinavian Conference on Image Analysis*, Uppsala, Sweden (1995).
- Edwards, C. H. ve Penney, D. E., “Elementary Linear Algebra”. Englewood Cliffs, *NJ: Prentice-Hall*, 1988.
- Gao, W., Cao, B., Shan, S., Zhou, D., Zhang, X. ve Zhao, D., “The CAS-PEAL Large-Scale Chinese Face Database and Baseline Evaluations”, *Technical Report of JDL*, 2004.
- Gao, Q., Zhang, L. ve Zhang, D., “Face recognition using FLDA with single training image per person”, *Applied Mathematics and Computation - AMC*, (205) 2: 726-734 (2008).
- Golub, G. H. ve Loan, C. F. V., “Matrix Computations”, *Johns Hopkins University Press*, Baltimore, Maryland, 1983.
- Gonzalez, R. C. ve Woods, R. E., “Digital Image Processing”, *Addison-Wesley Pub.*, 1992.
- Gülmezoğlu, M. B., Dzhafarov, V., Keskin, M. ve Barkana, A., “A novel approach to isolated word recognition”, *IEEE Transactions on Speech and Audio Processing*, 620-628 (1999).
- He, J., ve Du, M., “Face Recognition Based on Projection Map and SVD Method for One Training Image per Person”, *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'05)*, Washington, DC, USA, 1: 20-24 (2005).
- Hjelmas, E. ve Wroldsen, J., “Recognizing faces from the eyes only”, *Proceedings of the 11th Scandinavian Conference on Image Analysis*, 1999.
- Huang, J., Yuen P. C., Chen W.S. ve Lai J.H., “Component-based LDA Method for Face Recognition with One Training Sample” *Analysis and Modeling of Faces and Gestures (AMFG)*, 120-126 (2003).
- Jacobs, D.W., Weinshall, D. ve Gdalyahu, Y., “Classification with Non-Metric Distances: Image Retrieval and Class Representation”, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 22(6): 583-600 (2000).
- Jain, A. K., Ross, A. ve Prabhakar, S., “An Introduction to Biometric Recognition”, *IEEE Trans. on Circuits and Systems for Video Technology*, (14)1: 4-19 (2004).

KAYNAKLAR DİZİNİ (devam ediyor)

- Jain, A. K. ve Chandrasekaran, B., “Dimensionality and sample size considerations in pattern recognition practice”, *In Handbook of Statistics*, P.R. Krishnaiah and L.N. Kanal, Eds., Amsterdam, 2: 835-855 (1982).
- Kanade, T., “Picture processing by computer complex and recognition of human faces”, *Technical Report, Kyoto University, Department of Information Science*, 1973.
- Kanan, H. R. ve Moin, M. S., “Recognizing Partially Occluded Faces from a Single Exemplar Image Per Person”, *ISA'09 Proceedings of the 3rd International Conference and Workshops on Advances in Information Security and Assurance*, Springer-Verlag Berlin, Heidelberg, 100-109 (2009).
- Kaya, Y. ve Kobayashi, K., “A basic study on human face recognition”, *Frontiers of Pattern Recognition*, 265-289 (1972).
- Kim, C., Oh, J. ve Choi, C.-H., “Combined Subspace Method Using Global and Local Features for Face Recognition”, *Proceedings of International Joint Conference on Neural Networks*, Montreal, Canada, 2030-2035 (2005).
- Klema, V.C., “The singular value decomposition: its computation and some applications”, *IEEE Trans. Automation Control*, 25:164–176 (1980).
- Kohonen, T., “Self-Organizing Map”, *Berlin: Springer-Verlag*, 2nd edition, 1997.
- Kolman, B. ve Hill, D. R., “Uygulamalı Lineer Cebir”, Akın, Ö., *Palme Yayıncılık*, Ankara, 2000.
- Krueger, J., Robinson, M., Kochelek, D., ve Escarra, M., “Obtaining the Eigenface Basis”, *Connexions*, <http://cnx.org/content/m12531/1.3/>, 2004.
- Li, J.-B., Pan, J.-S. ve Chu, S.-C., “Face Recognition from a Single Image per Person Using Common Subfaces Method”, *Lecture Notes in Computer Science*, 4492: 905-912 (2007).
- Liu, W., Wang, Y., Li, S. Z. ve Tan, T., “Null Space-based Kernel Fisher Discriminant Analysis for Face ecognition”, *Proceedings of the 6th IEEE International Conference On Face and Gesture Recognition FGR'04*, 2004.
- Manjunath, B. S.,Chellappa, R., ve Malsburg, C. V. D., “A feature based approach to face recognition. In Proceedings”, *IEEE Conference on Computer Vision and Pattern Recognition*, 1: 373–378 (1992).
- Martinez, A. M. ve Benavente, R., “The AR Face Database”, *CVC Technical Report #24*, 1998.

