

개선된 ICA 기저영상을 이용한 국부적 왜곡에 강인한 얼굴인식

(Face Recognition Robust to Local Distortion using Modified ICA Basis Images)

김 종 선 [†] 이 준 호 ^{**}
 (Jong-Sun Kim) (June-Ho Yi)

요 약 부공간 투영기술(subspace projection)을 이용한 얼굴인식기술의 성능은 이들 기저영상들(basis images)의 특징과 밀접한 관련이 있다. 특히 표정변화와 같은 국부적 왜곡이나 오클루전이 있는 경우의 인식성능은 기저영상들의 특징에 의해 영향을 받게 된다. 부공간 투영기반의 얼굴인식 방법이 오클루전이나 표정변화와 같은 국부적인 왜곡발생에 강인하려면 부분국부적 표현(part-based local representation)의 기저벡터를 갖는 것이 중요하다. 본 연구에서는 국부적 왜곡과 오클루전에 강인한 효과적인 부분국부적 표현방법을 제안한다. 제안한 방법을 LS-ICA(locally salient ICA) 방법이라고 명명하였다. LS-ICA방법은 ICA 구조 I의 기저영상을 구하는 과정에서 공간적인 국부성(locality)의 제약조건을 부과함으로써 부분국부적 기저영상(part-based local basis images)을 얻는 방법이다. 결과적으로 공간적으로 현저한 특징만을 포함하는 기저영상을 사용하게 되며, 이는 “Recognition by Parts”의 방법론과 유사하다. LS-ICA방법과 LNMF(Localized Non-negative Matrix Factorization)와 LFA(Local Feature Analysis)와 같은 기존의 부분 표현방법(part-based representation)들에 대해 다양한 얼굴영상 데이터베이스를 사용하여 실험한 결과, LS-ICA방법이 기존의 방법에 비하여 높은 인식성능을 보였으며, 특히 오클루전이나 국부적인 변형이 포함된 얼굴영상에서 뛰어난 인식성능을 보였다.

키워드 : 얼굴인식, 부분국부적 표현, ICA, LS-ICA

Abstract The performance of face recognition methods using subspace projection is directly related to the characteristics of their basis images, especially in the cases of local distortion or partial occlusion. In order for a subspace projection method to be robust to local distortion and partial occlusion, the basis images generated by the method should exhibit a part-based local representation. We propose an effective part-based local representation method named locally salient ICA (LS-ICA) method for face recognition that is robust to local distortion and partial occlusion. The LS-ICA method only employs locally salient information from important facial parts in order to maximize the benefit of applying the idea of “recognition by parts.” It creates part-based local basis images by imposing additional localization constraint in the process of computing ICA architecture I basis images. We have contrasted the LS-ICA method with other part-based representations such as LNMF (Localized Non-negative Matrix Factorization) and LFA (Local Feature Analysis). Experimental results show that the LS-ICA method performs better than PCA, ICA architecture I, ICA architecture II, LFA, and LNMF methods, especially in the cases of partial occlusions and local distortions.

Key words : face recognition, part based local representation, ICA, LS-ICA

1. 서론

얼굴인식 분야에서 PCA, ICA, FLD와 같은 부공간(subspace) 투영 기술이 널리 사용되어왔다[1-5]. 이 방법들은 주어진 입력영상을 기저(basis) 벡터들에 투영하여 얻게 되는 계수들을 인식을 위한 특징벡터로 사용하게 된다. 부공간 투영에 기반한 얼굴인식방법이 오클루

· 본 연구는 BERCC의 지원으로 수행되었음

[†] 정 회 원 : 연세대학교 생체인식연구센터 교수
 kjongss@yonsei.ac.kr

^{**} 종 신 회 원 : 성균관대학교 정보통신공학부 교수
 jhyi@ece.skku.ac.kr

논문접수 : 2004년 12월 7일

심사완료 : 2006년 3월 15일

전이나 표정변화와 같은 국부적인 왜곡발생에 강인하기 위해서는 국부적 특징을 갖는 기저벡터를 갖는 것이 중요하다. 국부적 특징을 이용한 방법은 식별에 중요한 눈, 눈썹, 입, 코 부위등의 얼굴 특징 요소에 대응하는 국부적 정보만을 사용함으로써 표정변화, 가려짐에 의하여 입력영상의 일부가 변화하는 경우에도 좋은 인식결과를 제공한다. 이는 물체인식문제에서 널리 사용되는 "Recognition by Parts"[6]와 유사한 방법론이라고 할 수 있다.

본 논문은 부공간 투영기술 중에 비교사학습(unsupervised learning) 방법을 연구 대상으로 한다. 그림 1은 AR 데이터베이스에서 임의로 취한 얼굴영상의 집합으로부터 구한 PCA, ICA 구조I(이하에서 ICA-I으로 표시함), ICA 구조II(이하에서 ICA-II로 표시함), LFA 그리고 LNMF 기저 벡터들의 영상을 보여주고 있다. ICA는 서로 다른 두 가지 표현방식인 ICA-I과 ICA-II 방법에 의해 얼굴인식에 적용된다. ICA-I과 ICA-II 방법에 대하여는 2.1절에서 기술하였다. 그림 1의 (a)와 (c)는 각각 PCA와 ICA-II의 기저영상을 보여주고

