

# ASM기반 (2D)<sup>2</sup> 하이브리드 전처리 알고리즘을 이용한 얼굴인식 시스템 설계

## Design of ASM-based Face Recognition System Using (2D)<sup>2</sup> Hybrid Preprocessing Algorithm

김현기\* · 진용탁\* · 오성권\*

Hyun-Ki Kim, Yong-Tak Jin, and Sung-Kwun Oh<sup>†</sup>

\*수원대학교 전기공학과

<sup>†</sup> Department of Electrical Engineering, The University of Suwon

### 요 약

본 연구에서는 ASM기반 (2D)<sup>2</sup> 하이브리드 전처리 알고리즘을 이용한 얼굴인식 분류기와 그것의 설계방법론을 소개한다. 얼굴인식을 위한 이미지는 외부 환경에 쉽게 영향을 받기 때문에, 전처리 단계로 이러한 문제를 해결하기 위해서 ASM을 사용하였다. 특히 사람 얼굴의 특징 추출을 목적으로 널리 이용되고 있다. ASM을 이용해 얼굴영역을 추출 한 뒤 PCA와 LDA를 이용한 (2D)<sup>2</sup> 하이브리드 전처리 알고리즘을 이용하여 차원을 축소한다. 전처리 알고리즘을 통한 얼굴데이터는 제안된 다항식 기반 방사형 기저함수 신경회로망의 입력으로 사용된다. 기존의 신경회로망과는 달리 제안된 지능형 패턴 분류기는 강인한 네트워크 특성을 가지며, 예측능력이 우수할 뿐만 아니라 다차원 입출력에 대한 문제도 해결했다. 분류기의 중요한 필수 설계 파라미터(행의 고유벡터의 수, 열의 고유벡터의 수, 클러스터의 수, 퍼지화 계수)는 ABC알고리즘에 의해 최적화 되어진다. 얼굴인식에 많이 사용되는 Yale과 AT&T를 사용하여 인식률을 평가하였다.

**키워드** : ASM, (2D)<sup>2</sup>하이브리드 전처리 알고리즘, 얼굴인식 시스템, ABC

### Abstract

In this study, we introduce ASM-based face recognition classifier and its design methodology with the aid of 2-dimensional 2-directional hybrid preprocessing algorithm. Since the image of face recognition is easily affected by external environments, ASM(active shape model) as image preprocessing algorithm is used to resolve such problem. In particular, ASM is used widely for the purpose of feature extraction for human face. After extracting face image area by using ASM, the dimensionality of the extracted face image data is reduced by using (2D)<sup>2</sup> hybrid preprocessing algorithm based on LDA and PCA. Face image data through preprocessing algorithm is used as input data for the design of the proposed polynomials based radial basis function neural network. Unlike as the case in existing neural networks, the proposed pattern classifier has the characteristics of a robust neural network and it is also superior from the view point of predictive ability as well as ability to resolve the problem of multi-dimensionality. The essential design parameters (the number of row eigenvectors, column eigenvectors, and clusters, and fuzzification coefficient) of the classifier are optimized by means of ABC(artificial bee colony) algorithm. The performance of the proposed classifier is quantified through yale and AT&T dataset widely used in the face recognition.

**Key Words** : ASM, (2D)<sup>2</sup>Hybrid Preprocessing Algorithm, Face Recognition System, ABC

접수일자: 2013년 9월 1일

심사(수정)일자: 2013년 10월 12일

게재확정일자: 2013년 11월 26일

<sup>†</sup> Corresponding author

본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음[GRRRC 수원2013-B2, U-city 보안감시 기술협력센터] 그리고 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (NRF-2012R1A1B3003568)