KAYNAKLAR DİZİNİ (devam ediyor)

- Martinez, A.M., “Recognizing imprecisely localized, partially occluded, and expression variant faces from a single sample per class”, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 25(6): 748-763 (2002).
- Muller, N., Magaia, L. ve Herbst, B. M., “Singular Value Decomposition, Eigenfaces, and 3D Reconstructions”, *Society for Industrial and Applied Mathematics*, (46)3: 518-545 (2004).
- Pentland, A., Moghaddam, B. ve Starner, T., “View-Based and Modular Eigenspaces for Face Recognition”, *IEEE International Conference On Computer Vision & Pattern Recognition*, Washington, USA, 84-91 (1994).
- Phillips, P.J., Wechsler, H., Huang, J. ve Rauss, P.J., “The FERET database and evaluation procedure for face-recognition algorithms”, *Image and Vision Computing*, 16(5): 295-306 (1998).
- Prabhakar, S., Pankanti, S. ve Jain, A. K., “Biometric recognition: security and privacy concerns”, *Security & Privacy IEEE*, 1(2): 33-42 (2003).
- Raudys, S. J. ve Jain, A. K., “Small sample size effects in statistical pattern recognition: recommendations for practitioners”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (13)3: 252-264 (1991).
- Samaria, F. ve Harter, A., “Parameterisation of a Stochastic Model for Human Face Identification”, *Proceedings of 2nd IEEE Workshop on Applications of Computer Vision*, Sarasota FL, 1994.
- Sirovich, L. ve Kirby, M., “Low-dimensional procedure for the characterization of human faces”, *Journal of the Optical Society of America A*, 4(3): 519-524 (1987).
- Tan X., Chen, S. C., Zhou, Z.-H. ve Zhang, F., “Recognizing partially occluded, expression variant faces from single training image per person with SOM and soft kNN ensemble”, *IEEE Transactions on Neural Networks*, 16(4): 875-886 (2005).
- Tan, X., Chen, S., Zhou, Z.-H. ve Zhang, F., “Face recognition from a single image per person: A survey”, *Pattern recognition Journal*, 39: 1725-1745 (2006).
- Tian, Y., Tan, T., Wang, Y. ve Fang, Y., “Do singular values contain adequate information for face recognition?”, *Pattern Recognition*, (36)3: 649-655 (2003).
- Torre, F. De la, Gross, R., Baker, S., ve Kumar, V., “Representational Oriented Component Analysis (ROCA) for Face Recognition with One Sample Image per

KAYNAKLAR DİZİNİ (devam ediyor)

