

고유얼굴에 의한 얼굴인식

Face Recognition using Eigenface

박중조, 김경민
Joong Jo Park, Kyoung Min Kim

요약

고유얼굴 방법에 의한 얼굴인식은 얼굴 표정의 변화에 둔감한 유용한 인식기법이나 인식률이 낮아 지속적인 연구가 필요한 실정이다. 본 논문에서는 고유얼굴 특징을 이용한 얼굴인식에 있어서 인식률 개선을 위한 효과적인 방법을 제시한다. 이를 위해 본 연구에서는 고유얼굴 특징에 대해 세 종류의 분류기-단일원형 분류기, 최소거리 분류기, 신경회로망 분류기-를 사용하여 그 성능을 평가하고 분석함으로써 고유얼굴 특징의 분포 특성을 고찰하고, 분류기 및 학습용 샘플 영상의 선정이 인식률을 제고에 큰 영향을 미침을 보인다. ORL 얼굴영상 데이터베이스를 사용하여 실험한 결과 최소거리 분류기가 가장 좋은 인식률을 나타내었으며, 학습용 샘플영상의 선정과 최소거리 분류기에 의해 91.0%의 인식률을 달성하였다.

ABSTRACT

Eigenface method in face recognition is useful due to its insensitivity to large variations in facial expression and facial details. However its low recognition rate necessitates additional researches. In this paper, we present an efficient method for improving the recognition rate in face recognition using eigenface feature. For this, we perform a comparative study of three different classifiers which are i) a single prototype (SP) classifier, ii) a nearest neighbor (NN) classifier, and iii) a standard feedforward neural network (FNN) classifier. By evaluating and analyzing the performance of these three classifiers, we show that the distribution of eigenface features of face image is not compact and that selection of classifier and sample training data are important for obtaining higher recognition rate. Our experiments with the ORL face database show that 1-NN classifier outperforms the SP and FNN classifiers. We have achieved a recognition rate of 91.0% by selecting sample training data properly and using 1-NN classifier.

Keywords : face recognition, eigenface, neural network, nearest neighbor classifier

I. 서론

산업의 발달로 생활 패턴이 자동화됨에 따라 보안 시스템은 컴퓨터를 이용하여 점차 자동화 및 무인화의 방향으로 가고 있다. 보안 시스템의 기능은 기본적으로 개인 인증(identification)을 하는 것으로서, 그 동안에는 주로 암호 입력 방법을 사용하여 왔다. 그러나 이 방식은 개인 인증의 확실성에서는 뛰어난 면이 있으나 번거로운 방식이므로, 최근에는 영상인식을 이용한 개인 인증의 자동화 기술이 연구되고 있다. 영상인식을 이용한 개인 인증 방법에서는 각 사람이 가진 변하지 않는 고유의 특징을 사용하는데, 지문이나 손바닥, 홍채 그리고 얼굴 등이 유용한 특징으로 이용되고 있다. 이중에 무접촉 인증방식인 얼굴인식은 사용이 편리하고 활용도가 광범위하여 최근에 많은 연구가 이루어지고 있다[1,2].

얼굴인식 기법으로는 신경회로망 방법[3], 템플릿 매칭 방법[4], 주파수 또는 히스토그램 방법[5] 그리고 대수적 방법인 고유얼굴(eigenface) 방법[6-9] 등이 있다. 이 중에 비교적 인식률이 높은 방법은 얼굴 구성요소(눈, 코, 입)의 템플릿을 이용한 템플릿 매칭 방법이다. 이 방법은 인식의 정확도면에서 다른 방법에 비해 자신의 영상을 그대로 이용하기 때문에 잘못된 특징을 찾을 확률이 적다는 점에서 유리하다. 그러나 고정된 템플릿을 사용하므로 영상의 크기가 변하거나 얼굴표정이 다양할 경우 사용하기가 곤란하며, 계산시간이 길고 무표정의 정면얼굴에만 적용할 수 있다는 제약이 있다. 이에 대해 얼굴영상 자체를 기반(Holistic view approach)으로 하는 고유얼굴 방법은 다양한 표정변화에도 강한 효과적인 인식방법이다. 이 방법은 KL변환을 이용하여 통계적으로 특징을 결정하기 때문에 얼굴의 구성요소에 대한 개별적인 특징을 추출할 필요가 없으며, 다른 얼굴

2 / 고유얼굴에 의한 얼굴인식

인식 방법과 비교해서 속도, 단순성, 학습 능력 및 얼굴변화에 대한 둔감성 등 많은 이점을 가진다.

