

# LDA와 SVM을 이용한 얼굴 인식 시스템에 관한 연구

이정재\*

## A Study on Face Recognition System Using LDA and SVM

Jung-Jai Lee\*

요약

본 논문에서는 얼굴 인식을 위한 보다 안정적이며 조명 변화와 회전에 강인하게 얼굴 영역을 검출하며, 계산의 효율성과 검출 성능을 동시에 만족시키는 강인한 인식 알고리즘에 대해 제안한다. 제안하는 알고리즘은 전처리 과정을 거쳐 정규화한 후 얼굴 영역만을 분할 검출한 후 주성분분석(PCA)을 이용하여 특징벡터를 구한다. 또한 구해진 특징벡터를 SVM에 적용하여 최적의 이진분류를 진행함으로써 얼굴 영역에 대한 검증을 수행한다. 검증 후 특징벡터를 다시 LDA에 적용하여 2차원 공간상에서 유클리디안 거리 이용하여 최종 얼굴을 인식하게 된다. 본 논문에서 제안하는 방법으로 인식률의 안전성과 정확성을 향상시킬 수 있었으며, 차원 축소로 인해 많은 계산 량이 요구되지 않기 때문에 실시간 인식도 가능하다.

### ABSTRACT

This study proposed a more stable robust recognition algorithm which detects faces reliably even in cases where there are changes in lighting and angle of view, as well it satisfies efficiency in calculation and detection performance. The algorithm proposed detects the face area alone after normalization through pre-processing and obtains a feature vector using (PCA). Also, by applying the feature vector obtained for SVM, face areas can be tested. After the testing, the feature vector is applied to LDA and using Euclidean distance in the 2nd dimension, the final analysis and matching is performed. The algorithm proposed in this study could increase the stability and accuracy of recognition rates and as a large amount of calculation was not necessary due to the use of two dimensions, real-time recognition was possible.

### 키워드

PCA, LDA, SVM, Face Recognition  
주성분분석, 선형관별분석,서포트벡터머신,얼굴 인식

## 1. 서론

인간의 행동을 분석[1]에 대해 다양한 분야에서 각각의 특성에 맞는 연구가 진행되고 있지만 그 중에서

도 생체인식 분야가 주류가 된다고 해도 과언이 아닐 것이다. 생체인식 중에서도 얼굴 인식은 템플릿 매칭 접근, 통계적 분류 접근, 구문적 접근 및 신경망 접근 방법의 4가지 방법으로 분류할 수 있다. 이 중에서 통

\* 교신저자 : 송원대학교 컴퓨터정보학과  
• 접수일 : 2015. 10. 15  
• 수정완료일 : 2015. 11. 13  
• 게재확정일 : 2015. 11. 23

• Received : Oct. 15, 2015, Revised : Nov. 13, 2015, Accepted : Nov. 23, 2015  
• Corresponding Author : Jung-Jai Lee  
Dept. of Computer Information Science, Songwon University,  
Email : leje@songwon.ac.kr

계적 분류방법으로 주성분 분석(PCA)에 의한 얼굴 인식[2-3],[13], 서포트벡터머신(SVM)에 의한 얼굴 인식[2],[4],[11], 선형판별분석(LDA)에 의한 얼굴 인식[3],[5], 독립성분분석(ICA)에 의한 얼굴 인식[6]과 신경망(Neural Network)에 의한 얼굴 인식[7],[12] 등이 계산 량이 적으므로 얼굴 인식에서 주류를 이루고 있다.

