

# 선형판별법과 레이디얼 기저함수 신경망 결합에 의한 얼굴인식

Face Recognition by Combining Linear Discriminant Analysis and Radial Basis Function Network Classifiers

오병주

한남대학교 정보통신멀티미디어공학부

Byung-Joo Oh(bjoh@hannam.ac.kr)

## 요약

이 논문은 얼굴인식을 수행하기 위해서 이미 잘 알려진 주성분 분석법과 선형판별 분석법에 레이디얼 기저 함수 신경망을 결합한 인식 알고리즘을 제시하였다. 입력된 원래의 얼굴영상은 주성분분석법을 통하여 차원을 줄인 고유 얼굴 가중치를 산출한다. 이 가중치 벡터를 선형판별 분석법의 입력데이터로 사용하여 선형판별분석의 변환행렬을 계산할 때 클래스 내의 분산행렬에서 특이점이 발생하지 않도록 하면서 특정 벡터를 산출하여 인식을 수행하였다. 두 번째 시도에서는 선형판별분석법에 의해 생성된 특징벡터를 레이디얼 기저 함수 신경망에 입력하여 학습하고 얼굴인식을 수행하였다. ORL DB의 얼굴영상에 대해 실험한 결과 93.5%의 인식률을 얻을 수 있었다.

■ 중심어 : | 주성분분석 | 선형판별분석 | 레이디얼 기저함수 신경망 | 얼굴인식 |

## Abstract

This paper presents a face recognition method based on the combination of well-known statistical representations of Principal Component Analysis(PCA), and Linear Discriminant Analysis(LDA) with Radial Basis Function Networks. The original face image is first processed by PCA to reduce the dimension, and thereby avoid the singularity of the within-class scatter matrix in LDA calculation. The result of PCA process is applied to LDA classifier. In the second approach, the LDA process produce a discriminational features of the face image, which is taken as the input of the Radial Basis Function Network(RBFN). The proposed approaches has been tested on the ORL face database. The experimental results have been demonstrated, and the recognition rate of more than 93.5% has been achieved.

■ keyword : | Principal Components Analysis | Linear Discriminant Analysis | Face Recognition | Radial Basis Function Network |

\* 본 연구는 산업자원부 지역협력연구사업(R12-2003-004-03001-0) 지원으로 수행되었습니다.

접수번호 : #050622-002

접수일자 : 2005년 06월 22일

심사완료일 : 2005년 08월 11일

교신저자 : 오병주, e-mail : bjoh@hannam.ac.kr

## I. 서 론

오늘날 정보보호와 신분확인을 위해 이용되는 생체인식 기술 분야는 매우 다양해졌다. 이들 중 얼굴인식분야는 사용자에게 특별한 자세나 행위를 요구하지 않고 비접촉으로 자연스럽게 인식을 수행할 수 있다는 장점 때문에 경쟁력 있는 생체인식 기술로 평가되고 있다. 얼굴인식기술이란 사진 혹은 카메라를 통해 입력되는 정지영상 및 동영상의 자료를 분석하여 얼굴을 찾아내어 특징을 추출하여 기존의 확보된 데이터베이스 안에서 부합하는 특징을 가진 얼굴영상이 존재하는지 여부를 알아내는 인식기술이다.

얼굴인식 시스템은 비디오 감시 장치, 범죄용의자나 신분확인을 위한 데이터베이스 검색, 사람-기계 인터페이스나 네트워크상에서 사용자들의 사용권한 허용여부 등에도 응용될 수 있는 기술이다. 이러한 중요성으로 인하여 얼굴인식연구는 지난 20여 년간 패턴인식분야나 컴퓨터시각분야를 연구하는 사람들에게는 매우 큰 관심사가 되어 왔다. 그럼에도 불구하고 아직도 많은 어려운 문제들이 남아 있는 이유는 표정, 분장 등 얼굴 자체의 변화와 위치, 자세, 조명 등 영상획득에 영향을 주는 주변 환경의 변화 등으로 인하여 전실한 영상데이터를 얻기가 어렵기 때문이다.