본 연구에서는 고유얼굴 특징에 의한 얼굴인식 기법에 있어서, 이 특징에 대해 다양한 분류기법들을 적용하고 그 성능 평가를 통해 인식률 개선을 위한 효과적인 방안을 제시하였다. 단일원형(single prototype) 분류기와 최소거리(Nearest Neighbor) 분류기 그리고 신경회로망(Neural Network) 분류기를 사용하여 고유얼굴 특징에 대한 각각의 분류 성능을 고찰하고 특징공간상에서의 본 특징의 분포특성을 분석하였으며, 또한 학습용 샘플영상의 선정이 인식률에 미치는 영향에 대한 연구를 수행하였다. 다양한 표정의 얼굴로 구성된 ORL(Olivetti Research Laboratory) 얼굴 데이터베이스를 사용하여 실험한 결과, 기존의 신경회로망 분류기에 의한 인식률이 83.5%인데 비해, 본 연구에서는 1-NN 분류기에 의해 91.0%의 인식률을 달성하였다.

본 논문의 구성은 I장의 서론에 이어 II장에서는 KL변환과 고유얼굴에 대하여 기술하고, III장에서는 고유얼굴 특징을 이용한 얼굴인식 기법에 대해 설명한다. 그리고 IV장에서는 실험 결과 및 고찰을, 마지막으로 V장에서는 결론 및 향후과제에 대해 논한다.

II. KL변환과 고유얼굴

KL변환은 영상압축 분야에서 오랜 기간 동안 꾸준히 연구되어 왔으나 패턴인식 분야에서 크게 활용되지 못하다가 1987년 Kirby와 Sirovich가 KL변환을 이용하여 얼굴영상을 표현하는 방법을 소개함으로써 KL변환이 얼굴인식에 본격적으로 활용되기 시작하였다[6]. 이 방법은 많은 얼굴영상에서의 각 영상들의 특징을 가장 잘 표현하는 벡터를 찾아내는 것으로서, 이 벡터는 많은 얼굴 영상들의 기저(basis)가 되는 벡터이다.

1. KL 변환

KL변환은 입력 데이터를 상관성이 없는 계수 집합으로 변환시키는 변환 방법으로서 주성분 분석법(PCA, Principal Component Analysis)이라고도 하는데, 입력 데이터의 2차 통계량(분산)에 의한 직교 기저함수로 데이터를 표현하기 때문에 가우시안 분포를 갖는 데이터에 대해서는 데이터에 함유된 고유의 특징을 잃지 않으면서 선형 변환하거나 낮은 차원으로 변환시키는데 있어서 최적의 변환방식을 제공한다[10].

N^2 차원인 M개의 벡터 \mathbf{x}_i 로 구성된 벡터의 모집단 \mathbf{x} 에 대한 기대값(expected value) \mathbf{m}_x 와 공분산 행렬(covariance matrix) \mathbf{C}_x 는 아래와 같이 계산된다.

$$\mathbf{m}_x = E\{\mathbf{x}\} = \frac{1}{M} \sum_{i=1}^M \mathbf{x}_i \quad (1)$$

$$\begin{aligned} \mathbf{C}_x &= E\{(\mathbf{x} - \mathbf{m}_x)(\mathbf{x} - \mathbf{m}_x)^T\} \\ &= \frac{1}{M} \sum_{i=1}^M (\mathbf{x}_i - \mathbf{m}_x)(\mathbf{x}_i - \mathbf{m}_x)^T \end{aligned} \quad (2)$$

이때, \mathbf{C}_x 는 $N^2 \times N^2$ 행렬로서 그의 대각원소 c_{ii} 는 벡터 \mathbf{x}_i 의 분산이고, 비대각원소 c_{ij} 는 벡터 \mathbf{x}_i 와 \mathbf{x}_j 간의 공분산이며, 행렬 \mathbf{C}_x 는 실수값을 가지는 대칭행렬이 된다. 만일 벡터 \mathbf{x}_i 와 \mathbf{x}_j 가 상관성이 없으면 이 벡터들의 공분산은 0이고 따라서 $c_{ij}=c_{ji}=0$ 이 된다.