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

## 1. 서 론

현재 생체인식 중 가장 보편화되고 쉽게 볼 수 있는 기술은 지문인식이다. 하지만 최근에 생체인식 기술이 발전하면서 다양한 생체정보를 활용한 제품들이 개발되고 있는 실정인데, 그 중 얼굴인식은 편리성과 정확성, 그리고 사용자의 거부감을 덜어주는 장점을 가지고 있어 그 연구가 빠른 속도로 늘어나고 있다. 얼굴인식을 인식하기 위해선 얼굴 고유의 특징을 추출하는 것이 제일 중요하다. 이를 위해 ASM알고리즘을 통해 얼굴의 외형을 추출한 뒤 대표적인 차원축소 기법인 PCA와 LDA를 알고리즘의 장점을 결합한 (2D)<sup>2</sup> 하이브리드 전처리 알고리즘을 이용하여 차원을 축소한다. 하이브리드 전처리 알고리즘을 통한 데이터의 간략화와 효율성을 극대화 하여 이미지의 고차원의 고유의 특징을

최대한으로 유지하여 저차원으로 차원을 축소하였다. 전처리과정을 거친 데이터를 입력으로 사용하여 제안된 최적화를 결합한 지능형 패턴분류기로 인식률을 산출하였다. 실험에 사용된 데이터로는 얼굴인식 평가에 많이 사용되는 Yale data와 AT&T data를 통한 인식률을 산출한다.

## 2. 얼굴데이터의 전처리 과정

제안된 지능형 패턴 분류기로 얼굴인식을 수행하기에 앞서 얼굴 고유의 특징데이터를 추출하는 것이 얼굴인식 기술에 가장 중요한 점이라고 볼 수 있다. 전처리 과정은 ASM과 대표적인 특징추출 알고리즘은 PCA와 LDA를 결합한 (2D)<sup>2</sup>하이브리드 알고리즘을 사용한다. 얼굴 영역을 추출하기 위해 ASM을 사용하여 배경과 얼굴을 분리 하였고, (2D)<sup>2</sup>하이브리드 알고리즘으로 특징을 추출한다. 패턴인식에 있어 특징을 잘 표현하는 것이 인식률에 큰 영향을 미친다. 특징이 많으면 잡음이나 분류기의 학습과 인식 속도가 느려지는 단점이 있다. 이러한 이유로 입력 데이터의 특징을 최적의 표현에서 최대한의 특징을 추출하는 것이 전처리과정을 하는 이유이다.

### 2.1 ASM을 이용한 얼굴영역 추출

ASM(Active shape Model)은 통계적인 모델을 이용한 특징 점들을 추출하는 방법으로 얼굴의 특징점 추출을 위해서 많이 사용되고 있는 방법 중의 하나이다. ASM은 형상 모델을 생성하기 위해 학습 데이터로부터 특징 점들을 이용하여 평균 형상을 구한다. 다시 형상을 평균에 매칭 시키도록 크기변환, 회전변환, 평균이동 시킨 후 또 다시 변형된 형상들의 평균을 구한다. 이전 평균과 새로 구한 평균의 오차가 어느 특정 값 이상 나타나지 않을 때 까지 구하는 과정을 반복한다. 이렇게 구한 평균형상을 이용해서 새로운 얼굴 이미지가 들어오면 평균형상과 비교하여 얼굴 영역을 검출하게 된다. 그림 1은 ASM을 이용하여 실제 얼굴데이터의 윤곽만을 추출하게 되는 일련의 과정을 보여준다.



그림 1. 평균형상 학습 과정  
Fig. 1. Learning process of average shape




그림 2. ASM을 통한 얼굴윤곽 추출 과정  
Fig. 2. Contour extraction process of face through ASM

### 2.1 (2D)<sup>2</sup>하이브리드 특징 추출 알고리즘

일반적인 선형 특징 추출알고리즘은 입력받은 2차원 데이터를 1차원으로 변환하여 변환된 1차원의 데이터의 공분산을 이용한 차원축소 방법이 이루어진다. 이에 반해 본 연구에서 사용한 차원축소 방법은 개념은 동일하지만 (2D)<sup>2</sup>이라 명칭하여 입력받은 2차원데이터를 변환하지 않고 차원을 축소하는 방법이다. 2-Dimensional 2-Directional의 약자로 2차원 2방향이란 의미이다.[1][2]

