

# 가버 텐서를 이용한 얼굴인식 성능 개선

정희원 박경준\*, 고형화\*\*

## Efficiency Improvement on Face Recognition using Gabor Tensor

Kyung-jun Park\*, Hyung-hwa Ko\*\* *Regular Members*

### 요약

본 논문은 가버 텐서(Gabor tensor)를 이용한 얼굴인식 시스템을 제안하였다. 가버 변환은 얼굴 고유의 특징을 잘 나타내주며 외부적인 영향을 줄일 수 있어 인식률 향상에 기여한다. 이러한 특징을 이용한 3차원의 텐서를 구성하여 얼굴인식을 수행하는 방법을 제안한다. 3차원의 가버 텐서를 입력으로 하여 기존의 1차원이나 2차원 주성분 분석법(PCA)보다 다양한 특징을 이용할 수 있는 다중선형 주성분 분석법(Multilinear PCA)를 수행한 다음 선형 판별법(LDA)을 수행하는 얼굴인식 방법을 제안하였다. 이러한 방법들은 표정이나 조명등의 변화에 강연한 특성을 가진다. 제안한 방법은 매트랩(Matlab)을 이용하여 실험하였다. ORL과 Yale 데이터베이스를 이용한 실험 결과를 기존의 방법들과 비교하였을 경우 제안한 방법이 기본적인 1차원 주성분 분석법보다 최대 9~27% 향상된 우수한 인식성을 나타낼 수 있었다.

**Key Words :** Face recognition, Gabor, Tensor, MPCA, LDA

### ABSTRACT

In this paper we propose an improved face recognition method using Gabor tensor. Gabor transform is known to be able to represent characteristic feature in face and reduced environmental influence. It may contribute to improve face recognition ratio. We attempted to combine three-dimensional tensor from Gabor transform with MPCA(Multilinear PCA) and LDA. MPCA with tensor which use various features is more effective than traditional one or two dimensional PCA. It is known to be robust to the change of face expression or light. Proposed method is simulated by MATLAB9 using ORL and Yale face database. Test result shows that recognition ratio is improved maximum 9~27% compared with existing face recognition method.

### 1. 서 론

현대 사회의 발달은 개인정보의 중요성을 증대시켜 왔다. 개인정보의 보호를 위하여 여러 기술들이 발달되어 활용되고 있으며, 특히 디지털 시대의 발전으로 인하여 디지털 시스템의 보안 기기들이 주목을 받고 있다. 그 중 가장 대표적이며 널리 사용하는 방법이 암호화 시스템이다. 그러나 이 시스템은 암호의 분실

이나 복제, 위·변조 등의 문제 등이 발생할 수 있다. 이러한 위험성을 줄이면서 자연적이면서 강제성이 없이 사용할 수 있는 것이 바로 사람 고유의 생체정보를 이용한 시스템이다. 사람마다 고유의 생체정보를 통하여 인증을 통하여 중요 정보의 보호에 이용할 수 있다는 장점을 가진다. 생체정보를 이용한 개인의 인증 방법에는 지문, 홍채, 음성, 혈관, DNA, 서명(Signature) 등 여러 가지 방법들이 있다. 그 중에서도 비접촉식으

\* 본 연구는 2009년도 교내 학술연구비에 의해 이루어졌다.

\* 광운대학교 전자통신공학과 (red2000@kw.ac.kr), \*\* 광운대학교 전자통신공학과 (hhkoh@kw.ac.kr)

논문번호 : KICS2010-07-320, 접수일자 : 2010년 7월 23일, 최종논문접수일자 : 2010년 9월 9일

로 특정 행동을 하는 등의 거부감이 적은 생체인증 방법으로 얼굴인증 방법이 주목받고 있다.

얼굴인증 시스템은 개인의 얼굴을 인식하여 판별하는 시스템으로 개인 고유의 특징이 나타나 있으면서 거부감 없이 자연적으로 인증 데이터의 취득이 용이하다는 장점을 지니고 있다. 하지만 이러한 시스템도 조명, 카메라의 위치, 표정의 변화, 안경이나 모자 등에 의한 얼굴의 가림, 노화 등의 제약사항이 존재하여 인식에 어려움이 많다. 기술의 발달과 다각적인 방향에서 연구한 결과 많은 인식률의 개선을 보였으나 여전히 인식률 개선에 관한 효과적인 방법에 관한 연구가 진행되고 있다.<sup>[1-3]</sup>

현대의 얼굴인식을 위한 기술은 무인경비 및 출입통제 등의 보안 시스템, 신원 확인, 범죄 예방 및 해결 등 현재 산업화가 진행 중이며, 여러 분야에서 꼭넓게 활용되어지고 있고, 높은 신뢰성이 요구되고 있다. 이러한 요구사항에 대응할 수 있는 고성능의 얼굴인식 시스템의 개발이 필요하다.

본 논문의 구성은 1장에서 서론을 기술하였고, 2장에서 기존의 얼굴인식 방법에 대하여 설명을 하였다. 3장에서는 제안한 방법인 가버 텐서로 구성하여 얼굴인식을 수행하는 과정에 대하여 설명하였다. 4장에서는 실험을 통하여 제안한 방법의 우수성을 서술하였고, 5장에서 결론을 내었다.