공분산행렬 \mathbf{C}_x 는 실수값을 가지며 대칭이기 때문에, N^2 개의 정규직교고유벡터들(orthonormal eigenvectors)을 구하는 것은 항상 가능하다. \mathbf{C}_x 의 고유값(eigenvalue)을 크기순으로 정렬하여 $\lambda_1, \lambda_2, \dots, \lambda_{N^2}$ 이라 하고 그에 대응하는 각 고유벡터를 $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_{N^2}$ 이라 할 때, 이 \mathbf{C}_x 의 고유벡터들을 이용하여 다음의 행렬 \mathbf{A} 를 만든다.

$$\mathbf{A} = [\mathbf{e}_1 \ \mathbf{e}_2 \ \dots \ \mathbf{e}_{N^2}]^T \quad (3)$$

여기서, 행렬 \mathbf{A} 의 첫번째 행은 가장 큰 고유값에 대응되는 고유벡터이고, 마지막 행은 가장 작은 고유값에 대응되는 고유벡터이다. 그러면 이 행렬 \mathbf{A} 는 입력벡터 \mathbf{x} 를 계수벡터 \mathbf{y} 로 사상시키는 변환행렬이 되며, 이 행렬을 사용하여 다음과 같은 KL변환이 정의된다.

$$\mathbf{y} = \mathbf{Ax} \quad (4)$$

KL변환의 중요한 특성은 고유벡터와 계수벡터 \mathbf{y} 로부터 원래의 \mathbf{x} 를 완벽히 복원할 수 있다는 것이다. 즉, \mathbf{C}_x 는 실수값을 갖는 대칭행렬이므로 직교 정규인 고유벡터가 존재하게 되어 $\mathbf{A}^{-1}=\mathbf{A}^T$ 가 되고, 따라서 식 (4)의 역변환에 의해 다음과 같이 \mathbf{y} 로부터 \mathbf{x} 가 구해질 수 있다.

$$\mathbf{x} = \mathbf{A}^{-1}\mathbf{y} = \mathbf{A}^T\mathbf{y} \quad (5)$$

결국, 식 (5)를 사용하면 어떠한 벡터 \mathbf{x} 도 그에 대응되는 \mathbf{y} 로부터 복구될 수 있다.

한편, \mathbf{C}_x 의 모든 고유벡터를 사용하는 대신에 K개의 가장 큰 고유치에 대응하는 K개의 고유벡터들만을 사용하여 변환행렬 \mathbf{A}_K 를 구성한다면 차수가 $K \times N^2$ 인 변환행렬이 얻어지게 되는데, 이 경우 벡터 \mathbf{y} 는 K차원이 되며 이 방식으로 구해지는 벡터 \mathbf{x} 는 더 이상 정확한 본래의 값이 되지 못하고 근사치가 된다. 이 근사치 \mathbf{x}' 는 다음 수식으로 구해진다.

$$\mathbf{x}' = \mathbf{A}_K^T \mathbf{y} \quad (6)$$

이때, \mathbf{x} 와 \mathbf{x}' 사이의 평균 제곱 오차는 다음 수식으로 구해진다.

$$e_{ms} = \sum_{j=1}^{N^2} \lambda_j - \sum_{j=1}^K \lambda_j \quad (7)$$

여기서, λ_j 는 단조 감소로 정렬된 것이기 때문에 식 (7)은 가장 큰 고유값들과 관련 있는 K개의 고유벡터를 선택함으로써 오차를 최소화할 수 있다는 것을 보여준다. 즉, KL변환은 최소 제곱 오차의 의미에서 최적 변환이다. KL변환의 기본적인 개념은 기저 벡터를 선택하는데 있어

서 벡터가 자료의 분산이 최대인 방향을 가지도록 하고, 또한 벡터들 간에 상호 직교성을 가지며 변환된 성분들이 비상관적이 되도록 하는데 있다.

2. 고유얼굴

얼굴인식을 위한 고유얼굴 방법은 KL 변환을 사용하는 것으로서, 제약이 많은 환경에서 빠르고 간단하면서도 정확한 인식시스템을 개발하기 위한 수치적인 모델로서 제안된 방법이다[7]. 고유얼굴 방법은 샘플 얼굴영상 집단을 고유얼굴(eigenface)이라고 불리는 기저벡터의 집합으로 표현하여 이를 얼굴인식에 사용하는 방법으로서, 상관관계 정보를 영상에서 추출하고 KL변환 계수값의 유사도를 비교하여 얼굴인식을 수행한다. 그런데 KL변환은 본질적으로 1차원 데이터에 사용할 수 있으므로 2차원 데이터인 얼굴영상에 이를 적용하려면 이를 1차원 벡터 형태로 변형시킨 후 사용해야 한다.

