

Makalenin Geliş Tarihi : 04.12.2008
Makalenin Kabul Tarihi : 22.01.2009

TEMEL BİLEŞEN ANALİZİ YÖNTEMİNİN VE BAZI KLASİK VE ROBUST UYARLAMALARININ YÜZ TANIMA UYGULAMALARI

Işıl YAZAR¹, Hasan Serhan YAVUZ², Mehmet Atif ÇAY³

ÖZET: Bu çalışmada, temel bileşen analizi yöntemindeki klasik ortalama merkezileştirme yerine çeşitli klasik ve robust tahmin ediciler kullanılarak Yale, ORL ve AR yüz veritabanları üzerinde yüz tanıma uygulamaları yapılmıştır. Normal dağılım varsayımının sağlanmadığı durumlarda veya veri kümesinde aykırı değer bulunması durumunda klasik yöntemlerden daha iyi sonuçlar verdiği bilinen bazı robust yöntemler, bu üç veritabanı üzerinde yapılan yüz tanıma deneylerinde klasik yöntemlerle karşılaştırılmıştır. Yüz tanıma uygulamalarında görüntü örneği boyutları örnek sayısına göre çok büyüktür. Bu yüzden, veri kümesinin normal dağılım koşulunu sağlayıp sağlamadığı bilinmemektedir. Deneysel sonuçlar, temel bileşen analizi yöntemi tabanlı yüz tanıma uygulamalarında robust yöntemlerin klasik yöntemlerden genellikle daha başarılı doğru tanıma oranları verdiğini göstermiştir.

Anahtar kelimeler: Yüz tanıma, temel bileşen analizi, robust tahmin ediciler

FACE RECOGNITION APPLICATIONS OF PRINCIPLE COMPONENT ANALYSIS METHOD AND SOME OF ITS CLASSICAL AND ROBUST VARIANTS

ABSTRACT: In this study, face recognition applications on the YALE, ORL and AR face databases have been performed by using some classical and robust estimators instead of classical mean subtraction in the principal component analysis method. In the cases where the Normal distribution assumption is not valid or the data set includes outliers, some robust estimators which are known to have better results were compared with the classical estimators by making face recognition experiments using these three databases. In face recognition applications, the dimension of the image samples is very high as against the number of the samples. That's why it's not known whether the data set satisfies the Normal distribution condition. Experimental results demonstrated that robust methods usually gave better correct recognition rates than the classical methods in principal component analysis method based face recognition applications.

Keywords: Face recognition, principle component analysis, robust estimators

^{1,2,3} Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi,
Elektrik-Elektronik Mühendisliği Bölümü, Batı Meşelik Kampüsü, ESKİŞEHİR

I. GİRİŞ

Yüz tanıma yöntemleri son yıllarda hızla artan bir uygulama haline gelmiştir. Bu konu son zamanlarda güvenlik sistemleri, kredi kartı onaylama, suçlu teşhis etme gibi geniş kullanım alanıyla oldukça dikkat çekmektedir [1-3]. Başarılı bir yüz tanıma sistemi yaratılmasının önemi bu noktada ortaya çıkmaktadır. Yüz tanıma sistemleri öğrenen sistemlerdir. Burada öğrenen sistemden kastedilen sistemin eğitilmesi sonucunda sistemin belli girdiler için belli çıktılar sağlamasıdır. Sistemin başarısı sistemin girdiye uyguladığı dönüşümlere ve girdinin özelliklerini öğrenebilme başarısına bağlıdır [4].

Yüz tanıma işlemi, tanınmak istenen yüzün sistemdeki hangi yüzle daha çok eşleştiğine dayanarak yapılmaktadır. Tanınması istenen yüz bilgisi normalize edilir ve sistemde bulunan diğer yüzlerle karşılaştırılarak sınıflandırılır [5].

Asal bileşen analizi veya Karhunen-Loeve dönüşümü olarak da adlandırılan Temel Bileşen Analizi (TBA), örüntü tanıma çalışmalarında geniş kullanım alanı bulunan bir altuzay izdüşüm yöntemidir. Görünüşe dayalı yüz tanıma uygulamalarının büyük bir çoğunluğu bu boyut indirgeme yöntemine dayanmaktadır. Bunun nedeni olarak karmaşık hesaplama algoritmaları gerektiren yeni tekniklere temel çözüm modeli oluşturması ve ayrıca vektör, matris, özdeğer, özvektör gibi matematik elemanlarının anlaşılmasındaki kolaylık gösterilebilir [6]. Temel bileşen analizi; değişkenlerden oluşan bir veri kümesinin varyans-kovaryans yapısını, bu değişkenlerin doğrusal birleşimleri yardımıyla açıklayarak, boyut indirgemesi ve yorumlanmasını sağlayan bir çok değişkenli istatistiksel yöntemdir [7]. Yüz tanıma uygulamalarında TBA, yüz görüntülerinin temel bileşenlerinin elde edilip, özyüz adı verilen bu temel bileşenlerin doğrusal bileşimi ile yaklaşık olarak yüz görüntülerini modellemeyi amaçlar [8]. TBA vektör tabanlı bir yaklaşımdır. Bu yöntemde amaç, büyük boyutlu ve birbiriyle ilişkili vektörleri, küçük boyutlu birbiriyle ilişkisiz vektörler biçimine dönüştürmektir. TBA'nın sayısal görüntü verilerinde kullanımı, sayısal görüntü verisinin vektör biçiminde temsil edilmesiyle gerçekleşir.

