

논문 2004-41CI-3-4

고유 얼굴과 퍼지 신경망을 이용한 얼굴 인식 기법 (Face Recognition using Eigenfaces and Fuzzy Neural Networks)

김 재 협*, 문 영 식**

(Jae Hyup Kim and Young Shik Moon)

요 약

일반적으로 영상에서 얼굴 영상을 검출하고 인식하는 알고리즘은 패턴 인식 연구에 있어서 인간과 컴퓨터의 상호작용의 연구라는 면에서 아주 중요한 문제로 연구되어 왔다. 본 논문에서는 고유얼굴과 퍼지 신경망을 이용한 얼굴인식 기법을 제안한다. PCA(Principal Component Analysis) 방식은 우수한 인식 결과를 보장하는 얼굴인식 기법중의 하나이며, 얼굴 영상을 이용하여 공분산 행렬을 계산하고, 공분산 행렬을 통해 생성된 저차원의 벡터, 즉 고유얼굴(Eigenface)을 이용하여 가중치를 계산하고, 이 가중치를 기준으로 인식을 수행하는 기법이다. 이를 기반으로 하여, 본 논문에서는 전처리 과정, 고유얼굴 과정, 퍼지 소속도 함수 설계 과정, 신경망 학습 과정, 인식과정으로 구성된 5단계의 얼굴 인식 알고리즘을 제안한다. 먼저 각 얼굴 영상들은 전처리 과정을 거치며 이 영상들을 이용하여 고유얼굴을 추출한다. 추출된 고유얼굴을 이용한 가중치 135개에 대하여 비대칭 가우시안 함수를 응용한 퍼지 소속도 함수를 이용하여 퍼지 소속도가 부여되며 이 소속도들이 신경망의 입력으로 사용되어 학습과정을 거친다. 학습과정을 거친 후, 신경망의 출력은 현재의 얼굴 이미지가 데이터베이스의 얼굴 이미지와 유사한 정도를 나타내게 되어 인식을 수행한다. 제안하는 알고리즘으로 가중치의 개수와 퍼지 레벨의 개수에 대하여 기존의 얼굴 데이터 베이스를 이용하여 실험하였으며, 실험 결과 특정 조건하에서 약 95% 이상의 인식 성능을 확인할 수 있었다.

Abstract

Detection and recognition of human faces in images can be considered as an important aspect for applications that involve interaction between human and computer. In this paper, we propose a face recognition method using eigenfaces and fuzzy neural networks. The Principal Components Analysis (PCA) is one of the most successful techniques that have been used to recognize faces in images. In this technique the eigenvectors (eigenfaces) and eigenvalues of an image is extracted from a covariance matrix, which is constructed from image database. Face recognition is performed by projecting an unknown image into the subspace spanned by the eigenfaces and by comparing its position in the face space with the positions of known individuals. Based on this technique, we propose a new algorithm for face recognition consisting of 5 steps including preprocessing, eigenfaces generation, design of fuzzy membership function, training of neural network, and recognition. First, each face image in the face database is preprocessed and eigenfaces are created. Fuzzy membership degrees are assigned to 135 eigenface weights, and these membership degrees are then inputted to a neural network to be trained. After training, the output value of the neural network is interpreted as the degree of face closeness to each face in the training database.

Keywords : face recognition, eigenfaces, fuzzy, neural networks

I. 서 론

얼굴 영상을 인식하는 알고리즘은 컴퓨터 비전과 패턴

인식 연구에 있어서 인간과 컴퓨터의 상호작용의 연구라는 면에서 아주 중요한 문제로 연구되어 왔다. 그러나 같은 사람의 얼굴이라도 여러 가지 왜곡 요인에 의하여 서로 다른 시점에서 획득된 얼굴 영상의 정보가 크게 변하기 때문에 좀더 많은 연구가 필요하다. 예를 들어, 얼굴 표정, 포즈 또는 크기의 변화는 심한 기하학적인 왜곡을 일으키며, 설사 주어진 얼굴 영상들이 같

* 학생회원, ** 정회원, 한양대학교 컴퓨터공학과
(Dept. of Computer Science and Eng., Hanyang Univ.)
* 본 연구는 대학 IT연구센터 육성지원사업의 연구결과로 수행되었음.
접수일자: 2004년1월20일, 수정완료일: 2004년4월22일

은 기하학적 모양을 유지하는 경우라도 조명이 변하는 경우에는 얼굴 영상의 밝기 정보가 크게 왜곡 된다. 이외에도 배경의 변화나 안경착용, 화장, 노화, 얼굴 장식 품 등으로 인한 얼굴 영상의 왜곡이 얼굴을 분류하는데 많은 어려움을 주고 있다.

얼굴 인식 분야의 연구는 1990년대 이전에는 눈, 코, 입의 특징들에만 기초한 연구^[1,2]가 주로 진행되어왔으나, 컴퓨터의 계산기술 부족으로 인해 소수의 테스트만이 적용되었다. 그러나 1990년대 초부터 개인용 컴퓨터의 보급과 컴퓨터 영상 정보의 비약적인 증가 추세에 힘입어 컴퓨터 비전 분야의 핵심 연구 분야로 자리잡아 왔다.