있다. 이들 기저영상들에서는 얼굴의 전체 형태가 나타나며, 이는 각 기저 벡터에 투영되는 계수 값이 얼굴의 모든 화소로부터 영향을 받는다는 것을 의미한다. 따라서 PCA와 ICA-II를 통해 얻어진 특징값들은 오클루전이나 국부적인 왜곡발생에 민감하게 된다. 이러한 PCA 기저 영상들은 전역적 퓨리에 필터(global Fourier filters)의 확장된 모델이라고 할 수 있다[7]. 반면에 ICA-I 기저 영상들 각각에서는 얼굴의 전체형태가 보이지 않고 얼굴의 특징을 잘 나타내는 눈, 눈썹, 입, 코 부위 등에 대응하는 국부영역만이 현저하게 나타나고 있다. ICA-I 방법을 통해 얻어진 특징값들은 영상의 작은 영역내의 화소로부터 크게 영향을 받는 국부적 특성을 갖게 되어 오클루전이나 국부적인 왜곡발생에 대해 대체로 좋은 인식결과를 기대할 수 있다. 하지만, ICA-I을 통해 얻어진 기저 영상들도 완전한 국부적 특징을 갖지 않기 때문에 현저한 특징을 보이는 국부적 영역 이외의 화소를 값에 의해서도 여전히 영향을 받게 되며, 이는 인식성능의 저하를 초래하며 이를 실험을 통해 확인하였다.

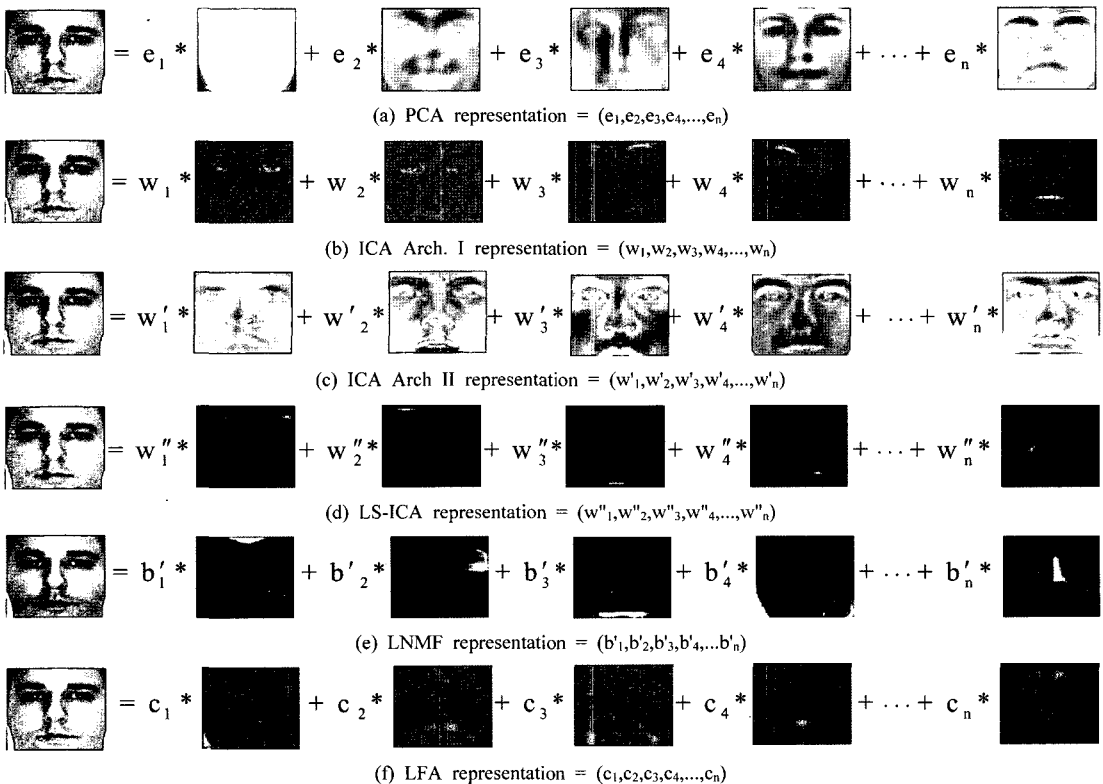


그림 1 (a) PCA, (b) ICA-I, (c) ICA-II, (d) LS-ICA, (e) LNMF, (f) LFA의 기저 영상들을 이용한 얼굴영상의 표현: 하나의 얼굴영상은 기저 영상들의 선형 조합으로 표현된다. 기저 영상들은 AR 데이터베이스로부터 계산되었다.

LFA[8]와 LNMF[9]는 국부적 특징을 사용하는 기존의 대표적인 방법들이다. LFA 방법은 공분산에 기반하여 국부적 특징들을 얻어낸다. 하지만 그림 1의 (f)에서 보듯이 LFA의 기저영상들은 완전한 국부적 특징을 갖지 않기 때문에 오클루전이나 국부적인 왜곡발생의 경우 국부적 영역 이외의 화소들 값에 의해 인식성능의 저하를 초래한다. LNMF 방법은 NMF에 공간적인 국부성(locality)을 부과한 방법이다[10]. 이 방법은 국부적인 영역 이외의 변형에 대해서는 영향을 받지 않도록 기저영상들이 완전한 국부특징을 갖는다는 장점이 있다. 그러나 LNMF 방법은 단순히 공간적인 국부성만을 기준으로 양의 값을 갖는 기저 영상들을 생성함으로써 그림 1의 (e)와 같이 식별에 도움이 되지 않은 뺨, 이마, 턱 등을 반영하는 기저영상을 생성하는 문제가 있다. 이러한 얼굴의 뺨, 이마, 턱 부위 등은 조명 또는 표정변화에 대해 민감하기 때문에 인식률의 저하를 야기시킨다.

