

# PCA와 LDA를 결합한 데이터 전 처리와 다항식 기반 RBFNNs을 이용한 얼굴 인식 알고리즘 설계

## Design of Face Recognition algorithm Using PCA&LDA combined for Data Pre-Processing and Polynomial-based RBF Neural Networks

오 성 권<sup>†</sup> · 유 성 훈<sup>\*</sup>  
(Sung-Kwun Oh · Sung-Hoon Yoo)

**Abstract** - In this study, the Polynomial-based Radial Basis Function Neural Networks is proposed as an one of the recognition part of overall face recognition system that consists of two parts such as the preprocessing part and recognition part. The design methodology and procedure of the proposed pRBFNNs are presented to obtain the solution to high-dimensional pattern recognition problems. In data preprocessing part, Principal Component Analysis(PCA) which is generally used in face recognition, which is useful to express some classes using reduction, since it is effective to maintain the rate of recognition and to reduce the amount of data at the same time. However, because of there of the whole face image, it can not guarantee the detection rate about the change of viewpoint and whole image. Thus, to compensate for the defects, Linear Discriminant Analysis(LDA) is used to enhance the separation of different classes. In this paper, we combine the PCA&LDA algorithm and design the optimized pRBFNNs for recognition module. The proposed pRBFNNs architecture consists of three functional modules such as the condition part, the conclusion part, and the inference part as fuzzy rules formed in 'If-then' format. In the condition part of fuzzy rules, input space is partitioned with Fuzzy C-Means clustering. In the conclusion part of rules, the connection weight of pRBFNNs is represented as two kinds of polynomials such as constant, and linear. The coefficients of connection weight identified with back-propagation using gradient descent method. The output of the pRBFNNs model is obtained by fuzzy inference method in the inference part of fuzzy rules. The essential design parameters (including learning rate, momentum coefficient and fuzzification coefficient) of the networks are optimized by means of Differential Evolution. The proposed pRBFNNs are applied to face image(ex Yale, AT&T) datasets and then demonstrated from the viewpoint of the output performance and recognition rate.

**Key Words** : pRBFNNs(Polynomial based Radial Basis Function Neural Networks), PCA(Principal Component Analysis), LDA(Linear Discriminant Analysis), FCM(Fuzzy C-means Method), DE(Differential Evolution)

### 1. 서 론

패턴 인식(Pattern Recognition)은 인지과학(Cognitive Science)과 인공지능(Artificial Intelligence) 분야에 속하는 문제 중 하나이다[1]. 패턴 인식을 적용할 수 있는 세부응용 분야로는 얼굴 인식과 같은 생체 인식(Biometric)을 들 수 있다. 기존의 얼굴인식에는 얼굴 이외에 국부적인 눈이나, 얼굴 형판 정합에 기반한 방법 등이 있었으나, 이미지가 가지는 데이터나 학습으로 인한 메모리양과 계산시간의 문제가 제기되었다. 이러한 문제를 해결하기 위해 얼굴 영상 벡터를 하나의 벡터 공간상의 특징 벡터들로 변환한 후 고유 특징 벡터와 양질의 얼굴 영상을 인공신경망을 결합하여 비

교할 수 있게 되었다. 대표적으로 Eigenface 방법인 PCA와 Fisherface 방법인 LDA가 제시되었다[2,7].

본 논문에서는 최적화 기법에 기반 한 패턴 분류기 모델들을 제안한다. 먼저 평가 방법에 입각한 pRBFNNs을 설계한다. 제안된 pRBFNNs 구조는 신경회로망 분류기의 성능 향상을 위해 퍼지 추론 메커니즘을 네트워크 구조에 적용하였으며, 은닉층과 출력층 사이의 상수항 연결가중치를 다항식으로 표현함으로써 출력 공간 내의 선형 판정 경계를 비선형 판정 경계로 나타내고자 한다. 또한 제안된 pRBFNNs 구조는 FCM 클러스터링에 기반 한 분할함수를 활성화함수로 사용한다. 이는 시그모이드 함수(Sigmoid Function), 방사형 기저 함수(Radial Basis Function)를 사용한 활성화함수보다 입력 공간의 데이터 분포 특성을 잘 반영함으로써 빠른 학습 수렴과 성능 개선의 특징을 가진다[3]. 또한 본 연구에서는 데이터 전처리 단계로서 PCA와 LDA가 가지는 장점들을 결합해 조명 및 환경 변화에 따른 노이즈를 제거하여 얼굴 영상의 특징을 가장 잘 나타내는 특징값을 추출한다. 이렇게 차원 축소된 데이터를 패턴 분류 알고리즘인

<sup>†</sup> 교신저자, 정회원 : 수원대 공대 전기공학과 교수 · 공박  
E-mail : ohsk@suwon.ac.kr

<sup>\*</sup> 정 회원 : 수원대 전기공학과 박사과정  
접수일자 : 2011년 9월 26일  
최종완료 : 2012년 3월 19일

pRBFNNs을 이용하여 얼굴 이미지 데이터가 가지고 있는 특성인 고차원 형태의 패턴 판별 문제에 대한 해결책을 제시하였다[4]. 또한 제안된 pRBFNNs 구조의 파라미터, 즉, 학습률, 모멘텀 계수, FCM 클러스터링의 퍼지화 계수 (Fuzzification Coefficient) 그리고 최적의 Feature 선택을 위하여 확률적인, 개체 집단에 기반을 둔 DE(Differential Evolution)[5]를 사용한다.

제안된 분류기의 얼굴인식 성능을 위하여 보편적으로 많이 사용되는 Yale과 AT&T 얼굴 데이터베이스를 적용하여 영상보정, 특징추출 등과 같은 전 처리과정을 포함하여 고차원 데이터로 이루어진 얼굴 이미지에 대한 인식 성능을 확인하여 패턴분류기로서의 성능 평가 및 분석을 수행한다.

## 2. 얼굴 데이터 특징점 추출을 위한 데이터 전처리

데이터 전 처리과정은 인식하기전 데이터를 준비하는 단계로서 히스토그램 평활화(Histogram Equalization), PCA, LDA와 같은 알고리즘을 이용하여 특징 데이터를 추출하는 단계이다.

