

사각형 특징 기반 분류기와 PCA기반 MLNN을 이용한 실시간 얼굴검출 및 인식

김종민*, 이기준 **

요약

본 논문은 사각형 특징 기반 분류기를 제안하여 실시간으로 얼굴 영역을 검출하며, 계산의 효율성과 검출 성능을 동시에 만족시키는 강인한 검출 알고리즘을 제안하였다. 또한 검출한 얼굴영역은 인식의 입력 영상으로 사용하여 PCA와 지능형 분류기법의 하나인 다층 신경망을 결합한 얼굴 인식 방법을 제안하고 성능을 평가 하였다. 이 방법은 입력된 얼굴 영상에 대해 전처리 과정으로서 PCA를 통하여 고유얼굴을 산출하고 이를 기본 벡터로 하여 훈련 영상들을 표현한다. 각 영상들은 기본벡터에 대한 가중치의 집합을 특징벡터로 함과 동시에 영상의 차원을 줄인 다음에 다층신경망에 입력하여 얼굴인식을 수행한다. 실험 결과 기존의 방식인 Euclidean과 Mahananobis방법과 비교한 결과 제안한 방법이 잘못된 매칭이나 매칭 실패에서 향상된 인식 성능을 보였다. 또한 학습률에 따른 인식률에 변화를 실험하여 가장 최적의 학습률의 값을 도출하였다.

Real Time Face Detection and Recognition using Rectangular Feature Based Classifier and PCA-based MLNN

Jong-Min Kim*, Kee-Jun Lee**

Abstract

In this paper the real-time face region was detected by suggesting the rectangular feature-based classifier and the robust detection algorithm that satisfied the efficiency of computation and detection performance was suggested. By using the detected face region as a recognition input image, in this paper the face recognition method combined with PCA and the multi-layer network which is one of the intelligent classification was suggested and its performance was evaluated. As a pre-processing algorithm of input face image, this method computes the eigenface through PCA and expresses the training images with it as a fundamental vector. Each image takes the set of weights for the fundamental vector as a feature vector and it reduces the dimension of image at the same time, and then the face recognition is performed by inputting the multi-layer neural network.

Keywords : Principal Component Analysis (PCA), Multi-Layer Neural Networks (MLNN)

1. 서론

최근 정보통신 기술의 급속한 발달과 함께 인간의 삶의 질은 향상되어 가고 있다. 하지만 컴

퓨터 간의 불법 복제 및 삭제, 정보유출 등에 의한 사회적 손실 또한 증가하고 있다. 이러한 문제점을 해결하기 위하여 해킹에 의해 정보가 도용될 수 없고, 또한 변경되거나 분실의 위험성이 없는 신분 검증 기법인 생체인식 기술이 각광을 받고 있다[1]. 이와 같은 생체를 이용하는 방법 중에서 얼굴 인식 분야는 사용자에 특별한 자세나 행위를 요구하지 않고 비접촉으로 자연스럽게 인식을 수행할 수 있다는 장점 때문에 경쟁력 있는 생체 인식 기술로 평가되어 왔다. 그러나 얼굴 인식을 하기 위해서는 아직 해결해야

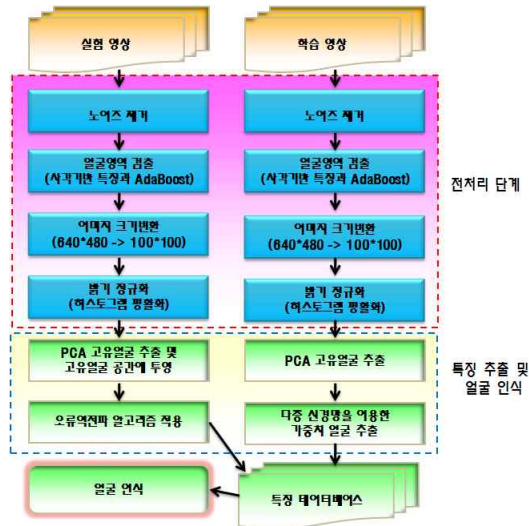
※ 제일저자(First Author) : 김종민
접수일:2010년 07월 13일, 수정일:2010년 12월 21일,
완료일:2010년 12월 23일
* 조선대학교 일반대학원 전산통계학과
mrjjoung@hotmail.com
** 광주보건대학 보건교육정보과(교신저자)
leekj@ghc.ac.kr

