

論文98-35C-10-6

## 독립 성분 분석을 이용한 얼굴인식

(Face recognition by using independent component analysis)

金鐘圭\*, 張珠錫\*\*, 金榮一\*\*\*

(Jong-Kyu Kim, Ju-Seog Jang, and Young-Il Kim)

## 요약

신호처리 분야에서 미지의 신호원 분리에 주로 응용되는 독립 성분 분석법을 이용하여 얼굴인식을 할 수 있는 한 방식을 제안하였다. 하나의 얼굴영상 자체가 통계적으로 서로 독립인 어떤 미지의 특징영상의 합으로 표현될 수 있다고 가정하고 이 특징영상을 독립성분분석을 이용하여 구한 후, 새로운 얼굴이나 변화된 얼굴을 특징영상의 공간에 투영시켜 투영된 성분을 기준 얼굴영상과 비교하는 방법으로 인식을 수행하였다. 변화가 심한 여러 얼굴영상으로 구성된 데이터베이스(한 사람 당 10개씩의 변화된 400개의 얼굴 영상)에 대해 얼굴인식 실험을 수행하였고 또한 주성분 분석에 기초한 고유얼굴을 이용한 인식률과 비교 분석하였다. 제안된 방식은 주성분 분석법에 비해 높은 인식률을 제공하며, 특히 입력 얼굴 영상에 첨가되는 랜덤 잡음에 대단히 강한 특성을 갖는다.

## Abstract

We present a method that can recognize face images using independent component analysis that is used mainly for blind sources separation in signal processing. We assumed that a face image can be expressed as the sum of a set of statistically independent feature images, which was obtained by using independent component analysis. Face recognition was performed by projecting the input image to the feature image space and then by comparing its projection components with those of stored reference images. We carried out face recognition experiments with a database that consists of various varied face images (total 400 varied facial images collected from 10 per person) and compared the performance of our method with that of the eigenface method based on principal component analysis. The presented method gave better results of recognition rate than the eigenface method did, and showed robustness to the random noise added in the input facial images.

## I. 서론

기계가 사람얼굴을 인식할 수 시스템을 구현하는 것

\* 正會員, 蓮庵工業大 電子科

(Dept. of electronics Yonam College of Eng.)

\*\* 正會員, 釜慶大學校 情報通信工學科

(Dept. of Telematics Eng., Pukyong Nat'l Univ.)

\*\*\* 正會員, 慶尙大學校 電子工學科

(Dept. of electronics, Kyeongsang Nat'l Univ.)

接受日字:1998年4月20日, 수정완료일:1998年9月21日

은 실생활에 대단히 유용하고 편리한 수단을 제공한다. 예를 들면 얼굴인식은 관공서나 은행 같이 보안이 아주 중요시되는 주요 기관의 보안 시스템, 출입국 관리 소나 경찰서 등에서의 범죄자 신원확인 시스템, 신분증이나 여권 등의 사진인식 시스템 등 여러 분야에 매우 다양하게 응용된다. 특히 지문인식, 화자인식, 홍채 인식 등과 함께 얼굴인식은 보안시스템의 주된 요소로서 중요성이 커지고 있다. 과거 수십년 동안 공학적으로 얼굴인식에 관한 연구가 꾸준히 진행되어 왔는데 심리학, 신경과학 등의 분야에서도 공학과는 독립적으

로 인간은 사람 얼굴을 어떻게 인식하는가라는 문제에 대해 수많은 연구가 되어 왔다. 효율적인 얼굴인식을 위해 신경과학에서의 뇌 연구결과를 이용하기도 한다. 즉, 포유동물의 시각체계에서의 정보처리 방법을 공학적으로 활용하여 신경회로망적으로 인식 시스템을 구현하는 연구도 많이 되고 있다. 그러나 얼굴영상은 인식하고자 하는 대상이 거의 비슷하고 시간이 지남에 따라 서서히 변화하는 특징을 갖고 있기 때문에 그것들을 정확하게 인식하는데는 많은 어려움이 있다.

얼굴영상 인식 기술은 크게 얼굴 영역의 분리, 얼굴의 특징 추출, 그리고 분류의 세 과정으로 구성된다.<sup>[1]</sup> 이 중에서 특징추출은 패턴인식 분야의 오래된 문제이면서 가장 근본적이고 또한 가장 중요한 문제이다. 따라서 효과적인 특징추출은 패턴인식 문제를 해결하는 열쇠가 된다. 얼굴영상의 특징은 경계선, 등고선, 영상 영역 등의 시각적 특징,<sup>[2]</sup> 히스토그램, 모멘트 등의 통계적 특징,<sup>[3]</sup> 푸리에변환 등의 변환 계수적 특징,<sup>[4]</sup> 주성분 분석법(principal component analysis, PCA), 특이값 분해법 등의 대수적 특징<sup>[5-8]</sup>으로 나누어진다.<sup>[8]</sup> 이 중에서 대수적 특징의 하나인 고유벡터(즉, 고유얼굴)를 이용한 방식<sup>[5-7]</sup>이 최근에 주목을 받고 있다. 이 방법은 고유얼굴 특징을 구하는 것이 매우 단순할 뿐만 아니라 이 단순성에 비해 비교적 높은 인식률을 제공한다. 또한 이 방식은 입력 데이터의 2차 통계량(분산)에 의한 직교기저함수로 데이터를 표현하기 때문에, 가우시안 분포를 갖는 데이터에 대해서는 데이터에 함유된 고유의 특징을 잃지 않으면서 선형 변환하거나 낮은 차원으로 변환시킬 때 최적의 변환방식을 제공한다. 그러나 얼굴영상은 비 가우시안 분포이면서 고계 통계량을 많이 포함하고 있기 때문에, PCA를 이용하여 얼굴영상을 낮은 차원으로 변환하는 것은 그다지 유용하지 않다.