## II. 얼굴 인식 방법

얼굴인식 방법은 통계학적인 분석방법, 특징기반의 인식방법, 외형기반의 방법 등으로 분류된다. 대표적인 인식 방법으로는 주성분 분석법(PCA), 선형판별분석법(LDA), 독립성분분석법(ICA: Independent Component Analysis), LFA(Local Feature Analysis) 등이 있다. 또 얼굴의 눈, 코 입 등의 특징점을 찾아 기하학적인 형태를 비교하여 인식하는 방법(AAM: Active Appearance Model), 또는 특정 모양의 템플릿을 찾아 각 구성 성분의 위치와 거리를 이용한 방법(Template Matching) 등이 있다. HMM(Hidden Markov Model)을 이용한 방법, 신경회로망(Neural Network)을 이용한 방법, 퍼지(Fuzzy)를 이용한 방법, 유전자 알고리즘(Genetic Algorithms)을 이용한 방법, SVM(Support Vector Machine) 분류기를 이용한 방법 등이 알려져 있다. 이 중에서 가장 많이 사용되는 주성분 분석법(PCA)과 선형판별 분석법(LDA)에 대하여 간략히 알아본다.

### 2.1 주성분 분석법 (PCA)

주성분 분석법 (PCA : Principal Component Analysis)은 고차원 입력벡터를 저차원의 벡터로 표현하여 몇 개의 주성분 값으로 나타내는 방식으로, 데이터의 평균과 표준편차, 공분산의 통계적 성질을 이용한 방법이다. 데이터의 분산을 큰 값을 가지는 몇 개의 고유 얼굴(Eigen face)이라 불리는 고유벡터 축으로 선형 투영시켜 차원을 축소하는 방법으로 클래스의 차원을 축소시켜 간단하게 표현 할 수 있어 많이 사용되어지는 방법이다.<sup>[1,4]</sup>

1차원 주성분 분석법은 입력 영상( $w \times h$ )을 1차원의 데이터로 변환하여  $M \times 1$ (여기서,  $M = w \times h$ ) 형태의 데이터를 이용하여 주성분 분석법을 수행한다. 반면에 2차원 주성분 분석법은 학습 영상을 1차원 벡터로 변환하지 않고, 직접 공분산을 구하는 방식을 의미한다.

학습 영상  $A$ 는  $s$ 개의 벡터로 1차원 또는 2차원의 행렬로 구성된다.

$$\text{Image } A = \{A_1, \dots, A_s\}, \text{ where } \begin{cases} A_i = M \times 1 & (\text{for 1D}) \\ A_i = w \times h & (\text{for 2D}) \end{cases} \quad (1)$$

공분산 행렬(Covariance matrix)  $G_t$ 를 다음 식과 같이 구한다.

$$J(\nu) = \nu^T \left( \frac{1}{S} \sum_{i=1}^S (A_i - \bar{A})^T (A_i - \bar{A}) \right) \nu = \nu^T G_t \nu \quad (2)$$

여기에서  $\bar{A}$ 는 훈련데이터의 평균 영상이고, 최적 투영 벡터인  $\nu$ 는  $G_t$ 의 가장 큰 고유값(Eigen value)에 상응하는 고유벡터(Eigen vector)이다. 즉,

$$\bar{A} = \frac{1}{S} \sum_{i=1}^S A_i \quad (3)$$

$$G_t = \frac{1}{S} \sum_{i=1}^S (A_i - \bar{A})(A_i - \bar{A})^T \quad (4)$$

여기서 고유값에 상응하는 고유벡터의 경우 1차원인 경우  $M \times M$  크기의 행렬로 나타나며, 2차원 데이터의 경우는  $w \times w$  또는  $h \times h$  크기의 행렬로 나타난다. 고유벡터의 차원을 축소하여 사용한다. 이는 가장 큰  $d$ 개의 고유값에 상응하는 고유벡터를 투영한 투영 행렬  $V = [\nu_1, \dots, \nu_d]$  는 다음에 의하여 구할 수 있다.

$$Y = A_i V \quad (5)$$

## 2.2 선형판별 분석법(LDA)

선형판별 분석법(LDA)은 특징 벡터의 차원 축소 기법으로 FLD(Fisher Linear Discriminant)를 분류 알고리즘으로 적용하고 있다. 한 클래스 내에서의 변화를 최소화 하고, 다른 클래스와의 변화를 최대화를 통하여 특징벡터의 차원을 축소하는 방법이다.<sup>[1][5]</sup>

선형 판별 분석법(LDA)은 주성분 분석법(PCA)에 비하여 조명이나 표정의 변화 등에 강인한 특성을 가진다.

학습 영상은 C개의 클래스를 가지고 있으며 각 클래스는 n개의 샘플을 가지고 있다면, 전체 샘플의 수  $N = n \times C$  이다. A는 1차원( $M \times 1$ ) 또는 2차원( $w \times h$ ) 데이터이다.

$$\text{Image } A = A^i = \{A_j^1, A_j^2, A_j^3, \dots, A_j^C\}, \\ i = \{1, 2, 3, \dots, C\}, j = \{1, 2, 3, \dots, n\}$$

여기서  $i$ 는 각 클래스의 위치를  $j$ 는 해당 클래스에 속하는 샘플의 위치를 나타낸다.