할 많은 문제점을 가지고 있다. 사람의 얼굴은 각 개인을 식별할 수 있는 많은 정보를 가지는 장점을 가지고 있지만 얼굴을 검출하고 인식하는 과정에서 외부의 환경에 많은 영향을 받는 단점을 가지고 있다. 기존의 얼굴 인식에는 얼굴의 국부적인 특징을 이용한 방법, 얼굴 형판 정합에 기반한 방법, 인공 신경망을 이용한 학습형 인식방법 등이 있었으나, 영상 학습으로 인한 방대한 메모리양과 계산 시간의 문제가 제기되었다. 이러 문제점을 해결하기 위한 방법으로는 얼굴 영상 벡터를 하나의 벡터 공간상의 특징 벡터들로 변환하여 비교하는 얼굴 인식 방법이 활발히 연구되고 있다. 대표적인 Eigenface 방법[2]인 PCA(Principal Component Analysis)[3], Fisherface 방법인 LDA(Linear Discriminants Analysis)[4] 그리고 ICA(Independent Component Analysis)[5]가 있다. 여기서 training set의 크기가 작을 경우 PCA가 LDA보다 우수하며[6], 반면에 영상의 조명변화가 큰 경우 LDA가 PCA보다 우수함[7]이 보고되어 있다. 본 논문에서는 가장 최적화된 PCA를 적용하기 위해 사각형 특징 기반 분류기를 이용하여 얼굴 영역만을 검출하는 알고리즘을 제안한다. 또한 PCA의 얼굴 인식은 모델 영상상의 각각의 얼굴의 대표 값을 만든 후에 실험 영상을 고유 공간에 투영 시켜서 나온 성분과 대표 값의 거리를 비교하는 방법인 point to point 방식을 많이 사용하였다. 그러나 이 방법은 단순 거리 계산을 계산하기 때문에 오차가 많아 실시간 인식 시 인식 저하를 발생 시켰다. 그래서 본 논문에서는 인식률을 향상시키기 위해 PCA를 거쳐 적은 수의 고유 얼굴 특징 벡터를 산출하여 다중 신경망과 결합하는 인식 방법을 제안한다. 제안된 방법은 잡음 및 조명 변화에도 향상된 성능을 보여 인식 오차를 줄일 수 있었다.

2. 전체 시스템 구성도

본 논문에서 제안하는 얼굴 인식 시스템의 알고리즘은 카메라를 통해 얻어진 배경 영상에서 사각형 특징 기법을 이용하여 얼굴만을 추출하고 영상의 크기 정규화 및 노이즈를 제거한 후 PCA를 통해 고유벡터를 산출한 후 MLNN을 적용하여 얼굴 인식을 수행한다. 그림 1은 본 논문

에서 제안하는 알고리즘의 순서도를 나타낸다.




(그림 1) 시스템 전체 구성도

3. 얼굴 검출 알고리즘

3.1 웨이블릿 특징 모형

웨이블릿 기반의 특징 계산은 픽셀 기반의 특징 계산보다 효율적으로 처리 할 수 있다. 또한 간단한 구조에도 불구하고 특정 영역에 대한 에지나 라인 등의 정보를 잘 제공해 준다[8-9]. 특징 모형의 선택은 이후에 전체 얼굴 검출의 연산 속도에 결정적인 영향을 미치게 되기 때문에 매우 중요한 과정이다. Paul Viola는 4종류의 특징 모형을 사용하여 좋은 결과를 도출하였다[8]. 본 논문에서는 Paul Viola의 방법을 확장하여 그림 2와 같이 고유한 얼굴의 특징을 추출하는 8종류의 웨이블릿을 제안하였다. 각각의 특징 모형은 얼굴 요소에서 특징들을 만들어 낸다.