한편 1980년대 이후 신호처리분야에서 통계적으로 상호 독립인, 숨겨진 신호를 찾아내는 문제에 주로 응용되는, 독립성분 분석법(independent component analysis, ICA)이 연구되어 왔다.<sup>[13-16]</sup> ICA는 PCA의 유용한 확장으로서, 측정 데이터의 고계 통계량으로 정의되는 오차함수(error function)의 극대 혹은 극소 값을 찾음으로써 구해진다. 이를 위해 신경회로망 방식을 포함하여 여러가지 효과적인 학습알고리즘이 개발되었다.<sup>[17-22]</sup>

본 논문에서는 ICA 방법을 이용하여 얼굴영상의 특

징을 추출하고, 이를 얼굴인식에 효과적으로 사용할 수 있음을 처음으로 보였다. 독립된 여러 영상의 합으로부터 각각의 영상을 분리하는 기존의 응용과는 달리, 본 논문에서는 하나의 얼굴영상 그 자체가 통계적으로 서로 독립인 어떤 미지의 영상(특징 영상)의 합으로 표현될 수 있다고 가정하고 이 미지의 특징영상을 ICA를 이용하여 구한다. 그리고 새로운 얼굴이나 변형된 얼굴을 특징영상 공간으로 투영시켜 그 성분을 기존 얼굴영상의 것과 비교하는 방법으로 인식을 수행한다.

이 방법의 유용성을 살펴보기 위해 PCA에 의한 얼굴인식과 비교 분석하였다. 객관성 확보를 위해 Cambridge 대학의 Olivetti 연구실(Olivetti Research Laboratory: ORL)의 얼굴영상 데이터베이스를 모의 실험에 사용하였다.

## II. 독립성분 분석(ICA)

### 1. ICA의 정의 및 사용 예

ICA란 관측된  $M$ 개의 랜덤 변수를 통계적으로 독립인  $N$ 개의 랜덤변수들의 선형 합으로 표현해 내는 것이라고 정의할 수 있다. 통계적으로 상호 독립인 랜덤변수 각각은 시불변 확률과정(stationary stochastic process)이고 기껏해야 한 개의 랜덤변수 만이 가우시안 분포를 가질 때에만 ICA가 가능하다.

관측한 랜덤변수의 개수  $M$ 이 통계적으로 상호 독립인 랜덤변수의 개수  $N$ 보다 크거나 같으면 관측한 랜덤변수로부터 통계적으로 상호 독립인 랜덤변수를 추출할 수 있다. 이것을 숨은 신호원 분리(blind sources separation)라고 한다. 즉, ICA는 이미 알고 있는 신호원(랜덤변수)들이 통계적으로 서로 독립이고 이들이 어떤 가중치로 서로 섞여서 관측될 때, 섞여진(따라서 숨은) 신호의 관측된 값으로부터 본래의 신호나 그 가중치를 찾아내는데 활용되고 있다. 예를 들면 안구 운동이나 근육의 활동 등으로 뇌파신호가 왜곡되어(즉 중첩되어) 관측되는데 이 왜곡된 뇌파신호로부터 의미있는 뇌의 활동정보를 분리하거나,<sup>[23]</sup> 혼합된 음성신호로부터 원래의 음성신호를 분리하거나,<sup>[24]</sup> 여러 영상의 합성영상으로부터 원래의 영상을 분리하는 문제<sup>[25]</sup> 등에 ICA가 응용되고 있다. 또 특징추출에도 사용되는데<sup>[26]</sup> 이때에는 선형결합 상수계수들이 특징이 된다.

2. 독립성분의 계산 : Hyvarinen 과 Oja의 알고리즘 상호 독립인  $N$ 개의 신호원 즉 랜덤과정  $s_1(t), s_2(t), \dots, s_N(t)$ 가 있고 이들이 각각 평균값이 0인 신호를 발생시킨다고 하자. 이들 신호원을 시각  $t=k$  ( $k=1, 2, \dots$ )에서 관측(측정 또는 샘플링)한 값들을 확률변수  $s_1(k), s_2(k), \dots, s_N(k)$  라 두자. 만약 이 신호원들이 섞여서 관측될 때  $i$ 번째 장소에서 시각  $k$ 에서의 관측된 신호  $x_i(k)$ 는

$$x_i(k) = \sum_{j=1}^M a_{ij} s_j(k) + n_i(k) \quad (1)$$

로 나타낼 수 있다. 여기서  $a_{ij}$ 는 선형결합 가중치이고  $n_i$ 는  $i$ 번째 장소에서의 잡음신호이다. (1)식을 행렬의 형태로 바꾸면

$$\mathbf{x}(k) = \mathbf{A} \mathbf{s}(k) + \mathbf{n}(k) \quad (2)$$

가 된다. 여기서  $\mathbf{x}(k) = [x_1(k) \ x_2(k) \ \dots \ x_M(k)]^T$ 는 주어진  $M$ 차원 벡터이고,  $\mathbf{s}(k) = [s_1(k) \ s_2(k) \ \dots \ s_N(k)]^T$ 는 추정하고자 하는 미지의  $N$ 차원 벡터이며 행렬  $\mathbf{A} = [a_{ij}]$ 는 신호의 결합을 나타내는 알고자하는 상수 행렬이다. 역행렬  $\mathbf{T}$ 는 행렬이나 벡터의 전치를 의미한다.

$\mathbf{A}$ 와  $\mathbf{s}$ 를 유일하게 ( $\pm$ 부호는 생각하지 않음) 결정하기 위해  $E\{s_i^2\}$ 는 모든  $i$ 에 대해 1로 둔다. 여기서  $E\{\cdot\}$ 는 기대값을 의미한다. 따라서

$$E\{\mathbf{s} \mathbf{s}^T\} = \mathbf{I} \quad (3)$$

이고, 또 앞의 가정으로부터  $E\{s_i\} = 0$ 이다. 여기서  $\mathbf{I}$ 는 단위행렬이다. 일반적으로  $M$ 개의 측정 장소마다 서로 독립인 잡음이 발생하면 신호원으로부터 잡음을 구분해 내는 것은 불가능하다. 만약 이들 잡음이 서로 종속이라면 잡음도 1개의 신호처럼 생각하여  $\mathbf{s}$ 에 포함시킬 수 있으므로 식(2)에서  $\mathbf{n}(k)$ 는 생략한다.

