

## 조명 변화, 얼굴 표정 변화에 강인한 얼굴 인식 방법

(A Face Recognition Method Robust to Variations in  
Lighting and Facial Expression)

양희성<sup>\*</sup> 김유호<sup>\*</sup> 이준호<sup>††</sup>

(Hee-Sung Yang) (Yu-Ho Kim) (June-Ho Yi)

**요약** 본 논문은 조명 변화, 표정 변화, 부분적인 오클루전이 있는 얼굴 영상에 강인하고 적은 메모리양과 계산량을 갖는 효율적인 얼굴 인식 방법을 제안한다. SKKUface(Sungkyunkwan University face)라 명명한 이 방법은 먼저 훈련 영상에 PCA(principal component analysis)를 적용하여 차원을 줄일 때 구해지는 특징 벡터 공간에서 조명 변화, 얼굴 표정 변화 등에 해당되는 공간이 최대한 제외된 새로운 특징 벡터 공간을 생성한다. 이러한 특징 벡터 공간은 얼굴의 고유특징만을 주로 포함하는 벡터 공간이므로 이러한 벡터 공간에 Fisher linear discriminant를 적용하면 클래스간의 더욱 효과적인 분리가 이루어져 인식률을 획기적으로 향상시킨다. 또한, SKKUface 방법은 클래스간 분산(between-class covariance) 행렬과 클래스내 분산(within-class covariance) 행렬을 계산할 때 문제가 되는 메모리양과 계산 시간을 획기적으로 줄이는 방법을 제안하여 적용하였다. 제안된 SKKUface 방법의 얼굴 인식 성능을 평가하기 위하여 YALE, SKKU, ORL(Olivetti Research Laboratory) 얼굴 데이터베이스를 가지고 기존의 얼굴 인식 방법으로 널리 알려진 Eigenface 방법, Fisherface 방법과 함께 인식률을 비교 평가하였다. 실험 결과, 제안된 SKKUface 방법이 조명 변화, 부분적인 오클루전이 있는 얼굴 영상에 대해서 Eigenface 방법과 Fisherface 방법에 비해 인식률이 상당히 우수함을 알 수 있었다.

**Abstract** This research feature a new method for automatic face recognition robust to variations in lighting, facial expression and eyewear. The new algorithm named SKKUfaces (Sungkyunkwan University faces) employs PCA (Principal Component analysis) and FLD (Fisher's Linear Discriminant) in series similarly to Fisherfaces. The fundamental difference is that SKKUfaces effectively eliminates, in the reduced PCA subspace, portions of the subspace that are responsible for variations in lighting and facial expression and then applies FLD to the resulting subspace. This results in superb discriminating power for pattern classification and excellent recognition accuracy. We also propose an efficient method to compute the between-class scatter and within-class scatter matrices for FLD analysis. We have evaluated the performance of SKKUfaces using YALE, SKKU, and ORL(Olivetti Research Laboratory) facial database. Initial experimental results show that the SKKUfaces method is computationally efficient and achieves much better recognition accuracy than Fisherface method especially for facial images with variations in lighting and eyewear.

### 1. 서 론

얼굴 인식은 동일 사람의 얼굴이라도 조명, 표정; 연령, 영상이 획득된 시기, 잡음 등의 변화에 따라 매우 다른 얼굴 영상들로 나타나기 때문에 매우 어려운 문제이다. 얼굴 인식 시스템의 핵심은 이러한 얼굴 영상 변화에 영향을 받지 않고 안정적인 얼굴 인식 성능을 구현하는 것이다. 안정된 성능을 갖는 얼굴 인식 시스템의 개발은 보안 시스템, 휴먼 컴퓨터 인터페이스(human-computer interface) 등의 분야에 파급 효과가 지대하

\* 학생회원 : 성균관대 전기전자및컴퓨터공학부  
hsyang@ece.skku.ac.kr  
luke79@ece.skku.ac.kr

†† 종신회원 : 성균관대 전기전자및컴퓨터공학부 교수

jhyi@ece.skku.ac.kr

논문접수 : 1999년 12월 30일

심사완료 : 2000년 12월 18일

다.

기존의 얼굴 인식은 얼굴의 국부적인 기하학적 특징을 이용하거나 템플릿 매칭(template matching)을 적용하는 방법[3, 4, 6]이 있었으나, 조명 변화나 표정 변화를 갖는 얼굴 영상을 인식하기 위해서는 많은 훈련 영상으로 인한 메모리양과 계산 시간이 문제가 되어 왔다. 메모리양과 인식 시간을 줄이기 위하여 하나의 얼굴 영상을 벡터 공간상의 하나의 특징 벡터들로 변환하여 입력 얼굴 영상의 특징 벡터와 인식 대상 얼굴의 특징 벡터들을 비교함으로써 얼굴을 인식하는 방법[5, 8]이 연구되어 왔으며 대표적으로 Eigenface 방법[2]과 Fisherface 방법[1]이 있다. 이하에서는 하나의 얼굴 영상이 하나의 벡터로 표현되는 벡터 공간을 얼굴 벡터 공간이라 칭한다.