(그림 2) 8종류의 웨이블릿 특징 모형

8종류의 간단한 웨이블릿 특징 모형은 20*20의 훈련영상에 맞추어 다양한 위치와 다양한 크기로 초기 특징 집합을 생성한다. 초기 특징 집합은 모든 가능성을 가진 집합으로 생성하기 때문에 영상 윈도우의 크기와 각각의 웨이블릿 형식에 따라 무수히 많은 특징을 형성하게 된다. 이러한 추기의 특징 집합은 이후에 학습된 분류기를 통하여 얼굴을 검출하는데 결정적 영향을 미치는 얼굴 특징 집합으로 선택될 가능성이 있기 때문에 매우 중요하다.

3.2 SAT(Summed-Area Tables)

웨이블릿에 의해 생성된 특징들은 특징값으로 계산되어 분류기에서 사용되어진다. 그러나 특징의 수가 많기 때문에 많은 연산 시간을 필요로 하게 된다. 본 논문에서는 특징 값을 빠르게 계산하기 위해서 그림 3과 같이 영역의 합 테이블(Summed Area Table)을 사용하였다. SAT는 영상 내에 존재하는 특정한 좌표 영역(x, y)의 값을 입력 영상의 원점(0, 0)에서부터 좌표 영역(x, y)를 포함하는 사각형 영역 내에 존재하는 모든 픽셀값을 더한 값이며, 식(1)과 같이 정의 된다.



(그림 3) 영역의 합 테이블(SAT)

$$s(x,y) = \sum_{x' \leq x, y' \leq y} I(x',y') \quad \text{식(1)}$$

따라서, 하나의 사각형 특징(RS)은 SAT(S)를 이용하여 효율적으로 계산되며, 식(2)와 같이 정의된다.

$$RS(x,y,w,h) = S(x+w,y+h) - S(x+w,y) - S(x,y+h) + S(x,y) \quad \text{식(2)}$$

식(2)에서 x와 y는 가로 x, 세로 y인 특징한

좌표 영역이며, w와 h는 너비 w, 높이 h인 사각형 영역을 나타낸다.

선택되어진 전체 영역의 특징값(RF)은 식(2)를 사용하여 전체 사각형 영역의 픽셀값(RSw)의 평균과 검정색 사각형 픽셀값(RSb)의 평균에 대한 차로 구하며, 식(3)과 같이 정의된다. 즉, 사각형 특징 마스크의 특징 값은 흰색과 검정색 영역의 각 평균을 차 연산한 결과 값으로 얻어진다.

$$RF(x,y,w,h) = \frac{1}{m} \sum RSw - \frac{1}{n} \sum RSb \quad \text{식(3)}$$

사각형 특징 마스크는 그림 2에서 언급한 2개의 흰색과 검정색 사각형 영역이 오버랩된 형태이다. 식(3)에서 m은 RSw의 픽셀 수, n은 RSb의 픽셀 수이다. 이와 같이 생성된 누적 영상과 특징값 계산 기법은 최종적으로 약한 분류기를 구성하는 함수의 계산 방법에 이용된다.

3.3 AdaBoost 알고리즘을 이용한 얼굴 특징의 분류

본 논문에서 AdaBoost 알고리즘을 이용하여 계층적 분류기를 학습한다. AdaBoost 알고리즘은 약한 분류기(weak classifier)를 선형적으로 결합하여 최종적으로 높은 검출 성능을 가진 강한 분류기(strong classifier)를 생성하는 알고리즘이다. 이는 분류기의 가중치를 바꾸어가면서 단계적으로 반복하여 적용하고 각 단계마다 특징 집합 중에서 얼굴을 검출할 수 있는 결정적인 특징만을 남기고 나머지 특징들은 제거하는 방식이다. 본 논문에서 사용한 AdaBoost 알고리즘은 그림 4와 같다.