본 논문에서는 얼굴 인식을 위한 보다 안정적이며 조명 변화와 회전에 강인하게 얼굴 영역을 검출하며, 계산의 효율성과 검출 성능을 동시에 만족시키는 강인한 인식 알고리즘에 대해 제안한다. 제안하는 시스템은 전처리 과정을 거쳐 영상의 정규화를 진행하였다. 첫째, 정규화된 영상에서 얼굴 영역만을 정확하게 분할 검출하기 위해 밝고 어두운 두 영상의 차분연산을 통해 배경 영역을 제거함으로써 얼굴 후보 영역을 검출한다. 둘째, 검출된 후보 영역에 대해 PCA를 적용하여 고차원의 데이터에 대해 차원을 축소하여 저차원의 특징 벡터를 구한 후 특징 벡터를 SVM에 적용하여 이진 분류를 수행함으로써 얼굴영역 후보에 대한 정확한 검증을 수행한다. 셋째, 검증과정을 거친 후 정확하고 안정된 인식률을 얻기 위해 LDA를 적용하여 클래스내 분산과 클래스간 분산의 유클리디안 거리를 비교하여 최종 얼굴을 인식한다. 또한 얼굴의 인식률을 높이기 위해 입력되는 각 얼굴 영상의 방향을 좌·우 45° 회전 정보를 갖는 영상을 획득한 후 데이터베이스를 생성하여 대표값을 구하고 PCA를 적용하여 고유공간에 투영시킴으로써 얼굴의 특징 값을 산출한다. 이 과정을 통해 입력 방향에 따른 인식률에 대해 안전성과 정확성을 향상시킬 수 있었다. 또한 차원 축소로 인해 많은 계산 량이 요구되지 않기 때문에 실시간 인식 시스템에도 적용할 수 있다.

## II. 본 론

### 2.1 전체 시스템 구성도

본 논문에서는 안정된 얼굴 인식에 대해 제안하며, [그림 1]은 전체 시스템 구성도이다.

### 2.2 배경제거

본 논문에서는 조명 변화로 인한 배경의 밝기 변화

를 측정하여 시간 요소( $t$ )를 고려해서 일정 시간  $T_i$  동안 배경 영상  $I_t$ 를 취득한 다음 영상 영역  $R$ 내에 있는 각 픽셀( $x$ )들을 분석하여 조명이 가장 밝았을 때의 화소 값  $P_{max}(x)$ 와 가장 어두울 때의 화소  $P_{min}(x)$ 을 얻는다. 이 두 화소 값의 차이  $D(x)$ 는 조명의 변화로 나타날 수 있는 밝기의 임계치이다. 수식으로는 식(1-4)와 같으며, 식(5)로 밝기의 기준을 정한 후 모폴로지 연산을 통해서 잡음을 제거하였다.

$$BM = \{P_{max}(x), P_{min}(x), D(x)\}_{x \in R} \quad (1)$$

$$P_{max}(x) = Max I_t(x), (1 \leq t \leq T_i) \quad (2)$$

$$P_{min}(x) = Min I_t(x), (1 \leq t \leq T_i) \quad (3)$$

$$D(x) = P_{max}(x) - P_{min}(x) \quad (4)$$

$$B(x) = \begin{cases} 255 & \text{if } |P_{max}(x) - I(x)| \text{ or } |P_{min}(x) - I(x)| > D(x) \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

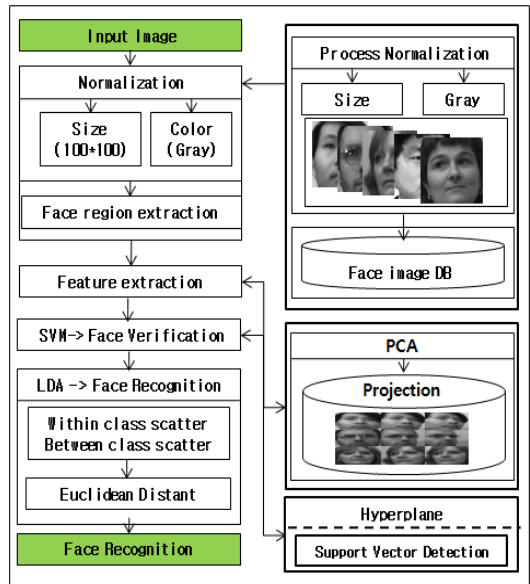


그림 1. 알고리즘 전체 시스템

Fig. 1 Algorithm of the whole system

### 2.3 주성분분석에 의한 얼굴 검출

본 논문에서는 안정된 인식률을 얻기 위해 PCA를 이용해 파라메트릭 공간을 생성하여 얼굴의 방향성 문제를 해결하는 방법을 제시한다. 이는 입력 영상의 변화율을 크게 하기 위해 각 얼굴 영상에 대해 좌·