본 논문에서 제안하는 LS-ICA(locally salient ICA) 방법은 ICA-I 기저영상들에서 나타나는 공간적으로 현저한(locally salient) 특징을 보이는 영역만을 사용하여 얼굴인식에 적용함으로써 인식성능을 향상하였다. LS-ICA 방법은 오직 현저한 국부적 특징만을 고려하기 위하여 ICA-I의 기저영상 영역 중 국부적 특징이 현저한 작은 영역을 제외한 나머지 영역을 제거하여 ICA-I의 국부적 정보만을 사용함으로써 얼굴의 현저한 특징에 해당하는 국부적인 영역 이외의 변형에 대해서는 영향을 받지 않도록 하는 방법이다. ICA-I의 기저영상들은 일종의 에지필터(edge filter)로서 얼굴의 특징을 잘 나타내는 눈, 눈썹, 입, 코 부위의 국부영역이 강조되는 특징을 지닌다[7]. 이처럼 ICA-I 기저영상에 기반한 LS-ICA 방법은 식별에 도움이 되는 얼굴의 특징요소에 대응하는 국부적 영역만을 인식에 사용하게 된다.

LS-ICA 방법은 두 가지 단계로 이루어진다. 첫 번째 단계에서는 침도 최대화(kurtosis maximization)를 변형한 방법을 이용하여 ICA-I의 기저영상에서 비국부적 영역(nonlocal modulation)을 제거함으로써 LS-ICA 기저영상을 생성한다. 두 번째 단계는 LS-ICA 기저영상들을 클래스 분별력 순으로 정렬한다. LS-ICA의 기저영상들을 정렬하는 이유는 LS-ICA 방법을 통해 얻어진 모든 기저 벡터들을 사용하는 것이 아니라 분별력이 큰 순서로 몇 개의 기저벡터만으로 표현함으로써, 효율적으로 차원을 줄이기 위함이다. 실험결과 LS-ICA 방법은 부분적인 오클루전이나 표정변화와 같은 국부적인 변형에 대해 강인함을 갖게 되어 기존의 PCA, ICA-I, ICA-II, LFA 그리고 LNMF 방법 보다 좋은 인식결과

를 보인다.

본 논문의 구성은 다음과 같다. 2절에서는 본 연구와 가장 관련된 ICA, LFA, 그리고 LNMF 방법에 대해 간략히 설명하고, 3절에서는 제안된 LS-ICA 방법에 대해서 기술한다. 4절에서는 사용된 얼굴 데이터베이스와 실험 결과에 대해서 설명한다.

2. 기존의 연구 방법

2.1 ICA(Independent Component Analysis)

ICA 방법은 고차원 공간에 존재하는 데이터들을 저차원 공간의 데이터로 효과적으로 줄이는 투영 방법으로서 부공간 투영기술에 널리 적용되어 왔다[2-4]. 이 방법은 투영된 데이터들 사이의 통계적인 독립성을 최대화하는 부공간을 찾는 고차통계 방법이다. ICA는 독립성을 측정하는 다양한 비용함수(cost function)와 이를 최적화하는 다양한 알고리즘에 의해서 얻어질 수 있는데, 대표적으로 InfoMax[2], FastICA[3], Maximum likelihood[4]방법 등이 있다. 본 연구에서는 ICA 기저영상을 얻기 위해 FastICA 알고리즘을 적용하였다.

FastICA 방법은 데이터들의 상관관계(correlation)를 제거하기 위해 전처리 과정에서 백색화(whitening)을 적용한 다음 데이터들의 비정규성 (nongaussianity)을 최대화하기 위해 침도(kurtosis)를 적용함으로써 독립성분을 계산하게 된다[3]. FastICA 방법은 다음과 같이 간단히 기술 할 수 있다. S 는 상호 독립인 n 개의 신호원이고 X 는 관측된 랜덤 변수라고 가정한다면, $X=AS$ 으로 나타낼 수 있다. 여기서 A 는 알려져 있지 않은 혼합 행렬이다. 독립 성분 계산의 기본적인 문제는 다음 식에서 보여지듯이 A 행렬과 상응하는 W 행렬을 추정함으로써 독립 신호원 U 를 추정하는 것이다.

$$U = WX = WAS. \tag{1}$$

먼저 관측된 입력 벡터들을 백색화된 Z 행렬로 선형 변환한다. 그 다음에 백색화된 Z 행렬의 비정규성을 최대 로 하는 선형변환 행렬 W 를 구한다. 침도는 비정규분포를 찾기 위한 척도로 사용된다. $U_i = X_i^T Z$ 의 침도는 식 (2)에 의해 구해지고, 벡터 W_i 는 침도의 값을 최대화함으로써 얻어진다[3].

$$kurt(U_i) = \left| E\left\{ (U_i)^4 \right\} - 3 \left(E\left\{ (U_i)^2 \right\} \right)^2 \right|. \tag{2}$$

ICA는 서로 다른 두 가지 표현방식으로 얼굴인식에 적용된다[2]. 본 논문에서는 국부적 특징표현방법과 전역적 특징표현방법을 각각 ICA-I 방법과 ICA-II 방법으로 명명하였다. ICA-I 방법은 입력영상 X 가 통계적으로 독립인 기저 영상 S 와 알려져 있지 않은 혼합 행렬 A 의 선형 결합으로 생성된 것 이라고 가정한다. 입력영

