

# Kanonik Korelasyon Analizi ile Düşük Çözünürlüklü Görüntülerden Yüz Tanıma

## Face Recognition from Low Resolution Images Using Canonical Correlation Analysis

B. Şen<sup>1</sup> and Y. Özkazanç<sup>2</sup>

<sup>1</sup> Karel Elektronik, Ankara/Türkiye, bekir.sen@hacettepe.edu.tr

<sup>2</sup> Hacettepe Üniversitesi, Ankara/Türkiye, yakup@ee.hacettepe.edu.tr

### Özetçe

Yüz tanıma problemi uzun yıllardır üzerinde çalışılan bir problemdir. Buna karşılık tanınmak istenen kişiye ait fotoğraf düşük çözünürlükte olduğunda problem zorlaşmakta ve standart yüz tanıma yöntemleri başarılı sonuçlar vermekten uzaklaşmaktadır. Bu makalede, güvenlik ve kriminal çalışmalarda karşılaşılan; düşük çözünürlükteki fotoğraflardan yüz tanıma için yenilikçi bir yaklaşım sunulmuştur. Kanonik Korelasyon Analizi (CCA) temeline dayanan bu yöntem yüksek çözünürlükteki (HR) ve düşük çözünürlükteki (LR) fotoğrafların yeni bir ara uzayda birbirleri ile en yüksek korelasyon gösterecek şekilde dönüştürülmesi esasına dayanmaktadır. Her iki çözünürlükteki fotoğrafların Temel Bileşen Analizi (PCA) yapıldıktan sonra; seçilen öznelikler CCA kullanılarak oluşturulan ara uzayda tanıma için kullanılmıştır.

Yöntemin performansı iki farklı uygulama ile gösterilmiştir. Birinci uygulamada 40 kişi ve herbirine ait 10 farklı açıdan çekilmiş 400 HR fotoğraflar ile bunların LR görüntüleri kullanılmıştır. İkinci uygulamada ise 123 kişiye ait HR fotoğraflar ve bunların LR görüntüleri kullanılmıştır. Önerilen yöntem ile yapılan tanıma sonrasında başarılı sonuçlar elde edilmiştir.

**Anahtar Sözcükler :** Yüz tanıma, CCA, Video gözleme, Düşük çözünürlüklü görüntü

### Abstract

In this paper, we present a novel framework for face recognition from low resolution face photos. Our framework is based on Principle Component Analysis (PCA) and Canonical Correlation Analysis (CCA). First, we apply PCA to dataset for dimension reduction and then, apply CCA for reaching maximum correlation between datasets. This approach is tested on two different dataset including 400 and 123 HR-LR photo pairs. The average performance reached 96.5% recognition rate on these experiments.

**Keywords—**face recognition, CCA, video surveillance, low resolution image

### 1. Giriş

Yüz tanıma problemi son 20 yılda üzerinde sıklıkla çalışılan bir problem olmuştur. Problem ilk zamanlarda yüksek çözünürlükte fotoğraflar üzerinden çalışılmış ve tanıma performansları yüksek seviyelere ulaşmıştır.

Özellikle güvenlik amaçlı kameralarının yaygınlaşmasıyla birlikte yüz tanımanın güvenlik amacıyla kullanılma ihtiyaçları da artmıştır.

Güvenlik amaçlı kameralar, tek kamerayla izlenebilen küçük alanlardan, onlarca kamerayla izlenebilen büyük alanlara kadar birçok yerde yaygın olarak kullanılmaktadır. Güvenlik kameraları geniş alanları görebilmesi için genellikle geniş açılı olarak seçilmektedir. Kameraların görüntü çektiği bölgelere olan uzaklığı ile beraber

yüz görüntülerinin kamera üzerindeki izdüşümleri 32x32 piksel veya daha düşük boyutlara düşebilmektedir. Düşük çözünürlük, bu yüz görüntüleri üzerindeki ayırt edici öznitelik sayısının azalmasına sebep olmaktadır [1]. Bu sebepten standart olarak kullanılan yüz tanıma yöntemleri bu tür problemlere çözüm getirememektedir. Yapılan deneysel çalışmalarda 64x64 veya 32x32 çözünürlüğün altında olan yüz resimleri için tanıma performansının dramatik olarak düştüğünü göstermiştir [2]. Gerçek hayatta karşılaşılan yüz tanıma problemleri, güvenlik kamerası ile elde edilmiş LR bir görüntünün, HR görüntülerden oluşan bir veri kümesindeki karşılığının bulunması şeklindedir.

