

## SKL 알고리즘을 이용한 얼굴인식 후보의 점진적 등록 Sequential Registration of the Face Recognition candidate using SKL Algorithm

한학용\*, 이성목\*, 곽부동\*\*, 최원태\*\*, 강봉순\*\*\*

Hag-yong Han\*, Sung-mok Lee\*, Boo-dong Kwak\*\*, Won-tae Choi\*\*, Bong-soon Kang\*\*\*

### 요약

본 논문은 주성분 분석을 이용하는 얼굴인식 시스템에서 인식후보를 점진적으로 등록하기 위한 방법과 절차에 관한 연구이다. 점진적인 주성분 개선 방법으로 R-SVD 알고리즘을 변형한 SKL 알고리즘을 이용한다. SKL 알고리즘을 이용하면 주성분을 이용하는 얼굴 인식의 문제점으로 지적되어 왔던 인식 후보의 점진적 증가에 따른 재학습 문제를 해결할 수 있다. 또한 이 방법은 밝기 변화에 견고한 객체 트랙킹 분야에도 이용될 수 있다. 본 논문에서는 얼굴인식 시스템에서 SKL 알고리즘을 이용하여 주성분을 점진적으로 개선하며 적용하는 절차를 제안하고, 표준 KL 변환에 의하여 주성분을 일괄적으로 계산하는 결과와 얼굴 인식 성능을 비교한다. 그리고 SKL 알고리즘에 포함된 망각 인자(forgetting factor)가 얼굴인식 성능에 미치는 효과를 실험적으로 확인한다.

### Abstract

This paper is about the method and procedure to register the candidate sequentially in the face recognition system using the PCA(Principal Components Analysis). We use the method to update the principal components sequentially with the SKL algorithm which is improved R-SVD algorithm. This algorithm enable us to solve the re-training problem of the increase the candidates number sequentially in the face recognition using the PCA. Also this algorithm can use in robust tracking system with the bright change based to the principal components. This paper proposes the procedure in the face recognition system which sequentially updates the principal components using the SKL algorithm. Then we compared the face recognition performance with the batch procedure for calculating the principal components using the standard KL algorithm and confirms the effects of the forgetting factor in the SKL algorithm experimentally.

**Keywords :** Face Recognition, SKL, KL Transform, PCA

### I. 서 론

얼굴인식은 생체인식의 한 분야로 HCI, 전자여권, 영상 감시 및 보안 시스템, 이미지 DB 관리 등 다양한 분야에 적용되면서 최근 활발한 연구가 이루어지고 있다. 현재까지의 얼굴인식 연구에서 사용되는 방법은 크게 두 가지 방법으로 접근하고 있다. 한 가지 접근법은 얼굴의 특징점에 기반한 방법으로 PCA(Principal Components Analysis), LDA(Linear Discriminabt Analysis), ICA(Independent Component Analysis) 알고리즘을 이용한다[1]. 또 다른 하나의 접근법은 얼굴 생김새 (Appearance)에 기반한 접근법으로 능동적으로 얼굴의 윤곽을 추출하는 방법인 ASM (Active Shape Model) [2]과 이를 개선한 AAM(Active Appearance Model)[3] 그리고

EBGM(Elastic Bunch Graph Matching)과 같은 알고리즘이 이러한 접근법에 속한다. 1988년에 Kirby와 Siribich[4]에 의하여 최초로 제안된 주성분 분석 방법은 Turk와 Pentland에 의하여 KL 기저 벡터에 해당하는 주성분 벡터를 고유 얼굴로 얼굴인식과 얼굴 검출에 이용하는 방법으로 제안되어 얼굴인식 연구의 선도적인 알고리즘으로 알려져 있다[5][6][7]. 이 방법은 이용되는 얼굴 영상의 밝기와 크기가 정규화 되어야 하며, 특히 눈과 입의 위치가 일정한 위치에 놓이도록 하는 전처리가 인식 성능에 결정적인 역할을 미치는 것과 같은 제약이 따른다. 그러나 이후에 제안된 다양한 얼굴인식 알고리즘에 비교할 때, 전체적인 정면 얼굴을 요구하는 조건에 비하여 낮은 인식율을 보이기는 하지만, 얼굴 영상에 대한 차원을 축소하여 낮은 차원에서 인식 처리를 행한다는 견지에서 장점을 가지고 있다[4][5]. 이 방법의 경우 고차원의 얼굴 영상을 고유 얼굴이라고 부르는 직교 성분으로 차원을 축소시켜 불필요한 정보를 제거하고 얼굴을 저차원으로 분해한 후, 각 얼굴을 분해된 고유 얼굴에 대한 가중 합으로 표현하고 저장하는 학습 단계를 거치게 된다. 주성분 분석법은 KL변환 알고리즘이라고