Eigenface 방법은 전체 훈련 영상 데이터의 분산을 나타내는 분산(covariance) 행렬로부터 고유치와 고유벡터를 구하고 얼굴 영상을 큰 값의 고유치들에 대응하는 고유벡터들의 좌표로 표현한다. 이렇게 구한 좌표가 하나의 얼굴 영상을 나타내는 특징 벡터이다. 실제 인식 단계에서는, 입력으로 들어온 얼굴 영상을 선형 변환하여 얻은 특징 벡터를 오프라인(off-line)시 미리 구해 놓은 특징 벡터들과 비교함으로써 얼굴을 인식하게 된다. 얼굴 영상에 대해 PCA(principal component analysis)를 적용하여 얼굴 벡터 공간의 차원을 효과적으로 줄임으로써 전체 얼굴 영상들을 선형 변환된 몇 개의 특징 벡터만을 비교하여 인식하므로 실제 인식(on-line)시 계산 속도가 빠르다는 장점이 있다. 그러나 조명 변화가 있는 얼굴 영상이나 얼굴의 표정이 변화할 때 또는 부분적인 오블루전(occlusion)이 있는 얼굴 영상들로부터 구하여진 특징 벡터들은 클래스간의 분리가 용이하지 않아 인식률이 저조하다는 단점이 있다. 그 이유는 Eigenface 방법은 각 클래스내, 클래스간 분산 행렬 대신 전체 얼굴 영상 벡터들의 분산 행렬의 고유치 분석을 수행하기 때문이다. 조명 변화에 의한 영향을 최소화하기 위해 3개의 가장 중요한 고유얼굴(eigenface)영상을 사용하지 않으면 특징 벡터들의 클래스 분리가 좀 나아진다는 연구보고[9]가 있지만 클래스 정보를 사용하는 방법보다는 인식률이 훨씬 떨어진다.

Fisherface 방법은 PCA를 적용하여 얼굴을 인식하는 방법에 부가하여 클래스내의 데이터 분산을 나타내는 행렬과 클래스간 데이터 분산을 나타내는 행렬을 이용하는 FLD(fisher linear discriminant)[10]를 적용하는 방법이다. FLD는 얼굴 벡터 공간의 차원을 획기적으로 줄이는 효과뿐만 아니라 선형 변환된 특징 벡터들 사이

의 클래스 분리를 최대로 하는 선형 변환을 이용함으로써 클래스간의 특징 벡터들을 비교적 정확하게 분류하는 장점이 있다. FLD를 적용하여 얼굴을 인식하는 Fisherface 방법은 조명이나 표정 변화가 있는 얼굴 영상에 대해 Eigenface 방법보다 우수한 인식 성능을 나타낸다. 클래스내, 클래스간 분산을 나타내는 행렬을 구하기 위해서는 많은 메모리양과 계산 시간을 필요로 하고, 조명 변화나 오블루전이 심한 얼굴 영상에 대해서는 여전히 인식률이 떨어지는 단점이 있다.

본 논문에서는 조명 변화, 표정 변화, 그리고 선글라스 등의 부분적인 오블루전이 있는 얼굴 영상 인식에 강인한 특징 벡터를 구하는 방법을 제안한다. SKKU face 방법은 PCA와 FLD를 연속으로 적용한다는 점에서는 Fisherface 방법과 유사하다. Fisherface 방법과의 근본적인 차이는 다음과 같다. PCA를 통하여 얼굴 벡터 공간의 차원을 줄일 때 차원이 줄어든 새로운 특징 벡터 공간은 원래의 특징 벡터 공간에서 조명 변화, 얼굴 표정 변화 등에 해당되는 공간이 최대한 제외된다는 점이다. 이러한 얼굴 벡터 공간은 얼굴의 고유특징만을 주로 포함하는 벡터 공간이므로 이러한 벡터 공간에 FLD를 적용하면 클래스간의 더욱 효과적인 분리가 이루어져 인식률을 획기적으로 향상시킨다. 간단히 기술하면, SKKUface 방법에서 계산되는 최종의 얼굴 벡터 공간은 Fisherface 방법에서 최종 도출되는 얼굴 벡터 공간보다 얼굴 인식목적에 더욱 적합한 벡터 공간이다. 또한, 본 연구에서는 FLD를 적용하는데 필요한 클래스내, 클래스간 분산 행렬 계산시 큰 문제점인 막대한 계산 시간과 메모리 용량을 획기적으로 줄일 수 있는 방법을 제안한다.

제안된 방법의 인식 성능을 검증하기 위하여 얼굴 인식 방법으로 널리 알려진 Eigenface 방법과 Fisherface 방법에 대하여 자체적으로 구축한 SKKU 얼굴 영상 데이터베이스(그림 3 참조)와 기존에 많이 사용된 YALE 데이터베이스(그림 6 참조)와 ORL(Olivetti Research Laboratory) 데이터베이스를 이용하여 인식 성능을 비교 평가하였다. 실험 결과, 제안된 방법이 위 두 방법에 비해 조명 변화와 오블루전이 있는 얼굴 영상에 대하여 인식률이 상당히 우수함을 알 수 있었다.

본 논문의 구성은 다음과 같다. 다음 장에서는 기존의 Eigenface 방법과 Fisherface 방법에 대하여 설명하고, 제 3장에서는 SKKUface 방법에서 제안하는 얼굴 영상 벡터의 선형 변환 행렬을 구하는 방법과 FLD를 적용시 필요한 클래스내, 클래스간 분산 행렬을 효과적으로 구하는 방법을 설명한다. 제 4장에서는 실험에 사

용된 얼굴 데이터베이스와 실험 방법 및 실험 결과에 대해서 설명한다.

