



CUMHURİYET ÜNİVERSİTESİ

Sosyal Bilimler Enstitüsü

İşletme Ana Bilim Dalı

Sayısal Yöntemler Bilim Dalı

**YÜZ TANIMA UYGULAMALARINDA
ÖZYÜZLER VE YAPAY SİNİR AĞLARININ
KARŞILAŞTIRILMASI**

Yüksek Lisans Tezi

Hakan KEKÜL

Sivas

Ekim 2017

CUMHURİYET ÜNİVERSİTESİ

Sosyal Bilimler Enstitüsü

İşletme Ana Bilim Dalı

Sayısal Yöntemler Bilim Dalı

**YÜZ TANIMA UYGULAMALARINDA
ÖZYÜZLER VE YAPAY SİNİR AĞLARININ
KARŞILAŞTIRILMASI**

Yüksek Lisans Tezi

Hakan KEKÜL

Tez Danışmanı

Doç. Dr. Hüdaverdi BİRCAN

Sivas

Ekim 2017

KABUL VE ONAY

Üniversite: : Cumhuriyet Üniversitesi
Enstitü : Sosyal Bilimler Enstitüsü
Ana Bilim Dalı : işletme
Bilim Dalı : Sayısal Yöntemler
Tezin Başlığı : Yüz Tanıma Uygulamalarında Özyüzler ve Yapay Sinir Ağlarının Karşılaştırılması
Savunma Tarihi : 15/09/2017
Danışmanı : Doç. Dr. Hudaverdi BİRCAN

Unvanı - Adı Soyadı

İmza

Jüri Başkanı : Prof. Dr. Üstün ÖZEN



Üye : Doç. Dr. Hudaverdi BİRCAN



Üye : Yrd. Doç. Dr. Halil ARSLAN



Oy Birliği ☒

Oy Çokluğu ☐

Hakan KEKÜL tarafından hazırlanan Yüz Tanıma Uygulamalarında Özyüzler ve Yapay Sinir Ağlarının Karşılaştırılması başlıklı tez, kabul edilmiştir.

.../.../.....

Prof. Dr. Ahmet ŞENGÖNÜL
Enstitü Müdürü

ETİK İLKELERE UYGUNLUK BEYANI

Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü bünyesinde hazırladığım bu Yüksek Lisans tezinin bizzat tarafımdan ve kendi sözcüklerimle yazılmış orijinal bir çalışma olduğunu ve bu tezde;

1- Çeşitli yazarların çalışmalarından faydalandığımda bu çalışmaların ilgili bölümlerini doğru ve net biçimde göstererek yazarlara açık biçimde atıfta bulunduğumu;

2- Yazdığım metinlerin tamamı ya da sadece bir kısmı, daha önce herhangi bir yerde yayımlanmışsa bunu da açıkça ifade ederek gösterdiğimi;

3- Başkalarına ait alıntılanan tüm verileri (tablo, grafik, şekil vb. de dâhil olmak üzere) atıflarla belirttiğimi;

4- Başka yazarların kendi kelimeleriyle alıntıladığım metinlerini, tırnak içerisinde veya farklı dizerek verdiğim yine başka yazarlara ait olup fakat kendi sözcüklerimle ifade ettiğim hususları da istisnasız olarak kaynak göstererek belirttiğimi, beyan ve bu etik ilkeleri ihlal etmiş olmam halinde bütün sonuçlarına katlanacağımı kabul ederim.



İmza

Hakan KEKÜL

TEŞEKKÜR

Tez çalışmam boyunca beni yönlendiren, ilgi ve yardımlarını esirgemeyen ve her türlü destek ve teşvikini gördüğüm danışman hocam Doç. Dr. Hüdaverdi BİRCAN'a teşekkür ederim. Yine araştırmam boyunca yardım ve desteklerini gördüğüm sayın Doç. Dr. Oğuz KAYNAR, Yrd. Doç. Dr. Halil ARSLAN, Mesut BIYAN ve bana emeği geçen tüm hocalarıma en kalbi saygılarımı sunarım. Çalışmalarım boyunca bilgi birikimlerinden, rehberliklerinden faydalandığım değerli dostlarıma ve desteklerini esirgemeyen değerli aileme teşekkürlerimi sunarım.

İÇİNDEKİLER

İÇİNDEKİLER	i
KISALTMALAR	iii
TABLO LİSTESİ	iv
ŞEKİL LİSTESİ	v
ÖZET	vi
ABSTRACT	vii
1. GİRİŞ	1
1.1. GİRİŞ	1
1.2. TEZİN AMACI	2
1.3. LİTERATÜR TARAMASI	3
1.4. TEZ DÜZENİ	6
2. ÖZYÜZLER – EIGENFACES	7
2.1. GİRİŞ	7
2.2. ÖZ YÜZLERİN (EİGENFACE) HESAPLAMASI	7
2.4. ÖZ YÜZLER ALGORİTMASI	13
2.3. ÖZ YÜZLER AKIŞ ŞEMASI	14
3. YAPAY SİNİR AĞLARI	15
3.1. GİRİŞ	15
3.2. YAPAY SİNİR AĞLARININ GENEL ÖZELLİKLERİ	16
3.2.1. Doğrusal Olmama	16
3.2.2. Öğrenme	16
3.2.3. Genelleme	17
3.2.4. Uyarlanabilirlik	17
3.2.5. Hata Toleransı	17
3.2.6. Donanım ve Hız	17
3.2.7. Analiz ve Tasarım Kolaylığı	17
3.3. YAPAY SİNİR AĞLARININ YAPISI	18
3.3.1. Biyolojik Sinir (Nöron) Hücresinin Yapısı	18
3.3.2. Yapay Sinir Ağlarının Yapısı	19
3.3.3.1. Giriş Katmanı	19
3.3.3.2. Ara Katman (Gizli Katman)	20
3.3.3.3. Çıkış Katmanı	20
3.3.4. Yapay Sinir Hücrelerinin Yapısı	20
3.3.4.1. Girdiler	21

3.3.4.2. Ağırlıklar	21
3.3.4.3. Toplama (Birleştirme) Fonksiyonu	21
3.3.4.4. Aktivasyon (Transfer) Fonksiyonları	22
3.3.4.4.1. Doğrusal (Lineer) Aktivasyon Fonksiyonu	23
3.3.4.4.2. Eşik Değer Aktivasyon Fonksiyonu	23
3.3.4.4.3. Adım (Step) Aktivasyon Fonksiyonu	24
3.3.4.4.4. Sigmoid Aktivasyon Fonksiyonu	24
3.3.4.4.5. Tanjant Hiperbolik Aktivasyon Fonksiyonu	25
3.3.4.5. Çıktılar	26
3.4. YAPAY SİNİR AĞLARININ SINIFLANDIRMASI	26
3.4.1. İleri Beslemeli Yapay Sinir Ağları	27
3.4.2. Geri Beslemeli Yapay Sinir Ağları	27
3.5. YAPAY SİNİR AĞLARI ÖĞRENME ALGORİTMALARI	28
3.5.1. Danışmanlı / Eğitici (Supervised) Öğrenme	28
3.5.2. Danışmansız / Eğitici (unsupervised) Öğrenme	28
3.5.3. Destekleyici/Takviyeli Öğrenme	29
3.6. YAPAY SİNİR AĞLARINDA ÖĞRENME KURALLARI	29
3.6.1. Hebb Kuralı	29
3.6.2. Delta Kuralı	29
3.6.3. Kohonen Kuralı	30
3.6.4. Hopfield Kuralı	30
4. UYGULAMA.....	31
4.1. GİRİŞ	31
4.2. ÖZYÜZLER (EİGENFACES) UYGULAMASI	31
4.2.1. Kullanılan Veri Tabanı	34
4.2.2. Özyüzler Uygulama Sonuçları	34
4.3. YAPAY SİNİR AĞLARI UYGULAMASI	41
4.3.1. Kullanılan Veri Tabanı	41
4.3.2. Yapay Sinir Ağları Uygulama Sonuçları	44
4.4. SONUÇ	47
5. SONUÇ VE DEĞERLENDİRME.....	49
5.1. TARTIŞMA VE ÖNERİLER	50
KAYNAKÇA	52
EKLER.....	56
EK:1. ÖZYÜZLER METODUNUN MATLAB UYGULAMASI.....	56
EK:2. YAPAY SİNİR AĞLARI MATLAB KODU.....	59
ÖZ GEÇMİŞ.....	60

KISALTMALAR

bk.	:	Bakınız
c	:	Cilt
ev.	:	eviren
haz.	:	Hazırlayan
no.	:	Numara
S	:	Sayı
s	:	Sayfa
vb.	:	Ve benzer(ler)i
yay.	:	Yayınevi, Yayınları
vd.	:	Ve diğlerleri
YSA	:	Yapay Sinir Ağları

TABLO LİSTESİ

Tablo No	Tablo Adı	Sayfa
Tablo 4.1	Test Sonucu Doğru Bulunan Örneklerden Bir Kısmı	35
Tablo 4.2	Test İşlemi Sonucu Yanlış Bulunan Örneklerin Bir Kısmı	36
Tablo 4.3	Özyüzler Performans Değerleri	40
Tablo 4.4	Veri Seti Koordinat Değerlerinden Bir Kısmı	43
Tablo 4.5	Hesaplanmış Ağız Bölgesi İçin Örnek Açık Değerleri	44
Tablo 4.6	Yapay Sinir Ağları Performans Değerleri	47
Tablo 4.7	Modellerin Performanslarının Karşılaştırılması	48

ŞEKİL LİSTESİ

Şekil No	Şekil Adı	Sayfa
Şekil 2.1	Öz Yüzler Akış Şeması	14
Şekil 3.1	Biyolojik Sinir Hücresi	18
Şekil 3.2	Yapay Sinir Ağlarının Yapısı	19
Şekil 3.3	Temel Yapay Sinir Ağı Hücresi	21
Şekil 3.4	Doğrusal aktivasyon fonksiyonu	23
Şekil 3.5	Eşik Değer Aktivasyon Fonksiyonu	24
Şekil 3.6	Sigmoid Aktivasyon Fonksiyonu	25
Şekil 3.7	Tanjant Hiperbolik Aktivasyon Fonksiyonu	26
Şekil 3.8	Çok Katmanlı ileri Beslemeli Yapay Sinir Ağı	27
Şekil 3.9	Geri Beslemeli Yapay Sinir Ağı	28
Şekil 4.1	Ortalama Averaj Yüz Resmi	32
Şekil 4.2	Veri Setlerimizden Hesaplanmış Örnek Öz Yüzler	33
Şekil 4.3	AT&T Veri Tabanından Bir Görüntü	34
Şekil 4.4	İdeal Görüntü Test Grafiği	38
Şekil 4.5	Göz Bölgesi Kapalı Görüntü Test Grafiği	38
Şekil 4.6	Ağız Ve Çene Bölgesi Kapalı Görüntü Test Grafiği	39
Şekil 4.7	Burun Bölgesi Kapalı Görüntü Test Grafiği	39
Şekil 4.8	Gürültülü Eklenmiş Görüntü Test Grafiği	40
Şekil 4.9	Ar Yüz Veri Tabanı Yüz Öz Nitelik Noktaları	42
Şekil 4.10	Tüm Açı Değerleri Kullanılan Test Grafiği	45
Şekil 4.11	Burun Bölgesi Açı Değerleri Eksik Test Grafiği	46
Şekil 4.12	Ağız Ve Çene Bölgesi Açı Değerleri Eksik Test Grafiği	46
Şekil 4.13	Göz Bölgesi Açı Değerleri Eksik Test Grafiği	47

ÖZET

Bu tez çalışması ile yüz tanımanın iki temel metodu görünüm ve öznitelik tabanlı yöntemlerin modellenerek karşılaştırılması ve iki metodun yüz tanıma sistemlerinde farklı alternatifler oluşturacak şekilde modellenmesi amaçlanmıştır. Bu amaçla görünüm tabanlı yöntem için özyüzler ve öznitelik tabanlı yöntem için ise yapay sinir ağları kullanılmıştır.

Özyüzler ve yapay sinir ağları için farklı veri tabanları kullanılarak sistemler eğitilmiş ve test verileri ile ağların sonuçları karşılaştırılmıştır. Farklı durumlardaki tanıma performansları ve yüz tanıma probleminin zorlukları karşısındaki başarımları değerlendirilmiştir. İki sistemin farklı durumlar için birbirinin alternatifi olabileceği belirlenmiştir.

Anahtar Kelimeler: Yüz Tanıma, Özyüzler, Yapay Sinir Ağları

ABSTRACT

This thesis view of two basic methods of face recognition and comparison with the operation of the feature-based methods and modeled in face recognition systems two methods are intended to be designed so as to generate different alternatives. For this purpose, eigenfaces for the view-based method and artificial neural Networks for the feature-based method are used.

The systems were trained using different data bases for eigenfaces and artificial neural networks, and the results of the test data and Networks were compared. The recognition performances in different situations and their performance against the difficulties of the face recognition problem have been evaluated. It has been determined that the two systems may be alternatives for different situations.