상들을 통계적으로 독립인 기저영상에 투영시켜 얻어진 계수들은 통계적으로 독립은 아니다. 반면에, ICA-II 방법은 입력영상을 표현하는 통계적으로 독립인 계수들을 찾는 것이다. ICA-I의 기저영상은 식 (1)에서 \mathbf{U} 가 되고, ICA-II의 기저영상은 \mathbf{W} 가 된다. ICA-II의 기저영상들은 그림 1의 (c)에서 보여지듯이 전역적(global) 특징을 가지고 있다. 침도의 최대화는 기저영상의 국부성을 야기시키기 때문에 ICA-I의 기저영상들은 공간적으로 국부화된 에지필터가 된다[7]. ICA-I의 기저영상들은 PCA처럼 얼굴의 특징들이 서로 겹치지않고, 얼굴의 공간적으로 국부화된 특징을 가지고 있음을 그림 1의 (b)에서 보여주고 있다. 얼굴 영상의 오직 작은 영역으로부터 영향을 받는 국부적인 특징들은 오클루전이나 국부적인 왜곡에 대해서 전역적인 특징에 비해 덜 민감하다. 그러나 ICA-I의 기저영상들은 입력영상의 모든 화소들의 영향을 받게 되므로 완전한 국부특징 방법은 아니다. 따라서 국부적인 변형이나 가려짐 등의 영향을 받게 되어 인식성능의 저하를 초래한다.

2.2 LFA(Local Feature Analysis)

LFA는 훈련 영상들의 공분산에 기반하여 국소적(topographic) 특징을 갖는 국소커널(local kernel)들의 집합을 정의한다. 입력영상의 공분산행렬 \mathbf{S} 의 고유값들과 그에 대응하는 고유벡터들을 각각 \mathbf{D} 와 \mathbf{E} 라 하면 커널은 다음과 같이 정의된다.

$$\mathbf{K} = \mathbf{E}\mathbf{D}^{-\frac{1}{2}}\mathbf{E}^T \quad (3)$$

여기서 $\mathbf{D}^{-\frac{1}{2}} = \text{diag}\left(\frac{1}{\sqrt{\lambda_i}}\right) \quad i=1, \dots, p$ 이고, λ_i 는 i 번째

고유값이다. 공간적으로 국부화되어 있는 각 커널들은 공간적인 위치 순서를 갖는다는 점에서 국소적 특징을 갖게 된다. 입력영상이 n 개의 화소로 이루어지는 경우에 LFA의 결과 역시도 n 차원으로 나타나게 된다. 따라서 추가적인 차원축소의 방법이 필요하다. Penev와 Atick은 가능한 한 적은 상관을 갖는 M 개의 ($M \ll n$) 커널들만을 이용하여 입력영상을 표현하기 위한 국소성(sparsification) 알고리즘을 제시하였다[8]. 이 알고리즘은 하나의 커널 부분집합을 선택하기 위하여 반복계산의 매 단계에서, 모든 훈련영상에 대하여 가장 큰 복원에러(reconstruction error)를 내는 커널을 하나씩 선정하는 방식이다. 그러나 LFA의 커널들이 완전한 국부적 특징을 갖지 않기 때문에 현저한 특징을 보이는 국부적 영역 이외의 화소들 값에 의해서도 여전히 영향을 받게 되므로 인식성능을 저하시킨다.

2.3 LNMFLocal Non-negative Matrix Factorization)

LNMFLocal Non-negative Matrix Factorization) 방법은 NMF 방법에 공간적인 국부성(locality)의 제약조건을 부과하여 확장한 방법이다[9]. LNMFLocal Non-negative Matrix Factorization)를 이용한 얼굴표현은 부분에 기반하여 나타낼 뿐만 아니라 공간적으로 국부화된 기저영상들로 분해된다. LNMFLocal Non-negative Matrix Factorization)의 기저영상을 계산하기 위한 목적함수는 다음 식과 같다.

$$D(X \| BH) = \sum_{j=1}^m \sum_{i=1}^n \left(X_{ij} \log \frac{X_{ij}}{[BH]_{ij}} - X_{ij} + [BH]_{ij} + \alpha U_{ij} \right) - \beta \sum_i V_{ii} \quad (4)$$

이 식에서 $\alpha, \beta > 0$ 는 임의의 상수들이고, $\mathbf{U} = \mathbf{B}^T \mathbf{B}$, $\mathbf{V} = \mathbf{H}\mathbf{H}^T$ 그리고 $\mathbf{B}, \mathbf{H} \geq 0$ 는 각각 기저영상들과 계수들을 의미한다. $\mathbf{U} = \mathbf{B}^T \mathbf{B}$ 의 최소화는 국부성을 최대화시키고 서로 다른 기저영상들 사이의 중복(redundancy)을 최소화시키는 것이다. 반면에, $\mathbf{V} = \mathbf{H}\mathbf{H}^T$ 의 최대화는 훈련영상의 얼굴정보를 최대한 반영하는 기저영상을 생성한다. \mathbf{B} 에 대한 갱신규칙(update rule)은 NMF와 동일하고, \mathbf{H} 에 대한 갱신규칙은 다음과 같이 정의된다.

$$H_{ij}^{(t+1)} = \sqrt{H_{ij}^{(t)} \sum_i B_{ai}^{(t)} \frac{X_{ij}}{(B^{(t)} H^{(t)})_{ij}}} \quad (5)$$

그림 1의 (e)는 LNMFLocal Non-negative Matrix Factorization)의 기저영상들을 보여주고 있다. 이 방법은 얼굴의 특징 요소는 반영하지 않고, 단순히 공간적인 국부성만을 기준으로 양의 값을 갖는 기저영상을 생성한다. 따라서 개인의 식별에 도움이 되지 않는 뺨, 이마 등을 반영하는 기저영상도 인식을 위해 사용하게 되는 단점이 있다. 얼굴의 뺨, 이마 등의 부위는 눈, 코, 입 부위에 비해 조명변화에 민감하기 때문에 인식률의 저하를 초래한다.