\* 동아대학교 \*\* (주)삼성모바일디스플레이

\*\*\* 동아대학교(교신저자)

투고일 : 2010. 4. 21 수정완료일 : 2010. 10. 27

제재확정일 : 2010. 10. 29

※ 이 논문은 동아대학교 학술연구비 지원에 의하여  
의하여 연구되었습니다.

도 하는데 이 방법을 이용하면 영상과 같은 고차원 데이터를 저차원의 부공간으로 차원을 축소할 수 있다. 또한 이 변환법을 이용하면 영상을 KL 기저 벡터의 선형 결합으로 표현하여 영상 압축 등에 이용하기도 한다. 얼굴인식에서는 KL 기저 벡터로 이루어진 고유얼굴에 대한 각 후보 얼굴의 사영값의 상대적인 거리로 얼굴을 인식하게 된다.

그러나 주성분 분석을 이용하는 얼굴인식 접근법은 실제 적용상에서 두 가지 문제점을 가지고 있다. 첫째는 다수의 인식 후보자에 대한 데이터로부터의 학습과정으로 볼 수 있는 고유얼굴 생성과정이 완성된 후에 새로운 후보자를 등록할 경우에 기존의 후보 데이터를 포함한 모든 후보자 데이터에 대한 재학습이 다시 필요하다는 문제이다. 이러한 문제점은 특히 얼굴검출과 같이 시간적으로 변하는 밝기 값에 대하여 적응적으로 고유 얼굴을 생성시켜 적용해야하는 얼굴 검출과 추적 분야에서는 처리속도가 떨어질 뿐 아니라 검출 성능 저하의 원인이 된다[8][9][10]. 둘째는 고유 얼굴을 구하기 위하여 영상의 입력 차원의 차승에 해당하는 아주 큰 내적 행렬 계산이 필요하다는 것이다. 두 번째 문제는 어떤 행렬 A에 대하여  $A^T A$ 와  $AA^T$ 는 영이 아닌 동일한 고유값 집합을 가진다는 성질을 이용하여 해결된다[4][5].

본 논문은 주성분을 이용하는 얼굴인식과 얼굴검출에 대하여 점진적인 학습이 필요한 첫 번째 문제점을 극복하기 위한 연구이다. 기존의 학습 결과 생성된 주성분에 새로운 후보얼굴의 정보가 포함된 주성분으로 갱신하기 위한 점진적인 학습 방법으로 SKL 알고리즘을 이용하고, 이를 얼굴인식에 적용하는 절차와 기존의 일괄학습에 의한 방법과 성능을 비교한다.

본 논문의 2장에서는 표준 KL 알고리즘과 효율적인 SVD 계산을 위한 R-SVD, 그리고 R-SVD를 개선한 분할 R-SVD 알고리즘과 SKL 알고리즘을 소개한다. 3장에서 점진적 얼굴인식 절차를 제안하고 기존 방법과 성능 비교 그리고 SKL 알고리즘에 포함된 망각인자의 효과에 대하여 논하고 마지막으로 결론을 맺는다.

## II. 점진적 KL 알고리즘[11-16]

### 1. 표준 KL과 R-SVD 알고리즘[12]

N차원으로 이루어진 영상 데이터에 대한 일정량의 데이터 집합이 주어질 때, 이산 KL 변환을 이용한 차원 축소 문제는 입력 영상의 고차원 벡터를 일정한 개수의 기저 벡터로 이루어진 부분 공간으로 사영을 시켜서 입력 벡터와 가장 근접하게 펼쳐지는 K( $K < N$ )개의 직교 단위 벡터의 집합을 찾는 문제로 해석된다. 여기서 사용되는 척도는 최소 자승 오차를 이용한다. 이 과정에서 KL 기저 벡터는 특이값 재구성(SVD) 알고리즘을 사용하여 입력 벡터에 대한 상관 행렬의 고유벡터를 계산하여 얻을 수 있다.

