

논문 2014-51-1-24

(2D)²PCA 알고리즘을 이용한 pRBFNNs 패턴분류기 기반 얼굴인식 시스템 설계

(Design of pRBFNNs Pattern Classifier-based Face Recognition System
Using 2-Directional 2-Dimensional PCA Algorithm)

오 성 권*, 진 용 탁**

(Sung-Kwun Oh[Ⓢ] and Yong-Tak Jin)

요 약

본 연구에서는 (2D)²PCA 알고리즘을 이용한 pRBFNNs 패턴분류기 기반 얼굴인식 시스템을 설계하였다. 기존의 1차원 PCA는 행과 열의 곱으로 표현한 이미지의 차원을 축소한다. 하지만 (2D)²PCA(2-Directional 2-Dimensional Principal Components Analysis)는 이미지의 행과 열에서 각각 차원축소를 수행한다. 그 다음 제안된 지능형 패턴분류기로 축소된 이미지를 사용하여 성능을 평가한다. (pRBFNNs)로 성능 평가를 한다. 제안된 다항식 기반 RBFNNs은 조건부, 결론부, 추론부 세 가지의 기능적 모듈로 구성되어 있고 조건부 퍼지 클러스터링을 사용하여 입력 공간을 분할하고, 결론부는 RBFNNs의 연결가중치로 일차 선형식으로 표현한다. 또한 차분진화 알고리즘을 이용하여 제안된 분류기의 파라미터, 즉 입력의 수, 퍼지 클러스터링의 퍼지화 계수를 최적화 한다. 얼굴인식에 많이 사용되는 Yale과 AT&T를 사용하여 인식률을 평가하였다. 실험 평가를 위해 IC&CI 연구실 데이터를 추가하여 실험하였다.

Abstract

In this study, face recognition system was designed based on polynomial Radial Basis Function Neural Networks(pRBFNNs) pattern classifier using 2-directional 2-dimensional principal component analysis algorithm. Existing one dimensional PCA leads to the reduction of dimension of image expressed by the multiplication of rows and columns. However (2D)²PCA(2-Directional 2-Dimensional Principal Components Analysis) is conducted to reduce dimension to each row and column of image. and then the proposed intelligent pattern classifier evaluates performance using reduced images. The proposed pRBFNNs consist of three functional modules such as the condition part, the conclusion part, and the inference part. In the condition part of fuzzy rules, input space is partitioned with the aid of fuzzy c-means clustering. In the conclusion part of rules, the connection weight of RBFNNs is represented as the linear type of polynomial. The essential design parameters (including the number of inputs and fuzzification coefficient) of the networks are optimized by means of Differential Evolution. Using Yale and AT&T dataset widely used in face recognition, the recognition rate is obtained and evaluated. Additionally IC&CI Lab dataset is experimented with for performance evaluation.

Keywords : 2-Directional 2-Dimensional principal component analysis, pRBFNNs, FCM, WLSE, DE

* 정회원, ** 학생회원, 수원대학교 전기공학과
(Dept.of Electrical Engineering, Suwon University)

Ⓢ Corresponding Author(E-mail: ohsk@suwon.ac.kr)

※ 본 연구는 경기도의 경기도지역협력연구센터사업의 일환으로 수행하였음[GRRC 수원2013-B2, U-city 보안감시 기술협력센터], 그리고 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2012-003568)

접수일자: 2013년9월26일, 수정완료일: 2013년12월24일

I. 서 론

얼굴인식 기술은 차세대 바이오인식 기술 중 하나다. 현재 전 세계 나라가 얼굴인식 관련 알고리즘과 제품을 만드는데 아낌없는 투자가 이루어지고 있는 것은 거짓 없는 사실이다. 이러한 사실에 본 논문에서는