분류기는 얼굴과 비 얼굴 패턴으로 구성된 훈련 영상 집합과 특징 집합을 이용하여 학습된다. 입력 벡터 X는 특징 집합이며, Xi는 하나의 사각형 특징 마스크이다. 출력 Y는 +1과 -1값을 가지며, 각각 얼굴과 비 얼굴을 나타낸다.

약한 분류기 ht가 하나의 사각형 특징 마스크 Xi를 이용하여 훈련패턴을 분류한다. 이때 잘못 분류된 훈련 패턴은 가중치 wt(i)를 증가 시키고, 옳게 분류된 훈련 패턴은 가중치 wt(i)를 감소시키는 과정을 반복한다. 분류기는 훈련 패턴의 변경된 가중치를 고려하여, 최소의 에러를 가지도록 하는 사각형 특징

마스크를 선택한다. 이와 같이 학습된 분류기는 얼굴 패턴의 특징을 추출하는데 결정적인 역할을 하는 사각형 특징 마스크들로 구성된다. 약한 분류기 h_t 는 하나의 사각형 특징 마스크 X_i 로 분류하며, 최종적으로 생성된 강한 분류기 $H(x)$ 는 t 개의 약한 학습기가 결합된 형태이다. 즉, 강한 분류기는 t 개의 사각형 특징 마스크가 선형적으로 결합한 형태이다. 강한 분류기는 약한 분류기의 수를 증가할수록 어려움이 영점에 지수적으로 접근한다.

1. Given N examples $(x_1, y_1), \dots, (x_N, y_N)$ with $x_i \in X, y_i \in Y = \{-1, +1\}$
2. Initialize weights $w_1(i) = \frac{1}{m}, \frac{1}{2n}$ $i = 1, \dots, N$
 m : number of positive, n : number of negative
3. Repeat for $t = 1, \dots, T$
 - (a) Train weak learner using weight w_t
 - (b) Repeat for $j = 1, \dots, n$, number of initial feature
 Get weak classifier $h_t = \{X \rightarrow \{1, -1\}\}$
 with error $\epsilon_{j1} = \sum_i^m w_t(i) |h_j(x_i) - y_i|$ (positive)
 $\epsilon_{j2} = \sum_i^n w_t(i) |h_j(x_i) - y_i|$ (negative)
 choose the classifier using error (ϵ_t, h_t)
 - (c) weight update

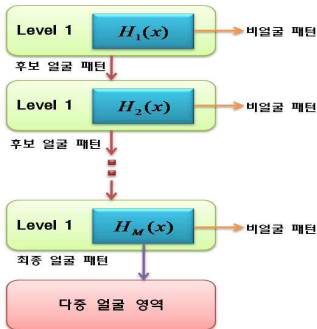
$$\alpha_t = \frac{1}{2} \ln \left(\frac{\epsilon_t}{1 - \epsilon_t} \right)$$

$$w_{t+1}(i) = w_t(i) \cdot \begin{cases} e^{-\alpha_t} & \text{if } h_t(x_i) = y_i \\ e^{\alpha_t} & \text{if } h_t(x_i) \neq y_i \end{cases}$$
4. Output the final hypothesis (strong classifier)

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t h_t(x) \right)$$

(그림 4) AdaBoost 알고리즘

강한 분류기는 높은 정확도를 가진 분류기가 단계적으로 구성되며, 그림 5와 같이 도식화된다.



(그림 5) 분류기의 계층도

분류기의 형태는 학습 과정에서 분류기를 구성할 레벨의 수와 각 레벨에서 사용할 특징을 결정하게 된다. 분류기는 중요한 얼굴 패턴은 다음 레벨에 다시 반복적으로 적용하고, 중요하지 않은 얼굴 패턴은 버림으로써 우수한 검출 성능을 가지게 된다.

4. 얼굴 인식 알고리즘

Mono 카메라를 이용하여 얼굴의 방향이 틀어지는 경우를 같은 형상으로 인식하기에는 많은 어려움이 있다. 따라서 본 논문에서는 그림 6과 같이 얼굴의 방향성이 틀어지는 경우 같은 얼굴 영상으로 인식하기 위해 주성분 분석을 이용한 얼굴 방향성 문제의 해결 방법을 제안한다.