우 45°씩 틀어 회전 정보를 갖는 영상을 데이터베이스화함으로써 입력 영상의 방향이 틀어져도 같은 영상으로 인식할 수 있게 된다.

[그림 2]는 자유롭게 입력되는 얼굴의 방향성을 고려하여 얼굴 영상을 5°씩 틀어서 획득한 영상의 일부이다(1얼굴=19개의 영상으로 분할 구성).



그림 2. 입력 방향성을 고려한 얼굴 영상  
Fig. 2 Facial image in consideration of the directionality

### 2.3.1 고유 공간 구성

고유벡터를 계산하기 위해서는 새로운 영상 집합  $X$ 에 대해 모든 영상의 평균 데이터를 구하여 각 영상들의 데이터의 차를 구한다. 고유공간을 구하기 위해서는  $M * N$ 의 크기를 지닌 영상 집합  $X$ 를 식(6)과 같이 계산하고 고유벡터를 구하면 된다. 즉, 공분산 행렬  $Q$ 에 대한 고유치  $\lambda$ 와 고유벡터  $e$ 를 구한다.

$$\lambda_i e_i = Q e_i \quad (6)$$

본 논문에서는 특이치 분해(SVD)를 이용하여 고유 공간을 구하여 영상 집합  $X$ 의 공분산 행렬에 대한 고유 벡터를 얻었다.

행렬은 분해가 가능하며 원 식은 식(7)로 나타낼 수 있으며,  $V$ 와  $U$  행렬은 각각 직교 행렬이기 때문에 식(8)처럼 표현된다.

$$X = V \sum U^T \quad (7)$$

$$[V^T] \cdot [V] = [U^T] \cdot [U] = [I] \quad (8)$$

이와 같은 과정을 통해 얻어진 고유치의 크기는 그 고유벡터의 중요도를 의미하며, 중요 고유벡터를 식(9)을 이용하여 선택한다. 즉, 영상을 대표할 수 있는 주성분의 벡터만을 이용하여 얼굴 영상의 고유 공간으로 표현한다.

$$\frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^N \lambda_i} \geq T_1 \quad (9)$$

### 2.3.2 고유공간에서의 상관관계

얼굴의 고유 공간에서 평균 영상  $C$ 에서  $n$  영상 집합  $x$ 를 모두 식(10)을 이용하여 투영시킨다.

$$f_j = [e_1, e_2, e_3, \dots, e_k]^T (x_n - c) \quad (10)$$

구해진  $f_j$  얼굴 영상의 고유 공간상에서 점들로 표현되는데 각 얼굴의 특징 심볼을 구한 것과 같다. 고유공간에 투영시킨 결과 이산적인 점들로 표현되며, 고유공간의 특성상 비슷한 특징 값을 가지는 벡터는 고유공간에서도 가까운 곳에 투영된다. 즉, 가까울수록 영상들의 높은 상관관계를 가진다.

## 2.4 SVM을 이용한 얼굴 검증

본 논문에서는 고유공간에서 겹침으로 인한 인식 오류를 없애기 위해 PCA에서 추출한 특징 값들을 SVM에 적용하여 최적의 이진분류를 하기 위해 초평면에서의 마진을 이용해 SV를 구함으로써 서로 다른 얼굴에 대한 검증을 한다.

