

얼굴인식을 위한 PCA, LDA 및 정합기법의 비교

(A Comparison of PCA, LDA, and Matching Methods for Face Recognition)

박 세 제 [†] 박 영 태 ⁺⁺

(Se-Je Park) (Young-Tae Park)

요약 얼굴 인식을 위한 주요 기법인 PCA, LDA 등과 같은 mapping에 의한 기법과 템플릿 정합 기법 모두 얼굴 영역의 회전, 이동, 표정, 그리고 조명조건의 변화에 민감한 특성을 가진다. 본 논문에서는, 영상의 변화를 보상할 수 있는 전처리 과정으로서 기하학적 특징에 기반한 순수 얼굴영역 검출기법을 도입하고 후처리 과정으로서 간단한 정합기법을 사용한 얼굴인식 기법을 제안한다. 제안한 기법은 PCA와 LDA 기법에 비해 영상의 변화에 민감하지 않고 높은 인식률을 보장할 수 있는 장점을 가진다.

키워드 : 얼굴인식, Mapping, Principal component analysis, 차원감소, 선형분별함수, 템플릿 정합

Abstract Limitations on the linear discriminant analysis (LDA) for face recognition, such as the loss of generalization and the computational infeasibility, are addressed and illustrated for a small number of samples. The principal component analysis (PCA) followed by the LDA mapping may be an alternative that can overcome these limitations. We also show that any schemes based on either mappings or template matching are vulnerable to image variations due to rotation, translation, facial expressions, or local illumination conditions. This entails the importance of a proper preprocessing that can compensate for such variations. A simple template matching, when combined with the geometrically correlated feature-based detection as a preprocessing, is shown to outperform mapping techniques in terms of both the accuracy and the robustness to image variations.

Key words : Face recognition, Mapping, Principal component analysis, Linear discriminant analysis, Template matching, Generalization, Computational infeasibility

1. 서 론

얼굴 인식을 위한 두가지 주요 기법으로서 1) 기하학적인 특징에 기반한 템플릿 정합, 2) PCA(principal component analysis) 나 LDA(linear discriminant analysis) 매핑과 같은 차원 감소에 의한 순수한 얼굴 영역 분류 등을 들 수 있다. PCA 기법은 클래스 정보를 사용하지 않고 특정공간에서의 데이터 분포의 특성을 유지하면서 영상의 차원을 줄이는데 목적을 둔다[1, 2, 3]. 따라서 PCA 기법은 인식을 위한 분류의 목적으로 사용하기에는 적합하지 않다. 반면에 LDA 기법은

클래스 정보를 사용하여 동일 부류에 속한 데이터는 서로 모이고 다른 부류에 속한 데이터는 되도록 분리가 잘 되도록 저 차원 공간으로 mapping 하는데 그 목적을 둔다[4, 5, 6, 7]. 대표적인 예로서 FLD (Fisher's linear discriminant) [3] 기법을 들 수 있다.

$m \times n$ 크기의 2차원 얼굴영역은 $m \cdot n$ 크기의 1차원 벡터로 표시된다. $m \cdot n$ 값이 작을 경우 유사 얼굴 형상에 대한 변별력이 낮아 지며, 그 경우 얼굴 영역의 회전, 이동, 표정, 그리고 조명조건의 변화에 따라 인식 특성이 민감하며 eigenface나 fisherface의 계산이 어려운 단점을 갖는다. 따라서 다양한 얼굴 영상의 변화에 민감하지 않으면서 영상의 고차원 데이터를 저차원의 특징벡터로 줄이기 위한 연구가 진행되어 왔다. LDA 기법을 영상에 직접 적용했을 때의 인식률이 PCA의 경우 보다 월등한 것으로 보고되었지만[6] 학습영상이 충분하지 않을 경우, 영상의 미세한 변화에 매우 민감하며

[†] 정 회 원 : 경희대학교 전자공학과
spark@kvision.khu.ac.kr

⁺⁺ 비 회 원 : 경희대학교 전자공학과 교수
ytpark@khu.ac.kr

논문접수 : 2002년 6월 25일
심사완료 : 2003년 2월 4일

fisherface의 계산이 어려운 단점도 갖는다. 즉, 매핑이나 템플리트 정합[8, 9] 모두 영상의 회전, 이동, 및 크기 변화에 매우 민감한 특성을 가진다. 따라서 신뢰도가 높은 얼굴인식 기법의 구현을 위해선 순수한 얼굴 영역의 위치를 정확히 추출하는 전처리 과정이 필수적 으로 요구된다.