먼저, 2차원 데이터인 얼굴영상에 KL변환을 적용하기 위해, 크기가 NxN인 M개의 얼굴영상을 크기가 N²x1인 1차원 벡터 I_k , k=1,2,...,M로 변형시킨다. 그후 다음 수식에 의해 이들의 평균영상 Ψ 를 구한다.

$$\Psi = \frac{1}{M} \sum_{k=1}^M I_k \quad (8)$$

그리고, 각 얼굴영상에서 평균영상을 뺀 차이영상 Φ_k 를 구한다.

$$\Phi_k = I_k - \Psi, k = 1, 2, \dots, M \quad (9)$$

이제, M개의 차이영상 Φ_k 를 사용하여 주성분 분석법에 의해, 주어진 얼굴영상들의 분포를 가장 잘 나타내는 M개의 정규직교벡터 u_k 를 구한다. 이 u_k 는 식 (10)의 공분산행렬 C 의 고유벡터를 계산함으로써 구할 수 있다. 이때 행렬 C 의 가장 큰 고유값부터 시작하여 크기순으로 각 고유값에 해당되는 고유벡터를 구해야 한다.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = BB^T \quad (10)$$

여기서, 행렬 $B = [\Phi_1 \Phi_2 \dots \Phi_M]$ 이다. 이런 방식으로 얻어진 고유벡터를 원래의 영상 표현인 NxN으로 재배열하여 보면 얼굴영상과 닮아있게 되고, 따라서 얼굴영상에 대한 이 고유벡터 u_k 를 고유얼굴이라고 한다. 이 고유얼굴은 샘플 얼굴영상들의 주성분으로 해석될 수 있다.

일단, 고유얼굴 u_k 가 구해지면, 식 (11)에 의해 임의의 얼굴영상 I 에 대한 가중치 벡터 $Q = [w_1, w_2, \dots, w_M]$ 가 구해지고, 이 가중치 벡터 Q 는 얼굴영상 I 에 대한 특징벡터로 사용된다.

$$w_k = u_k^T (I - \Psi), k = 1, \dots, M \quad (11)$$

한편 얼굴영상의 개수 M이 1차원 벡터화된 얼굴영상의 차수 N²보다 작은 경우에는 의미있는 고유벡터 즉 고유얼굴의 개수는 M-1개가 되고 나머지 고유얼굴들은 0

의 고유값에 해당된다. 이는 고유얼굴에 의한 얼굴인식에서 흔히 나타나는 경우로서, 이 경우에는 식 (10)의 행렬 C 로부터 직접 고유벡터를 구하는 것보다 행렬 $B^T B$ 의 고유벡터 v_k 를 먼저 구하고 $u_k = B v_k$ 를 사용함으로써 보다 적은 계산량으로 고유얼굴 u_k 를 구할 수 있다[7].

III. 고유얼굴을 이용한 얼굴 인식

고유얼굴을 이용한 얼굴 인식방법은 미지 영상과 학습용 샘플영상에서 얻어진 각각의 고유얼굴 특징값들의 유사도를 비교하는 방식을 사용한다. 이는 학습용 샘플모집단 얼굴영상들의 공분산 행렬의 고유벡터(즉, 고유얼굴)를 계산하고 학습용 샘플 얼굴영상과 미지의 얼굴영상은 이 고유벡터 공간으로 투영시킨 투영값을 특징값으로 사용하여 이들을 비교함으로써 미지의 얼굴이 학습용 샘플얼굴들의 어느 것에 해당되는지를 판정하는 방식이다. KL변환은 본질적으로 큰 고유값에 대응하는 몇 개의 고유벡터만 사용하여도 본래의 벡터를 잘 표현하는 특성을 가지고 있으므로 이를 얼굴인식에 사용할 경우 사용되는 고유벡터(즉, 고유얼굴)의 개수를 얼굴 영상의 픽셀 개수에 비해 매우 작게 선택할 수가 있어서 패턴 분류기의 수행시에 계산량이 매우 작아진다.

고유얼굴 특징을 이용한 얼굴인식은 학습단계와 인식 단계로 나뉘어 수행된다. L(<M)개의 고유얼굴을 사용한다고 가정할 때, 각 단계의 처리 내용은 다음과 같다.

먼저, 학습단계에서는 M개로 구성된 샘플 모집단 얼굴영상들을 사용하여 고유값이 큰 순서대로 L개의 고유얼굴 $u_k, k=1, 2, \dots, L$ 을 구하고, 각 샘플 얼굴영상 I_m 에 대한 가중치 벡터 $Q_m = [w_{m1}, w_{m2}, \dots, w_{mL}]$, m=1,2,...,M을 구한다. 여기서, w_{mk} 는 식 (12)로 계산되는데, 이는 각 샘플영상 I_m 의 고유얼굴 u_k 에 대한 투영값으로서 각 샘플영상에 대한 특징값으로 사용된다.

$$w_{mk} = u_k^T (I_m - \Psi), k = 1, \dots, L \quad (12)$$

여기서, Ψ 는 샘플 모집단 얼굴영상들의 평균얼굴영상이다. 이렇게 구해진 가중치 벡터 Q_m 들은 특징공간상에서 각 샘플영상을 하나의 점으로 나타내며, 같은 사람에 대해 군집화된 분포를 이루게 된다.