### 2.4.1 최적 분류 SVM

SVM은 이진패턴 분류 문제를 해결하기 위해 제안된 학습방법으로 각 범주의 대표적인 특성을 갖는 벡터를 이용하여 최적의 초평면을 찾아서 두 범주를 분류하는 기법이다[4]. 초평면을 만드는 선형 분류기의 정의는 식(11)와 같다. 선형 분류기는 분류될 클래스가 (+1)과 (-1)일 경우에 대해 클래스를 결정한다.

$$g(x, y) = \langle W, x \rangle + \omega_0 = W^T x + \omega_0 = \sum_{i=1}^n w_i x_i + \omega_0 \quad (11)$$

SVM에 의한 분류는 두 클래스 사이에서 일차 직선을 데이터 점과 만날 때까지 확장한 폭을 선형 분류기의 마진이라고 정의 하며, 마진에는 작은 마진에서 큰 마진 등이 존재한다. [그림3]은 작은 마진, 최대 마진, OSH, Support Vector를 보여주고 있다.




그림 3. 작은 마진, 최대 마진, OSH, SV  
 Fig. 3 Small margin, Max margin, OSH, SV

[그림 3]에서처럼 초평면으로부터 가장 가까이에 위치한 데이터를 서포트벡터(SV)라 하고 초평면에서 SV의 위치까지의 최소 거리를 마진이라 한다. 또한 최적의 초평면 OSH(Optimal Separating Hyperplane)는 마진을 가능한 최대로 하여 두 클래스 간의 구분을 최적화 한다.

SVM은 입력이 m차원일 경우를 포함하여 최적 분류 초평면인 결정경계와 마진을 최대화하는 최적 파라미터 (W, b)를 찾아내는 방법으로써 초평면들을 벡터의 내적으로 표현하면 식(12)과 같고, W는 초평면과 직교하는 가중치 벡터이고, b는 기준값이다.

$$(W \cdot X) + b = 0 \quad W \in R^n, b \in R \quad (12)$$

여기서, 가중치(W)와 기준값(b)를 구하여 평면과 한점간의 거리(d)를 구한 후 d=0 인 결정경계, 결정경계와 가장 가까운 학습 표본에 대하여 +1, -1이 되는 평면을 각각 Plus-Plane과 Minus-Plane으로 정의하며, W는 Plus-Plane과 Minus-Plane 둘 다에 수직인 법선 벡터이므로 u와 v가 Plus-Plane 상의 두 벡터라고 하면, W(u-v)=0 이 된다.

SVM의 학습은 초평면들 중에서 최적 초평면을 찾는 과정이며, 이 때 W와 b항으로 최적의 초평면은

$$\text{식(13)처럼 마진(M)} \quad \frac{2}{\|W\|} \text{가 최대가 되도록 하며,} \\ \frac{\|W\|}{2} \text{가 최소화하는 문제가 된다.}$$

$$M = |x^+ - x^-| = |\lambda W| = \lambda \|W\| \quad (13) \\ = \lambda \sqrt{W^T W} = \frac{2 \sqrt{W^T W}}{W^T W} \\ = \frac{2}{\sqrt{W^T W}} = \frac{2}{\|W\|}$$

SVM의 테스트 단계는 임의의 n차원 벡터의 입력 객체  $X_i \in R^n$ 을 두 개의 클래스  $y_i \in \{+1, -1\}$ 로 예측하는 과정이며, 분류 결정 함수에 적용된다.

선형 분리가 가능한 경우에는 최적화 문제가 되며, 해법으로 라그랑지 함수와 울프 쌍대문제로 유도 후 KKT(karush kuhn Tucker) 필요충분조건을 적용하면 최적화 문제가 된다[8].