### 2.1 히스토그램 평활화(Histogram Equalization)

디지털 영상(Digital Image)에는 인공조명이나 자연조명이 포함되며 조명광의 세기가 강하거나 약하여 영상의 실백에 어려움을 주는 경우가 발생할 수 있다. 이러한 영상에서는 표현하고자 하는 명암도의 범위, 명암도의 동적 영역(Dynamic Range)을 늘림으로써 화질을 향상 할 수 있으며, 동적 영역을 증가시키는 여러 가지 방법 중에서 가장 널리 쓰이는 방법 중의 하나가 히스토그램 평활화이다[6].

### 2.2 PCA(Principal Component Analysis)

주성분 분석법(PCA)은 고차원 특징 벡터를 저차원 특징 벡터로 축소하는 특징 벡터의 차원 축소(Dimension Reduction)뿐만 아니라, 데이터 시각화와 특징 추출에도 유용하게 사용되는 데이터 처리 기법 중의 하나이다[2]. 고유 벡터로부터 인식후보 얼굴의 가중치를 구하는 알고리즘은 다음과 같다.

**[Step 1]** 인식후보 얼굴 벡터 집합( $S$ )을 구성한다. 얼굴 영상의 크기가  $N \times N$ 이고, 인식후보 얼굴 영상의 개수가  $M$ 일 때, 각 후보 얼굴 영상을  $M$ 개의  $N^2 \times 1$  열벡터로 인식후보 얼굴 벡터 집합( $S$ )을 구성한다. 이때 각 후보 영상의 크기는 일정해야 하며, 얼굴의 중심이 일치하도록 준비한다.

$$S = \{I_1, I_2, I_3, \dots, I_M\} \quad (1)$$

**[Step 2]** 인식후보 얼굴 벡터 집합( $S$ )에서 평균 얼굴 벡터( $\Psi$ )를 계산한다.

$$\Psi = \frac{1}{M} \sum_{n=1}^M I_n \quad (2)$$

**[Step 3]** 각 인식후보 얼굴 벡터와 평균 얼굴 벡터의 차 벡터( $\Phi_i$ )를 계산한다.

$$\Phi_i = I_i - \Psi \quad (3)$$

여기서  $i=1, \dots, M$ 이며  $i$ 번째 인식후보 얼굴 벡터이다.

**[Step 4]**  $N^2 \times 1$  벡터  $\Phi_i$ 에서 공분산 행렬( $C$ )를 계산한다.

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \Phi_n^T = AA^T \quad (4)$$

이 단계의 결과,  $A = \frac{1}{\sqrt{M}} [\Phi_1, \Phi_2, \Phi_3, \dots, \Phi_M]$ 는  $N^2 \times M$  행렬이 되며, 공분산 행렬( $C$ )은  $N^2 \times N^2$ 의 고차행렬이 된다.

**[Step 5]** 공분산 행렬( $C$ )에서  $M$ 개의  $N^2$ 개 고유값  $\lambda_i$ 와 이에 대응하는 고유벡터  $u_i$ 를 계산한다. 여기서 고유값은 평균 얼굴 영상에 대한 분산의 정도를 나타내며, 고유값에서 얻은 고유벡터를  $N \times N$ 로 재배열하면 얼굴의 모양과 닮아 보이므로 이를 고유얼굴이라고 한다. 고유얼굴은  $M$ 개가 존재한다.



그림 1 고유 얼굴  
Fig. 1 Eigenface

**[Step 6]**  $M$ 개의 고유벡터(고유얼굴)  $u_i$ 에서 가장 큰 고유값을 갖는  $M$ 개만을 선택한다. 고유값이 크면 클수록 얼굴 특징을 고유벡터가 더 많이 표현하게 된다. 일단 이 단계가 완성되면 얼굴 인식을 위한 학습 단계는 끝난다.

**[Step 7]** 각 인식후보 얼굴 영상에 대해서 가중치로 이루어진 특징벡터를 고유벡터를 통해 계산한다. 각 인식후보 얼굴 영상의 가중치는  $M$ 개의 고유벡터에 대한 사영을 취해 구한다. 입력되는 얼굴 영상에 대한 각 고유얼굴 가중치( $\omega_i$ )는 식 (5)를 통해 계산된다.

$$\omega_k = u_k^T (I - \Psi) \quad (5)$$

여기서  $k=1, \dots, M$ 이다.

### 2.3 LDA(Linear Discriminant Analysis)

선형판별분석(LDA)은 PCA와 더불어 대표적인 특징 벡터 축소 기법 중의 하나이다. LDA를 간단히 정의하면 클래스 간 분산(Between-class Scatter)과 클래스 내 분산(Within-class Scatter)의 비율을 최대화하는 방식으로 데이터에 대한 특징 벡터의 하원을 축소하는 방법이다[7,8].

앞에서 설명한 PCA 방법은 어떤 집단의 특성을 잘 축약해서 표현하는 데는 유용하지만 집단 간을 잘 분리해서 나타내는 데는 취약하다. 얼굴인식에 있어서 얼굴 영상을 잘 축약해서 표현하는 것도 중요하지만 더욱 중요한 것은 서로

다른 개인의 얼굴을 잘 분리해서 표현하는 것이다. 따라서 영상의 변화가 각 얼굴 자체의 변화 때문인지 구분을 할 수 없다[9]. LDA 방법은 바로 이런 개인의 변화와 그 밖의 다른 요인에 의한 변화를 구분할 수 있도록 해준다[8]. LDA 알고리즘은 다음과 같다.