(2D)²PCA 알고리즘을 이용한 pRBFNNs 패턴분류기 기반 얼굴인식 시스템을 설계하였다. 기존 얼굴인식이 가장 많이 겪은 어려움은 바로 주변여건의 변화이다. 얼굴은 빛에 따라 윤각이 바뀌고 어두운 실내이면 인식이 떨어질 수밖에 없다. 이러한 문제를 해결하기 위해 히스토그램 평활화를 이용해 인식에 사용되는 모든 이미지의 명암도를 고르고 만들어 주었고, 주변 영상과 얼굴을 분리하기 위해 Adaboost 알고리즘을 사용하였다. 얼굴 영역을 추출한 이미지에 대표적인 차원 축소 기법은 PCA를 1차원이 아닌 2차원 축소를 통해 많이 사용하는 1차원 PCA보다 이미지의 특징을 최대한으로 잘 나타낸 차원만을 추출하여 얼굴을 인식하는데 사용하였다. 그리고 얼굴 인식을 위해 다항식 기반 방사형 기저 함수 신경회로망 지능형 패턴 분류기를 구축하였다. 구축된 지능형 패턴분류기는 조건부로 FCM 클러스터링을 사용하였고, 연결 가중치는 상수항에서 2차식 이상까지 확장하여 성능을 개선시켰다. 다항식 차수의 파라미터를 독립적으로 결정하는 WLSE를 사용하였고, 최적화 기법으로 DE를 사용하여 퍼지화 계수, 입력의 수를 최적화 하였다. 제안된 지능형 패턴 분류기의 성능 평가를 위해 보편적으로 얼굴인식에 많이 사용되는 Yale과 AT&T 데이터를 사용하였다.

II. 본 론

1. 이미지 전처리 기법

제안된 분류기로 인식률을 산출하기 위해서는 입력 이미지 잘 다듬는 것이 매우 중요한 사실이다. 입력 이미지를 전처리 과정 없이 그대로 사용 할 수도 있겠지만, 그렇게 되면 사진의 왜곡된 부분이나 실제 얼굴영역이 아닌 다른 부분으로도 인식을 수행 할 수 있기 때문에 전처리 과정은 매우 중요하다. 본 논문에서는 조명에 의한 인식률을 최소화하기 위해 히스토그램 평활화를 실시하였고, 이미지에서 얼굴 영역만을 분리하기 위해 Adaboost 알고리즘을 사용하였다. 또한 이미지의 표현을 최대화하기 위해 특징추출 알고리즘인 (2D)²PCA를 사용하였다. 전처리 과정을 거친 데이터를 제안된 분류기의 입력으로 사용하여 인식률을 산출하였다.

가. 히스토그램 평활화

히스토그램이란 도수 분포의 상태를 기둥 모양의 그

래프로 나타낸 것으로 우리는 이미지의 한 픽셀의 값을 그래프로 나타내었다. 히스토그램 평활화는 좁은 명암 영상의 밝기 분포를 균일한 분포를 나타낼 수 있도록 변환해주는 영상 처리의 한 기법으로 명암의 분포를 재분배 및 새로운 값으로 설정하는 과정을 의미한다. 명암이 일정하게 되면 희고 검은 부분이 명확하게 드러남으로써 좀 더 깔끔한 영상이 되고 특징 추출 알고리즘을 사용하기 위해서도 이미지의 화질을 개선시키는 것이 좀 더 많은 특징을 표현할 수 있기 때문에 히스토그램 평활화는 얼굴 인식 사용에 있어 인식률을 개선시키는데 매우 중요한 역할을 차지하고 있다.

히스토그램 평활화는 다음 세 단계를 거쳐 영상을 화질을 개선시킨다.

[단계 1] 영상의 히스토그램 생성.

[단계 2] 식(1)을 이용하여 히스토그램의 정규화 및 누적합을 계산.

$$h(i) = \frac{G}{N} \times H(i) \tag{1}$$

G : 영상의 밝기 N : 영상의 크기

H(i) : 정규화 누적값 h(i) : 보정 값

[단계 3] 입력영상의 화소 위치에 새로운 출력 맵핑

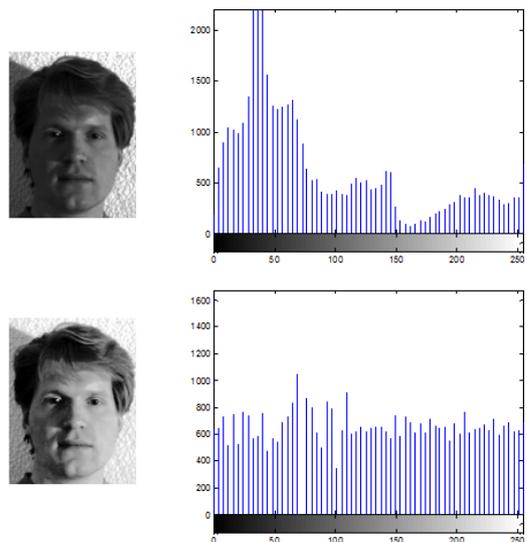


그림 1. 히스토그램 평활화

Fig. 1. Histogram Equalization.