샘플 얼굴영상에 대한 상기의 학습작업이 완료되면, 미지 얼굴영상에 대한 인식은 다음과 같이 수행된다. 즉, 미지의 얼굴영상 X 가 입력되면, 학습에서 사용된 L개의 고유얼굴 $u_k, k=1, 2, \dots, L$ 을 사용하여 미지영상에 대한 가중치 벡터 $Q_x = [w_{x1}, w_{x2}, \dots, w_{xL}]$ 을 구한다. 여기서, w_{xk} 는 미지영상 X 의 고유얼굴 u_k 에 대한 투영값으로서 다음의 수식으로 계산된다.

$$w_{xk} = u_k^T (X - \Psi), k = 1, \dots, L \quad (13)$$

이렇게 구해진 가중치 벡터 Q_x 는 주어진 미지얼굴의 특징벡터를 나타낸다. 고유얼굴 방법에 의한 얼굴인식은 가

중치 벡터 Q_x 와 학습시에 구해진 샘플영상들의 가중치 벡터 Q_m , $m=1,2,\dots,M$ 사이의 유사도를 측정함으로써 수행된다. 결국, 고유얼굴에 의해 구해지는 가중치벡터를 고유얼굴 특징벡터라고 생각할 수 있다. 일단 이 고유얼굴 특징이 결정되고 나면 이후의 인식과정은 이 가중치 벡터를 특징벡터로 취급하여 기존의 일반적인 패턴분류기법들을 사용할 수 있다.

본 연구에서는 단일원형 분류기와 최소거리 분류기 그리고 신경회로망 분류기를 사용하여 고유얼굴 특징에 대한 각각의 분류 성능을 고찰하였다. 이중 단일원형 분류기에서는 학습용 샘플얼굴의 고유얼굴 특징벡터에서 각 사람에 대해 중심벡터를 구하고 이 중심벡터와 미지얼굴의 고유얼굴 특징벡터사이의 거리를 측정하는 방식을 사용하였고, 최소거리 분류기로는 미지얼굴에 대해 최근접 샘플얼굴만을 이용하는 1-NN과 3개 및 5개의 샘플얼굴들을 이용하는 3-NN 및 5-NN을 사용하였다. 그리고 신경회로망 분류기로는 오류역전파 학습 알고리즘에 의한 3층의 다층퍼셉트론 신경회로망을 사용하였다.

IV. 실험 및 고찰

본 실험에서는 세 종류의 분류기를 사용하여 고유얼굴 특징에 대한 각각의 분류 성능을 고찰하였다. 또한 학습용 샘플영상의 선정이 인식률에 미치는 영향을 조사하였으며, 학습용 샘플영상은 테스트영상으로 사용하여 실험해 봄으로써 특징공간상에서 고유얼굴 특징들의 분포상태를 추정하여 보았다. 실험은 Pentium II 400 PC에서, C언어를 사용하여 구현하였다. 실험에 사용한 얼굴영상은 ORL(Olivetti Research Laboratory) 얼굴영상 데이터베이스로서 99×112 픽셀 크기의 계조치 영상이다. 이 데이터베이스는 40명의 남녀에 대해 한사람당 10장씩 다양한 표정의 얼굴영상으로 구성된다.

본 실험에서는 총 400장의 얼굴영상 데이터베이스에서 1사람당 5장씩 총 200장의 영상을 학습용 영상으로 사용하고 나머지 5장씩 총 200장을 미지 영상으로 사용하여 인식률을 조사하였다. 이때 학습영상으로는 얼굴데이터베이스로부터 두가지 방식으로 선정하여 실험하였는데, 첫 번째 선정 방법은 기존의 논문에서 사용된 방식으로서 얼굴 데이터베이스에서 각 사람당 10장의 얼굴영상들 중 처음 5장을 학습용 영상으로 사용하는 것이고, 두 번째 선정 방법은 홀수번째의 영상들 5장을 학습용 영상으로 선정하는 것이다. 이중 두 번째 방법에 의하면 보다 다양한 표정의 얼굴영상들이 샘플영상으로 선택될 수 있다.