**[Step 1]** 표본  $x, y$ 의 평균 벡터를 각각  $\mu_1, \mu_2$ 라고 하면 사영된 데이터들의 중심 간의 거리를 목적함수로 선택하면 식 (6)과 같다

$$\mathcal{J}(W) = |\tilde{\mu}_1 - \tilde{\mu}_2| = |W^T \times (\mu_1 - \mu_2)| \quad (6)$$

식 (8)의  $\tilde{S}_1^2 + \tilde{S}_2^2$ 을 사영 표본의 클래스 내 분산이라고 하면 동일한 클래스의 표본들은 인접하게 사영을 취하고, 동시에 클래스간의 사영은 중심이 가능한 멀리 떨어지게 하는  $W$ 를 찾는 것이 목적이다.

**[Step 2]** 클래스 각각의 분산은  $S_1, S_2$ 로 놓고  $S_1 + S_2 = S_W$ 라고 할 때, 사영분산은 식 (7)과 같이 분산 행렬이 포함된 함수로 표현되어 질 수 있다.

$$\begin{aligned} \tilde{S}_1^2 &= \sum_{y \in \omega_1} (y - \tilde{\mu}_1)^T = \sum_{x \in \omega_1} (W^T x - W^T \mu_1)^2 \quad (7) \\ &= \sum_{x \in \omega_1} W^T (x - \mu_1)(x - \mu_1)^T W = W^T \end{aligned}$$

$$\tilde{S}_1^2 + \tilde{S}_2^2 = W^T S_W W \quad (8)$$

마찬가지로  $(\tilde{\mu}_1 - \tilde{\mu}_2)^2$ 은 식 (9)와 같이 표현할 수 있다.

$$\begin{aligned} (\tilde{\mu}_1 - \tilde{\mu}_2)^2 &= (W^T \mu_1 - W^T \mu_2)^2 \quad (9) \\ &= W^T (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T W = W^T S_B W \end{aligned}$$

이때, 행렬  $S_B$ 를 클래스 간 분산이라 부르며, 두 벡터간의 외적이므로 이 행렬의 랭크(rank)는 1이 된다.

**[Step 3]** 최종적인 Fisher의 목적함수를  $S_W$ 와  $S_B$ 항으로 식 (10)과 같이 간략히 정의할 수 있다.

$$\mathcal{J}(W) = \frac{W^T S_B W}{W^T S_W W} \quad (10)$$

여기서 [Step 3]의 목적함수를 최대화 하는 변환행렬  $W$ 를 찾아내는 문제는 최대화 정리, 일반화된 고유 값 문제의 해법을 이용한다.

**[Step 4]** 최대화 정리에 의하여 분자를 클래스 간 평균의 차인 상수로 취급하면, 다음과 같은 최적화된 변환행렬  $W^*$ 를 구할 수 있다.

식 (11)을 Fisher's Linear Discriminant라고 한다.

$$W^* = \arg \max \frac{W^T S_B W}{W^T S_W W} = S_W^{-1} (\mu_1 - \mu_2) \quad (11)$$

### 2.3 제안된 PCA&LDA 융합 알고리즘

PCA를 적용하여 얻은 특징 벡터 공간은 영상의 조명 변화와 얼굴의 표정 변화 등의 특징이 포함되어 있어 여전히 인식이 떨어지게 된다. 이 점을 고려하여, PCA를 이용하여 구한 특징 벡터에서 조명 변화, 표정 변화, 가려짐 등을 포함하는 가장 큰 고유 값 몇 개에 해당하는 고유벡터를 제거한 후, LDA를 적용함으로써 더욱 효과적인 분류가 되어 인식을 향상시키는 결과를 얻을 수 있다.

#### [Step 1] Training 행렬의 평균

Training 행렬의 행의 요소를 횡으로 모두 더하여 기준이 되는 전체 이미지에 대한 평균을 구한다.

#### [Step 2] Covariance Matrix

Covariance Matrix를 구하기 위해서 Training 행렬의 각 이미지(열의 요소)에서 Training 행렬의 평균을 차감한다. 위의 행렬과 위의 행렬의 전치 행렬을 곱하여 Covariance Matrix를 구한다.

#### [Step 3] PCA Vector

Training 행렬의 Covariance Matrix를 이용하여 Training 행렬의 Eigen Value와 Eigen Vector를 구한다.

**[Step 4]** PCA로 각 이미지를 고유한 특성을 띄도록 Dimension을 줄인 행렬을 이용한다.

**[Step 5]** PCA에서 구현했던 내용과 마찬가지로 Dimension이 줄어든 행렬의 횡에 대한 전체 평균을 구한다. 각 이미지는 모두 다른 표정 및 각도로 구성되어 있으므로 LDA를 구현하기 위해서는 반드시 주어진 개인의 이미지의 평균이 필요하다. 각 Class에 주어진 이미지 행의 평균을 구한다.

#### [Step 6] $S_b$ (Between Class의 Covariance Matrix)

Between Class의 Covariance Matrix를 구하기 위해서 각 Class의 평균(횡)에서 PCA를 통하여 변환된 이미지의 전체 평균(횡)을 차감한다. 위와 같이 구한 행렬과 이 행렬의 전치 행렬을 곱하여 Between Class의 Covariance Matrix를 구한다.

#### [Step 7] $S_w$ (Within Class의 Covariance Matrix)

PCA에서 Eigen Vector값으로 추출한 각 열의 이미지에서 각 Class의 평균(횡)에서 PCA를 통하여 변환된 이미지의 전체 평균(횡)을 차감한 행렬을 구한다. 위의 행렬과 이 행렬의 전치 행렬을 곱하여 Within Class의 Covariance Matrix를 구한다.

#### [Step 8] LDA Vector

이미지의 인식을 위한 기준 Vector를 생성하는 과정으로 Within Class의 역행렬과 Between Class를 곱한다. 이후 위

의 행렬의 Eigen Vector와 Eigen Value를 구할 수 있다. Eigen Vector와 PCA에서 생성한 각 이미지의 고유 Vector의 곱을 구함으로써 이미지 인식을 할 때 기준이 되는 Vector가 생성된다.