이 문제를 해결하기 위해서는 한 사람의 영상을 5°씩 회전을 해서 얼굴 영상을 습득하여 데이터베이스를 구축해야 한다. 그러나 주성분 분석에서는 단지 영상의 외관기반으로 인식을 수행하기 때문에 사람의 머리 모양의 변화만으로도 같은 사람으로 인식하기가 어렵다. 그래서 본 논문에서는 앞에서 설명한 사각형 특징 기반 분류기를 이용하여 얼굴 영역이 추출 가능한 영상만을 모델 영상으로 사용하였다.



(그림 6) 서양 여자의 회전 영상



(그림 7) 회전 영상에서 사각형 특징 기반 분류기를 이용한 얼굴 영역 검출 영상

그림 7은 그림 6에서 얼굴 영역이 추출 가능한 영상만을 나타내었다. 그러나 사각형 특징 기반 분류기를 이용하여 얼굴 영역을 추출하는 방법은 얼굴의 상하 좌우의 큰 회전에 대해서는 추출이 불가능하며 좌우 회전 30°까지만 얼굴 추출이 가능하였다.

4.1 PCA에 의한 특징추출 및 분류

PCA는 K-L 변환(Karhunen-Lo'eve transform)이라고도 불리는데 K-L 변환은 클래스 정보를 사용하지 않고 특징 공간에서 데이터의 분포 및 특성을 유지하면서 영상의 차원을 줄이는데 목적을 둔 방법이다.

고유벡터를 계산하기 위해 N(Row×Col) 크기의 M개의 학습영상의 집합을 $X = [x_1, x_2, x_3, \dots, x_m]$ 라고 하면 이 차를 나타내는 공분산 행렬 S 는 다음과 같이 정의 할 수 있다. 여기서 r 는 평균 데이터이다.

$$S = \sum_{i=1}^M [x_i - r][x_i - r]^T, \quad r = \frac{1}{M} \sum_{i=1}^M x_i \quad \text{식(4)}$$

위 식(4)에서 S 의 고유벡터와 고유값을 다음 식을 이용해 구할 수 있다.

$$\lambda e_i = S e_i \quad \text{식(5)}$$

여기서 e_i 는 고유벡터이고, λ 는 고유값이 된다. 다음으로 고유값의 크기가 큰 순으로 고유벡터 e_i 를 정렬하면 p 개의 고유벡터로 구성된 식(6)을 구할 수 있다.


$$W_{PCA} = [Xe_1, Xe_2, Xe_3, \dots, Xe_p] \quad \text{식(6)}$$

식(6)에서 구한 p 차원의 고유벡터는 각 영상마다 고유값을 가지고 있으므로 이를 특징벡터라 한다. 여기서 정규 직교하는 열로 이루어진 고유벡터를 고유얼굴이라 하며, 여기서 얻어진 고유얼굴과 특징벡터의 선형적 결합으로 얼굴영상을 표현할 수 있다. 그러나 각 고유벡터가 지닌 고유치의 크기는 그 고유벡터의 중요도를 의미하므로 그 고유공간을 규정하는 중요 고유벡터를 식

(7)을 이용하여 선택한다. 따라서 모든 고유벡터를 고유 공간 구성에 이용하지 않고 많은 영상을 대표할 수 있는 주성분의 벡터만을 이용할 수 있다.

$$\frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^N \lambda_i} \geq T_1 \quad \text{식(7)}$$

여기서 T_1 은 고유벡터의 개수를 조정하는 문턱치이며, 인식과 회전 포즈 평가 시 이용되는 고유벡터는 저차원 공간을 구성하기 고유 벡터를 고유치의 값이 큰 순서로 배열하면 그림 8과 같다. 실험에서는 $K = 8$ 를 이용하였다. 이렇게 구성된 공간을 얼굴 고유공간으로 표현한다.