라그랑지 계수  $\alpha_i$ 는 2차 프로그래밍 문제(QP)의 해[9]이며, 목적식 Q(α)를 최대화하는  $\alpha_i$ 를 구한 후 KKT 조건에서 유도된 식(14)을 사용하여 최적 가중치 벡터  $\hat{W}$ 를 구한다.

$$\hat{W} = \sum_{i=1}^N \alpha_i y_i X_i \quad (14)$$

$$\hat{b} = \frac{1 - y_i \hat{W}^T X_i}{y_i} \Rightarrow \hat{b} = 1 - \hat{W}^T X_i, y_i = 1 \quad (15)$$

여기서, Support Vector는  $\alpha_i \neq 0$ 이고  $\alpha_i > 0$ 인  $X_i$ 이다. 따라서 임의의 입력 패턴 X가 주어지면 식(14)와 식(15)에 의해 계산되어진  $\hat{W}$ 와  $\hat{b}$ 를 사용하여 식(16)을 식(14)로 치환하여 유도된 식(17)의 판별함수에 의해 분류 결과가 계산되어 진다.

$$f(x) = \text{sgn}(\hat{W}^T X + \hat{b}) \quad (16)$$

$$f(x) = \text{sgn}\left(\sum_{i=1}^N \hat{\alpha}_i y_i X_i^T X + \hat{b}\right) \quad (17)$$

선형적으로 분리되지 않는 경우 오류에 대한 슬랙 변수)를 제약조건에 포함시켜야 한다. 슬랙 변수를 사용함으로써 식(18) 비용 함수를 통해 최적화가 가능하다.

$$\Phi(W, \xi) = \frac{1}{2} \|W\|^2 + C \sum_{i=1}^N \xi_i \quad (18)$$

여기서, C는 오분류와 성능간의 trade-off를 나타내는 비용 변수로 “trade-off 파라미터”로 정의한다. C의 값이 커지면 오분류 오차가 적어지고, C의 값이 적어지면 최소거리가 최대화되어 풀이의 복잡도는 낮아지게 된다.

비선형 SVM의 경우에는 거리 관계를 어느 정도

보존 시킬 필요가 있기 때문에 사상 함수를 이용하여 커널 함수를 식(19)과 같이 정의 한다.

$$K(X, X') = \phi(X)^T \phi(X') \quad (19)$$




그림 4. 2차원에서의 사상  
Fig. 4 2D' Projection

또한 2차원 데이터를 3차원으로 사상시키면 선형 분리 가능한 평면을 얻을 수 있다.

### 2.4.2 SVM을 이용한 얼굴 검증

SVM은 얼굴과 비얼굴 영상에 대해 각각 PCA를 통해 추출된 고유 얼굴에 투영하여 얼굴(+1)클래스와 비얼굴(-1)클래스로 하여 학습하였으며, 얼굴 검증을 하기 위해 고유 공간에서 고유값에 가까우면 얼굴로 멀면 비얼굴로 검출한다.

본 실험에서 SVM의 학습을 위해 마스크를 설정하여 훈련 데이터를 만들었다. 또한 생성된 훈련 데이터에 비선형 SVM을 적용하여 모든 오분류 표본이 최소가 되도록 파라미터 C를 설정하여 학습하였다. 또한 특징 계수를 비선형 SVM의 학습데이터로 사용하였다. 식(20)은 전체 특징 계수 중에서 상위 R개의 특징 계수를 선택한 경우이다.

$$X_i = (d_1, \dots, d_R, y), y_i \in \{face, non\ face\} \quad (20)$$

## 2.5 LDA의 최적 분류

SVM을 통해 검증된 특징 값들을 LDA에 적용하여 2차원 공간에서 클래스내 분산과 클래스간 분산으로 유클리디안 거리를 비교하여 한번 더 분류함으로써 최종 얼굴 인식을 수행한다.

### 2.5.1 Linear Discriminant Analysis

LDA는 클래스간 분산과 클래스내 분산의 비율을 최대화 하는 방식으로 데이터에 대한 특징 벡터의 차원을 축소하는 방법이라고 할 수 있다[10]. LDA는 변환 후 서로 다른 class에 속하는 영상간의 분산은 최대로 하고 동일 class의 영상간의 분산은 최소가 되도록 하는 것이다. 얼굴 인식에서 차원 축소도 중요하지만 더 중요한 것은 서로 다른 특징의 얼굴을 잘 분리하는 것이다.