### 3. 다항식 기반 RBFNNs을 이용한 패턴 분류기 설계

본 장에서는 퍼지 추론 메커니즘에 기반 한 Polynomial-based Radial Basis Function Neural Networks를 설계 한다. 기존의 많은 논문에서 다층 퍼셉트론, 다항식 신경회로망, 폴신경회로망 등과 같이 신경회로망을 기반으로 여러 가지 패턴인식 모델이 제안되었다[10-13]. 제안된 다항식 기반 RBFNNs 구조는 FCM 클러스터링에 기반 한 분할 함수를 활성화 함수로 사용하며, 다항식 함수로 구성된 연결가중치를 사용함으로써 기존 신경 회로망 분류기의 선형적인 특성을 개선한다.

#### 3.1 다항식 기반 RBFNNs의 구조

본 논문에서 제안한 pRBFNNs 구조는 FCM 클러스터링에 기반한 분할 함수를 활성화 함수로 사용하며, 다항식 함수로 구성된 연결가중치를 사용함으로써 식 (12)의 퍼지 규칙 표현과 같이 언어적 관점에서 해석될 수 있다.

$$\text{If } x \text{ is } A_i \text{ Then } f_{ji}(x) \tag{12}$$

$x$ 는 입력 벡터,  $A_i$ 는 FCM 클러스터링에 의한  $i(i=1, \dots, c)$ 번째 그룹의 소속 함수,  $f_{ji}(x)$ 는  $j(j=1, \dots, s)$ 번째 출력에 대한  $i$ 번째 퍼지 규칙의 다항식이다. FCM 클러스터링을 이용함으로써 네트워크 측면에서는 활성화 함수를 언어적 측면에서는 소속 함수의 기능을 수행한다. “Then” 이후 결론부의 다항식은 네트워크 연결가중치로, 퍼지 규칙의 로컬 모델로 동작된다. 추론부에서 네트워크의 최종출력이 퍼지 규칙의 추론 결과로서 구해진다.




그림 2 조건부, 결론부, 추론부의 세 가지 모듈로서 표현된 다항식 기반 RBFNNs의 구조

Fig. 2 Topology of Polynomial-based RBFNNs showing three modules of condition, conclusion, and inference phases

#### 1) 다항식 기반 RBFNNs의 조건부

pRBFNNs의 조건부는 FCM 클러스터링[14] 방법을 사용한다. 이는 학습 데이터의 특정 반응을 위해 입력 공간을  $c$ 개의 클러스터 수(퍼지 규칙 수)만큼의 로컬 영역으로 분리하고 각 로컬 영역의 소속정도를 퍼지 집합으로서 출력한다. FCM 클러스터링은 목적함수인 식 (13)을 최소화함으로써 입력데이터의 각 클러스터에 대한 소속값을 구한다.

$$Q = \sum_{i=1}^c \sum_{k=1}^N u_{ik}^m \| \mathbf{x}_k - \mathbf{v}_i \|^2 \tag{13}$$

여기서,  $c$ 는 클러스터의 개수(퍼지 규칙 수),  $N$ 은 입력패턴 수,  $m$ 은 퍼지화 계수이다.  $\mathbf{x}_k$ 는  $k$ 번째 입력 벡터이고  $\mathbf{v}_i$ 는  $i$ 번째 클러스터의 중심이다.  $u_{ik}$ 는  $k$ 번째 데이터가  $i$ 번째 클러스터에 속하는 소속정도를 나타내는 0과 1사이의 실수이다. 식 (13)의  $\| \cdot \|$  부분은 식 (14)로 표현되는 Weighted Euclidean distance를 사용한다.

$$\| \mathbf{x}_k - \mathbf{v}_i \|^2 = \sum_{j=1}^n \frac{(x_{kj} - v_{ij})^2}{\sigma_j^2} \tag{14}$$

$\sigma_j$ 는 입력 패턴들의  $j$ 번째 입력 차원의 표준편차이다. Weighted Euclidean distance는 데이터 크기 분포에 크게 영향을 받지 않는 알맞은 거리 정보를 제공하므로 많이 사용되고 있다.  $n$ 차원 유클리드 공간상의  $N$ 개의 패턴으로 구성된 입력 벡터 집합  $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$ ,  $\mathbf{x}_k \in R_n$ ,  $1 \leq k \leq N$ 와 클러스터 중심  $\mathbf{V} = \{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_c\}$ ,  $\mathbf{v}_i \in R_n$ ,  $1 \leq i \leq c$ 에 대한 소속정도를 소속행렬로 표현하면  $U = [u_{ik}]$ 로 표현되고  $u_{ik}$ 와  $\mathbf{v}_i$ 는 식 (15)와 식 (16)에 의해 각각 계산 된다.

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left( \frac{\| \mathbf{x}_k - \mathbf{v}_i \|^2}{\| \mathbf{x}_k - \mathbf{v}_j \|^2} \right)^{\frac{2}{m-1}}}, \quad 1 \leq k \leq N, 1 \leq i \leq c \tag{15}$$

$$\mathbf{v}_i = \frac{\sum_{k=1}^N u_{ik}^m \mathbf{x}_k}{\sum_{k=1}^N u_{ik}^m}, \quad 1 \leq i \leq c \tag{16}$$

위의 식 (15)와 (16)을 반복적으로 수행하면서 소속행렬  $U$ 와 각 클러스터의 중심  $\mathbf{v}$ 를 수정하면서 식 (13)의 목적함수  $Q$ 를 특정값으로 수렴시킨다. 식 (12)의 “Then” 이후의 규칙을 형성한다.

#### 2) 다항식 기반 RBFNNs의 결론부

pRBFNNs 구조의 결론부는 조건부에서 분리한 각 로컬 영역을 다항식 함수의 로컬 회기모델로서 표현하여 식 (8)의 “Then” 이후의 규칙을 형성한다.  $f_i(x)$ 에서 식 (17)-(19)의 형태를 갖는, 즉 상수항, 선형식, 2차식의 세 가지 타입의 함수 중 하나의 형태를 갖는다.

$f_i(x)$ 가 식 (17)의 형태인 경우 FCM 클러스터링을 통한 소속 함수를 활성화 함수로 사용한 RBFNN과 동일한 구조를 갖는다.