TBA, veri kümesinin Normal dağılım modeline uyduğu varsayımına dayanmaktadır. Ancak çoğunlukla eldeki veri seti, normal dağılıma sahip değildir. Bir veri kümesindeki gözlemlerin uygun olduğu dağılıma uymayan gözlemler aykırı değer olarak adlandırılmaktadır [7]. Aykırı değerlerin varlığı, TBA yönteminin verimliliğini olumsuz yönde etkiler [9]. Normal dağılım

modeli sağlanmadığında veya veri kümesinin aykırı değerler içermesi durumunda robust yöntem olarak adlandırılan istatistiksel yöntemler daha iyi sonuçlar verebilmektedir. Birçok istatistiksel yöntemde olduğu gibi, TBA yönteminin de klasik veya robust olarak ayrılan uyarlamaları mevcuttur [10]. Klasik olan yöntemler arasında standartlaştırma ve normalleştirme; robust olan yöntemler arasında medyan merkezileştirme, *SN*-standartlaştırma, Medyan Normalleştirme, *SN*-Normalleştirme yöntemleri TBA ile birlikte kullanılmak üzere uyarlanabilir [11].

Bu çalışmada, temel bileşen analizi yöntemindeki klasik ortalama merkezileştirme yerine çeşitli klasik ve robust tahmin ediciler kullanılarak Yale, ORL ve AR yüz veritabanları üzerinde yüz tanıma uygulamaları yapılmıştır. Çalışma dört bölümden oluşmaktadır. Çalışmanın ikinci bölümünde temel bileşen analizi yönteminin metodolojisi ve TBA metodolojisiyle birlikte kullanılacak çeşitli klasik ve robust tahmin edicilere değinilmiştir. Üçüncü bölümde bazı yüz veritabanları üzerinde değişik klasik ve robust yöntemler kullanılarak yapılan deneyler ve bu deneylerin sonuçları yer almaktadır. Son bölümde ise sonuç ve öneriler verilmiştir.

II. TEMEL BİLEŞEN ANALİZİ

1901 yılında Karl Pearson'un başlattığı temel bileşenler analizi çalışmaları, 1933 yılında Hotelling tarafından geliştirilmiştir [12]. TBA çok sayıda birbiri ile ilişkili değişkenler içeren veri setinin boyutlarını veri içerisinde varolan değişimlerin mümkün olduğunca korunarak daha az boyuta indirgenmesini sağlayan bir dönüşüm tekniğidir [13]. Analiz, eldeki veriyi daha az sayıda değişkenle ifade edebilecek en iyi dönüşümü belirlemeyi amaçlar. Dönüşüm sonrasında elde edilen değişkenler ilk değişkenlerin temel bileşenleri olarak adlandırılır. İlk temel bileşen varyans değeri en büyük olandır ve diğer temel bileşenler varyans değerleri azalacak şekilde sıralanır. Gürültüye karşı düşük hassasiyet, bellek ve kapasite ihtiyaçlarının azalması, az boyutlu uzaylarda daha etkin çalışması TBA'nın temel avantajları arasında sıralanabilir [5].

II.1. Temel Bileşen Analizi Metodolojisi

Temel Bileşen Analizinin yüz tanıma bilinen en etkili uygulaması Turk ve Pentland tarafından geliştirilen özyüz (eigenface) yöntemidir [8]. Bu yöntem, eğitim kümesi veri

matrisinin (\mathbf{X}), Eşitlik 1 ve 2'de gösterildiği gibi M tane $N \times 1$ 'lik gözlem vektöründen oluştuğu kabul edildiğinde aşağıda verildiği gibi özetlenebilir.

$$\mathbf{X} = [\mathbf{x}^1 \mid \mathbf{x}^2 \mid \dots \mid \mathbf{x}^M] \quad (N \times M) \quad (1)$$

$$\mathbf{X} = \begin{bmatrix} x_1^1 & x_1^2 & \dots & x_1^M \\ x_2^1 & x_2^2 & \dots & x_2^M \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 & x_N^2 & \dots & x_N^M \end{bmatrix} \quad (2)$$