$i$ 번째 클래스의 평균은  $\bar{A}^i$  이고, 전체 샘플의 평균은  $\bar{A}$ 로 다음 식에 의하여 구한다.

$$\bar{A}^i = \frac{1}{n} \sum_{j=1}^n A_j^i \quad (6)$$

$$\bar{A} = \frac{1}{N} \sum_{i=1}^C \sum_{j=1}^n A_j^i \quad (7)$$

클래스 내의 샘플들의 분산행렬  $S_w$ 는 다음의 식과 같다,

$$S_w = \sum_{i=1}^C \sum_{j=1}^n (A_j^i - \bar{A}^i)(A_j^i - \bar{A}^i)^T \quad (8)$$

클래스 간의 분산행렬  $S_b$ 는 다음의 식과 같다.

$$S_b = \sum_{i=1}^C (\bar{A}^i - \bar{A})(\bar{A}^i - \bar{A})^T \quad (9)$$

2차원 선형 판별 분석법의 합수는 다음 식과 같이 정의할 수 있다.

$$\mathcal{J}(X) = \frac{X^T S_b X}{X^T S_w X} \quad (10)$$

최적의 사영축  $X_{opt}$ 은  $J(X)$ 의 클래스 내의 행렬과 클래스간의 행렬의 비가 최대화 되도록 하여 구한다. 이 값을 이용하여  $S_b S_w^{-1}$ 의 최대의 고유값에 상응하는 고유벡터를 구한다.

$$S_b S_w^{-1} X_{opt} = \Lambda X_{opt} \quad (11)$$

이로부터 d개의 고유 벡터가 구하여진다.

$$X_{opt} = \{X_1, X_2, X_3, \dots, X_d\} \quad (12)$$

## III. 제안한 방법

제안한 방법의 전체적인 구성도는 그림 1과 같다. 입력된 훈련 영상은 가벼 변환을 통하여 3차원의 텐서를 구성하고, 이를 다중선형 주성분 분석법(Multilinear PCA)을 수행하고 다시 선형판별 분석법(LDA)을 수행하여 고유의 특징벡터를 구성하고, 이것을 입력된 테스트 영상과 비교를 통하여 얼굴 인식이 수행된다.

### 3.1 2차원 가벼 변환 (2D Gabor transform)

가벼 필터는 시간 영역의 해상도 정보와 주파수 영역의 성분을 나타내는 STFT(Shot Time Fourier Transform)으로 사인파에 의해 변조된 가우시안 커널 함수의 형태를 가진다. 가벼 필터는 다른 모파형(Mother wavelet)으로 확장과 회전에 의해 생성될 수 있는 모든 필터들과 자기유사(Self-similar)적인 성질

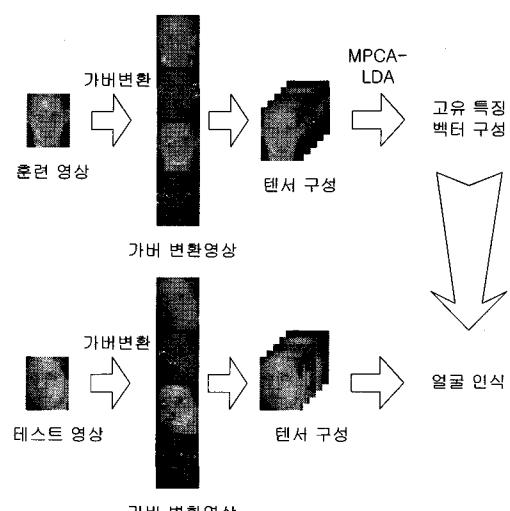


그림 1. 제안한 얼굴 인식 불러도.

을 지니고 있고, 영상을 공간적으로 국부화 시키는 특성을 가지며, 주파수 영역에서도 특정 주파수와 방향에 대하여 선택적으로 반응하는 대역통과 필터(Band pass filter)의 특성을 지니고 있어서 입력 영상의 크기 변화나 회전의 변화에 영향을 덜 받는다. 또 경계의 변화를 찾기 위하여 영상 처리에 많이 사용되고 있는 선형 필터로 가버 필터의 주파수와 방위들은 인간의 시각 시스템과 유사한 특징을 가지고 있다. 이러한 특징은 질감(Texture)의 표현이나 식별에 적합하여 질감 분할, 물체 검출, 영상 해석 등의 분야에서 널리 사용되어지고 있다.<sup>[6-8]</sup>

2차원 가버 필터의 일반적인 형태는 다음과 같다.

$$g(x, y; \lambda, \theta, \varphi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \times \cos\left(2\pi \frac{x'}{\lambda} + \varphi\right) \quad (13)$$

여기서,

$$\begin{aligned} x' &= x \cos \theta + y \sin \theta \\ y' &= -x \sin \theta + y \cos \theta \end{aligned} \quad (14)$$

$x$ 와  $y$ 는 가버 필터의 중심점에서  $x$ 축,  $y$ 축으로의 거리를 나타내며,  $\theta$ 는 가버 필터의 방향을 나타낸다.  $\lambda$ 는 파형의 길이를 나타내고,  $\varphi$ 는 삼각함수의 위상을,  $\sigma$ 는 가우시안의 반경을,  $\gamma$ 는 가우시안의 가로세로 비율을 나타낸다.