(그림 8) 고유치의 개수에 따른 누적 기여도

4.2 오류역전파를 이용한 얼굴인식

얼굴 인식방법에서 입력되는 얼굴 영상의 특징 벡터가 유클리디안 거리가 가장 가까운 특징 벡터를 가지는 모델영상내의 얼굴을 찾아냄으로써 수행된다. 하지만 얼굴 영상 공간에서 실제 얼굴 영상은 매칭에 성공했을지라도 다른 얼굴 영상으로 인식하는 잘못된 매칭이 발생하였다. 이러한 문제를 해결하기 위해 기존의 유클리디안 거리를 활용하는 대신에 신경망을 활용하여 분류하는 방식을 제안하려고 한다.

PCA를 통해 얻어진 고유얼굴의 가중치를 MNLN의 입력으로 사용하는데 본 논문에서는 오류역전파 알고리즘을 이용하여 신경망의 가중치를 학습함으로써 분류기로서의 역할을 수행한다.

본 연구에서 설계된 신경망의 구조는 그림 9와 같다.



(그림 9) 다층신경망의 구조

신경망의 입력으로 사용하는데 본 논문에서는 오류역전파 알고리즘을 이용하여 신경망의 가중치를 학습함으로써 분류기로서의 역할을 수행한다.

본 연구에서 설계된 신경망의 구조는 그림 9와 같다. 그림 9의 입력 층과 제 1은닉 층 사이 가중치 학습은 오류역전파(Error back-propagation) 알고리즘의 식(8)~식(14)에 의해 반복적 학습을 통해서 찾아진다[10].

$$w^{k+1} = w^k - \eta \frac{\partial E^k}{\partial w_{ij}} \quad \text{식(8)}$$

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial h_i} \frac{\partial h_i}{\partial w_{ij}} \quad \text{식(9)}$$

$$\frac{\partial E}{\partial h_i} = \frac{\partial E}{\partial s_i} \frac{\partial s_i}{\partial h_i} \quad \text{식(10)}$$

$$E = \frac{1}{2} \sum_{i=1}^r (t_i - y_i)^2 \quad \text{식(11)}$$

$$s_i = \frac{1}{1 + e^{(-\lambda h_i)}} \quad \text{식(12)}$$

$$h_i = \sum_{l=1}^q w_{il} v_l + w_{iq+1} \quad \text{식(13)}$$

$$y_i = \sum_{l=1}^r v_{il} s_l + v_{ir+1} \quad \text{식(14)}$$

여기서 \$k\$는 학습 반복회수, \$i, j\$는 각각 입력과 은닉 층 노드의 번호, \$\eta\$는 수렴상수, \$s\$는 활성화함수, \$h\$는 중간 합계함수, \$y\$는 출력 값, \$t\$는 목표 값, \$m\$는 입력 노드 수, \$r\$는 출력 노드 수, \$v_{ij}\$는 은닉층과 출력층과의 사이의 학습 가중치를 나타낸다. 은닉층과 출력층간의 가중치 학습은 식(15-16)로 구해진다.

$$v^{k+1} = v^k - \eta \frac{\partial E^k}{\partial v_{ij}} \quad \text{식(15)}$$


$$\frac{\partial E}{\partial v_{ij}} = \frac{\partial E}{\partial y_i} \frac{\partial y_i}{\partial v_{ij}} \quad \text{식(16)}$$

위 두 학습가중치 식(8)에서 식(16)을 반복적으로 학습하여 최적의 값을 얻으면 학습은 끝나고, 이것을 이용하여 분류기로 사용하게 된다.

5. 실험결과

5.1 MLNN를 이용한 인식결과

본 논문에서 제안한 실시간 얼굴 검출 실험은 Web Camera를 통한 실시간 영상을 다양한 조건하에서 얼굴 검출을 실험하였고, 결과는 그림 10과 같다. 그림 10의 (a)는 정면 얼굴을 검출한 결과이고, (b)(c)는 얼굴 영상의 다양한 회전을 통한 얼굴 검출결과이며 좌우 회전은 30°까지 회전에서 검출 가능하며 상하 이동은 45°까지 검출이 가능하였다. (d)는 동일한 인물에 안경을 추가하여 검출한 결과이다. (f)는 한 영상에 다중 사람이 입력되었을 때 검출한 결과이다.



