

퍼지 소속도를 갖는 Fisherface 방법을 이용한 얼굴인식

(Face Recognition using Fisherface Method with Fuzzy Membership Degree)

곽근창^{*} 고현주^{**} 전명근^{***}

(Keun-Chang Kwak) (Hyoun-Joo Go) (Myung-Geun Chun)

요약 본 논문에서는 퍼지논리에 기초한 Fisherface 얼굴인식 방법의 확장을 다룬다. Fisherface 얼굴인식 방법은 주성분 분석 기법만을 이용하는 경우에 비해 조명의 방향, 얼굴의 포즈, 감정과 같은 변동에 대해 민감하지 않은 장점을 가지고 있다. 그러나, Fisherface 방법을 포함한 얼굴인식의 다양한 방법들은 입력 벡터가 한 클래스에 할당되어질 때 그 클래스에서 소속의 정도를 0 또는 1로서 나타낸다. 따라서 이러한 방법들은 얼굴영상들이 조명이나 보는 각도로 인해 변형이 생기는 경우에 인식률이 저하되는 문제가 있다. 본 논문에서는 PCA에 의해 변환된 특징벡터에 퍼지 소속도를 할당하는 것으로, 퍼지 소속도는 퍼지 kNN(k-Nearest Neighbor)으로부터 얻어진다. 실험 결과 ORL, Yale 얼굴 데이터베이스에서 기존의 인식방법 보다 향상된 인식 성능을 보임을 알 수 있었다.

키워드 : 얼굴인식, 고유얼굴, 주성분 분석기법, 선형판별분석, 퍼지 KNN

Abstract In this study, we deal with face recognition using fuzzy-based Fisherface method. The well-known Fisherface method is more insensitive to large variation in light direction, face pose, and facial expression than Principal Component Analysis method. Usually, the various methods of face recognition including Fisherface method give equal importance in determining the face to be recognized, regardless of typicalness. The main point here is that the proposed method assigns a feature vector transformed by PCA to fuzzy membership rather than assigning the vector to particular class. In this method, fuzzy membership degrees are obtained from FKNN(Fuzzy K-Nearest Neighbor) initialization. Experimental results show better recognition performance than other methods for ORL and Yale face databases.

Key words : face recognition, eigenface, Fisherface, PCA, LDA, K-NN

1. 서 론

오늘날 우리는 급속도로 발전하는 정보화사회에 살고 있다. 이러한 정보화사회는 정보의 생성, 저장, 처리, 운반, 검색 기능이 상호 연결된 통신망 환경하에서 다양한 형태의 정보 서비스를 제공하고 있다. 그러나 인가 받지 않은 불법 사용자로 인한 정보시스템의 파괴, 개인 신상

의 누설 및 유출, 불건전 정보의 유통 등과 같은 정보화의 역기능으로 인해 고통 받고 있다. 이에, 기존의 단순한 형태의 개인확인 및 검증방법의 한계를 극복하기 위해, 새로운 형태의 신분검증 방법에 대한 연구가 한창 진행중이다.

바이오메트릭스(Biometrics)는 개인의 신원확인 혹은 인증을 위해 생리학적이거나 행동학적인 특징들을 획득하여 연구하는 분야이다. 바이오메트릭스 가운데 얼굴인식은 자연스러우면서도 직접적인 생체인식 방법이며, 컴퓨터 비전, 영상처리, 패턴인식과 같은 다양한 분야에서 연구되어지고 있다. 그러나, 얼굴인식은 조명의 방향, 얼굴의 포즈, 얼굴 감정과 같은 큰 변동에 의해 매우 어려운 문제점을 가지고 있다. 얼굴 인식을 위해 가장 잘 알려진 방법들은 eigenface와 Fisherface 방법이다. eigen-

* 본 연구는 한국과학재단 목적기초연구(R01-2002-000-00315-0) 지원으로 수행되었음

† 비회원 : University of Alberta, Post-doc
kckwak_2000@yahoo.co.kr

** 학생회원 : 충북대학교 제어계측공학과
ghjswy@hanmail.net

*** 비회원 : 충북대학교 전기전자컴퓨터공학부 교수
mgchun@chungbuk.ac.kr

논문접수 : 2003년 7월 24일

심사완료 : 2004년 3월 5일

face 방법은 주성분 분석기법(Principal Component Analysis)에 의해 변환된 특징벡터를 이용한다. 이 방법은 얼굴영상 공간을 저차원의 특징공간으로 선형적으로 투영하는 것을 기초로 하고 있다. 얼굴인식을 위한 eigenface 방법의 주된 문제점은 주성분 분석 기법이 조명이나 얼굴감정으로 인해 원하지 않는 변동을 보유하기 때문에 저차원으로의 차원축소에는 최적의 방법이지만 분류에 있어서는 그렇지 않다[1-2]. 이러한 eigenface 방법의 확장된 접근 방법이 많이 제시되었다[3-6]. 한편, Fisherface 방법은 주성분 분석 기법과 선형판별 분석법(Linear Discriminant Analysis)을 이용하며, 조명 방향이나 얼굴 포즈 및 감정과 같은 큰 변화에도 민감하지 않은 장점을 가지고 있다. 여기서 선형판별 분석법은 클래스간 분산 행렬(Between-Class Scatter Matrix)과 클래스내 분산 행렬(Within-Class Scatter Matrix)의 비가 최대화하는 통계적 방법으로, 선형판별 분석법과 관련된 다양한 얼굴인식 방법들이 있다[7-10]. 이러한 접근 이외에도 신경회로망[11-12], 유전 알고리즘[13]에 근거한 얼굴인식 연구가 진행되고 있다.