## 2. 기존의 얼굴 인식 방법

### 2.1 Eigenface 방법

Eigenface 방법은 PCA (또는 Karhunen-loeve 변환)에 기반한 방법이다. PCA는 선형 변환된 얼굴 영상 벡터들의 퍼짐(scatter)이 최대가 되는 방향의 벡터들로 구성된 직교 기저(orthonormal basis)벡터들을 제공하여 주며, 하나의 얼굴 영상 벡터를 이렇게 구한 직교 기저에서의 좌표로 표현하는 방법이다. Kirby와 Sirovich[7]는 얼굴 영상을 나타내기 위해 PCA를 처음 적용하였고 그 후 Turk와 Pentland[2]에 의해 얼굴 인식에 PCA가 적용되었다. Eigenface 방법을 간단히 살펴보면 다음과 같다. 훈련을 위해 사용된 얼굴 영상들의 집합을  $X = [\vec{X}_1, \vec{X}_2, \dots, \vec{X}_T]$ , 각 얼굴 영상 벡터에서 전체 얼굴 벡터의 평균 벡터를 뺀 벡터들의 집합을  $\Phi = [\vec{\Phi}_1, \vec{\Phi}_2, \dots, \vec{\Phi}_T]$ 라고 하면, 얼굴 영상들의 분산(covariance) 행렬은 다음과 같다.

$$S_T = \sum_{i=1}^T \vec{\Phi}_i \vec{\Phi}_i^T = \Phi \Phi^T \quad (1)$$

$S_T$ 의 고유벡터 행렬  $\Psi$ 와 고유값 행렬  $\Lambda$ 는 식 (2)에 의해 구해진다.

$$S_T \Psi = \Psi \Lambda \quad (2)$$

영상의 크기가  $M \times N$ 이고 영상의 개수가  $T$ 개일 때,  $S_T$ 의 크기는  $MN \times MN$ 이므로 계산하기에 불가능할 정도의 많은 메모리와 계산 시간이 필요하다. 대개의 경우  $M \times N \gg T$ 이므로 식 (3-4)에서와 같이  $\Phi \Phi^T$  ( $MN \times MN$ ) 대신  $\Phi^T \Phi$  ( $T \times T$ ) 행렬의 고유치 분석을 통하여 효율적으로  $\Psi$ 와  $\Lambda$ 를 구한다[2].

$$(\Phi^T \Phi) V = V \Lambda \quad (3)$$

식 (3)의 양변에  $\Phi$ 를 곱하면 아래의 결과를 얻는다.

$$\Phi (\Phi^T \Phi) V = (\Phi \Phi^T) (\Phi V) = (\Phi V) \Lambda \quad (4)$$

여기서  $V = [\vec{V}_1, \vec{V}_2, \dots, \vec{V}_T]$ ,  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_T)$ 이다.  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_T$ 로서 정렬된다면, 이에 대응하는 처음  $m$  개의 고유벡터는 식 (5)와 같이 구하게 되며 이렇게 구한 고유벡터들로 선형 변환 행렬  $W_{pca}$ 를 계산한다.

$$W_{pca} = [\Phi \vec{V}_1, \Phi \vec{V}_2, \dots, \Phi \vec{V}_m] \quad (5)$$

$\Phi \vec{V}_1, \Phi \vec{V}_2, \dots, \Phi \vec{V}_m$  가  $m$  개의 고유얼굴(eigen-face)들(그림 1 참조)을 나타내며 하나의 얼굴 영상을 나타내는 벡터  $\vec{X}_i$ 는 식 (6)과 같이 선형 변환 행렬

$W_{pca}$ 에 의해  $m$  차원으로 줄여든 벡터 공간상의  $\vec{Y}_i$ 로 변환된다.

$$\vec{Y}_i = W_{pca}^T \vec{X}_i \quad (6)$$

이렇게 구한  $\vec{Y}_i$  와 오프라인(off-line)으로 미리 구하여진 벡터들과의 비교에 의하여 얼굴을 인식하는 방법이 Eigenface 방법이다. PCA는 모든 데이터의 퍼짐(scatter)을 최대화하기 때문에 인식 목적보다는 신호 데이터의 차원을 효과적으로 줄여서 표현하는 방법이다. 한편, Eigenface 방법에서 처음  $m$  개의 고유벡터를 취할 때  $m$ 의 값을 정하는 문제에 대한 연구보고[5]가 있으나 아직 일반적으로 통용되는 연구 결과는 확립되어 있지 않다.



그림 1 SKKU 얼굴 영상으로부터 계산된 처음 네 개의 고유얼굴

### 2.2 Fisherface 방법

Fisherface 방법은 PCA를 적용하여 구하여진 축소된 벡터 공간에서 인식 목적을 위해 적합한 정보를 얻기 위해, 얼굴 벡터들을 클래스내 분산은 최소로, 클래스간 분산은 최대가 되도록 하는 선형 변환을 구하여 나타낸다. 전체 얼굴 영상 벡터의 분산에 대하여 고유값 분석(eigenvalue analysis)을 행하는 Eigenface 방법과는 달리 클래스내 분산, 클래스간 분산에 고유값 분석을 행하여 클래스 정보를 이용하므로 Eigenface 방법의 인식률 보다 훨씬 높을 것이다.

$w_1, w_2, \dots, w_c$  를 분류된 클래스들,  $N_1, N_2, \dots, N_c$  를 각 클래스에 속한 얼굴 영상의 개수,  $\vec{M}_1, \vec{M}_2, \dots, \vec{M}_c$  를 PCA를 적용한 후, 구한 각 클래스의 평균,  $\vec{M}$  을 전체 평균이라고 하자.  $\vec{Y}_{ij} = W_{pca}^T \vec{X}_{ij}$  이므로  $\vec{M}_i = -\frac{1}{N_i} \sum_{j=1}^{N_i} \vec{Y}_{ij} = W_{pca}^T \left( -\frac{1}{N_i} \sum_{j=1}^{N_i} \vec{X}_{ij} \right)$  이고  $\vec{Y}_{ij}$  들의 클래스내 분산 행렬  $S_w$ , 클래스간 분산 행렬  $S_b$  는 식 (7)과 같이 계산된다. 여기서  $\vec{X}_{ij}$  와  $\vec{Y}_{ij}$  는  $W_{pca}$ 에 의한 선형 변환 이전 및 이후의  $i$  번째 클래스에 속한  $j$  번째 얼굴 벡터를 나타낸다.