본 논문에서는 얼굴인식 시스템을 구현함에 있어 매핑과 템플리트 정합에 의한 인식 특성을 비교하고, 기존의 기법을 보완할 수 있는 전처리 과정을 도입함으로써 상용화가 가능한 궁극적인 얼굴 인식 기법을 제안한다. 또한 PCA와 LDA 기법을 결합함으로써 높은 인식률을 유지하면서 고차원의 영상 데이터에서의 계산상의 어려움을 극복할 수 있음을 보인다. 얼굴 영역의 회전, 이동, 조명조건의 변화를 자동으로 보상할 수 있는 전처리 과정으로서 기하학적 특징에 기반한 순수 얼굴영역 검출 기법[10]을 적용한다. 전처리 과정에서 산출된 순수 얼굴 영역으로부터 대표적인 템플리트 영상을 산출하는 기법을 제시하고, 간단한 템플리트 정합에 의해 PCA나 LDA 기법에 비해 월등한 성능을 보장할 수 있는 얼굴 인식 알고리듬을 구현할 수 있음을 보인다.

2. PCA, LDA, PCA+LDA에 의한 mapping 기법

2.1 PCA

학습 영상의 집합을 $\Phi = [\Phi_1, \Phi_2, \dots, \Phi_N]$ 로 표기하고 각 영상으로부터 평균영상벡터 $\bar{\Phi}$ 를 뺀 영상의 집합을 $X = [x_1, x_2, \dots, x_N]$ 로 표기한다. scale factor $1/N$ 을 생략하면 covariance matrix는 다음과 같이 주어진다.

$$\sum_x = \sum_{i=1}^N x_i x_i^T = XX'$$
 (1)

\sum_x 의 eigenvalue 와 eigenvector 행렬 Λ 와 Ψ 는 다음과 같은 관계를 갖는다.

$$(XX')\Psi = \Psi\Lambda$$
 (2)

\sum_x 는 $(m \cdot n \times m \cdot n)$ 의 크기를 가지므로 학습 영상의 수가 적을 경우 계산이 어렵지만 다음과 같은 기법에 의해 이를 효율적으로 계산할 수 있다. 행렬 $X'X$ 의 eigenvalue 와 eigenvector matrix를 V 와 Λ' 라 하자.

$$(X'X)V = V\Lambda'$$
 (3)

식(3)의 양변에 X 를 곱하면 다음과 같다.

$$X(X'X)V = (XX')(XV) = (XV)\Lambda'$$
 (4)

식(4)와 식(2)를 비교하면, Λ' 와 XV 는 \sum_x 의 eigenvalue 와 eigenvector matrix 임을 알 수 있다. 따라서 $m \cdot n \times m \cdot n$ 의 eigenvalue matrix 를 $N \times N$ 의 저차원

의 공간에서 계산할 수 있다. 일반적으로 학습영상의 수는 영상의 크기보다 매우 작다.(즉, $N \ll m \cdot n$). eigenvalue의 크기가 큰 순으로 배열했을 때 p 개의 eigenvector로 구성된 matrix를 다음과 같이 구할 수 있다.

$$W_{PCA} = [X_{v_1}, X_{v_2}, \dots, X_{v_p}]$$
 (5)

$m \cdot n$ 크기의 영상벡터 x_i 는 p 차원의 새로운 벡터 y_i 로 다음 식에 의해 재 구성된다.

$$y_i = W_{PCA}^T x_i$$
 (6)

2.2 LDA

FLD 기법에서 within-class matrix와 between-class matrix는 다음과 같이 계산된다.

$$S_w = \sum_{i=0}^N \Pr(C_i)E[(V_i - \mu_i)(V_i - \mu_i)^T],$$
 (7)

$$S_b = \sum_{i=0}^N \Pr(C_i)(\mu - \mu_i)(\mu - \mu_i)^T,$$
 (8)