컴퓨터에서 얼굴영상은 다양하게 분포된 그레이 혹은 컬러 레벨의 화소들의 분포로 볼 수 있다. 따라서 얼굴인식을 수행하기 위해서는 얼굴영상을 충분히 적은 차원의 고 판별력을 가지는 특징벡터로 나타내어야 한다. 이러한 특징벡터 표현을 찾아내는 것이 얼굴인식을 수행하는 중요한 단계라고 할 수 있다[1]. 현실적으로 크기  $p \times q$  화소의 얼굴영상을  $p \cdot q$  차원의 벡터로 표현하게 되면 너무 커져서 견실하고 빠른 인식을 수행하기 어렵게 된다. 따라서 일반적으로 이 벡터의 차원을 줄이기 위하여 주성분분석(Principal Component Analysis : PCA)기법과 선형판별분석(Linear Discriminant Analysis : LDA) 기법이 가장 많이 사용되어 왔다 [2-5].

이 두 가지의 형태기반 접근 방법은 단순히 차원을 줄일 뿐만 아니라 그 자체로 얼굴인식의 주요기법으로 발

전되어 왔다. 이를 방법은 얼굴영상의 화소 농도자체나 농도에 의한 특징들을 활용하는 접근방법을 취하여왔다. 따라서 이들이 가지는 문제점은 많은 현실상황, 즉, 알아내고자 하는 입력 얼굴영상이 포즈, 조명, 표정 등의 변화로 인하여 이미 훈련에 사용된 얼굴영상들과 많이 다른 상황이 될 때는 제대로 성능을 내지 못하게 된다는 것이다.

비록 이러한 형태기반의 접근법이 위 변화들을 어느 정도 감내하는 견실한 인식기법을 설계한다고 하더라도 앞에서 언급된 모든 변화에 잘 적용하는 기법을 설계하기는 어려운 일이다. 즉, 각 인식기법은 각 변화에 다른 성능을 나타내게 된다. 따라서 이러한 상황으로 미루어 서로 보완기능이 있는 인식기법들을 결합한다면 위의 다양한 변화에 좀 더 나은 성능을 낼 수 있는 얼굴인식 기법을 설계할 수 있다는 생각을 갖게 만든다. 즉, 개별 인식기법이 가지는 장점과 단점을 서로 보강하여 전체적으로 보다 나은 성능을 가지는 결합된 인식방법 [5][6]을 찾아내자는 것이다.

원래의 영상행렬은 각 행 혹은 열을 이어 붙임으로써 2차원의 영상을 하나의 벡터로 변환한다. 이 벡터는 너무 커서 PCA와 LDA 인식기법은 이 벡터를 기본벡터에 투영함으로써 벡터의 차원을 줄일 수 있고 동시에 투영계수들이 각 얼굴영상의 특징을 나타내는 특징표현으로 이용될 수 있도록 하는 것이다. 차원이 줄여진 이 특징표현 벡터들이 신경망에서의 연결가중치들을 학습하는데 이용되어 형태기반 얼굴인식 기법과 신경망이 결합하는 얼굴인식방법을 제안해 낼 수 있는 것이다. 이러한 개념들은 이미 몇몇 연구자들[7-10]이 부분적으로 제안하여 결과를 내놓은 바 있다. 그러나 통계적 방법인 형태기반 인식기법 간의 결합이 주류를 이루고 있으며 신경망의 최적화를 통한 결합은 아직 진행단계에 있다고 하겠다.

본 논문에서는 우선 PCA를 전처리과정으로 하여 차원을 줄인 고유얼굴 특징벡터를 산출한 다음에 LDA를 전처리로 하여 적은 수의 Fisher 얼굴 특징벡터를 산출하여 RBF 신경망과 결합하는 인식방법을 제안하고 컴퓨터 실험 결과를 산출하여 PCA, LDA와 RBF 알고리즘들을 결합하였을 때 고유의 알고리즘들이 가지고 있

는 인식 성능들이 변화되는 과정을 비교하려고 한다.