나. Adaboost 알고리즘을 이용한 얼굴영역 추출

Adaboost 개념은 예측 성능이 조금 떨어지는 규칙이지만 이들을 조합하여 더 높은 성능을 발휘하는 효과적인 방법을 찾는 것으로 즉 약한 분류기가 결합하여 성능이 우수한 강한 분류기 하나를 만들겠다는 의미이다. Harr-like Feature를 이용하는데 Harr-like Feature란 Harr-like Filter에 의해 계산되며, 0 또는 1의 값을 갖는다. Harr-like Feature의 형태는 무수히 많이 존재 할 수 있으며, 각각은 물체 분류를 위한 Classifier로서 사용된다. 하지만 Harr-like Filter만으로 강건하게 물체 분류를 하는 것은 불가능하기 때문에 이를 해결하기 위하여 Adaboost 알고리즘을 사용하였다. 무수히 많은 Harr-like Filter들 중 가장 효과적인 것들만을 선택하고, 이들을 선형 조합하여 최종 Classifier를 구성하는 것이다.

그림 3은 연속적인 연결 구조를 나타내며 얼굴영역을 찾아가는 과정을 나타내었다.



그림 2. Haar-like Feature의 종류
Fig. 2. kind of Haar-like Feature.

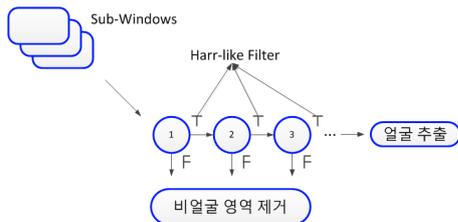


그림 3. 연속적인 연결구조
Fig. 3. A series of connection structure.

다. 특징 추출 기법 (2D)²PCA를 이용한 차원 축소
제한된 분류기의 입력으로 사용하기 위한 마지막 단계인 (2D)²PCA^[1~2]과정은 이미지를 표현하는데 있어 매우 중요하다. 기존의 PCA방법은 입력받은 이차원의 이미지를 1차원으로 변환 후 특징 추출 및 차원을 축소하는 과정을 의미하는 것이고, (2D)²의 의미는 두 방향 이차원이라는 뜻으로 입력받은 이차원 데이터를 일차원으로 변환하는 과정 없이 횡에서 한번 열에서 한번 특

징 추출 및 차원을 축소하는 과정을 의미한다. 이론적으로 같은 알고리즘이나 차원을 축소하는 크기에 있어 큰 차이를 보인다. 112*92의 사진을 벡터화하면 10304*1이 된다. 따라서 공분산 행렬의 크기는 10304*10304이 되어 계산이 매우 복잡해지고 공분산의 고유벡터를 정확히 구하는데 어려움이 따른다. 하지만 2차원 PCA는 2차원 이미지 자체를 행렬로 두고 공분산 행렬을 구하기 때문에 공분산 행렬의 크기가 112*112와 92*92 밖에 되지 않아 데이터 처리하는데 있어 기존 일차원 PCA 보다 데이터 차원이 낮다.

본 논문에서는 히스토그램 평활화와 Adaboost알고리즘을 거친 이미지를 (2D)²PCA알고리즘을 이용하여 차원을 축소하는 과정을 전처리 과정 마지막에 수행하였고, 단계 설명은 다음과 같다.

[단계 1] 전체 학습이미지 데이터의 개수를 M개, 이때 n 번째 학습이미지를 $A_n^{R \times C}$ 행렬(n=1,2,...,M)로, 학습이미지의 샘플들의 평균 이미지를 $\bar{A}^{R \times C}$ 로 나타낸다고 하자. 이때 이 학습이미지 세트들의 이미지 열의 공분산 행렬 RG_t 는 다음의 식으로 계산된다.

$$RG_t = \frac{1}{M} \sum_{n=1}^M (A_n - \bar{A})^T (A_n - \bar{A}) \quad (2)$$

[단계 2] RG_t 와 같이 행의 공분산 행렬 LG_t 는 다음의 식으로 계산된다.

$$LG_t = \frac{1}{M} \sum_{n=1}^M (A_n - \bar{A})(A_n - \bar{A})^T \quad (3)$$

공분산행렬 $RG_t^{R \times R}$ 행렬이 되고, $LG_t^{C \times C}$ 행렬이 된다.

[단계 3] 공분산 행렬 $RG_t^{R \times R}$ 의 고유 값 $\lambda_R^{R \times R}$ 과 이에 대응하는 고유벡터 $U_R^{R \times R}$ 을 계산한다.