그림 1은 ORL 얼굴영상 데이터베이스의 일부를 나타낸 것이고, 그림 2는 학습용 얼굴영상들의 평균영상의 예이며, 그림 3은 가장 큰 고유값에 해당하는 고유얼굴을 나타낸다.

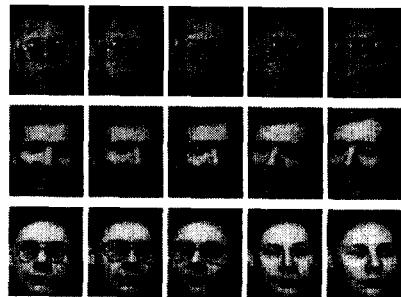


그림 1. ORL 얼굴영상 데이터베이스
Fig. 1. ORL face image database

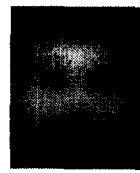


그림 2. 평균 얼굴영상
Fig. 2. Average face image



그림 3. 가장 큰 고유값에 해당하는 고유얼굴
Fig. 3. Eigenface for a largest eigenvalue

본 실험에서는 가장 큰 고유값에 해당하는 80개의 고유얼굴을 사용하여 실험을 수행하였다. 실험에서 사용한 분류기는 세가지 종류로서, 먼저 단일원형 분류기에서는 학습용 얼굴영상의 고유얼굴 특징벡터에서 각 사람에 대해 중심벡터를 구하고 이 중심벡터와 미지 얼굴영상의 고유얼굴 특징벡터사이의 거리를 측정하는 방식을 사용하였다. 그리고 최소거리 분류기로는 1-NN, 3-NN 및 5-NN을 사용하였고, 신경회로망 분류기로는 오류역전파 학습 알고리즘을 채용한 3층의 다층퍼셉트론 신경회로망 모델을 사용하였다. 신경회로망의 입력 노드의 개수는 고유얼굴 가중치 벡터의 차수와 동일하게 80개이고, 출력노드의 개수는 분류하고자 하는 사람수인 40개이다. 신경회로망의 입력값을 위해 고유얼굴로부터 구해진 가중치들을 0에서 1사이의 값으로 정규화하여 사용하였으며, 이를 위해 200개의 학습용 얼굴영상에 대한 가중치 벡터들에서 각 차원에 해당하는 요소 값들의 최대값과 최소값을 이용하여 정규화 시켰다. 그리고 미지의 얼굴영상에 대한 가중치 벡터의 정규화시에도 역시 학습용 얼굴영상의 가중치 벡터에 사용된 데이터를 사용하였다.

표1은 얼굴 데이터베이스에서 각 사람당 10장의 얼굴영상들 중 처음 5장인 1,2,3,4,5번 영상을 학습용 영상으로

사용한 경우의 인식률 결과이고, 표2는 홀수번째인 1,3,5,7,9번의 영상 5개를 학습용 영상으로 사용한 결과이다. 여기서, 표1에서 사용된 학습용 영상들은 표정의 변화가 다양하지 못하며 테스트용 영상들은 학습용 영상과는 다른 표정이 많이 포함되어 있다. 한편, 표2의 경우의 학습용 영상들은 보다 다양한 표정의 얼굴영상들로 구성되어 테스트용 영상과 유사한 표정을 많이 포함하고 있다.

표 1. 인식률 결과 (학습용 영상 번호 = 1,2,3,4,5)

Table 1. Recognition results
(No of learning images = 1,2,3,4,5)

분류기	학습영상에 대한 인식률	미지영상에 대한 인식률
단일원형 분류기	92.0 %	67.0 %
최소거리 분류기	1-NN	100 %
	3-NN	95.0 %
	5-NN	79.0 %
신경회로망 분류기	99.5 %	83.5 %

표 2. 인식률 결과 (학습용 영상 번호 = 1,3,5,7,9)

Table 2. Recognition results
(No of learning images = 1,3,5,7,9)

분류기	학습영상에 대한 인식률	미지영상에 대한 인식률
단일원형 분류기	85.5 %	74.5 %
최소거리 분류기	1-NN	100 %
	3-NN	91.0 %
	5-NN	74.0 %
신경회로망 분류기	96.5 %	86.5 %