그러나, 위와 같은 다양한 얼굴인식 방법들은 입력 벡터가 한 클래스에 할당되어질 때 그 클래스에서 소속의 정도를 0 또는 1로서 나타낸다. 이러한 방법들은 얼굴영상들이 조명이나 보는 각도로 인해 변형이 생기는 곳에서 인식의 어려움을 보이고 있다. 그러므로, 우리는 퍼지 집합의 이론과 결합되어진 퍼지 Fisherface 방법을 제안하고 이를 얼굴인식에 적용한다.

본 논문의 구성은 다음과 같다. 2절에서 퍼지 집합의 이론과 제안된 퍼지 기반 Fisherface 방법을 설명하고, 3절에서는 각각 ORL[16], Yale[17] 얼굴 데이터 베이스에 제안된 방법을 이용함으로서 얻어진 실험 결과를 나타낸다. 마지막으로 결론은 5절에서 기술되어진다.

2. 퍼지 Fisherface를 이용한 얼굴인식 방법

주성분 분석 기법(PCA)은 다변수 선형 데이터 분석에서 잘 알려진 기법이며 주된 개념은 데이터의 최대 분산 방향을 나타내는 상호직교 기저 벡터의 집합을 찾는 것을 목적으로 하며, 이때, PCA를 이용한 eigenface 방법은 다음과 같이 간략히 기술되어진다. 하나의 얼굴 영상이 각각의 화소 값을 갖는 2차원 배열($n \times n$)이라고 가정하자. 영상 \mathbf{z}_i 는 연속적인 행들의 연결로 $n^2 \times 1$ 의 벡터로서 고려되어진다. 그러면 N 개 얼굴영상의 학습 집합은 $\mathbf{Z} = (\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_N)$ 로 표시된다. 공분산 행렬을 정의하면 다음과 같다.

$$\mathbf{R} = \frac{1}{N} \sum_{i=1}^N (\mathbf{z}_i - \bar{\mathbf{z}})(\mathbf{z}_i - \bar{\mathbf{z}})^T = \mathbf{\Phi}\mathbf{\Phi}^T \quad (1)$$

$$\bar{\mathbf{z}} = \frac{1}{N} \sum_{i=1}^N \mathbf{z}_i \quad (2)$$

그러면, 공분산 행렬의 고유치와 고유벡터가 계산되어진다. 여기서 r 개의 가장 큰 고유치에 대응하는 r 개의 고유 벡터를 $\mathbf{E} = (\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_r)$ 라 하자. 얼굴영상의 집합 Z 에 대해서, 그것들의 대응되는 특징벡터 $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)$ 는 다음과 같이 Z 를 PCA-변환된 공간으로 투영함으로서 얻어진다.

$$\mathbf{x}_i = \mathbf{E}^T (\mathbf{z}_i - \bar{\mathbf{z}}) \quad (3)$$

여기서 \mathbf{x}_i 는 i 번째 $r \times 1$ 벡터이다. 얼굴인식을 위한 거리 측정은 식 (4)와 같이 유clidean 거리를 사용한다. 이 거리 측정은 학습 집합의 영상들과 테스트 집합의 주어진 영상 사이에서 정의된다. 학습 영상 \mathbf{z} 와 주어진 테스트 영상 \mathbf{z}' 사이의 거리 측정 $\epsilon(\mathbf{z}, \mathbf{z}')$ 은 다음과 같은 PCA에 의해 변환된 공간에서 정의된다.

$$\epsilon(\mathbf{z}, \mathbf{z}') = \| \mathbf{x} - \mathbf{x}' \| \quad (4)$$

여기서 \mathbf{x} 와 \mathbf{x}' 는 각각 얼굴 영상 \mathbf{z} 와 \mathbf{z}' 의 PCA-변환된 특징 벡터이다. 이러한, 주성분 분석 기법은 차원 축소에는 최적의 방법이 될 수 있으나, 변환된 특징 벡터들이 특정공간에서 서로 겹치는 현상으로 인해 데이터 분류에는 어려운 점이 있으며, 조명이나 보는 각도, 얼굴감정과 같은 원하지 않는 변동을 보유하는 문제점을 가지고 있다.