특이값 재구성 방법을 이용하는 경우, 각 입력 벡터들을

행렬  $A(n \times m)$ 의 열이 되도록 데이터 행렬을 구성하고, 특이값 재구성 행렬  $A = UDV^T$ 을 계산한다. 여기서 U는 좌측 특이 벡터를 이루는 열로 구성되며,  $V^T$ 는 우측 특이 벡터를 이루는 행으로 구성된다. D는  $n \times m$ 인 대각 행렬로, 대각성분은 0이 아닌 양수로 구성되며, 이 대각성분을 특이값이라고 한다. U와 V는  $A^T A$ 와  $AA^T$ 의 고유값과 고유벡터에서 구한다. 즉,  $A^T A$ 의 고유벡터는  $V$ 의 열을 이루며,  $AA^T$ 의 고유벡터는 U의 열을 이루며, 모두 직교하는 성질을 가진다. 또한 D의 특이값들은  $AA^T$ 와  $A^T A$ 의 고유값의 자승근에 해당한다. 영이 아닌 특이값의 수는 행렬 A의 행렬의 계수(rank)와 같으며  $D = diag(\sigma_1, \sigma_2, \dots, \sigma_n)$ 이고  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n$ 로 정렬될 수 있다. 만약  $U = (u_1, u_2, \dots, u_n)$ 이고,  $V = (v_1, v_2, \dots, v_n)$ 이며,  $A = \sum_{i=1}^n \sigma_i u_i v_i^T$ 가 성립한다.

결국, KL기저는 K개의 가장 중요한 좌 특이 벡터(U의 첫 번째 K개의 열)로 펼쳐진다. 이 과정에서 R-SVD 알고리즘을 이용하면  $M \gg N$ 인 경우에 효과적으로 특이값 재구성(SVD)을 계산할 수 있다. R-SVD 알고리즘은 다음과 같다.

- 1) QR 재구성( $A = QR$ )을 계산한다. 여기서, Q는 열-정규 직교한  $M \times N$  행렬이고 R은  $N \times N$  상삼각 행렬이다.
- 2) R의 SVD를 계산한다,  $R = U'DV^T$
- 3)  $U = QU'$  계산한다.

### 2. 분할 R-SVD 알고리즘 [12]

대용량 학습 영상 집합 전체를 처리하지 않고 순차적으로 학습하는 반복 알고리즘은 각 영상에 해당하는 열벡터를 작은 블록으로 나누어서 KL기저에 대한 SVD 내부 성분들을 표현하고 갱신하는 과정을 반복한다. 제안된 알고리즘은 R-SVD 알고리즘을 개선한 분할 R-SVD 알고리즘으로  $M \gg N$ 인 경우에 유효하다. 이 방법은 계산 복잡도는 대부분 QR 재구성에서 포함되며, SVD 계산과 갱신 과정의 복잡도는 무시할 수 있는 정도이다.

분할 R-SVD 알고리즘은 행렬을 분할하여 큰 행렬의 SVD를 계산한다. 3개의 행렬 곱  $B = UDV^T$ 로 표현되는  $M \times L$  행렬 B의 SVD에서 U는 우 특이 벡터로  $M \times L$  열 직교 행렬, D는 대각성분이 B의 특이 값인  $L \times L$  대각 행렬, V는 열이 우 특이 벡터인  $L \times L$  정규직교 행렬이다.  $B = UDV^T$ 이 행렬 B의 SVD라고 하면, 이보다 큰 행렬  $B^* = (B|E)$ 에 대한 SVD는 다음과 같은 방법으로 효율적으로 계산될 수 있다. 여기서 E는 P개의 추가 열로 구성된  $M \times P$  행렬이다.

- 행렬  $(U|E)$ 의 정규직교화를 수행하여  $U' = (U|E)$ 인 열 정규직교 행렬을 만든다.

-  $V' = \begin{pmatrix} V & 0 \\ 0 & I_p \end{pmatrix}$  인  $(L+P) \times (L+P)$  행렬을 재구성한다. 여기서  $I_p$ 는  $p$ 차원의 단위 행렬이다.

$- D' = U^T(B^*)V' = \begin{pmatrix} U^T \\ E^T \end{pmatrix}(B|E)\begin{pmatrix} V & 0 \\ 0 & I_p \end{pmatrix} = \begin{pmatrix} U^T B V & U^T E \\ E^T B V & E^T E \end{pmatrix}$ , 여기서,  $U^T B V = D$ 이고  $E^T B V = 0$ .  $D'$ 의 맨 우측 열  $P$ 는  $B$ 에 추가 되는 새로운 벡터로  $U'$ 의 열로 펼쳐지는 정규직교 기저로 표현된다.