Hyvarinen과 Oja의 알고리즘에서는 관측된 신호로부터 통계적으로 상호독립인 신호원을 추정하기 위해서 다음 식과 같은 신호의 커토시스(kurtosis)

$$\text{kurt}\{s_i\} = E\{s_i^4\} - 3[E\{s_i^2\}]^2 \quad (4)$$

를 이용한다. 식 (4)에서 시각  $k$ 는 편의상 생략되었다. 랜덤변수  $s_i$ 가 가우시안이면 커토시스는 0이 되고,  $s_i$

의 확률밀도함수가 0부근에서 가우시안 분포 보다 뽀족한 분포를 가지면 커토시스 값은 양수가 되며, 가우시안 분포보다 평탄하면 커토시스 값은 음수가 된다. 그리고 비 가우시안의 랜덤 변수가 합해지면 그들의 합은 가우시안에 가까워지므로 이들 합의 랜덤 변수의 커토시스는 0에 가까워진다.

이러한 가정과 사실로부터, 주어진  $\mathbf{x}$ 에 대해  $\mathbf{s}$ 와  $\mathbf{A}$ 를 구하는 절차는 다음과 같다. 먼저  $\mathbf{x}$ 를 적절한  $M \times M$  행렬  $\mathbf{M}$ 을 사용하여  $\mathbf{v}$ 로 선형 변환한다. 즉  $\mathbf{v} = \mathbf{M}\mathbf{x}$ 이다. 이 때  $\mathbf{M}$ 은

$$E\{\mathbf{v} \mathbf{v}^T\} = \mathbf{I} \quad (5)$$

가 되게 하는 행렬이다. 이러한  $\mathbf{M}$ 은 항상 존재하는데 PCA를 이용하여 얻는다. 즉  $\mathbf{x}$ 의 공분산 행렬을  $\mathbf{C} = E\{\mathbf{x} \mathbf{x}^T\}$ 라 하자. 또  $\mathbf{C}$ 의 고유값을 크기 순서대로  $\lambda_1, \lambda_2, \dots, \lambda_M$ , 이 고유값에 대응하는 고유벡터를  $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_M$ 이라 두자. 이때  $\mathbf{e}_i^T \mathbf{e}_j = \delta_{ij}$ 가 성립한다. 여기서  $\delta_{ij}$ 는 kronecker delta이다. 이 고유벡터를 병치한 행렬을  $\mathbf{G} = [\mathbf{e}_1 \ \mathbf{e}_2 \ \dots \ \mathbf{e}_M]$ 이라 하고 고유값을 대각선 요소 값으로 하는 대각행렬을  $\mathbf{D}$ 라 하자. 그러면 행렬  $\mathbf{M}$ 은

$$\mathbf{M} = \mathbf{D}^{-1/2} \mathbf{G}^T \quad (6)$$

가 된다.  $\mathbf{D}^{-1/2}$  역시 대각행렬이고  $i$ 번째 대각선 요소는  $1/\sqrt{\lambda_i}$ 이다.

이  $\mathbf{v}$ 로부터  $\mathbf{s}$ 를 구한다.  $\mathbf{v}$ 와  $\mathbf{s}$ 와의 관계를  $M \times N$  행렬  $\mathbf{B}$ 로 나타내자. 그러면  $\mathbf{v} = \mathbf{B}\mathbf{s} = \mathbf{M}\mathbf{A}\mathbf{s}$ 이다. 식 (3)과 (5)에서  $E\{\mathbf{v} \mathbf{v}^T\} = \mathbf{I} = E\{(\mathbf{B}\mathbf{s})(\mathbf{B}\mathbf{s})^T\} = \mathbf{B}E\{\mathbf{s} \mathbf{s}^T\}\mathbf{B}^T = \mathbf{B} \mathbf{B}^T$ 이므로  $\mathbf{B}$ 는 일반적으로 직교행렬이 된다. 이러한  $\mathbf{B}$ 를 구하기 위해 커토시스를 사용한다.  $\mathbf{v}$ 는 여전히  $\mathbf{s}$ 들의 합이므로  $\text{kurt}(\mathbf{v})$ 를 계산하면 0에 가깝다. 이때  $\text{kurt}(\mathbf{w}^T \mathbf{v})$ 가 극대 혹은 극소값이 되도록 하는 어떤  $M$ 차원 벡터  $\mathbf{w}$ 를 찾는다.

$\|\mathbf{w}\|$ 는 고정된 값이어야 하며  $\|\mathbf{w}\| = 1$ 로 둔다. 어떤 하나의 극값을 주는  $\mathbf{w}$ 를 찾았다면  $\mathbf{w}^T \mathbf{v} = \pm s_i$  (어떤 한 개의 비 가우시안 분포를 갖는  $s_i$ )가 될 것임을 예측할 수 있다. 그리고 식(4)의 정의에서  $\text{kurt}(c_1 s_i + c_2 s_j) = c_1^4 \text{kurt}(s_i) + c_2^4 \text{kurt}(s_j)$ 의 성질이 있으므로 ( $c_1$ 과  $c_2$ 는 임의의 상수)  $\text{kurt}(\mathbf{w}^T \mathbf{v})$

$= \text{kurt}\{\mathbf{w}^T \mathbf{B} \mathbf{s}\} = \text{kurt}\{\mathbf{z}^T \mathbf{s}\} = \sum_{i=1}^N z_i^4 \text{kurt}\{s_i\}$  가 된다. 따라서  $\text{kurt}\{\mathbf{w}^T \mathbf{v}\}$ 는 여러 개의 극대 또는 극소값을 가지며 각각의 극값에 대응되는  $\mathbf{w}$ 가 있음을 알 수 있다. 만약  $\mathbf{w}^T \mathbf{v} = s_i$ 인  $\mathbf{w}$ 를  $\mathbf{w}_i$ 라 하면  $\mathbf{w}_i^T \mathbf{B} \mathbf{s} = \mathbf{z}_i^T \mathbf{s} = s_i$ 이다. 이때의  $\mathbf{z}_i$ 는  $i$ 번째 요소가 1이고 나머지가 0인 벡터가 된다. 그러면  $\mathbf{B} \mathbf{B}^T = \mathbf{I}$ 이므로  $\mathbf{w}_i = \mathbf{B} \mathbf{z}_i$ 가 되어 결국  $\mathbf{w}_i = \mathbf{b}_i$ 로 된다. 여기서  $\mathbf{b}_i$ 는 행렬  $\mathbf{B}$ 의  $i$ 번째 열벡터이다.