본 논문의 구성은 다음과 같다. 2장에서는 각 얼굴인식 방법들에 대하여 간략하게 이론적 배경을 소개하고 3장에서는 결합된 인식 방법에 대한 실험 결과를 비교 제시하며 4장에서 결론을 맺으려고 한다.

여기서  $Y$ 는  $m \times N$  특징벡터이며,  $m$ 은 특징벡터의 차원을 나타내며  $W$ 은  $n \times m$  크기의 선형 변환행렬이며 그 행들은 다음 식 (2)에서 계산되는 고유치들 중 크기가  $m$  번째까지에 해당하는 고유벡터로 이루어진다.

$$\lambda e_i = S e_i \quad (2)$$

## II. 제안된 인식기법

본 장에서는 PCA, LDA, RBFN 알고리즘 각각에 대해 이론적 배경과 제안 된 알고리즘을 설명하려고 한다.

### 1. 주성분분석법(Principal Component Analysis: PCA)

주성분 분석법은 전 영상 공간 내에서 얼굴영상의 분포를 가장 잘 나타내주는 감소된 차원의 벡터를 생성해내는데 이용된다. 생성된 벡터들은 얼굴영상의 부분공간을 정의해 주며 이 부분공간을 얼굴공간이라고 한다. 훈련용 집합 내에 있는 모든 얼굴영상들을 얼굴공간으로 투영하여 얼굴 공간 내에서 각 벡터가 차지하는 가중치 집합을 찾아내게 된다.

주성분분석의 기본적 해법은 주어진 영상에서 공분산 행렬의 고유벡터를 계산하여 원래의 데이터를 주요 고유벡터의 선형결합으로 간략하여 나타내는 것이다. 이 과정은 다음과 같이 기호를 도입하여 설명될 수 있다.

원래  $p \times q$  차원의 개별 얼굴영상을 행 혹은 열을 순차적으로 연결하여 총 화소수가  $p \times q = n$ 인 요소를 갖는 벡터  $x_i$ 를 얻고, 훈련영상집합내의 얼굴영상의 개수를  $N$ 로 나타내면, 훈련영상 집합은  $n \times N$  크기의 데이터 행렬  $X = (x_1, x_2, \dots, x_i, \dots, x_N)$ 로 나타낼 수 있다. 여기서 각  $x_i$ 는  $n$ 차원의 얼굴벡터이다. 주성분분석은 원래 영상벡터를 선형 변환하여 투영된 공간의 감소된 차원의 특징벡터로 나타낸다고 할 수 있다[2-5]. 즉,

$$Y = W^T X \quad (1)$$

여기서 총 분산행렬  $S$ 와 모든 영상의 평균  $\mu$ 는 다음 식 (3)과 식 (4) 같이 정의되어진다.

$$S = \sum_{i=1}^N (x_i - \mu)(x_i - \mu)^T \quad (3)$$

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (4)$$

선형변환  $W^T$ 를 적용하면 변환된 특징벡터  $\{y_1, y_2, \dots, y_N\}$ 의 분산은  $W^T S W$ 가 된다. 주성분분석에서 투영  $W_{opt}$ 는 투영된 영상의 전체 산란(scatter)의 행렬식 (5)를 최대화시키도록 선택된다.

$$W_{opt} = \arg \max_w |W^T S W| \\ = [w_1 \ w_2 \ \dots \ w_m] \quad (5)$$

여기서  $\{w_i | i=1, 2, \dots, m\}$ 는  $S$ 의  $n$ -차원 벡터들 중에서  $m$ -개의 큰 고유치에 해당하는 고유벡터들이다. 다시 정리하자면  $n$  차원 공간의 입력벡터가  $m$  차원의 부분공간에 있는 특징벡터로 줄여지는 것이다.