3. LS-ICA 방법

제안하는 방법은 두 단계로 이루어진다. 첫 번째 단계에서는 ICA-I 방법에 기반한 부분 국부적(part-based local) 기저영상을 구하고, 두 번째 단계에서는 인식성능의 향상을 위해 클래스분별력 크기 순으로 LS-ICA 기저영상들을 정렬한다.

LS-ICA 방법은 ICA의 침도 최대화 과정에 공간적인 국부성(locality)의 제약조건을 부과하여 국부적 기저영상을 얻는 방법이다. 침도 최대화 계산을 위한 각 반복(iteration) 수행단계에서는 ICA-I의 기저영상 내에 가장 큰 화소들의 값을 강조함으로써 국부적 기저영상을 얻는다. \mathbf{u} 는 각 반복 수행단계의 솔루션 벡터(solution vector)이고, \mathbf{b} 는 식 (6)과 같이 가중된 솔루션(weighted solution)으로 정의하기로 한다.

$$\mathbf{b}_i = |u_i|^{\alpha} u_i, \quad \mathbf{b} = \mathbf{b} / \|\mathbf{b}\| \quad (6)$$

여기서 $\alpha > 1$ 는 작은 상수이다. 식 (6)에 의해 솔루션 영상 \mathbf{u} 에서 큰 화소들의 값을 갖는 픽셀영역, 즉 국부적 특징을 나타내는 영역은 더욱 큰 화소들의 값을 갖게 되고, 작은 화소들의 값을 갖는 픽셀영역은 더욱 작은 값을 갖게 함으로써 가중된 솔루션 영상 \mathbf{b} 를 구할 수 있다. α 값의 크기에 따라 국부성의 가중된(weighted) 값이 달라지게 된다. 그림 1의 (d)에서 보여진 LS-ICA 기저영상은 α 값을 1.2로 하여 구해진 기저영상이다. 첨도는 다음 식과 같이 \mathbf{u} 대신에 \mathbf{b} 로 대입되어 최대화된다.

$$kurt(\mathbf{b}) = \left| E\{(\mathbf{b})^4\} - 3\left\{E\{(\mathbf{b})^2\}\right\}^2 \right| \quad (7)$$

식 (7)을 최대화하는 분류 벡터(separating vector) \mathbf{W} 는 다음 식과 같은 갱신 규칙(update rules)을 이용하여 구할 수 있다.

$$\mathbf{w}^{(i+1)} = E\left\{ |u_i|^\alpha \mathbf{Z} \left(|u_i|^\alpha \mathbf{w}^{(i)} \mathbf{Z} \right)^3 \right\} \quad (8)$$

여기서 \mathbf{Z} 는 백색화된 영상들(whitened image samples)을 의미한다. 결과적으로, LS-ICA 기저영상은 $\mathbf{b}_i = |u_i|^\alpha (\mathbf{w}^T \mathbf{Z})_i$ 가 된다. LS-ICA의 기저영상들은 서로 독립이 되기 때문에 직교성(orthogonality)을 만족해야 한다. LS-ICA의 기저영상들의 집합을 $\mathbf{B} = \{\mathbf{b}_1, \mathbf{b}_2, \dots, \mathbf{b}_n\}$ 이라 하면, $\mathbf{B}\mathbf{B}^T = \mathbf{D}$ 가 되어야 한다. 여기서 \mathbf{D} 는 대각 행렬(diagonal matrix)이다. 식 (8)에 의해 구해진 \mathbf{W} 는 대칭적 직교(Symmetric orthogonalization)방법인 다음과 같은 갱신 규칙(update rules)을 이용하여 다시 구할 수 있다.

$$\mathbf{w}^{(i+1)} = \left(\mathbf{w}^{(i)} \mathbf{w}^{(i)T} \right)^{-\frac{1}{2}} \mathbf{w}^{(i)} \quad (9)$$

식 (9)에 의해 \mathbf{W} 가 구해지고, $\mathbf{W}\mathbf{W}^T = \mathbf{I}$ 의 조건을 만족하지 않으면 다시 (8)의 식으로 이동된다. 본 논문에서는 LS-ICA 기저영상들을 구하기 위하여 변형된 첨도 최대화 방법을 사용하였으나 모포로지 연산을 이용하는 단순한 영상분할 기법의 적용도 가능하다[11].

클래스 분별력 r 값의 크기 순으로 정렬된 LS-ICA 기저 벡터 행렬을 얻어낸다[2]. 분별력 r 값을 구하기 위해서, 우선 각 특징(feature)에 대한 클래스간 분산

$\sigma_{between}$ 과 클래스내 분산 σ_{within} 을 각각

$$\sigma_{between} = \sum_i (M_i - M)^2 \quad (10)$$

$$\sigma_{within} = \sum_i \sum_j (h_{ij} - M_i)^2 \quad (11)$$

으로 구할 수 있다. 여기에서 M 은 전체 평균, M_i 는 i 번째 클래스의 평균, h_{ij} 는 i 번째 클래스에 속해있는 j 번째 얼굴영상의 계수를 나타낸다. 클래스 분별력 r 은 식 (12)에 의해 구해진다.

$$r = \frac{\sigma_{between}}{\sigma_{within}} \quad (12)$$

클래스 분별력 r 값에 의해 LS-ICA의 기저 벡터들을 정렬하는 이유는 LS-ICA 방법을 통해 얻어진 모든 기저 벡터들을 사용하는 것이 아니라, 몇 개의 기저벡터들만으로 표현함으로써 효율적으로 차원을 줄이기 위함이다.