Constant ;  $f_i(\mathbf{x})=a_{i0}$  (17)

Linear ;  $f_i(\mathbf{x})=a_{i0} + \sum_{j=1}^n a_{ij}x_j$  (18)

식 (17)-(18)의 다항식 함수들은 조건부의 소속 함수(활성 함수)에 의해 활성화 되며 각 퍼지 규칙의 로컬 회기 모델로 동작한다.

3) 다항식 기반 RBFNNs의 추론부

제안된 다항식 기반 RBFNNs의 구조는 위에서 언급한 바와 같이 조건부를 FCM 클러스터링을 통한 퍼지 공간 분할, 결론부를 다항식으로 로컬 영역을 표현하는 로컬 회기 모델로 이해할 수 있다. 추론부에서는 “If-then” 퍼지 규칙 기반의 퍼지 추론에 의해 네트워크의 최종출력을 구하게 된다. 그림 7의 추론부의 “II”로 표기된 뉴런에 의해 입력신호들은 합하여져 그 결과를 출력층 뉴런의 최종 출력으로 내보낸다. 이와 같이 일련 과정은 퍼지 추론 과정과 같으며, Fuzzy Neural Networks[15]와 같은 형태를 갖게 된다. 결론적으로 제안된 다항식 기반 RBFNNs 구조를 보인 그림 7에서  $j(=1,\dots,s)$ 번째 출력의 최종출력은 퍼지 추론에 의한 식 (19)과 같이 표현된다.

$$y_j = g_j(\mathbf{x}) = \frac{\sum_{i=1}^c u_i f_{ji}(\mathbf{x})}{\sum_{k=1}^c u_k} = \sum_{i=1}^c u_i f_{ji}(\mathbf{x}) \quad (19)$$

여기서,  $u_i$ 는 그림 7의  $A_i(\mathbf{x})$ 와 같고 식 (15)와 같이 모든 클러스터에 대한 총합은 1이다.

3.2 차분진화 알고리즘을 이용한 pRBFNNs의 최적화

차분진화 알고리즘은 현재 널리 사용되고 있는 통계적 임의 탐색법인 유전 알고리즘(Genetic Algorithm: GA)과 유사한 알고리즘이다[5]. 유전 알고리즘과 차분진화 알고리즘은 초기 개체군을 이루는 개체를 샘플링하고, 이들의 교배(Crossover), 변이(Mutation), 선택(Selection) 과정을 거쳐 적합도(Fitness)가 개선되는 새로운 개체들을 추출해 내는 공통점이 있다. 그러나 유전 알고리즘의 단점이었던 너무 복잡한 구조와 연산대신 간단하고 합리적인 구조와 빠른 속도가 장점이다. 파라미터 벡터의 차원은 목적함수를 이루는 설계변수의 개수와 같으며, 초기 파라미터 벡터 가용 영역(Feasible region)에서 임의로 선택하되, 일반적으로 균등 확률 분포를 따르도록 한다[16]. 차분진화의 실행 단계를 정리하면 다음과 같다.

[Step 1] 초기 집단(P) 구성(랜덤 값으로  $\mu$ 개의 개체를 초기화. 각 개체는  $n$ 개의 목적변수로 구성,  $t=0$ )

$$P(t) = a_1(t), a_2(t), \dots, a_\mu(t), a_k = x_{1k}, \dots, x_{nk} \quad (20)$$

[Step 2] 집단내의 모든 개체의 목적함수( $\Phi$ ) 평가

$$\Phi(t) = \Phi(a_1(t)), \dots, \Phi(a_\mu(t)), \Phi(a_k(t)) \quad (21)$$

$$= Func(x_{1k}, \dots, x_{nk})$$

[Step 3] 모든 개체( $i=1,\dots,\mu$ )에 대해 차분 변화를 위한 개체  $a_{r1}, a_{r2}$ 와  $a_{r3}$ 를 선택하여 교배용 벡터를 만들고 이를 교배 대상 벡터와 교배함