LDA 방법은 특징 공간상에서 클래스 분리를 최대화하는 주축으로 사상시켜 선형 부공간으로 차원을 축소하는 방법으로 클래스간 분산과 클래스내 분산의 개념을 2차원 공간으로 표현하면 [그림 5]와 같으며, LDA로 차원을 축소하게 되면 차원 축소 후 특징들의 재배치가 이루어지는데 [그림 6]와 같다.




그림 5. 클래스간 분산과 클래스내 분산  
Fig. 5 Within-class and Between-class scatter




그림 6. LDA에 의한 차원 축소  
Fig. 6 Dimensionality reduction by LDA

LDA의 목적은 클래스간의 분별 정보를 최대한 유지시키면서 차원을 축소시키는 것으로써 식(21)과 같다.

$$y = W^T x \quad (21)$$

$W$ 는  $D \times 1$ 행렬이며,  $x$ 는  $D \times 1$ 차원 데이터이다.

분류를 최대화 하는 최적의 사영벡터를 구하기 위해 사영벡터들의 평균벡터를 구한다. 이는 클래스의 평균점이 멀수록 클래스간 분류가 용이하기 때문이다. 원 데이터 표본의 평균벡터  $\mu_i$ 와 사영된 표본  $y$ 의 평균벡터  $\tilde{\mu}_i$ 는 식(22)와 같다.

$$\mu_i = \frac{1}{N_i} \sum_{x \in \omega_i} x, \tilde{\mu}_i = \frac{1}{N_i} \sum_{y \in \omega_i} y = \frac{1}{N_i} \sum_{y \in \omega_i} W^T x = W^T \mu_i \quad (22)$$

표본  $x, y$ 의 평균벡터를 각각  $\mu_1, \mu_2$ 라고 했을 때 사영된 데이터들의 중심 간의 거리를 목적함수로 선택하면 식(23)과 같으며, 표준편차를 고려한 목적함수의 최대화는 식(24)와 같다.

$$\mathcal{J}(W) = |\tilde{\mu}_1 - \tilde{\mu}_2| = |W^T(\mu_1 - \mu_2)| \quad (23)$$

$$\tilde{S}_i^2 = \sum_{y \in \omega_i} (y - \tilde{\mu}_i)^2 \quad (24)$$

따라서 동일한 클래스는 인접하게, 클래스간은 멀리 떨어지게 하는 최종 목적함수를  $S_W$ 와  $S_B$ 로 정의하면 식(25)와 같고, 최적화된 변환행렬은 식(26)과 같다.

$$\mathcal{J}(W) = \frac{W^T S_B W}{W^T S_W W} \quad (25)$$

$$W^* = \operatorname{argmax} \left\{ \frac{W^T S_B W}{W^T S_W W} \right\} = S_W^{-1}(\mu_1 - \mu_2) \quad (26)$$

### 2.5.2 특징 값을 이용한 얼굴의 최적 분류

앞에서 구해진 특징 벡터를 LDA에 이용하여 2차원 공간상에서 클래스내 분산과 클래스간 분산을 측정 한 후 유클리디안 거리를 이용하여 서로 다른 특징 값들 간의 분류를 효과적으로 할 수 있었으며, 인식률을 크게 향상시킬 수 있었다.