Düşük çözünürlüklü görüntülerde yüz tanıma için kullanılan iki temel yaklaşım vardır: Birinci ve daha geleneksel olan iki basamaklı yaklaşımda [3] tanınması istenen LR görüntüleri süper çözünürlük (SR) yöntemi ile HR görüntülere çevrilmekte veya HR veri kümesindeki tüm görüntüler aşağı-örnekleme yöntemi ile LR görüntülere dönüştürmektedir. Bu işlemlerden herhangi biri sonrasında LR ve HR görüntüler aynı uzayda tanımlanmakta ve tanıma algoritması çalıştırılmaktadır. SR yöntemleri yapılmak istenen, LR görüntüdeki kaybolmuş bilgiyi geri getirmektir [1]. LR görüntü [4] veya görüntü serilerinden [5] HR görüntü elde etme işlemi zaman alan bir işlemdir ve performansı özellikle farklı poz ve ışık altında kötüleşmektedir. Veri kümesindeki tüm HR resimlerin elde edilen LR resme göre aşağı-örnekleme yöntemi zaman alıcı bir işlem olmasına ek olarak ayırt edici özellikleri de yitirmesi sebebiyle; kötü performans göstermekte ve tercih edilmemektedir [3], [6], [7].

Bu makalede, CCA tabanlı bir yaklaşımla düşük çözünürlükteki görüntülerden yüz tanıma için bir çalışma çerçevesi çizilecektir. Bu anlayış içinde yapılan işlemler sırasıyla

1. Kullanılacak özniteliklerin belirlenmesi:
  - (a) Temel bileşen analizinin (PCA) yapılması
  - (b) Bileşenlerin seçimi
2. CCA ile ara uzaylara geçilmesi
3. Ara uzaylar arasında dönüşüm yapılması şeklinde özetlenebilir.

Önerilen bu yöntem, LR veya HR uzayına doğrudan bir geçiş yapmak yerine ara bir uzayda işlemlerin yapılmasını sağlamayı hedeflemektedir. İki basamaklı yöntemlerin aksine; ulaşılmak istenen uzay, LR ve HR fotoğrafların birisi değil, aralarındaki korelasyonun en yüksek değeri gösterdiği uzaydır. Önerilen bu yöntem gibi ara uzaylara geçilerek yapılan başka çalışmalar da bulunmaktadır [3], [7], [8].

Önerilen yenilikçi yöntem iki farklı veri kümesi üzerinde test edilmiştir.

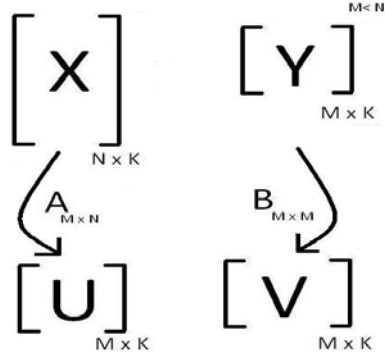
Bölüm 2'de önerilen yüz tanıma yönteminin temel dayandığı Kanonik Korelasyon Analizinin (CCA) nasıl yapıldığı anlatılmıştır.

Bölüm 3'de düşük çözünürlüklü görüntülerden yüz tanıma için önerilen çerçevenin nelerden oluştuğu ve önerilen bu yöntemin her bir adımda yapılanlardan bahsedilmiştir.

Bölüm 4'de, önerilen yöntemin, veri kümesi üzerinde uygulamasını verilmiştir.