이러한 가버 변환은 물질 고유의 특징을 방향성과 크기를 이용하여 표현하는 방식으로 얼굴인식 분야에서 널리 사용되고 있다. 가버 특징 벡터는 입력되어진 얼굴 영상과 가버 필터와의 컨벌루션(Convolution)에 의하여 얻어진다. 이러한 가버 특징 벡터는 다중화된 필터에 의해 특징이 검출됨으로 공간적인 특징을 반영한다. 이것은 잡음이나 조명 등에 강인한 특징을 가진다.

### 3.2 다중선형 주성분 분석법 (MPCA)

텐서(Tensor)란 일반적인 2차원 벡터를 표현하는

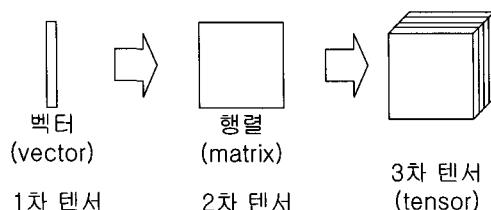


그림 2. 텐서의 구성

방법으로 0차 텐서는 스칼라 값을, 1차 텐서는 벡터값을, 2차 텐서는 행렬을 의미한다. 3차 이상의 경우  $n$  차 텐서라고 한다. 다중선형 주성분 분석법 (Multilinear PCA)은 텐서를 이용하여 주성분 분석법을 수행한다.<sup>[9,10]</sup>

$N$ 차 텐서의 경우 다음의 식과 같이 표현된다.

$$A \in \mathbb{R}^{I_1 \times I_2 \times \dots \times I_N} \quad (15)$$

이것은  $N$ 개의  $i_n$  ( $n=1, \dots, N$ )을 가리키고 있으며, 각  $i_n$ 은  $A$ 의  $n$ -모드를 나타낸다.

텐서  $A$ 의  $n$ -모드 곱은 행렬  $\{U \in \mathbb{R}^{J_n \times I_n}\}$ 에 의해  $A \times_n U$  라 쓴다.

$$(A \times_n U)(i_1, \dots, i_{n-1}, j_n, i_{n+1}, \dots, i_N) = \sum_{i_n} A(i_1, i_2, \dots, i_N) \cdot U(j_n, i_n) \quad (16)$$

두 텐서  $A, B$ 의 스칼라 곱은 다음의 식에서 정의 된다.

$$\langle A, B \rangle \geq \sum_{i_1} \sum_{i_2} \dots \sum_{i_N} A(i_1, i_2, \dots, i_N) \cdot B(i_1, i_2, \dots, i_N) \quad (17)$$

$A$ 의 Frobenius norm 은  $\|A\|_F = \sqrt{\langle A, A \rangle}$  으로 정의된다.  $A$ 의  $n$ -모드 벡터는 다른 모든 순서(Index)가 고정될 때  $i_n$ 의 순서가 변하면서  $A$ 로부터 얻어진  $I_n$  차 벡터에 의하여 정의된다. 1차(Rank) 텐서  $A$ 는  $N$  벡터의 외적으로 다음의 식에서와 같다.

$$A = u^{(1)} \circ u^{(2)} \circ \dots \circ u^{(N)} \quad (18)$$

모든 순서(Index)에 대해서 다시 나타내면 다음의 식과 같다.

$$A(i_1, i_2, \dots, i_N) = u^{(1)}(i_1) \cdot u^{(2)}(i_2) \cdot \dots \cdot u^{(N)}(i_N) \quad (19)$$

$n$ -모드의  $A$ 의 전개(Unfolding)는 다음의 식으로 나타낸다.

$$A_{(n)} \in \mathbb{R}^{I_n \times (I_1 \times \dots \times I_{n-1} \times I_{n+1} \times \dots \times I_N)} \quad (20)$$

열(Column) 벡터  $A_{(n)}$ 는  $A$ 의  $n$ -모드 벡터이다. 표준 다중 선형 대수식에 따라 텐서  $A$ 는 다음의 곱

의 형태로 나타난다.

$$A = S \times_1 U^{(1)} \times_2 U^{(2)} \times \cdots \times_N U^{(N)} \quad (21)$$

여기서  $S = A \times_1 U^{(1)^T} \times_2 U^{(2)^T} \times \cdots \times_N U^{(N)^T}$  이고,  $U^{(n)} = (u_1^{(n)}, u_2^{(n)}, \dots, u_{I_n}^{(n)})$ 로  $I_n \times I_n$  직교(Orthogonal) 행렬이다.  $U^{(n)}$ 이 직교정규(Orthonormal) 열(Column) 이면  $\|A\|_F^2 = \|S\|_F^2$  이다.