### 2.6 실험결과

얼굴 인식은 카메라로부터 촬영된 입력 영상을 전처리 과정을 거쳐 정규화한 후 서로 다른 밝기값을 가진 두 영상의 차를 이용함으로써 목표 영역에 대한 접근 및 검출 능력을 향상시켰다. 얼굴 영상에 대해 PCA를 적용하여 얼굴 특징 벡터를 구하였으며, SVM

을 이용 최적의 이진분류가 되도록 초평면상에서 SV를 구하여 얼굴 영역에 대한 정확한 검증을 수행하였다. 검증 후 LDA를 적용하여 2차원 공간상에서 클래스내 분산과 클래스간 분산을 측정 한 후 유클리디안 거리를 비교하여 최종 얼굴을 인식한다. 본 논문에서 제안하는 얼굴 인식 방법의 성능 평가를 위하여 기존의 다른 알고리즘과 비교하였다. [표 1]은 기존 알고리즘들과의 성능을 비교한 것이다.

표 1. 기존 알고리즘에 대한 인식률 비교(%)  
Table 1. Recognition compared to the existing algorithm(%)

Algorithm	Success Ratio	Fail Ratio	Time (sec)
Single-PCA	88.1	11.9	0.62
Single-LDA	89.6	10.4	0.56
Single-SVM	86.6	13.4	0.67
PCA+LDA	93.7	6.3	0.83
PCA+SVM	92.5	7.5	0.87
PCA+SVM+LDA	96.1	3.9	0.91

[표 1]를 보면 알 수 있듯이 Single로 사용한 경우에는 LDA가 가장 높은 인식률을 보였으며, 복합 알고리즘을 사용한 경우에는 Single에 비해 약3%~5% 정도의 인식률이 향상되었지만 그 중에서도 본 논문에서 제안하는 방법이 96.1%로 가장 높은 인식률을 보여줌으로써 기존의 다른 방법보다 안정된 얼굴 인식이 가능하다는 것을 알 수 있다. 반면, 인식 시간에 있어서는 4개의 알고리즘 모두가 근소한 차이를 보이고 있으며, 반응 시간에서는 제안하는 방법이 다른 알고리즘보다 약간 뒤처지고 있지만 근소한 차이를 보이고 있다.

[표 2]는 조명 변화를 고려하여 밝은 조명에서 촬영된 영상과 어두운 조명에서 촬영된 영상 그리고 본 논문에서 제안하는 방법으로 얼굴 영역의 검출율을 비교한 것이다.

표 2. 조명변화에 의한 얼굴 영역 검출 비교(%)  
Table 2. Face detection by comparison to lighting changes(%)

Lighting changes	Success Ratio	Fail Ratio	Time (sec)
Bright light	82.1	17.9	0.64
Difference Image	91.7	8.3	0.56
Dark light	79.5	20.5	0.71

[표 2]는 수시로 변하는 조명하에서의 얼굴 검출을 확인하기 위한 실험으로 본 논문에서 제안하는 방법이 91.7%로 앞의 두 조명 조건에 비해 높은 검출율을 보였다. 이 실험을 통해 얼굴 검출에 있어 조명의 변화는 매우 민감한 요소가 된다는 것을 다시 한번 알 수 있었다.

### III. 결 론

본 논문에서는 얼굴 인식을 위한 보다 안정적이며 조명 변화와 회전에 강인하게 얼굴 영역을 검출하며, 계산의 효율성과 검출 성능을 동시에 만족시키는 강인한 인식 알고리즘에 대해 제안한다. 웹 카메라를 통해 얼굴 영상이 입력되면 높은 전처리 과정을 거쳐 정규화 한 후 정규화된 영상에서 얼굴 영역만을 정확하게 분할 검출하기 위해 서로 다른 밝기 값을 가진 두 영상의 차분연산을 통해 목표 영역에 대한 접근 및 검출 능력을 향상시켰다. 검출된 후보 영역에 대해 PCA를 적용한 후 특징 벡터를 SVM에 적용하여 후보가 된 얼굴 영역에 대한 검증을 수행한다. 검증과정을 거친 특징 벡터를 LDA에 적용하여 유클리디안 거리를 비교함으로써 최종 얼굴을 인식하였다.