## 2. KANONİK KORELASYON ANALİZİ

Kanonik Korelasyon Analizi (CCA), çok boyutlu iki değişken kümesi arasındaki doğrusal benzerliği ortaya çıkaran istatistiksel bir yöntemdir [9]. H. Hotelling tarafından 1936'da ortaya konulan [10] bu yöntem, temelde iki ayrı uzayda tanımlanmış veri kümeleri üzerine uygulanacak iki farklı doğrusal dönüşümü (temel vektörler kümesini) bulmayı hedeflemektedir. Bu iki temel vektörler kümesinin özelliği, üzerlerine yapılan izdüşümlerin sonucunda ortaya çıkan yeni ara uzayların birbirleri ile olan korelasyonunu maksimize ediyor olmalarıdır. CCA yöntemi Şekil 1'de gösterilmiştir.



Şekil 1: Kanonik Korelasyon Analizi

Şekil 1'de gösterilen  $X$  matrisinin her bir kolonu,  $N$  boyutlu  $\mathbf{X}$  uzayında tanımlanmış bir örneğe,  $Y$  matrisinin her bir kolonu ise  $M$  boyutlu  $\mathbf{Y}$  uzayında tanımlanmış bir örneğe karşılık gelmektedir. CCA en basit anlamda,  $\mathbf{X}$  ve  $\mathbf{Y}$  uzaylarına doğrusal dönüşümler uygulayarak yeni elde edilecek verilerin arasındaki korelasyonu maksimize etmeye çalışmaktadır.

$X$  matrisi,  $X \in R^{N \times K}$  olmak üzere, her bir kolonu bir örneğe ait  $N$  adet öznelik içeren ve  $x_1, x_2, x_3, \dots, x_K$  olmak üzere toplam  $K$  örneğe ait öznelikleri içeren,

$Y$  matrisi,  $Y \in R^{M \times K}$  olmak üzere, her bir kolonu bir örneğe ait  $M$  adet öznelik içeren ve  $y_1, y_2, y_3, \dots, y_K$  olmak üzere toplam  $K$  örneğe ait öznelikleri içeren matrislerdir.

$X$  ve  $Y$  veri kümeleri aralarındaki korelasyonu maksimize eden doğrusal dönüşüme  $A$  ve  $B$  temel vektörler kümesi dedikimizde;

$U$  matrisi,  $U \in R^{\min(\text{rank}(X), \text{rank}(Y)) \times K}$  olmak üzere, her bir kolonu  $\mathbf{X}$  uzayındaki bir örnek verinin  $A$  doğrusal dönüşüm uygulanmış vektörü ifade etmektedir. Diğer bir ifadeyle  $U$  matrisi; CCA sonucunda elde edilen  $A$  doğrusal dönüşüm matrisi ile  $X$  matrisinin çarpımıyla ( $U = AX$ ) elde edilir.  $A \in R^{\min(\text{rank}(X), \text{rank}(Y)) \times N}$  boyutundadır.

$V$  matrisi,  $V \in R^{\min(\text{rank}(X), \text{rank}(Y)) \times K}$  olmak üzere, her bir kolonu  $\mathbf{Y}$  uzayındaki bir örnek verinin  $B$  doğrusal dönüşüm uygulanmış vektörü ifade etmektedir. Diğer bir ifadeyle  $V$  matrisi; CCA sonucunda elde edilen  $B$  doğrusal dönüşüm matrisi ile  $Y$  matrisinin çarpımıyla ( $V = AY$ ) elde edilir.

$B \in R^{\min(\text{rank}(X), \text{rank}(Y)) \times M}$  boyutundadır.