Keywords:Face Recognition, Eigenfaces, Artificial Neural Networks

1. GİRİŞ

1.1. Giriş

Bilişim teknolojilerinde yaşanan gelişmelerle birlikte hayatımıza giren pek çok yenilik olmuştur. Bunlardan bir tanesi ise biyometrik kimlik tespit teknolojisi. Bu teknolojiler hızla gelişmekte ve kendisine kullanım alanı bulmaktadır. Bir sektör haline de gelen global biyometrik sanayi, yayınlanan bir pazar araştırması çalışmasına göre, 2017 yılında 16.47 milyar doları aşan bir Pazar büyüklüğüne kavuşacağı öngörülmüştür (New report predicts Global Biometrics Market, 2011). Bu teknolojinin alt dallarından biri ise yüz tanıma sistemleridir. Yüz tanıma sistemleri, insanların dijital imgeler halinde kaydedilmiş yüzleri ile eğitilen bir sisteme, insanların eğitim aşamasında kullanılmayan yeni bir dijital yüz imgesi verildiğinde kimlik tespitinin yapıldığı uygulamalardır.

Yüz tanıma, yüksek güvenliğe olan artan ihtiyaçlar, internette çok fazla miktarlarda (sosyal medya hesapları vb.) dijital yüz imgelerinin bulunması ve görüntü yakalama araçlarındaki hızlı gelişmeler, sonucunda giderek daha önemli bir hale gelmiştir. (Liand,Jain 2011:1)

Herhangi bir fiziksel temasa ihtiyaç duymadan mevcut görüntüleme cihazları ile gelişmiş bir donanıma ihtiyaç duymadan elde edilen görüntülerle çalışabilmesi yüz tanıma sistemlerinin en büyük avantajıdır. (Jainand,Kumar 2010:3)

İdeal olmayan şartlarda yüz tanıma sistemlerinin başarı sağlamakta zorlanmasına karşın, görüntülerin elde edilmesinde kullanıcılara müdahale edilmemesi sayesinde sağlanan yüksek kullanıcı kabulü kontrollü ortamlarda kabul edilebilir düzeylerde tanıma performansı sağlamaktadır. (Biometrics 2011)

Yüz tanıma sistemlerinin temel amacı insan beyninin gerçekleştirdiği gibi bir tanıma işlemi makineler aracılığı ile gerçekleştirmektir. İnsan beyninin yüzleri nasıl tanıdığı tam olarak bilinmemesine rağmen beynimizin yüz tanıma işleminde oldukça başarılı olduğu açıktır. Yüz tanıma probleminin çözümünde farklı pek çok metot önerilmiş olsa da araştırmacıların yapmış oldukları çalışmalar, insan beyninin

belirli yüz özelliklerini tanıma amacıyla kullandığını ortaya koymuştur. (Goldstein, Harmon, Lesk 1971:59; Haig 1985:601; Rhodes 1988:43)

Yüz tanıma problemi bilim insanlarının üzerinde yoğun olarak çalıştıkları güncel, önemli ve zor problemlerden biridir. Günümüzde artan güvenlik gereksinimleri diğer biyometrik yöntemlere olduğu gibi yüz tanımaya olan ihtiyacın ve ilginin artmasına neden olmuştur. Bu konuda uzun zamandır çok sayıda bilimsel çalışma yapılmasına karşın, gerçek yaşamda karşılaşılan sorunları çözmeye yetecek başarıya sahip yüz tanıma sistemleri hala geliştirilememiştir. Yüz tanıma probleminin zorlukları arasında; pozdaki değişimler, ışık kaynağının yeri ve şiddetindeki değişimler, yüz ifadesindeki değişimler, ölçek sorunu, zamanla veya yaşlanmayla oluşan değişimler, tanınacak kişilerin çokluğu ve işlem zamanı yer almaktadır. (Gökmen, Kurt 2007:12)

Yüz tanıma sistemlerinin iki temel metodu vardır. Birinci yaklaşıma göre tüm yüz görüntüsünden elde edilen bilgi bir yüzü en iyi şekilde tanımlayan bilgidir. Bu yaklaşıma görünüm tabanlı (appearance-based) yüz tanıma yöntemi denir. İkinci yaklaşım ise bir yüzün ağız, burun, çene ve gözler gibi kısımlarından elde edilecek değerlerle oluşturulan öz niteliklerin tanıma amacıyla kullanılmasıdır. (Yaman 2006:2)

Bir yüzün bilgisi ister tüm yüzden isterse yüzün belirli kısımlarının öz niteliklerinden elde edilmiş olsun makineler aracılığıyla kimlik tespitin yapılabilmesi için bir modele ihtiyaç vardır. Bu tez çalışmamızda iki yöntemde modellenmiştir.

1.2. Tezin Amacı

Bu tez çalışması ile yüz tanımanın iki temel metodunun modellenerek karşılaştırılması ve iki metodun yüz tanıma sistemlerinde farklı alternatifler oluşturacak şekilde modellenmesi amaçlanmıştır. Geliştirilen modelde, Tüm yüz bilgisinden tanıma yaklaşımının modellenmesinde özyüzler yöntemi kullanılmıştır. Yüzün belirli kısımlarından elde edilen bilgilerle tanıma işleminin modellenmesinde ise Yapay Sinir Ağları yöntemi kullanılmıştır.

Bu tez çalışması ile ayrıca eğitim ve test verileri ile iki farklı yaklaşımın yüz tanıma problemine çözümü karşılaştırmalı olarak ortaya konulmuştur. Modellerin avantaj ve dezavantajları karşılaştırmalı olarak tanımlanması amaçlanmıştır.

Tüm yüz görüntülerinin elde edilmesi sırasında yaşanan zorluklar (pozdaki değişimler, ışık kaynağının yeri ve şiddetindeki değişimler, yüz ifadesindeki değişimler, ölçek sorunu, zamanla veya yaşlanmayla oluşan değişimler, sakal, bıyık, gözlük ve makyaj vb.) nedeni ile elde edilen yüz imgelerinde gürültüler oluşması durumunda özyüzler yaklaşımının probleme çözümü ile yapay sinir ağlarının probleme çözümü karşılaştırılmıştır.

Sonuç olarak bu tez çalışması ile yüz tanıma sistemlerinin temel iki yöntemi için farklı iki model geliştirilmiştir. Her iki yönteminde kullanılabilirliğine yönelik bir yapı karşılaştırmalı olarak ortaya konulmuştur.

1.3. Literatür Taraması

Literatürde, yüz tanıma sistemlerin geliştirilmesinde birçok çalışma yapıldığı ve farklı yaklaşımlar sunulduğu görülmektedir. Özellikle son yıllarda görüntüleme sistemlerindeki gelişmeler ve veri boyutlarındaki artış, bu verilerin ham halleriyle işlenmesinde güçlükler neden olmaktadır. Buna bağlı olarak geçmişten günümüze kullanılan yöntemler sürekli değişmekte ve gelişmektedir.

İlk olarak Kanade (1973:55) ayrıt haritaları ve histogramlar gibi basit görüntü işleme tekniklerini kullanarak öznitelik tabanlı öklid uzaklıklarıyla tanıma yapan insan yüzü tanıma sistemini gerçekleştirmiştir. Yuille vd., (1989:104) çok daha gelişmiş bir öznitelik çıkarma işlemi olan deformable template (bozulabilir şablon) yöntemini önermiştir. Reisfeld (1994:148) simetri operatörü ile Graf vd.,(1995:41) süzgeçleme ve morfolojik işlemlerini de ilk öznitelik tabanlı yüz tanıma çalışmalarına ekleyebiliriz. Roeder (1995:8) ve Colombo (1995:258) bu yöntemlerin gerçek zamanlı bir sistem için yüz bölgesini saptamada yeterli olmadığı tespit etmişlerdir.

Oldukça başarılı sonuçlar veren dalgacık dönüşümünü kullanarak öznitelik çıkaran Manjunath (1992:373) elde ettiği öznitelikleri insan yüzü tanımada

kullanmıştır. Turk vd., (1991:586) Karhunen - Loeve dönüşümüyle veri setinin daha düşük boyutlu bir uzayda ifade edilerek kullanabileceğini göstermiştir. Özyüz yönteminin tanıma başarısının daha iyi sonuçlar verdiği ise Pentland vd.,'ın son çalışmasından anlaşılmaktadır. (1994:84) Ancak bu dönüşümler doğrusal dönüşümlerdir ve bu algoritmalarda kullanılan yüz resimlerinin aydınlatmasının iyi olması ve önden çekilmesi gerekmektedir.(Xiaoguang, Hsu,2004:215)

Kirby vd.,(1990:12) orijinal metotlarını geliştirmek için çalışmalarını 115 dijital yüz görüntüsünün bulunduğu bir veri tabanı ile test etmişlerdir. Bu çalışma sonucunda elde ettikleri yaklaşık %97 bir doğruluk oranıyla yüzü yeniden oluşturmak için sadece 40 öz vektörün yeterli olduğunu göstermişlerdir. Yüzün simetri özelliklerini dikkate alarak (örneğin bütün yüzlerde gözler, burun v.s. aynı bölgede) geliştirdikleri son metotlarının algoritmasını 87 kişinin yüz resminin bulunduğu bir veri tabanında test etmişlerdir.

Turk vd., (1991:71) ilk tam otomatik sistemlerden birini yaparak bu fikri daha da geliştirmişlerdir. 16 kişiden elde edilen 2500 yüz resminden oluşan bir veri tabanında bu sistemlerini test etmişlerdir. Resimler farklı baş oryantasyonları, boyutları, ışıklandırma koşullarından seçilmiştir. Tasarladıkları sistem değişen resim ölçeklerinde %64 doğru sınıflandırma yaparken, farklı ışık değerlerine sahip resimlerde başarı %96 olmuştur. Resimler farklı baş oryantasyonunda seçildiğinde ise başarılarının %85 olduğu göstermişlerdir.

Pentland vd.,(1994:91) öz şablon kullanarak kısmi özellikleri çıkarmışlardır. Bayesian tabanlı istatistik metotlar ile tanıma işi için sadece öz yüz kullanmak gibi bir takım düzenlemeler yapmışlardır. Pentland vd.,'ın (1997:696) 3000 kişinin 7562 resmini barındıran bir veri tabanı kullanarak en iyi sistemlerinde yaklaşık olarak %95'lik bir doğru sınıflandırma elde etmişlerdir.

İnsan yüzü tanıma sistemlerinde genellikle görünüm tabanlı sistemler kullanılmaktadır. (Turk,Pentland 1991:591) Bu sistemlerin istenen başarıyı elde edebilmesi için yeterli sayıda ve değişik çevre koşullarında hazırlanmış bir veri seti ile eğitilmeleri gerekmektedir. Ancak gerçek zamanlı sistemlerin eğitiminde sınırlı sayıda veriye sahip olduğu için tanıma başarıları etkilenmektedir. (Belhumeur,

Hespanha 1997:711;Lee, Kriegman 2001:519)

Zhan vd.,(1997:1423)öz yüzler metodunda ışık değişikliği çok fazla olduğu zaman ciddi seviyede kötüleşme olduğunu göstermişlerdir.

O'Tool vd.,(1993:405) baskın öz yüzün bir yüzü tanıma işinde en uygun seçim olmadığını ama kodlamak için kullanmanın en uygun olduğunu göstermişlerdir. 100 kişilik bir öz yüz veri tabanında bulunan 45. ve 80. arasındaki herhangi bir 15 öz yüz seçiminin, en iyi öz yüz kadar, iyi ayırım gücüne sahip olduğunu göstermişlerdir.

O'Tool vd., (1991:411) 50 bayan ve 50 erketen oluşan 100 tane digital yüz imgesiyle test ettikleri iki çalışmada öz yüzler ve bir yüzün cinsiyet ve ırk gibi özellikleri arasındaki ilişkileri incelemişlerdir. %88.8 gibi yüksek bir oranla ikinci en büyük öz yüzün tek başına bir kişinin ırkını başarılı bir şekilde belirleyebildiğini göstermişlerdir. En yüksek öz değere sahip dört öz yüzün toplamının %74,3 oranında doğru cinsiyet tahminini yapabildiğini göstermişlerdir.

Aydınlatma ve poz değişimlerine duyarlı olmak gibi sorunlarına rağmen kullanımı en yaygın olan görünüm tabanlı yöntem Temel Bileşen Analizi temelli Özyüzler yöntemi olup, başarılı sonuçlar elde edilen özyüzlere dayalı yöntemler hala kullanılmaktadır. (Belhumeur, Hespanha 1997:720)

Kişinin tanınması, poz tahmini, yüz ifadelerinin belirlenmesi problemlerinde sıklıkla kullanılan model tabanlı yöntemler son yıllarda çalışma alanı olarak tercih edilmeye başlanmıştır. (Xiaoguang, Hsu 2004:250)

Arama algoritmasından kaynaklanan sorunlar yüzünden istenilen başarıyı elde edemeyen Nastar vd., (1996:589) insan yüzünün şekil ve görünümünü gri seviye yüzey modeli kullanarak üç boyutlu modellemeye çalışmıştır. İnsan yüzünün şekillerini gri seviye değerleri olarak ayrı ayrı modelleyen bir yöntemi Lanitis vd.,(1997:743) geliştirmiştir. Lanitis'in yöntemini gri seviye ve şekil bilgisi arasında bir ilişki olduğunu hesaplayarak modelleyen Edwards, (1997:756) modeli daha da geliştirmiştir.