그 동안 제안된 얼굴 인식 방식에는, 얼굴의 눈, 코, 입과 같은 특징점을 추출하여 기하학적인 형태를 비교하여 얼굴 인식을 수행하는 방식^[2], 얼굴영상의 많은 왜곡들을 포괄할 수 있는 얼굴 영상의 템플릿을 이용하여 템플릿의 단순비교를 통해 인식을 수행하는 방식^[2], Principal Component Analysis(PCA)를 이용한 방식^[3], Linear Discriminant Analysis(LDA)^[4,5]를 이용한 방식 등이 대표적이다. 그 외에도 NN(Neural Network)^[6], HMM(Hidden Markov Model)^[18] 등을 이용한 수많은 연구가 진행되어 제한적인 환경에서 비교적 우수한 인식 결과를 보이고 있다. 한편, ARL에서 주관한 FERET 테스트의 성능평가에 의하면 대용량의 얼굴 데이터베이스에서 PCA-LDA 방법, Elastic Bunch Graph Matching 방법 등이 우수한 연구 성과를 보이고 있다^[7].

특히 PCA를 이용한 방법은 얼굴 영상을 이용하여 생성된 저차원의 벡터, 고유얼굴(Eigenface)을 이용하여 가중치를 계산하고, 이 가중치를 기준으로 인식을 수행하는 방식으로 매우 큰 얼굴 영상의 데이터를 저차원의 벡터(고유얼굴)로 표현함으로써 데이터의 양과 계산량을 감소시킬 수 있으며, 또한 우수한 인식성능을 보장하는 방식이기 때문에 그동안 가중치의 개수, 즉 인식에 사용되는 고유얼굴의 개수나 인식의 대상이 되는 얼굴영상 데이터베이스의 구성, 가중치 값에 따른 패턴 분류방식들에 따라 많은 연구가 진행되고 있다.

그동안의 연구들은 주로 고유얼굴을 이용한 얼굴 인식 방식의 기본적인 틀은 유지하고 다른 조건을 이용하여 인식 성능을 높이는 방향이 주를 이루고 있다. 전체 영상에서 얼굴 영상의 부분만을 추출하여 일반화한 후 얼굴 인식에 활용하는 방식^[8], 얼굴 영상 데이터베이스를 구성할 때 하나의 얼굴에 대하여 여러 가지 조건을

이용하여 데이터를 구성하는 방식^[9], 또 얼굴 영상의 각 부분만을 이용하여 고유얼굴을 생성하여 인식하는 방식들이 제안되었으며, 각각의 방식에 따른 인식 성능에 대한 테스트도 매우 활발히 진행되어 왔다.

그러나 이러한 방식과 더불어 함께 연구되고 있는 방향이 고유얼굴을 이용하여 구해진 가중치 값에 따른 패턴 분류분야이다. 대표적으로 Support Vector Machine을 이용하는 방식^[10,17]이 있으며, 이 방식은 전처리를 거친 얼굴 영상들을 이용하여 고유얼굴을 추출하고, 그를 이용하여 계산된 가중치를 효과적으로 분류하기 위하여 Support Vector Machine을 이용하는 방식이다. 이러한 방향의 연구는 그동안 연구된 기초적인 얼굴 영상 구성에 관한 연구와 더불어 패턴 인식 방식을 함께 적용함으로써 보다 높은 인식 성능을 보여주고 있다.

본 논문에서는 고유얼굴과 퍼지 신경망을 이용한 얼굴 인식 기법을 제안하였다. 알고리즘은 크게 전처리 과정, 고유얼굴을 이용한 가중치 계산과정, 퍼지 소속도 추출 과정, 신경망 학습과정, 인식 수행과정으로 구성되어 있다. 먼저, 전체 인식 대상 얼굴영상 각각에 대하여 전처리를 통하여 135개의 영상으로 확장한 후 이를 대상으로 고유얼굴을 추출하여 최대 135개의 가중치를 계산한다. 이 계산된 가중치 벡터는 일반화를 거쳐 각 가중치마다 퍼지 소속도를 구한다. 이 소속도를 신경망에 입력하여 학습과정을 거치며, 인식과정에서 신경망의 출력은 주어진 가중치 벡터를 가지는 얼굴 영상이 어느 얼굴 영상에 얼마나 가까운지를 나타낸다.