커토시스의 극대 혹은 극소값을 주는  $\mathbf{w}$ 들은 최대경사하강(상승)법으로부터 임의의 초기값  $\mathbf{w}(t=0)$ 에 대해

$$\mathbf{w}(t+1) = \mathbf{w}(t) \pm \eta \{ \mathbf{v}(t) [\mathbf{w}(t)^T \mathbf{v}]^3 - 3 \|\mathbf{w}(t)\|^2 \mathbf{w}(t) + f(\|\mathbf{w}(t)\|^2) \mathbf{w}(t) \} \quad (7)$$

를 얻게 된다. 식 (7)에서  $f$ 는  $F$ 의 도함수이고  $+$ 와  $-$ 는 각각 최대경사 상승과 하강을 의미한다.  $\mathbf{w}$ 의 변화가 없는 지점이 찾고자 하는  $\mathbf{w}$ 이며 이 때에는 식 (7)의 우변 2번째 항이 0일 때이다. 따라서

$$E\{ \mathbf{v}(\mathbf{w}^T \mathbf{v})^3 \} - 3 \|\mathbf{w}\|^2 \mathbf{w} + f(\|\mathbf{w}\|^2) \mathbf{w} = 0 \quad (8)$$

을 만족하는  $\mathbf{w}$ 를 찾으면 된다. 그런데  $f(\|\mathbf{w}\|^2)$ 은 임의의 상수이므로

$$\mathbf{w} = \text{scalar} \times [E\{ \mathbf{v}(\mathbf{w}^T \mathbf{v})^3 \} - 3 \|\mathbf{w}\|^2 \mathbf{w}] \quad (9)$$

이다.  $\|\mathbf{w}\| = 1$ 이 되어야 한다는 조건이 있으므로 scalar는 중요하지 않다. 식 (9)를 만족하는  $\mathbf{w}$ 를 찾는 것이 바로 Hyvarinen 과 Oja의 고정점 알고리즘으로서 다음과 같이 요약할 수 있다.

1. 임의로  $\mathbf{w}(0)$ 를 정한다. 단  $\|\mathbf{w}(0)\| = 1$ 이 되도록 한다. 또 시간  $k=1$ 로 둔다.

2.  $\mathbf{w}(k+1) = E\{ \mathbf{v}(\mathbf{w}(k)^T \mathbf{v})^3 \} - 3 \mathbf{w}(k)$ 를 계산한다. 기대값  $E$ 는 충분히 많은  $\mathbf{v}$ 에 대해 추산한다.

3. 만약 이미 알고 있는  $\mathbf{b}_i$ 가 있다면, 이들  $\mathbf{b}_i$ 들을 병치한 행렬을  $\mathbf{B}$ 라고 하자. 그러면 2에서 구한

$\mathbf{w}(k+1)$ 을  $\mathbf{w}(k+1) = \mathbf{w}(k+1) - \mathbf{B} \mathbf{B}^T \mathbf{w}(k+1)$ 로 바꾼다.

4.  $\mathbf{w}(k+1)$ 을  $\|\mathbf{w}(k+1)\| = 1$ 이 되도록 정규화한다.

5. 만약  $|\mathbf{w}(k+1)^T \mathbf{w}(k)|$ 이 1에 충분히 가깝지

않으면  $k$ 를 하나 증가시키고 2번 이후 의 과정을 반복한다. 만약 이 값이 1에 충분히 가까우면  $\mathbf{w}(k+1)$ 을 출력한다.

맨 처음에는 3번 과정이 필요 없다. 그러나  $\mathbf{w}$ 가 1개 구해지면,  $\mathbf{w}_1 = \mathbf{b}_1$ 이 되고 두 번째  $\mathbf{b}_2$ 는  $\mathbf{b}_1$ 과는 수직인 새로운 것을 찾아야 하므로 3번 과정이 필요하게 된다.  $\mathbf{B}$ 가 완전히 구해지면  $\mathbf{A} = \mathbf{M}^{-1} \mathbf{B}$  및  $\mathbf{s} = \mathbf{B}^T \mathbf{v}$ 로부터  $\mathbf{A}$ 와  $\mathbf{s}$ 를 찾게 된다.

### 3. 얼굴인식

$K$ 개의 화소를 갖는  $M$ 개의 얼굴영상이 있다고 하자.  $i$ 번째 얼굴영상을  $f_i(k)$ 로 표현할 수 있다. 여기서  $k=1, 2, \dots, K$  이고  $k$ 는 시간이 아닌 공간적인 위치이다.  $f_i(k)$ 는  $i$ 번째 얼굴영상을  $k$ 번째 위치에서 샘플링한 밝기를 의미한다. 이제부터 평균이라든지 기대값  $E\{\cdot\}$ 의 의미는 이 공간영역  $k$ 에 대해서 수행된다. 얼굴영상은 영상의 밝기 값을 수치화한 것이므로 평균

$E\{f_i(k)\} = \bar{f}_i = \frac{1}{K} \sum_{k=1}^K f_i(k)$  는 0이 아니다. 이때 얼굴영상에서 자신의 평균값을 뺀 것을  $x_i(k) = f_i(k) - \bar{f}_i(k)$ 로 두자. 우리가 관측하는  $M$ 개의 얼굴영상은

알지 못하는  $N(N \leq M)$ 개의 서로 독립이고 분산이 1인 특징얼굴  $s_j(k), k=1, 2, \dots, N$  의 선형 합으로 구성되어 있다고 간주한다. 그러면  $x_i$ 와  $s_j$  역시 식(1) 또는