4. 실험결과

본 논문이 제안한 LS-ICA 방법과 기존의 PCA, ICA-I, ICA-II, LFA 그리고 LNMF 방법에 대한 성능 평가를 하기 위해서 FERET[12], AR[13], AT&T[14]의 데이터베이스 얼굴영상에 대하여 실험하였다. 그림 2는 각각의 데이터베이스에 대한 임의의 얼굴영상을 보여주고 있다. 공정한 성능 평가를 위해 본 논문이 제안한 방법과 기존의 방법들의 기저영상들을 클래스 분별력 r 값을 사용하여 정렬하였으며, 정확한 성능 평가를 위해 서로 다른 거리 계산방식인 L1, L2, cosine을 이용하여 인식성능의 변화를 30번 이상의 반복 실험을 통해 비교 평가하였다.

FERET 데이터베이스의 얼굴영상은 조명변화와 표정변화를 모두 포함하고 있다. 본 연구에서 사용한 실험의 전체 집합 U 는 표 1에서 보여지듯이, FERET 데이터베이스에서 'fa', 'ba', 'bj', 'bk'로 명명된, 네 가지 부분집합으로 이루어진다. 실험에서 영상들의 전체 집합 U 를 훈련 집합 T 와 갤러리(Gallery) 영상 집합 G , 그리고 테스트(Probe) 영상 집합 P 로 구분하였으며 T 와 G , P 의 영상들은 중복되지 않는다. AR 데이터베이스는 100명의 사람에 대해 각각 8개의 얼굴영상을 가지고 있다. 실험에 사용된 테스트영상의 개수는 200장이고 훈련영



그림 2 AT&T (왼쪽), AR (가운데) 그리고 FERET (오른쪽) 데이터베이스의 한 예

표 1 실험에 사용된 FERET 데이터베이스

Two letter code	설명	전체영상 개수(U)	클래스 개수(C)	'ba'-'bj' 집합	'ba'-'bk' 집합
fa	정상적인 정면 얼굴영상	1758	1009	훈련영상개수(T): 1758	
ba	'fa'와 유사한 정면 얼굴영상	200	200	갤러리영상개수(G): 100	갤러리영상개수(G): 100
bj	표정변화를 갖는 얼굴영상	200	200	테스트영상개수(P): 100	
bk	조명변화를 갖는 얼굴영상	194	194		테스트영상개수(P): 100

상의 개수는 600장이다. 테스트영상은 오클루전이나 표정변화와 같은 국부적인 변형을 많이 포함하고 있다.

본 논문에서는 오클루전이 있는 얼굴영상에 대해 성능 평가를 하기 위해서 AT&T 데이터베이스를 사용하였다. AT&T 데이터베이스는 40명의 사람에게 대해 각각 10개의 얼굴 영상을 가지고 있다. 각 사람의 얼굴 영상은 좌우로 회전하면서 다양한 얼굴 표정을 갖는다. 각 사람에 대한 10장의 영상을 훈련 영상과 테스트영상으로 각각 5장씩 나누어 실험하였다. 그림 3은 실험을 위해 사용한 $s \times s (s \in \{10, 20, 30\})$ 크기의 임의로 생성한 오클루전을 갖는 영상을 보여주고 있다.

그림 4와 5에서는 제안된 방법을 AR, FERET,




그림 3 10×10, 20×20 그리고 30×30 크기의 임의로 취한 오클루전을 갖는 AT&T 얼굴 영상

AT&T의 얼굴 데이터베이스에 적용한 인식결과를 나타내고 있다. 모든 결과에서 LS-ICA 방법이 거리공식에 관계없이 기존의 다른 방법보다 인식성능이 더 우수함을 보여준다. 그림 4의 FERET 데이터베이스의 실험결과