선형판별분석법은 분류를 위해 최적의 투영을 찾는 방법 중의 하나로, 투영된 분산을 최대화하는 투영을 찾기보다는 클래스간 분산(Between-Class Scatter Matrix) 행렬과 클래스내 분산(Within-Class Scatter Matrix) 행렬의 비가 최대가 되는 최적의 투영 행렬을 찾는 것이다. 또한, 분류는 투영된 공간에서 간소화되어지며, 최적 투영행렬 \mathbf{W}_{FLD} 를 계산하기 전에 클래스내 분산 행렬이 정칙이 되도록 주성분 분석 기법을 이용하여 영상공간을 저차원 공간으로 투영함으로서 수행할 수 있다. 주성분 분석 기법과 선형판별분석법을 이용한 Fisherface 방법은 다음과 같이 서술되어진다. N 개의 벡터를 갖는 c 개의 클래스(얼굴인식인 경우 사람의 수) 문제를 고려할 때, 클래스간 분산 행렬은 다음 식과 같이 정의된다.

$$\mathbf{S}_B = \sum_{i=1}^c N_i (\mathbf{m}_i - \bar{\mathbf{m}})(\mathbf{m}_i - \bar{\mathbf{m}})^T \quad (5)$$

여기서, N_i 는 i 번째 클래스 C_i 에서의 벡터의 수이며, $\bar{\mathbf{m}}$ 은 모든 벡터들의 평균이다. 또한 \mathbf{m}_i 는 클래스 C_i 에서 PCA에 의해 변환된 벡터의 평균이다.

클래스내 분산 행렬은 다음 식과 같이 정의되어진다.

$$S_w = \sum_{i=1}^c \sum_{x_k \in C_i} (x_k - m_i)(x_k - m_i)^T = \sum_{i=1}^c S_{w_i} \quad (6)$$

여기서, S_{w_i} 는 클래스 C_i 의 공분산 행렬이다. 최적의 투영 행렬 W_{FLD} 는 다음 식과 같이 투영된 샘플의 클래스내 분산 행렬에 대한 클래스간 분산 행렬의 행렬식의 비를 최대화하는 정규직교 행들을 가진 행렬로서 선택되어진다.

$$W_{FLD} = \arg \max_w \frac{|W^T S_B W|}{|W^T S_w W|} = [w_1 \ w_2 \ \dots \ w_m] \quad (7)$$

여기서, w_i 는 다음 식과 같이 가장 큰 $c-1$ 개의 일반화된 고유치에 대응하는 일반화된 고유벡터의 합이다.

$$S_B w_i = \lambda_i S_w w_i, \quad i=1, 2, \dots, m \quad (8)$$

그러나, S_B 의 rank가 $c-1$ 개의 영이 아닌 일반화된 고유값을 가지므로 m 의 한계 값은 $c-1$ 개다. 유사하게

S_w 의 rank도 $N-c$ 이다. N 이 n^2 보다 보통 더 작은 얼굴 영상의 합집합에 대해서, 클래스내 분산 행렬 S_w 은 항상 비정칙이다. 이것은 투영 행렬이 적당히 선택되지 않는다면, 투영된 클래스내 분산 행렬은 영이 될 수 있다. 이러한 문제는 주성분 분석 기법을 이용함으로서 저차원 공간으로 영상 합집합을 투영함으로서 해결할 수 있다. 어떤 얼굴 영상 x_i 에 대한 특징 벡터들 $V = (v_1, v_2, \dots, v_N)$ 은 다음 식과 같이 계산되어질 수 있다.

$$v_i = W_{FLD}^T x_i = W_{FLD}^T E^T (x_i - \bar{z}) \quad (9)$$

이와 같은 결과를 주성분 분석 기법 투영과 비교할 때, 주성분 분석 기법은 투영된 공간에서 선형적으로 분리하기 어렵지만, 선형판별분석법은 데이터 분류를 위한 최적의 투영임을 확인할 수 있으며, 특징 벡터는 입력 벡터가 한 클래스에 할당되어질 때 그 클래스에서 소속의 정도를 0 또는 1로서 나타낸다.

퍼지 합집합은 소속함수 $\mu: U \rightarrow [0, 1]$ 에 대한 특성함수의 개념을 일반화함으로서 유도되어진다[14,15]. 주성분 분석기법에 의해 변환된 특징벡터의 합집합 $X = (x_1, x_2, \dots, x_N)$ 이 주어질 때 이 벡터들의 퍼지 분할 행렬은 c 클래스에서 각 벡터의 소속도로서 특성화되며, $c \times N$ 의 행렬 U 로 표현한다. 여기서 $\mu_{ij} = \mu_i(x_j)$, $i=1, 2, \dots, c$, $j=1, 2, \dots, N$ 는 클래스 i 에서 x_j 의 소속도이다. 퍼지 분할 행렬 U 은 다음과 같은 식들을 만족해야 한다[15].

$$\sum_{i=1}^c \mu_{ij} = 1 \quad (10)$$

$$0 < \sum_{i=1}^c \mu_{ij} < N \quad (11)$$

$$\mu_{ij} \in [0, 1] \quad (12)$$

c 클래스에서 특징 벡터의 퍼지 소속도의 합은 항상 1이어야하며, 두 개의 클래스의 경우를 예로 들면 0.5

근처의 소속도는 두 클래스에서 높은 소속도를 가짐을 의미한다. 퍼지 소속도를 계산하기 위한 단계는 앞의 식 (3)에서와 같이 구해진다.

[단계1] 학습 집합의 특징벡터들 사이의 유clidean 거리 행렬을 구한다.

[단계2] $i=j$ 경우에 영의 값을 가지기 때문에 거리 행렬에서 대각요소의 값을 무한대(큰 값)로 정한다.

[단계3] 거리 값이 작은 순서로 거리 행렬을 나열한다. 그리고, 고려하는 특징벡터에서 가장 가까운 이웃에 위치한 특징벡터의 c 클래스 중에서 하나의 레벨을 선택한다. 즉, 1에서 k 번째로 가까운 특징벡터에 해당되는 클래스를 구한다.