- SVD  $D' = \tilde{U}\tilde{D}\tilde{V}^T$ 를 계산한다.  $B^*$ 의 SVD는 식(1)과 같다.

$$B^* = U'(\tilde{U}\tilde{D}\tilde{V}^T)V'^T = (U'\tilde{U})\tilde{D}(\tilde{V}^TV'^T) \quad (1)$$

여기서,  $\tilde{D}$ 는  $(L+P) \times (L+P)$  대각 행렬이고,  $U'\tilde{U}$ 는  $M \times (L+P)$  열 정규 직교 행렬,  $\tilde{V}^TV'^T$ 는  $(L+P) \times (L+P)$  정규직교 행렬이다.

-  $B^*$ 의 SVD 계산은  $U'$ ,  $V'$ ,  $D'$ 의 계산과 작은 행렬  $D'$ 의 SVD를 요구한다. 이 개신과정을 보완한 것이 다음에 제안하는 SKL 알고리즘이다.

### 3. SKL 알고리즘[12]

점진적 KL(SKL)알고리즘은 데이터를 열벡터(이미지)를 블록으로 분할하고 첫 번째 블록의 SVD를 계산하는 것으로 시작한다. 그리고 매 단계에서 다음 열 블록이 추가되고 분할 R-SVD 알고리즘을 이용하여 SVD를 개신하여 계산한다. KL기저에 저차원 근사화만 관심이 있으므로, 알고리즘은 개신된  $U$ 행렬에서 열인 기저 벡터와 매우 작은 특이값과 관련된 기저 벡터들은 제거하여 기저 벡터의 수에 제한을 한다. 입력과 사용되는 파라미터는 다음과 같다.

$A : M \times N$  데이터 행렬,  $P$  : 각 블록에서 열의 수

$K$  : 행렬에 대한 열의 최대수,

$\epsilon$  : 유지되는 특이값에 대한 하한값,

$ff$  : 망각인자(forgetting factor)값

#### 1) 초기화 단계

행렬  $A$ 의 첫번째  $K_0 = K$  열로부터 행렬  $A_0$ 를 취하여 R-SVD를 계산하여  $A_0 = U_0 D_0 V_0^T$ 를 계산하고  $U_0$ 와  $D_0$ 를 얻는다.

#### 2) i번째 단계

a)  $A$ 의 다음  $P$ 열을 포함하는 행렬  $A_i$ 를 읽어서  $ff \cdot U_{i-1} D_{i-1}$  행렬에 추가한 조합 행렬의 QR 재구성 ( $ff \cdot U_{i-1} D_{i-1} | A_i$ ) =  $U_{i-1}' D_{i-1}'$ 을 계산한다. 여기서  $U_{i-1}'$ 은  $M \times (K_{i-1} + P)$  정규직교 행렬이고  $D_{i-1}'$ 는 크기  $(K_{i-1} + P) \times (K_{i-1} + P)$ 의 상대각 행렬이다. 여기서  $ff$ 값은 현재 블록에 대한 이전 블록의 기여도를 고려하기 위한 인자값으로 망각인자라고 한다.

b)  $D_{i-1}' = \tilde{U}_{i-1} \tilde{D}_{i-1} \tilde{V}^T$ 의 꼽으로  $D_{i-1}'$ 의 SVD를 계산한다.

c)  $\sigma_i^1, \sigma_i^2, \dots, \sigma_i^K$ 가 대각 행렬  $\tilde{D}_{i-1}$ 의  $K$ 번째 가장 큰 인자가 되도록 하고 한다. 에너지적으로 무시할만한 나머지 특이값은 버린다.

$$(\sigma_i^j)^2 < \epsilon \sum_{k=1}^K (\sigma_i^k)^2 \quad (2)$$

$D_i$ 는 해당 성분이 남아있는  $K_i$ 특이값이 되는 대각 행렬이 되게 한다.

d) 위에서 제거된 특이값과 관련된 모든 열을  $\tilde{U}_{i-1}$ 로부터 제거한다. 그리고  $\tilde{U}_{i-1}$  결과 행렬이 되도록하고,  $U_i = U_{i-1}' \tilde{U}_{i-1}$ 을 계산한다.