또한, 입력되는 얼굴 영상의 방향을 고려하여 좌·우 45°회전을 가진 영상에 대해 데이터베이스를 생성한 후 PCA를 적용하여 입력 영상의 방향성에 대한 인식 오차를 줄일 수 있었다.

향후에는 기존의 알고리즘에 적용하는 것에 그치지 않고 새로운 알고리즘을 개발하는 연구가 이루어져야 할 것이다.

### 감사의 글

본 논문은 2015년도 송원대학교 학술연구비의 지원을 받아 연구되었음.

### References

- [1] R. C. Gonzalez and R. E. Woods, *Digital Image Processing. Upper Saddle River. New Jersey 07458*: Prentice Hall, 2002.
- [2] M. O. Faruqe and M. A. M. Hasan, "Face Recognition Using PCA and SVM", *Anti-counterfeiting, Security, and Identification in Communication*, 2009. ASID 2009. 3rd Int. Conf. on, Hong Kong, 20-22 Aug 2009, pp. 97-101.
- [3] J. Yang and J. Yang, "Why can LDA be performed in PCA transformed space?," *Pattern Recognition* vol. 36, no. 2 Feb 2003, pp. 563-566.
- [4] V. N. Vapnik, *The Nature of Statistical Learning Theory*. New York: Springer-verlag, 1995.
- [5] P. Liao, J. Liu, M. Wang, J. Ma, and W. Zhang, "Ensemble local fractional LDA for Face Recognition," *Computer Science and Automation Engineering(CSAE)*, 2012 *IEEE Int. Conf. on, Zhangjiajie, China* vol. 3, 25-27 May 2012, pp. 586-590.
- [6] C. Liu and H. Wechsler, "Independent component analysis of Gabor feature for face recognition," *IEEE Trans. Neural Networks*, vol. 14, no. 4, July 2003, pp. 919-928.
- [7] S. E. El-Khamy, O. Abdel-Alim, and M. M. Saei, "Neural Network Face Recognition Using Statistical Feature Extraction," *Radio Science Conf.*, 2000. 17th NRSC '2000. Seventeenth National, Minufiya, 22-24 Feb 2000, pp. C31/1-C31/8.
- [8] E. Osuna, R. Freund, and F. Girosi, "Training Support Vector Machines: An application of face detection." *Proc. IEEE. Computer Society Conference on. Computer Vision and Pattern Recognition(CVPR)*, San Juan, Puerto Rico. 17-19 Jun 1997, pp. 130-136.
- [9] J. C. Platt, "Sequential Minimal Optimization: A

- Fast Algorithm for Training Support Vector Machines," *Microsoft Research Technical Report MSR-TR-98-14*, Microsoft, Redmond Wash., January, 1998.
- [10] M.-H. Yang, "Kernel Eigenfaces vs, Kernal Fisherfaces: Face Recognition Using kernal Methods, Automatrix Face and Gesture Recognition," 202, *Proc. Fourth IEEE Int. Conf., Washinton D.C., U.S.A, 20-21 May 2002*, pp. 0215.
- [11] H. Kim, "Vocal Separation in Music Using SVM and Selective Frequency Subtraction," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 10, no. 1, 2015, pp. 1-6.
- [12] J. Jo, "A Car License Plate Recognition Using Colors Information, Morphological Characteristic and Neural Network," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 5, no. 3, 2010, pp. 304-308.
- [13] H. Park, "A User Adaptation Method for Hand Shape Recognition Using Wrist-Mounted Camera," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 8, no. 6, 2013, pp. 805-814.

## 저자 소개



### 이정재(Jung-Jai Lee)

1985년 조선대학교 공과대학 졸업(공학사)

1987년 조선대학교 대학원 전산기공학과 졸업(공학석사)

1997년 조선대학교 대학원 전기공학과 졸업(공학박사)

1994년 ~ 현재 송원대학교 컴퓨터정보학과 교수

※ 관심분야 : 멀티미디어, 영상처리, 디지털콘텐츠