$$S_w = W_{pca}^T S_w W_{pca}, S_b = W_{pca}^T S_b W_{pca} \quad (7)$$

FLD를 적용하여  $\frac{|W^T S_b W|}{|W^T S_w W|}$ 를 최대값으로 만들어 주는 선형 변환 행렬  $W = W_{fld}$ 를 계산하게 되며  $W_{fld}$ 의 각 열은  $(S_w)^{-1} S_b$ 의 가장 큰  $(C-1)$ 개의 고유치에 해당하는 고유벡터로서 구한다[11]. 결과적으로 Fisherface 방법은 얼굴 영상 벡터  $\vec{X}_{ij}$ 를  $\vec{Q}_{ij} = W_{fld}^T W_{pca}^T \vec{X}_{ij}$ 에 의해 선형 변환된  $\vec{Q}_{ij}$ 로 표현되어 오프라인(off-line)에서 미리 구하여진 벡터들과의 비교에 의하여 얼굴을 인식하게 된다.

### 3. 제안된 방법: SKKUfaces

#### 3.1 SKKUfaces

본 논문이 제안하는 SKKUface 방법이 그림 2에 개략적으로 나타나 있다. 하나의 얼굴 영상을 나타내는 최종 특징 벡터를 얻기 위해서 Fisherface 방법과 유사하게  $\vec{Q}_{ij} = W_{fld}^T W_{pca}^T \vec{X}_{ij}$ 로 표현되는 선형 변환을 적용한다.

Fisherface 방법과의 근본적인 차이는 다음과 같다. PCA를 적용하여  $W_{pca}$ 를 구할 때, 가장 큰 고유치 몇 개에 해당하는 고유벡터들은 제외하고 구한  $W_{pca}$ 로 특정 벡터 공간의 차원을 줄인다는 것이다. 차원이 줄어든 새로운 특징 벡터 공간은 원래의 특징 벡터 공간에서 조명변화, 얼굴 표정 변화 등에 해당되는 공간은 최대한 제외된 특징 벡터 공간이다. 이러한 특징 벡터 공간은 얼굴의 고유특징만을 주로 포함하는 벡터 공간이므로

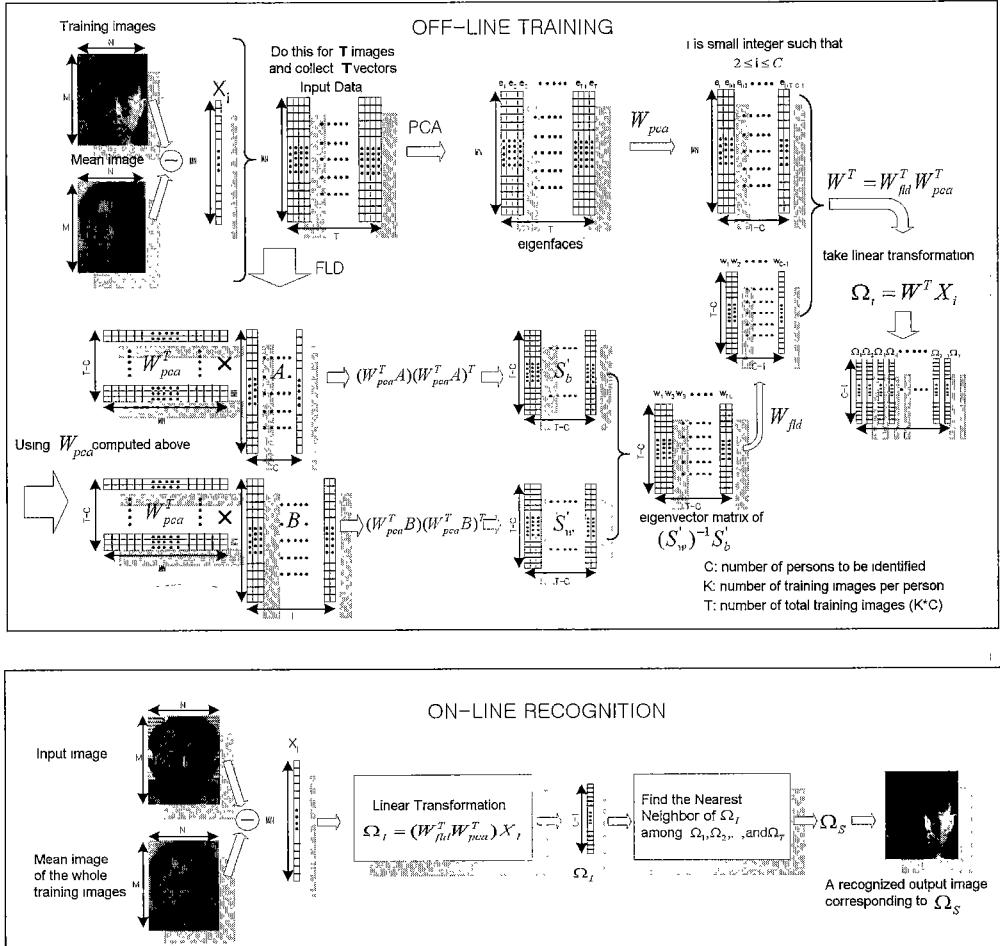


그림 2 제안된 얼굴 인식 시스템

이러한 벡터 공간에 FLD를 적용하면 폐턴 인식률을 훨씬 개선시키리라는 것을 기대할 수 있다. 간단히 기술하면, SKKUface 방법에서 계산되는 특징 벡터가 Fisherface 방법에서 도출되는 특징 벡터보다 폐턴 인식 목적에 더욱 적합하다.