- Training Class”, *In Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2: 266-273 (2005).
- Turhal, Ü. Ç., Gülmezoğlu, M. B. ve Barkana, A., “A face recognition algorithm using common matrix approach”, *EUSIPCO*, Antalya, 4-8 (2005).
- Turk, M. ve Pentland, A., “Eigenfaces for recognition”, *Journal of Cognitive Neuroscience*, 3(1): 71-86 (1991).
- Villela, P. R. ve Azuela, J. H. S., “Improving Pattern Recognition Using Several Feature Vectors”, *Lecture Notes In Computer Science*, Springer-Verlag London, UK, 282-291 (2002).
- Wang, Y.-H., Tan, T.-N. ve Zhu, Y., “Face identification based on singular values decomposition and data fusion”, *Chinese Journal of Computers*, 23(6) (2000).
- Welling, M., “Classnotes in Machine Learning”, University of Toronto, <http://www.ics.uci.edu/~welling/classnotes/classnotes.html>
- Wu, J. ve Zhou, Z.-H., “Face Recognition with one training image per person”, *Pattern Recognition Letters*, 23(14): 1711-1719 (2002).
- Wu, C., Liu, C., Shum, H. Y., Xu, Y. Q. ve Zhang, Z., “Automatic Eyeglasses Removal from Face Image”, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 26(3): 322-336 (2004).
- Yang, M., “Kernel Eigenfaces v.s. Kernel Fisherfaces: Face recognition using kernel methods”, *Proceedings of the fifth IEEE International Conference on Automatic Face and Gesture Recognition*, 2002.
- Yang, J., Yang, J. Y. ve Frangi, A. F., “Combined fisherfaces framework”, *Image and Vision Computing*, 21: 1037-1044 (2003).
- Yang, J., Frangi, A. F., Yang, J. Y. Ve Zhang, D., “KPCA plus LDA: A complete kernel fisher discriminant framework for feature extraction and recognition”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 27 (2005).
- Yin, H., Fu, P. ve Meng, S., “Sampled FLDA for face recognition with single training image per person”, *Neurocomputing*, (69)16-18: 2443-2445 (2006).
- Yu, H. ve Yang, J., “A direct LDA algorithm for high-dimensional data with application to face recognition”, *Pattern Recognition*, 34: 2067-2070 (2001).

KAYNAKLAR DİZİNİ (devam ediyor)

- Zhao, W., Chellappa, R., Phillips, P. J. ve Rosenfeld, A., “Face Recognition: A Literature Survey”, *ACM Computing Survey*, 399-458 (2003).
- Zhang, D.Q., Chen, S.C. ve Zhou, Z.-H., “A new face recognition method based on SVD perturbation for single example image per person”, *Applied Mathematics and Computation*, 163(2): 895-907 (2005).
- Zhao, W. ve Chellappa, R., “Image-based Face Recognition: Issues and Methods”, *Image Recognition and Classification* , Ed. B. Javidi, M. Dekker, 375-402 (2002).

TEZ KAPSAMINDA YAYINLANAN BİLDİRİLER

- Apaydın, M., Turhal, Ü. Ç. ve Duysak, A., “An SVD Based Common Matrix Method for Face Recognition: Single Image per Person”, *25th International Symposium on Computer and Information Sciences*, London, 289-292, (2010).
- Apaydın, M. ve Turhal, Ü. Ç., “Tek Görüntü Probleminde Tanıma Performansının Artırılması: Birleştirilmiş Ortak Öznitelik Altuzayı”, *IEEE 19. Sinyal İşleme ve İletişim Uygulamaları Kurultayı*, Antalya, (2011).

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Meltem Apaydın
Doğum Yeri ve Tarihi : Samsun 01.01.1986



Eğitim Durumu

Lisans Öğrenimi : Anadolu Üniversitesi
Elektrik-Elektronik Mühendisliği
Bildiği Yabancı Diller : İngilizce

İş Deneyimi

Stajlar : HAVELSAN, Arçelik
Çalıştığı Kurumlar : Bilecik Üniversitesi
Mühendislik Fakültesi

İletişim

Adres : Kılıçdede Mah. Kılavuz Sok.
Ümit Apt. Samsun
Tel : 0 505 779 6625
E-posta : meltem.apaydin@bilecik.edu.tr

Tarih: 11.08.2011