Yüz tanıma sistemlerin performanslarının yüksek olabilmesi için iyi bir şekilde eğitilmeleri gerekmektedir. Veri setlerindeki resimlerin doğru olarak elde

edilebilmesine yönelik çalışmalar son yıllarda artmaktadır. Bu yaklaşımlarda en başarılı sonucu aktif görüntü modeli (active appearance model, AAM) olarak adlandıran sistem vermektedir. (Cootes, Edwards 2001:681)

%31 gibi yüksek bir yıllık bileşik büyüme oranına (CAGR) sahip yüz tanıma teknolojisinin diğer biyometrik teknolojiler arasında en hızlı büyüyen teknoloji olarak ortaya çıktığı dünya çapında kabul edilen bir gerçektir, gelecekte de aynı trendi takip etmeye devam edeceği öngörülmüştür. (Global Facial Recognition Market 2011)

1.4. Tez Düzeni

Tezin ilk bölümünde, konuya genel bir bakış açısı kazandırmaya yönelik temel bilgiler verilmiş, çalışmanın amacı sunulmuş, literatürde daha önce benzer alanlarda yapılan çalışmalar değerlendirilerek tezin temel dayanakları ve araştırma alanları tanımlanmış, çalışma mimarisi oluşturulmuş ve diğer bölümlerin içeriği kısaca sunulmuştur.

Bölüm 2'de, Özyüz tanıma modeli çerçevesinde, Özyüzler yaklaşımı hakkında bilgiler verilmiştir. Bu bölümde özellikle tezin temel araştırma alanlarından biri olan Özyüzler olarak belirlenen yüz tanıma sistemi kavramı detaylandırılmıştır. Özyüzler modelinin temeli olan Temel Bileşenler Analizi tanımlanmıştır. Daha sonra modelin matematiksel hesaplamaları ayrıntılı bir şekilde sunulmuştur.

Bölüm 3'te, tezin diğer bir çalışma alanı olan Yapay Sinir Ağları hakkında geniş bir bilgi verilmiştir. Yapay Sinir Ağlarının genel özellikleri ve yapısı ayrıntılı olarak açıklanmıştır. Bunlara ek olarak bu bölümde Yapay Sinir Ağlarının sınıflandırması ve öğrenme algoritmaları hakkında bilgiler verilmiştir.

Bölüm 4'te, teze konu olan Özyüzler ve Yapay Sinir Ağları ile oluşturulan uygulamalar hakkında bilgilendirme yapılmıştır. İlk olarak modelin işlevleri açıklanmış ve ardından modellerin eğitimleri için kullanılan veri tabanları tanıtılmıştır.

Bölüm 5'te ise tezin sonuçları kapsamlı olarak değerlendirilmiş ve ileride yapılacak çalışmalar için önerilerde bulunulmuştur.

2. ÖZYÜZLER – EIGENFACES

2.1. Giriş

Sirovich ve Kirby (1987:519) yüzü efektif bir formda göstermek için ilk defa kullandıkları bu yöntem öz yüzler (Eigenfaces, Principal Component Analysis, PCA) olarak bilinmektedir. Karhunen-Louve genişlemesine dayanmaktadır. Bu yöntem Temel bileşen analizi olarak da bilinmektedir. Yüz resimlerinden oluşan uzayın dağılımını temsil eden temel bileşenlerin bulunması amaçlanmaktadır.

Temel bileşen analizi; değişkenlerden oluşan bir veri kümesinin varyans – kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri yardımıyla açıklayarak, boyut indirgemesi ve yorumlamasını sağlayan birçok değişkenli istatistiksel yöntemdir. (Yaycılı 2006:56)

Eigenfaces yönteminde amaç yüz uzayındaki resimleri Temel Bileşenler Analizi(PCA) kullanarak daha az boyutlu bir alt uzayda ifade etmektir. Eigenfaces yöntemi yüz uzayının temel bileşenlerini ve yüz vektörlerinin temel bileşenler üzerine izdüşümünü kullanır. Bu yöntem boyut indirgeme yöntemidir ve yüz uzayının boyutunu azalttığı için tanıma ve öğrenme işlemlerini hızlıdır.

Yüz uzayında bulunan resimlerin değerleri arasındaki varyanslardan yararlanır. Örneğin bir x değeri y ile bağlantılı ise ve x 'in değerini bilmek y 'nin değerini ifade etmede yeterli ise (x,y) iki boyutlu uzayı yerine tek boyutlu x değerlerini tutmak yeterli olacaktır.

2.2. Öz Yüzlerin (Eigenface) Hesaplaması

$I(x,y)$ yüz görüntüsü, 8 bit yoğunluk değerlerine (Gri seviye resim) sahip $N \times N$ boyutlu bir matristir. $N \times N$ 'lik bir matris N^2 boyutunda bir vektör olarak düşünülebilir. Yani 128×128 boyutundaki tipik bir görüntü 16,384 boyutunda bir vektör veya eşit şekilde 16,384 boyutlu uzayda bir nokta olur.

Aynı olan yüz görüntüleri, bu büyük uzayda rastgele bir şekilde dağılmayacaktır ve bu nedenle nispeten düşük boyutlu alt uzayda tarif edilebilir.

Temel bileşen analizinin ana fikri, tüm görüntü uzayında yüz görüntülerinin dağıtılmasını en iyi açıklayan vektörleri bulmaktır.

Bu vektörler, orijinal yüz görüntülerine karşılık gelen kovaryans matrisinin öz vektörleri olduğundan ve görünüm olarak yüze benzediklerinden bunlara “özyüzler – eigenfaces ” adı verilir.

1. Eğitim için kullanılacak veri setimizde M adet yüz resmi var ise ve bunları S kümesinde gösterecek olursak yüz uzayımız formül 1’deki gibi gösterilebilir. Γ_i yüz uzayındaki bir resmi ifade etmektedir. Γ_i değerleri $N \times N$ ’lik bir resmin N^2 boyutlu vektörüdür.

$$S = \{\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M\} \quad N \times M \quad (1)$$

$$S = \begin{bmatrix} \Gamma_1^1 & \Gamma_1^2 & \dots & \Gamma_1^M \\ \Gamma_2^1 & \Gamma_2^2 & \dots & \Gamma_2^M \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma_N^1 & \Gamma_N^2 & \dots & \Gamma_N^M \end{bmatrix} \quad (2)$$

2. Yüz uzayındaki yüz resimlerinin ortalaması alınarak ortalama(average) yüz bulunur. Ψ Eğitim setinin ortalama matrisi formül 3’deki gibi hesaplanır.

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n = \begin{bmatrix} \Psi_1 \\ \Psi_2 \\ \vdots \\ \Psi_N \end{bmatrix} \quad (3)$$

3. Yüz uzayındaki her yüz vektör değerinden ortalama yüz değeri çıkarılarak yüz uzayının ortalama yüzleri bulunur (normalizasyon). Buradaki amaç ortalama değeri sıfır olan bir veri kümesi elde etmektir. Ortalaması

hesaplanmış verilerin vektörleri Φ_i ve bu vektörlerden oluşan matris A şeklinde gösterilirse ortalaması çıkarılmış vektörler ve matris formül 4 ve 5'deki gibi hesaplanır.

$$\Phi_i = \Gamma_i - \Psi \quad (4)$$

$$A = \begin{bmatrix} \Phi_1^1 - \Psi_1 & \Phi_1^2 - \Psi_1 & \dots & \Phi_1^M - \Psi_1 \\ \Phi_2^1 - \Psi_2 & \Phi_2^2 - \Psi_2 & \dots & \Phi_2^M - \Psi_2 \\ \vdots & \vdots & \ddots & \vdots \\ \Phi_N^1 - \Psi_N & \Phi_N^2 - \Psi_N & \dots & \Phi_N^M - \Psi_N \end{bmatrix} \quad (5)$$

4. Sıfır ortalamalı A matrisinin kovaryans matrisi C formül 6'daki gibi hesaplanır.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (6)$$

$$C = \begin{bmatrix} (\Gamma_1^1 - \Psi_1)^2 & (\Gamma_1^1 - \Psi_1)(\Gamma_1^2 - \Psi_2) & \dots & (\Gamma_1^1 - \Psi_1)(\Gamma_1^M - \Psi_N) \\ (\Gamma_1^2 - \Psi_2)(\Gamma_1^1 - \Psi_1) & (\Gamma_1^2 - \Psi_2)^2 & \dots & (\Gamma_1^2 - \Psi_2)(\Gamma_1^M - \Psi_N) \\ \vdots & \vdots & \ddots & \vdots \\ (\Gamma_1^M - \Psi_N)(\Gamma_1^1 - \Psi_1) & (\Gamma_1^M - \Psi_N)(\Gamma_1^2 - \Psi_2) & \dots & (\Gamma_1^M - \Psi_N)^2 \end{bmatrix}$$

Burada köşegen üzerinde bulunan değerler varyans, diğerleri ise kovaryans değerleridir. Varyans diğer boyutlardan bağımsız olarak yalnızca bir boyuttaki verinin ortalama etrafındaki dağılımı hakkında bilgi vermektedir. Kovaryans ise bir değişkenin diğer değişkenlerle birlikte nasıl bir değişim gösterdiği hakkında bilgi verir ve daima iki değişken arasında hesaplanır. (Konak, 2006:58) C kovaryans matrisi simetrik bir matristir ve öz değerleri (eigenvalue) ve öz vektörleri (eigenvector) hesaplanabilir.

5. Kovaryans matrisine ait öz değer ve öz vektörlerin hesaplanmasında formül 7 kullanılır. C , $N \times N$ boyutlu bir matris, λ herhangi bir skaler ve v sıfırdan farklı bir sütun vektör olmak üzere aşağıdaki eşitliği sağlayan λ sayısı C matrisinin öz değeri ve v de λ ile ilişkili öz vektördür.

$$Cv = \lambda v \quad (7)$$

λ öz değerlerinin hesaplanmasında I_n birim matris olmak üzere,

$$Cv = \lambda v \quad (7)$$

$$\lambda v - Cv = 0 \quad (8)$$

$$(\lambda I_n - C)v = 0 \quad (9)$$

Şeklinde yazılabilir. $(\lambda I_n - C)v = 0$ ifadesi $(C - \lambda I_n)v = 0$ şeklinde de yazılabilir ve ilk ifade için verilebilecek tanımlar ikinci ifade içinde doğrudur. (Pentland, Moghaddam 1991:586)

$\lambda I_n - C$ ifadesi matris formda,

$$\lambda I_n - C = \begin{bmatrix} \lambda - c_1^1 & -c_1^2 & \dots & -c_1^n \\ -c_2^1 & \lambda - c_2^2 & \dots & -c_2^n \\ \dots & \dots & \dots & \dots \\ -c_n^1 & c_n^2 & \dots & \lambda - c_n^n \end{bmatrix} \quad (10)$$

şeklinde gösterilebilir. Bu matrisin determinantına C matrisinin karakteristik polinomu denir. $v \neq 0$ çözümü için,

$$p(\lambda) = \det(\lambda I_n - C) = 0 \quad (11)$$

olmalıdır. Buna C matrisinin karakteristik denklemi denir. Bu denklemin kökleri C matrisinin öz değerlerini verir. Bu öz değerler formül 9'da yerine yazılırsa bu öz değerlere karşı gelen öz vektörler elde edilir.

Elde edilen öz değer matrisindeki en büyük değere sahip olan bileşen temel bileşendir. Yani veri kümesi içindeki en önemli ilişkidir. Öz değerler küçükten büyüğe doğru sıralanacak biçimde dizildiğinde, en önemli olandan en az önemli olan bileşene doğru sıralanmış olur. Bu dizilime göre istenirse sıfıra yakın veya ihmal edilebilecek daha az önemli olan bileşenler elenerek boyut azaltılmış olur. Bu şekilde seçilmiş öz vektörlerden oluşan matrise öz nitelik matrisi denir.

6. Öz değer ve öz vektörler hesaplandıktan sonra u öz yüzlerin hesaplanmasına geçilir. Öz yüzler Φ ortalama değerlerinin öz vektörlerin oluşturduğu matrisle çarpılarak formül 12'deki gibi hesaplanabilir.

$$u_i = \sum_{k=1}^M v_{ik} \Phi_k \quad l = 1, 2, \dots, M \quad (12)$$

7. Tanıma işlemine geçilmeden öz yüzler matrisi A veri kümesine iz düşürülerek temel bileşenler analizi ile boyut azaltma işlemi gerçekleştirilmiş olur. u , yüksek öz değere gelen öz yüzler matrisinin transpozu ve A veri matrisi çarpılarak Ω matrisi formül 13'deki gibi oluşturulur.

$$\Omega = u^T x A \quad (13)$$

v ve Ω matrisi belirlenerek eğitim aşaması tamamlanmış olur.

8. Tanıma işlemi için ilk olarak test resmi ile ortalama resim arasındaki fark bulunur ve bu fark her öz vektör değeri ile formül 14'deki gibi çarpılır. Bu çarpım sonucu elde edilen veriler ile Ω^T matrisi oluşturulur.

$$\omega_k = u_k^T (\Gamma - \Psi) \quad k = 1, 2, \dots, M \quad (14)$$

$$\Omega^T = [\omega_1, \omega_2, \dots, \omega_M] \quad (15)$$

Hangi yüz sınıfının test resmi için en uygun tanımlama olduğunu bulunur. Bu işlem öklid uzaklığının minimize edilmesi ile gerçekleşir.


$$\varepsilon_k = \|\Omega^T - \Omega\|^2 \quad (16)$$

ε_k değerinin minimum olduğu değere ait yüz resmi tanıma sonucu olarak bulunmuş olur.