하이브리드 알고리즘이란 대표적인 차원축소 알고리즘인 PCA와 LDA를 결합한 방법이다. PCA는 주성분 분석법으로 데이터의 공분산 행렬을 이용하여 구한 특징데이터의 차원이 실제 입력 데이터의 차원보다 작은 값이 되어 저차원의 특징을 추출하는 알고리즘이다. 주성분 분석법의 가장 큰 목적은 변화 후의 특징데이터가 변환전의 데이터의 정보를 최대한 유지하도록 하는 것이다. 주성분 분석법을 통해 변환된 특징데이터를 입력으로 선형판별 분석법을 수행한다. 선형판별 분석법은 클래스 간 분산과 클래스 내 분산의 비율을 최대화하는 방식으로 특징 추출을 목적으로 한다. (2D)<sup>2</sup>하이브리드 알고리즘의 순서는 다음과 같다.

단계 1 : 학습데이터의 평균을 구함.

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

단계 2 : 공분산 행렬(Covariance Matrix) - 공분산 행렬을 구하기 위해 전체 학습데이터에서 학습데이터 평균을 차감.

$$C_x = \frac{1}{N} (X - M_x)(X - M_x)^T, M_x = \mu_x \mathbf{1}^T \quad (2)$$

(1은 모든 원소의 값이 1인 n차원 열 벡터)

단계 3 : 고유치 분석을 통해 C<sub>x</sub>의 고유행렬과 고유벡터행렬을 선택.

$$C_x = UAU^T = [u_1, u_2, \dots, u_n] \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} [u_1, u_2, \dots, u_n]^T \quad (3)$$

단계 4 : 고유치 값이 큰 것부터 순서대로 M개의 고유치  $[\lambda_1, \lambda_2, \dots, \lambda_m]$ 를 선택, 선택한 고유치의 대응되는 고유벡터를 열벡터로 가지는 변환행렬  $W = [u_1, u_2, \dots, u_m]$ 를 생성. W에 의한 특징 데이터 Y를 얻음.

$$Y = W^T X \quad (4)$$

단계 5 : 입력데이터 Y를 각 클래스 라벨에 따라 M개의 클래스로 나누어 평균  $m_k$ 를 구함.

$$m_k = \frac{1}{|N_k|} \sum_{x_i \in C_k} Y_i, \quad (k=1,2,\dots,M) \quad (5)$$

(N<sub>k</sub>는 클래스 C<sub>k</sub>의 데이터 수)

단계5. Sb(Between Class의 Covariance Matrix)

Between Class의 Covariance Matrix를 구하기 위해서 각 Class의 평균에서 PCA를 통하여 변환된 이미지의 전체 평균(m)을 차감.

$$S_B = \sum_{k=1}^M N_k (m_k - m)(m_k - m)^T \quad (6)$$

( $N_k$ 는 클래스  $C_k$ 의 데이터 수)

단계 6 : Sw(Within Class의 Covariance Matrix)

PCA에서 Eigen Vector값으로 추출한 각 열의 이미지의 각 Class의 평균에서 PCA를 통하여 변환된 이미지의 전체 평균을 차감.

$$S_W = \sum_{k=1}^M S_k = \sum_{k=1}^M \sum_{x_i \in C_k} (y_i - m_k)(y_i - m_k)^T \quad (7)$$

( $N_k$ 는 클래스  $C_k$ 의 데이터 수)

단계 7 : 이미지의 인식을 위한 고유치 분석을 통해

$S_W^{-1}S_B$ 의 고유치행렬  $\Lambda'$ 과 고유벡터행렬  $U'$ 를 선택.