3)  $A$ 의 모든 열이 처리된 후 마지막 단계의 행렬을 출력한다.

### III. 얼굴 인식 성능 비교 및 망각 인자 효과

본 장에서는 점진적으로 얼굴 인식 후보수를 증가시키면서 주 성분을 개신하며 얼굴인식을 수행하는 절차를 제시하고 표준 KL 변환에 의하여 일괄적으로 주성분을 계산하는 경우와 인식 성능을 서로 비교하였다. 그리고 SKL 알고리즘에 포함된 망각인자가 얼굴 인식 성능에 미치는 효과를 실험적으로 확인하였다.

#### 1. 실험에 사용된 데이터

실험에 사용한 얼굴 데이터베이스는 ORL 얼굴DB (Cambridge ORL DB)를 이용하였다. 이 DB는 40명당 10장씩 총 400장으로 구성되어 있다[17]. 그림1은 각 얼굴에 부여된 인덱스 중 1번 인덱스 대한 이미지 집합이다.



그림1. 인덱스1 Cambridge ORL 얼굴 DB

Fig. 1. Index1 Cambridge ORL Face DB

#### 2. SKL을 이용한 얼굴 인식 절차와 성능비교

표준 KL에 의한 얼굴인식과 SKL에 의한 점진적 개신에 의한 얼굴인식 절차는 그림2와 그림3과 같다. 표준 KL에 의한 일괄학습과 인식 절차는 Turk와 Pentland가 제안한 절차이다[5]. SKL 알고리즘을 이용하여 점진적으로 고유얼굴을 구할 경우, 초기5명에 대한 고유 얼굴 초기값은 표준 KL에 의한 일괄학습의 결과와 동일하다. 그러나 추가 등록되는 후보 얼굴에 대하여는 일괄학습과 같이 전체 후보 얼굴에 대한 고유얼굴을 구하지 않고, SKL 알고리즘으로 이미 계산되어 등록된 고유 얼굴에 새로이 등록될 후보

얼굴만을 추가하여 고유얼굴이 점진적으로 생성되도록 한다. 일괄학습과 점진적 학습에 대한 복잡도와 요구되는 메모리는 표준 KL을 이용할 경우, 크기  $M$ 인  $N$ 개의 이미지 데이터에 대하여 복잡도가  $O(MN^2)$ 이고 요구되는 메모리 유니트가  $O(MN)$ 인데 비하여 SKL 알고리즘을 이용할 경우, 복잡도가  $O(MNK)$ 이고 요구되는 메모리 유니트가  $O(MK)$ 로 복잡도와 요구되는 메모리 유니트가 적어지는 것으로 보고되어 있다[12].

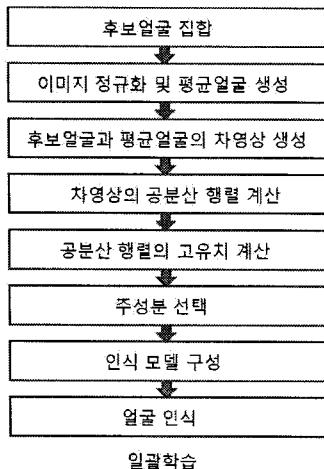


그림 2. 표준 KL에 의한 일괄학습에 의한 얼굴인식 절차  
Fig. 2. Face Recognition Flow by Batch Train using Standard KL

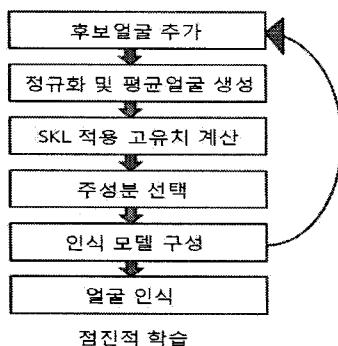


그림 3. SKL에 의한 점진적 학습에 의한 얼굴인식 절차  
Fig. 3. Face Recognition Flow by Sequential Train using SKL

ORL 얼굴DB를 표준 KL에 의한 일괄학습 방법으로 얼굴인식에 적용한 경우의 인식 결과는 표1과 같다. 일괄 학습과 점진적 학습 모두에 200 PCs의 주성분을 사용하였다. 그리고 DB에서 개인별로 5장은 등록용으로 이용하고, 나머지 5장은 시험용으로 이용하였다.