2.4. Öz Yüzler Algoritması

- 1 - Eğitimde kullanılacak resimleri al.
- 2 – Her bir resmi sütun vektöre dönüştür. (S)
- 3 – Tüm sütun vektörlerini birleştirerek bir matris oluştur. (M)
- 4 – Oluşturmuş olduğun matrisin aynı satır değerlerini topla ve sütun sayısına yanı resim sayısına böl ve ortalama yüz vektörü (averaj resmi) hesapla. (O)
- 5 - M matrisinden O ortalama yüz vektörünü çıkar ve her bir resmin ortalama etrafındaki dağılımını veren fark matrisini hesapla. ($F = M - O$)
- 6 – Fark matrisini kendi tranpozu ile çarp ve kovaryans matrisi bul. ($C = F * F^T$)
- 7 –Kovaryans matrisinin öz değer ve öz vektörlerini hesapla.
- 8 –Öz değeri 1’den büyük olan öz vektörleri al ve diğerlerini çıkar. (V)
- 9 – Öz vektörleri ile Kovaryans matrisini çarparak öz yüzleri hesapla. ($\text{ÖY} = C * V$).
- 10 – Öz yüzler matrisinin transpozu ile fark matrisini çarp ve boyut azalma işlemini gerçekleştir. ($A = F * \text{ÖY}^T$)
- 10 – Test resimlerini al.
- 11 – Test resimlerini sütun matrise düştür.(T)
- 12 – Test resimlerinden O ortalama matrisi çıkar ve farkı bul.($F_T = T - O$)
- 13 -Test resimlerinin ortalama resimler arasındaki fark matrisini öz yüzler ile çarp. ($B = F_T * \text{ÖY}$)
- 14 –Hesaplanan B değerlerinden A değerini çıkarı karesini al ve Öklid mesafelerini hesapla ($\text{Öklid} = (B - A)^2$).
- 15 – En küçük Öklid değerine denk gelen resmi tanıma işleminin sonucu olarak göster.

2.3. Öz Yüzler Akış Şeması



Şekil 2.1 – Öz Yüzler Akış Şeması

3. YAPAY SİNİR AĞLARI

3.1. Giriş

Yapay sinir ağları (YSA), insan beyninin öğrenme yolu ile yeni bilgiler üretme ve keşfedebilme gibi becerilerini otomatik olarak gerçekleştirebilmek amacı ile geliştirilen bilgisayar sistemleridir.(Öztemel 2003:238) Yapay Sinir Ağları, eğitim verileri ile eğitilerek öğrenebilme ve genelleme yapabilme özellikleri sayesinde çok esnek ve güçlü araçlar olma özelliğine sahiptirler. Bu sebeple Yapay Zekâ biliminin altında araştırmacıların çok yoğun ilgi gösterdikleri bir araştırma alanıdır. (Saraç 2004:4)

İnsan beyninin ve düşünme yeteneğinin taklit edilmesi çok eski zamanlarda var olmuş bir istektir. İlk olarak insan beyni ve düşünebilme becerileri üzerine teori geliştirme çalışmaları Antik Yunan düşünürleri olan Plato (İ.Ö. 427-327) ve Aristoteles'e (İ.Ö. 384-322) tarafından ortaya atılmıştır. (Saraç 2004:15)

Bir sinir hekimi olan Warren.S. McCulloch ve matematikçi WalterA. Pitts'in, 1943 yılında yayınladıkları bir makaleyle yapay sinir ağlarının dayandığı ilk hesaplama modelinin temelleri atılmış ve ilk yapay sinir ağı modeli gerçekleştirilmiştir. İnsan beyninin hesaplama yeteneğini temel alan McCulloch ve Pitts,, elektrik devreleriyle bu yeteneği taklit eden basit bir sinir ağı modellemişlerdir. Yapay sinir hücrelerine dayanan eşik değerli mantıksal devrelerin geliştirilmesi ve hesaplama teorisinin ortaya atılması bu yılda olmuştur. (Karaboyacı 2009:109)

1954 yılında B.G. Farley ve W.A. Clark'ın geliştirdiği uyarılara adapte olabilen ve bir ağ içerisinde uyarılara tepki veren modelden sonra 1960 yılı ilk neural bilgisayarın ortaya çıkış yılıdır. Ancak 1970 ve 1980'lere kadar başarılı sonuçlar alınamamıştır. Başarılı sonuçlar alınması termodinamikteki teorik yapıların doğrusal olmayan ağların geliştirilmesinde kullanılmasıyla sağlanmıştır. Yapay sinir ağların tanınması ve yoğun araştırmaların başladığı yıl 1985 olmuştur. (Benjamin 1992:45)

Yapay sinir ağları insan beyninin öğrenme, ilişkilendirme, sınıflandırma,

genelleme, tahmin, özellik belirleme ve optimizasyon gibi fonksiyonel özelliklerini başarılı bir şekilde uygulamaktadır. Bu özellikleri sayesinde arıza analizi ve tespiti, tıp, haberleşme, savunma, üretim ve otomasyon gibi çok farklı alanlarda kullanıldığından günümüzde kullanım alanlarını belirli gruplara ayırmak zorlaşmıştır.

3.2. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağları sahip oldukları genelleme yeteneği, paralel dağıtılmış yapısı ve eğitilerek öğrenebilme gibi yetenekleri sayesinde çok güçlü veri işleme ve hesaplama becerisine sahip olduğu söylenebilir. Genelleme eğitilmiş bir yapay sinir ağının eğitim sürecinde kullanılmayan veri girişleri için de uygun sonuçlar vermesi olarak tanımlanabilir. Tüm bu üstün becerileri sayesinde yapay sinir ağları doğrusal olmayan karmaşık problemlerin çözümünde oldukça başarılı sonuçlar göstermektedir. Yapay Sinir Ağlarının (YSA), aşağıdaki özellikleri nedeniyle günümüzde birçok bilim alanında etkin olmuş ve uygulama yeri bulmuştur. (Yüksek 2007:16)

3.2.1. Doğrusal Olmama

Yapay sinir ağlarını oluşturan en önemli elemanlar olan hücreler doğrusal değildir. Bunun sonucu olarak hücrelerin bir araya gelmesi ile oluşan yapay sinir ağları da doğrusal olamazlar. Doğrusal olmayan bu yapı bütün ağı kapsamaktadır. Bu sayede doğrusal olmayan karmaşık problemlerin çözümünde en önemli araçlardan birisi yapay sinir ağları olmuştur. (Yüksek 2007:16)

3.2.2. Öğrenme

Yapay sinir ağlarının istenilen sonuçları üretebilmesi için eğitilmesi gerekir. Bu eğitim amaca uygun olmalıdır. Bunun için hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlık değerlene sahip olmasını gerekir. Yapay sinir ağlarının yapısından dolayı bağlantılar ve ağırlık değerleri eğitimden önce tasarlanamaz ve verilemez. Bu nedenle yapay sinir ağları eğitim örneklerini kullanarak problemi öğrenmelidir. (Yüksek 2007:16)

3.2.3. Genelleme

Yapay sinir ağıları uygun bir şekilde eğitildikten sonra, eğitim sırasında kullanılmayan test verileri içinde istenilen sonuçları üretebilir. Örneğin, yüz tanıma amacıyla eğitilmiş bir yapay sinir ağı, uygun şartlarda alınmamış yüz verisi girişlerinde de doğru sonuçları üretebilir. Eğitilmiş yapay sinir ağı modeli, eğitim sürecinde kullanılan veri seti içerisinde yer almayan giriş verileri için de arzu edilen sonuçları üretebilir. (Yüksek 2007:16)

3.2.4. Uyarlanabilirlik

Yapay sinir ağıları veri setinin değerlerine göre hücrelerin ağırlıklarını ayarlar. Bu sayede yapay sinir ağıları çözüm ürettiği problemdeki değişimler sonucu çıkan yeni verilerle tekrar eğitilebilir. Değişimlerin devamlılığı durumunda gerçek zamanlı olarak eğitime devam edilebilir. (Yüksek 2007:16)

3.2.5. Hata Toleransı

Yapay sinir ağıları yapısı gereği pek çok hücrenin bağlanması ile oluşur. Bu nedenle yapay sinir ağıları paralel dağılmış bir yapıya sahiptir. Paralel dağılmış yapısı sayesinde ağı girişlerindeki bilgi, ağıdaki bütün bağlantıların üzerine dağılmış durumdadır. Bunun sonucu olarak, yapay sinir ağındaki bazı bağlantılar veya hücrelerin etkisiz hale gelmesi ağı doğru sonuçlar üretmesini önemli ölçüde etkilemez. Yapay sinir ağlarının hataları tolere etme yeteneği bu nedenle geleneksel yöntemlere göre son derece başarılıdır. (Yüksek 2007:17)

3.2.6. Donanım ve Hız

Yapay sinir ağıları paralel yapısı nedeniyle entegre devre teknolojisi ile tasarlanabilir. Bu özelliği sayesinde hızlı bir şekilde çalışıp problem çözme yeteneğine sahiptir. (Yüksek 2007:17)

3.2.7. Analiz ve Tasarım Kolaylığı


Tüm yapay sinir ağı modellerinde kullanılan temel eleman olan hücrenin yapısı yaklaşık olarak aynıdır. Bundan dolayı farklı alanlarda kullanılan yapay sinir ağlarının hepsi standart yapıdaki bu hücrelerden oluşmaktadır. Bu sayede farklı

uygulama alanları için tasarlanan yapay sinir ağı benzer öğrenme algoritmaları ve prensiplere sahip olabilirler. Bu özellik yapay sinir ağılarıyla problemlerin çözümünde çok önemli bir kolaylık sağlamaktadır. (Yüksek 2007:17)

3.3. Yapay Sinir Ağlarının Yapısı

3.3.1. Biyolojik Sinir (Nöron) Hücresinin Yapısı

Sinir hücreleri sinir sistemini oluşturan temel elemanlardır. Nöron olarak isimlendirilen bu hücrelerin birbirleri ile oluşturdukları bağlantılara ağ(network) denir. Birbiriyle bağlantılı iki nöronun axon, dentrite, synapse ve soma olma üzere dört önemli bölümü bulunmaktadır. Bu yapının bütünü sinir sistemini oluşturur. İnsan beyinde 10 milyar sinir hücresi (nöron) ve hücreler arası 60 trilyon synapse olduğu tahmin edilmektedir. (Elmas 2003:176)



Şekil 3.1- Biyolojik Sinir Hücresi (Yüksek 2007:11)


Duyu organlarından alınan uyarılar sinirlerin girdi bilgileri olarak kullanılırlar. Her bir sinir hücresi aldıkları sinyalleri işleyerek bir sonraki hücreye aktarır ve sinyalin merkezi sinir sistemine kadar ulaşması sağlanır. Sinir hücrelerinden gelen uyarılar (elektiriksel sinyaller) synapslar üzerinden dentritlerine alınır. Gelen sinyaller güçlendirilir ya da zayıflatılır ve hücre gövdesine iletilirler.

Kuvvetlendirme ve zayıflatma etkilerine göre gelen sinyaller hücre gövdesinde işlenir. Gelen sinyaller etkileşim sonucunda yeteri bir eşit değerini aşacak şekilde kuvvetlenirlerse, aksona sinyal gönderilir ve sinir aktif hale getirilir. Aksi takdirde, sinyal gönderilmez ve sinir pasif durumda kalır. (Elmas 2003:205)

3.3.2. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları ile aslında biyolojik sinir ağlarının bir benzeri modellenmeye çalışılmaktadır. Sinir hücreleri bir birleri ile bağlantılı olarak işlem yaptıklarından dolayı ağ (network) olarak isimlendirilirler. Bir sinir ağları grubunda binlerce nöron bulunabilir. Yapay sinir hücrelerinin birbirleri ile bağlantı kurarak oluşturdukları bu yapıya yapay sinir ağları denilmektedir. (Elmas 2003:210)

Yapay sinir hücrelerinin bir araya gelmeleriyle yapay sinir ağlarının katmanları oluşmaktadır. Yapay sinir ağları 3 katmandan oluşur. Giriş katmanı, ara (gizli) katmanlar ve çıkış katmanı. (Elmas 2003:215)



Şekil 3.2– Yapay Sinir Ağlarının Yapısı (Öztemel 2003:238)

3.3.3.1. Giriş Katmanı

Yapay sinir ağına tasarımcı tarafından girdilerin geldiği katmandır. Bu katmanda giriş sayısı kadar hücre bulunmaktadır. Bazı ağlarda bu katmanda girdiler herhangi bir işleme tutulmadan bir sonraki katmana gönderilirler. (Elmas 2003:211)

3.3.3.2. Ara Katman (Gizli Katman)


Girdi katmanından gelen bilgiler çıktı katmanına gönderilmeden önce işlenirler. Bu işlem ara katmanlarda gerçekleştirilir. Ara katmanların sayısı sabit değildir. Ağdan ağa değişebildiği gibi bazı ağlarda ara katman bulunmayabilir. Bazı yapay sinir ağlarında ise birden fazla ara katman bulunmaktadır. Ara katmanlar oluşturulurken belirlenen nöron sayıları giriş ve çıkış sayısından bağımsız olarak belirlenebilir. Oluşturulan yapay sinir ağı modelinde birden fazla ara katman kullanılacak olsa bile bu katmanlardaki nöron sayıları aynı olmak zorunda değildir. Oluşturulan modeldeki ara katman ve nöronların sayısının artması hesaplama karmaşıklığını ve süresini arttırmasına rağmen yapay sinir ağının daha karmaşık problemlerin çözümünde de kullanılabilmesini sağlar.(Elmas 2003:218)