$$S_W^{-1}S_B = U' \Lambda' U'^T$$

$$= [u'_1, u'_2, \dots, u'_n] \begin{bmatrix} \lambda'_1 & 0 & \dots & 0 \\ 0 & \lambda'_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda'_n \end{bmatrix} [u'_1, u'_2, \dots, u'_n]^T \quad (8)$$

단계 8 : 인식을 위해 선택되는 고유벡터를  $U'$ 를 PCA를 통해 특징을 구한  $Y$ 와의 곱으로 선택.

$$Y' = U'^T Y \quad (9)$$

단계 9 : 단계 2 ~ 단계 8의 과정은 행에 대한 방향의 특징벡터를 구하는 과정이고 열에 대한 과정을 한 번 더 수행함으로써 열에 대한 특징벡터  $V$ 를 구해 최종적인 벡터 생성.

$$Y'' = Y' V \quad (10)$$

### 3. 제안된 지능형 패턴 분류기

본 장에서는 전처리 과정에서 구한 특징벡터를 입력으로 사용하여 인식률을 산출하는 지능형 패턴 분류기인 다항식 기반 방사형 기저함수 신경회로망에 대해 서술한다. 구조는 전처리, 조건부, 결론부, 추론부 4가지의 기능적 모듈로 구성되어 있으며 식 (11)과 같이 퍼지규칙 표현과 같이 언어적 관점에서 해석될 수 있다. 전처리 과정은 앞장에서 설명하였으므로 나머지 부분에 대해 서술한다.[3][4]

$$\text{If } x \text{ is } A_i \text{ then } f_{ji}(x) \quad (11)$$

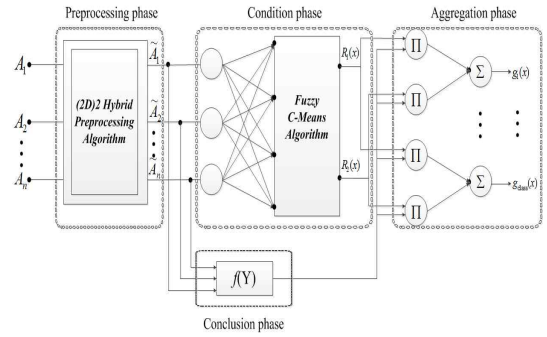


그림 3. 제안된 지능형 패턴 분류기의 구조

Fig. 3. Architecture of proposed intelligent pattern classifier

#### 3.1 다항식 기반 방사형 기저함수 신경회로망 조건부

조건부는 일반적인 신경회로망의 은닉층을 의미하며 은닉층의 노드수는 사용자에게 의해 결정되고 각 노드마다 입력 변수 개수만큼의 활성화함수가 존재한다. 활성화함수로는 정규 분포 형태의 방사형 기저함수를 사용한다. 여러 종류의 활성화함수 중 일반적으로 가우시안 함수를 사용하지만 이러한 가우시안 형태를 대신하여 조건부를 FCM클러스터링 알고리즘으로 구성하였다. FCM클러스터링은 하나의 클러스터에 속해져 있는 각각의 데이터 점을 소속정도에 의해서 클러스터에 대한 데이터 소속 정도를 일일이 열거한 데이터 알고리즘이다. 알고리즘 순서는 다음과 같다.[5~7]

단계 1 : 클러스터의 개수, 퍼지화 계수를 선택하고 소속 함수  $U^{(0)}$ 를 초기화 한다.

$$U^{(0)} = \left\{ u_{ik} \in [0, 1], \sum_{i=1}^c u_{ik} = 1 \forall k, 0 < \sum_{k=1}^n u_{ik} < n \forall i \right\} \quad (12)$$

단계 2 : 각 클러스터에 대한 중심 벡터를 구한다.

$$v_{ij} = \frac{\sum_{k=1}^n (u_{ik})^m X_{kj}}{\sum_{k=1}^n (u_{ik})^m} \quad (13)$$