CCA'nın yapmaya çalıştığı  $U$  ve  $V$  değişkenler kümelerinin satırları arasındaki korelasyonu maksimize etmektir.  $U$  ve  $V$  matrislerinin her bir satırı, yeni uzaylardaki özneliklere karşılık gelmektedir. CCA sonucunda, bu yeni öznelikler ( $U$  ve  $V$  matrislerinin satırları) korelasyonu büyükten küçüğe olmak üzere sıralanmış olacaktır. Bu işlem esnasında  $\mathbf{X}$  ve  $\mathbf{Y}$  uzaylarını  $\min(\text{rank}(X), \text{rank}(Y)) \times K$  boyutuna indirir.  $A$  matrisinin her bir satırı üzerine  $X$  veri setinden alınan her bir örnek ( $X$  matrisinin kolonları) yansıtıldığında elde edilen  $U$  matrisinin birinci özneliği (satırı) ile,  $B$  matrisinin her bir satırı üzerine  $Y$  matrisinden alınan her bir örnek ( $Y$  matrisinin kolonları) yansıtıldığında elde edilen  $V$  matrisinin birinci özneliği (satırı) en fazla korelasyonu göstermektedir. Şimdi,  $X$  ve  $Y$  veri seti arasındaki verilerin izdüşümlerinin korelasyonunu maksimize edecek vektörleri ( $A$  ve  $B$  matrislerinin satırları) matematiksel olarak gösterelim:  $a_1, A$  matrisinin,  $b_1$  ise  $B$  matrisinin birinci satırını gösteren kolon vektörü olsun. Korelasyon katsayısı ( $\rho$ ),

$$\rho = \frac{a_1^T X Y^T b_1}{\sqrt{(a_1^T X X^T a_1)(b_1^T Y Y^T b_1)}} \quad (1)$$

şeklinde ifade edilir.  $\rho$  korelasyon katsayılarını içeren köşegen  $r$  matrisi korelasyon matrisi,  $r \in R^{\min(\text{rank}(X), \text{rank}(Y)) \times \min(\text{rank}(X), \text{rank}(Y))}$  boyutundadır.  $a_1$  ve  $b_1$  vektörlerinin özelliği,  $\rho$ 'yu maksimize edecek olmalarıdır.

$$\max_{a_1, b_1} a_1^T X Y^T b_1 \quad \text{koşul: } a_1^T X X^T a_1 = 1 \quad b_1^T Y Y^T b_1 = 1 \quad (2)$$

Denklem-3'de verilen koşullu optimizasyon probleminin çözülmesiyle  $a_1$  vektörünün elde edilebileceği gösterilebilir [11], [12].

$$\max_{a_1} a_1^T X Y^T (Y Y^T)^{-1} Y X^T a_1 \quad \text{koşul: } a_1^T X X^T a_1 = 1 \quad (3)$$

Denklem-2 ve Denklem-3, Denklem-4'de verilen genelleştirilmiş özdeğer vektör probleminin en

büyük özdeğerlerine karşılık gelen özvektörleri bulmaktadır.

$$XY^T(YY^T)^{-1}YX^T a_1 = \eta XX^T a_1 \quad (4)$$

$\eta$ ,  $a_1$  özvektörlerine karşılık gelen özdeğerlerdir.  $\mathbf{X}$  uzayı imin  $M$  adet özvektör, Denklem-5'de verilen optimizasyon probleminin çözülmesi ile elde edilir [11].

$$\max_A \text{trace}(A^T XY^T (YY^T)^{-1} YX^T A) \quad (5)$$

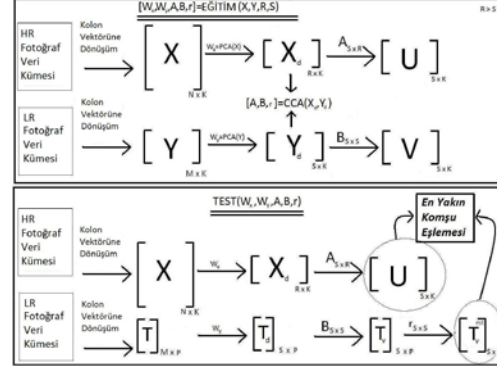
*koşul:  $A^T X X^T A = I$*

$M \leq N$  kabullenmesi yapıldığında,  $A$  matrisi  $M \times N$  boyutunda olacak ve  $N$  uzunluğunda  $M$  adet özvektörden oluşacaktır. Aynı yöntemle elde edilen  $B$  matrisi de kullanılarak  $U$  ve  $V$  uzaylarını oluşturduğumuzda, bu iki uzay arasında birbiri ile en çok korelasyonu gösteren veriler birinci satırlarındaki değişkenler, en az korelasyonu gösterenler ise son satırlarındaki veriler olacaktır.