II. 고유 얼굴과 퍼지 신경망을 이용한 얼굴 인식 기법

1. 전처리 과정

고유얼굴을 이용한 얼굴인식 알고리즘을 최초로 제안한 논문^[3]에서는 한 명마다 하나의 영상을 이용하여 고유얼굴을 생성하였으며, 이를 이용하여 인식을 수행하였다. 그러나 얼굴 영상은 많은 왜곡을 포함하고 있을 경우가 많기 때문에 최초의 데이터베이스를 생성할 당시에 왜곡을 어느 정도 포함할 수 있는 데이터베이스를 구성하는 것이 보다 인식 성능을 효과적으로 높일 수 있는 방법이다^[4,5,8,9]. 그러나, 데이터베이스 구성당시에 한 명마다 여러 가지의 왜곡 조건을 가지는 영상을 촬영한다는 것은 매우 번거로운 작업일 뿐만 아니라, 현실적으로 실현이 힘든 단점이 있다. 그래서, 데이터베

이스를 구성할 당시에는 가급적 여러 가지의 왜곡조건을 이용하여 촬영을 한 후, 영상처리 기술을 이용하여 보다 많은 범위의 왜곡 조건을 설정함으로써 이러한 단점을 보완하는 방식이 흔히 이용되고 있다^[6]. 본 논문에서도 이와 같은 방식을 기본 축으로 하여 얼굴 영상마다 클래스를 구성하여 최대한 왜곡을 포함하면서 데이터베이스 구성의 어려움을 최소화하고자 하였다. 클래스를 구성하는 방식은 하나의 얼굴 영상에 대하여 회전, 밝기, 크기에 따라 왜곡 영상을 만들어 내어 총 135개의 영상을 하나의 클래스로 구성하는 방식이다.

회전은 $-10^\circ, -5^\circ, 0^\circ, +5^\circ, +10^\circ$ 의 조건을 할당하였으며, 영상 각각의 위치에 따른 픽셀값을 회전하는 위치로 이동하는 방식을 사용하였다. 밝기는 전체 영상을 360. 로 보았을 때, 밝기 효과가 없는 조건, $0^\circ, 45^\circ, 90^\circ, 135^\circ, 180^\circ, 225^\circ, 270^\circ, 315^\circ$. 방향에서부터 점차 빛의 밝기가 변화하는 조건을 주었으며, 그레이스케일 영상에서 밝기값의 비율을 조절하는 방법을 사용하였다. 크기는 90%, 100%, 110%의 범위에서 각각 조건을 할당하였다.

2. 고유얼굴과 가중치 계산

본 논문에서는 각각의 클래스 별로 별도의 고유얼굴과 가중치를 계산하여 각 클래스 마다의 퍼지 소속도 함수를 작성하여 최종 신경망 학습에 이용한다. 하나의 클래스에 있는 135개의 얼굴 영상을 대상으로 고유얼굴을 추출하여 가중치를 계산하는 방식은 다음과 같다. 먼저 목적 영상들의 평균영상을 구한다.

$$\Psi_j = \frac{1}{M_j} \sum_{n=1}^{M_j} \Gamma_n^j \quad (1)$$

식 (1)은 평균영상을 구하는 식이다. j 는 각각의 얼굴의 클래스를 의미하며, Ψ 는 평균영상, Γ_n 는 클래스 내의 얼굴 영상, M 은 각 얼굴 영상의 클래스 안에 있는 전처리된 영상들의 개수, 즉 135개의 이미지를 의미한




그림 1. 평균 영상
Fig. 1. Average faces.

다. 그림 1에서는 계산된 평균영상을 보여주고 있다. 구해진 평균영상을 이용하여 다음과 같이 공분산 행렬 C 를 구성한다.

$$\Phi_i^j = \Gamma_i^j - \Psi^j \quad (2)$$

$$C^j = \frac{1}{M^j} \sum_{n=1}^{M^j} \Phi_n^j \Phi_n^{jT} = A^j A^{jT} \quad (3)$$

식 (2)는 얼굴 영상들과 평균 영상과의 차이 영상을 구하는 식이며 이를 이용하여 식 (3)과 같이 공분산 행렬을 구성한다. 생성된 공분산 행렬을 대상으로 고유치와 그에 대응하는 고유벡터를 계산한다. 그림 2는 구해진 고유벡터중 고유치가 큰 상위 50개의 고유벡터를 고유얼굴의 예로써 보여주고 있다.

고유벡터를 생성하는 방식은 jacobi 방식^[11]을 이용한다. 그런데 실제로 jacobi 방식을 이용하는데 있어 이미 그대로 이용하여 구성한 공분산 행렬을 그대로 이용한다는 것은 무리가 따른다. 이 경우 공분산 행렬의 차원만큼의 고유벡터를 얻을 수 있는데, 일반적으로 얼굴 인식등의 활용에 있어 고유값이 큰 상위의 벡터들만을 이용하기 때문에 선형 대수적 해법을 사용하여 고유값이 큰 상위의 벡터들만을 추출하였다. 본 논문에서 사용한 선형 대수적 해법은 아래와 같다^[9].

고유 벡터 λ_k 를 고유치, u_k 를 고유벡터 라고 했을 때 식 (4)를 얻을 수 있다.

$$C u_k = \lambda_k u_k \quad k=1, 2, \dots, M \quad (4)$$

그리고 식 (4)와 식 (3)을 이용하여 다음과 같이 유도할 수 있다.