[단계4] Keller[15]에 의해 제안된 다음 식을 이용하여 j 번째 특징벡터에 대한 i 번째 클래스의 퍼지 소속도를 계산한다.

$$\mu_{ij}(x) = \begin{cases} 0.51 + 0.49(n_{ij}/k) & \text{if } i=j \\ 0.49(n_{ij}/k) & \text{if } i \neq j \end{cases} \quad (13)$$

여기서 n_{ij} 는 k -NN중에서 w_i 에 속하는 특징벡터의 수이다. 이 방법을 설명하기 위해 그림 1과 같이 세 개의 클래스를 갖는 9개의 2차원 데이터를 고려해 볼 수 있다. 예를 들어 퍼지 소속도가 (0.6733 0.3267)인 샘플 포인트(클래스 2)의 퍼지 소속도는 식(13)을 이용하여 다음과 같이 계산되었다.

(1) 할당된 클래스 2 \neq 클래스 1이므로 클래스 1에 속한 소속도는

$$0.49(n_{ij}/k) = 0.49(0/3) = 0$$

(2) 할당된 클래스 2 $=$ 클래스 2이므로 클래스 2에 속한 소속도는

$$0.51 + 0.49(n_{ij}/k) = 0.51 + 0.49(1/3) = 0.6733$$

(3) 할당된 클래스 2 \neq 클래스 3이므로 클래스 3에 속한 소속도는

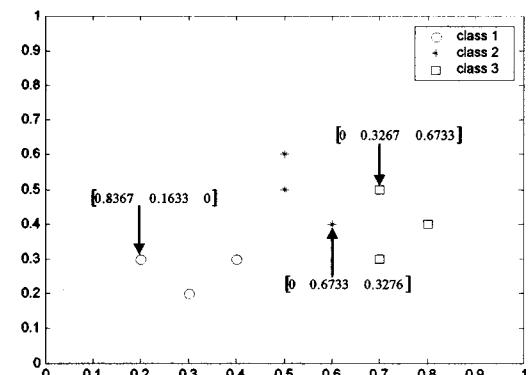


그림 1 퍼지 KNN 초기화를 이용한 퍼지 소속도($k=3$)

$$0.49(n_{ij}/k) = 0.49(2/3) = 0.3267$$

본 논문에서 제안하는 폐지 Fisherface 알고리즘을 위한 각 클래스 \hat{m}_i 의 평균 값은 다음 식과 같이 특징 벡터와 폐지 소속도를 이용함으로서 정의된다.

$$\hat{m}_i = \frac{\sum_{j=1}^N \mu_{ij} x_j}{\sum_{j=1}^N \mu_{ij}} \quad (14)$$

여기서 μ_{ij} 는 j 번째 레벨된 샘플 집합의 i 번째 클래스의 소속도이다. 위의 결과를 이용하여 폐지 클래스간 분산 행렬 S_{FB} 와 폐지 클래스내 분산 행렬 S_{FW} 는 각각 다음과 같이 정의한다.

$$S_{FB} = \sum_{i=1}^c N_i (\hat{m}_i - \bar{m})(\hat{m}_i - \bar{m})^T \quad (15)$$

$$S_{FW} = \sum_{i=1}^c \sum_{x_k \in C_i} (x_k - \hat{m}_i)(x_k - \hat{m}_i)^T = \sum_{i=1}^c S_{FWi} \quad (16)$$

위 식에서 \bar{m} 은 모든 특징벡터들의 평균 값이다. 최종적으로 최적의 폐지 투영행렬 W_{F-FLD} 와 폐지 Fisherface 방법에 의해 투영된 특징벡터는 각각 다음과 같이 계산되어진다.

$$W_{F-FLD} = \arg \max_w \frac{|W^T S_{FB} W|}{|W^T S_{FW} W|} \quad (17)$$

$$\hat{v}_i = W_{F-FLD}^T x_i = W_{F-FLD}^T E^T (z_i - \bar{z}) \quad (18)$$

다음 예제는 제안된 방법이 얼굴인식 분야에서 어떻게 개선시킬 수 있는지를 보여준다. 그림 2는 Yale[16] 얼굴 데이터베이스에서 eigenface, Fisherface, 제안된 방법을 이용한 인식 결과를 보여주고 있다. 그림에서 알 수 있듯이 그림 2(a)와 (b)는 조명 변화와 같은 큰 변동으로 인해 오분류를 갖으며, 그림(c)는 Fisherface 방법으로만 사용했을 경우, 오분류의 결과를 볼 수 있다. 그러나 그림 2(d)는 폐지 소속도를 선형판별분석법에 의해 변환된 특징벡터에 부여함으로서 더 좋은 인식 성능을 보여주고 있으며, 그림 2(c)의 폐지 소속도는 그림 3에 나타내고 있다. 그림 4는 앞에서와 같이 제안된 방법을 구현하기 위한 순서도로서, 우선 학습 얼굴영상에 대해 독립성분분석기법(PCA)을 이용하여 차원축소를 하고, 폐지 KNN 초기화과정에서 특징벡터에 대한 폐지소속도를 계산하며, 선형판별분석법에 의해 특징점을 추출하여 코드북을 형성할 수 있다. 이에, 검증 얼굴영상에 대해 독립성분분석기법을 이용하여 학습 영상과 같이 차원축소를 하고 선형판별분석법에 의해 특징점을 추출하여 코드북으로 만들어 놓은 기준 데이터와의 유클리디안 거리를 측정하여 분류를 하게 된다. 이때, 폐지 KNN 초기화를 계산함에 있어 최적의 k 값은 각 실험을 통해 가장 좋은 인식률을 나타내는 값에 의해 결정된다.