μ 는 전체 평균벡터를, μ_i 는 i 번째 클래스의 평균벡터를 나타낸다. $\Pr(C_i)$ 은 클래스 C_i 의 원시확률(a priori probability)을 의미한다. FLD 기법에서는 $|W^T S_b W| / |W^T S_w W|$ 를 최대로하는 프로젝션 matrix W 를 사용한다. 이는 eigenvalue 문제로서 다음식에 의해 구할수있다.

$$S_b \mu_i = \lambda_i S_w \mu_i,$$
 (9)

eigenvalue의 크기가 큰 순으로 배열했을 때 q 개의 eigenvector로 구성된 matrix를 다음과 같이 구할 수 있다.

$$W_{LDA} = [\mu_1, \mu_2, \dots, \mu_q]$$
 (10)

$m \cdot n$ 크기의 영상벡터 x_i 는 q 차원의 새로운 벡터 z_i 로 다음 식에 의해 재 구성된다.

$$z_i = W_{LDA}^T x_i$$
 (11)

2.3 PCA+LDA

LDA 기법에 의해 고차원의 데이터를 저 차원 공간에서 클래스 별로 모이도록 할 수 있지만, 얼굴인식의 분야에 직접 적용할 경우 다음과 같은 문제점을 갖는다. 첫째, 패턴인식 시스템의 분류 바이어스(classification bias)가 필연적으로 커진다. 즉, FLD 계산에 사용되지 않은 테스트 데이터가 반드시 학습데이터와 유사하게 저 차원 공간에서 모이지는 않는다. 둘째, 학습 영상의 수가 적을 경우 식(9)의 eigenvalue와 eigenvector를 계산하는 알고리듬이 수렴하지 않는다. 이와 같은 문제점을 극복하기 위해 PCA 와 LDA를 결합한 PCA+LDA 기법을 다음과 같이 적용할 수 있다. $m \cdot n$ 크기의 영상 벡터 x_i 는 PCA에 의해 p 차원의 벡터로 투영되고, 다시 LDA에 의해 q 차원의 새로운 벡터 z_i 로 다음 식에 의해 재 구성된다.

$$\tau_i = W_{LDA}^t W_{PCA}^t x_i \quad (12)$$

2.4 분류기법 (classification)

클래스의 개수를 N_c 라 하면 식(9)에서 0이 아닌 eigenvalue는 최대 $N_c - 1$ 개 존재한다. 따라서 $N_c - 1$ 개의 특징량으로 구성된 특징벡터에 대해 간단한 nearest neighbor rule을 사용하여 특징벡터를 분류한다. i번째 특징벡터를 $F_i = ((f_{i1}, f_{i2}, \dots, f_{i, N_c-1})^T)^T$ 로 표기하고 각각의 특징량을 정규화한 특징벡터는 $\bar{F}_i = (f_{ij} - \mu_j)/\sigma_j$, (13)로 구성된다. μ_j 와 σ_j 는 각각 j번째 특징량의 평균과 표준 편차를 나타낸다. 클래스 별로 계산된 클러스터 센터를 $\{\eta_1, \eta_2, \dots, \eta_{N_c}\}$ 로, 식 (13)에 의해 계산된 입력 특징벡터를 \bar{F} 로 표기하면 입력 얼굴영상은 다음과 같이 분류된다.

$$\text{classification} = \arg \min_k \| \bar{F} - \eta_k \|, \quad (14)$$

3. 템플리트 정합기법

기하학적 특징에 기반한 순수 얼굴영역 검출기법[10]에 의해 회전과 이동 변화를 보상한 얼굴 영역을 산출할 수 있으므로 간단한 템플리트 정합으로도 높은 정확도를 보장할 수 있는 얼굴 인식기법을 구현할 수 있다. 얼굴 표정의 다양함을 고려하여 템플리트 영상의 자동 생성기법을 다음과 같이 제안한다. k번째 클래스에 속한 학습영상의 집합을 $I^k = \{I_1^k, I_2^k, \dots, I_n^k\}$ 로 표기한다.