그림 2. 고유 얼굴
Fig. 2. Eigenfaces.

$$AA^T u_k = \lambda_k u_k$$

$$A^T A(A^T u_k) = \lambda_k (A^T u_k) \tag{5}$$

즉, 식 (5)는 식 (6)을 이용하여 식 (7)과 같은 형태로 나타낼 수 있다.

$$Y_k = A^T u_k \tag{6}$$

$$A^T A Y_k = \lambda_k Y_k \tag{7}$$

여기서, 행렬 $A^T A$ 의 고유 벡터를 X_k 라 하고 식 (8)과같이 정의하면 식 (9)를 얻을 수 있다.

$$X_k = \alpha_k Y_k \tag{8}$$

$$X_k^T X_k = (\alpha_k A^T u_k)^T (\alpha_n A^T u_n) = \alpha_k \alpha_n \lambda_n u_k^T u_n \tag{9}$$

식 (9)에서 k와 n이 같을 경우 식 (9)는 식 (10)과 같이 나타낼 수 있다.

$$\lambda_k \alpha_k^2 = 1, \quad \alpha_k = \frac{1}{\sqrt{\lambda_k}} \tag{10}$$

따라서, 우리는 고유 벡터 u_k 를 다음과 같이 유도할 수 있다.

$$A Y_k = A A^T u_k, \quad A Y_k = \lambda_k u_k \tag{11}$$

$$u_k = \frac{(A Y_k)}{\lambda_k} = \frac{(A Y_k)}{(\lambda_k \alpha_k)} = \frac{(A Y_k)}{\sqrt{\lambda_k}} = \frac{\sum_{i=1}^M \Phi_i X_{ki}}{\sqrt{\lambda_k M}} \tag{12}$$

계산된 고유 벡터를 사용하여 식 (13)과 같이 클래스의 얼굴 영상들과의 곱을 통하여 각각의 얼굴 이미지에 대한 가중치를 계산한다.

$$\omega_{ik}^j = u_k^{jT} (\Gamma_i^j - \Psi^j) \tag{13}$$

u_k 는 고유벡터를 의미하며, ω_k 는 가중치를 의미한다. j는 각각의 클래스를 나타내며, i는 클래스 내의 이미지, k는 한 클래스 내에서 계산된 고유벡터의 개수를 의미한다. 이때 계산된 가중치를 이용하여 인식을 수행한다. 본 논문에서는 각 얼굴 영상의 클래스마다 고유

얼굴과 가중치를 계산하며, 이를 이용하여 퍼지 소속도 함수를 설계하여 퍼지 소속도를 계산하는데 이용된다.

3. 퍼지 소속도 함수의 설계

생성된 가중치 그래프로부터 퍼지 소속도 함수를 만든다. 소속도 함수란 퍼지 이론에서 어떤 연속 또는 이산적인 값의 소속도를 나타내는 함수로써, 값의 분포나 모양에 따라 여러 가지 형태가 있다. 가장 많이 쓰이고 간단한 소속도 함수의 형태는 삼각형 소속도 함수 (Triangular Fuzzy Number ; T.F.N.), 사다리꼴 소속도 함수 (Trapezoidal Fuzzy Number ; Tr. F. N.), 지수형 소속도 함수, L-R 퍼지 소속도 함수의 형태들이 있다. 그러나 일반적인 이러한 형태들의 소속도 함수는 가중치 그래프와 같이 여러 개의 피크를 가지는 형태의 그래프를 이용하여 퍼지 소속도 함수를 만들어 나가는데 상당한 어려움이 있다. 그래서, 본 논문에서는 고유치 크기와 그에 따른 벡터에 의한 가중치의 위치에 기반한 가우시안 함수의 퍼지 소속도 함수를 구한다. 이 방법은 히스토그램기반의 소속도 함수를 구하는 과정^[12,13]과 동일하다. 각 위치에 대한 가중치 값을 기반으로 해서 구한 퍼지 소속도 함수는 어떤 한 가중치 벡터에서 해당 위치의 가중치 값이 얼마나 해당 얼굴의 클래스의 가중치 값에 가까운지를 소속도로 나타내게 된다.

일반화 된 가중치 기반의 퍼지 소속도 함수를 구성하기 위해 먼저, 가중치 벡터로부터 주어지는 일반화된 가중치 값의 분포를 확률 분포 함수로 간주한다^[12,13]. 그림 3는 가중치 값중 상위 50개의 분포를 예로 보여주고 있다.

주어지는 135개의 가중치 값의 범위가 [0, 1]에 오도록 일반화 한 후에 각각의 가중치 값들을 Q레벨의 가




그림 3. 고유얼굴의 가중치 그래프
Fig. 3. Eigenfaces weight graph.

우시안 퍼지집합들로 나타낸다. Q의 크기에 따라 소속도 함수의 정확성과 적합성 등이 결정되며, 본 논문에서는 Q의 크기에 따른 인식 결과를 실험을 통해 설정하였다.