CCA yönteminin,  $U$  ve  $V$  uzayları arasındaki korelasyonu büyükten küçüğe doğru olan özvektörler şeklinde sıralaması, sınıflandırma/tanım için önemli bir altyapı sağlamaktadır. Bu sıralama, özneliklerin indirgenmesi probleminde optimal çözüm sağlayacaktır.  $U$  ve  $V$  uzayları arasındaki bu yüksek korelasyon sayesinde  $U$  uzayında tasarlanmış bir sınıflandırma veya tanıma yöntemi,  $V$  uzayındaki veriler için de kullanılabilir. Birbirleri ile yüksek korelasyon gösteren özneliklerin aynı sınıflandırıcıda, korelasyon göstermeyenlere göre daha iyi performans vermesi beklenen bir durumdur.

### 3. CCA İLE DÜŞÜK ÇÖZÜNÜRLÜKLÜ GÖRÜNTÜDEN YÜZ TANIMA

CCA sonucunda ulaşılan yeni uzaylar birbirleri ile en yüksek korelasyonu gösteren özneliklerin bulunduğu uzaylar olduğundan; bu uzayda tanıma yapmanın başarılı sonuçlar vermesi beklenmektedir. LR görüntülerden yüz tanıma için önerilen yöntemin basamaklarının neler olduğu Şekil-2'de gösterilmiştir.



Şekil 2: CCA ile LR Görüntülerden Yüz Tanıma

#### a. Öznelik Belirlenmesi

Kullanılacak öznelikler, temel bileşen analizi (PCA) yöntemi ile elde edilmiştir [13]. İşlem yapılan veri sayısını küçültmek ve veriler üzerindeki gürültü miktarını azaltmak için, en yüksek özdeğerlere karşılık gelen belirli sayıda özvektörün kullanılması yeterlidir. Bu işlem sonrasında  $\mathbf{X}$  ve  $\mathbf{Y}$  uzayındaki yeni veriler sırasıyla  $X_d$  ve  $Y_d$  olarak isimlendirilecektir.  $X_d$  matrisi,  $\mathbf{X}$  matrisinin ilk  $R$  adet temel bileşeni içermekte ve  $R \leq N$  olmak üzere  $X_d \in R^{R \times K}$ ,  $Y_d$  matrisi,  $\mathbf{Y}$  matrisinin ilk  $S$  adet temel bileşeni içermekte ve  $S \leq M$  olmak üzere  $Y_d \in R^{S \times K}$  matrislerine dönüşecektir. Bu işlem eğitim aşamasında, ilgili temel bileşenleri ( $W_x$  ve  $W_y$ ) belirlemek için yapılmalı, tanıma aşamasında ise bu temel bileşen vektörleri kullanılmalıdır.  $W_x$ ,  $\mathbf{X}$  uzayındaki verilerin  $R^{R \times K}$  boyutuna indirgenmesi için  $R \leq N$  ilk  $R$  adet temel bileşenin alınması ile oluşturulmuş  $W_x \in R^{R \times N}$  ve  $W_y$ ,  $\mathbf{Y}$  uzayındaki verilerin  $R^{S \times K}$  boyutuna indirgenmesi için  $R \leq S$  ilk  $R$  adet temel bileşenin alınması ile oluşturulmuş  $W_y \in R^{S \times M}$  matrisleridir.