단계 3 : 중심과 데이터와의 거리를 계산, 새로운 소속함수  $U^{(1)}$  계산

$$d_{ik} = d(x_k - v_i^{(r)}) = \left[ \sum_{j=1}^l (x_{kj} - v_{ij}^{(r)})^2 \right]^{1/2} \quad (14)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left( \frac{d_{ik}}{d_{jk}} \right)^{2/(m-1)}} \quad (15)$$

단계 4 : 오차가 허용범위 안에 도달하면 종료하고, 그렇지 않으면 단계 2로 돌아간다.

$$\| U^{(r+1)} - U^{(r)} \| \leq \epsilon \quad (16)$$

**3.2 다항식 기반 방사형 기저함수 신경회로망 결론부**

결론부는 조건부에서 분리한 각 로컬 영역을 다항식 함수의 로컬 회기모델로서 표현하며 식 (11)의 “then” 이후의 규칙을 형성한다. 식 (11)의  $f_{ji}(\mathbf{x})$ 에서 출력 뉴런에 대한 첨자  $j(=1, \dots, s)$ 를 생략한  $f_i(\mathbf{x})$ 는 식 (17)-(19)의 형태를 갖는 세 가지 타입의 함수 중 하나의 형태를 갖는다. 즉, 로컬 회기 모델은 상수항, 일차식 또는 이차식으로 표현되어진다.[8]

$$\text{Constant : } f_i(\mathbf{x}) = a_{i0} \tag{17}$$

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

Quadratic :

$$f_i(\mathbf{x}) = a_{i0} + \sum_{j=1}^n a_{ij}x_j + \sum_{j=1}^n \sum_{k=1}^n a_{ijk}x_jx_k \tag{19}$$

만약 입력 공간의 차원이 매우 클 경우 식 (19)의 2차 항에 대해 입력변수들의 조합수가 증가하여 계산 량이 크게 증가하기 때문에 식(20)로 표현되는 감소된 2차 함수를 사용하여 계산 량을 줄인다.

Reduced Quadratic :

$$f_i(\mathbf{x}) = a_{i0} + \sum_{j=1}^n a_{ij}x_j + \sum_{k=1}^n a_{ijk}x_k^2 \tag{20}$$

다항식 파라미터 계수를 추정하기 위해서 가장 최소자승법 (Weighted Least Square Estimation : WLSE)을 사용하였다. WLSE는 회귀다항식의 계수를 추정하는 알고리즘이며 LSE와 유사하다. LSE는 오차제곱의 합이 최소가 되도록 계수를 추정하지만, WLSE는 오차제곱의 가중치가 곱해진다는 차이가 있다. LSE는 다항식의 계수를 한꺼번에 구하기 때문에 전역 모델의 학습을 수행하고, 입력변수와 멤버쉽 함수의 수가 많아지면 퍼지 규칙수가 기하급수적으로 늘어나기 때문에 컴퓨터 연산을 수행하지 못하는 경우가 발생한다. 하지만 WLSE는 각 규칙의 독립적으로 구하며 로컬학습을 수행한다. 각 로컬영역에 대한 해석력을 향상시킬 수 있는 장점이 있어 컴퓨터의 계산부하를 줄일 수 있고 서로 다른 형태의 다항식으로 표현될 수 있다.

본 논문에서 제안한 다항식 기반 방사형 기저함수 신경회로망은 기존의 상수항의 연결가중치를 1차식과 2차식으로 확장함으로써 은닉층 뉴런의 출력간의 비선형 결합으로 인해 분류기로서의 성능을 향상시킨다.