여기서 u번째 가중치 벡터를 $x_u^j = (x_{1u}^j, \dots, x_{ku}^j)$ 로 나타낼 때, k번째 가중치의 영역에서 정의되는 클래스에 대한 소속도함수 u_k^j 는 식 (14)와 같다.

$$u_k^j(i) = \frac{1}{M^j} \sum_{u=1}^{M^j} f_{ki}^j(x_{ku}^j) \quad (14)$$

$f_{ki}^j()$ 는 특정 클래스에 대해서 x_k 의 영역에 정의된 i번째 소속도 함수이고, N^j 은 클래스의 샘플의 개수이다. 식 (14)는 Q개의 퍼지 레벨에서의 가중치의 소속도를 준다^[12,13]. 퍼지 소속도 함수 $u_k^j(x_k)$ 가 여러 개의 최고점을 가지는 형태라면, 퍼지 소속도 함수는 여러 개의 가우시안 함수의 합으로 모델링 될 수 있다. 그리고, 가우시안 함수를 소속도 함수로 더욱 유용성 있게 모델링하기 위해서 비대칭 가우시안 함수로 나타낼 수 있다. 소속도 함수 $u_k^j(x_k)$ 가 다중 최고점을 가지고 있다면 소속도 함수는 식 (15)와 같이 비대칭 가우시안 함수의 합으로 모델링할 수 있다^[12,13].

$$u_k^j(x_k) \approx F_k^j(x_k) = \sum_{i=1}^{L_k^j} a_{ki}^j F_{ki}^j(x_k)$$

$$F_{ki}^j(x_k) = \begin{cases} G(x_k, c_{ki}^j, \sigma_{1ki}^j) & x_k < c_{ki}^j \\ G(x_k, c_{ki}^j, \sigma_{2ki}^j) & x_k \geq c_{ki}^j \end{cases} \quad (15)$$

여기서 $F_{ki}^j(x_k)$ 함수는 클래스 j의 가중치 값의 파라미터 $p_{ki}^j = (a_{ki}^j, c_{ki}^j, \sigma_{1ki}^j, \sigma_{2ki}^j)$ 에 해당하는 비대칭 가우시안 함수가 된다. $a_{ki}^j, c_{ki}^j, \sigma_{1ki}^j, \sigma_{2ki}^j$ 는 각각 가우시안 함수의 높이, 평균값, 좌우 표준편차를 의미한다. 정확한 파라미터를 생성하기 위하여 가중치 그래프의 소속도 함수를 앞에서 생성한 가중치 그래프로부터 학습시킨다. 학습이 끝난 후에는 가중치 그래프의 소속도 함수의 가우시안 파라미터를 얻게 된다. 가중치 그래프의 소속도 함수를 비대칭 가우시안 함수의 합으로 그래프로부터 학습시킬 때, 식 (16)과 같은 목적함수를 최소화시킬 수 있다^[12,13].

$$J_k^j(p_k^j) = \frac{1}{2} \left(\sum_{i=1}^{L_k^j} h_k^j(x_k, p_{ki}^j) - u_k^j(x_k) \right)^2 \quad (16)$$

$h_k^j(x_k, p_{ki}^j)$ 는 클래스 j의 가중치 x_k 에 대한 소속도 함수 $u_k^j(x_k)$ 를 모델링 하기 위해서 선택한 파라미터 함수이다. 그리고 파라미터 벡터를 학습, 갱신시켜 최종적인 값을 구하기 위해서 식 (17)의 gradient-descent 방법을 사용한다.

$$p_{ki}^{j(new)} = p_{ki}^{j(old)} - \rho \frac{\partial J_k^j}{\partial p_{ki}^j} \quad (17)$$

실험에서는 퍼지 소속도 함수로 사용되는 가우시안 함수의 높이는 1.0, 평균값은 일반화된 가중치 값의 최고값, 표준편차는 0.1을 초기값으로 하였다. 학습상수 σ 는 0.01로 초기치를 정하였다.

위의 방법으로 생성한 가중치 그래프의 비대칭 가우시안 퍼지 소속도 함수에서 고려할 것은 그래프 안에서 위치에 따른 가중치로 구한 퍼지 소속도 함수이다. 즉, 위치에 대한 가중치의 퍼지 소속도 함수이다. 그러므로, 주어지는 가중치에서 한 위치의 가중치가 가중치 그래프에 얼마나 가까운지 소속도로 나타내기 위해서 식 (18)과 같이 가중치 그래프의 퍼지 소속도를 모델링한다^[12,13].

$$Face(i) = 1.0 - |Weight(i) - Membership(i)| \quad (18)$$

i : 그래프의 위치

$Weight(i)$: 위치 i에서의 일반화된 가중치 값

$Membership(i)$: 위치 i의 퍼지 소속도

4. 신경망 학습 및 인식

그동안 많은 연구를 통하여 퍼지 시스템과 신경망의 결합은 각 이론의 장점을 결합하고 단점에 대해 상호보완적인 시스템을 만들려는 방향과 연산의 유사성에 기반하여 새로운 계산 모델을 구축하려는 방향으로 진행되어 왔다. 퍼지 시스템의 성능 향상을 위해 신경망의 구조와 학습방법을 퍼지 시스템에 사용하는 방식, 신경망의 구성이나 학습을 위해 퍼지 논리를 사용하는 방식, 신경망과 퍼지 이론을 적합한 부분에 사용함으로써 문

제를 상호 협조하에 해결하는 방식, 신경망 자체가 퍼지 정보를 처리할 수 있도록 하기 위해 뉴런과 시냅스에서 연산을 확장하는 방식 등이 있으며, 본 논문에서는 첫 번째 방식인 퍼지 시스템의 성능 향상을 위해 신경망을 사용하는 방식을 채택하였다.