$$v_i(t) = a_{r1}(t) + F \cdot (a_{r2}(t) - a_{r3}(t)); \text{ 교배용 벡터}$$

$$x'_i(t) = (v_i(t) * a_i(t)); \text{ 교배} \quad (22)$$

[Step 4] 모든 개체의 목적함수 평가

$$\Phi(t) = \Phi(x'_1(t)), \dots, \Phi(x'_\mu(t)),$$

$$\text{if}(\Phi(x'_i(t)) > \Phi(a_i(t))) \quad a_{i(t)} = x'_i(t) \quad (23)$$

[Step 5] 종료조건을 확인하고 종료조건이 만족되지 않으면  $t=t+1$ 로 하고 [Step 3]으로 복귀

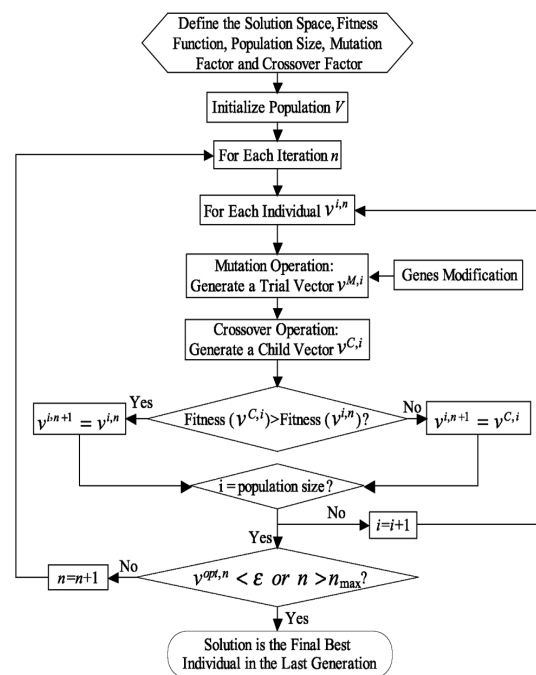


그림 3 DE알고리즘의 순서도  
Fig 3 Flowchart of Differential Evolution Algorithm

4. 실험 및 결과고찰

본 장에서는 최적화기법이 적용된 pRBFNNs을 사용해 얼굴이미지 데이터에 대한 인식률을 실험한다. 사용되는 데이터는 기존에 많은 연구에서 적용된 Yale Database와 AT&T Database를 이용한다. 사용된 이미지들은 PCA(Principal Component Analysis)와 PCA 및 LDA(Linear Discriminant Analysis)가 결합된 알고리즘을 통하여 전 처리 되어진 50차원의 입력 패턴을 생성하게 된다. 50차원의 전처리 데이터는 곧바로 분류기의 입력 데이터 패턴으로 사용하지 않고 최적화 알고리즘을 이용하여 Feature selection 기능을 추가하여 수행된다. 이는 50개의 변수를 갖는 연결가중치 1차식에서의 변수를 줄여주는 의미도 있지만 50개의 특징이 얼굴 인식을 수행하는데 있어서 모두 필요하다고 말할 수 없기 때문에 꼭 필요한 특징들을 탐색하는 의미도 갖게 된다.

	Learning Rate	Momentum Coefficient	Fuzzification Coefficient	Feature Selection (Size of Dimension)	
<b>Vectors</b>	[1e-8, 0.01]	[1e-8, 0.9]	[1.1, 3.0]	0.63	0.54

그림 4 얼굴인식에 사용된 최적화 파라미터 vector의 구조  
 Fig. 4 Construction of optimization parameter vectors used in face recognition

본 실험에서는 보다 정확한 비교 연구와 검증된 결과를 얻기 위하여 얼굴 인식 연구에 널리 사용되어 지고 있는 Yale 및 AT&T 표준 데이터베이스를 사용하였다. 각 데이터베이스에 대한 이미지는 아래와 같다.



(a) Yale Database



(b) AT&T Database

그림 5 얼굴인식 실험에 사용된 얼굴 영상 데이터  
 Fig. 5 Facial image dataset used for face recognition experiment

실험의 성능 지수는 1:N Identification 방식으로 전체 인식 대상에 대한 인식 성공률을 계산한다. 모든 실험들은 발생된 결과들의 타당성으로써 좀 더 높은 객관성을 제공하기 위하여 Cross-validation 방법 중 대표적인 Resampling 모드를 실행 하였으며 이를 다시 세분화하여 학습 데이터 (Training dataset)와 평가용 데이터(Validation dataset) 그리고 테스트 데이터(Testing dataset)로 구분하여 실험한다. 학습 데이터와 평가용 데이터 집합은 분류기를 학습시켜

표 1 얼굴 인식에 사용된 실험 파라미터

Table 1 Experiment parameters used for face recognition

pRBFNNs		
학습 횟수	100	
Polynomial type	Linear	
Data Split	Training : Validation : Testing = 5 : 3 : 2	
Feature Selection	0.5이상	
Optimization Algorithm	DE	
목적함수 평가 횟수 (Generation/Swarm)	2000 (20×100)	
Search space	학습률	[1e-8, 0.01]
	모멘텀 계수	[1e-8, 0.01]
	퍼지화 계수	[1.1, 3.0]

DE로 최적의 학습률과 모멘텀 계수 그리고 퍼지화 계수를 동조하기 위하여 사용된다. 실험은 PCA만을 사용하여 차원을 축소해 50차원의 입력 벡터로 표현하는 경우(Case 1)와 PCA와 LDA를 결합하여 제안된 알고리즘으로 50차원의 입력 벡터로 표현한 경우(Case 2)로 나누어 수행한다. 또한, 두 경우 모두 DE를 통하여 필요한 특징을 선택(Feature selection) 함으로써 분류기에 직접 학습되는 벡터의 차원수를 동정한다. 표 2는 실험에 사용된 데이터 분할율과 다항식 기반 RBFNNs의 최적화에 사용된 파라미터 값이다

4.1 Yale Database를 이용한 얼굴인식 실험

Yale 데이터베이스는 15명의 사진이 각각 11장씩 있는 얼굴 이미지 데이터이다. 이 데이터베이스의 얼굴 영상은 3개의 조명 각도를 갖고 얻어지는 반면, 광원의 정확한 위치는 언급되어 있지 않으며, 모든 영상이 정면이기 때문에 어떠한 자세 각도 변화나 환경적 요인(주변 조명의 유무)도 묘사되지 않는다. 본 실험에서 데이터를 PCA(Case 1) 및 PCA-LDA 결합(Case 2) 알고리즘을 사용하여 한 장의 사진을 인덱스를 포함한 51차원의 벡터를 추출하여 실험을 수행한다.

표 2 Yale 데이터의 분할 및 이미지 사이즈

Table 2 Image size and division of Yale dataset

DB	Image size	Division of dataset			
		Total	TR	VA	TE
Yale	320×243(L)	165	90	45	30

표 3 Yale 이미지 데이터 집합 얼굴인식 결과(Case 1)


Table 3 Result of pattern classification for Yale dataset(Case 1)

Classifier Model	No. of Rules	Classification rate(%)		
		Training	Validation	Testing
DE-pRBF NNs (Case 1)	2	97.35±2.46	95.20±4.04	88.82±4.83
	3	<b>99.66±0.49</b>	<b>96.43±2.38</b>	<b>91.22±3.57</b>
	4	98.60±1.68	96.99±5.84	88.78±5.39
	5	98.71±1.77	97.47±2.56	87.03±6.34
6	97.68±2.33	93.82±4.83	86.41±3.67	


표 4 Yale 이미지 데이터 집합 얼굴인식 결과(Case 2)

Table 4 Result of pattern classification for Yale dataset(Case 2)

Classifier Model	No. of Rules	Classification rate(%)		
		Training	Validation	Testing
DE-pRBF NNs (Case 2)	2	99.78±0.50	98.22±2.43	92.45±1.034
	3	99.72±0.56	99.45±1.11	93.61±6.04
	4	<b>98.64±2.06</b>	<b>98.89±2.22</b>	<b>95.58±6.35</b>
	5	99.57±1.16	98.85±0.69	93.06±5.66
6	100.0±0.00	100.0±0.00	92.89±4.32	