#### b. CCA ile Ara Uzaylara Geçilmesi

CCA yöntemi kullanılarak,  $X_d$  ve  $Y_d$  uzaylarındaki verilerin CCA dönüşümleri birbirleri ile maksimum korelasyon yapısını tanımlayacaktır. Bu işlem sonucunda  $X_d$  matrisinden elde edilecek verilere  $U$ ,  $Y_d$  matrisinden elde edilecek verilere  $V$  diyeceğiz. Bu matrislerin bulunduğu uzaylar sırasıyla ( $S \leq R$  kabul edilmiştir),  $U \in R^{S \times K}$  ve  $V \in R^{S \times K}$  olacaktır. Bu işlem, eğitim aşamasında kanonik korelasyon dönüşüm ( $A$  ve  $B$ ) ve köşegen korelasyon matrisini ( $r$ ) bulmak için yapılmalı, tanıma aşamasında bu matrisler kullanılmalıdır.

### c. Ara Uzaylar arasında Dönüşüm Yapılması

Tanıma aşamasında, tanınması istenen LR görüntünün temel bileşenlerini içeren  $T_v$  ( $T_v \in \mathbb{R}^{S \times \#LR}$ ) verilerini doğrudan kullanmak yerine,  $T_v$  verilerinden doğrusal en küçük karesel hata kestiricisi (LMMSE) ile  $U$  verilerinin kestirilmesi önerilmiştir. Elde edilen  $T_v^{est}$  matrisi,  $T_v^{est} \in \mathbb{R}^{S \times P}$  olarak bulunacaktır.  $P$ , tanınacak LR görüntü sayıdır. Böylece birbirleriyle maksimum korelasyonu göstermelerine ek olarak doğrusal bir dönüşüm ile  $U$  ve  $T_v^{est}$  matrisleri arasındaki uzaklık azaltılmış olacaktır. Verilerin ortalamaları sıfır ise,  $T_v = rU$  şeklinde bulunur.  $U$  ve  $V$  uzayları arasında LMMSE kestiricisi tasarlandığında  $V$  uzayındaki verilerin kovaryans matrisi CCA'nın diklik özelliğinden dolayı birim matrise,  $U$ - $V$  çapraz kovaryans matrisi ise, köşegeninde korelasyonların olduğu köşegen bir matrise dönüşecektir.  $U$  ve  $V$  çapraz kovaryans matrisi  $r$  matrisi ile aynı olacaktır.


## 4. UYGULAMA

Önerilen yöntemin performansı iki deney üzerinden çalışılmıştır. Birinci uygulamada 40 kişiye ait ve 10 farklı açıdan çekilmiş toplam 400 fotoğraftan oluşan "ORL veri kümesi" [14] kullanılmıştır. İkinci uygulamada ise 123 kişiye ait önden ve normal ışık altında çekilmiş yüz fotoğraflarından oluşan "AR veri kümesi" kullanılmıştır [15].


### a. ORL Veri Kümesi Uygulaması

Şekil-3'de ORL veri kümesinden seçilmiş bir kişiye ait 10 farklı açıdan elde edilmiş fotoğraflar gösterilmiştir.

İlk işlem olarak 112 X 92 boyutlarında olan HR görüntülerin tamamı bikümbik interpolasyon ve aşağı-örnekleme yöntemi ile 11 X 9 boyutlarına indirgenmiştir. Şekil-4'de aşağı örneklenmiş LR görüntüler gösterilmiştir.



Şekil 3: ORL veri kümesi HR görüntü



Şekil 4: ORL veri kümesi LR görüntü

Eğitim kümesi olarak her bir kişiye ait 10 fotoğraftan 5 tanesi ve bunların düşük çözünürlükteki karşılıkları olmak üzere toplam 200 HR ve 200 LR görüntü kullanılmış, kalan 200 HR ve 200 LR görüntü test etmek için bırakılmıştır.