$R^{I_1} \otimes R^{I_2} \otimes \cdots \otimes R^{I_N}$  공간에서 M 텐서 샘플의 집합  $\{A_m, m=1, \dots, M\}$  일 때, 텐서의 총 분산은

$$\Psi_A = \frac{1}{M} \sum_{m=1}^M \|A_m - \bar{A}\|_F^2 \quad (22)$$

이고, 평균 텐서

$$\bar{A} = \frac{1}{M} \sum_{m=1}^M A_m \quad (23)$$

이다. n-모드 총 분산 행렬은

$$C_{T_A} = \sum_{m=1}^M (A_m^{(n)} - \bar{A}^{(n)})(A_m^{(n)} - \bar{A}^{(n)})^T \quad (24)$$

으로, 여기서  $A_m^{(n)}$ 은  $A_m$ 의 n-모드 전개행렬(unfolded matrix)이다.

M 텐서 객체의 집합  $\{x_m, m=1, \dots, M\}$ 은 각 텐서 객체  $x_m \in R^{I_1 \times I_2 \times \cdots \times I_N}$ 의 학습 데이터 일 때 MPCA 객체는 원래의 N차 텐서 공간(Tensor space)  $R^{I_1} \otimes R^{I_2} \otimes \cdots \otimes R^{I_N}$ 에서 텐서 부공간(Tensor subspace)  $R^{P_1} \otimes R^{P_2} \otimes \cdots \otimes R^{P_N}$  ( $P_n < I_n, n=1, \dots, N$ )으로 사상되는 다중선형 변환(Multilinear transform)  $\{\tilde{U}^{(n)} \in R^{I_n \times P_n}, n=1, \dots, N\}$ 으로 정의된다.

$$y_m = x_m \times_1 \tilde{U}^{(1)^T} \times_2 \tilde{U}^{(2)^T} \times \cdots \times_N \tilde{U}^{(N)^T}, \\ m=1, \dots, M \quad \{y_m \in R^{P_1 \times P_2 \times \cdots \times P_N}, m=1, \dots, M\} \quad (25)$$

원 텐서 객체에서 편차의 대부분이 포함됨을 알 수 있다. 이러한 편차는 총 텐서 분산에 의해 측정됨이 추정 가능하다. 이는 MPCA 객체가 N개의 투영 행렬  $\{\tilde{U}\}$ 로 전체 텐서 분산  $\Psi_y$ 를 최대화 하는 것이다.

$$\{\tilde{U}^{(n)}, n=1, \dots, N\} = \arg \max_{\tilde{U}^{(1)}, \tilde{U}^{(2)}, \dots, \tilde{U}^{(N)}} \Psi_y \quad (26)$$

각 모드에 대한 차원  $P_n$ 은 알거나 미리 정한 값으로 추정한다.

MPCA에 의한 고유벡터는 다음과 같다.

$$\Phi^{(n)} = \sum_{m=1}^M (X_{m(n)} - \bar{X}_{(n)}) \cdot \tilde{U}_{\Phi(n)} \cdot \tilde{U}_{\Phi(n)}^T \cdot (X_{m(n)} - \bar{X}_{(n)})^T \quad (27)$$

여기서

$$\tilde{U}_{\Phi(n)} = (\tilde{U}^{(n+1)} \otimes \tilde{U}^{(n+2)} \otimes \cdots \otimes \tilde{U}^{(N)} \otimes \tilde{U}^{(1)} \otimes \tilde{U}^{(2)} \otimes \cdots \otimes \tilde{U}^{(n-1)})$$

이다.

총 분산 텐서는  $Y_{var}^* \in R^{I_1 \times I_2 \times \cdots \times I_N}$ 로 각 항목 텐서  $Y_{var}^*$ 는 다음과 같이 정의된다.

$$Y_{var}^* = \sum_{m=1}^M [(Y_m^* - \bar{Y}^*)]^2 \quad (28)$$

$$\text{여기서 } Y_m^* = X_m \times_1 U^{(1)*T} \times \cdots \times_N U^{(N)*T}, \quad \bar{Y}^* = \frac{1}{M} \sum_{m=1}^M Y_m^* \text{이다.}$$

각 모드별 고유값 표현의 예시는 그림 3에 간략히 보였다.

다중선형 주성분 분석법(MPCA) 알고리즘에 대한 내용은 표 1에서 간략히 표시되어 있다.

1차원 주성분 분석법(1D PCA)의 경우는  $N=1$ 이고, 입력 값은 벡터  $\{x_m \in R^{I_1}\}$ 이다. 차원 축소를 위해서는  $y_m = x_m \times_1 U = U^T x_m$ 의 계산에 하나만의 투영 행렬  $U$ 만을 이용한다. 고유벡터는  $\Phi^{(n)} = \Phi^{(1)} = \sum_{m=1}^M (x_m - \bar{x}) \cdot (x_m - \bar{x})^T$ 로 입력 샘플의 전체 분산 행렬이 된다. 투영행렬  $U^{(1)}$ 은 투영공간에서 전체 분산 행렬의 최대화로 고유벡터  $\Phi^{(1)}$ 로부터 결정된다.