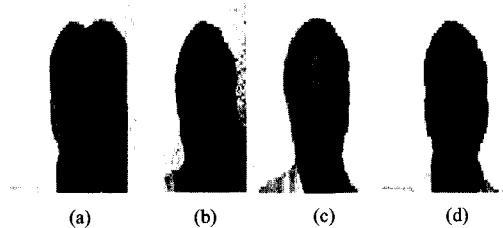


그림 2 (a) 테스트영상(클래스5), (b) eigenface방법으로 인식된 영상(클래스12), (c) Fisherface방법으로 인식된 영상(클래스12), (d) 폐지기반 Fisherface 방법으로 인식된 영상(클래스5)

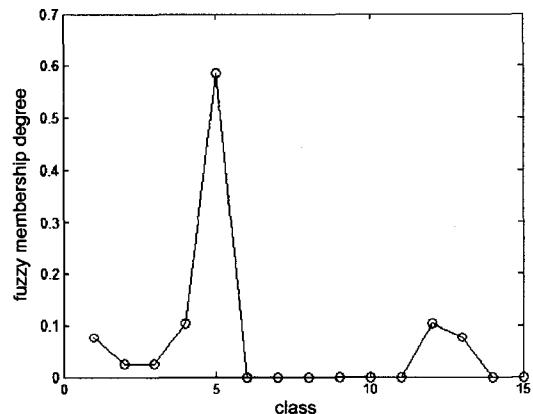


그림 3 그림 2(d) 영상에 대한 폐지 소속도

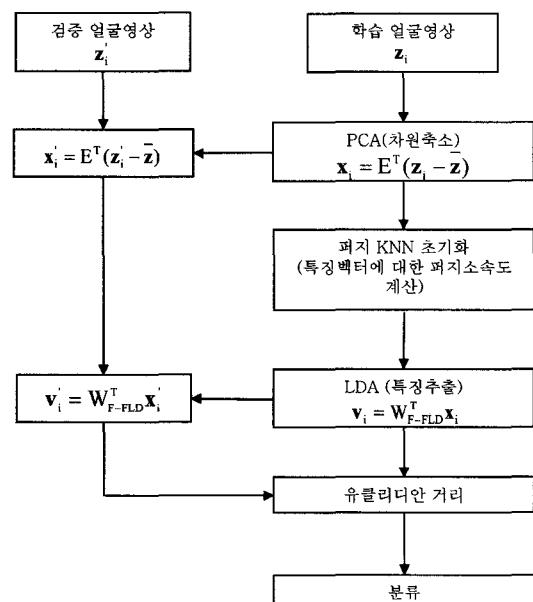


그림 4 폐지 Fisherface 방법의 순서도

3. 얼굴인식 실험 및 결과

3.1 ORL 얼굴 데이터베이스를 이용한 실험

ORL[17] 얼굴 데이터베이스는 서로 다른 환경에서 40명으로부터 400개의 얼굴영상을 포함하고 있다. 각 개인에 대해서 얼굴 영상의 수는 10이며, 이 영상들은 위치, 회전, 스케일, 얼굴 감정에서 변화를 주고 있다. 회전에서 변화는 최대 20도 회전하였고, 스케일에서 변화는 사람과 비디오 카메라 사이에 거리를 변화하였다. 또한 어떤 사람에 대해서는 안경 착용에 변화를 주었고, 서로 다른 시간에 영상을 얻었다. 각 영상들은 디지털화 되고 0에서 255까지 그레이 값을 가진 112×92 영상 크기에 의해 나타내어진다. ORL 얼굴 데이터베이스의 일부를 그림 5에서 나타내었으며, 학습과 검증 영상 집합은 다음과 같이 세 경우를 고려하여 임의로 선택하였다.

경우 1 : 개인당 학습 영상의 수 : 5장, 검증 영상의 수 : 5장
 경우 2 : 개인당 학습 영상의 수 : 4장, 검증 영상의 수 : 6장
 경우 3 : 개인당 학습 영상의 수 : 6장, 검증 영상의 수 : 4장

인식 실험은 각 경우에 있어 임의의 선택된 영상에 대해서 10번 동안 반복적으로 수행하였다. 먼저, 주성분 분석 기법에 의해 얻어진 200개의 고유치는 그림 6과 같다. 여기서, 우리는 10번 실험에서 가장 좋은 성능을 나타내는 60개의 고유치에 대응하는 고유벡터를 결정하였다. 또한, 선형판별 분석법에서 $c-1$ 개 가장 큰 일반화된 고유치에 대응하는 판별 벡터의 수는 39이다. 그림 7은 제안된 방법에 의해 얻어진 Fisherface 영상의 일부를 보여주고 있다. 각 경우에 대한 얼굴인식률의 실험 결과는 그림 8-10에 나타내어진다. 또한, 세 경우에 대한 평균 얼굴인식률은 그림 11에 나타내어진다. 결과에서 알 수 있듯이 제안된 방법이 모든 경우에 있어서 다른 인식 방법과 비교하여 좋은 성능을 나타냄을 알 수 있고, 따라서 제안된 방법이 얼굴 인식 시스템에 유용하다는 것을 알 수 있었다. 그림 12는 네 개의 임의의 집합에서 k 변동에 의한 인식률을 보여주고 있으며, 여기