Çok değişkenli analizde, çoğu zaman değişkenlerin ölçü birimleri birbirinden oldukça farklıdır. Ancak, bazı durumlarda verilerin aynı ölçü biriminde olması daha iyi sonuç verir. Bu amaçla, öncelikle değişken değerleri merkezileştirilerek aynı birime dönüştürülür. Bu standartlaştırma veri ortalaması 0'a çekilerek yapılır. Eğitim vektörlerinin ortalaması \mathbf{m} , Eşitlik 3'deki gibi hesaplanır. Hesaplanan ortalama vektörü her bir gözlem vektöründen çıkartıldığında değişkenler sıfır ortalamalı olur. Ortalaması çıkarılmış veri matrisi $\tilde{\mathbf{X}}$ biçiminde gösterilirse ortalaması çıkarılmış gözlem vektörleri Eşitlik 4, sıfır ortalamalı gözlem matrisi de Eşitlik 5 ve 6'da verildiği gibi belirlenir.

$$\mathbf{m} = \frac{1}{M} \sum_{i=1}^M \mathbf{x}^i = \begin{bmatrix} m_1 \\ m_2 \\ \vdots \\ m_N \end{bmatrix} \quad (3)$$

$$\tilde{\mathbf{x}}^i = \mathbf{x}^i - \mathbf{m}, \quad \forall i \quad (4)$$

$$\tilde{\mathbf{X}} = [\tilde{\mathbf{x}}^1 \mid \tilde{\mathbf{x}}^2 \mid \dots \mid \tilde{\mathbf{x}}^M] \quad (N \times M) \quad (5)$$

$$\tilde{\mathbf{X}} = \begin{bmatrix} x_1^1 - m_1 & x_1^2 - m_1 & \dots & x_1^M - m_1 \\ x_2^1 - m_2 & x_2^2 - m_2 & \dots & x_2^M - m_2 \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 - m_N & x_N^2 - m_N & \dots & x_N^M - m_N \end{bmatrix} \quad (6)$$

Bir sonraki aşamada sıfır ortalamalı gözlem verisinin kovaryans matrisi Eşitlik 7 kullanılarak hesaplanır ve Eşitlik 8 elde edilir.

$$\mathbf{C} = \tilde{\mathbf{X}}\tilde{\mathbf{X}}^T \quad (7)$$

$$\mathbf{C} = \begin{bmatrix} (x_1^1 - m_1)^2 & (x_1^2 - m_1)(x_2^1 - m_2) & \dots & (x_M^1 - m_1)(x_N^1 - m_N) \\ (x_2^1 - m_2)(x_1^2 - m_1) & (x_2^2 - m_2)^2 & \dots & (x_M^2 - m_2)(x_N^2 - m_N) \\ \vdots & \vdots & \ddots & \vdots \\ (x_N^1 - m_N)(x_1^M - m_1) & (x_N^2 - m_N)(x_2^M - m_2) & \dots & (x_N^M - m_N)^2 \end{bmatrix} \quad (8)$$

Burada köşegen üzerinde bulunan katsayılar varyans, diğerleri 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 [14]. Değişkenlerden birinin değeri artarken diğerinin de değeri artıyor ya da biri azalırken diğeri de azalıyorsa iki değişken arasındaki kovaryans değeri pozitifdir. Değişkenlerden birinin değeri artarken diğerinin değeri azalıyor ya da birinin değeri azalırken diğerinin değeri artıyorsa kovaryans değeri negatif olur. Eğer değişkenler arasında belirgin bir ilişki yoksa, kovaryans değeri sıfırdır [15].

TBA için kovaryans matrisine özdeğer-özvektör ayrıştırması Eşitlik 9 kullanılarak gerçekleştirilir. \mathbf{C} , $N \times N$ boyutlu bir matris, λ herhangi bir skaler ve \mathbf{v} sıfırdan farklı bir sütun vektör olmak üzere, Eşitlik 9'u sağlayan λ sayısı \mathbf{C} 'nin özdeğeri ve \mathbf{v} de λ ile ilişkili özvektörüdür.

$$\mathbf{C}\mathbf{v} = \lambda\mathbf{v} \quad (9)$$

Özdeğerler büyükten küçüğe doğru sıralanacak biçimde dizildiğinde, sıralı özdeğerlere karşılık gelen özvektörlerden ilk P tanesi bir matrisin sütunlarını oluşturacak şekilde dizildiğinde en iyi izdüşümü gerçekleştiren \mathbf{W} izdüşüm matrisi Eşitlik 10'daki gibi elde edilir. Veri örneklerinin öznitelikleri de özvektörlerin belirlediği uzay üzerine izdüşüm alınarak Eşitlik 11'de verildiği gibi hesaplanır.