본 논문에서 제안한 알고리즘에서 사용된 신경망의 구조는 3-layer network이고, 각 레이어의 뉴런의 개수는 각각 135개, 12개, 1개이다. 신경망의 학습 방법으로는 오류 역전파 학습 방법^[14]을 채택하였다. 실제로 가장 널리 사용되는 오류 역전파 학습방법은 델타 학습방법의 일종이다. 델타 학습방법의 기본은 현재 주어진 연결 강도로 생성되는 오차값을 구하여 이를 감소시키는 방향으로 연결 강도의 값을 조정하는 것으로 이때 오차값의 계산을 위해 각 노드의 올바른 출력값을 제공해 주어야 한다. 이러한 문제를 해결하기 위해 오류 역전파 방식은 만일 어떤 뉴런의 활성이 다른 뉴런의 잘못된 출력에 영향을 미친다면 두 뉴런간의 연결 가중치를 그것에 비례하게 조절해 주는 방법을 기본으로 하고 있다.

135개의 소속도 값을 이용하여 입력 레이어의 입력으로 주어지게 되며 히든 레이어를 통하여 최종 레이어에 결과가 나오게 된다. 먼저 현재 얼굴의 클래스 안의 135개의 영상을 이용하여 오류 역전파 학습을 실행하며, 현재의 클래스 외에 다른 클래스의 이미지들은 반대 집합으로 학습을 시킴으로써 현재 얼굴 클래스의 영상들뿐만 아니라 다른 클래스의 영상들도 함께 학습하여 클래스간 구별이 명확한 결과로 나오도록 학습하였다. 이때, 현재의 얼굴 영상 클래스로 결과가 나온 다른 얼굴 영상을 이용하여 다시 학습시킨다.

인식하고자 하는 테스트 영상은 이전에 생성된 135개의 목적 클래스 각각에 대한 퍼지 소속도 함수를 이용하여, 각각 135개 위치에 대한 소속도를 계산할 수 있으며, 이를 각 얼굴 클래스에 할당된 신경망의 입력으로 주면, 최종적으로 현재 목적 클래스에 얼마나 가까운지를 계산할 수 있다. 최종 레이어의 결과는 테스트 얼굴 영상이 해당 얼굴 클래스에 가까운 정도를 나타내며, 최종적으로 135개의 얼굴 클래스 각각에 대한 가까운 정도가 결과로써 나오게 되며, 이 값을 기준하여 가장 가까운 얼굴 클래스, 즉 얼굴 영상으로 인식을 수행하게 된다. 일반적으로 고유얼굴 기법에서 가중치의 개수는 80~100개 정도에서 가장 좋은 인식 결과를 얻는다고 실험적으로 제시되어 있다^[45,7]. 그러나, 입력 레이어의 뉴

런의 개수, 즉 가중치의 개수를 몇 개로 두느냐에 따른 많은 성능 변화가 예상되므로, 실험에서 가중치의 개수에 따른 성능 변화를 나타내었다.

III. 실험 결과

본 논문에서는 고유얼굴과 퍼지 신경망을 이용한 얼굴인식 알고리즘을 제안하였으며, 앞서 본문에서 언급한 바와 같이 얼굴 영상들을 전처리를 거친 후 고유얼굴을 추출하고, 가중치를 계산하여 퍼지 소속도를 계산하였으며, 계산된 결과를 신경망을 이용하여 학습시킴으로써 우수한 인식 성능을 얻고자 하였다. 얼굴 인식 알고리즘에 있어 성능을 실험하는 방식은 매우 중요한 부분중의 하나이다. 여러 가지 조건과 데이터베이스, 알고리즘 상의 파라미터등에 따라 인식 성능의 차이가 많기 때문에 이러한 부분들에 대한 실험을 통해 명확한 성능 평가가 이루어져야 한다^[7]. 본 논문에서는 가중치의 개수, 데이터베이스의 종류, 퍼지 소속도 함수를 구성하는 퍼지 레벨의 개수에 따른 실험을 통하여 알고리즘의 인식 성능을 최적화 및 평가하였으며, AR 얼굴 데이터베이스^[15]와 Yale 얼굴 데이터베이스^[4]를 통해 얻어진 4926개의 얼굴 이미지에 대하여 다른 알고리즘들과 성능을 비교하였다. 실험에 사용된 시스템은 Pentium 4 2.0 GHz 컴퓨터이다.

1. 가중치 개수에 따른 성능 평가

제안하는 알고리즘의 성능을 평가하기 위하여 가중치의 개수를 달리 하여 실험해 보았다. 데이터베이스는 AR 데이터베이스^[15]와 Yale 데이터베이스^[4]를 사용하였으며, 그림 4는 두 데이터베이스의 얼굴 영상에 대한 가중치 개수에 따른 인식 결과를 보여주고 있다. 각각의 가중치 개수에 따른 인식률은 여러 가지 다른 조건들에 따른 인식률 중에서 가장 높은 수치를 해당 가중치 개수에 따른 인식률로 결정 하였다.