2차원 주성분 분석법(2D PCA)은  $N=2$ 인 경우로 2개의 투영행렬  $U$ 를 이용하는 것으로 1차원, 2차원 주성분 분석법과 동일한 방법으로 차이가 있다면, 2

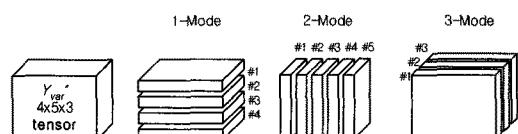


그림 3. 모드별 고유값 계산

표 1. 다중선형 주성분 분석법(MPCA) 알고리즘

입력 : 텐서 샘플들의 집합  
 $\{x_m \in R^{I_1 \times I_2 \times \dots \times I_N}, m = 1, \dots, M\}$   
 $x_m$ 은 텐서 공간  $R^{I_1} \otimes R^{I_2} \otimes \dots \otimes R^{I_N}$ 의 추정값으로, 여기서  $I_n$ 은 텐서의 n차원(n-모드)을 나타낸다.

출력 : 최대 편차를 가지는 입력 텐서 샘플들의 저차원 표현  $\{y_m \in R^{P_1 \times P_2 \times \dots \times P_N}, m = 1, \dots, M\}$

알고리즘 :

Step 1. (전처리) 입력샘플들의 편차를 구함  
 $\{\tilde{x}_m = x_m - \bar{x}, m = 1, \dots, M\}$ ,  
 샘플의 평균  $\bar{x} = \frac{1}{M} \sum_{m=1}^M x_m$

Step 2. (초기화)  $\Phi^{(n)*} = \sum_{m=1}^M \tilde{X}_{m(n)} \cdot \tilde{X}_{m(n)}^T$  고유-분해를 계산  
 가장 중요한 고유값  $P_n(n=1, \dots, N)$ 에 상응하는 고유벡터로 구성된  $\tilde{U}^{(n)}$  집합을 구성

Step 3. (최적화)  
 Calculate  
 $\{\tilde{y}_m = \tilde{x}_m \times_1 \tilde{U}^{(1)*} \times_2 \tilde{U}^{(2)*} \times \dots \times_N \tilde{U}^{(N)*}, m = 1, \dots, M\}$   
 Calculate  $\Psi_{y_0} = \sum_{m=1}^M \|\tilde{y}_m\|_F^2$   
 ( $\tilde{x}_m$ 이 중심이 되므로 평균  $\bar{y}_m$ 는 모두 0이다.)  
 for k=1 : K  
 for n=1 : N  
 가장 큰 고유값  $P_n$ 에 상응하는  $\Phi^{(n)}$  행렬의 고유벡터  $P_n$ 으로 구성된 행렬  $\tilde{U}^{(n)}$   
 Calculate  $\{\tilde{y}_m, m = 1, \dots, M\}$  과  $\Psi_{y_k}$   
 if  $\Psi_{y_k} - \Psi_{y_{k-1}} < \eta$  면 Step 4.로 이동

Step 4. (투영) 투영으로 특징 텐서를 얻는다.  
 $\{\tilde{y}_m = \tilde{x}_m \times_1 \widehat{U^{(1)*}} \times_2 \widehat{U^{(2)*}} \times \dots \times_N \widehat{U^{(N)*}}, m = 1, \dots, M\}$

차원 주성분 분석법의 경우 입력데이터의 크기가  $w \times h$ 인 경우  $w \times w$  또는  $h \times h$ 의 크기를 가지는 고유벡터 중 하나만을 구하여 사용하는데 다중선형 주성분 분석법의 경우는 두 가지 형태의 고유벡터를 모두 구하여 이용한다. 인식률에 있어서는 동일한 성능을 가진다.

### 3.3 제안한 방법

본 논문에서는 가버 텐서와 다중선형 주성분 분석법(Multilinear PCA)과 선형판별 분석법(LDA)을 이용한 얼굴인식 방법을 제안하였다. 먼저 가버(Gabor) 변환을 이용하여 3차원의 가버 텐서(Gabor tensor)를 구성한다. 가버 변환의 경우 얼굴 고유의 특징을 나타내



그림 4. 가버 텐서의 구성

는데 효율적이며, 환경에 강인한 특성을 나타낸다. 또 텐서의 경우 다양한 특징을 이용할 수 있으며, 특징간의 상관도를 이용하여 인식의 효율을 높일 수 있다.

이 Gabor 텐서를 이용하여 다중선형 주성분 분석법(MPCA)을 수행 후 선형 판별법(LDA)을 수행한다. 다중선형 주성분 분석법은 다양한 특징을 이용하여 다차원의 고유의 특징 벡터를 표현이 가능하여 이를 이용하여 인식 성능을 향상 시킬 수 있다. 선형 판별법 역시 주성분 분석법의 부족한 부분인 표정 및 조명 등의 개인성을 보완할 수 있어 인식 성능 향상에 기여할 수 있다.

수행 결과로 나온 고유한 특징벡터를 이용하여 입력된 테스트 영상과의 유clidean 거리(Euclidean distance)를 측정하는 방식에 의하여 가장 근접한 거리의 얼굴을 선택하도록 한다. 이는 해당 클래스에 속한 영상으로 간주하여 얼굴 인식을 수행한다. 이때 고유의 특징벡터는 가장 큰 고유값에 상응하는 고유벡터를 차원 축소하여 이용하였다. 본 논문에서 전체 고유값 중 상위 1,600개의 값만을 이용하여 차원 축소하여 실험을 수행하였다.