3.3.3.3. Çıkış Katmanı

Ağın çıktılarının üretildiği katmandır. Bu katmana bilgiler ara katmanlardan gelir ve son işlemden sonra çıktı üretilir. Bu aşamadan sonra üretilen değerler geri beslemeli ağlarda ağın yeni ağırlık değerleri hesaplamak için kullanılabilir ama diğer ağlarda dış dünyaya çıktı olarak verilir.(Elmas 2003:219)

3.3.4. Yapay Sinir Hücrelerinin Yapısı

Biyolojik sinir hücreleri taklit edilerek tasarlandığı için yapay sinir hücreleri yapı olarak biyolojik sinir hücrelerine benzemektedirler. Yapay sinir hücresi yapay sinir ağlarını oluşturan ve çalışmasını sağlayan temel bilgi işleme birimidir. Yapay sinir ağını oluşturan tüm hücreler bir veya daha fazla girdi alabilmesine rağmen sadece bir tane çıktı üretebilirler. Hücrelerin üretmiş oldukları çıktı değerleri sonuç olarak üretilen çıktılar olabileceği gibi komşu hücrelerine girdi olarak da kullanılabilirler. Biyolojik sinir hücresi nöronlarda olduğu gibi yapay sinir hücrelerinde de girdi sinyallerini aldıkları, toplanıp işlendiği ve çıktı olarak verildiği bölümleri vardır. Bir yapay sinir hücresi girdiler, ağırlıklar, toplama (birleştirme) fonksiyonları, aktivasyon (transfer) fonksiyonu ve çıktılar olmak üzere beş bölümden oluşmaktadır. (Saraç 2004:42)



Şekil 3.3 – Temel Yapay Sinir Ağı Hücresi (Yüksek 2007:15)

3.3.4.1. Girdiler

Girdiler yapay sinir hücresine gelen verilerdir. Yapay sinir hücresine girdiler dış ortamlardan veya diğer hücrelerden gelen verilerdir.(Saraç 2004:43)

3.3.4.2. Ağırlıklar

Girdilerin değerlerinin hücreler üzerindeki etkilerini belirleyen göreceli kuvvetini (matematiksel katsayısını) gösterir. Bir yapay sinir ağını oluşturan hücrelerin her biri arasındaki bağlantıların farklı ağırlık değerleri mevcuttur. Ağırlık değerler ile çarpılarak bulunan değer ile üretilecek çıktının değeri üzerinde girdi değerinin etkisi ayarlanmaktadır. Kullanılan ağırlıkların değerleri pozitif, negatif veya sıfır olabilir. Ağırlığı sıfır olan girdilerin çıktı üzerinde herhangi bir etkisi olmamaktadır.(Saraç 2004:43)

3.3.4.3. Toplama (Birleştirme) Fonksiyonu

Bu fonksiyon yapay sinir hücresinin net girdisinin hesaplandığı fonksiyondur. Bu işlemin sonucu her girdi değerinin kendi ağırlık değeri ile çarpılarak toplanmaları

ile bulunur. Toplama veya birleştirme isimleri ile adlandırılan fonksiyon, oluşturulan yapay sinir ağının yapısına göre farklı fonksiyonlar olarak seçilebilir. (Saraç 2004:44)

Bazı Toplama Fonksiyonları

V: Hücrenin Net Girişini

W: Hücrenin Ağırlıklar Matrisini

X: Hücrenin Giriş Vektörü

Toplam
$$V = \sum_{i=1}^N X_i * W_i$$

Çarpım
$$V = \prod_{i=1}^N X_i * W_i$$

Maksimum
$$V = \text{Max}(X_i * W_i)$$

Minimum
$$V = \text{Min}(X_i * W_i)$$

Çoğunluk
$$V = \sum_{i=1}^N \text{Sgn}(X_i * W_i)$$

Kümülatif Toplam
$$V = \text{Net}(\text{eski}) + \sum_{i=1}^N X_i * W_i$$

3.3.4.4. Aktivasyon (Transfer) Fonksiyonları

Yapay sinir hücrelerinin toplama fonksiyonları ile hesaplanan net girdi değerleri kullanılarak bir çıktı değeri hesaplanır. Bu çıktı değerinin hesaplanmasında kullanılan matematiksel fonksiyonlardır. Bu fonksiyonlar yapısı gereği biri dışında doğrusal olmayan fonksiyonlardır. Bu özellikleri sayesinde Yapay sinir ağları doğrusal olmama özelliği kazanırlar. Bu fonksiyona sıkıştırma, transfer, işlemci veya eşik fonksiyonu gibi farklı isimlerde verilebilmektedir. Aktivasyon fonksiyonu tasarlanan sistemin yapısına ve gerçekleştireceği işleve göre farklı türde aktivasyon fonksiyonu kullanılabilir. Bu fonksiyonun seçimi ağın eğitiminde kullanılan veri


setine ve ağıın çözmeye çalıştığı probleme bağlıdır.(Saraç 2004:45)

Yapay sinir ağı sistemleri tasarlanırken sıklıkla tercih edilen aktivasyon fonksiyonları aşağıda açıklanmıştır.

3.3.4.4.1. Doğrusal (Lineer) Aktivasyon Fonksiyonu

Doğrusal olan tek aktivasyon fonksiyonudur. Doğrusal problemler çözümüd kullanılmak için seçilebilir. Bu fonksiyonda toplama fonksiyonu ile hesaplanan net girdi sabit bir değerle çarpılarak hücrenin çıktı değeri üretilir. Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. (Taşova 2011:17)

Şekil 'de doğrusal aktivasyon fonksiyonunun grafiği gösterilmektedir.




Şekil 3.4– Doğrusal aktivasyon fonksiyonu (Taşova 2011:17)

3.3.4.4.2. Eşik Değer Aktivasyon Fonksiyonu

Toplama fonksiyonundan çıkan sonuç belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır. (Öztemel 2003:238)

$$f(net) = \begin{cases} 0, & net \leq EşikDeğer \\ 1, & net > EşikDeğer \end{cases}$$

Şekil 'de eşik değer aktivasyon fonksiyonunun grafiği gösterilmektedir.



Şekil 3.5 – Eşik Değer Aktivasyon Fonksiyonu (Taşova 2011:18)

3.3.4.4.3. Adım (Step) Aktivasyon Fonksiyonu

Toplama fonksiyonundan çıkan sonuç 0'dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı ve 0 ile 1 arasında olduğunda ise yine toplama fonksiyonundan gelen değeri veren çıktılar üretilebilir. (Öztemel 2003:240)

$$f(net) = \begin{cases} 0, & net \leq 0 \\ net, & 0 < net < 1 \\ 1, & net \geq 1 \end{cases}$$

3.3.4.4.4. Sigmoid Aktivasyon Fonksiyonu


Sigmoid Aktivasyon Fonksiyonu, sürekli ve doğrusal olmayan bir fonksiyondur, türevi alınabilir. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en çok kullanılan aktivasyon fonksiyonudur. Bu fonksiyon, toplama fonksiyonundan çıkan her sonuç değeri için sıfır ile bir arasında bir değer üretir. Türevlenebilir olduğu için geriye yayılım algoritmaları ile kullanılabilir.

(Öztemel2003:240)

$$f(\text{net}) = \frac{1}{1 + e^{-\beta \text{net}}}$$

β eğim sabiti olup genelde 1 olarak seçilmektedir.

Şekil 'de sigmoid aktivasyon fonksiyonunun grafiği gösterilmektedir.




Şekil 3.6 – Sigmoid Aktivasyon Fonksiyonu (Taşova 2011:19)

3.3.4.4.5. Tanjant Hiperbolik Aktivasyon Fonksiyonu

Bu fonksiyon sigmoid fonksiyonuna benzeyen bir fonksiyondur. Bu iki fonksiyon arasındaki fark sigmoid fonksiyonunda üretilen çıkış değerleri 0 ve 1 arasında değerlerdir. Ancak hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir. Ürettiği değerler itibari ile negatif değerler bulunan zaman serileri gibi problemlerin çözünmede kullanılabilir. (Öztemel 2003:241)

$$f(\text{net}) = \frac{e^{\text{net}} + e^{-\text{net}}}{e^{\text{net}} - e^{-\text{net}}}$$

Şekil 3.7'de Tanjant Hiperbolik aktivasyon fonksiyonunun grafiği gösterilmektedir.



Şekil 3.7 – Tanjant Hiperbolik Aktivasyon Fonksiyonu (Taşova 2011:20)

3.3.4.5. Çıktılar


Yapay sinir hücrelerinin ürettiği çıktı değerleridir. Aktivasyon fonksiyonun ürettiği değerler sistemin veya hücrenin net çıktısı olarak bulunur. Bu değer doğrudan dış dünyaya verilebileceği gibi geri beslemeli ağlarda olduğu gibi ağı yeni ağırlık değerlerinin hesaplanmasında kullanılabilir. Yapay sinir ağı hücrelerinin birden fazla girdisi olabilmesine rağmen sadece tek bir çıktısı olmaktadır. Bu çıktı değerleri ihtiyaca göre değişken sayıda hücreye girdi olarak kullanılabilir. (Öztemel 2003:241)

3.4. Yapay Sinir Ağlarının Sınıflandırması

Yapay sinir ağlarını işleyiş mantığı genel olarak birbirine benzemektedir. Bununla birlikte herhangi bir tasarım ve işleyiş standardı bulunmamaktadır. Tasarlanan modellerde seçilen öğrenme kuralı, aktivasyon fonksiyonu ve hücre sayılarına göre çeşitli yapay sinir ağları modelleri geliştirilmiştir. Yapay sinir ağları yapısal olarak iki gruba ayrılmıştır. Bunlar ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olarak isimlendirilir. (Öztemel 2003:244)

3.4.1. İleri Beslemeli Yapay Sinir Ağları


İleri beslemeli yapay sinir ağları tek katmanlı ve çok katmanlı ağlar olarak sınıflandırılırlar. Yapay sinir ağları içerisinde tek katmanlı ileri beslemeli tasarım en basit ve en temel ağ yapısıdır. İleri beslemeli bir ağda bilgi girişten çıkışa doğru ilerler ve bu nedenle gecikmeler yoktur. Eğitim sırasında üretilen çıkış değerleri gerçek çıkış değerleri ile karşılaştırılarak bir hata sinyali üretilir ve ağ ağırlıkları bu sinyal değerine göre yeniden hesaplanarak güncellenir.(Yüksek 2007:23)



Şekil 3.8 – Çok Katmanlı ileri Beslemeli Yapay Sinir Ağı (Yüksek 2007:25)

3.4.2. Geri Beslemeli Yapay Sinir Ağları

Bu ağ yapısının ileri beslemeli ağ yapısından temel farkı hücre çıktılarının kendisinden sonra gelen katmandaki hücrelere doğrudan bir girdi olarak verilmeyip kendinden önceki katmanda veya kendi katmanında buluna başka hücrelerde girdi olarak verilebilmesidir. Bu sayede geri beslemeli yapay sinir ağları doğrusal olmayan dinamik bir yapıya kavuşmaktadır. Bu ağların tasarımlarında geri besleme özelliği kazanan ağlar farklı bağlantı şekline göre farklı davranışlar sergileyebilen geri beslemeli yapay sinir ağları elde edilebilir. İleri beslemeli yapay sinir ağlarının aksine; geri besleme özelliğinin neden olduğu bir gecikme söz konusudur (Yüksek 2007:27)



Şekil 3.9 – Geri Beslemeli Yapay Sinir Ağı (Yüksek 2007:27)

3.5. Yapay sinir ağları Öğrenme Algoritmaları

Yapay sinir ağlarının öğrenme ağırlık değerlerinin verilen girdi ve çıktı değerlerine göre istenilen sonuca ulaşılan kadar değiştirilmesi süreci olarak tanımlanabilir. Öğrenme işleminde kullanılan yöntemlerde çeşitlere ayrılmıştır. Danışmanlı, danışmansız ve takviyeli öğrenme olmak üzere yapay sinir ağlarının öğrenme algoritmaları üçe ayrılır. (Öztemel 2003:261)

3.5.1. Danışmanlı / Eğitici (Supervised) Öğrenme

Danışmanlı/eğitici öğrenme işleminde ağa eğitim için verilen girdi değerleri için gerçek çıktı değerleri de verilir. Ağa verilen örnek kümesi ağ performansı açısından çok önemlidir. Veri kümesi problemin yapısı ve özelliklerini en iyi şekilde temsil etmelidir. Bu öğrenme algoritmasında ağın ürettiği sonuç ile gerçek sonuç karşılaştırılarak hata payı hesaplanır. Hesaplanan hata değerleri kullanılarak daha önce ağın oluşturmuş olduğu ağırlık değerleri güncellenir. Yeni ağırlık değerleri ile hesaplanan çıktıların da gerçek çıktılar ile arasındaki hata payı hesaplanarak ağırlık değerleri güncellemeye devam eder. Bu işlem sonucunda eğilen ağın test aşamasında kullanılan ağırlıkları genellikle sabit kalır ve tekrar güncellenmez. (Yüksek 2007:29)

3.5.2. Danışmansız / Eğitici (unsupervised) Öğrenme

Danışmansız öğrenmede ağa öğrenme sırasında veri probleme ait veri setindeki bilgilerden sadece örnek girdiler verilmektedir ve örnek girdilere karşılık

bir çıktı değeri verilmez. Girişte verilen bilgilere göre ağ her bir örneği kendi arasında sınıflandırır ve aynı özellikte olan dokuları ayırabilecek şekilde düzenleyerek öğrenme işlemini tamamlar. Yani, hücreler arasındaki ilişki dışarıdan bir etki olmadan kendi kendine oluşur. (Yüksek 2007:30)

3.5.3. Destekleyici/Takviyeli Öğrenme

Bu öğrenme kuralı danışmanlı öğrenme kuralına yakın bir metottur. Bu öğrenme kuralında da örnek girdi değerleri için bir çıktı değeri ağa verilmez, sistemin çıktısını üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu belirten bir skor, ölçüt veya derece bildirilir. Bu bildirme göre ağ ağırlıkları güncellenerek eğitim süreci devam ettirilir. (Elmas 2003:245)

3.6. Yapay Sinir Ağlarında Öğrenme Kuralları

Yapay Sinir Ağları uygulamalarında birçok öğrenme algoritması kullanılmaktadır. Bu algoritmalar ağırlıkların güncelleştirilmesi için kullanılırlar ve çoğunluğu matematik tabanlıdır. Bunların çoğu en eski öğrenme algoritması olan Hebb öğrenme algoritmasının değişimleridir. Araştırmacıların bir kısmı öğrenme algoritmaları ile ilgili, biyolojik sinir sistemini araştırarak modellenmeye çalışmışlardır. Diğer bazı araştırmacılar ise kendi algılamalarını uyarlamaya çalışmaktadır. Bu algoritmaların birçoğu Hebb, Delta, Kohonen ve Hopfield kurallarından esinlenerek geliştirilmiştir.