템플리트 생성기법:

- Step 1: $m=1$ (m 은 템플리트 개수를 의미한다.)
 - Step 2: 모든 화소의 좌표 (x, y) 에 대해 화소값들 $\{I_1^k(x, y), I_2^k(x, y), \dots, I_n^k(x, y)\}$ 의 median 값을 산출하여 m 번째 템플리트 영상 T_m 을 생성한다.
 - Step 3: T_m 과 각 영상 I^k 의 거리(distance)를 다음과 같이 계산한다.
- $$\delta_i = \frac{1}{N_\Delta} \min_\Delta \sum_{(x, y)} |T_m(x, y) - I_i(x, y + \Delta)|, \quad (15)$$
- 여기서 N_Δ 는 T_m 과 I_i 영상에서의 중첩된 영역에 속한 화소수를 의미한다.
- Step 4: 템플리트 영상의 생성에 참여한 모든 영상의 δ 값이 Q 보다 작다면 템플리트 생성과정을 마친다.
 - Step 5: 일부 영상의 δ 값이 Q 보다 작다면, 이를 영상의 다음 단계의 템플리트 생성과정에서 m 을 증가시키고 Step 2의 과정을 되풀이한다.
 - Step 6: δ 값이 Q 보다 작은 영상이 존재하지 않을 경우, δ 값이 가장 큰 영상으로 T_m 을 대체한다. m 을 증가시키고 Step 2의 과정을 되풀이한다.

얼굴영상의 표정 변화에 따른 템플리트의 자동 생성을 위해 step 2에서는 median을 사용하였다. 식(15)에서는 수직 좌표축의 변화의 가능성을 고려하여 δ_i 의 계산과정에서 수직축으로 일정 구간만큼 이동시키면서 최소의 δ_i 값을 계산한다. 또한 Q 값이 작을수록 템플리트 개수가 증가한다. 적절한 Q 값은 전체 얼굴영상의 표정 변화와 유사도에 의해 결정되므로 이론적인 최적치를 설정하기 매우 어렵다. 실험적으로 40을 사용하였다. 템플리트 영상의 생성후, 입력영상은 거리 δ 가 가장 작은 클래스로 분류된다.

4. 실험결과 및 고찰

4.1 영상 데이터베이스와 전처리 과정

실험에서는 AR-face 데이터베이스[11]를 사용하였다. 이 데이터베이스는 126명의 인물에 대한 정면 영상으로 3200개 이상의 영상으로 구성되어있다. 2주의 기간을 두고 2개의 세션으로 기록되었고, 각 세션은 13개의 영상들로 구성되었다. 다양한 조명 조건에서 자연스럽고, 웃고, 화내고, 분노하고, 선글라스와 스카프를 착용한 다양한 얼굴 표정을 가진 얼굴 영상들이 데이터베이스에 포함되어 있다. 기하학적 특징에 기반한 순수 얼굴영역 검출기법을 적용하여 각 영상으로부터 회전과 이동 변화가 보상된 순수 얼굴 영역을 추출하였다. 그림 1에 그 예를 보인다. 조명 변화를 보상하기 위해 DC-notch filter를 사용하였다. 얼굴영역 검출기법에 관한 자세한 내용은 [10]에서 다룬다.

4.2 저해상도 영상에서의 실험결과(16x16)

각 클래스마다 10개의 순수 얼굴영상을 추출하여 16x16 (혹은 30x30) 크기로 정규화 하고 각 영상은 256 (혹은 900) 크기의 1차원 벡터로 변환하였다. 에러율을 측정하기 위해 leave-one-out 기법을 사용하였다. 즉, 각 클래스 별로 1개의 영상을 제외하고 나머지 9개의 영상을 학습데이터로 사용하고 제외된 1개의 영상을 분류하여 전체 에러율을 측정하였다. 10명의 인물 데이터에 대해 식(11)에 의해 FLD 공간으로 mapping하고 첫 번째와 두 번째의 principal axis로 투영한 결과를 그림 2(a)에 보인다. 학습 영상과 테스트 영상을 구별하기 위해 테스트 영상을 둘러 쌓인 사각형으로 표현하였다. 학습 영상들은 모두 소속된 클래스에 따라 거의 동일한 점으로 투영되었지만 테스트 영상의 위치는 소속된 클래스로부터 상당히 멀리 떨어져 분포하며 에러율이 점점으로 높아 진다. 이는 영상 데이터의 차원에 비해 너무 적은 수의 영상을 학습과정에 사용했기 때문이다. 이 경우 영상의 미세한 변화도 FLD 공간에서 부정확하

게 증폭될 수 있음을 의미한다.