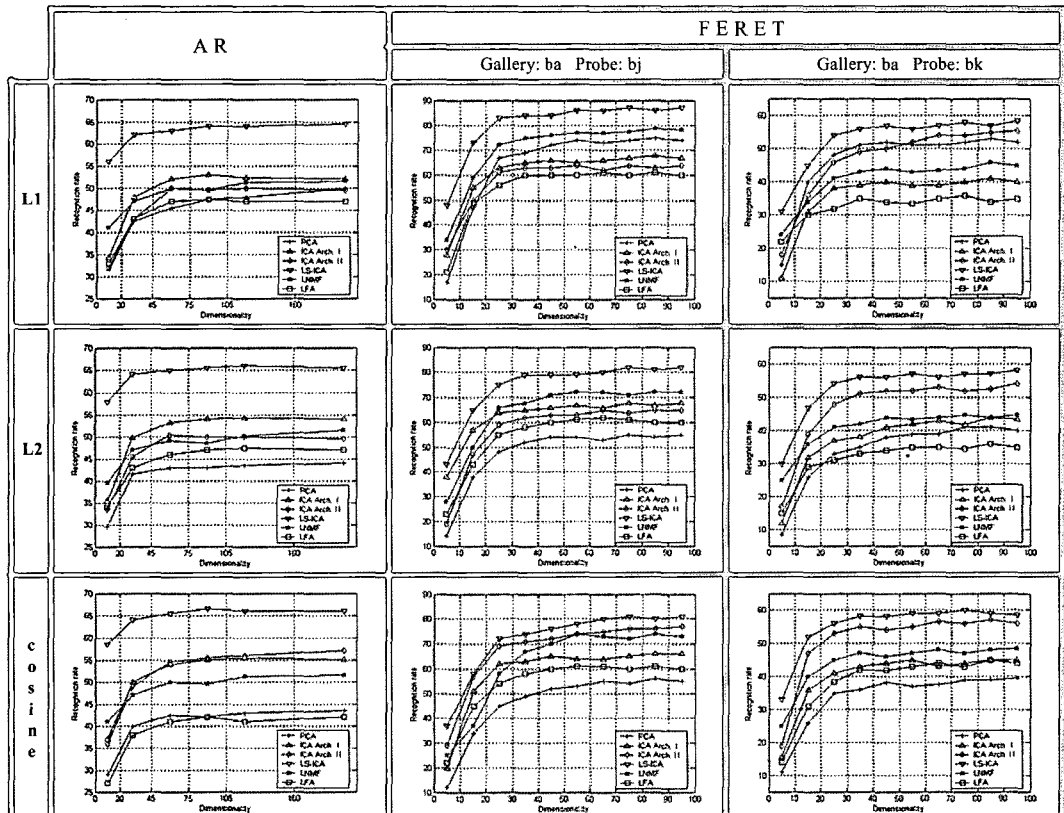


그림 4 AR, FERET ('ba'-'bj' 집합과 'ba'-'bk' 집합) 데이터베이스에 대해 L1, L2, cosine의 거리공식을 사용한 PCA, ICA-I, ICA-II, LNMF, LFA 그리고 LS-ICA의 인식을 비교

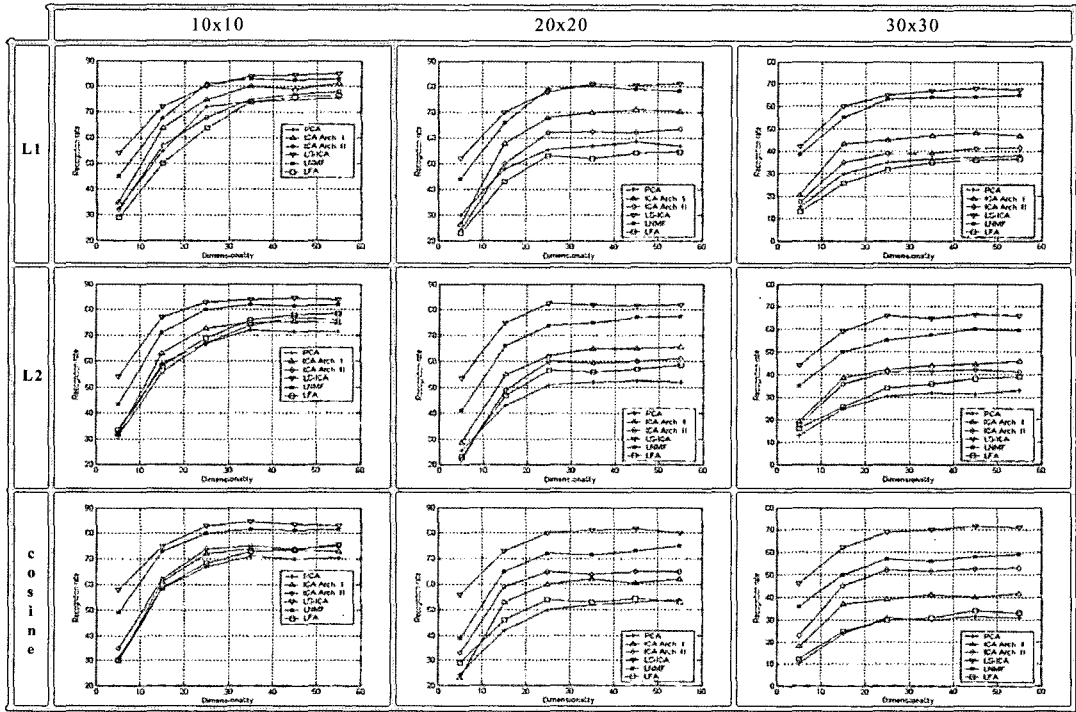


그림 5 10×10, 20×20 그리고 30×30 크기의 오클루전을 갖는 AT&T 데이터베이스에 대해 PCA, ICA-I, ICA-II, LNMF, LFA 그리고 제안된 LS-ICA의 인식률 비교

에서는 Draper[15]의 연구결과에서 보여지듯이, PCA와 ICA 방법의 인식 성능이 거리공식에 의존함을 알 수 있다. 즉, PCA방법의 경우에는 L1 거리를 사용하는 것이 더 좋은 인식성능을 보였다. LS-ICA 방법은 L1 거리에서 좋은 인식결과를 보인 PCA방법보다도 더 우수한 인식 성능을 보임을 알 수 있다. 표정변화와 같은 부분적인 왜곡을 갖는 얼굴 영상의 경우에 ICA-I 방법이 ICA-II 방법보다 더 좋은 인식결과를 갖는다. 이는 Bartlett[16]의 연구결과와도 일치함을 보여준다. 그림 5의 실험결과에서는 오클루전의 크기가 증가됨에 따라 LS-ICA와 LNMF 방법이 다른 방법들 보다 더 월등한 인식 성능을 보였다. 반면에 ICA-I 방법은 LFA 방법 보다 나은 성능을 보였으나 두 방법 모두 여전히 국부적 영역 이외의 화소들 값에 의해 영향을 받기 때문에 인식 성능의 저하를 초래하였다. 이는 ICA-I이 LFA 보다 더 의미 있는 얼굴특징요소들을 가지고 있음을 실험적으로 보여주는 것이며 표정변화를 갖는 얼굴 영상의 경우에 ICA-I 방법이 LFA방법보다 더 좋은 인식결과를 갖는다는 기존의 연구[16]와도 일치함을 알 수 있다. LS-ICA방법이 LNMF방법보다 더 나은 인식결과를 보였으며 LNMF 방법에서는 단순히 공간적인 국부성만을 기준으로 양의 값을 갖는 기저영상을 생성하는 반면

LS-ICA방법은 개인간의 식별에 의미가 있는 눈, 코, 입, 눈썹 등의 얼굴 특징요소를 반영하는 기저영상을 생성하였기 때문에 분석된다. 본 논문에서 제안한 LS-ICA방법은 국부적 변형이나 오클루전에 강인한 효과적인 국부적 표현 방법임을 알 수 있다.