### 2. 선형판별 분석법(Linear Discriminant Analysis: LDA)

선형판별 분석법은 입력영상을 클래스 공간으로 사상(mapping)하여 유clidean 거리 등에 기반하여 클래스 확인을 할 수 있도록 최적의 선형판별함수를 산출하는 기법이다. 선형판별분석법은 Fisher 판별방식으로도 알려져 있는데 클래스에 특정한 정보를 이용한다. 선형판별분석법의 목표는 얼굴벡터공간을 표현할 수 있는 효과적인 방법을 찾아내는 것이다. 클래스 정보를 활용하

면 인식작업에 도움이 될 수 있다. 두 개 혹은 그이상의 그룹들이 특정변수의 평균에 대해 많이 다르든지 아니든지 다른 통계치를 가지는 다른 클래스들을 정의함으로써 훈련 집합 내의 영상이 해당되는 클래스들로 나누어지게 된다.

$N$  개의 얼굴영상을 가진 훈련 집합이  $c$ 개의 다른 클래스로 이루어져 있다고 하자. 훈련영상 집합내의 얼굴영상들은 2차원의 놓도를 가지는 행렬이 되며 원래의  $n$  차원의 입력데이터가 앞 절의 PCA 과정을 거친 결과  $m$  차원의 벡터로 나타낼 수 있다. 이처럼  $m$  차원으로 줄여진 새로운 데이터  $y$ 에 대해 LDA는 변환행렬  $W$ 를 선택하여 클래스 간 산란과 클래스내의 산란의 비가 최대가 되도록 하는 것이다. 즉, 변환은 다음 식(6)으로 이루어진다.

$$z_i = W^T y_i \quad (6)$$

$S_w$  가 비 특이(non-singular)라고 가정하면  $W$  내의 기본벡터가  $S_w^{-1}S_B$  의 고유치의 크기 순서대로의  $m$ 개의 고유벡터로 이루어진다. 여기서  $S_B$ 를 훈련영상 집합의 클래스 간 산란 행렬이라고 하고  $S_w$ 를 클래스 내 산란 행렬이라고 아래와 같이 정의하자[3-5].

$$\mu_i = \frac{1}{N_i} \sum_{k=1}^{N_i} y_k \quad (7)$$

$$S_B = \sum_{i=1}^c N_i (\mu_i - \mu)(\mu_i - \mu)^T \quad (8)$$

$$S_w = \sum_{i=1}^c \sum_{y_k \in X_i} (y_k - \mu_i)(y_k - \mu_i)^T \quad (9)$$

여기서  $N_i$ 은 클래스  $X_i$ 에 속하는 훈련영상의 수이고,  $c$ 는 클래스의 수이며,  $\mu_i$ 는 클래스  $X_i$ 에 속하는 샘플의 평균벡터이며,  $y_k$ 은 클래스  $X_i$ 에 속하는 샘플을 나타낸다. 최적의 투영  $W_{opt}$ 는 식 (10)으로 나타낼 수 있다.

$$W_{opt} = \arg \max \frac{W^T S_B W}{W^T S_w W} \\ = [w_1 \ w_2 \dots \ w_m] \quad (10)$$

여기서  $\{w_i | i=1, 2, \dots, m\}$ 은 다음의 (11)에서 계산되는  $m$ 개의 큰 고유치에 해당하는 고유벡터의 집합을 나타낸다.