표1과 표2는 미지영상에 대한 인식률뿐만 아니라 학습에 사용된 영상에 대한 인식률도 보인다. 일반적으로 특징공간상에서 특징값의 분포가 양호하여 클래스들의 군집화가 잘 이루어져 있다면 학습영상에 대한 인식률은 100%로 되는 것이 정상이다. 그러나 이를 표에서 보면 1-NN 분류기의 경우를 제외하면 학습영상에 대해서도 완벽한 인식률을 나타내지 못하고 있다. 이는 고유얼굴 특징의 분포가 해당 클래스에 대해 밀집되어 있지 못하며 클래스들간에도 매우 근접되어 분포되어 있음을 의미한다. 여기서 표1의 경우가 표2의 경우보다 학습영상에 대한 인식률이 높게 나타나고 있는데, 이는 표1에서 사용된 학습영상들이 표2의 경우에 비해 얼굴표정이 다양하지 못하기 때문이다. 그러나 실제의 인식 목표인 미지얼굴에 대한 인식률은 표2의 경우가 표1에 비해 더 높은 인식률을 나타내고 있는데, 이는 표2에서 사용한 학습영상이 보다 다양한 얼굴표정 영상들로 구성되어 있기 때문이다. 이 두 실험 결과표에서 각 분류기들의 성능을 살펴보면, 1-NN 분류기가 가장 좋은 결과를 나타내고, 그 다음으로 신경회로망 분류기가 비교적 높은 분류성능을 나타낸다. 그리고, 5-NN 분류기 및 단일원형 분류기는 매우 저조한 인식률을 나타내고 있다. 이 결과는 역시 특징공간상에서의 고유얼굴 특징의 분포가 클래스별로 군

집화가 잘 되어 있지 못함을 의미한다. 즉, 이러한 군집화 특성에 따라, 단일원형 분류기는 샘플 특징벡터의 중심벡터만을 사용하므로 좋은 인식률을 기대하기 힘들며, 모든 샘플들의 분포를 이용하는 신경회로망 분류기도 샘플들 자체의 완벽한 학습이 이루어지지 못하여 좋은 인식률을 내지 못한다고 생각된다. 그리고 최소거리 분류기의 경우에도, 유사도 비교에서 다수의 샘플들을 사용하는 3-NN과 5-NN에 비해 최근접 샘플만을 사용하는 1-NN이 보다 좋은 인식률을 나타낸다고 생각된다.

이상의 실험결과에 따르면, 고유얼굴 특징이 다양한 표정의 얼굴에 대한 얼굴인식에 매우 효과적이기는 하지만 높은 인식률을 얻기 위해서는 먼저 학습용 얼굴영상을 다양한 표정을 갖는 영상들로 구성되도록 선정하는 것이 중요하며 또한 고유얼굴 특징의 분포가 양호한 군집화 특성을 갖지 않으므로 분류기로는 1-NN 기법이 가장 효과적임을 알 수 있다. 본 실험의 결과 고유얼굴 특징과 1-NN 분류기의 사용으로 최대 91%의 인식률을 달성하였다.

한편 사람수의 변화에 따른 실험도 수행하여 보았다. 상기의 실험이 사람수가 40명인 경우인데 반해, 표3은 사용된 사람수를 보다 적게 하였을 때의 인식률 결과이다. 여기서는 ORL 영상 데이터베이스의 홀수번째인 1,3,5,7,9 번의 영상 5개를 학습용 영상으로 사용하였고, 사용된 고유얼굴 개수는 80개이며 1-NN 분류기법을 사용하였다. 이 결과를 보면 사람 수가 5명인 경우 100%의 인식률을 보이고 있다. 이는 본 얼굴인식 기법이 추가의 개선없이도 가정용 보안 시스템으로 실용화할 수 있는 가능성을 보인다. 그러나 사람수가 증가함에 따라 인식률은 저조해짐을 볼 수 있는데, 이는 고유얼굴 방식에 의한 얼굴인식 기법의 실용화를 위해서는 지속적인 추가 연구가 필요함을 나타낸다.

표 3. 다양한 사람수에 대한 인식률

Table 3. Recognition results for different numbers of men

분류기	5명	10명	20명	30명	40명
1-NN	100%	98%	96%	95%	91%

V. 결론

고유얼굴에 의한 얼굴인식 방법은 얼굴표정의 다양한 변화에 강인하고 얼굴 구성요소에 대한 개별적인 특징을 추출할 필요가 없으며 다른 얼굴인식 방법에 비해 인식 속도가 매우 빠른 효과적인 방법이다. 그러나 실용적인 관점에서 인식률이 미흡하여 현재 인식률 개선을 위한 연구가 계속되고 있다. 이에 본 연구에서는 고유얼굴 특징에 대해 다양한 분류기법들을 적용하고 그 성능평가와 특징 분포의 분석을 통해 보다 효과적인 인식방안을 도

출하였다.