(그림 10) 다양한 조건하에서 실시간 얼굴 검출

제안한 사각형 특징 기반 분류기는 640*480 크기의 입력 영상에 대해, 1초당 약 22프레임을 실시간으로 처리하며, 다양한 위치와 크기의 얼굴 영역을 빠르고 효율적으로 검출하였다.

5.2 MLNN를 이용한 인식결과

실험에 사용된 영상은 ORL DB와 자체 제작

한 얼굴영상 데이터베이스(CSDB)를 사용하여 실험을 하였다. 그러나 사용된 얼굴 영상은 사각형 특징 기반 분류기를 통하여 검출된 얼굴 영역만을 사용하였다. ORL DB는 서로 다른 환경에서 40명으로부터 각 개인에 대하여 10장의 얼굴로 구성되어 있으며, 이 영상들은 위치 회전, 스케일, 얼굴 감정에 변화를 주고 있다. (회전에서의 변화는 최대 20° 회전하였고, 스케일에 변화는 사람과 비디오카메라 사이에 거리를 변화시켰다.) 자체 제작한 CSDB는 10명으로부터 개인당 5°씩 회전한 영상 40 장을 제공한다. 학습을 위해 ORL DB 200개와 CSDB 200개의 얼굴영상을 PCA에 적용하여 특징벡터를 산출하였다. 검증하기 위해서는 학습에 사용되지 않은 나머지 영상 사용하였다. 제안한 방법의 우수성을 검증하기 위하여 PCA 결과 가중치를 신경망에 입력하여 신경망의 가중치를 학습한 후에 인식 성능을 기존의 Euclidean 거리척도 방법, Mahalanobis 거리 척도를 적용한 결과를 표 1에 나타내었다. 제안한 신경망은 입력노드 수는 400개이며 은닉층은 10개를 사용하였다. 초기 가중치는 0.01, 오차 허용 한계는 0.005로 설정하였다.

<표 1> 매칭 방법에 따른 매칭 성공률

매칭 방법	매칭 실패	잘못된 매칭	매칭 성공
Euclidean	3.5 %	4.0 %	92.5 %
Mahalanobis	5.5 %	3.5 %	91.0 %
Proposed MLNN	1.7 %	3.0 %	95.3 %

표 1에서 보는 바와 같이 제안한 방법을 이용했을 때 기존의 제안한 방법인 Euclidean 과 Mahalanobis의 방식보다 매칭 실패율은 상당히 좋은 향상을 보였고, 잘못된 매칭에서도 기존의 방법보다는 우수성을 나타내었다.

5.3 학습률에 따른 인식률

본 논문에서는 최적의 학습률에 따른 인식률의 차이를 알기 위해 표 2와 같이 실험을 진행하였다. 표 2의 실험환경은 얼굴 영상 학습 모델 200개를 가지고 얼굴 영상 100개의 영상에 대해 인식을 수행하는 실험을 하였다. 실험에서 출력 오차의 임계값은 0.025로 사용하였다.

<표 2> 실험 환경


영상개수 실험환경	학습에 사용된 얼굴 영상 수	인식에 사용된 얼굴 영상 개수
실험환경	200	100

표 3은 표 2의 실험에 대한 결과이다. 실험에서 알 수 있듯이 학습률이 증가함에 따라 학습 횟수가 감소되는 것을 알 수 있었고, 학습률에 따른 인식률에서는 학습률을 0.2로 하여 학습하였을 때 인식률이 가장 좋음을 알 수 있었다. 또한 학습에 사용한 얼굴 영상을 입력 영상에 포함 시킬 때 인식률이 향상되어진다.

<표 3> 학습률에 따른 인식률

Learning rate	학습 횟수	인식률 (%)
0.01	3360	95.32
0.1	372	93.54
0.2	149	97.20
0.3	101	95.35
0.4	68	95.36
0.5	70	93.50
0.6	47	93.50
0.7	59	93.52
0.8	43	91.65
0.9	27	91.65
1.0	28	93.50

그림 11은 학습률에 따른 인식률에 변화를 나타낸 그림이다.