$$S_B w_i = \lambda_i S_w w_i, \quad i=1, 2, \dots, m. \quad (11)$$

여기서 주의할 것은 클래스의 수를  $c$ 라고 할 때  $m$ 의 상한선은  $c-1$ 이며 최대  $c-1$ 의 영이 아닌 고유치가 존재한다. 얼굴인식의 문제에 있어서 클래스 내 산란 행렬  $S_w$ 은 거의 항상 특이(singular)하다. 이것은  $S_w$ 의 계수(rank)가 커도  $N-c$ 이며, 일반적으로 훈련 영상 집합 내의 영상 수  $N$ 는 각 영상의 화소 수  $n$ 보다 훨씬 작은데서 연유한다. 이 문제를 해결하기 위해서는 PCA를 적용하여 원래의 영상집합을  $N-c$ 의 낮은 차원의 특징공간으로 투영하고 다음에 LDA를 적용하여  $c-1$ 의 차원으로 줄인다. 결과적으로  $S_w$ 가 비 특이 행렬이 되도록 한다[3][4][6]. 예를 들어서 ORL DB의 경우, 얼굴영상의 크기는 (112 X 92)가 되므로  $S_w$ 와  $S_B$ 의 행렬의 차원은 (10304 X 10304)가 된다.  $S_B$ 의 계수는  $rank(S_B) = \min(N, c-1)$  으로 결정된다. ORL DB의 경우  $c = 40$ 이므로  $rank(S_B) = 39$  가 된다.

### 3. 레이디얼 기저함수 신경망(Radial Basis Function Network : RBF Network)

RBF는 감시적 방식으로 학습되는 지역적 망이어서 전역적 망인 다층신경망과 대비된다. 지역적 망과 전역적 망의 차이는 학습에 활용되는 입력공간의 범위로 구별될 수 있다. RBF는 수용영역에 가까운 입력만이 활성화에 기여하는 지역적 사상을 수행한다.

RBF 신경망은 다층신경망과 비슷한 함수사상을 수행하나 그 구조와 기능은 다르다고 할 수 있으며 구조

는 아래의 [그림 1]에 나타난 바와 같이 입력층, 은닉층, 출력층으로 구성되어 있으며 각 층의 역할과 계산방식은 아래의 관계식들로 표현된다.

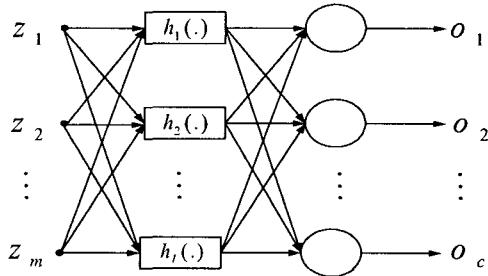


그림 1. 레이디얼 기저 함수 신경망의 구조.

망의 입력 층은  $m$ 개의 단위로 되어 있어  $m$  차원의 입력특징벡터의 요소들을 받아들인다. 입력벡터  $z_i$ 의  $l$ 개의 요소는  $l$ 개의 은닉 함수로 입력되며 은닉 함수의 출력은 가중치  $w_{ij}$ 가 곱해져서 망의 출력 층  $o_j$ 로 출력된다.

RBF 단위의 전형적인 활성함수는 평균벡터  $\mu_i$ 와 분산벡터  $\sigma_i$ 를 가지는 가우시안 함수를 이용한다[8-11]. 즉,

$$h_i(z) = \exp\left(-\frac{\|z - \mu_i\|^2}{2\sigma_i^2}\right), \quad i=1, 2, \dots, l \quad (12)$$

여기에서  $\|\cdot\|$ 는 입력공간에서의 유클리디안 크기를 나타내며,  $z$ 은  $m$  차원의 입력특징벡터,  $\mu_i$ 은  $m$  차원의 RBF 단위의 중심,  $\sigma_i$ 은  $i$ 번째 RBF 단위의 넓이,  $l$ 은 RBF 단위의 개수를 나타낸다. 입력  $z$ 에 대한  $j$ 번째 출력은 다음과 같이 주어진다.

$$o_j(z) = \sum_{i=1}^l w_{ij} h_i(z) \quad (13)$$

여기서  $w_{ij}$ 는  $i$ 번째 단위와  $j$ 번째 출력 노드를 연결하는 가중치이다. (12)와 (13)를 행렬로 표현할 수 있다.

$$o = Wh \quad (14)$$

이 가중치는 다음의 관계식들에서 구해진다.

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij} \quad (15)$$

$$\Delta w_{ij} = \alpha(t_j - o_j)h_i \quad (16)$$

여기서  $\alpha$ 는 학습속도를 나타내는 상수이며,  $t_j$ 는 목표출력이며,  $o_j$ 는 실제 출력을 나타낸다.