식(2)와 같이 표현할 수 있다.  $n_i(k)$ 는 생략한다. 따라서 2.2절에서 기술한 방법을 이용하여  $M$ 개의  $s_j(k)$ 와  $\mathbf{A}$ 를 구할 수 있다. 그런데  $x_i(k)$ 나  $s_j(k)$  그 자체를  $K \times 1$  차원의 벡터로 표현할 수 있으므로 이들을 각각  $\mathbf{x}_i$  및  $\mathbf{s}_j$ 로 표현하기로 한다. 그리고  $\mathbf{x}_i$ 를 병치한 행렬을  $\mathbf{X} = [\mathbf{x}_1 \mathbf{x}_2 \dots \mathbf{x}_M]$ 이라 하고  $\mathbf{s}_j$ 를 병치한

행렬을  $\mathbf{S} = [\mathbf{s}_1 \mathbf{s}_2 \dots \mathbf{s}_N]$ 이라 두자. 그러면 식(2)는  $\mathbf{X} = \mathbf{S} \mathbf{A}^T$ 가 되고,  $E\{s_i s_j\} = \delta_{ij}$ 이므로  $\mathbf{S}^T \mathbf{S} = \mathbf{K} \mathbf{I}$ 가 된다. 따라서  $\mathbf{S} / \sqrt{K} = \mathbf{U}$ 라하고  $\sqrt{K} \mathbf{A}^T = \mathbf{Q}$ 라 두면  $\mathbf{U}^T \mathbf{U} = \mathbf{I}$ 이므로  $\mathbf{X} = \mathbf{U} \mathbf{Q}$ 가 된다. 즉,

$$\mathbf{Q} = \mathbf{U}^T \mathbf{X} \quad (10)$$

이다.  $\mathbf{Q}$ 의  $i$ 번째 열벡터를  $\omega_i$ 라 두면 식(12)로부터  $\omega_i$ 는 얼굴영상  $\mathbf{x}_i$ 를  $N$ 개의 독립성분을 갖는 특징행렬  $\mathbf{U}$ 에 투영한 성분벡터가 된다.

$\mathbf{Q}$ 를 구할 때 사용한 얼굴영상(학습영상)이 아닌 변

화된 다른 어떤 얼굴영상  $x_{in}$ 이 있다고 하자. 식(12)로부터  $w_{in} = U x_{in}$ 을 구하고  $w_{in}$ 과 가장 비슷한  $w_i$ 를 찾는다. 즉,  $\min_i(\|w_i - w_{in}\|)$ 를 계산하여 이때의  $i$ 를 구하면  $x_{in}$ 은  $i$ 번째 얼굴임을 알 수 있다. 인식률을 높이기 위해서 한 사람 마다 여러 가지로 변화된 얼굴영상을 학습영상으로 사용할 수 있다. 또 학습되지 않은 영상을 가려내기 위해  $\|w_i - w_{in}\|$ 에 어떤 한계 값을 두어 이 값보다 작은  $w_i$ 가 없으면 학습되지 않은 모르는 얼굴영상이라고 간주할 수 있다.

### III. 얼굴인식에 대한 컴퓨터 실험

#### 1. 학습얼굴과 ICA에 의해 추출된 특징얼굴

얼굴인식 실험에 사용된 ORL 데이터베이스는 40명의 남녀에 대해 1사람 당 10개씩의 변화된 얼굴영상으로 구성되어 있다. 본 실험에서는 1사람 당 5개의 얼굴영상은 학습에 사용하고 나머지 5개씩은 시험영상으로 사용하였다. 그림 1은 학습얼굴영상의 일부이다. 200개의 학습얼굴에 대해서 ICA를 사용하여 추출한 독립성분을 본래의 얼굴영상처럼 재배열한 특징얼굴의 모습은 그림 2와 같다. 일반적으로 200개의 학습영상은 서로 다르므로 특징얼굴도 200개가 존재하나 학습된 사람의 수가 40명이므로 독립된 성분도 40개라 간주하고 특징얼굴을 구하였다.(가정한 독립성분의 개수가 작을 수록 인식률은 나빠진다.)




그림 1. 학습얼굴영상의 일부  
Fig. 1. Part of the training facial images.




그림 2. ICA에 의해 얻어진 40개의 특징얼굴  
Fig. 2. The forty feature facial images obtained from ICA.

이러한 특징얼굴에는 학습얼굴의 윤곽이 희미하게 일부 포함되어 있으면서 여러 가지 형태의 명암패턴이 나타나 있다. 특히 그림 2의 첫째 줄 맨 오른쪽과 셋째 줄의 세 번째 특징얼굴에는, 주 시각 피질의 단순 세포(simple cell)의 수용영역(receptive field)의 패턴과 비슷한 길쭉한 Gabor 필터 형태가 존재한다.<sup>[27]</sup> 또 눈이나 눈썹, 입 같은 특정 부위가 다른 부분보다 훨씬 선명하게 특징적인 모습으로 나타나기도 한다. 그림 2의 밑에서 세 번째 줄 맨 오른쪽 특징얼굴은 눈 혹은 안경을 나타내는 것이라 볼 수 있고, 맨 아래 줄의 세 번째 특징얼굴은 눈썹을 나타내는 것이라고 볼 수 있다. 이러한 특징얼굴 패턴은 원숭이의

측두엽(inferior temporal: IT)영역에 있는 세포들의 수용영역과 정성적으로 닮아 있다.<sup>[28]</sup> 물론 특징얼굴은 서로 직교하며 명암의 반전은  $\pm s_i$ 를 생각하면 의미가 없다.

2. 실험결과

가. 인식률

ORL 데이터베이스의 200개의 얼굴영상(학습얼굴)에 대해 그림 2와 같은 특징얼굴을 구한 후, 학습얼굴을 특징얼굴에 투영시킨  $\omega_i$  벡터와 나머지 학습되지 않은 200개의 시험영상을 특징얼굴에 투영시킨  $\omega_m$  벡터와의 유클리드 거리를 계산하여 얼굴인식을 수행하였다. 그 결과 92.5%의 인식률을 얻었다. 그리고 이 방법을 고유얼굴 방법과 비교하기 위해 동일한 얼굴영상 데이터베이스를 동일한 조건으로 사용하여 참고문헌 [5]에 따라 특징얼굴인 고유얼굴을 구한 다음, 이를 이용하여 인식 실험을 수행하였다. 고유값이 가장 큰 40개의 고유얼굴을 이용한 경우(PCA) 인식률이 83.5%였고 더 많은 고유얼굴을 이용하여도 인식률은 더 높아지지 않았다. 이렇게 인식률이 낮은 것은 시험영상의 변화가 심하기 때문이다. 그럼에도 불구하고 본 논문에서 제시한 ICA를 이용한 얼굴인식 방법이 PCA를 이용한 얼굴인식 방법 보다 인식률에 있어서 크게 우수함을 알 수 있다.