3.6.1. Hebb Kuralı

Kanadalı araştırmacı Donald Hebb'in 1949 yılında biyolojik sinir sisteminden esinlenerek geliştirdiği bu algoritma ilk, en basit ve en ünlü öğrenme kuralı olarak bilinir. Basit bir mantığa dayanmaktadır. (Saraç 2004:55) Hebb Kanunu, birbiri ile bağlantılı iki hücreden biri diğerine girdi olarak bir değer aktarıyorsa ve aynı anda matematiksel olarak aynı işaretli durumda iseler, bu anda bu iki hücre arasındaki ağırlık değerlerinin artması beklenilir ve ağırlıklarının ayarlanması ile öğrenmenin oluşacağını ön görür.(Elmas 2003:247)

3.6.2. Delta Kuralı

Delta kuralı Hebb kuralının gelişmiş şeklidir. Widrow ve Hoff tarafından geliştirilmiştir. Daha çok mühendislik kökenli bir algoritmadır. Bu kuralın temel amacı üretilen çıktı ile gerçek çıktı arasındaki farkı azaltmaktır. Delta kuralı, ortalama karesel hatayı, en küçük kareler (Least-Mean-SquareRule LMS) hesaplamasını kullanılır. Hatanın azaltılması için bir katmandan bir önceki katmanlara aynı anda geri yayılır. Bu işlem son çıkış katmanından giriş katmanına kadar ağırlık hata değeri düşürülene kadar devam eder. Bu kuralın temel amacını çıkış değerleri ile gerçek çıkış değerleri arasındaki farkın en küçük olduğu değerin elde edilmesi olarak düşünebiliriz. (Saraç 2004:56)

3.6.3. Kohonen Kuralı

Kohonen tarafından biyolojik sistemlerdeki öğrenmeden esinlenerek geliştirilmiştir. Hücrelerin birbirleri ile yarışmaları ilkesine dayanır. En büyük çıktıyı üreten hücre kazanır ve kazanan hücrenin ağırlıkları güncellenir. Kazanan hücre diğer bağlantılı olduğu hücrelere göre daha kuvvetli duruma gelir. Bu hücre, bağlantılı olduğu hücreleri uyarma ve yasaklama kapasitesine sahiptir. Bu kural “kazanan tamamını alır” olarak da bilinir. Kohonen kuralı, hedef çıkışa gereksinim duymaz. Bu nedenle danışmansız bir öğrenme metodudur. (Saraç 2004:56)

3.6.4. Hopfield Kuralı

Hebb kuralından esinlenerek geliştirildiği için birbirlerine benzemektedirler. Hopfield ağırlık yapıları itibari ile tek katmanlı ve geri dönüşümlü ağlardır. Bu kuralda gerçek çıktı değerleri ile o çıktı değeri için kullanılan girdi değerlerin her ikisinin de pozitif/negatif olmasına göre öğrenme katsayısı kadar ağırlık değerlerini de artırır veya azaltır. Burada kullanılan öğrenme katsayısı değeri ağırlıkların ne kadar artırılıp azaltılacağını belirleyen değerdir. Öğrenme katsayısının değeri genellikle 0 ile 1 arasında pozitif bir değerdir ve tasarımcı bu değeri sabit olarak eğitim başlamadan belirlemektedir. (Elmas 2003:249)

4. UYGULAMA

4.1. Giriş

Bu bölümde, tez çalışmasının temel araştırma alanını oluşturan Özyüzler ve Yapay Sinir Ağları ile oluşturulmuş uygulamalar ayrıntılı bir şekilde açıklanmıştır. Ayrıca uygulamaların eğitilip test edilmesinde kullanılan veri tabanları hakkında bilgiler verilmiştir.

Çalışmanın ilk aşamasında özyüzler modeli anlatılarak sistemin çalışması ve işlem basamakları açıklanmıştır. Özyüzler yaklaşımı görüntü tabanlı bir yaklaşımdır. Yani yüz görüntüsü hakkındaki bilginin tüm yüz görüntüsü ile elde edilebileceği varsayılarak oluşturulmuştur. Bu sebeple kullanılan veri tabanındaki resimler her hangi bir ön işleme tutulmadan modelin eğitimi için kullanılmıştır.

Çalışmanın ikinci aşamasında ise Yapay Sinir ağları ile oluşturulan model ve bu modelin eğitiminde kullanılan veri tabanının hazırlanması hakkında bilgiler verilmiştir. Yüz tanıma sistemlerinin temel yöntemlerinden olan bir yüzün öznitelik değerleri ile tanınabileceği varsayımı denenmiştir. Yüz veri setindeki görüntülerin öznitelikleri kullanılarak bir Yapay Sinir Ağı eğitilmiş ve test edilmiştir.

4.2. Özyüzler (Eigenfaces) Uygulaması

Bu çalışmada 2. Bölümde anlatılan eigenfaces hesaplamalarının uygulamaları matlab programında hazırlanmış ve test edilmiştir. Test aşamasında farklı yüz veri tabanları ile testler yapılmış ve sonuçlar kaydedilmiştir.

Uygulamanın matematiksel işlemleri 2. Bölümde ayrıntılı bir şekilde açıklamıştır. Öncelikle resimler okunarak gri seviye resimlere dönüştürülmektedir. Daha sonra matris formunda olan resimler vektör olarak yeniden yapılandırılmıştır. Oluşturulan her vektör ise birer sütun halinde birleştirilerek işlemlerde kullanılacak veri seti matrisi oluşturulmuştur. Yani yeni matrisin her bir sütunu sisteme eklenmiş bir resmi ifade etmektedir.

Veri seti matrisimizi oluşturduktan sonra matrisimizin ortalaması (averajı)

hesaplanmıştır. Burada yapılan işlemde veri tabanımızdaki her bir resmin aynı piksel değerlerine denk gelen değerlerinin toplanmış ve veri tabanındaki yüz resmi sayısına bölünmüştür. Bu işleme ortalama (averaj)resmin bulunması da denilir.



Şekil 4.1– Ortalama Averaj Yüz Resmi

Ortalama yüz resmi hesaplandıktan sonra veri tabanındaki her resmin ortalama yüz görüntüsünden sapması hesaplanmıştır. Bu işlem veri seti matrisimizdeki her bir sütundan ortalama yüz resmi vektörünün çıkarılması ile elde edilmiştir. Bu işlemin amacı ortalama değeri sıfır olan bir veri kümesi elde etmektir.

Sıfır ortalamalı yeni veri setimizin kovaryans matrisi hesaplanmıştır. Bu işlem bir matrisin kendi (devriği) transpozu ile çarpılması sonucu bulunan matristir. Kovaryans matrisi simetrik bir matristir ve öz değerleri (eigenvalue) ve öz vektörleri (eigenvector) hesaplanabilir. Kovaryans matrisi hesaplanmış olan veri setimizin bu aşamada öz değer ve öz vektörleri hesaplanmıştır. Öz değer ve öz vektörler hesaplandıktan sonra öz yüzlerin hesaplanmasına geçilmiştir. Öz yüzler ortalama değerlerinin öz vektörlerin oluşturduğu matrisle çarpılarak hesaplanmıştır.



Şekil 4.2– Veri Setlerimizden Hesaplanmış Örnek Öz Yüzler.

Tanıma işlemine geçilmeden önce öz yüzler matrisi veri kümesine iz düşürülerek temel bileşenler analizi ile boyut azaltma işlemi gerçekleştirilmiştir.

Tanıma işlemi için ilk olarak test resmi ile ortalama resim arasındaki fark bulunmuştur ve bu fark her öz vektör değeri ile çarpılmıştır. Hangi yüz sınıfının test resmi için en uygun tanımlama olduğunu bulunmuştur. Bu işlem öklid uzaklığının minimize edilmesi ile gerçekleştirilmiştir. Öklid uzaklığının minimum olduğu değere ait yüz resmi tanıma sonucu olarak bulunmuştur.

4.2.1. Kullanılan Veri Tabanı

AT&T Veri tabanı, (eski adıyla 'ORL Yüzleri Veri tabanı'), Nisan 1992 ile Nisan 1994 tarihleri arasında laboratuvarında alınan yüz imgeleri dizisi içermektedir. Veri tabanı ile işbirliği içinde yürütülen bir yüz tanıma projesi kapsamında kullanılan Konuşma, Vizyon ve Robotik Grubu arasında Cambridge Üniversitesi Mühendislik Bölümü tarafından oluşturulmuştur.

40 ayrı kişinin her biri farklı on görüntüsü vardır. Bazı imgelerde, ışıklar, yüz ifadeleri (açık / kapalı gözler, gülümseyen / gülmeyen) ve yüz ayrıntıları (gözlük / gözlük yok) değişen görüntüler farklı zamanlarda çekilmiştir. Tüm görüntüler karanlık, homojen bir zemin üzerine çekilmiştir. Her görüntünün boyutu, piksel başına 256 gri seviyeyle 92x112 pikseldir. (AT & T Laboratories Cambridge 2017)




Şekil 4.3– AT&T Veri Tabanından Bir Görüntü

4.2.2 . Özyüzler Uygulama Sonuçları


Uygulamada 40 kişinin toplam 400 adet yüz görüntüsü kullanılmıştır. 400 görüntünün 320 tanesi eğitim seti için, 80 tanesi ise test seti için ayrılmıştır. Test seti ideal haliyle kullanıldıktan ve sonuçlar elde edildikten sonra test setindeki resimlerin belirli bölgeleri değiştirilerek test işlemi tekrarlanmıştır. Değiştirilen bölgeler sırayla göz, burun ve ağı-çene bölgeleridir. Ayrıca test verileri üzerinde belirli bir gürültü oluşturularak da test yapılmıştır. Tüm işlemlerin sonuçları kayıt edilmiştir.

Tablo 4.1 – Test Sonucu Doğru Bulunan Örneklerden Bir Kısmı


	Test Resmi	Sonuç Resmi
İdeal Görüntü		
		
Göz Bölgesi Kapalı Görüntü		
Ağız – Çene Bölgesi Kapalı Görüntü		
Burun Bölgesi Kapalı Görüntü		

Gürültü Oluşturulmuş Görüntü		
------------------------------	---	---

Tablo 4.2 – Test İşlemi Sonucu Yanlış Bulunan Örneklerin Bir Kısım


	Test Resmi	Sonuç Resmi
İdeal Görüntü		
		
		

Göz Bölgesi Kapalı Görüntü		
Ağız – Çene Bölgesi Kapalı Görüntü		
Burun Bölgesi Kapalı Görüntü		
Gürültü Oluşturulmuş Görüntü		



Şekil 4.4 - İdeal Görüntü Test Grafiği


Sonuçlar incelendiğinde ideal şartlarda ön profilden alınan görüntülerin tanınmasında özyüzlerin tanıma performansının %96,25 gibi çok üst düzeyde olduğu görülmüştür.




Şekil 4.5 - Göz Bölgesi Kapalı Görüntü Test Grafiği

Ancak yüz görüntülerinin belirli bölgelerinde yapılan değişikliklerde tanıma

performansı oldukça düşmektedir. Özellikle göz ve ağız-çene bölgelerini değiştirilmiş görüntülerde sırayla elde edilen %13,75 ve %7,5'lık tanıma başarısı oldukça düşük çıkmıştır.




Şekil 4.6 - Ağız Ve Çene Bölgesi Kapalı Görüntü Test Grafiği



Şekil 4.7 - Burun Bölgesi Kapalı Görüntü Test Grafiği

Burun bölgesinin tanıma performansı ise diğer bölgelerin tanıma oranları

dikkate alındığında nispeten % 31,25 gibi bir oranla biraz yüksek çıkmaktadır.



Şekil 4.8 – Gürültülü Eklenmiş Görüntü Test Grafiği

Yine test aşamasında kabul edilebilir bir gürültü oluşumunda tanıma performansının çok etkilenmediği görülmüştür.