반면에 PCA 기법에서는 클래스 정보를 사용하지 않으므로 학습 영상의 수가 상대적으로 많은 효과를 가진다. 따라서 PCA에 의해 차원을 줄인 후 LDA 기법을 적용할 경우 위에서 언급한 LDA의 단점을 극복할 수 있다. PCA+LDA 기법에 의해 투영된 예를 그림 3에 보인다. 군집화 특성은 LDA 보다 못 하지만 테스트 영상의 위치는 소속 클래스의 위치에 가까이 분포함을 알 수 있다. 그림 3(a)에서 일부 데이터는 인접한 클래스와 중첩이 되어 보이지만 세번째, 네번째 축으로 투영한 그림 3(b)에서는 뚜렷이 분리됨을 알 수 있다. (\vee 와, 혹은 \checkmark 와 +의 경우)

표 1과 그림 4에서 제시한 바와 같이 클래스의 수 N_c 가 증가할수록 많은 영상이 학습과정에서 사용되므로 LDA 기법에서의 인식률이 향상된다. PCA+LDA 기법에서는 N_c 에 무관하게 높은 인식률을 보인다. 따라서 LDA에 비해 우수한 인식 성능을 가진다. 템플리트 정합은 PCA+LDA 기법과 거의 유사한 인식 성능을 보인다. 이는 전처리 과정에서 얼굴영상의 변화가 전처리 과정에서 이미 정확히 보상되었기 때문이다. Data set 2에 대한 템플리트 영상을 그림 5에 보인다.

4.3 고해상도 영상에서의 실험결과(30x30)

PCA+LDA 기법과 템플리트 정합의 성능을 비교하기 위해 leave-one-out 방식과 hold-out 방식을 사용해 에러율을 측정하였고 그 결과를 표 2와 그림 6에 보인다. 두 가지 에러 측정 방식에서 모두 템플리트 정합의 성능이 월등함을 알 수 있다. leave-one-out 방식에서는 100%의 정인식률을 보이며 특히 적은 수의 학습 영상을 사용한 hold out 방식에서도 클래스의 수에 무관하게 매우 높은 인식률(98% 이상)을 얻을 수 있었다. 이와 같이 고해상도 영상에서의 성능이 월등한 이유는 그림 7에 보인 바와 같이 템플리트 영상의 해상도가 높아 유사한 클래스 영상에서의 변별력이 높기 때문이다. 이와 같은 템플리트 정합의 우월성은 ARENA [12] 알고리듬에서도 보고되었다.

4.4 영상의 변화에 따른 실험결과

회전, 이동변화에 따른 인식 알고리듬의 강건성을 유추하기 위해, 전처리 과정에서 회전, 이동변화의 보상 가능을 제거하여 실험하였다. Data set 10에 대한 실험 결과를 그림 8에 제시한다. leave-one-out 방식의 에러율에서 PCA+LDA 기법은 3.2%에서 5%로, 템플리트 정합은 1.8%에서 2%로 증가했다. hold-out 방식의 에러율에서 PCA+LDA 기법은 3.2%에서 5%로, 템플리트 정합은 1.8%에서 2%로 증가했다. 따라서 고 정확도의 얼굴인식 기법을 구현하기 위해서는 영상의 미세한 변화를 보상

할 수 있는 전처리 과정의 선택이 필수적이다.

영상의 회전에 따른 효과를 명확히 보이기 위해 Data set 3에 속한 샘플 영상 1개를 선택하여 3°에서 15°까지 3° 간격으로 회전하고 학습된 PCA+LDA 공간에 투영하였다. 그림 9에 보인 바와 같이 투영된 점들은 소속된 클래스로부터 상당히 이탈되어 나타난다. 이는 mapping 기법에서의 인식 성능이 영상의 미세한 회전에도 매우 민감함을 의미한다.