Öncelikle, eğitim kümesindeki HR görüntülerin boyutlarının büyük olması sebebiyle temel bileşen analizi uygulanmış ve temel bileşenlerden ilk 50 bileşen seçilmiştir. HR görüntülerin düşük boyuta indirgenmesi aşamasında  $W_x$  matrisi test aşamasında yeniden hesaplanmadan aynen kullanılmıştır. LR görüntülerin toplam boyutu 11 X 9 olmak üzere toplam 99 olduğu için opsiyonel olan PCA analizi LR görüntülere uygulanmamış ve 99 adet öznitelik olarak kullanılmıştır. 50 boyuta indirgenmiş HR görüntülerin öznitelikleri ile LR görüntüler üzerinde CCA uygulanmış ve kanonik dönüşüm matrisleri ( $A, B$ ) ile korelasyon matrisi ( $r$ ) bulunmuştur. Eğitim aşamasında bulunan bu matrislerden kanonik dönüşüm matrisleri ( $A, B$ ) test aşamasında 'CCA ile

Ara Uzaylara Geçilmesinde korelasyon matrisi ( $r$ ) ise 'Ara Uzaylar arasında Dönüşüm Yapılması'nda kullanılmıştır.

Tanıma aşaması,  $L_2$  normda  $T_v^{est}$  matrisindeki verilere  $U$  matrisinden en yakın olan verinin eşlenmesi şeklinde yapılmıştır.

Bu yöntem sonucunda ORL veri kümesinde %94,5 oranında doğru tanıma sağlanmıştır.

### b. AR Veri Kümesi Uygulaması

AR veri kümesi 768 X 576 boyutunda görüntülerden oluşmaktadır. Bu yüksek boyutlarda işlem yapmanın zorluğundan dolayı; öncelikle görüntüler 191 X 151 boyutuna indirgenmiş ve bu görüntüler HR görüntü olarak adlandırılmıştır. Şekil-5'de AR veri kümesinden seçilmiş iki kişiye ait HR görüntüler ile bu görüntülerin bikübik interpolasyon ve aşağı indirgenmiş 19 X 15 boyutundaki LR görüntüleri gösterilmiştir.

Uygulamada birini dışarda bırakma yöntemi kullanılmıştır. 122 görüntü, PCA eğitimi ( $W_x$  ve  $W_y$  matrislerini bulmak için) ve CCA eğitimi ( $A, B$  ve  $r$  matrislerini bulmak için) için kullanılmış, bir görüntü ise test amaçlı kullanılmıştır. Bu işlem her bir görüntü için yani 123 defa tekrarlanmıştır.

Eğitim kümesindeki HR görüntüler üzerinde temel bileşen analizi uygulanmış ve temel bileşenlerden ilk 50 bileşen seçilmiştir. Bu uygulamada da PCA sonucu elde edilen  $W_x$  matrisi test aşamasında da aynen kullanılmıştır. LR görüntülerin toplam boyutu 19 X 15 olmak üzere toplam 285 olduğu için opsiyonel olan PCA işlemi LR görüntülere de uygulanmış ve  $W_y$  matrisi bulunmuştur. LR öznitelikleri arasından da ilk 50 bileşeni öznitelik olarak seçilmiştir. 50 boyuta indirgenmiş HR ve LR görüntülerin öznitelikleri üzerinde CCA uygulanmış ve kanonik dönüşüm matrisleri ( $A, B$ ) ile korelasyon matrisi ( $r$ ) bulunmuştur. Eğitim aşamasında bulunan bu matrislerden kanonik dönüşüm matrisleri ( $A, B$ ) test aşamasında 'CCA ile Ara Uzaylara Geçilmesinde korelasyon matrisi  $r$  ise 'Ara Uzaylar arasında Dönüşüm Yapılması'nda kullanılmıştır.



Şekil 5: (a)AR veri kümesi HR görüntü, (b)AR veri kümesi LR görüntü

Tanıma aşaması,  $L_2$  normda  $T_v^{est}$  matrisindeki verilere  $U$  matrisinden en yakın olan verinin eşlenmesi şeklinde yapılmıştır.

Bu yöntem sonucunda AR veri kümesinde %98,4 oranında doğru tanıma sağlanmıştır.

## 5. SONUÇ

Bu makalede de düşük çözünürlüklü görüntülerden yüz tanıma için yenilikçi bir yaklaşım ortaya konmuştur. Önerilen yaklaşım, HR veya LR görüntüleri uzayında değil, CCA tabanlı bir dönüşüm ile verilerin korelasyonlarının maksimum olduğu ara uzaylarda tanıma yapma esasına dayanmaktadır.