SKKUface 방법을 좀 더 자세히 살펴보면 다음과 같다. 그럼 2에서 보여지듯이 특징벡터공간의 차원을 줄이기 위해 PCA를 적용한다. 전체 훈련 영상에는 각 사람에 대한 표정 변화, 조명 변화, 부분적인 오클루전이 있는 얼굴 영상들로 구성되어 있으므로 구해진 고유얼굴들에서 조명 변화 등의 특징을 포함한 고유벡터를 제거한다. 즉, 그림 2에서 보듯이  $e_i$ 에서  $e_{i+T-C-1}$ 에 대응되는 (T-C) 개의 고유벡터들로 구성된 선형 변환 벡터  $W_{pca}$ 를 구하며 여기서  $i$ 는  $2 \leq i \leq C$  이다. 본 논문의 실험에서는  $i = 2$  즉, 가장 큰 고유치에 해당하는 고유얼굴만을 제외하였다. 또한 FLD 단계에서의 선형 변환 행렬  $W_{fld}$ 를 구하기 위해  $W_{pca}$ 를 이용한 선형 변환을 통하여 차원이 줄어든 특징 벡터 공간의 클래스내 분산 행렬  $S_w'$ 와 클래스간 분산 행렬  $S_b'$ 를 3.2절에서 제안된 방법을 통하여 계산한다.

### 3.2 $S_w'$ 와 $S_b'$ 를 구할 때 메모리와 계산량을 줄이는 방법

$W_{pca}$ 를 적용하여 얼굴 벡터 공간의 차원을 줄인 후,  $(S_w')^{-1}S_b'$ 의 고유치  $\lambda_i$  중에 가장 큰 (C-1) 개에 대응하는 고유벡터  $\vec{v}_i$ 를 구해서 선형 변환 행렬  $W_{fld}$ 를 얻게 된다.

$$\{(S_w')^{-1}S_b'\}\vec{v}_i = \lambda_i \vec{v}_i \quad (8)$$

여기서  $S_w' = W_{pca}^T S_w W_{pca}$ ,  $S_b' = W_{pca}^T S_b W_{pca}$ 이다.

$S_b'$ ,  $S_w'$ 를 구하기 위해서는  $W_{pca}$ 에 의한 선형 변환 이전의 얼굴 영상 벡터들의  $S_b$ 와  $S_w$ 를 먼저 계산하여야 하는데 행렬의 크기가 각각  $MN \times MN$ 으로서 염청난 메모리와 계산 시간을 요구한다. 한편, 각 클래스의 크기 즉, 얼굴 영상의 수가 같다고 가정하고 클래스의 크기를 나타내는 상수를 무시하면  $S_b$ 는 식 (9)과 같이 다시 정리될 수 있다.

$$\begin{aligned} S_b &= \sum_{i=1}^c (\vec{M}_i - \vec{M}) (\vec{M}_i - \vec{M})^T \\ &= (\vec{M}_1 - \vec{M}) (\vec{M}_1 - \vec{M})^T + \dots + (\vec{M}_c - \vec{M}) (\vec{M}_c - \vec{M})^T \quad (9) \\ &= [\vec{M}_1 - \vec{M}, \vec{M}_2 - \vec{M}, \dots, \vec{M}_c - \vec{M}] \begin{bmatrix} (\vec{M}_1 - \vec{M})^T \\ (\vec{M}_2 - \vec{M})^T \\ \vdots \\ (\vec{M}_c - \vec{M})^T \end{bmatrix} \\ &= A A^T \end{aligned}$$

여기서,  $\vec{M}_i$ 는  $i$ 번째 클래스의 평균,  $\vec{M}$ 은 전체 평균,

$A = [\vec{M}_1 - \vec{M}, \vec{M}_2 - \vec{M}, \dots, \vec{M}_c - \vec{M}]$  이다.

$A$  행렬의 크기는  $MN \times C$ 이고  $MN \gg C$  이므로 염청난 메모리 절약 효과가 있으며 계산 시간도 상당히 줄어든다. 또한, 일단  $W_{pca}^T A$ 를 구하면  $W_{pca}^T A$ 의 전위(transpose)를 취하여 두 행렬의 곱으로 식 (10)과 같이  $S_b'$ 를 계산하게 된다.

$$S_b' = W_{pca}^T S_b W_{pca} = W_{pca}^T A A^T W_{pca} = (W_{pca}^T A)(W_{pca}^T A)^T \quad (10)$$

$\vec{K}_{ij} = \vec{X}_j - \vec{M}_i$ 로 두면 유사한 방법으로  $S_w'$ 도 식 (11)과 같이 표현할 수 있다.

$$\begin{aligned} S_w' &= \sum_{i=1}^c \sum_{j=1}^N (\vec{X}_j - \vec{M}_i) (\vec{X}_j - \vec{M}_i)^T \\ &= [\vec{K}_{11}, \dots, \vec{K}_{1N_1}, \vec{K}_{21}, \dots, \vec{K}_{2N_2}, \dots, \vec{K}_{c1}, \dots, \vec{K}_{cN_c}] \begin{bmatrix} \vec{K}_{11}^T \\ \vec{K}_{21}^T \\ \vdots \\ \vec{K}_{cN_c}^T \end{bmatrix} \quad (11) \\ &= B B^T \end{aligned}$$

여기서  $B = [\vec{K}_{11}], \dots, \vec{K}_{1N_1}, \vec{K}_{21}, \dots, \vec{K}_{2N_2}, \dots, \vec{K}_{c1}, \dots, \vec{K}_{cN_c}]$ 이다.