## IV. 실험 및 결과

실험 환경은 Intel Core2Duo CPU를 이용한 PC에서 매트랩2008(MATLAB 2008) 프로그램을 이용하여 실험을 수행하였다. 실험 영상은 ORL 얼굴 데이터베이스와 Yale 얼굴 데이터베이스를 사용하였다.

ORL 데이터베이스는 112x92 크기의 얼굴영상으로 40명의 서로 다른 얼굴 10장씩으로 구성되어 있다 [11]. 총 400장의 얼굴영상으로 구성된 데이터베이스로 실험에는 각 사람(클래스:Class) 별로 훈련에 5장, 인식 테스트에 5장의 영상으로 충복되지 않게 나누어 실험을 수행하였다. 훈련에 모두 200장, 테스트에 200장의 얼굴 영상으로 실험을 하였다.

한편 Yale 데이터베이스는 64x64 크기의 얼굴 영상으로 15명의 서로 다른 얼굴 11장으로 모두 165장으로 구성되어 있다.[12] 실험에서는 충복되지 않도록 훈련 데이터로 각 사람별로 6장을, 인식 테스트 데이터로 5장으로 나누어 실험을 수행하였다. 훈련에 모두 90장, 테스트에 75장을 이용하였다.



그림 5. ORL 훈련 데이터 예



그림 6. ORL 테스트 데이터 예



그림 7. Yale 훈련 데이터 예



그림 8. Yale 테스트 데이터 예



그림 9. Gabor 변환된 훈련 영상 예



그림 10. Gabor 변환된 테스트 영상 예

그림 5~그림 8은 실험에 사용한 얼굴 데이터베이스의 예를 보였다.

실험에 사용된 데이터베이스는 2차원 가버 변환을 이용한다. 가버 필터는  $0^\circ, 45^\circ, 90^\circ, 135^\circ$ 의 4방향의 방향성을 갖도록 구성하였다. 이를 이용하여 가버 텐서를 구성하였다. 그림 9, 10에서는 가버 변환된 영상의 예로 이를 이용하여 3차원의 가버 텐서를 구성하였다.

실험은 기존의 방법들인 1차원 주성분 분석법(1D PCA)과 2차원 주성분 분석법(2D PCA), 2차원 주성분 분석법과 SVM을 적용한 방법(2D PCA+SVM), 2차원 텐서를 이용한 주성분 분석법과 선형판별법(2D PCA+LDA) 등의 실험을 수행하였다. 제안한 방법인 가버 변환을 이용하여 3차원 텐서를 구성하고, 이를 이용한 다중선형 주성분분석법(G+MPCA)과 다중선형 주성분분석과 선형 판별법(G+MPCA+LDA)의 비교를 수행하였다. 인식률을 비교의 결과는 표 2에서 보였다.

표 2의 인식률 비교에서 보는 것처럼 1차원 주성분 분석법 보다는 2차원 주성분 분석법이 인식률이 4%~18% 정도 좋고, 2차원 다중선형 주성분 분석법과 선형판별법(2D MPCA+LDA)을 수행한 방법이 3~4% 더 좋은 인식률을 보임을 알 수 있다. 마지막으로 제안한 방법인 가버 텐서를 구성하여 다중선형 주성분분석법(G+3D MPCA)과 다중선형 주성분분석과 선형 판별법(G+3D MPCA+LDA)을 수행한 방법의 인식률이 기존의 방법들보다 최대로는 9~27%, 최소는 2~5% 정도 더 좋은 인식률을 보임을 알 수 있었다.

인식 오류의 경우 ORL 데이터베이스의 경우 200개의 테스트 영상 중 2개의 영상이, Yale 데이터베이스의 경우 75장의 테스트 영상 중 7개의 영상에서 오류를 보였다. 오류는 포즈가 비슷하거나 밝기나 콧수

표 2. 얼굴인식 알고리즘의 인식률 비교

인식방법	ORL DB	Yale DB
1D PCA	90%	63.33%
2D PCA (2D MPCA)	94%	81.33%
2D PCA+SVM	97%	82.67%
2D MPCA+LDA	97.5%	85.33%
G+3D MPCA	97%	88%
G+3D MPCA+LDA	99%	90.67%

염, 안경 등의 문제로 인하여 오인식을 보였다. 그림 11과 그림 12에서 그 결과를 보이고 있다.

표 3에서는 인식 알고리즘별로 처리 시간을 비교해 보았다. 같은 인식률을 보인 2차원 주성분 분석법(2D PCA)과 2차원 다중선형 주성분 분석법(2D MPCA)의 경우는 데이터베이스에 따라 약간의 처리시간이 차이가 나는 것을 알 수 있었으며, 선형판별법(2D MPCA+LDA) 추가할 경우 더 많은 처리시간을 필요로 하였다. 가버텐서를 이용한 방법의 경우는 가버 변환에 ORL DB의 경우는 51.2초가 Yale DB의 경우는 4.4초가 소요되었으며, 이는 학습과 인식에서도 3차원 처리를 하므로 더 많은 처리시간이 소요되기 때문이다.