RBF 신경망 분류기를 설계하는데 있어서 입력 데이터  $o_i$ 의 개수는 특징벡터 요소의 개수와 같으며 LDA 처리에 의해 생성된다. 출력의 개수는 훈련영상 데이터 베이스내의 클래스 개수와 같다.

위의 내용을 알고리즘으로 정리하면 다음과 같다[12].

단계 1:  $w_{ij}(0)$ 을 매우 작은 수로 초기값을 정해주고 평균치  $\mu_i$ 와 표준편차  $\sigma_i$ 를 정의하고 식(12)의 함수를 정의한다.

단계 2: 입력 특징 벡터  $z$ 를 입력하고 식(12)과 식(13)을 이용하여  $h$ 와  $o$ 를 계산한다.

단계 3:  $\Delta w_{ij}$ 를 계산한다.

단계 4:  $w_{ij}(k+1)$ 을 계산한다.

단계 5:  $E = \frac{1}{2} \sum_{j=1}^c (t_j - o_j)^2$  를 계산한다.

단계 6: 단계 2-5를  $E \leq E_{\min}$  될 때까지 반복한다.

단계 7: 단계 2-6을 모든 훈련영상에 대해 반복한다.

다음 [그림 2]는 본 논문에서 제안한 전체알고리즘의 계산과정, 즉, PCA, LDA와 RBF 기법을 결합한 알고리즘의 계산순서를 보여준다[13]. [그림 2]를 따라 전체 알고리즘의 흐름을 살펴보면, 입력된 원래 영상은 히스토그램 과정을 거쳐 영상의 명암대조를 정규화 한 다음에  $n$  차원의 벡터  $x$ 를 PCA를 거쳐  $m$  ( $m \ll n$ ) 차원의 고유얼굴 벡터  $y$ 를 생성한다.

이 데이터를 LDA 처리를 통하여 클래스 내와 클래스 간의 산관행렬을 이용한 투영행렬로 변환된 투영 벡터  $z$ 를 산출하게 된다. 이 벡터  $z$ 는  $y$ 에 비해 동일 클래스에 대한 통계적 동질성이 비교적 강하여 명암의 변화

등에 비교적 우수한 분류를 보인다고 알려져 있다. 여기서 얻어진 가중치 벡터를 RBF 네트워크에 입력하여 최종 분류를 수행하게 된다.

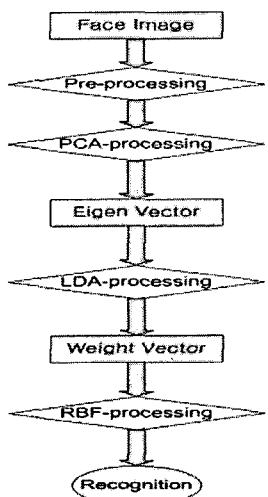


그림 2. PCA+LDA+RBF 처리순서도

## II. 실험 및 결과 비교

### 1. 환경과 데이터베이스

본 실험에서는 ORL 데이터베이스를 이용하였다. ORL DB는 40명에 대해 다양한 표정과 방향의 얼굴사진 10개씩, 총 400개의 흑백 얼굴사진으로 구성된 세계적으로 널리 사용되는 DB이다. 인식 알고리즘에 영상을 입력하기 전에 히스토그램을 적용하여 영상처리를 하였으며 총 400개의 영상 중 각 클래스의 5개의 영상은 훈련용으로 하고 다른 5개의 영상은 시험용으로 사용하였다. 각 얼굴사진의 원래의 크기는 92X112 화소인데 실험을 위하여 45X45 화소의 크기로 축소한 후에 전처리를 하였다. 모의실험을 위해 소프트웨어는 MATLAB 6.5 버전을 사용하였다.