$B$  행렬의 크기는  $MN \times T$ 이고  $MN \gg T$  이므로  $S_b'$ 와 마찬가지로 많은 메모리와 계산 시간을 줄일 수 있다. 마찬가지로 일단  $W_{pca}^T B$ 를 구하면  $W_{pca}^T B$ 의 전위(transpose)를 취하여 두 행렬의 곱으로 식 (12)과 같이  $S_w'$ 를 계산하게 된다.

$$S_w' = W_{pca}^T S_w W_{pca} = W_{pca}^T B B^T W_{pca} = (W_{pca}^T B)(W_{pca}^T B)^T \quad (12)$$

( $S_w'$ ) $^{-1}S_b'$ 는 (T-C)  $\times$  (T-C) 행렬이므로 (T-C) 개의 고유치중에 가장 큰 (C-1) 개의 고유치에 대응하는 고유벡터를 구해서 선형 변환 행렬  $W_{fld}$ 를 구한다.

제안된 방법의 메모리 절약 효과와 계산 시간을 예를 들어서 설명하면 얼굴 영상의 크기가  $M = N = 256$ 이고 인식하고자 하는 클래스가  $C = 10$ 개이고 각 클래스의 얼굴 영상이  $K = 15$ 개라고 하자.  $S_b$ 와  $S_w$ 를 따로 먼저 구할 때는 크기가  $65536 \times 65536$ 인 행렬을 계산하여야 한다. 제안된 방법을 적용하면  $S_b$ 를 계산할 때는 크기가  $65536 \times 10$ 인 행렬을 계산하고  $S_w$ 를 구할 때는 크기가  $65536 \times 150$ 인 행렬만 계산하면 되기 때문에 메모리는  $S_b$ 에서 약 650 배 정도,  $S_w$ 에서는 약 43 배 정도 절약되며, 계산량은  $S_b$ 에서 약 6500 배 정도,  $S_w$ 에서는 약 430 배 정도 감소함을 알 수 있다.

## 4. 실험

본 논문이 제안한 SKKUface 방법의 얼굴 인식 성능을 검증하기 위하여 자체적으로 제작한 SKKU 데이터

베이스의 얼굴 영상과 기존의 얼굴 인식 연구에 많이 사용된 YALE 데이터베이스와 ORL(Olivetti Research Laboratory)데이터베이스의 얼굴 영상을 가지고 실험하였다. 각 데이터베이스는 조명 변화, 얼굴의 표정 변화, 부분적인 오블루전을 갖는 얼굴 영상으로 구성되어 있

으며, 이러한 얼굴 영상에 대하여 기존의 Eigenface, Fisherface 방법에 대한 인식률과 SKKUface 방법의 인식률과 비교 평가하였다.

#### 4.1 SKKU 데이터베이스에 대한 실험 영상 및 결과

SKKU 데이터베이스[13]는 화상 통신용 저가의



그림 3 실험에 사용된 SKKU 얼굴 데이터베이스

CCD 카메라를 가지고 단일 배경 하에서 촬영한 256 음 영값(gray scale)의 얼굴 영상들로 구성되어 있다. 10명의 사람에 대해 각각 10개의 얼굴 영상을 가지고 있으며 영상의 크기는  $50 \times 40$  픽셀이다. 각 사람의 얼굴 영상은 왼쪽과 오른쪽에서 조명을 비추었을 때 촬영한 조명 변화의 영상군과 웃거나 찡그리거나 입을 벌리거나 오므리거나 눈을 감았을 때 촬영한 표정 변화의 영상군, 안경 착용 유무에서 촬영한 오클루전 영상군, 그리고 헤어스타일이 변했을 때 촬영한 얼굴 영상으로 구성된 총 10개의 영상을 갖는다. 또한, 10개의 영상 중에 5개의 영상을 먼저 촬영하여 얻은 다음, 2주 후 나머지 5개의 영상을 동일한 환경에서 다시 촬영하여 시간 경과에 따라 나타날 수 있는 동일 사람의 미묘한 변화도 고려하였다. 그림 3은 위에서 설명한 SKKU 데이터베이스를 나타낸다.

실험은 leaving-one-out 방법[11]을 통하여 이루어지는데 SKKU 데이터베이스의 전체 영상 중에 인식하고자 하는 얼굴 영상을 제외한 나머지 영상을 훈련 영상으로 정하여 제안된 방법을 통하여 구한 PCA 단계에서의 선형 변화 행렬과 FLD 단계에서의 선형 변환 행렬을 서로 곱하여 전체 선형 변환 행렬( $W^T$ )를 구하게 된다. 전체 선형 변환 행렬의 열벡터들이 SKKUfaces를 나타낸다. 그림 4는 SKKU 데이터베이스를 이용하여 얻어진 선형 변환 행렬 중 처음 4개의 열벡터 즉, SKKUface를 보여준다.



그림 4 체안된 방법을 통하여 구해진 SKKUfaces

구해진 선형 변환 행렬을 가지고 훈련 영상을 작은 차원의 패턴 벡터들로 선형 변환한다. 그리고 인식하고자 하는 얼굴 영상도 SKKUface 방법을 적용하여 구해진 패턴 벡터를 가지고 훈련 영상에서 미리 구해진 패턴 벡터들과의 최소 유clidean 거리를 구하는 nearest neighbor 분류법[11]을 적용하여 얼굴을 인식하게 된다. 그림 5에서는 제안된 SKKUface 방법에 대하여 SKKU 데이터베이스를 가지고 leaving-one-out 방법과 nearest neighbor 분류법을 적용하여 얻은 인식 결과를 Fisherface 방법과 비교 평가하였다.