Tablo 4.3 – Özyüzler Performans Değerleri

	Test Verisi Sayısı	Doğru Sayısı	Hata Sayısı	Başarı Yüzdesi
İdeal Görüntü	80	77	3	96,25
Göz Kısmı Kapılı Görüntü	80	11	69	13,75
Ağız-Çene Kapalı Görüntü	80	6	74	7,5
Burun kapalı görüntü	80	25	55	31,25
Gürültü Oluşturulmuş görüntü	80	75	5	93,75

4.3. Yapay Sinir Ağları Uygulaması


Uygulamamızda yüz tanıma işleminin gerçekleşmesi için yapay sinir ağı oluşturulmuş ve en doğru sonucu elde etmek için testler yapılmıştır. Bu aşamada veri setlerindeki yüz resimleri özyüzler yaklaşımında olduğu gibi tüm yüz görüntüleri kullanılarak eğitmeye çalışılması durumunda çok fazla giriş katmanı oluşmuş ve istenilen sağlıklı sonuçlar elde edilemediği görülmüştür.

Yapay sinir ağları eğitimi için yüz resimlerinin belirli özellik noktalarından; göz, burun, ağız, çene vb. değerler çıkarılarak yüz geometrisi bilgilerinden sonuçlar üretilmiştir.

Kullanılan veri tabanı içerisinde bulunan veri setimizde yüz resimlerinin 22 ayrı bilgi noktası bulunmaktadır. Bu noktaların koordinat bilgileri arasında uzaklıkları ve açıları hesaplanarak yüz resmini ifadede yeterli bir veri seti oluşturulmuştur.

4.3.1. Kullanılan Veri Tabanı

AR Yüz Veri tabanı ayrıntılı test ve model oluşturma işlemini etkinleştirmek için, her yüzdeki 22 yüz özelliği ile manüel olarak etiketlenmiştir. Seçilen 22 puan tüm görüntülerde tutarlıdır. Simgesel plan aşağıda gösterilmiştir. (AR-Face 2017)



Şekil 4.9 – Ar Yüz Veri Tabanı Yüz Öz Nitelik Noktaları

İşaretleme şeması şöyledir:

0 = sağ göz bebeği	7 = sol göz kaşının dış ucu
1 = sol göz bebeği	8 = sağ şakak
2 = sağ ağız köşesi	9 = sağ gözün dış köşesi
3 = sol ağız köşesi	10 = sağ gözün iç köşesi
4 = sağ göz kaşının dış ucu	11 = sol gözün iç köşesi
5 = sağ göz kaşının iç ucu	12 = sol gözün dış köşesi
6 = sol göz kaşının iç ucu	13 = sol şakak

14 = burun ucu	18 = alt dudağın dış kenarındaki merkez
15 = sağ burun deliği	nokta
16 = sol burun deliği	19 = çene ucu
17 = üst dudağın dış kenarındaki merkez	20 = Sağ yüz kenarı
nokta	21 = Sol Yüz Kenarı

Veri setinde bulunan her yüz resmi için 22 koordinat belirtilmiştir. Bu koordinatlar kullanılarak yüz tanıma için gerekli öz nitelikler belirlenmiştir. Öz niteliklerin belirlenmesinde çene, ağız, burun ve sol-sağ göz açı değerleri derece cinsinden hesaplanmıştır.

Bu işlem için ilk olarak koordinat değerlerinden noktalar arası mesafelerin uzunlukları formül kullanılarak hesaplanmıştır.

$$|AB| = \sqrt{(X_1 - X_2)^2 + (Y_1 - Y_2)^2}$$

Tablo4.4 – Veri Seti Koordinat Değerlerinden Bir Kısım

Kişi Id	0-sağ göz bebeği		1-sol göz bebeği		2-sağ ağız köşesi		3-sol ağız köşesi	
	X	Y	X	Y	X	Y	X	Y
0	328,444	275,496	434,921	275,029	331,713	401,121	427,449	400,187
1	327,193	263,025	437,671	258,127	342,887	379,987	432,444	376,537
2	324,151	259,223	435,740	256,488	330,168	381,751	435,193	383,392
3	318,380	277,063	450,532	268,861	333,873	418,329	443,241	414,684
4	331,267	279,792	456,388	284,604	325,920	412,399	434,999	419,350
5	338,274	255,705	447,832	255,041	343,769	373,008	445,902	374,791
6	325,671	261,570	441,418	254,278	351,190	384,608	443,241	377,316
7	325,969	255,594	440,992	265,086	327,887	384,105	432,362	386,517
8	315,646	266,127	430,481	268,861	331,139	397,367	418,633	396,456
9	358,206	254,370	475,129	249,109	368,814	395,177	473,848	389,111
10	335,696	253,367	456,911	257,924	340,578	386,567	442,802	392,835

Noktalar arasındaki uzaklıklar hesaplandıktan sonra aşağıda verilen Kosinüs teoremi formülü ile noktalar arasında oluşan açılar hesaplanmıştır.

$$\cos A = \frac{B^2 + C^2 - A^2}{2BC}$$

Tablo4.5 – Hesaplanmış Ağız Bölgesi İçin Örnek Açı Değerleri

1	2	3	4	5	6
27,87189	82,5086	69,61951	84,99364	72,53394	22,47243
28,33897	99,85005	51,81098	87,27864	62,21579	30,50557
30,48662	89,08031	60,43307	81,99727	72,16591	25,83682
34,01369	67,62074	78,36557	66,61506	82,30329	31,08165
34,9582	73,61885	71,42295	78,67674	68,75947	32,56379
31,38695	87,5639	61,04915	84,97598	62,18985	32,83417
32,95861	76,82639	70,21499	78,63825	74,34027	27,02148
33,61439	72,64672	73,73889	67,28573	75,65115	37,06312
33,0646	79,3743	67,5611	76,26161	73,20434	30,53405
25,56896	89,51779	64,91326	89,40083	65,41442	25,18475


Bu yöntemle tüm veri setinde bulunan koordinat noktalarından çene bölgesi için 19-20-21 noktalarının koordinatları kullanılmış ve 3 açı adet açı değeri üretilmiştir. Ağız bölgesi için 2-3-17-18 noktalarının koordinatları kullanılmış ve 6 adet açı değeri üretilmiştir. Burun bölgesi için 14-15-16 noktalarının koordinatları kullanılmış ve 3 adet açı değeri üretilmiştir. Sol göz bölgesi için 0-9-10 noktalarının koordinatları kullanılmış ve 3 adet açı değeri üretilmiştir. Sağ göz bölgesi için 1-11-12 noktalarının koordinatları kullanılmış ve 3 adet açı değeri üretilmiştir. Toplamda bir yüzü ifade etmek için yüzün temel kısımlarından elde edilen 18 farklı açı değeri ile veri setimiz oluşturulmuş ve Yapay Sinir Ağımız eğitilmiştir.

4.3.2. Yapay Sinir Ağları Uygulama Sonuçları

Yapay sinir ağlarının eğitiminde 134 kişiye ait 511 adet yüz görüntüsünün

22 noktasından alınan koordinat bilgilerinin bulunduğu veri tabanı kullanılmıştır. Bunun için ilk olarak koordinat noktaları kullanılarak yüzün öznitelikleri çıkartılmıştır. Bu amaç veri seti hazırlanırken göz için 6 (sağ ve sol olmak üzere iki ayrı bölge), burun için 3, ağız için 6 ve çene için ise 3 olmak üzere bu bölgelerine ait toplam 18 adet açı değeri üretilmiştir. Üretilen bu 18 açı değeri ile sistem test edilmiştir. Veri setinin bilgilerinin 410 tanesi eğitim için 101 adedi ise test amaçlı kullanılmak üzere ayrılmıştır.


Modelimiz test edilirken öncelikle sistemin testinde tüm açı değerleri kullanılarak sonuçlar karşılaştırılmıştır. Daha sonra özyüzler uygulamasında olduğu gibi belirli bölgelerin açı değerleri test setinden silinerek testler tekrarlanmış ve sistemin eksik değerlerle olan genelleme yeteneği ile sonuçlar üretilmiştir. Eksik verilerin testinde öncelikle göz bölgesinin 6 açısı silinmiş ve sisteme yüz görüntüsüne ait 12 açı değeri verilmiştir. Sonra burun bölgesinin 3 açısı silinerek sistem 15 açı değeri ile test edildikten sonra sistem ağız ve çene bölgelerinin 9 açısı silinerek 9 açı değeri ile test edilmiş ve tüm sonuçlar kaydedilmiştir.



Şekil 4.10 – Tüm Açı Değerleri Kullanılan Test Grafiği


Uygulama sonuçları incelendiğinde yapay sinir ağların yüz tanıma uygulamalarında öz nitelik değerleri kullanılarak %98,7 gibi bir yüksek başarıya

sahip olduđu gör÷lmektedir.




Şekil 4.11.- Burun Bölgesi Açı Değerleri Eksik Test Grafiđi

Yapay sinir ađlarının genel özelliklerinden biri olan eksik verilerle genelleme yapabilme yeteneđi sayesinde özellikle burun ve ađız – çene bölgesi verileri eksik iken de %82,4 - %98,2’lık başarı oranlarının çok başarılı olduđu gör÷lmektedir.



Şekil 4.12 – Ađız Ve Çene Bölgesi Açı Değerleri Eksik Test Grafiđi



Şekil 4.13 – Göz Bölgesi Açık Değerleri Eksik Test Grafiği

Ancak göz bölgesine ait değerler veri setimizden çıkartılarak yapılan testlerde çok düşük bir tanıma yüzdesi olduğu görülmektedir.

Tablo 4.6 – Yapay Sinir Ağları Performans Değerleri

	Test Verisi Sayısı	Kullanılan Açık Sayısı	Başarı Yüzdesi
Tüm Yüz Açıkları Kullanılan Test	101	18	98,7
Burun Bölgesi Açık Değerleri Eksik Test	101	15	82,4
Ağız-Çene Bölgesi Açık Değerleri Eksik Test	101	9	98,2
Göz Bölgesi Açık Değerleri Eksik Test	101	12	0,6

4.4. Sonuç

Her iki modelin uygulama sonuçları incelendiğinde ideal şartlarda elde edilmiş tüm yüz bilgisi ile tanıma yapan özyüzler ve tüm özniteliklerin kullanıldığı yapay sinir ağlarının yakın bir performans gösterdiği görülmektedir. Ancak modellerin testinde eksik verilerin kullanıldığı senaryolar test edildiğinde yapay sinir

ağlarının tanıma performansının özyüzlere oranla oldukça yüksek olduğu görülmektedir.

Tablo 4.7 – Modellerin Performanslarının Karşılaştırılması

	Öz yüzler	Yapay Sinir Ağları
Tüm Yüz – Tüm Veri	96,25	98,7
Göz Verisi Eksik	13,75	0,6
Ağız – Çene Verisi Eksik	7,5	98,2
Burun Verisi Eksik	31,25	82,4

5. SONUÇ VE DEĞERLENDİRME

Yapılan tez çalışması ile ilk olarak yüz tanıma sistemleri için önemli görünüm (tüm yüz verisinin kullanıldığı) ve öz nitelik tabanlı yaklaşımların literatür çalışmaları ele alınmıştır. Yapılan değerlendirmeler mevcut çalışmalarda belirli bir yöntemin yüz tanıma için tek başına ideal koşullar dışında yeterli sonuçlar üretmediği ve eş zamanlı çalışan gerçek uygulamalarda yeterli başarımlar sağlanamadığı belirtilmektedir.

Literatürde sıklıkla kullanılan insan yüzü tanıma yöntemlerinin genellikle görünüm tabanlı (appearance-based) yöntemler olduğu belirtilmektedir. Bu yöntemler her insan için, farklı çevre koşullarını içerecek şekilde eğitim verisine ihtiyaç duymaktadır. Fakat gerçek uygulamalarda sınırlı sayıda eğitim verisine sahip olduğu için insan yüzüne ait tüm değişimleri bu sistemler yakalayamamaktadır.

Belirtilen yöntemlerden Temel Bileşen Analizi temelli “Özyüzler” yöntemi en yaygın görünüm tabanlı yöntem olup, özyüzlere dayalı yöntemler hala kullanılmakta ve başarılı sonuçlar elde edilmektedir. Bu yaklaşımın önemli sorunları arasında aydınlanma ve poz değişimlerine duyarlı olması yer almaktadır. Ayrıca, bu algoritmalarda tanıma başarısının yüksek çıkması için, algoritmaya giriş olarak sunulan insan yüzlerinin önden çekilmiş (frontal) ve iyi aydınlatılmış olmasına ihtiyaç duyulmaktadır.

Özyüzler modeli hazırlanırken model iyi eğitilmiş olmalıdır. İdeal şartlarda alınan görüntüler üzerinden tanıma değerleri %96,25 gibi oldukça yüksek bir değerdir. Ancak yüz tanıma probleminin zorlukları olan pozdaki değişimler, ışık kaynağının yeri ve şiddetindeki değişimler, yüz ifadesindeki değişimler, ölçek sorunu, zamanla veya yaşlanmayla oluşan değişimler vb. gibi durumlarda tanıma performansı %31,25, %13,5 ve %7,5 gibi oldukça düşük değerlere sahiptir.

Özniteliklerin kullanıldığı modellerin görünüm tabanlı modellere göre en büyük dezavantajının bu nitelikleri elde etmekten kaynaklandığı söylenebilir. Çünkü birçok alanda görüntü alan basit bir kamere ile yüz görüntüsü elde edilebilirken öz niteliklerin elde edilmesi için görüntü üzerinde birçok işleme ihtiyaç vardır.