### 2. PCA+LDA와 RBF를 결합한 인식방법

앞 II장 2절에서 기술한 바와 같이 LDA 만으로는 클래스내 분산행렬  $S_w$ 는 항상 특이현상이 발생하므로

PCA로 전처리를 하여 LDA를 적용하였다. 학습을 위해 40명의 각각에 5개씩 200개의 얼굴사진으로 PCA에 적용하여 특징벡터를 산출하여 식 (1)과 같이 변환된 데이터  $Y$ 를 얻어 LDA에 입력으로 하였다.

PCA + LDA와 PCA + LDA + RBF 알고리즘의 인식 성능을 시험하여 표1과 같은 결과를 얻었다. 우선 PCA+ LDA 알고리즘에서는 PCA와 LDA를 통하여 얻어진 데이터를 유clidean 거리 방식으로 분류를 수행하여 얼굴인식을 수행하였다. PCA를 적용하였을 때 식(5)에서 선택한 고유치의 수  $m$ 값에 따라 인식률의 차이가 발생하며 여기서는 기준치를 잡기 위하여 45를 사용하였으나 보다 더 적은  $m$ 을 사용할 수도 있으며, 오히려 명암의 차이와 얼굴방향의 변화 등에서 오는 영상의 데이터 변화로 인한 오류를 줄이기 위해서는 큰 차수의 고유치를 우선적으로 제거하여야 한다는 주장이 있으며 최적의  $m$ 을 선택하여 더 나은 결과를 얻은 보고도 있다[14].

PCA+LDA+RBF 알고리즘에서는 PCA+LDA를 통해 얻어진 데이터에 다시 RBF 분류기법을 더하여 얼굴인식을 수행하였다.

표 1. PCA+LDA와 PCA+LDA+RBF 의 인식률 비교

방법	PCA+LDA	PCA+LDA+RBF
오류인식	13	11
인식률 (Recog./Try)	92.35% (157/170)	93.53% (159/170)

RBF를 적용하기 위해 학습용 얼굴영상들의 중심점, 입력 영상의 중심점들을 찾아 식(12)에 적용하였다. 여기서 RBF를 결합하여 얻어진 인식율의 향상은 1.2%로 크게 향상되었다고 보기는 어렵다. 위 결과는 RBF를 도입함으로써 잡음이나 입력환경의 변화에 미미하지만 견실한 결과를 얻을 수 있다는 가능성을 보여 준다고 하겠다. 그러나 향상된 인식률이 부가된 계산시간에 비해 크게 향상되지 않았다고 판단될 여지도 있어서 이 부분에 대해서는 좀더 다양한 입력데이터를 가지고 충분히 시험되어야 할 것이다. 본 실험에서는 은닉층의 신경개수를 최대 200까지 하여 실험을 수행하였으나 최종 인식률을 높이기 위해서는 RBF를 적용하기 이전에

PCA와 LDA단계에서 좀더 최적의  $m$ 을 선택하고 RBF 신경망의 학습과정에서 은닉층의 신경개수를 최적화하는 시도가 좀 더 진행되어야 할 것이다.

#### IV. 결론

이 논문은 지금까지 개별적으로 얼굴인식을 위하여 이용되어 왔던 PCA, LDA 및 RBF 알고리즘들을 결합하여 성능을 시험하여 비교하였다. PCA를 전처리로 하여 차원을 낮춘 변환행렬을 산출하여 이를 LDA에 입력하였으며 이렇게 얻어진 데이터를 다시 RBF의 입력 데이터로 활용함으로써 차원을 낮추면서도 인식 성능을 높일 수 있는 방안을 제시하였다. 시험결과 인식율이 93.5%로 기준의 국제 논문지 등에 발표되고 있는 결과와 비슷한 성능의 결과를 얻었다. RBF 신경망을 도입하여 얻어진 결과를 더 향상시키기 위해서는 전처리와 신경망의 파라미터들을 최적화 하여 더 나은 성능을 얻는 방안을 찾아야 할 것으로 보이며 또한 실제 상황에서 카메라로 영상을 입력하여 실시간으로 인식성능을 시험하는 과정에서 예상되는 문제점들을 분석하는 과정이 남아있다.