**3.3 다항식 기반 방사형 기저함수 신경회로망 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 3의 추론부의 “II”로 표기된 뉴런에 의해 입력신호들은 합하여져 그 결과를 출력층 뉴런의 최종 출력으로 내보내지고 식 (21)과 같다.

$$y_j = g_j(\mathbf{x}) = \frac{\sum_{i=1}^c u_i f_{ji}(\mathbf{x})}{\sum_{k=1}^c u_k} = \sum_{i=1}^c u_i f_{ji}(\mathbf{x}) \tag{21}$$

여기서,  $u_i$ 는 그림 3의  $R_i(\mathbf{x})$ 와 같고,  $g_j(\mathbf{x})$ 는 다항식 기반 RBFNNs의  $j$ 번째 클래스에 대한 판별함수가 되며 패턴 분류율을 계산하는 척도가 된다.

**3.3 ABC알고리즘을 이용한 파라미터 최적화**

Artificial Bee Colony(ABC) 알고리즘은 꿀벌 집단의 먹이를 수집하는 행동양식에서 아이디어를 얻어 최적화 알고리즘으로 2005년 Karaboga에 의해 소개되었다. ABC 최적화 알고리즘은 일 벌, 탐색 벌, 스카우트 벌로 구성된 세 개의 연산자를 사용하여 탐색을 수행하며 순서는 다음과 같다.[9~11]

단계 1 : 초기 파라미터 설정 및 탐색공간 내에서 임의의 지역해를 생성

$$D_i(t) = [x_1(t), x_2(t), \dots, x_n(t)] \tag{22}$$

$$NP(t) = [D_1(t), D_2(t), \dots, D_s(t)] \tag{23}$$

단계 2 : 식 (24)을 이용하여 일 벌을 s개 생성하고 목적함수 평가 및 적합도 생성

$$v_{ij}(t+1) = x_{ij}(t) + \Phi_{ij}(x_{ij}(t) - x_{kj}(t)) \tag{24}$$

여기서,  $\Phi$ 는 [-1 1]의 랜덤상수이며,  $i$ 와  $k$ 는 개체의 번호를 나타내고,  $i \neq k$ 를 만족한다.

단계 3 : 식 (25)을 이용하여 적합도를 [0, 1] 사이의 확률 값으로 변환

$$p_i = \frac{fit_i}{\sum_{j=1}^s fit_j} \tag{25}$$

여기서,  $i$ 와  $j$ 는 개체의 수를 나타낸다.

단계 4 : 위의 식과 확률값  $p_i$ 를 이용하여 정찰 벌을 s개 생성하고 목적함수를 평가

단계 5 : 스카우트 벌을 통해 제한 조건을 만족하는 해를 판별. 만약 조건을 만족하는 해는 제거되고 새로운 해를 임의로 생성.

단계 6 : 종료조건을 만족할 때까지 단계 2 ~ 5를 반복 수행

**4. 시뮬레이션 및 결과**

제안된 분류기의 성능평가를 위해 얼굴인식에서 성능 평가의 척도로 많이 사용되는 Yale data와 AT&T data를 사용하여 성능을 평가한다. 전체 데이터를 3-split으로

Training, Validation, Testing으로 나누고, k-fold cross validation을 사용하여 전체 데이터를 k개로 분할하여 한번 씩 Testing 하여 나온 인식률의 평균을 최종 인식률로 산출한다. 모든 데이터를 한번 씩 Testing 함으로써 인식률의 대한 견고함을 가졌다. 최종 패턴 분류율 식은 (26)와 같다.

$$PCR[\%] = 100 - \left( \frac{Err}{N_{tr}} \times 100 \right) \quad (26)$$

여기서,  $Err$ 은 분류 실패 횟수를 나타내며,  $N_{tr}$ 은 학습 데이터의 수를 나타냄

표 1은 실험에 사용된 데이터 및 클래스 정보를 나타내고, 표 2는 ABC최적화 알고리즘의 설정 파라미터 및 최적화 파라미터 탐색 범위를 나타낸다.