표 1. 표준 KL 일괄학습과 SKL 점진적 학습에 의한 얼굴인식 실험결과

Table 1. Experimental results for the Standard KL Batch Train and SKL Sequential Train

인식수	표준 KL 일괄학습	SKL( $ff=0.1$ ) 점진적 학습	SKL( $ff=0.9$ ) 점진적 학습
5	100% (25/25)	100% (25/25)	100% (25/25)
10	98% (49/50)	98% (49/50)	98% (49/50)
15	96% (72/75)	96% (72/75)	96% (72/75)
20	94% (94/100)	86% (86/100)	94% (94/100)
25	92% (115/125)	86.4% (108/125)	92% (115/125)
30	90.7% (136/150)	85.3% (128/150)	90.6% (136/150)
35	91.4% (160/175)	81.7% (143/175)	91.4% (160/175)
40	90% (180/200)	78.5% (157/200)	89.5% (179/200)

표1에서 점진적 학습 결과는 초기 5명에 대한 표준 KL 일괄학습 결과를 초기 파라미터로 하며, 이후 학습은 SKL 방법으로 후보 인원을 5명 단위로 점진적으로 증가시키면서 고유얼굴을 생성하고 인식한 경우의 인식 결과이다. 그림4은 인식 후보수의 증가에 따른 고유얼굴을 일괄학습과 점진적 학습에 따라 서로 비교한 것이다. 생성되는 고유얼굴은 초기 5명에 대하여만 동일하며 이후 점진적인 후보 등록에 따라서 생성되는 고유얼굴은 동일하지 않지만, 거의 동일한 얼굴인식 성능을 가진다.

### 3. SKL 알고리즘의 망각계수 효과

SKL 알고리즘은 객체 트래킹 분야에 이용할 경우에 이전 프레임에서 검출된 객체 정보를 현재 기저 계산에 포함시켜 기저를 재생산한다. 이 과정에서 이전 데이터에 대한 기여도를 조정하기 위한 인자값으로 망각인자(forgetting factor)를 정의하고 그 값을 설정할 수 있도록 제안하고 있다. 그림4는 망각인자를 0.1에서 0.9까지 변화시키면서 얼굴인식 성능을 확인한 결과이다. 망각 인자가 1에 가까울수록 인식율이 높아지는 것을 확인할 수 있다. 따라서 SKL 알고리즘에 포함된 망각인자는 1에 가깝게 설정되는 것이 요구되며, 이 인자는 얼굴 인식 보다는 연속되는 동영상 프레임에서 특정한 객체를 추적하는 경우에 주성분을 이용하는 경우와 같이 이전 데이터에 대한 정보를 유지하기 위한 인자로 효과적으로 이용된다.