그림 3. 학습 영상의 그룹에 대한 거리비  $\min(d_b) / d_w$   
 Fig. 3. Distance of  $\min(d_b) / d_w$  for number of class.

ICA를 이용한 방식이 더 높은 인식률을 제공하는 이유를 살펴보기 위해 얼굴영상들의  $\omega$  벡터에 대한 거

리를 비교하였다. 즉, 한 사람 당 5개의 얼굴로 그룹 되어진 학습얼굴에 대해 각 그룹에 속한 학습얼굴들 간의  $\omega_i$  벡터의 평균 거리를  $d_w$ 로 두고 특정 그룹과 타 그룹 간의  $\omega_i$  벡터의 최소거리를  $\min(d_b)$ 라 할 때  $\min(d_b) / d_w$ 는 그림 3과 같이 된다. 40개의 학습 그룹에 대해 PCA의 경우는 이 거리비가 전체적으로 낮은 값을 유지하고 있으나 ICA의 경우는 훨씬 더 큰 값을 유지하고 있음을 알 수 있다. 즉 ICA를 이용함으로써 얼굴영상의 군집화가 더 잘 이루어지는 것을 알 수 있다.

나. 특징얼굴의 개수

특징얼굴의 개수가 많을수록 인식과정에서의 패턴매칭의 수가 많아지므로 적절한 개수의 특징얼굴로 한정하는 것이 필요하다. 그림 4는 독립성분의 개수가 최소 10개에서 최대 200개 라고 가정하고, 이에 따라 독립성분을 구한 다음 인식실험을 수행했을 때 얻은 오인식률이다. 그림에서 보는 바와 같이 특징얼굴의 개수는 학습얼굴에 이용한 사람수 정도라고 가정하면 충분하다고 할 수 있다.




그림 4. 특징얼굴의 개수에 따른 오인식률  
 Fig. 4. Error rate for various number of feature facial images(i.e., independent components).

다. 영상의 크기 변화

실질적인 경우 시험영상의 크기는 학습시의 영상의 크기와는 다소 달라질 수 있기 때문에 입력영상의 크기가 변화되었을 때의 인식률의 변화를 살펴보았다. 그림 5와 같이 PCA를 이용한 경우는 영상의 크기가 감소함에 따라 인식률이 대단히 급격하게 떨어지지만 ICA를 이용한 경우는 크기 변화에 다소 둔감하여 인식률이 완만하게 떨어지는 특성을 갖는다.




그림 5. 영상의 크기 변화에 따른 인식률  
Fig. 5. Correct recognition rate for various image sizes.

라. 영상의 위치 이동

이동된 영상에 대해서 얼마나 잘 인식할 수 있는가를 알기 위해 입력영상을 왼쪽으로, 위로 각각 2 픽셀씩 이동시키면서 인식실험을 하였다. 그 결과 그림 6과 같이 ICA와 PCA 두 방식 모두 약간의 영상 이동에 대해서도 인식률이 크게 떨어졌다. 그러나 이동된 영상에 대한 푸리에 변환은 이동 전 영상에 대한 푸리에 변환과 동일하므로 시험영상을 푸리에 변환한 후 인식과정을 수행함으로써 이러한 인식률 저하 문제를 해결할 수 있을 것이다.<sup>[29]</sup>




그림 6. 이동영상에 대한 인식률  
Fig. 6. Recognition rate for shifted images.

마. 영상의 밝기 변화

주위의 조명의 영향으로 입력 얼굴영상의 밝기가 크게 변화되어 영상의 콘트라스트가 나빠졌을 때 인식률에 어떤 영향이 있는지를 살펴보았다. 그림 7은 전체적으로 영상이 어두워진 모습을 보여주고 있다. 여기

서  $m$ 은 영상을 어둡게 하기 위해 곱해진 1보다 작은 상수이다. 실제적인 응용에서는 그림 7과 같은 형태의 어둡게 된 영상이 얼마든지 발생할 수 있다.

$m=1(\text{original})$     $m=0.9$     $m=0.8$     $m=0.7$     $m=0.6$



그림 7. 영상의 밝기가 변화된 얼굴 모습.  $m$ 은 영상의 밝기를 변화시키기 위한 승 수이다.

Fig. 7. The shape of facial images varied brightness.  $m$  is the multiplier to vary brightness of the images.




그림 8. 밝기가 변화된 영상에 대한 인식률  
Fig. 8. Recognition rate for images with varied brightness.

그림 8에서 보는 것과 같이 ICA를 이용한 경우는 입력 영상의 어두운 정도에 대해서 인식률의 변화가 적으나 PCA를 이용한 경우는 입력영상의 밝기에 아주 민감하게 반응함으로써 인식률이 크게 저하되었다. ICA를 이용한 방식이 PCA를 이용한 경우 보다 입력영상의 밝기 변화에 둔감한 이유를 좀 더 자세히 살펴 보기 위해 시험영상과 학습영상 간의  $\omega_i$  벡터에 대한 거리 비를 비교하였다. 즉, 임의의 시험영상에 대한  $\omega_{in}$  벡터와 그 시험영상에 대응되는 학습영상 그룹의  $\omega_i$  벡터 사이의 최소 거리를  $d_1$ 이라 두고, 시험영상에 대한  $\omega_{in}$  벡터와 다른 학습영상 그룹의  $\omega_i$  벡터 사이의 최소 거리를  $d_2$ 라 할 때 모든 시험영상에 대하여 밝기 계수  $m$ 에 따른  $d_1/d_2$ 의 평균값을 그림 8에 나타내었다.  $d_1/d_2$ 가 1보다 크다는 것은 어떤 특정한 얼굴 영상과 어둡게 변화된 그 자신의 얼굴영상(시험영상)