4.5 FRR/FAR 특성비교

FRR(False Rejection Rate)와 FAR(False Acceptance Rate)에 관한 특성 비교를 위해 얼굴영상의 클래스를 75개로 늘려 실험하였다. matching 기법에서는 leave-one-out 측정기법을 사용할 경우 클래스 개수에 무관하게 0에 가까운 FRR과 FAR 특성을 보인다. 따라서 의미 있는 비교를 위해 hold-out 기법을 사용하여 (즉, 각 클래스마다 5개의 학습영상과 5개의 테스트 영상을 사용할 경우), 템플리트 정합과 PCA+LDA 기법의 FRR/FAR 특성을 비교하였다. 템플리트 정합과 PCA+LDA 기법에서 정인식, 오인식된 얼굴영상의 cluster distance 분포를 그림 10 (a)와 (b)에 보인다. 각각의 에러율은 3.7%, 10.7%로서 템플리트 정합의 성능이 월등함을 알 수 있다. cluster distance의 문턱치를 사용함으로써 입력영상과 학습영상의 유사도가 크지 않을 경우 거부 기능을 구현할 수 있다. 문턱치에 따른 FRR과 FAR의 변화를 그림 11에 보인다. 개인인증을 위한 목적으로 사용할 경우 0에 가까운 FAR 특성이 요구된다. 템플리트 정합에서는 FRR=13.1%, PCA+LDA에서는 FRR=26.9%에서 FAR=0의 특성을 보인다. 또한 동일한 FRR에서, 템플리트 정합의 FAR가 훨씬 낮다. 예를 들어 FRR=5.9%일 때 템플리트 정합과 PCA+LDA의 FAR은 각각 0.8%, 6.1%의 실험결과를 보인다. 따라서 FRR/FAR 특성 역시 템플리트 정합기법의 성능이 월등함을 실험을 통하여 확인하였다.

4. 결 론

얼굴 인식기법에서 널리 사용되어 온 PCA, LDA 등의 mapping 기법과 템플리트 정합 기법 모두 학습 영상의 수가 적을 경우, 얼굴 영역의 미세한 회전과 이동 변화에 민감하게 반응하여 높은 인식률을 유지하기 어려움을 실험을 통해 확인하였다. 특히 LDA 기법을 직접 영상에 적용하면 분류 바이어스(classification bias)가 커지고 학습 영상의 수가 적을 경우 fisherface의 계산이 불가능한 단점을 가진다. PCA+LDA는 이러한 문제점을 극복할 수 있는 기법이다. 기하학적 특징에 기반한

순수 얼굴영역 검출기법과 같이 회전 및 이동 변화를 보상할 수 있는 강건한 전처리 과정을 도입할 경우, 본 논문에서 제안한 간단한 템플리트 정합기법이 mapping에 의한 기법에 비해 월등한 성능을 가짐을 확인하였다. 또한 템플리트 정합기법은 클래스의 수가 증가할 경우 새로운 클래스의 템플리트 영상만을 추가함으로써 새로운 인식 시스템을 구성할 수 있는 장점을 가진다. 따라서 본 논문에서 제안한 기법은 높은 인식률을 보장할 수 있는 궁극적인 얼굴 인식기법으로 활용될 수 있다.

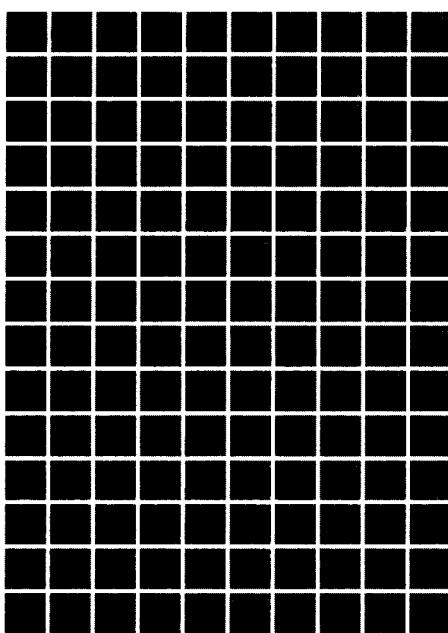


그림 1 검출된 순수 얼굴영역의 예

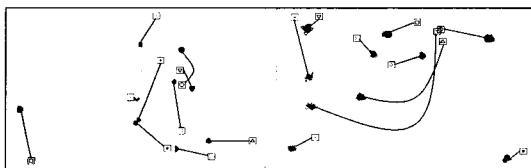


그림 2 FLD 공간에서의 데이터 분포 (data set 3)