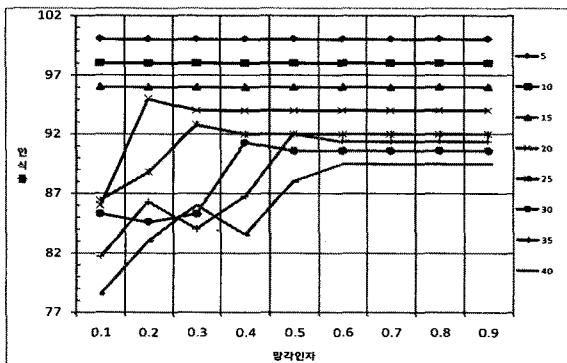


그림 4. 망각인자에 따른 인식률 변화

Fig. 4. Recognition Rate variation according to the forgetting factor

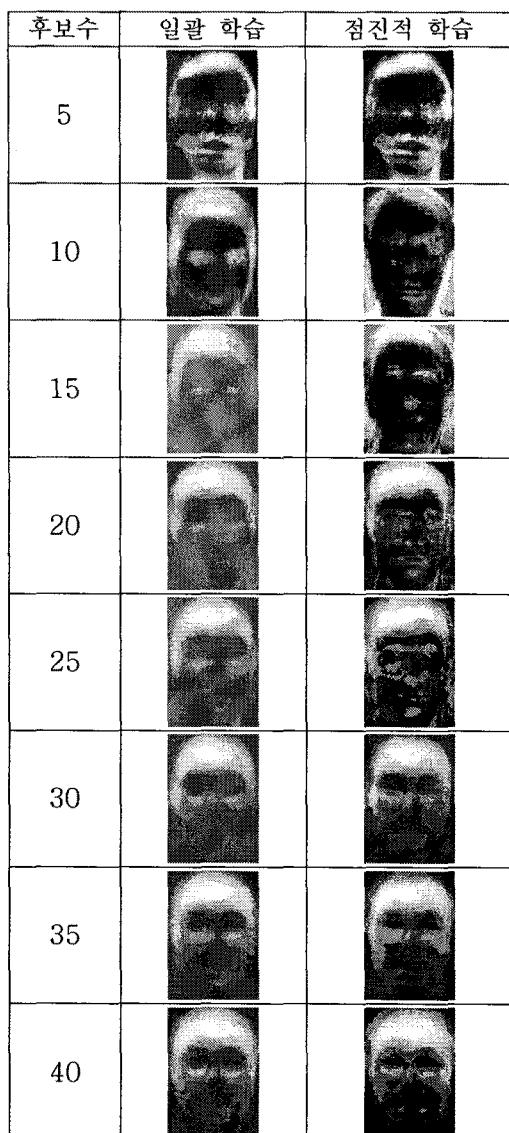


그림4. 학습방법과 인식수에 따른 고유얼굴 비교

Fig. 4. Comparison of the Eigen Face according to the train method and the candidate number

#### IV. 결 론

본 논문에서는 R-SVD 알고리즘을 개선한 SKL 알고리즘을 이용하여 주성분 분석을 이용한 얼굴인식의 문제점으로 지적되어 왔던 일괄학습을 개선하여 점진적 학습이 가능하도록 하였다. 제안된 알고리즘은 얼굴인식에서 후보자 얼굴이 추가되는 경우에 적용한 결과, 표준 KL 방법에 의한 일괄 학습 후 인식하는 경우와 대등한 결과를 얻을 수 있었다. 이 방법을 검출 및 트래킹 분야에 적용할 경우에 얼굴인식에서 이용하는 고유얼굴과 같은 고유객체를 일반 환경과 같은 외부 밝기가 변하는 환경에서도 적응적으로 고유객체를 생성하는 처리가 가능하게 되므로 보다 안정적인 실시간 검출과 트래킹이 가능할 것으로 예상된다.

#### 참고 문헌

- [1] Y. Adini, Y. Moses, and S. Ullman, "Face Recognition: The Problem of Compensating for Changes in Illumination Direction," *IEEE Trans. on Pattern Anal. and Mach. Intel.*, Vol. 19, No. 7 pp. 721-732, July 1997.
- [2] T. F. Cootes, C. J. Taylor, D. H. Cooper, J. Graham, "Active Shape Models? Their Training and Application," *Computer Vision and Image Understanding*, Vol. 61, No. 1, pp. 38-59, Jan. 1995.
- [3] T. Cootes, G. Edwards, and C. Taylor, "Active Appearance Models," *IEEE Trans. on Pattern Anal. and Mach. Intel.*, Vol. 23, No. 6, pp. 681-685, June 2001.
- [4] M. Kirby and L. Sirovic, "Application of the Karhunen-Loeve Procedure for the Characterization of Human Faces," *IEEE Trans. on Pattern Anal. Mach. Intel.*, Vol. 12, No. 1, pp. 103-108, Jan. 1990.
- [5] M. Truk and A. Pentland, "Eigenfaces for Recognition," *Journal of Cognitive Neuroscience*, Vol. 3, No. 1, pp. 71-86, 1991.
- [6] 한학용, 장원우, 하주영, 허강인, 강봉순, "학습 알고리즘을 이용한 AF용 ROI선택과 영역 안정화 방법," *한국신호처리시스템학회 논문지*, 제10권 4호, pp. 233-238, 2009.10.
- [7] 이성진, 장원우, 최원태, 김석찬, 강봉순, "적목현상 특징을 이용한 적목현상 보정 알고리즘 및 하드웨어 구현," *한국신호처리시스템학회 논문지*, 제10권 3호, pp. 151-157, 2009.7.
- [8] A. D. Jepson, D. J. Fleet, and T. F. El-Maraghi, "Robust Online Appearance Models for Visual Tracking," *IEEE Trans. on Pattern Anal. and Mach. Int.* Vol. 25, No. 10, pp. 1296-1311, Oct. 2003.