PCA ile kullanılacak özniteliklerin belirlenmesi/azaltılması, bu öznitelikler ile CCA yapılması ve bu yönteminin düşük çözünürlüklü görüntülerden yüz tanınmasında kullanılması yeni bir yaklaşımdır. Önerilen yöntemde CCA sonrası belirlenen öznitelikler, korelasyonu yüksek olandan az olana doğru sıralanmış olduğu için; istenilen sayıda özniteliğin optimal olacak şekilde seçilmesine izin vermektedir.

Çalışma sonrasında önerilen yöntem ile yüksek tanıma oranlarına ulaşıldığı gözlenmiştir. Özellikle güvenlik amaçlı kameralardan elde edilen görüntülerin düşük çözünürlüklü yüz imgelerine bu yöntemin başarı ile uygulanabileceği değerlendirilmektedir.

## KAYNAKÇA

- [1] W. Zou and P. Yuen, "Very low resolution facerecognition problem," in *Biometrics: Theory Applications and Systems (BTAS), 2010 Fourth IEEE International Conference on*, 2010, pp. 1–6.
- [2] Y. M. Lui, D. Bolme, B. Draper, J. Beveridge, G. Givens, and P. Phillips, "A meta-analysis of face recognition covariates," in *Biometrics: Theory, Applications, and Systems, 2009. BTAS '09. IEEE 3rd International Conference on*, 2009, pp. 1–8.
- [3] B. Li, H. Chang, S. Shan, and X. Chen, "Lowresolution face recognition via coupled locality preserving mappings," *Signal Processing Letters, IEEE*, vol. 17, no. 1, pp. 20–23, 2010.
- [4] W. T. Freeman and E. C. Pasztor, "Learning lowlevel vision," *International Journal of Computer Vision*, vol. 40, p. 2000, 2000.
- [5] M. Elad and A. Feuer, "Super-resolution reconstruction of image sequences," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 21, pp. 817–834, 1999.
- [6] P. Hennings-Yeomans, S. Baker, and B. Kumar, "Simultaneous super-resolution and feature extraction for recognition of low-resolution faces," in *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on*, 2008, pp. 1–8.
- [7] S. Biswas, E. Ortiz, and K. Bowyer, "Multidimensional scaling for matching low-resolution face images," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 34, no. 10, pp. 2019–2030, 2012.
- [8] J. Wright, A. Yang, A. Ganesh, S. Sastry, and Y. Ma, "Robust face recognition via sparse representation," *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 31, no. 2, pp. 210–227, 2009.
- [9] Y.-O. Li, T. Adali, W. Wang, and V. D. Calhoun, "Joint blind source separation by multiset canonical correlation analysis," *Trans. Sig. Proc.*, vol. 57, no. 10, pp. 3918–3929, Oct. 2009.
- [10] H. Hotelling, "Relations Between Two Sets of Variates," *Biometrika*, vol. 28, no. 3/4, pp. 321–377, 1936.
- [11] L. Sun, S. Ji, and J. Ye, "A least squares formulation for canonical correlation analysis," in *Proceedings of the 25th international conference on Machine learning*, ser. ICML '08. New York, NY, USA: ACM, 2008, pp. 1024–1031.
- [12] M. Borga, "Learning Multidimensional Signal Processing," *Linköping Studies in Science and Technology. Dissertations No. 531*, Linköping University, Sweden, 1998.
- [13] M. Turk and A. Pentland, "Eigenfaces for recognition," *J. Cognitive Neuroscience*, vol. 3, no. 1, pp. 71–86, Jan. 1991.
- [14] F. S. Samaria and A. C. Harter, "Parameterisation of a stochastic model for human face identification," in *Applications of Computer Vision, 1994., Proceedings of the Second IEEE Workshop on*, 1994, pp. 138–142.
- [15] A. Martinez and R. Benavente, "The ar face database," in *CVC Tech. Report #24*, 1998.