2. 퍼지 레벨에 따른 성능 평가

그림 5에서는 퍼지 소속도 함수를 구성하는 퍼지 레벨의 개수에 따른 제안하는 알고리즘의 인식 성능을 보여주고 있다. 퍼지 레벨의 크기에 따라 계산되는 퍼지 소속도 함수의 정도가 다르기 때문에 실제 알고리즘의 인식 성능도 또한 많은 변화가 있었다. 물론, 그림 5에서 보여지는 인식률은 다른 조건에 따른 인식률중에서




그림 4. 가중치 개수에 따른 인식 성능
 Fig. 4. Recognition rate as a function of the number of eigenfaces.




그림 5. 퍼지 레벨 개수에 따른 인식 성능
 Fig. 5. Recognition rate as a function of the number of fuzzy level.

가장 높은 수치를 해당 레벨 개수에 대한 인식률로 결정 한 것이다.

그림 4와 5는 제안하는 알고리즘에 대하여 두 개의 데이터 베이스를 이용하여 퍼지 레벨의 개수, 가중치의 개수 각각의 변화에 따른 인식 성능을 보여주고 있다. 이 두가지 요소를 알고리즘의 성능 변화에 가장 큰 결정 요소로 간주하였으며, 그림 6과 그림 7에서는 두 가지 요소에 대한 인식 성능 변화를 함께 보여주고 있으며, 그림 6은 AR 데이터베이스에 대한 성능 변화를 나타내며, 그림 7을 YALE 데이터베이스에 대한 성능 변화를 나타내고 있다.




그림 6. AR 데이터베이스 이미지에 대한 인식률과 가중치와 퍼지 레벨의 관계
 Fig. 6. Recognition rate as a function of the number of fuzzy level and eigenfaces in the AR database.




그림 7. YALE 데이터베이스 이미지에 대한 인식률과 가중치와 퍼지 레벨의 관계
 Fig. 7. Recognition rate as a function of the number of fuzzy level and eigenfaces in the YALE database.

2. 고유 얼굴을 이용한 다수의 알고리즘에 대한 성능 평가

제안하는 알고리즘 이외에도 고유 얼굴을 이용한 여러 가지 알고리즘들이 제안되어 왔다. 이 알고리즘들중 대표적인 5가지의 알고리즘을 AR, YALE 데이터 베이스를 이용하여 실험하여 제안하는 알고리즘의 성능을 평가 하였다. 그림 8, 그림 9는 고유 얼굴을 이용한 여러 가지 다른 알고리즘들과의 비교 실험 결과를 보여주고 있다.

NMC는 가장 기초적인 패턴인식 기법인 NMC(Near




그림 8. 가중치 개수에 따른 인식 성능 (AR데이터베이스)

Fig. 8. Recognition rate as a function of the number of eigenfaces in the AR database.




그림 9. 가중치 개수에 따른 인식 성능 (Yale데이터베이스)

Fig. 9. Recognition rate as a function of the number of eigenfaces in the YALE database.

-est Mean Classifier)를 이용하여 고유얼굴의 가중치를 분류함으로써 인식을 수행하는 기법^[3]이며, Eigeneye^[8]를 이용한 기법은 얼굴 영상의 눈 부분을 추출하여 고유벡터를 취하는 방식으로, 얼굴 영상의 다른 부분에 비해 눈 부분이 더욱 인식에 큰 역할을 한다는 아이디어를 기본으로 한다. Local PCA^[16] 방식은 얼굴 영상의 컬러값을 이용하여 얼굴 부분만을 추출한 후 Eigenface를 이용하는 방식이다. SVM을 이용한 방식은 패턴 분류의 한 방식인 SVM을 이용하여 PCA (Principal Component Analysis), ICA(Independent Component Analysis)를 이용한 얼굴 인식 방식^[17]이다. 실험결과

약 50개 이상의 개수일 때부터 평균적으로 95% 이상의 인식 성능을 보이는 것을 확인할 수 있었다. 본 논문에서와 같이 135개의 가중치를 이용하여 인식 성능을 평가했을 경우 데이터 베이스, 가중치의 개수에 따른 변화가 매우 다양함을 알 수 있었으나 가장 우수한 인식률인 5개의 값의 평균을 통해 약 96%의 인식률이 나왔으며, 고유얼굴을 이용한 다른 기법들에 비해 우수한 인식률을 보이는 것을 볼 수 있다.

IV. 결론 및 향후 과제

본 논문에서는 고유얼굴과 퍼지 신경망을 이용한 얼굴 인식 알고리즘을 제안하였다. 전처리와 고유얼굴, 퍼지 소속도 계산, 신경망 학습 및 인식의 단계로 얼굴 인식 알고리즘을 설명하였으며, 실험을 통하여 기존의 알고리즘과 비교하여 손색이 없는 인식 성능을 얻을 수 있음을 볼 수 있었다. 그러나, 퍼지 소속도 계산이나 신경망에 필요한 파라미터가 너무 많아 보다 많은 데이터 베이스를 이용한 실험을 통해 많은 검증할 필요성이 있다. 이를 위해 더욱 많은 데이터베이스를 통한 실험과 기존의 연구에 대한 비교검증이 필요하다. 또한 신경망의 구조와 초기 전처리 과정을 통한 데이터베이스 구성에 관한 연구가 좀더 이루어져 보다 많은 왜곡에 충분히 대처할 수 있도록 보정해 나가야 한다.