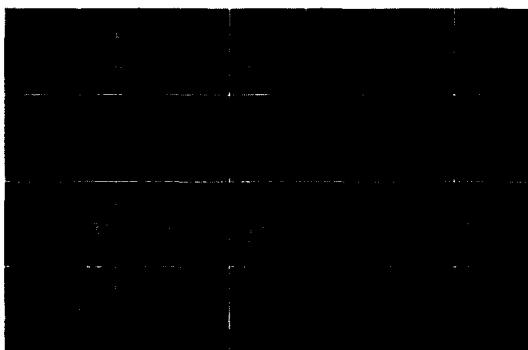


그림 5 ORL 얼굴 데이터베이스에서 일부의 얼굴영상

에서 최적의 k 값은 각 실험을 통해 가장 좋은 인식률을 나타내는 값에 의해 결정하였다.

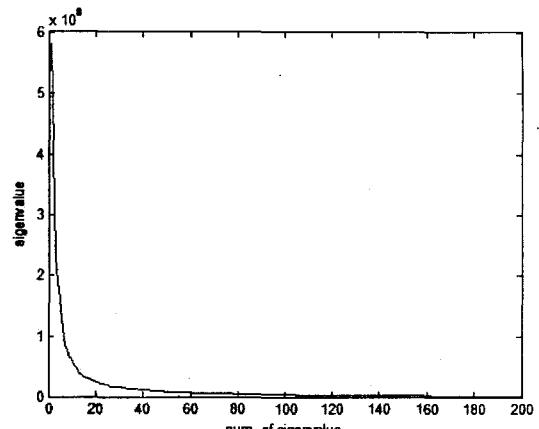


그림 6 PCA에 의해 얻어진 고유치



그림 7 퍼지 Fisherface 방법에 의해 얻어진 일부의 Fisherface 영상

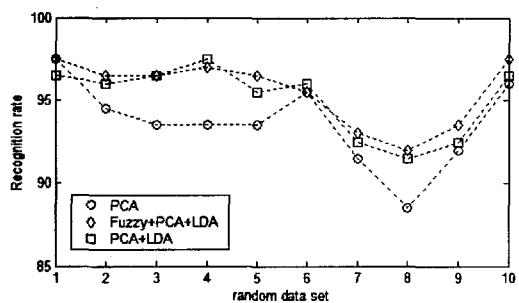


그림 8 ORL 얼굴 데이터베이스로부터 인식률 비교(경우1)

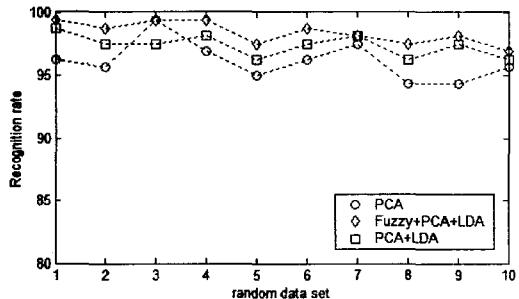


그림 9 ORL 얼굴 데이터베이스로부터 인식률 비교(경우2)

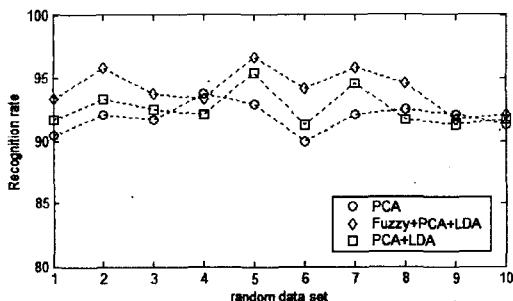


그림 10 ORL 얼굴 데이터베이스로부터 인식률 비교(경우3)

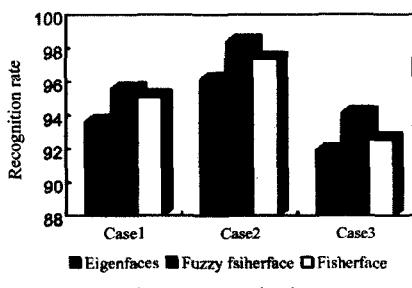


그림 11 인식률의 비교

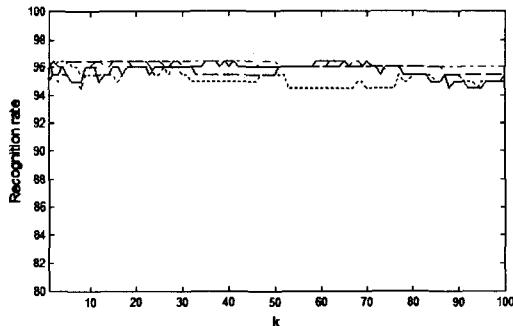


그림 12 네 개의 임의의 테스트 영상 집합에서 k변동에 의한 인식률(경우1)