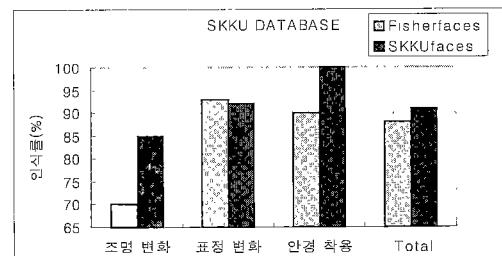


그림 5 SKKU 데이터베이스를 사용하여 구한 인식률 비교

#### 4.2 YALE 데이터베이스에 대한 실험 영상 및 결과

YALE 데이터베이스는 10 명의 사람에 대해 각각 10개의 얼굴 영상을 가지고 있으며 영상의 크기는  $50 \times 40$  픽셀이다. 각 사람의 얼굴 영상은 3개의 조명 변화의 영상군과 6개의 표정 변화의 영상군, 안경이나 선글라스 착용 유무에서 촬영한 오클루전 영상으로 구성된 총 10개의 영상을 갖는다. 그림 6은 위에서 설명한 YALE 데이터베이스[12]중의 입의의 한사람에 대한 10개의 영상을 보여준다.



그림 6 실험에 사용된 YALE 데이터베이스의 한 예

YALE 데이터베이스도 leaving-one-out 방법과 nearest neighbor 분류법을 적용하여 SKKUface 방법과 Fisherface 방법의 인식률을 그림 7에 나타내었다.

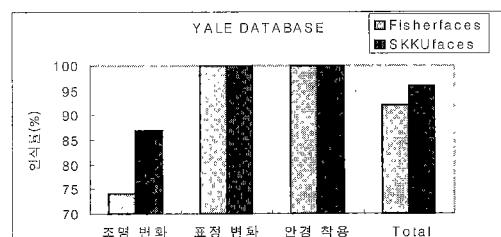


그림 7 YALE 데이터베이스를 사용하여 구한 인식률 비교

### 4.3 ORL(Olivetti Research Laboratory) 데이터베이스에 대한 실험 영상 및 결과

ORL 데이터베이스는 40 명의 사람에 대해 각각 10 개의 얼굴 영상을 가지고 있으며 영상의 크기는  $56 \times 46$  픽셀이다. 각 사람의 얼굴 영상은 좌우로 회전하면서 다양한 얼굴 표정을 갖는다. 그림 8은 ORL 데이터베이스[14] 중의 임의의 한 사람에 대한 10개의 영상을 보여준다.



그림 8 ORL 데이터베이스의 한 예

ORL 데이터베이스는 leaving-one-out 방법과 nearest neighbor 분류법을 적용하여 SKKUface 방법과 Fisherface 방법의 인식률을 그림 9에 나타내었다.

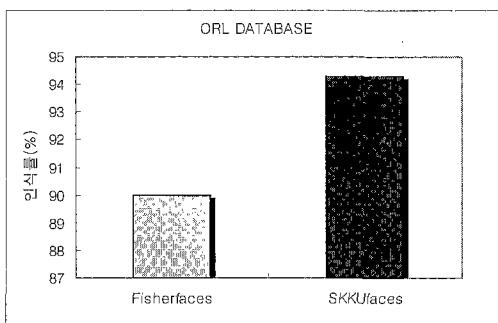


그림 9 ORL 데이터베이스를 사용하여 구한 인식률 비교

### 4.4 결과 분석

표 1에서 보듯이, 제안된 방법은 입력 영상이 조명 변화가 심한 얼굴 영상일 때 기존의 Eigenface 방법이나 Fisherface 방법에 비해 인식률이 상당히 우수함을 알 수 있다. ORL 데이터베이스는 얼굴 영상의 좌우의 회전 및 표정 변화만을 가지고 있으므로 기존의 영상군으로 나누어 실험할 수 없었으므로 표 1에는 제외하였다. 이를 통하여 SKKUface 방법으로 생성된 새로운 특징 벡터 공간이 Fisherface 방법이 PCA를 적용하여 구한

특징 벡터 공간보다 클래스의 분류 목적에 더욱 적합함을 실험적으로 확인할 수 있다. SKKUface 방법을 사용하여 향상되어진 클래스의 분리도(class separability)를 측정하기 위하여 SKKUface 방법과 Fisherface 방법 각각에 대하여  $\frac{|W_{fd}^T S_b W_{fd}|}{|W_{fd}^T S_w W_{fd}|}$  의 값을 구하여 두 값의 비율(ratio)을 계산한다. SKKU와 YALE과 ORL 데이터베이스에 대해 계산한 비율을 표 2에 나타내었다. SKKUface 방법이 생성한 특징 벡터 공간에 FLD를 적용함으로 클래스의 분리도가 상당히 향상됨을 알 수 있다. 따라서, SKKUface 방법은 폐단 분류에 있어 더 나은 분별력을 제공하여 인식률을 크게 향상한다.

표 1 기존 방법들과 SKKUface 방법과의 상대적인 성능 비교(인식률)

Method	Reduced Space	조명 변화(%)		표정 변화(%)		안경 착용(%)		Total(%)	
		SKKU	YALE	SKKU	YALE	SKKU	YALE	SKKU	YALE
Eigenfaces	18	45	30	542	884	70	80	55	70
Fisherfaces	9	70	74	93	100	90	100	88	92
SKKUfaces	9	85	87	92	100	100	100	91	96

표 2 YALE과 SKKU 데이터베이스에 대한 SKKUface 방법과 Fisherface 방법의 클래스 분리도 측정

$$\left( \frac{|W_{fd}^T S_b W_{fd}|}{|W_{fd}^T S_w W_{fd}|} \right)$$

	SKKUfaces	Fisherfaces	ratio(SKKUfaces/Fisherfaces)
SKKU database	$9.92 \times 10^{18}$	$4.98 \times 10^{17}$	19.9
YALE database	$4.83 \times 10^{40}$	$2.89 \times 10^{39}$	1.7
ORL database	$5.71 \times 10^{40}$	$3.23 \times 10^{39}$	1.77

또한, 3.2장에서 제안한 방법으로  $S_b$ 와  $S_w$ 를 계산할 때 얻게 되는 메모리와 계산량의 감소량은 다음과 같다. 얼굴 영상의 해상도가  $50 \times 40$ 이고 인식하고자 하는 클래스가 10개이고 각 클래스의 얼굴 영상이 10개이므로 3.2장의 방법을 사용하지 않고  $S_b$ 와  $S_w$ 를 구할 때는 각각의 크기가  $2000 \times 2000$ 이다. 제안된 방법은  $S_b$  행렬을  $2000 \times 10$  크기의 행렬을 이용하여 구하고  $S_w$ 는  $2000 \times 100$  크기의 행렬을 사용하여 계산될 수 있기 때문에 메모리와 계산량은  $S_b$ 의 계산에서 약 200 배 정도,  $S_w$ 의 계산에서는 약 20 배 정도 감소함을 알 수 있다.