5. 결론

본 논문에서 제안한 LS-ICA방법은 “Recognition by Parts”의 효과를 최대화 하기 위해 ICA-I의 기저영상들로부터 국부적 특징을 갖는 기저영상들을 생성하여 얼굴 인식에 사용되었다. LS-ICA방법은 기존의 알고리즘과는 달리 거리공식에 영향 받지 않고 PCA, ICA-I, ICA-II, LNMF 그리고 LFA 방법 보다 좋은 인식성능을 보였다. 특히, 완전한 국부적 특징을 가지므로 부분적인 오클루전이나 표정변화를 갖는 얼굴영상에 대해 기존의 방법들보다 더 좋은 인식결과를 보이게 된다.

참고문헌

[1] M. A. Turk and A. P. Pentland, "Eigenfaces for recognition," *Cognitive Neuroscience*, vol. 3, no. 1, pp. 71-86, 1991.
 [2] M. S. Bartlett, J. R. Movellan, and T. J.

- Sejnowski, "Face Recognition by Independent Component Analysis," *IEEE Trans. Neural Networks*, vol. 13, no. 6, pp. 1450-1464, 2002.
- [3] Aapo Hyvarinen and Erki Oja, "Independent component analysis: a tutorial," http://www.cis.hut.fi/~aapo/papers/IJCNN99_tutorialweb/, 1999.
- [4] A. Hyvärinen, "The Fixed-point Algorithm and Maximum Likelihood Estimation for Independent Component Analysis," *Neural Processing Letters*, vol. 10, pp. 1-5, 1999.
- [5] P. Belhumeur, J. Hespanha, and D. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection," *IEEE PAMI*, vol. 19, no. 7, pp. 711-720, 1999.
- [6] A. P. Pentland, "Recognition by parts," *IEEE Proceedings of the First International Conference on Computer Vision*, pp. 612-620, 1987.
- [7] A. J. Bell and T. J. Sejnowski, "The Independent Components of Natural Scenes are Edge Filters," *Vision Research*, vol. 37, no. 23, pp. 3327-3338, 1997.
- [8] P. Penev and J. Atick, "Local Feature Analysis: A general statistical theory for object representation," *Network: Computation in Neural Systems*, vol. 7, no. 3, pp. 477-500, 1996.
- [9] S. Z. Li, X. W. Hou, H. J. Zhang, "Learning Spatially Localized, Parts-Based Representation," *Computer Vision and Pattern Recognition*, vol. 1, pp. 207-212, 2001.
- [10] D. D. Lee and H. S. Seung, "Learning the parts of objects by non-negative matrix factorization," *Nature*, vol. 401, pp. 788-791, 1999.
- [11] J. S. Kim, J. M. Choi, J. H. Yi, "ICA Based Face Recognition Robust to Partial Occlusion and Local Distortions," *ICBA 2004, LNCS*, vol. 3072, pp. 147-154, 2004.
- [12] P. J. Phillips, H. Moon, S. A. Rizvi, and P. J. Rauss, "The FERET Evaluation Methodology for Face Recognition Algorithms," *IEEE PAMI*, vol. 22, no. 10, pp. 1090-1104, 2000.
- [13] A. M. Martinez and R. Benavente, "The AR face database," *CVC Tech*, 1998.
- [14] <http://www.uk.research.att.com/facedatabase.html>.
- [15] B. A. Draper, K. Baek, M. S. Bartlett, and J. R. Beveridge, "Recognizing faces with PCA and ICA," *Computer Vision and Image Understanding*, vol. 91, no. 1, pp. 115-137, 2003.
- [16] M. S. Bartlett, *Face Image Analysis by Unsupervised Learning*, Kluwer Academic Publishers, 2001.
- [17] S. Wild, J. Curry, A. Dougherty, "Motivating Non-Negative Matrix Factorizations," *In Proceedings of the Eighth SIAM Conference on Applied Linear Algebra*, July 2003.



김 종 선

1999년 목포대학교 컴퓨터공학과(학사)
2002년 성균관대학교 전기전자 및 컴퓨터공학과(석사). 2006년 성균관대학교 전기전자 및 컴퓨터공학과(공학박사). 2006년~현재 연세대학교 생체인식연구센터 연구교수. 관심분야는 컴퓨터비전, 얼굴

인식, 패턴인식



이 준 호

1985년 서울대학교 전기공학과(학사). 1987년 The Pennsylvania State University, Department of Electrical Engineering (석사). 1994년 Purdue University, School of Electrical and Computer Engineering(공학박사). 1994년~1995년 University of California, Riverside 연구원. 1995년~1997년 한국과학기술연구원 선임연구원. 1997년~2001년 성균관대학교 전기전자컴퓨터공학과 조교수. 2001년~현재 성균관대학교 정보통신공학부 부교수. 관심분야는 컴퓨터비전 기반 HCI