3.2 Yale 얼굴 데이터베이스를 이용한 실험

Yale 얼굴 데이터베이스는 15명으로 165장의 얼굴 영상이 포함되어져 있다. 이 데이터베이스는 개인당 11장의 영상이 있으며, 조명의 방향, 얼굴의 감정(즐거움, 슬픔, 놀람, 웁크), 안경의 착용 혹은 미착용 등 다양한 변화를 사용하였다. 여기에서는 웁크 영상을 제외한 150장의 얼굴 영상을 사용하였다. 각 영상은 디지털화되고 0에서 255사이의 그레이 값을 가진 61×80 픽셀 배열에 의해 표현되어진다. Yale 얼굴 데이터 베이스의 일부는 그림 13에 나타내었다. 학습 및 테스트 영상 집합은 ORL의 경우와 마찬가지로 세 가지 경우에 대해서 임의로 선택함으로서 얻어진다. 이 절차는 각 경우에 있어서

10번 동안 반복적으로 수행되어지며, 우리는 10번 실험에서 가장 좋은 성능을 나타내는 40개의 고유벡터를 결정하였고, 선형판별 분석법에서 판별벡터는 $c-1$ 개로 14개를 선택하였다. 얼굴인식을 위한 실험적인 결과는 그림 14-16에서 보여주고, 세 경우에 대한 평균 인식률은 그림 17에 나타내었다. 결과에서 알 수 있는 바와 같이 제안된 방법이 큰 조명 변화에서 유용하게 사용될 수 있음을 확인하였다. 그림 18은 k 의 함수로서 다른 어진 인식률의 일부를 보여주고 있으나, 이 파라미터가 분류기의 성능에 큰 영향을 주지 않음을 알 수 있다.

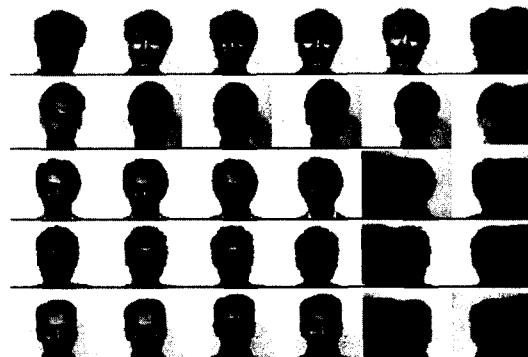


그림 13 Yale 얼굴 데이터베이스에서 일부의 얼굴영상

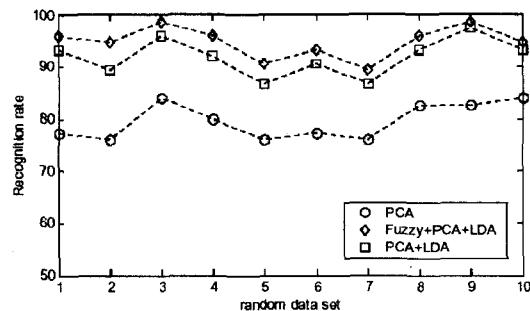


그림 14 Yale 얼굴 데이터베이스에 대한 인식률(경우1)

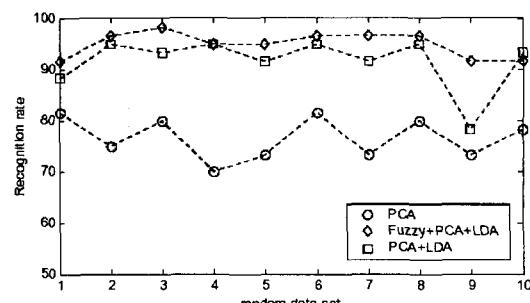


그림 15 Yale 얼굴 데이터베이스에 대한 인식률(경우2)

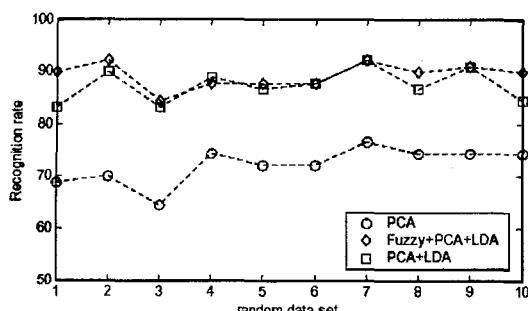


그림 16 Yale 얼굴 데이터베이스에 대한 인식률(경우3)

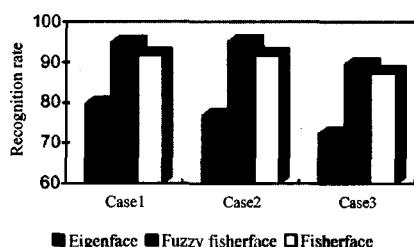


그림 17 Yale 얼굴 데이터베이스에 대한 인식률의 비교

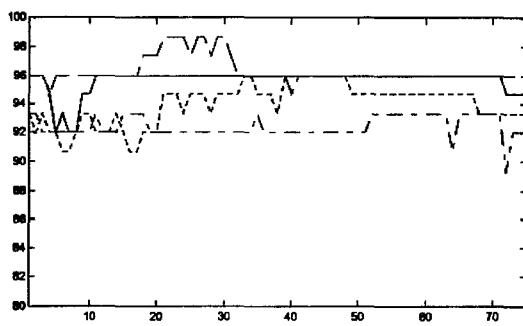


그림 18 네 개의 임의의 테스트 영상 집합에서 k변동에 의한 인식률(경우1)