(a) Training data (b) Validation data



(c) Testing data

그림 6 전처리 기법에 따른 패턴분류 결과 비교(후반부 다항식 타입: Linear)

Fig. 6 Comparison of classification rate according to preprocessing method (Polynomial type: Linear)

- ▶ 다수의 클래스로 인하여 후반부 차수가 Constant 형태는 학습 자체가 어려우므로 성능 평가에 고려하지 않았다.
- ▶ 학습데이터에 비하여 테스트 데이터의 표준편차가 크며, 전체적으로 평가 하였을 때 DE-pRBFNNs(Linear)모델이 규칙수 4개에서 가장 우수한 성능(Recognition rate for testing data :  $95.58 \pm 6.35\%$ )을 보임을 알 수 있다.
- ▶ 전반적으로 규칙수가 증가함에 따라 학습데이터의 성능은 증가 되고 PCA와 LDA의 융합 알고리즘이 적용된 모델이 우수함을 볼 수 있다.

4.2 AT&T Database를 이용한 얼굴인식 실험

AT&T 데이터베이스는 얼굴인식 분야에서 가장 많이 쓰이는 데이터로 총 40명의 사진이 각각 10장씩 있는 이미지 데이터이다. 이미지는 40명에 대하여 일정한 어두운 배경에서 얼굴표정과 안경 착용 유무에 따라 각 10장씩 구성되어 있으며 안경, 수염 등이 있는 얼굴들이 많이 분포되어 있고 좌우 회전을 통해 변형된 얼굴영상도 다소 존재하기 때문에 난이도가 있는 얼굴 데이터베이스라고 할 수 있다. 본 실험에서는 Yale 데이터베이스를 이용한 실험과 마찬가지로 Case 별로 얼굴인식 실험을 수행한다.

표 5 AT&T 데이터의 분할 및 이미지 사이즈

Table 5 Image size and division of AT&T dataset

DB	Image size	Division of dataset			
		Total	TR	VA	TE
Yale	92×112(L)	400	200	120	80

표 6 AT&T 이미지 데이터 집합 얼굴인식 결과(Case 1)


Table 6 Result of pattern classification for AT&T dataset (Case 1)

Classifier Model	No. of Rules	Classification rate(%)		
		Training	Validation	Testing
DE-pRBF NNs (Case 1)	2	99.245±2.78	90.25±0.80	86.57±1.18
	3	<b>98.50±2.14</b>	<b>88.41±3.69</b>	<b>88.08±2.01</b>
	4	97.76±4.02	91.84±1.53	86.28±2.50
	5	98.12±1.46	87.74±0.62	85.57±3.09
	6	98.74±1.63	85.48±2.18	83.91±6.98


표 7 AT&T 이미지 데이터 집합 얼굴인식 결과(Case 2)

Table 7 Result of pattern classification for AT&T dataset(Case 2)


Classifier Model	No. of Rules	Classification rate(%)		
		Training	Validation	Testing
DE-pRBF NNs (Case 2)	2	96.63±2.53	93.96±2.27	91.65±3.78
	3	97.58±1.11	95.83±0.68	92.66±3.82
	4	<b>99.00±0.71</b>	<b>95.63±1.05</b>	<b>93.65±1.78</b>
	5	97.81±1.63	94.22±1.96	91.17±2.38
	6	98.88±1.60	94.79±1.58	89.17±5.23



(a) Training data



(b) Validation data



(c) Testing data

그림 7 전처리 기법에 따른 패턴분류 결과 비교(후반부 다항식 타입: Linear)

Fig. 7 Comparison of classification rate according to preprocessing method (Polynomial type: Linear)

- ▶ 그림 7을 보면 규칙수가 2일 때 학습데이터의 성능이 가장 좋았고, 전반적으로 규칙수가 증가함에 따라 성능에 변화가 있음을 알 수 있다.

- ▶ 테스트 데이터의 경우 규칙수가 증가함에 따라 성능이 저하됨을 볼 수 있고, 규칙수가 4개(Linear) 일 때, 가장 우수한 성능 (Recognition rate for testing data :  $93.65 \pm 1.78$ )을 보임을 확인할 수 있다.
- ▶ 학습데이터에 비하여 테스트 데이터의 표준편차가 크게 나타났다.
- ▶ 전반적으로 규칙수가 증가함에 따라 학습데이터의 성능은 증가 되고 PCA와 LDA의 융합 알고리즘이 적용된 모델이 우수함을 보임을 확인하였다.
- ▶ PCA기법만 사용한 것에 비하여 PCA와 LDA의 융합 알고리즘이 적용된 모델이 우수함을 볼 수 있지만, 양기법은 규칙수가 증가함에 따라 테스트 데이터의 성능이 저하됨을 볼 수 있다.

## 5. 결 론

본 논문에서는 얼굴 인식 시스템 설계를 위해서 크게 두 가지 모듈로 구성하였다. 데이터 전처리에서는 이미지 개선, 특징 추출을 위해 가장 보편적인 히스토그램 평활화, PCA, LDA 방법을 사용하였다. 그리고 얼굴인식을 위한 패턴분류기로서 퍼지 추론에 기반 한 Polynomial-based Radial Basis Function Neural Networks를 제안하였다. 다항식 기반 RBFNNs는 Fuzzy C-mean(FCM) 클러스터링을 사용하여 퍼지규칙의 전반부 멤버십을 결정한다. 이렇게 결정되는 멤버십은 네트워크의 구조적인 측면에서 볼 때 은닉층 노드의 활성화수로 사용된다. 이 같은 클러스터링 방법의 사용은 고차원의 패턴인식 문제 및 모델링 문제에 멤버십 함수형성에 알맞은 방법이다. 제안된 다항식 기반 RBFNNs의 패턴 분류 성능 분석을 위해, 고차원 입력패턴으로 이루어진 Yale과 AT&T 얼굴 데이터베이스에 적용하여 고차원 패턴인식 문제에 대한 문제 해결을 증명하였다. 얼굴 데이터는 직접 이미지로부터 기존의 PCA 변환(Case 1)을 개선한 PCA-LDA 융합 알고리즘(Case 2)에 의해 특징 벡터를 추출하였다. 실험 결과 제안된 PCA-LDA 융합 알고리즘에 의한 특징벡터 추출 방법이 기존 PCA에 비해 인식률이 상당히 높음을 증명하였다. 이는 대체로 정규화 된 집합이고, 조명이나 크기, 자세에 있어 큰 변화를 주지 않는 데이터일수록 PCA의 성능도 우수하지만 본 실험에 사용된 데이터의 경우들에 자세 및 표정, 그리고 조명 변화 등 개인의 변화와 그 밖의 다른 요인에 의한 변화를 구분할 수 있는 LDA가 융합된 알고리즘으로 주어진 클래스를 명확히 구분해주는 효과가 있는 것으로 보인다.