$$\mathbf{W} = [\mathbf{w}_1 \quad \mathbf{w}_2 \quad \dots \quad \mathbf{w}_p] \quad (10)$$

$$\mathbf{y}^i = \mathbf{W}^T \mathbf{x}^i, \quad i=1,2,\dots,M \quad (11)$$

Öznitelikler belirlenerek eğitim aşaması tamamlanmıştır. Bir sonraki aşama, sınıflandırma aşamasıdır. Sınıflandırma aşaması, eğitimde kullanılmayan bir test görüntüsü verildiğinde, eğitim aşamasındaki öznitelikler kullanılarak test vektörünün, eğitim aşamasındaki sınıflardan birine atanmasıdır. TBA temeline uyumlu ve yüksek performans veren en yaygın sınıflandırıcı, en yakın komşu (nearest neighbour) sınıflandırıcısıdır. Bu sınıflandırıcıda öncelikle hangi sınıfa ait olduğu bilinmeyen test vektörünün özniteliği hesaplanır ve eğitim aşamasında belirlenen özniteliklerle karşılaştırılır. Test vektörünün özniteliğine en yakın uzaklığa sahip olan eğitim örneğinin sınıfı, test vektörünün sınıfı olarak belirlenir.

II.2. Temel Bileşen Analizi Yönteminin Bazı Klasik ve Robust Uyarlamaları

TBA'nin de diğer çok değişkenli istatistiksel yöntemlerde olduğu gibi çeşitli robust uyarlamaları mevcuttur. Bu bölümde, çalışmada görüntü tanıma amacıyla kullanılan bazı robust TBA yöntemleri verilmiştir. Eğitim kümesinin veri matrisi \mathbf{R} ve gözlem vektörleri de \mathbf{r} sembolleriyle gösterilirse, [10, 11, 15] kaynaklarından derlenen çeşitli klasik ve robust tahmin ediciler aşağıdaki gibidir.

- *Standartlaştırma*: M tane görüntüden oluşan veri kümesindeki görüntülerin standart sapma değeri Eşitlik 12'deki gibi hesaplanır. Daha sonra veri kümesindeki görüntüler Eşitlik 13'deki gibi eleman elemana standart sapma değerine bölünür. Burada “ $\cdot /$ ” işleci matris veya vektör biçimindeki verinin aynı konumdaki değerlerinin birbirine bölünmesini temsil etmektedir.

$$\sigma_r = \sqrt{\frac{1}{(M-1)} \sum_{i=1}^M (\mathbf{r}^i - \boldsymbol{\mu}_r)^2} \quad (12)$$

$$\tilde{\mathbf{r}} = \mathbf{r} \cdot / \sigma_r \quad (13)$$

- *Normalleştirme*: Bu yöntemde, verilerin ölçü birimindeki farklılığın giderilmesi için her bir gözlem verisi, gözlem ortalamasından çıkarıldıktan sonra standart sapmasına bölünür. Gözlem vektörlerinin normalleştirilmesi Eşitlik 14’de gösterilmiştir.

$$\tilde{\mathbf{r}} = (\mathbf{r} - \boldsymbol{\mu}_r) \cdot / \boldsymbol{\sigma}_r \quad (14)$$

- *Medyan Merkezileştirme*: Bu yöntem ortalama merkezileştirmedeki durumla aynıdır. Tek fark veri kümesindeki görüntülerden veri kümesinin medyan değerinin çıkarılmasıdır. Medyan merkezileştirme Eşitlik 15’deki gibi hesaplanır.

$$\tilde{\mathbf{r}} = \mathbf{r} - \text{medyan}(\mathbf{r}) \quad (15)$$

- *SN-Standardlaştırma*: SN-standartlaştırma yönteminin klasik standartlaştırmadan farkı, standartlaştırmada kullanılan standart sapma verisi yerine SN tahmin edicisinin kullanılmasıdır. SN tahmin edicisi Eşitlik 16’daki gibi hesaplanır ve Eşitlik 17’de yerine konulur.

$$\boldsymbol{\sigma}_{SN} = (1,1926) \text{medyan}^i \left\{ \text{medyan}^j \left| \mathbf{r}^i - \mathbf{r}^j \right| \right\} \quad i,j=1,2,\dots,M \quad (16)$$

$$\tilde{\mathbf{r}} = \mathbf{r} \cdot / \boldsymbol{\sigma}_{SN} \quad (17)$$

- *Medyan Normalleştirme*: Eşitlik 20’de gösterilen medyan normalleştirme yönteminde verinin, Eşitlik 14’deki gibi ortalamadan olan farkı yerine medyandan olan farkı alınarak veri normalleştirilir.