(a)

(b)

그림 3 PCA+LDA 공간에서의 데이터 분포 (data set3)

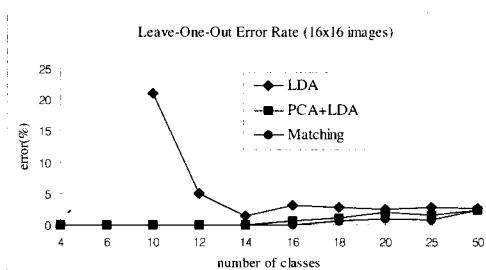


그림 4 Leave-One-Out 에러율 (16×16 영상)



그림 5 템플리트 영상의 예 (16×16)

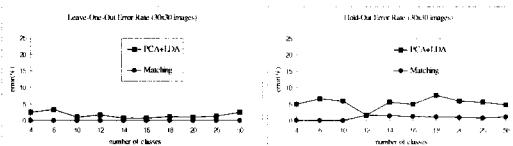


그림 6 Leave-One-Out 에러율과 Hold-Out 에러율



그림 7 템플리트 영상의 예(30×30)

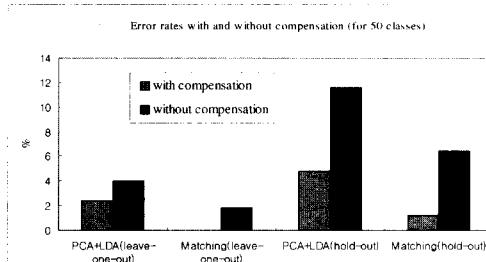


그림 8 PCA+LDA와 템플리트 정합의 에러율 비교

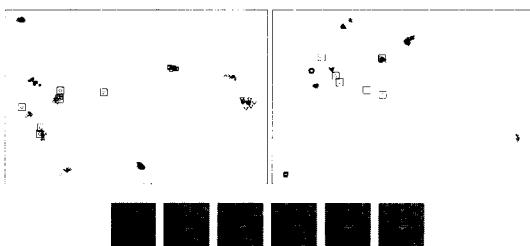


그림 9 회전된 얼굴여상에 대한 PCA+LDA 공간에서의 데이터 분포



그림 10 Nearest cluster와의 거리 분포(75 classes, hold-out 기법)

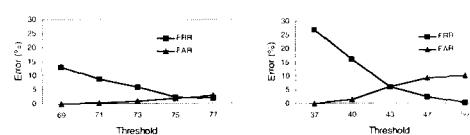


그림 11 Threshold에 따른 FRR과 FAR (75 classes, hold-out 기법)

표 1 LDA, PCA+LDA, 템플릿 정합의 Leave One Out 예러율(16×16영상)

Data Set				LDA	PCA+LDA	Template Matching	
1	4	40	3		0 (0%)	0 (0%)	5
2	6	60	5		0 (0%)	0 (0%)	7
3	10	100	9	21 (21.0%)	0 (0%)	0 (0%)	12
5	14	140	13	2 (1.4%)	0 (0%)	0 (0%)	16
6	16	160	15	5 (3.13%)	1 (0.63%)	0 (0%)	19
7	18	180	17	5 (2.78%)	2 (1.11%)	1 (0.56%)	21
8	20	200	19	5 (2.5%)	4 (2%)	2 (1%)	26
9	25	250	24	7 (2.8%)	4 (1.6%)	2 (0.8%)	35
10	50	500	49	13 (2.6%)	12 (2.4%)	12 (2.4%)	97

표 2 PCA+LDA, 템플릿 정합의 예러율(30×30 영상)