표 1. 실험에 사용된 데이터  
Table 1. Data used in experiments

Data	Yale	AT&T
No. of classes	15	10
No. of images	16	40
No. of total data	165	400

표 2. ABC 알고리즘의 초기 설정 파라미터 및 파라미터 탐색범위

Table 2. Initial setup parameters of ABC algorithm and searching range

Parameters		Values
No. of generations		50
No. of populations		Employed Bee : 30 Onlooker Bee : 30
Limit		30
Random value[ $\Phi$ ]		[-1 1]
Search range	Fuzzification Coefficient	[1.1 5]
	No. of clusters	[2 10]
	No. of row eigenvectors	[2 10]
	No. of column eigenvectors	[2 10]

표 3은 제안된 분류기의 성능을 평가하기 위해 ASM을 거친 데이터와 다른 특징 추출 알고리즘으로 비교 분석 해 본다.

표 3. 기존 분류기와의 성능 비교

(a) Yale data (b) AT&T data

Table 3. Comparison of performance with other classifiers. (a) Yale data (b) AT&T data

(a)	Classification Rate [%]	
Preprocessing Method	Yale	
	RBFNNs	ASM+ RBFNNs
PCA	<b>87.78</b> (±8.07)	87.22 (±4.43)
PCA&LDA	87.22 (±3.89)	<b>87.22</b> (±4.43)
(2D) <sup>2</sup> PCA	95.00 (±5.05)	<b>95.55</b> (±3.71)
(2D) <sup>2</sup> LDA	97.22 (±3.27)	<b>98.51</b> (±1.14)
<b>(2D)<sup>2</sup> Hybrid</b>	97.22 (±2.50)	<b>97.78</b> (±0.00)

(b)	Classification Rate [%]	
Preprocessing Method	AT&T	
	RBFNNs	ASM+ RBFNNs
PCA	<b>85.00</b> (±2.04)	84.50 (±4.37)
PCA&LDA	88.00 (±5.62)	<b>89.25</b> (±3.54)
(2D) <sup>2</sup> PCA	86.75 (±5.00)	<b>87.75</b> (±3.71)
(2D) <sup>2</sup> LDA	91.25 (±3.17)	<b>92.62</b> (±3.55)
<b>(2D)<sup>2</sup> Hybrid</b>	94.00 (±3.16)	<b>94.25</b> (±2.37)

## 5. 결론 및 향후과제

본 논문에서는 전처리 과정을 통한 입력 이미지의 처리 기법과 다항식 기반 방사형 기저함수 신경회로망을 제안하여 인식 성능을 확인하였다. 패턴분류를 할 때 가장 중요한 것은 입력데이터를 잘 표현하는 것도 있지만 얼마만큼의 데이터를 사용하여 가장 효율적인 성능을 결정하는 것도 중요한 문제이다. 본 논문에서는 (2D)<sup>2</sup>방법을 사용하여 횡과 열의 고유벡터의 수를 조절하여 최적의 입력데이터의 수를 찾았다. 퍼지화 계수는 각 클러스터의 소속함수의 형태를 결정하는 매우 중요한 요소이고 클러스터의 수를 조절함으로써 입력 공간을 효율적으로 분류 하였다. 또한 연결가중치는 1차 선형식만을 사용하였다. 2차식이나 변형된 2차식도 있지만 1차 선형식만을 사용한 이유는 데이터 분류에 있어 3-split으로 나누었기 Training과 Validation을 가장 잘 표현하기 때문에 최적화 파라미터에서 제외 시켰다. 분류기의 최적의 설계를 위한 ABC알고리즘 통해 최적화 파라미터들을 동조하였다.

실험결과로는 ASM을 거친 데이터가 전반적인 성능이

우수하고 제한한 하이브리드 방식이 다른 전처리 방법에 비해 높은 성능을 보였지만 많은 차이는 볼 수 없었다. 그렇지만 입력데이터를 1차원으로 변환하는 방법보다 2차원이 미지를 사용하는 (2D)<sup>2</sup>방식이 우수함을 알 수 있었다.