$$\tilde{\mathbf{r}} = (\mathbf{r} - \text{medyan}(\mathbf{r})) \cdot / \text{medyan}(\mathbf{r}) \quad (20)$$

- *SN-Normalleştirme*: SN-normalleştirme yönteminde, klasik normalleştirmede kullanılan ortalama ve standart sapmanın yerine SN tahminleri kullanılmaktadır. SN-normalleştirme yöntemi Eşitlik 21’de verilmiştir.

$$\tilde{\mathbf{r}} = (\mathbf{r} - \boldsymbol{\sigma}_{SN}) \cdot / \boldsymbol{\sigma}_{SN} \quad (21)$$

Eğitim aşamasında, gözlem vektörlerinin tahminleri herhangi bir yöntem kullanılarak belirlendikten sonra matris sütununa dizilerek, tüm veri örneklerinin tahminlerini içeren $\tilde{\mathbf{R}}$ matrisi oluşturulur. Çeşitli klasik veya robust tahmin edicilerle uyarlanan TBA yönteminde kovaryans matrisi, $\mathbf{C} = \tilde{\mathbf{R}}\tilde{\mathbf{R}}^T$ eşitliğinden hesaplanır. Bundan sonrası klasik TBA yöntemi ile benzeşmektedir. Kovaryans matrisine özdeğer-özvektör ayrıştırması yapılarak en iyi izdüşüm matrisi Eşitlik 10 kullanılarak ve öznitelik çıkarma işlemi ise Eşitlik 11 kullanılarak gerçekleştirilir. Test aşamasındaki sınıflandırma prosedürü, klasik TBA da olduğu gibi, öznitelikler üzerinden en yakın komşu sınıflandırıcısı yöntemine göre tamamlanır.

III. YÜZ TANIMA DENEYLERİ

TBA yöntemi [8] temel alınarak yapılan yüz tanıma uygulamalarında AR [16], Yale [17] ve ORL [18] veritabanları kullanılmıştır. Görüntü tanıma deneylerinde tüm veritabanları için, veritabanını oluşturan görüntülerden rastgele seçilen yarısı eğitim kümesinde, diğer yarısı test kümesinde kullanılmıştır [19-20]. Rastgele seçim işlemi 10 kez tekrarlanmış ve toplamda 10'ar adet eğitim ve test kümeleri elde edilmiştir. Çeşitli temel bileşen sayıları için yapılan yüz tanıma deneylerinde her bir bileşen için test kümesi doğru tanıma oranlarının ortalaması hesaplanarak ortalama en yüksek doğru tanıma oranını veren bileşen sayısı sonuçları tablolaştırılmıştır.

III.1. Yale Veritabanı Deneyleri

Yale yüz veritabanı, 15 farklı kişiden alınan 11 farklı görüntü ile toplamda 165 görüntüden oluşan bir veritabanıdır. Veritabanı merkezden aydınlanmış, sağdan aydınlanmış, soldan aydınlanmış, gözlüklü, gözlüksüz, normal, uykulu, şaşkın, mutlu, üzgün, göz kırpmış görüntülerden oluşmaktadır. Deneyde eğitim ve test kümesinin eşit sayıda eleman içermesi için bireylerin 10 pozunu kullanılmıştır. Görüntülere, insanların gözleri yaklaşık olarak aynı yerleşkelerde konumlandırılacak biçimde önışleme yapılmış ve hesap yükünün hafiflemesi için downsampling uygulanarak boyutları 76×63'e indirgenmiştir. Yale veritabanından kullanılan bazı örnek görüntüler Şekil 1'de verilmiştir.



Şekil 1. Yale veritabanından rastgele seçilen 3 bireyin görüntüleri

Yale veritabanı deneylerinde, 1'den 75'e kadar olan temel bileşen sayısı için 10 test kümesinin her bir bileşene karşılık gelen test kümesi doğru tanıma oranlarının ortalaması hesaplanmıştır. Ortalamada en yüksek test kümesi doğru tanıma oranını veren bileşenin sonuçları Çizelge 1'de gösterilmiştir.