본 연구 결과, 다양한 표정의 얼굴영상에 대해 고유얼굴 특징은 특징공간상에서 특정 분포가 클래스별로 밀집되어 있지 못하고 클래스간에도 매우 근접되어 분포되어 있는 것으로 분석되었으며, 얼굴영상 데이터베이스에서 학습시에 사용하는 샘플 영상의 선정이 인식률에 큰 영향을 미침을 알 수 있었다. 특히, 고유얼굴에 의한 얼굴인식시 학습용 얼굴영상으로서 다양한 표정의 영상들을 선정하는 것이 인식률의 향상을 위해 매우 중요한 사항으로 판명되었다. 이러한 분석을 토대로 다양한 얼굴표정의 영상으로 학습 영상을 구성하고 최소거리 분류기를 사용함으로써 단일원형 분류기나 신경회로망 분류기에 비해 보다 우수한 인식률을 얻을 수 있었다. 400장의 얼굴영상으로 이루어진 ORL 데이터베이스에 대해 실험해 본 결과, 다양한 표정의 얼굴영상을 학습용 영상으로 선정하고 최소거리 분류기중 1-NN을 사용함으로써 91%의 인식률을 얻었다. 참고로 학습용 영상의 선정시 기준의 방법을 사용할 경우, 얻을 수 있는 최대 인식률은 신경회로망 분류기에 의한 83.5%이다. 한편 사람수를 축소하여 실험해 본 결과 5명인 경우에 대해서는 100%의 인식률을 나타내었는데, 이는 본 고유얼굴 방법이 추가의 개선없이도 가정과 같은 소규모 집단의 보안 시스템으로 실용화할 수 있음을 나타낸다.

향후 연구과제로는 사람수의 증가에 따른 인식률 저하 문제에 대한 것과 학습용 샘플영상의 효과적인 선정 방법의 개발이 있으며, 보안 시스템에서 주로 사용되는 무표정 정면얼굴에 대한 고유얼굴 기법의 성능 분석 및 인식률 개선 연구가 필요하다.

접수일자 : 2001. 1. 10

수정완료 : 2001. 3. 23

참고문헌

- [1] R. Chellappa, C.L. Wilson and S. Sirohey, "Human and Machine Recognition of Faces : A Survey", Proc. of The IEEE, Vol. 83, No. 5, pp. 705-740, May 1995.
- [2] A. Samal and P.A. Lyengar, "Automatic Recognition and Analysis of Human Faces and Facial Expressions : A Survey", Pattern Recognition, Vol. 25, No. 1, pp. 65-77, 1992.
- [3] S. Lawlence, C.L. Giles, A.C. Tsoi, and A. D. Back, "Face Recognition : A Convolutional Neural-Network Approach", IEEE Trans. on Neural Network, Vol. 8, No. 1, pp. 98-113, 1997.
- [4] R. Brunelli and T. Poggio, "Face Recognition : Features versus Templates", IEEE Trans. on PAMI, Vol. 15, No. 10, pp. 1042-1052, Oct. 1993.

- [5] S. Akanatsu, T. Sasaki, H. Fukamachi and N. Masui, "An Accurate and Robust Face Identification Scheme", IEEE ICIP, pp. 217-220, 1992.
- [6] M. Kirby and L. Sirovich, "Application of the Karhunen-Loeve Procedure for the Characterization of Human Faces", IEEE Trans. on PAMI, Vol. 12, No. 1, pp. 103-108, 1990.
- [7] M. Turk and A. Pentland, "Eigenface for Recognition", J. Cognitive Neuroscience, vol.3, pp. 71-86, 1991.
- [8] A. Pentland, T. Starner, N. Etocoff, A. Masoiu, O. Oliyide, and M. Turk, "Experiments with Eigenfaces", IJCAI '93, Chambery, France, 1993.
- [9] Markus Grob, Visual Computing, Springer-Verlag, 1994.
- [10] A.K. Jain, Fundamentals of Digital Image Processing, Prentice Hall, 1989.



박종조(Joong Jo Park)

正會員

1981년 고려대학교 전기공학과 졸업
(공학사)

1983년 고려대학교 전기공학과 졸업
(공학석사)

1995년 고려대학교 전기공학과 졸업
(공학박사)

1996년~현재 경상대학교 전기전자공학부 부교수
관심분야 : 컴퓨터비전, 생체인식.



김경민(Kyoung Min Kim)

正會員

1988년 고려대학교 전기공학과 졸업
(공학사)

1991년 고려대학교 전기공학과 졸업
(공학석사)

1996년 고려대학교 전기공학과 졸업
(공학박사)

1997년~현재 여수대학교 전기공학과 조교수
관심분야 : 컴퓨터비전, 퍼지 및 신경회로망 응용.