Ancak görüntülerden öznitelikler gerekli hassasiyetle elde edilebilirse yapay sinir ağlarının yüz tanıma performansının %98,7 gibi oldukça yüksek olduğu görülmektedir. Ayrıca yüz görüntüsün belli bölgeleri eksik ise yapay sinir ağlarıyla yapılan öznitelik tabanlı modelin başarısının özyüzlere göre oldukça yüksek olduğu da anlaşılmaktadır.

Eksik verilerle çok yüksek tanıma performansı gösteren yapay sinir ağlarının başarısı yapılan tüm testler için geçerli olmamıştır. Yapay sinir ağlarıyla yapılan testlerde göz bölgesi eksik verilerin testinin %0,6 gibi oldukça düşük bir değer olduğu görülmektedir. Ayrıca burun bölgesi eksik verinin ağız – çene bölgesi eksik olan verimizden tanıma performansının yaklaşık %13 düşük olması bize öznitelik tabanlı uygulamalarda yüzün üst bölgesinin tanıma performansına alt bölgesinden daha fazla etki ettiğini göstermektedir.

5.1. Tartışma Ve Öneriler

Çalışma sonucunda ortaya çıkan yüz tanıma probleminin zorlukları yanında gözlük, şapka ve yüzü örten diğer unsurların bulunduğu durumlarda, yüzün belirli bölgesinin incelenmesi sonuçlar açısından önemlidir. Bu gibi zor şartlar altında elde edilmiş görüntülerde ve eksik verilerin fazla olduğu durumlarda görünüm tabanlı yöntemler yerine yapay sinir ağları ile oluşturulan modeller kullanılabilir. Yapay sinir ağlarının genelleme ve eksik veriler ile tahmin edebilme özellikleri kullanılarak bu iki model farklı durumlar için birbirinin alternatifi olarak kullanılabilirler.

Ayrıca görünüm tabanlı eş zamanlı çalışan modellerin geliştirilmesinde özyüzler yaklaşımı kullanılmak istenirse elde edilen test resimleri üzerinde görüntü işleme yöntemleri ile iyileştirmelerin yapılması tahmin performansını artırabilir. Bu yönde yapılacak çalışmalarda elde edilecek başarılar önemli bir yenilik olacaktır.

Özniteliklerin çıkartılmasında kullanılan tekniklerde meydana gelecek olan yenilikler, bu modellerin kullanılmasını artırıcı bir etki yapacaktır. Özellikle günümüzde görüntüleme cihazlarının yazılım ve teknolojilerindeki gelişmeler sayesinde gerçek zamanlı görüntülerden yeterli özniteliklerin kolayca elde edilebilmesi sağlınırsa bu modelin kullanılmasına büyük kolaylıklar sağlayacaktır.

Görüntüleme cihazlarındaki gelişmeler ve görüntü işleme alanında yapılan

alışmaların etkisi ile hem yüzün görüntüsü hem de öz nitelikleri aynı anda elde edilebilmesi kolaylaşmaktadır. Bu yüzden yüz tanıma sistemlerinde, tüm yüz görüntüsünü kullanan görünüm tabanlı model ve öznitelik tabanlı sistemlerinin birlikte çalışmasıyla oluşturulacak bir hibrit modelin gerçek zamanlı ve ideal olmayan koşullarda üreteceğı çözümler daha başarılı sistemler olabilirler.



KAYNAKÇA

“Biometrics” erişim tarihi: 20 Aralık 2011 <http://www.globalsecurity.org/security/systems/biometrics.htm>.

“Global Facial Recognition Market to Witness Double Digit Growth” erişim tarihi:20 Aralık 2011 http://www.rncos.com/Press_Releases/Global-Facial-Recognition-Market-to-Witness-Double-Digit-Growth.htm.

“New report predicts Global Biometrics Market to reach US\$16.47 Billion” erişim tarihi:20 Aralık 2011 <http://www.planetbiometrics.com/article-details/i/917/>.

AR Face Yüz Veri Tabanı, erişim tarihi: 21 Haziran 2017 http://www.prima.inrialpes.fr/FGnet/data/05-ARFace/tarfd_markup.html.

AT & T Laboratories Cambridge'e Yüz Veri Tabanı, erişim tarihi: 21 Haziran 2017 <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>

Belhumeur P.N., Hespanha, J.P., Kriegman, D.J. (1997). “Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection”. IEEE Trans.19:711-720.

Colombo C., Bimbo Del A., ve Magistris De S.. (1995) “Human-computer interaction based on eye movement tracking”. Computer Architectures for Machine Perception. 258-263, 1995.

Cootes T., Edwards G., ve Taylor C. (2001). “Active appearance models”. IEEE Transactions on Pattern Analysis and Machine Intelligence. 23(6):681–685.

D. Reisfeld (1994). “Generalized symmetry transforms: attentional mechanisms and face recognition”. phd. thesis. Technical report. Tel-Aviv University.

Edwards G. J., Taylor C. J., ve Cootes T. (1997). “Learning to Identify and Track Faces in Image Sequences”. British Machine Vision Conference.

Elmas Çetin (2003). Yapay Sinir Ağları. İstanbul:Seçkin Yayınevi

Goldstein A.J., Harmon, L.D., ve Lesk, A. B. (1971). “Identification of human

faces". Proc. IEEE 59: 748-760.

Gökmen Muhittin, Kurt Binnur, Kahraman Fatih ve Çapar Abdülkerim (2007). Çok Amaçlı Gürbüz Yüz Tanıma; Proje No: 104E121.

GrafH.P., Chen T., Petajan E., ve Cosatto E. (1995). "Locating faces and facial parts". International Workshop on Automatic Face- and Gesture – Recognition. 41-46.

Haig N. K. (1985). "How faces differ - a new comparative technique". Perception 14:601-615.

Jain A. K., Kumar A. (2010). "Biometrics of Next Generation: An Overview, Second Generation Biometrics". Springer.

Kanade T. (1973). "Picture Processing System by Computer Complex and Recognition of Human Faces". PhD. Thesis. Kyoto University, Japan.

Karaboyacı, C. (2009), "Geometrik Özellik Temelli Yüz İfadesi Analizi", Yüksek Lisans Tezi.

Kirby M., Sirovich, L. (1990). "Application of Karhunen – Loeve procedure for characterization of human faces", IEEE. 12:1.

Konak E. S. (2006). "Bilgisayar Destekli Yüz Tanıma Sistemi Tasarımı", Yüksek Lisans Tezi.

Lanitis A., Taylor C., ve Cootes T. (1997). "Automatic Interpretation and Coding of Face Images Using Flexible Models". IEEE Transactions on Pattern Analysis and Machine Intelligence. 19(7):743–756.

Lee, K.C., Ho, J., Kriegman, D.J. (2001) "Nine points of light: acquiring subspaces for face recognition under variable lighting". CVPR. 519-526.

Liand S.Z., Jain A.K. (2011). "Handbook of Face Recognition, Springer Verlag". 1.

Manjunath B.S., Chellappa R., ve Malsburg C.V.D.. (1992). "A feature based approach to face recognition". IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 373-378.

Mehra Pankaj Wah W Benjamin (1992). "Artificial Neural Networks

Conceptsand Theory”. IEEE Computer Society Press:45.

Moghaddam B., Pentland, A. (1997). “Probabilistic visial learning for object representation”. IEEE. 19:696-710.

Nastar C., Moghaddam B., ve Pentland A. (1996). “Generalized Image Matching: Statistical Learning of Physically – Based Deformations”. European Conference on Computer Vision,1:589–598.

O’Toole A. J., Deffenbacher K., A., Barlett J. (1991). “Classifying faces byrace and sexusing an auto associative memory trained for recognition”. Annual Conf Cognition Science Society.13.

O’Toole A., J., Deffenbacher K., A., Valentin D. (1993). “A low dimensional representation of faces in the higher dimensions of space”, J OptSoc Amer A 10:405-411.

Öztemel E. (2003). Yapay Sinir Ağları. İstanbul: Papatya Yayıncılık.

Pentland A., Moghaddam B., ve Starner T. (1994). “View-based and modular eigen spaces for face recognition”. IEEE Computer Society Conference on Computer Visionand Pattern Recognition. 84-91.

RhodesG.(1988). “Looking at faces: First-order and second order features as determinants of facialappearance” Perception17:43-63.

Roederand N. Li X. (1995). “Experiments in analyzing the accuracy of facial feature detection”. Vision Interface.95:8-16.

Saraç Tuğba (2004). Yapay Sinir Ağları. Seminer Projesi. Gazi Üniversitesi.

SirovichL.,Kirby M. (1987). “Low Dimensional Procedure for Characterization of Human Faces”, J. Opt. Cos. Amer.l4:519-524.

Taşova Ozan (2011). “Yapay Sinir Ağları İle Yüz Tanıma”. Yüksek Lisans Tezi.

Turk M.,Pentland A. (1991). “Eigenfaces for Recognition”, J. Cognitive Neuroscience,3:71-86.

Turk and M.A. Pentland A.P. (1991). “Face recognition using eigenfaces”. IEEE Computer Society Conference Computer Visionand Pattern Recognition. 586-

591.

Xiaoguang L., Hsu R., Jain A.K. (2004). “Face Recognition with 3D Model – Based Synthesis”. International Conference on Bioinformatics and its Applications.

Yaman, Bahattin Özyüz (2006). “Kullanılarak Yüz Tanıma”. Yüksek Lisans Tezi.

Yaycılı A. Ö. (2006). “Temel Bileşenler Analizi İçin Robust Algoritmalar”, Yüksek Lisans Tezi.

Yuille A., Cohen D., ve Hallinan P. (1989). “Feature extraction from faces using deformable templates”. IEEE Computer Society Conference on Computer Vision and Templates. 104-109.

Yüksek Ahmet Gürkan (2007). “Hava Kirliliği Tahmininde Çoklu Regresyon Analizi ve Yapay Sinir Ağlarının Karşılaştırılması”. Doktora Tezi.

Zhang J., Yan Y., Lades M. (1997). “Face Recognition: Eigenface, Elastic Graph Matching and Neural Nets”, IEEE. 85:1423-1435.

EKLER

Ek:1. Özyüzler Metodunun Matlab Uygulaması

% 2 Boyutlu Matrisleri 1 Boyutlu Vektöre Çevirme

T = [];

for i = 1 : EgitimNo

str = int2str(i);

str = strcat('\',str,'.jpg');

str = strcat(EgitimSeti,str);

img = imread(str);

img = rgb2gray(img);

[irowicol] = size(img);

temp = reshape(img',irow*icol,1);

T = [T temp];

End

% Ortalam Hesaplama

m = mean(T,2); % Averaj Yüz Resmini Hesaplama

EgitimNo = size(T,2);

% Her Görüntünün Ortalama Görüntüden Sapmasını Hesaplama

A = [];

for i = 1 : EgitimNo

temp = double(T(:,i)) - m; %Ai = Ti - m

A = [A temp];

end

```

L = A'*A;

[V D] = eig(L);

L_oz_yuz = [];

for i = 1 : size(V,2)
    if( D(i,i)>1 )
        L_oz_yuz = [L_oz_yuz V(:,i)];
    end
end

%EigenvectorlerininCovariance Matrisi C Hesaplama
Ozyuz = A * L_oz_yuz;

HedeflenenResimler = [];

EgitimNo = size(Eigenfaces,2);

for i = 1 : EgitimNo
    temp = Eigenfaces'*A(:,i);
    HedeflenenResimler = [HedeflenenResimlertemp];
end

% Test Resmi Üzerinden Tanıma

GirisResmi = imread(TestResmi);

temp = GirisResmi(:, :, 1);

[irowicol] = size(temp);

Resim = reshape(temp',irow*icol,1);

```

```

Fark = double(Resim)-m; % Ortalanmış Test Resmi
HedeflenenTestResmi = Eigenfaces'*Fark; % Test Resmi Özellik Vektörü

%Öklid mesafesini Hesaplama
OklMesafe = [];
for i = 1 : EgitimNo
    q = HedeflenenResimler(:,i);
    temp = ( norm( HedeflenenTestResmi - q ) )^2;
    OklMesafe = [OklMesafetemp];
end
[OklMesafe_min ,Taninan_index] = min(OklMesafe);
CikisIsmi = strcat(int2str(Taninan_index),'.jpg');

```

Ek:2. Yapay Sinir Ağları Matlab Kodu

```
%Ağ oluşturuluyor

%newff(girdi,çıktı,hiddeden   layer   nöron   sayısı,transfer   fonk,eğitim
algoritması)

net = newff(NorEgitimGirdisi,NorEgitimCiktisi,[15 15],{ },'trainlm');

net.trainParam.lr=0.05;

net.trainParam.epochs=10000;

net.trainParam.goal=1e-10000000000;

net.trainParam.show=NaN;

net.trainParam.max_fail=20;

net.trainParam.min_grad=1e-10

net.trainParam.show =10;

net.trainParam.time=inf ;

%Ağı Eğitme

net = train(net,NorEgitimGirdisi,NorEgitimCiktisi);
```

ÖZ GEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Hakan KEKÜL
Uyruğu : T.C.
Doğum Tarihi ve Yeri : 28.09.1983 / Sivas
e-posta : hakankekul@gmail.com

EĞİTİM

Derece	Kurum	Mezuniyet Yılı
Lisans	Sakarya Üniversitesi, Teknik Eğitim Fakültesi, Bilgisayar Sistemleri Öğretmenliği	2006
Yüksek Lisans	Sivas Cumhuriyet Üniversitesi İşletme Bölümü	Devam Ediyor