Çizelge 1. Yale Veritabanı Deney Sonuçları

Yöntem	Kullanılan Temel Bileşen Sayısı	Test Kümesi Doğru Tanıma Oranı (%)
Klasik-Ortalama Merkezileştirme	16	75,73
Robust-Medyan Merkezileştirme	16	76,27
Klasik-Standartlaştırma	40	74,80
Robust-SN Standartlaştırma	19	75,47
Klasik-Normalleştirme	73	75,07
Robust-Medyan Normalleştirme	73	75,60
Robust-SN Normalleştirme	22	75,60

Yöntemlerin doğru tanıma verimliliği yüksek olandan alçak olana göre bir sıralama yapıldığında robust medyan merkezileştirme, klasik ortalama merkezileştirme, SN-normalleştirme, medyan normalleştirme, SN-standartlaştırma, klasik normalleştirme ve klasik standartlaştırma biçiminde bir sıralama ortaya çıkmıştır. Buna göre, YALE veritabanı için, merkezileştirme yöntemleri, normalleştirme ve standartlaştırma yöntemlerinden daha başarılı sonuçlar verdiği söylenebilir.

Merkezileştirme yöntemlerinden de robust medyan merkezileştirme, klasik ortalama merkezileştirmeden daha iyi doğru tanıma oranları vermiştir. Normalleştirme yöntemlerinde robust *SN*-normalleştirme ve medyan normalleştirme klasik normalleştirmeden daha yüksek, standartlaştırma yöntemleri arasında ise robust *SN*-standartlaştırma, klasik standartlaştırmadan daha yüksek doğru tanıma oranları vermiştir.

III.2. AR Veritabanı Deneyleri

AR, 117 kişiden alınan 26 farklı görüntüden oluşan bir veritabanıdır. Ön cepheden çekilen görüntülerden ilk 13'ü bir oturumda diğer 13'ü ise 14 gün sonra aynı koşullarda yapılan diğer bir oturumda alınmıştır [21]. AR veritabanı deneylerinde, veritabanından rasgele seçilen 50 kişinin yüzü kapatmayan ve farklı ışık koşulları altında çekilmiş 14'er farklı gri seviyeli görüntüsü kullanılmıştır. Deneyde kullanılan, gözler yaklaşık olarak aynı yerleşelerde konumlandırılacak biçimde önışleme yapılan ve aşağı örneklenen görüntülerin boyutları 60×45 'dir. AR veritabanından seçilip önışlenen bazı görüntüler Şekil 2'de verilmiştir.



Şekil 2. AR veritabanından rastgele seçilen 4 bireyin görüntüleri

Deneyde, bir bireye ait önışlenmiş görüntülerden rastgele seçilen 7 tanesi eğitim aşaması, geriye kalan 7 tanesi ise test aşamasında kullanılmıştır. Rastgele seçim işlemi 10 kez tekrarlanmış ve kullanılan temel bileşen sayısına göre, her bir tekrarda test veri kümesi doğru tanıma oranlarının ortalaması hesaplatılmıştır. Bileşen sayısı, hesap kolaylığı sağlaması açısından 10 bileşenden başlatılıp, 10'ar 10'ar artırılarak 350 bileşene kadar denenmiş ve test kümesinde, ortalamada en

yüksek doğru tanıma oranını veren bileşen sayısı ve doğru tanıma oranları Çizelge 2’de gösterilmiştir.

Çizelge 2. AR Veritabanı Deney Sonuçları

Yöntem	Kullanılan Temel Bileşen Sayısı	Test Kümesi Doğru Tanıma Oranı (%)
Klasik-Ortalama Merkezileştirme	150	76,80
Robust-Medyan Merkezileştirme	150	76,83
Klasik-Standartlaştırma	80	76,91
Robust-SN Standartlaştırma	90	76,97
Klasik-Normalleştirme	80	76,91
Robust-Medyan Normalleştirme	200	76,83
Robust-SN Normalleştirme	80	77,06

AR veritabanı deneylerinde tüm yöntemlerin doğru tanıma oranı değerleri birbirine yakın olmasına rağmen klasik ortalama merkezileştirme yöntemi en düşük tanıma oranına sahiptir. Diğer tüm yöntemler, klasik ortalama merkezileştirme yönteminden daha yüksek tanıma oranları vermiştir. En yüksek tanıma oranına ise robust SN-normalleştirme yöntemi sahiptir.

III.3. ORL Veritabanı Deneyleri

ORL veritabanı, 40 farklı kişiden alınan 10 farklı görüntü ile toplamda 400 görüntüden oluşan bir veritabanıdır. Veritabanı, 40 kişiden farklı zaman dilimlerinde farklı aydınlanma koşulları, farklı yüz ifadeleri, farklı yüz detaylarına bağlı olarak alınan görüntülerden oluşmaktadır. Deneylerde kullanılan ORL veritabanında görüntü boyutları 56×46’ya indirgenecek biçimde bir önileme yapılmıştır. Görüntülerden rastgele seçilen 5’i eğitim kümesi, geriye kalan 5’i ise test kümesinde kullanılmıştır. ORL veritabanından kullanılan bazı görüntüler Şekil 3’de verilmiştir. ORL veritabanı test kümesi doğru tanıma yüzdeleri bileşen sayısı 5’den başlatılıp beşer beşer artırılarak 200 temel bileşene kadar 10 test kümesi için hesaplanmıştır. Ortalamada en yüksek

tanıma oranı veren bileşen sayısı ile ilgili bileşene karşılık gelen doğru tanıma oranı Çizelge 3'de gösterilmiştir.