향후 과제로는 최적화 파라미터로 전처리 기법을 추가하여 제한한 분류기의 적합한 전처리 기법을 찾아내는 분류기를 설계할 것이고 추가적인 데이터베이스 확장으로 분류기의 성능을 평가할 필요가 있다.

## References

- [1] Daoqiang Zhang and Zhi-Hua Zhou, "(2D)2PCA: 2-Directional 2-Dimensional PCA for Efficient Face Representation and Recognition", *IEEE*, Volume 69, Issues 1-3, pp 224-231, 2003
- [2] Waiyawut Sanayha and Yuttapong Rangsanteri, "Relevance-Weighted (2D)2LDA Image Projection Technique for Face Recognition", *ETRI Journal*, Volume 31, Number 4, pp438-447, 2009
- [3] S. K. Oh, W. D. Kim, and W. Pedrycz, "Polynomialbased radial basis function neural networks(P-RBFNNs) realized with the aid of particle swarm optimization," *Fuzzy Sets and Systems*, vol. 163, no. 1, pp. 54-77, 2011.
- [4] R. O. Duda, P. E. Hart, and D. H. Stork, *Pattern Classification*, Wiley Interscience 2nd, 2000.
- [5] W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks," *IEEE Trans. Neural Networks*, vol. 9, no. 4, pp.601-612, 1998.
- [6] J. C. Bezdek, *Pattern recognition with Fuzzy Objective Function Algorithm*, Plenum, New York, 1981.
- [7] James C. Bezdek, Robert Ehrlich, William Full "FCM: The Fuzzy C-Means Clustering Algorithm" *Computers & Geosciences*, Vol. 10, No. 2-3, pp. 191-203, 1984.
- [8] S. P. Lloyd, "Least squares quantization in PCM," *IEEE Tran. on Information Theory*, vol. 28, no. 2, pp. 129-137, 1992.
- [9] B. Gabrys and B. Ruta, "Genetic algorithms in classifier fusion," *Applied soft Computing*, vol. 6, pp. 337-347, 2006.
- [10] K. Dervis, O. Selcuk, A Simple and Global Optimization Algorithm for Engineering Problems: Differential Evolution Algorithm, *Turk J Elec Engin*, 12 (2004) 53-60.
- [11] D. Karaboga and B. Basturk, "Artificial bee colony optimization algorithm for solving constrained optimization problems," *LNAI4529 (IFSA 2007)*, pp. 789-798, 2007.

## 저 자 소개



### 김현기(Hyun-Ki Kim)

1977년 : 연세대학교 전기공학과 공학사  
 1985년 : 연세대학교 전기공학과 공학석사  
 1991년 : 연세대학교 전기공학과 공학박사  
 1997년~2010년 : 경기지역 산학연 기술지원단 단장  
 1998년~현재 : 사업기술정책연구소 심의위원

2000년~현재 : 사단법인 산학연 컨소시엄 적극협의회 회장  
 1989년~현재 : 수원대학교 전기공학과 교수

관심분야 : Automatic System and Control, Intelligent Modeling and Control.

Phone : +82-31-220-2666

E-mail : hkim@suwon.ac.kr



### 진용탁(Yong-Tak Jin)

2013년 : 수원대학교 전기공학과 졸업.  
 20013~현재 : 동 대학원 석사과정.

관심분야 : Fuzzy Inference, Neural Network, Evolutionary Optimization, Granular Computing

Phone : +82-31-222-6544

E-mail : jinyt@suwon.ac.kr



### 오성권(Sung-Kwon Oh)

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

2005~현재 : 수원대학교 전기공학과 교수, 2002~현재 대한전기학회, 제어로봇시스템학회, 퍼지 및 지능시스템학회 편집위원, Information Sciences의 Associate Editor.

관심분야 : 퍼지시스템, 퍼지-뉴럴네트워크, 자동화 시스템, 고급 computational intelligence, 지능제어 등.

Phone : +82-31-229-8162

E-mail : ohsk@suwon.ac.kr