참고 문헌

- [1] Y. Kaya and K. Kobayashi, "A Basic Study on Human Face Recognition," in *Frontiers of Pattern Recognition*, 1972, p. 265.
- [2] R. Brunelli and T. Poggio, "Face Recognition: Feature versus Templates," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 15, no. 10, October 1993.
- [3] M. Turk and A. Pentland, "Eigenfaces for Recognition," *J. Cognitive Neuroscience*, vol. 3, no. 1, pp. 71-86, 1991.
- [4] P.N. Belhumeur, J.P. Hespanha, and K.J. Kriegman, "Eigenfaces vs. Fisherfaces: Recognition Using Class Specific Linear Projection," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 19, no. 7, pp. 711-720, 1997.

- [5] A.M. Martinez and A.C. Kak, "PCA versus LDA," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 23, no. 2, Feb. 2001.
- [6] S. Lawrence, C.L. Giles, A.C. Tsoi, A.D. Back, "Face Recognition: A Conventional Neural Network Approach," *IEEE Trans. on Neural Networks, Special Issue on Neural Networks and Pattern Recognition*, vol. 8, no. 1, pp. 98-113, 1997.
- [7] P.J. Phillips, H. Moon, S.A. Rizvi, and P.J. Rauss, "The FERET Evaluation Methodology for Face-Recognition Algorithms," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 22, no. 10, Oct. 2000.
- [8] T.E. Campos, R.S. Feris, and R.M.C. Junior, "Eigenfaces versus EigenEyes: First Steps Toward Performance Assessment of Representation for Face Recognition," *Lecture Notes in Artificial Intelligence*, vol. 1793, pp. 197-206, April 2000.
- [9] A. Pentland, T. Starner, N. Etcoff, N. Masoiu, O. Oliyide, and M. Turk, "Experiments with Eigenfaces," *Proc. Looking at People Workshop Int'l Joint Conf. Artificial Intelligence*, Aug. 1993.
- [10] P.J. Phillips, "Support Vector Machines Applied to Face Recognition," *Advances in Neural Information Processing Systems 11*, eds. M.J. Kearns, S.A. Solla and D.A. Cohn, MIT Press, 1999.
- [11] W.H. Press, S.A. Teukolsky, W.T. Vetterling, B.P. Flannery, "Numerical Recipes in C," Cambridge University Press.
- [12] F.C.-H. Rhee, "Fuzzy Rule Generation and Inference Methods for Pattern Recognition and Computer Vision," Ph.D. thesis, University of Missouri, May 1993.
- [13] 이창수, 이정훈, "영상영역 기반 퍼지 신경망을 이용한 얼굴 검출," *퍼지 및 지능시스템학회 논문지*, vol. 1, no. 1, pp. 39-44, 2001.
- [14] 임영도, 이상부, "퍼지, 신경망, 유전진화," *인솔미디어*, 2002.
- [15] A.M. Martinez and R. Benavente. The AR face Database. <http://rvll.ecn.purdue.edu/v1/ARdatabas>
e/ARdatabase
- [16] A.M. Martinez, "Recognition of Partially Occluded and/or Imprecisely Localized Faces Using a Probabilistic Approach," *Proc. Computer Vision and Pattern Recognition*, vol. 1, pp. 712-717, June 2000.
- [17] O. Deniz, M. Castrillon, and M. Hernandez, "Face Recognition Using Independent Component Analysis and Support Vector Machines," *AVBPA*, pp. 59-64, 2001.
- [18] L. Wiskott, J. Fellous, N. Kruger, and C. Malsburg, "Face Recognition by Elastic Bunch Graph Matching," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 19, no. 7, pp. 775-779, July 1997.
- [19] A.V. Nefian and M.H., "Hayes. Face Detection and Recognition using Hidden Markov Models," *Int. Conf. on Image Processing*, vol. 1, pages 141-145, October 1998.

저 자 소 개

김 재 협(학생회원)

2001년 한양대학교 전자계산학과
졸업(공학사).

2003년 한양대학교 컴퓨터공학과
졸업(석사).

2003년~현재 한양대학교 컴퓨터
공학과 박사과정.

<주관심분야: 영상처리, 컴퓨터 비전, 패턴인식
등>

문 영 식(정회원)

1980년 서울대학교 공과대학
전자공학과 졸업(학사).

1982년 한국과학기술원 전기 및
전자공학과 졸업(석사).

1990년 University of California
at Irvine Dept. of Electrical
and Computer Engr. (박사).

1982년~1985년 한국전자통신연구소 연구원

1989년~1990년 Inno Vision Medical 선임연구원

1990년~1992년 생산기술연구원 선임연구원

1992년~현재 한양대학교 전자계산학과 부교수

<주관심분야: 영상처리, 컴퓨터비전, 패턴인식 등>