사이의 유클리드 거리가 다른 사람의 얼굴영상과 시험 영상 사이의 유클리드 거리보다 더 크다는 것을 의미한다. 즉,  $d_1/d_2$ 가 1보다 크면 오인식됨을 의미한다. 그림 9에서 보는 바와 같이 ICA를 이용한 방식은 상당히 어렵게 변화된 영상에 대해서도  $d_1/d_2$  값은 1이하의 작은 값을 유지하지만 PCA의 경우는 영상이 약간만 어렵게 변화되어도  $d_1/d_2$  값이 1을 초과하게 되어 오인식을 하게 됨을 알 수 있다. PCA방식에서는 시험얼굴에서 학습얼굴의 전체 평균을 뺀 후 인식과정을 수행한다. 따라서 그림 7과 같이 시험얼굴이 학습된 원래의 얼굴에 비해 조명과 같은 DC값을 많이 포함되면, 학습얼굴 전체의 평균을 빼더라도 DC값이 남아 있기 때문에 인식과정 수행 시 오차가 커지게 된다. 이런 문제점을 해결하기 위해서 학습과정과 인식과정에서 학습얼굴 전체의 평균을 빼는 대신에 각각의 영상에서 자기자신의 평균을 미리 빼서 고유얼굴을 구하고 인식을 수행할 수도 있다. 그러나 이렇게 하면 영상의 밝기의 변화에는 둔감하지만 정상적인 시험영상에 대해서 인식률이 오히려 약간 떨어지는 새로운 문제점이 발생함을 볼 수 있었다.




그림 9. 승수  $m$ 에 대한  $d_1/d_2$ 의 평균값  
Fig. 9. Mean value of  $d_1/d_2$  for the multiplier  $m$ .

입력영상의 밝기가 부분적으로 변화되었을 때의 인식률을 살펴보았다. 이는 조명이 한쪽으로 치우칠 때 발생할 수 있는 상황을 염두에 둔 것이다. ORL 얼굴 데이터베이스에는 조명의 변화에 대한 영상이 없으므로 그림 10과 같이 인위적으로 밝기 분포의 부분적인 변화를 만들어서 시험하였다. 그림 10에서 집합 1은 정면 조명의 경우이고 집합 2는 조명이 오른쪽에 치우친 경우, 집합 3은 조명이 왼쪽에 치우친 경우, 집합

4는 조명이 위쪽에 치우친 경우를 각각 훑내낸 것이다. 그림 11에서와 같이 PCA를 이용한 경우는 이러한 변화에 대해 인식률이 크게 떨어져 거의 인식을 할 수 없는 상태이나 ICA를 이용한 경우는 조명의 변화에 대해 비교적 높은 인식률이 유지됨을 알 수 있다. 이것은 ICA의 알고리즘 수행 시 자신의 영상에 대한 평균값을 뺀 후 정규화하는 과정에 의해 조명의 영향이 감소되기 때문이다. 실제 조명의 경우는 그림자가 생겨나므로 단순히 밝기 분포의 변화만 가지고는 조명의 효과를 완전히 알 수는 없다. 따라서 실제로 조명 변화가 있는 데이터베이스를 가지고 조명에 대한 영향을 구체적으로 실험할 계획이다.

subset 1      subset 2      subset 3      subset 4



그림 10. 공간적으로 밝기의 부분적 변화를 갖는 얼굴 영상

Fig. 10. The shape of facial images with spatially varying lighting.




그림 11. 공간적으로 밝기 변화를 갖는 영상 대한 인식률

Fig. 11. Recognition rate for the images with spatially varying lighting.



#### 바. 잡음의 영향

잡음에 대한 강인성을 살펴보기 위해 평균값이 0이고 분산이 1인 가우시안 분포를 갖는 랜덤잡음의 정수 배를 입력영상에 첨가하였다. 표 1에서 보는 바와 같이 두 경우 모두 10dB 정도의 PSNR 영상에 대해서도 정상적으로 인식하는 잡음에 대단히 강한 인식 수단을 제공함을 알 수 있다. 주요 기관의 보안시스템 같은 실질적인 응용에 있어서는 CCD카메라 등을 통해 입력되는 영상은 주위가 어두워 졌을 때 아주 많은 잡음이 첨가될 수 있는데 이런 경우에 본 논문에서 제시한 ICA를 이용한 인식방식이 아주 유효할 수 있을 것이다.

표 1. 첨가된 잡음에 따른 오인식률 비교  
Table 1. Comparison of error rates when Gaussian noise are added.

PSNR	ICA	PCA
$\infty$	7.5%	16.5%
65	7.5%	16.5%
51	7.5%	16.5%
43	8.0%	16.5%
37	8.0%	17.0%
33	8.0%	17.5%
5	9.0%	19.0%

#### IV. 결 론

본 논문에서는 ICA를 이용하여 얼굴인식을 효과적으로 할 수 있는 새로운 방식을 제안하고 기존의 유사한 방식과 비교 분석하였다. 변화가 심한 여러 얼굴영상으로 구성된 ORL 데이터베이스에 대해 제안된 방식을 이용하여 인식실험을 한 결과 92.5%라는 인식률을 얻었는데 이는 PCA(고유얼굴)를 이용한 경우의 인식률 83.5%와 비교할 때 ICA는 상당히 높은 인식률을 제공함을 알 수 있다. 특히 제안된 ICA를 이용한 인식방식은 밝기 변화에 둔감하고 잡음에 대단히 강하기 때문에 잡음이 많이 함유되는 실질적인 응용에 대단히 유효할 것으로 생각된다. 학습이 이루어진 상태 하에서는 1명의 얼굴을 인식하는데 소요되는 시간은 펜티엄급 PC로 약 1초 정도 되었다.

그러나 92.5%라는 인식률은 만족할 만한 수준은 아니므로 더욱 높은 인식률을 갖게 하는 연구가 계속되

어야 할 것이다.