(그림 11) 학습률에 따른 인식률에 변화

6. 결론

본 논문은 지금까지 개별적으로 얼굴 인식을 위하여 이용되어 왔던 PCA, MLNN 알고리즘들을 결합하여 기존의 PCA의 매칭 방법들과 비교하여 성능을 비교하였다. PCA를 전처리로 하여 특징 벡터를 산출하여 이를 신경망에 입력 데이터로 활용함으로써 차원을 낮추면서도 인식 성능을 높일 수 있는 방안을 제시하였다. 실험 결과 기존의 방식들과 비교하여 제안한 방법이 95.3%로 기존의 방법과 비교하여 인식률의 향상을 시켰다. 또한 학습률에 따른 인식률에 변화를 실험하여 가장 최적의 학습률의 값을 도출하였다. 향후 전처리와 신경망의 파라미터들을 최적화 과정에 대하여 심도 깊은 연구가 필요하다고 사료된다.

참 고 문 헌

[1] Rodrigo de Luis-Garcia, Carlos Alberola-Lopez, Otm an Aghzout and Juan Ruiz-Alzola "Biometric identification systems,J" Signal Processing Vol. 83, Issue 12. pp. 2539-2557, Dec 2003.

[2] Z. Zang, M. Lyons, M. Schuster and S.Akamatsu, "Comparison between Geometry-Based and Gabor Wavelets-Based Facial Expression Recognition Using Multi-Layer Perceptron", Proceedings of Third IEEE International Conference on Automatic Face and Gesture Recognition, pp.454-459, 1998.

[3] Hiroshi Murase and Shree K. Nayar, "Visual Learning and Recognition 3-D object from appearance", international journal of Computer Vision, Vol,14,1995.

[4] Paul Viola and m. Jones, "Robust real time object detection", International Conference on Computer Vision, 2001.

[5] S.Z. Li, L. Zhu, A.Q Zhang, and H.J. Zhang, "Statistical Learning of Multi-View Face Detection", In Proc. 7th European Conference on Computer Vision, Copenhagen, Denmark. May 2002.

[6] Martinez, A.M; Kak, A.C; "PCA versus LDA, "IEEE Transactions, Pattern Analsis and Machine Intelligence, Volume: 23, Issue: 2, pp.228 - 233, Feb 2001.

[7] Belhumeur, P.N.; Hespanha, J.P.; Kriegman, D.J.; "Eigenfaces vs. Fisherfaces: recognition using class specific linear projection," IEEE Transactions, Pattern Analysis and Machine Intelligence, Volime: 19, Issue: 7, pp. 711 - 720, July 1997.

[8] F. Crow, "Summed-area tables for texture mapping", In Proceedings of SIGGRAPH, Vol. 18(3), pp. 207-212, 1984.

[9] Jong-Min, Kim, Kyoung-Ho Kim, Maeng-Kyu Song; "Real Time Face Detection and Recognition Using Rectangular Feature Based Classifier and Modified Matching Algorithm", Proceedings of Fifth IEEE International Conference on Natural Computation", pp.171-175, 2009.

[10] A. D. Kulkarni, Computer Vision and Fuzzy-Neural Systems, Prentice-Hall, 2001



김 종 민

2008년 2월: 조선대학교 전산통계학과 (이학박사)

2009년11월 ~ 현재 : (주)에스티정보통신 책임연구원, 조선대학교 외래교수, 광주보건대학 겸임교수

관심분야: 컴퓨터비전, 멀티미디어, 생체보안



이 기 준

1994년 2월 : 조선대학교 전산통계학과 (이학사)

1997년 2월: 조선대학교 전산통계학과 (이학석사)

2001년 8월: 조선대학교 전산통계학과 (이학박사)

2002년 3월 ~ 현재 : 광주보건대학 보건교육정보과 부교수

관심분야: 영상처리, 내용기반검색, 멀티미디어