### 감사의 글

본 연구는 경기도의 경기도지역협력연구센터(GRRC) 사업의 일환으로 수행하였음 [GRRC수원 2011-B2, U-city 보안감시 기술협력센터] 그리고 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2009-0074928)

## 참 고 문 헌

- [1] A. Patrikar, J. Provence, "Pattern classification using polynomial networks," *Electronics Letters*, Vol. 28, No. 12, pp. 1109-1110, 1992.
- [2] M. Turk and A. Pentland, "Eigenfaces for Recognition," *Journal of Cognitive Neuroscience*, Vol. 3, pp. 71-86, 1994.
- [3] J. Moody and C. J. Darken, "Fast learning in network of locally-tuned processing units," *Neural Comput.*, Vol. 1, pp. 281-294, 1989.
- [4] C. Mazzetti, F. M. Frattale Mascioli, F. Baldini, M. Penella, R. Risica, and R. Bartnikas, "Partial Discharge Pattern Recognition by Neuro-Fuzzy Networks in Heat-Shrinkable Joints and Terminations of XLPE Insulated Distribution Cables," *IEEE Trans. on Power Delivery*, Vol. 21, No. 3, pp. 1035-1044, 2006.
- [5] Michalewicz. Z, "Genetic Algorithm + Data Structures = Evolution Programs," Springer-Verlag, Berlin Heidelberg, 1996.
- [6] A. Aiyer, K. Pyun, Y. Z. Huang, D. B. O'Brien, R. M. Gray, "Lloyd clustering of Gauss mixture models for image compression and classufication," *Signal Processing: Image Communication*, Vol. 20, pp. 459-485, 2005.
- [7] S. Balakrishnama and A. Ganapathiraju, "LINEAR DISCRIMINANT ANALYSIS A BRIEF TUTORIAL," Institute for Signal and Information Processing, 1998.
- [8] Ming-Hsuan Yang, Kernal Eigenfaces vs. Kernal Fisherfaces: Face Recognition Using Kernal Methods, *Automatrix Face and Gesture Recognition*, 202, Proceedings, Fourth IEEE International Conference on, 2002 Page(s): 208-213.
- [9] Martinez A. M., Kak A. X., "PCA versus LDA," *IEEE Trans. on Pattern Analysis and Machine Intelligenece*, 23(2), pp. 228-232, 2001.
- [10] S. K. Oh, W. Pedrycz, and S. B. Roh, "Genetically Optimized Hybrid Fuzzy Set-based Polynomial Neural Networks," *Journal of the Franklin Institute*, Vol. 348, No. 2, pp. 415-425, 2011.
- [11] D. Valentin, H. abdi, A. J. O'Toole, and G. W. Cottrell, "Connectionist models of face processing: A Survey," *Pattern Recognition*, Vol. 27, pp. 1209-1230, 1994.
- [12] M. J. Er, S.Q. Wu, J.W. Lu, H.L. Toh, "Face recognition with radial basis function (RBF) neural networks," *IEEE Trans. Neural Networks*, Vol. 13, No. 3, pp. 697-710, 2002.
- [13] J. Moody and C. J. Darken, "Fast learning in network of logically-tuned processing units," *Neural Comput.*, Vol. 1, pp. 281-294, 1989.
- [14] J. C. Bezdek, "Pattern recognition with Fuzzy



Objective Function Algorithms,” Plenum Press, New York, 1981.

[15] S. K. Oh, W. Pedrycz, and H. S. Park, “Hybrid Identification in Fuzzy-Neural Networks,” Fuzzy Sets and Systems, Vol. 138, Issue 2, pp. 399-426, 2003.

[16] R. Storn, Differential Evolution, A Simple and Efficient Heuristic Strategy for Global Optimization over Continuous Spaces, Journal of Global Optimization, Vol. 11, pp. 341-359, 1997.

## 저 자 소 개



### 오 성 권 (吳 聖 權)

1981년 연세대학교 전기공학과 졸업, 동 대학원 석사(1983), 박사(1993). 1983-1989년 금성산전연구소(선임연구원). 1996-1997년 캐나다 Manitoba 대학 전기 및 컴퓨터 공학과 Post-Doc. 1993-2004년 원광대학교 전기전자 및 정보공학부 교수. 2005~

현재 수원대학교 전기공학과 교수, 2002~현재 대한전기학회, 제어로봇시스템학회, 퍼지및지능시스템학회 편집위원. 관심분야는 퍼지 시스템, 퍼지-뉴럴 네트워크, 자동화 시스템, 고급 computational intelligence, 지능 제어등.

Tel : 031-229-8162

Fax : 031-220-2667

E-mail : ohsk@suwon.ac.kr



### 유 성 훈 (柳 成 勳)

2010년 수원대학교 전기공학과 졸업, 동 대학원 석사(2012), 2012~현재 동 대학원 박사과정.

관심분야는 퍼지추론 시스템, 뉴럴 네트워크, Granular Computing, 진화론적 최적화 알고리즘, 컴퓨터 비전 등.

Tel : 031-229-8162

Fax : 031-220-2667

E-mail : shyoo@suwon.ac.kr