Şekil 3. ORL veritabanından rastgele seçilen 3 bireyin görüntüleri

Çizelge 3. ORL Veritabanı Deney Sonuçları

Yöntem	Kullanılan Temel Bileşen Sayısı	Test Kümesi Doğru Tanıma Oranı (%)
Klasik-Ortalama Merkezileştirme	105	93,95
Robust-Medyan Merkezileştirme	195	94,20
Klasik-Standartlaştırma	115	94,00
Robust-SN Standartlaştırma	120	93,95
Klasik-Normalleştirme	120	93,90
Robust-Medyan Normalleştirme	35	93,90
Robust-SN Normalleştirme	120	94,00

ORL veritabanında, genelde tüm yöntemlerin doğru tanıma oranları oldukça yüksek ve birbirine yakın çıkmıştır. En yüksek tanıma oranını % 94,20 değeriyle robust medyan merkezileştirme verirken, en düşük tanıma oranını ise % 93,90 değeriyle klasik normalleştirme ve medyan normalleştirme yöntemleri vermiştir. Tüm yöntemlerin genelde başarılı sonuçlar verdiği söylenebilir.

IV. SONUÇ ve ÖNERİLER

Klasik istatistiksel yöntemlerin çoğu, analiz edilen verinin Normal dağıldığı varsayımı üzerine kurulmuştur. Temel bileşen analizi yöntemi de verinin Normal dağılıma sahip olduğu varsayımı altında iyi sonuçlar veren bir boyut indirgeme ve öznitelik çıkarma yöntemidir. Pratikte gözlem yapılan veri kümeleri, çoğunlukla varsayılan modelden farklılıklar gösterirler. Bunun en önemli nedeni aykırı değerlerdir. Robust istatistiksel yöntemler, veri kümesinde bulunan aykırı değerlerden ve varsayımlardaki sapmalardan etkilenmeyen, varolan klasik yöntemlerden daha iyi başarımlar sağlamayı amaçlayan yöntemlerdir.

Bu çalışmada, temel bileşen analizinde kullanılan ortalama merkezileştirme yerine, çeşitli klasik ve robust merkezileştirme, normalleştirme ve standartlaştırma teknikleri temel bileşen analizi yönteminin içinde kullanılarak Yale, ORL ve AR yüz veritabanları üzerinde yüz tanıma deneyleri yapılmıştır. Genelde, robust yöntemler klasik yöntemlerden daha başarılı sonuçlar vermiştir. Bu durum, veritabanlarındaki yüz görüntülerinin Normal dağılıma uymadığını gösterir. Yale ve ORL veritabanlarında, robust medyan merkezileştirme yöntemi en yüksek tanıma oranlarını verirken, AR veritabanı için robust SN -normalleştirme yöntemi en yüksek tanıma oranlarını vermiştir. Klasik temel bileşen analizinde kullanılan ortalama merkezileştirme yöntemi, doğru tanıma başarımlarını sıralamasında diğer yöntemler arasında YALE veritabanında ikinci sırada, ORL veritabanında orta sıralarda, AR veritabanında ise en alt sırada kalmıştır. Özetlemek gerekirse, yapılan yüz tanıma deneyleri sonucunda robust yöntemlerin, klasik yöntemlerden daha başarılı tanıma oranları verdiği gözlemlenmiştir.

Klasik TBA yönteminin verimliliğinin yüksek olabilmesi için verilerin çok değişkenli Normal dağılıma sahip olması gerekmektedir. Oysaki uygulamalarda tek bir değişkenin dahi normal dağılıma sahip olmadığı belirtilmektedir. Bu yüzden pratikte normal dağılım varsayımı sağlanması pek mümkün değildir [22]. TBA'da ele alınan tüm değişkenlerin aynı anda normal dağılıma sahip olabilmesi ise neredeyse imkansızdır. Bu nedenle varsayımdan sapmalardan ve aykırı gözlemlerden etkilenmeyen robust yöntemlerin görüntü tanıma uygulamalarında kullanılması, yapılan çalışmanın güvenilirliğini arttıracaktır. Çalışmada yapılan yüz tanıma deneyleri sonucunda, eğitim için kullanılan örnek sayısının oldukça az olmasına rağmen, robust tahmin edicilerin bazı yüz veritabanlarında klasik yöntemlerden daha yüksek doğru tanıma oranları verdiği gözlemlenmiştir. Bu sonuçlar göz önünde bulundurulduğunda, yüz tanıma

uygulamalarında robust tekniklerin kullanımının klasik tekniklerden daha başarılı doğru tanıma oranları sağlayacağı düşünülmektedir.