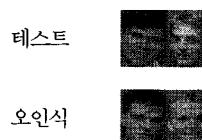


그림 11. ORL DB 오류 영상



그림 12. Yale DB 오류 영상

표 3. 얼굴인식 알고리즘의 처리시간 비교 (단위: 초(s))

인식방법	ORL DB	Yale DB
2D PCA	11.76	0.70
2D MPCA	10.35	1.38
2D PCA+SVM	11.25	0.78
2D MPCA+LDA	13.06	10.34
G+3D MPCA	72.38 (G:51.2)	7.83 (G:4.4)
G+3D MPCA+LDA	82.12 (G:51.2)	17.06 (G:4.4)

## V. 결 론

본 논문에서는 가버 변환된 영상을 3차원 텐서로

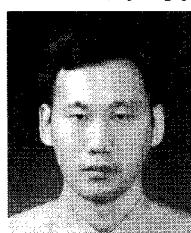
구성하여 다중선형 주성분 분석법과 선형 판별법 (MPCA+LDA)을 이용한 얼굴인식 방법을 제시하였다. 가버 변환의 경우 조명의 변화나 회전 등에 강인한 특성을 가지고 있어 효과적인 얼굴 인식 능력 향상에 기여할 수 있다. 가버 변환된 얼굴 영상을 이용하여 3차원의 텐서를 구성하여 다중선형 주성분 분석법 (MPCA)을 수행한다. 기존의 2차원 영상과 가버 변환된 영상들과의 관계를 이용한 텐서를 이용함으로서 3차원의 데이터를 이용함으로서 고유의 특징을 얻을 수 있어 인식 성능을 향상 시킬 수 있다. 얼굴 영상들의 클래스간 관계를 고려한 선형판별법(LDA)를 수행함으로서 차수를 낮추어 인식을 수행한다. 제안된 방법에 의하여 얼굴 인식을 실험해 본 결과 기존의 방법들 보다 더 좋은 인식 성능을 보임을 확인할 수 있었다. 기존의 방법 중 가장 대표적이며 널리 사용 중인 1차원 PCA 방법 보다는 ORL 데이터베이스의 경우 약 9%, Yale 데이터베이스의 경우는 약 27% 이상의 인식률 향상을 보였다. 2차원 PCA와 SVM을 결합한 방식보다도 2%에서 8%의 인식 성능이 향상되었음을 확인할 수 있었다. 제안한 방법의 경우 우수한 인식 성능을 보인 반면 가버 변환의 과정을 수행하는 만큼 전처리 과정이 소용되고, 1차원 또는 2차원 PCA 방법보다 3차원의 텐서를 이용하기 때문에 처리 시간이 다소 걸린다. 향후 다양한 형태의 데이터베이스를 이용한 추가적인 실험과 수행 시간의 단축을 위한 실험이 필요하다.

## 참고문현

- [1] Stan Z. Li and Anil K. Jain, "Handbook of Face Recognition," Springer, 2004.
- [2] A.K. Jain, R.P.W. Duin, and J. Mao, "Statistical Pattern Recognition: A Review," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.22, No.1, Jan. 2000, pp. 4-37
- [3] R. Chellappa, C.L. Wilson, and S. Sirohey, "Human and Machine Recognition of Faces: A Survey," Proceedings of the IEEE, Vol.83, Issue5, May 1995, pp. 705-740
- [4] J. Yang, Zhang, and et al, "Two dimensional PCA: a new approach to appearance-based face representation and recognition," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.26, No.1, pp.131-137, Jan. 2004.
- [5] M. Li and B. Yuan, "2D-LDA: A Statistical

- linear discriminant analysis for image matrix," Pattern Recognition Letters, 2005, pp 527-532
- [6] T. S. Lee, "Image Representation using 2D Gabor Wavelet," IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.18, No.10, Oct. 1996, pp. 957-971.
  - [7] C. Liu and H. Wechsler, "Gabor Feature Based Classification Using the Enhanced Fisher Linear Discriminant Models for Face Recognition," IEEE Trans. Image Processing, Vol.11, No.4, Apr. 2002, pp. 467-476.
  - [8] R.M Mutelo, W.L. Woo and S.S Dlay, "Discriminant analysis of the two-dimensional Gabor feature for face recognition," IET Computer Vision, Vol.2, No.2, 2008, pp. 37-49.
  - [9] H. Lu, K.N. Plataniotis, and A.N. Venetsanopoulos, "MPCA: Multilinear Principal Component Analysis of Tensor Objects," IEEE Trans. Neural Networks, Vol.19, Jan. 2008, pp. 18-39
  - [10] H. Lu, K.N. Plataniotis, and A.N. Venetsanopoulos, "Uncorrelated Multilinear Discriminant Analysis With Regularization and Aggregation for Tensor Object Recognition," IEEE Trans. Neural Networks, Vol.20, 2009, pp.103-123
  - [11] "Olivetti-AT&T database of faces," <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>
  - [12] "Yale Face database," <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>

박경준 (Kyung-jun Park)



정희원

1999년 2월 서울 산업대학교  
전자공학과

2001년 2월 광운대학교 전자통  
신공학과 석사

2001년 8월~현재 광운대학교  
전자통신공학과 박사과정

<관심분야> 얼굴인식, 영상신호  
처리, 임베디드시스템

고형화 (Hyung-hwa Ko)

한국통신학회 논문지 제35권 2호 참조

정희원