## 5. 결 론

본 논문은 조명 변화, 표정 변화, 그리고 손, 선글라스 등의 부분적인 오클루전이 있는 얼굴 영상에 강인한 얼굴 인식 방법을 제안하였다. 제안된 SKKUface 방법은 전체 훈련 영상을 가지고 Eigenface 방법처럼 PCA(principal Component analysis)를 적용하여 고유 얼굴들을 구한다. 구해진 고유얼굴들 중에서 조명 변화와 오클루전과 같은 얼굴 영상의 큰 변화에 해당하는 고유얼굴들을 제거한 후, 얼굴의 순수한 특징만을 갖는 고유얼굴들을 가지고 FLD를 적용하여 패턴 벡터들을 구하여 인식하게 된다. 따라서, 조명 변화 등으로 인하여 얼굴에 큰 변화가 생긴 영상들도 명확히 분류할 수 있으므로 기존 방법들이 인식하기 어려웠던 조명 변화와 오클루전에 대한 인식률을 크게 향상시킬 수 있었다. 또한, 기존의 FLD를 적용할 때 클래스내, 클래스간 분산 행렬 계산의 문제점인 막대한 계산량과 메모리 용량을 간단한 연산을 통하여 획기적으로 줄일 수 있는 방법을 제안하였다. SKKUface 방법은 저가의 컴퓨터 사용으로도 고속의 우수한 인식 성능을 갖는 차세대 인식 알고리듬이다.

## 감사의 글

본 연구는 2000년도 대학기초연구 지원으로 수행되었습니다.

## 참 고 문 현

- [1] P. Belhumeur, J. Hespanha, and D. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection," IEEE Trans. on PAMI, vol. 19, no. 7, pp. 711-720, 1997.
- [2] M. Turk and A. Pentland, "Eigenfaces for Recognition," Journal of Cognitive Neuroscience, vol. 3, no. 1, pp. 71-86, 1991.
- [3] R. Brunelli and T. Poggio, "Face Recognition: Features vs. Templates," IEEE Trans. on PAMI, vol. 15, no. 15, pp. 1042-1052, 1993.
- [4] Shang-Hung Lin et al., "Face Recognition and Detection by Probabilistic Decision Based Neural Network," IEEE Trans. on Neural Network, vol. 8, no. 1, pp. 114-132, 1997.
- [5] Chengjun Liu and Harry Wechsler, "Enhanced Fisher Linear Discriminant Models for Face Recognition," Proceedings of the 14th International Conference on Pattern Recognition, vol. 2, pp. 1368-1372, 1998.
- [6] Rama Chellappa, Charles L. Wilson, and Saad Sirohey, "Human and Machine Recognition of Faces: A Survey," Proceedings of The IEEE, vol. 83, no. 5, 1995.
- [7] 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.
- [8] K. Etemad and R. Chellappa, "Discriminant Analysis for Recognition of Human Faces Image," Journal of Optical Society of America, vol. 14, no. 8, pp. 1724-1733, 1997.
- [9] A. Pentland, B. Moghaddam, T. Starner, and M. Turk, "View-Based and Modular Eigenspaces for Face Recognition," Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 84-91, 1994.
- [10] R. A. Fisher, "The Use of Multiple Measures in Taxonomic Problems," Ann. Eugenics, vol. 7, pp. 179-188, 1936.
- [11] K. Fukunaga. Introduction to Statistical Pattern Recognition. Academic Press, second edition, 1991.
- [12] <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>
- [13] <http://vulcan.skku.ac.kr/research/skkufaces.html>
- [14] [ftp://ftp.uk.research.att.com:pub/data/att\\_faces.zip](ftp://ftp.uk.research.att.com:pub/data/att_faces.zip)



양 희 성

1999년 2월 성균관대학교 제어계측공학과 학사. 1999년 3월 ~ 현재 성균관대학교 전기전자 및 컴퓨터공학부 석사과정. 관심분야는 컴퓨터비전, 영상처리, 신경망



김 유 호

1999년 2월 성균관대학교 제어계측공학과 학사. 1999년 3월 ~ 현재 성균관대학교 전기전자 및 컴퓨터공학부 석사과정. 관심분야는 컴퓨터비전, 컴퓨터그래픽스, 네트워크



이 준 호

1985년 서울대학교 전기공학과 학사. 1987년 The Pennsylvania State Univ. Dept. of Elec. Engr. 석사, 1989년 3월 ~ 1989년 11월 삼성종합기술원 연구원. 1994년: Purdue Univ. School of Elec. Engr. 박사. 1994년 9월 ~ 1995년 10월 University of California, Riverside 연구원. 1995년 11월 ~ 1997년 2월 한국과학기술원 선임연구원. 1997년 3월 ~ 현재 성균관대학교 전기전자 및 컴퓨터공학부 조교수. 관심분야는 컴퓨터 비전, 영상처리, 인공지능, 멀티미디어 시스템