- [9] R. S. Lin, D. Ross, J. Lim, and M. H. Yang, "Adaptive discriminative generative model and its applications," In Proc. Cong. on Neural Information Processing Systems, pp. 801-808, MIT Press, 2005.
- [10] I. Matthews, T. Ishikawa, and S. Baker, "The template update problem," IEEE Trans. on Pattern Anal. and Mach. Int., Vol. 26, No. 6, pp. 810-815, June 2004.
- [11] P. Hall, D. Marshall, and R. Martin, "Adding and subtracting eigenspaces with eigenvalue decomposition and singular value decomposition," Image and Vision Computing, Vol. 20, Issues 13-14, pp. 1009-1016, Dec. 2002.
- [12] A. Levy and M. Lindenbaum, "Sequential Karhunen-Loeve Basis Extraction and its Application to Images," IEEE Trans. on Image Proc., Vol. 9, No. 8, pp. 1371-1374, Aug. 2000.
- [13] D. Ross, J. W. Lim, R. S. Lin, and M. H. Yang, "Incremental Learning for Robust Visual Tracking," International Journal of Computer Vision, Vol. 77, No. 1, pp. 125-141, May 2008.
- [14] D. Ross, J. W. Lim, and M. H. Yang, "Adaptive Probabilistic Visual Tracking with Incremental Subspace Update," Proc. 8th European Conference on Computer Vision, Vol 3022 of Lecture Notes in Computer Science, Springer, pp. 470-482, May 2004.
- [15] D. Comaniciu, V. Ramesh, and P. Meer, "Kernel-Based Object Tracking," IEEE Trans. on Pattern Anal. and Mach. Int., Vol. 25, No. 5, pp. 564-577, May 2003.
- [16] P. Hall, D. Marshall, and R. Martin, "Incremental Eigen Analysis for Classification." British Machine Vision Conference, pp. 286-295, May 1998.
- [17] CBCL Face Data Set:  
<http://cbcl.mit.edu/software-datasets/>



한 학용(Hak-yong Han)

1994년 2월 동아대학교 전기전자컴퓨터공학부 전자공학과(공학사)  
 1998년 2월 동아대학교 전자공학과(공학석사)  
 2004년 8월 동아대학교 전자공학과(공학박사)

2006년 7월~ 2007년 11월 부산대학교 영상IT산학공동사업단 Post-Doc  
 2008.3~현재 동아대학교 BK21 계약교수(멀티미디어 연구센터)

※ 주관심분야 : Pattern recognition, DSP application



이 성목(Sung-mok Lee)

2005년 2월 동아대학교 전기전자컴퓨터공학부 전자공학과(공학사)  
 2007년 2월 동아대학교 전자공학과(공학석사)  
 2007년 3월 ~ 현재 동아대학교 전자공학과 박사과정

※ 주관심분야 : VLSI algorithm/architecture design, image /video processing and wireless communication



곽 부동(Boo-dong Kwak)

1999년 2월 동아대학교 전기전자컴퓨터공학부 전자공학과(공학사)  
 2001년 2월 동아대학교 전자공학과(공학석사)  
 2001년 3월~2010년 8월 삼성전기 중앙연구소 책임연구원

2008년 9월~현재 동아대학교 전자공학과 박사과정  
 2010년 9월~현재 삼성모바일디스플레이 책임연구원

※ 주관심분야 : 영상신호처리, SoC설계 및 무선통신



최 원태(Won-tae Choi)

1986년 8월 경북대학교 전자공학과(공학사)  
 1994년 8월 포항공과대학교 전자공학과(공학석사)  
 1986년 ~ 1991년 삼성전자 반도체 선임연구원  
 1990년 3월 ~ 현재 경상대학교 부속 공학연구원 연구원

1998년 ~ 2010년 8월 삼성전기 중앙연구소 수석연구원  
 2010년 9월 ~ 현재 삼성모바일디스플레이 수석연구원

※ 주관심분야 : Camera module for mobile phone



강 봉순(Bong-soon Kang)

1985년 연세대학교 전자공학과(공학사)  
 1987년 미국 University of Pennsylvania 전기공학과(공학석사)  
 1990년 미국 Drexel University 전기 및 컴퓨터공학과(공학박사)

1989년~1999년 삼성전자 반도체 수석연구원

1999년~현재 동아대학교 전자공학과 교수

2006년~현재 멀티미디어 연구센터 소장

2006년~현재 2단계 BK21 사업팀장

※ 주관심분야 : 영상신호처리, SoC설계 및 무선통신