#### 참고 문헌

- [1] [http://www.cse.msu.edu/%7Elvxiaogu/publications/ImAna4FacRcg\\_Lu.pdf](http://www.cse.msu.edu/%7Elvxiaogu/publications/ImAna4FacRcg_Lu.pdf).
- [2] W. Zhao, A. Krishnaswamy, and R. Chellappa, "Discriminant Analysis of Principle Components for Face Recognition," 3rd Intern. Conf. on Face & Gesture Recognition, Nara, Japan, pp.336-341, April, 1998.
- [3] A. M. Martinez and A. C. Kak, "PCA versus LDA," IEEE Trans. On pattern Analysis and Machine Intelligence, Vol.23, No.2, pp.228-233, 2001.
- [4] P. N. Belhumeur, J. P. Hespanha, and D. J. Kriegman, "Eigenfaces vs. Fishfaces: Recognition Using Class Specific Linear Projection," IEEE Trans. On Pattern Analysis and Machine Intelligence, Vol.19, No.7, pp.711-720, July, 1997.
- [5] G. L. Marcialis and F. Roli, "Fusion of appearance-based face recognition algorithms," Pattern Analysis & Applications, Vol.7, No.2, pp.151-163, Springer-Verlag London, 2004.
- [6] L. Juwei, K. N. Plataniotis, and A. N. Venetsanopoulos, "Face recognition using LDA-based algorithms," IEEE Transactions on Neural Networks, Vol.14, No.1, pp.195-200, 2003.
- [7] X. Lu, Y. Wang, and A. K. Jain, "Combining Classifier for Face Recognition," Proceedings of IEEE 2003 Intern. Conf. on Multimedia and Expo. Vol.3, pp.13-16, 2003.
- [8] V. Espinosa-Duro and M. Faundez-Zanuy, "Face Identification by Means of a Neural Net Classifier," Proceedings of IEEE 33rd Annual 1999 International Carnahan Conf. on Security Technology, pp.182-186, 1999.
- [9] M. J. Er, S. Wu, J. Lu, and H. L. Toh, "Face Recognition with Radial Basis Function(RBF) Neural Networks," IEEE Trans. On Neural Networks, Vol.13, No.3, pp.697-710, 2002.
- [10] J. Haddadnia, K. Faez, and M. Ahmadi, "N-feature Neural Network Human Face recognition," Proc. Of the 15th Intern. Conf. on Vision Interface, Vol.22, Issue.12, pp.1071-1082, 2004.
- [11] J. W. Hines, *Fuzzy and Neural Approaches in Engineering*, John Wiley & Sons, 1997.
- [12] A. D. Kulkarni, *Computer Vision and Fuzzy- Neural Systems*, Prentice-Hall, 2001.
- [13] 양근화, PCA와 신경망을 결합한 얼굴인식 알고리즘, *한국신경망학회*, 2004, pp.1-10.

리즘의 성능분석, 학위논문, 한남대학교, 2005.

- [14] R. Q. Feitosa, C. E. Thomaz, and A. Veiga,  
"Comparing the Performance of the  
Discriminant Analysis and RBF Neural  
Network for Face Recognition," Proc. Intern  
Conf. ISAS, Vol.6, 1999.

### 저자 소개

오 병 주(Byung-Joo Oh)

정회원



- 1976년 2월 : 부산대학교 전자공  
학과(공학사)
  - 1976년 3월 ~ 1981년 8월 : 국방과  
학연구소 연구원
  - 1983년 5월 : University of New  
Mexico, 전기 & 컴퓨터공학과  
(공학석사)
  - 1988년 5월 : University of New Mexico, 전기 & 컴퓨터공학과(공학박사)
  - 1988년 10월 ~ 1992년 2월 : 한국전자통신연구소 선임  
연구원
  - 1992년 3월 ~ 현재 : 한남대학교 전자공학과 교수
- <관심분야> : 얼굴인식, 신경망 및 퍼지제어, 로봇시  
각 및 제어, 패턴인식, 진화알고리즘