4. 결론

본 논문에서는 얼굴영상에 대해서 클래스 소속에 대한 정보를 이용함으로서 얼굴인식을 위한 Fisherface 방법의 일반화된 형태인 퍼지 Fisherface방법을 기술하였다. 이 방법은 전형적인 fisherface 방법의 핵심 부분을 형성하는데 있어 퍼지 클래스간 행렬과 클래스내 행렬을 계산하도록 하였다. 제안된 방법을 적용함으로서, 조명변화나 보는 각도에 의해 발생하는 얼굴 영상 사이의 본질적인 변화에 대한 민감함을 줄일 수 있었다. 실험 결과에서 알 수 있듯이 ORL, Yale 얼굴 데이터베이스에 적용할 때 eigenface, Fisherface 같은 전형적인

방법에 비교하여 일관되게 좋은 인식률을 보여줄을 알 수 있다.

참고 문헌

- [1] M. Turk, A. Pentland, "Face recognition using eigenfaces," *Proc. IEEE Conf. On Computer Vision and Pattern Recognition*, pp. 586-591, 1991.
- [2] P. N. Belhumeur, J. P. Hespanha, D. J. Kriegman, "Eigenfaces vs. Fisherfaces: recognition using class specific Linear Projection," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 19, No. 7, pp. 711-720, 1997.
- [3] H. C. Kim, D. Kim, S. Y. Bang, "Face recognition using the mixture-of-eigenfaces method," *Pattern Recognition Letters*, Vol. 23, pp. 1549-1558, 2002.
- [4] A. Pujol, J. Vitria, F. Llumbreras, J. J. Villanueva, "Topological principal component analysis for face encoding and recognition," *Pattern Recognition Letters*, Vol. 22, pp. 769-776, 2001.
- [5] K. I. Kim, K. Jung, H. J. Kim, Face recognition using kernel principal component analysis, *IEEE Signal Processing Letters*, Vol. 9, No. 2, pp. 40-42, 2002.
- [6] B. Li, Y. Liu, When eigenfaces are combined with wavelets, *Knowledge-Based Systems*, Vol. 15, pp. 343-347, 2002.
- [7] C. Liu, H. Wechsler, Gabor feature based classification using the enhanced fisher linear discriminant model for face recognition, *IEEE Trans. on Image Processing*, Vol. 11, No. 4, pp. 467-476, 2002.
- [8] H. Yu, J. Yang, A direct LDA algorithm for high-dimensional data-with application to face recognition, *Pattern Recognition*, Vol. 34, pp. 2067-2070, 2001.
- [9] Z. Jin, J. Y. Yang, Z. S. Hu, Z. Lou, Face recognition based on the uncorrelated discriminant transformation, *Pattern Recognition*, Vol. 34, pp. 1405-1416, 2001.
- [10] D. L. Swets, J. Weng, Using discriminant eigen-features for image retrieval, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 18, No. 8, pp. 831-836, 1996.
- [11] M. J. Er, S. Wu, H. L. Toh, Face recognition with radial basis function (RBF) neural networks, *IEEE Trans. on Neural Networks*, Vol. 13, No. 3, pp. 697-710, 2002.
- [12] S. Lawrence, C. L. Giles, A. C. Tsoi, A. D. Back, Face recognition: a convolutional neural-network approach, *IEEE Trans. on Neural Networks*, Vol. 8, No. 1, pp. 98-113, 1997.
- [13] C. Liu, H. Wechsler, Evolutionary pursuit and its application to face recognition, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. 22, No. 6, pp. 570-582, 2000.

- [14] L. A. Zadeh, Fuzzy sets, *Information and Control*, Vol. 8, pp. 338-353, 1965.
- [15] J. M. Keller, M. R. Gray, J. A. Givens, A fuzzy k-nearest neighbor algorithm, *IEEE Trans. on Systems, Man, and Cybernetics*, Vol. 15, No. 4, 580-585, 1985.
- [16] Yale face database, <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>
- [17] ORL face database, <http://www.uk.research.att.com/facedatabase.html>

**곽근창**

1996년 충북대학교 전기공학과(학사)
 1998년 충북대학교 전기공학과(공학석사)
 2002년 충북대학교 전기공학과(공학박사)
 2003년~현재 Dept. Electrical and Computer engineering, University of Alberta, Post-doc. 관심분야는 계산지능, 생체인식

**고현주**

1999년 한밭대학교 제어계측공학과(학사)
 2002년 충북대학교 제어계측공학과(공학석사). 2002년~현재 충북대학교 제어계측공학과 박사과정. 관심분야는 Biometrics, Computer vision, 감정인식

**천명근**

1987년 부산대학교 전자공학과(학사). 1989년 한국과학기술원 전기 및 전자공학과(공학석사). 1993년 한국과학기술원 전기 및 전자공학과(공학박사). 1993년~1996년 삼성전자 자동화연구소 선임연구원
 2000년~2001년 University of Alberta 방문교수. 1996년~현재 충북대학교 전기전자컴퓨터공학부 교수. 관심분야는 Biometrics, 감정인식, 음성신호처리, 얼굴인식