#### 참 고 문 헌

- [1] R. Chellapa, C. L. Wilson and S. Sirohey, "Human and machine recognition," *Proc. IEEE*, vol. 86, pp. 705-736, 1995.
- [2] O. Nakamura, S. Mathur and T. Minami, "Identification of human faces based on isodensity maps," *Pattern Recognition*, vol. 24, pp. 263-272, 1991.
- [3] C. H. Teh and R. T. Chin, "On image analysis by the method of moments," *IEEE Trans. Patt. Anal. Machine Intell.* vol. 10, pp. 496-513, 1988.
- [4] S. R. Dubois and F. H. Grantz, "A autoregressive model approach to two-dimensional shape classification," *IEEE Trans. Patt. Anal. Machine Intell.* vol. 8, pp. 56-65, 1986.
- [5] M. Turk and A. Pentland, "Eigenface for recognition," *J. Cognitive Neuroscience*, vol. 3, pp. 71-86, 1991.
- [6] A. J. O'Toole, H. Abdi, K. A. Deffenbacher and D. Valentin, "Low dimensional representation of faces in high dimensions of the face space," *J. Opt. Soc. Am. A*, vol. 10, pp. 405-411, 1993.
- [7] L. Sirovich and M. Kirby, "Low dimensional procedure for the characterization of human faces," *J. Opt. Soc. Am.* vol. 4, pp. 519-524, 1987.
- [8] Z. Q. Hong, "Algebraic feature extraction of images for recognition," *Pattern Recognition*, vol. 24, pp. 211-219, 1991.
- [9] Y. K. Ham, S. Y. Lee, and R. H. Park, "Knowledge-based face recognition using neural networks," in *Proc. Int. Joint Conf. Neural Networks*, Nagoya, Japan, pp. 2125-2128, 1993.
- [10] R. J. Baron, "Mechanisms of human facial recognition," *Int. J. Man Machine Studies*, vol. 15, pp. 137-178, 1981.
- [11] D. J. Burr, "Elastic matching of line drawing," *IEEE Trans. Patt. Anal.*

- Machine Intell.* vol. 3, pp. 1006-1015, 1981.
- [ 12 ] R. Brunelli and T. Poggio, "Face recognition: features versus templates," *IEEE Trans. Patt. Anal. Machine Intell.* vol. 15, pp. 1042-1052, 1993.
- [ 13 ] C. Jutten and J. Herault, "Blind separation of sources, part I" *Signal Processing*, vol. 24, pp. 1-10, 1991.
- [ 14 ] P. Common, "Independent component analysis, A new concept?," *Signal Processing*, vol. 36, pp. 287-314, 1994.
- [ 15 ] J.-F. Cardoso and B. Laheld, "Equivariant adaptive source separation," *IEEE Trans. Signal Processing*, vol. 44, pp. 3017-3030, 1996.
- [ 16 ] A. Bell and T. Sejnowski, "An information maximization approach to blind separation and blind deconvolution," *Neural Computation*, vol. 7, pp. 1129-1159, 1995.
- [ 17 ] A. Hyvarinen and E. Oja "A fast fixed-point algorithm for independent component analysis," *Neural Computation*, vol. 9, pp. 1483-1492, 1997.
- [ 18 ] A. Hyvarinen "A family of fixed-point algorithm for independent component analysis," Lab. of computer and information science, Helsinki Univ. of Technology, Report A40, 1996.
- [ 19 ] L. Wang, J. Karhunen, and E. Oja, "A bigradient optimization approach for robust pca, mca, and sources separation," Lab. of computer and information science, Helsinki Univ. of Technology, 1995.
- [ 20 ] E. Oja "The nonlinear pca learning rule and signal separation," Lab. of computer and information science, Helsinki Univ. of Technology, technical report A26, 1995.
- [ 21 ] E. Oja and J. Karhunen, "Signal separation by nonlinear hebbian learning," Lab. of computer and information science, Helsinki Univ. of Technology, 1996.
- [ 22 ] J. Karhunen, E. Ojal, L. Wang, R. Vigarior, and J. Joutsensalo, "A class of neural networks for independent component analysis," *IEEE, Trans. Neural Networks*, vol. 8, pp. 486-503, 1997.
- [ 23 ] R. Vigrario, A. Hyvarinen and E. Oja, "ICA fixed point algorithm in extraction of artifacts from EEG," *Proc. IEEE Nordic Signal Processing Symp.* pp. 383-386, 1996.
- [ 24 ] A. Bell and T. Sejnowski, "Learning higher-order structure of natural sound," *Network*, vol. 7, pp. 261-266, 1996.
- [ 25 ] H. W. Yang and S. Amari, "Adaptive online learning for blind separation : Maximum entropy and minimum mutual information," *Neural Computation*, vol. 9, pp. 1457-1482, 1997.
- [ 26 ] J. Hurri, A. Hyvarinen, J. Karhunen and E. Oja, "Image feature extraction using independent component analysis," *proc. of 1996 IEEE Nordic Signal Processing Symp., Espoo, Finland*, pp. 475-478, 1996.
- [ 27 ] A. B. Olshausen and D. J. Field, "Emergence of simple-cell receptive field properties by learning a sparse code for natural images," *Nature*, vol. 381, pp. 607-609, 1996.
- [ 28 ] C. G. Gross, "Representation of visual stimuli in inferior temporal cortex," *Phil. Trans. R. Soc. Lond. B* vol. 214, pp. 3-10, 1992.
- [ 29 ] 심영미, 장주석, 김종규, "Fourier 변환된 얼굴의 진폭스펙트럼의 Karhunen-Loeve 근사 방법에 기초한 변위 불변적 얼굴인식," *전자공학 회논문지 제35권 c편 제3호*, pp. 97-107, 1998

---

 저 자 소 개
 

---

金 鐘 圭(正會員) 第 34卷 C編 第 10號 參照  
 현재 연암공업대 교수. 주관심분야는  
 패턴인식, 음성신호 처리 등임

張 珠 錫(正會員) 第 34卷 C編 第 10號 參照  
 현재 부경대학교 정보통신공학과 조  
 교수. 주관심분야는 광정보처리, 광메  
 모리, 광패턴인식, 신경정보처리 모델  
 링 등임

金 榮 一(正會員) 第 34卷 C編 第 10號 參照  
 현재 경상대학교 전자공학과 교수. 주  
 관심분야는 음성신호처리, 실시간 디  
 지털신호처리 등임