Data Set	Leave One Out Error Rate (%)		Hold Out Error Rate (%)	
	PCA+LDA	Template Matching	PCA+LDA	Template Matching
1	2.5	0	5	0
2	3.3	0	6.67	0
3	1	0	6	0
4	1.67	0	1.67	1.67
5	0.71	0	5.71	1.43
6	0.63	0	5	1.25
7	1.11	0	7.78	1.11
9	1.36	0	5.6	0.8
10	2.4	0	4.8	1.2

참고문헌

- [1] M. A. Turk, A. P. Pentland, Face recognition using eigenfaces, Int. Conf. on Pattern Recognition, (1991) 586-591.
- [2] M. Kirby and L. Sirovich, "Application of the Karhunen-Loeve procedure for the characterization of human faces," IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 12, (1990) 103-108.
- [3] R.O. Duda, P.E. Hart, D.G. Stork, Pattern Classification, 2nd Edition, John Wiley & Sons, (2001).
- [4] P. N. Belhumeur, J. P. Hespanha, D. J. Kriegman, Eigenfaces vs. fisherfaces: recognition using class specific linear projection, IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 19, (1997) 711-720.
- [5] A. M. Martinez, A. C. Kak, PCA versus LDA IEEE Trans. IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 23, (2001) 228-233.
- [6] K. Etemad, R. Chellappa, Discriminant analysis for recognition of human face images, J. Opt. Soc. Amer. Vol. 14, No. 8, (1997) 1724-1733.
- [7] C. Liu, H. Wechsler, Enhanced Fisher Linear Discriminant Models for Face Recognition, 14th Int'l Conf. on Pattern Recognition, ICPR'98, Brisbane, Australia, August (1998) 17-20.
- [8] R. Brunelli, T. Poggio, Face recognition: Features versus templates, IEEE Transaction on Pattern Analysis and Machine Intelligence, Vol. 15, (1983) 1042-1052.
- [9] R. Brunelli, T. Poggio, Face recognition through geometrical features, Computer Vision, ECCV '92, Lecture Notes in Computer Science, (1992) 792-800.
- [10] 이대호, 박영태, 기하학적 특징에 기반한 순수 얼굴영역 검출기법, 한국정보과학회 논문집 (2003).
- [11] A.M. Martinez, R. Benavente, "The AR Face Database," CVC Technical Report #24, June (1998).
- [12] T. Sim, R. Sukthankar, M. D. Mullin, S. Baluja, High-performance memory-based recognition for visitor identification, Tech. Report JPRC-TR-1999-001-1, Just Research, (1999).
- [13] V. Brennan, J. Principe, Face classification using a multiresolution principal component analysis, Neural Networks for Signal Processing VIII, Proceedings of the 1998 IEEE Signal Processing Society Workshop, (1998) 506-515.
- [14] S. H. Lin, S. Y. Kung, L. J. Lin, Face recognition/detection by probabilistic decision-based neural network, IEEE Transactions on Neural Networks, Vol. 8, No. 1, (1997) 114-132.
- [15] B. Moghaddam, W. Wahid, A. Pentland, Beyond Eigenfaces: Probabilistic Matching for Face

- Recognition", Proc. of Int'l Conf. on Automatic Face and Gesture Recognition, (1998) 30-35.
- [16] A. Pentland, B. Moghaddam, T. Starner, View-based and Modular Eigenspaces for Face Recognition, Proc. of IEEE Conf. on Computer-Vision and Pattern Recognition (CVPR'94), (1994) 84-91.



박 세 재

1996년 2월 경희대학교 전자공학과(학사),
1998년 2월 경희대학교 대학원 전자공학
과(석사), 현재 동 대학원 박사과정 중, 주
관심분야는 컴퓨터 비전, 패턴인식 등



박 영 태

1979년 2월 서울대학교 전자공학과(학사),
1981년 8월 한국 과학기술원전기 및 전자
공학과(석사), 1989년 12월 University of
California, Irvine 전기 및 컴퓨터공학과
(Ph.D.), 1990년 1월~1990년 7월 Uni-
versity of California, Irvine(Post Doc.),
1990년 7월~1991년 2월 Innovision Medical Inc., 1991년 6
월~1992년 1월 대우통신 중앙연구소, 1992년 3월~현재 경
희대학교 전자정보학부(교수).주 관심 분야는 컴퓨터 비전, 패
턴인식, ITS, 신경회로망 학습이론 등