V. KAYNAKLAR

- [1] W. Zhao, R. Chellappa, P. J Phillips and A. Rosenfeld, “Face Recognition: A Literature Survey”, *ACM Computing. Surveys*, Vol.35, No.4, pp.399–458, 2003.
- [2] R. Chellappa, C. L. Wilson and S. Sirohey, “Human and Machine Recognition of Faces: A Survey”, *Proceedings of IEEE*, Vol.83, No.5, pp.705–741, 1995.
- [3] A. K. Jain, A. Ross and S. Prabhakar, “An Introduction to Biometric Recognition”, *IEEE Trans. Circ. and Sys. for Video Tech.* Vol.14, No.1, pp.4–20, 2004.
- [4] A. A. Salah, “İnsan ve Bilgisayarda Yüz Tanıma”, Bilgi İşleyen Makine Olarak Beyin Sempozyumu-3, Boğaziçi Üniversitesi, İstanbul, 2005.
- [5] E.Sütçüler, “Gerçek Zamanlı Video Görüntülerinden Yüz Bulma ve Tanıma Sistemi”, Yüksek Lisans tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, 90 s, 2006.
- [6] H. Durucasu, “Asal Bileşen Analizi ve Bir Uygulama Denemesi”, Yüksek Lisans Tezi, Anadolu Üniversitesi Fen Bilimleri Enstitüsü, 89 s,1991.
- [7] A. Ö.Yaycı, “Temel Bileşenler Analizi için Robust Algoritmalar”, Yüksek Lisans Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, 56 s, 2006.
- [8] M. A. Turk and A. P.Pentland, “Eigenfaces for recognition”, *Journal of Cogn. Neuroscience*, Vol.3, pp.71–86, 1991.
- [9] I. Stanimirova, M. Daszykowski and B. Walczak, “Dealing with Values and Outliers in Principal Component Analysis”, *Talanta*, Vol. 72, No. 1, pp. 172–178, 2007.
- [10] M. Daszykowski, K.Kaczmarek, Y. V. Heyden and B. Walczak, “Robust Statistics in Data Analysis- A Review Basic Concepts”, *Chemometrics and Intelligent Laboratory Systems*, Vol. 85, No. 2, pp. 203–219, 2007.
- [11] M. Daszykowski, S.Serneels, K.Kaczmarek, P. V. Espen, C. Croux and B. Walczak, “TOMCAT: A MATLAB Toolbox for Multivariate Calibration Techniques”, *Chemometrics and Intelligent Laboratory Systems*, Vol. 85, No. 2, pp. 269–277, 2007
- [12] Z. Filiz, “Güvenilirlik Çözümlemesi, Temel Bileşenler ve Faktör Çözümlemesi”, *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi*, Cilt.4, No.2, s. 211–222, 2003.

- [13] M. Çilli, “İnsan Hareketlerinin Modellenmesi ve Benzeşiminde Temel Bileşenler Analizi Yönteminin Kullanılması”, Doktora Tezi, Hacettepe Üniversitesi Sağlık Bilimleri Enstitüsü, 240 s, 2007.
- [14] E. S. Konak, “Bilgisayar Destekli Yüz Tanıma Sistemi Tasarımı”, Yüksek Lisans Tezi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, 58 s, 2006.
- [15] R. Alpar, “Uygulamalı Çok Değişkenli İstatiksel Yöntemlere Giriş 1”, Nobel Yayın Dağıtım/Teknik Dizisi, 410 s, 2003.
- [16] http://cobweb.ecn.purdue.edu/~aleix/aleix_face_DB.html
- [17] <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>
- [18] <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>
- [19] S. Watanabe, P. F.Lambert, C. A. Kulikowski, J. L. Buxton and R.Walker, Evaluation and Selection of Variables in Pattern Recognition”, *Computing and Information Sciences II*, pp. 91–122, 1967.
- [20] H. Cevikalp, H. S. Yavuz, M. A. Cay and A. Barkana, “ Two-dimensional Subspace Classifiers for Face Recognition”, *Neurocomputing*, Vol.72, pp.1111–1120, 2009.
- [21] A.M. Martinez, R. Benavente, “The AR face database”, CVC Technical Report #24,1998.
- [22] H. Scheffe, “*The Analysis of Variances*”, John Wiley&Sons, New York, 1959.