[단계 4] 단계 3과 같이 공분산 행렬 $LG_t^{C \times C}$ 의 고유 값 $\lambda_L^{C \times C}$ 과 이에 대응하는 고유벡터 $U_L^{C \times C}$ 을 계산한다.

[단계 5] 단계 3, 단계 4에서 나온 고유 값 $\lambda_R^{R \times R}$ 와

$\lambda_L^{C \times C}$ 대해 고유 값이 큰 순서대로 다시 재배열하고, 재배열된 고유 값에 대해 고유 벡터도 재배열한다.

[단계 6] 재배열된 고유벡터들을 줄이고 싶은 차원의 수 d만큼 차원을 줄이게 되면 $U_{dR}^{R \times d}$, $U_{dL}^{C \times d}$ 이 된다.

[단계 7] d만큼 차원을 줄인 벡터 $U_{dR}^{R \times d}$ 와 $U_{dL}^{C \times d}$ 가지고 실제 전체 이미지를 얻는 식은 다음과 같다.

$$\tilde{A}_j = \sum_{j=1}^M U'_{dR} \times A_j \times U_{dL}, \tilde{A}^{d \times d} = [\tilde{A}_1, \tilde{A}_2, \dots, \tilde{A}_M] \quad (4)$$

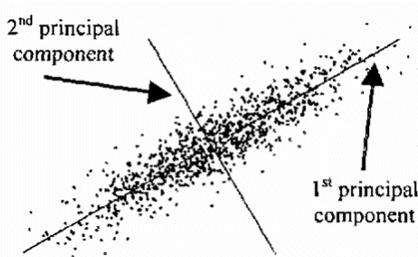


그림 4. (2D)²PCA를 이용한 차원 축소
Fig. 4. Dimensional Reduction Using 2-Directional 2-Dimensional Principal Component Analysis.

2. 제안된 지능형 패턴분류기

본 논문에서 제안된 지능형 패턴분류기는 다항식 기반 방사형 기저함수 신경회로망^[3-5]으로 기존의 신경회로망에서 전처리 부분을 결합해 4가지의 기능적 모듈로 동작한다.

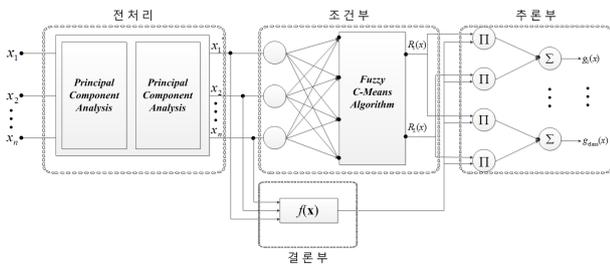


그림 5. 제안된 지능형 패턴분류기 구조
Fig. 5. The Proposed Intelligent Pattern Classifier Structure.

가. 제안된 지능형 패턴분류기 구조

기존의 신경회로망 은닉층의 활성화함수로 많이 쓰이는 가우시안 함수 대신에 제안된 지능형 패턴분류기에서는 활성화함수로 FCM클러스터링을 사용하였다. 클러스터링은 데이터의 분류에서 사용되는 알고리즘으로 데이터 안의 유사한 패턴, 속성, 형태 등의 기준을 통하여 데이터를 분류하여 내부의 구조를 찾아내는 알고리즘이다. 전처리 과정을 거친 입력데이터가 은닉층으로 들어오면 특정 데이터는 FCM클러스터링^[7-8]을 통해 클러스터 개수만큼의 중심점과 데이터 사이의 소속정도를 나타내는 소속값을 계산하여 이를 활성화함수의 적합도 개념과 동일하게 사용하였고 식(5)와 같다.

$$u_{ik} = \frac{(1/\|y'_k - v_i\|^2)^{1/m-1}}{\sum_{j=1}^c (1/\|y'_k - v_j\|^2)^{1/m-1}} = \frac{1}{\sum_{j=1}^c (d_{jk}/d_{ik})^{2/m-1}} \quad (5)$$

d_{ik} 는 식(6)와 같이 유클리드 거리로 표현된다.

$$d_{ik} = d(y'_k - v_i) = [\sum_{j=1}^s (y'_{ki} - v_{ij})^2]^{1/2} \quad (6)$$

여기서 u_{ik} 는 0과 1사이의 값이며, i번째 클러스터에 속해져 있는 y'_k 의 k번째 데이터의 소속정도이며, v_i 는 i번째 클러스터 중심벡터이다. j는(j=1,2,...,s) 특성 공간상의 변수이며, m은 퍼지화 계수이다.

은닉층과 출력층 사이의 연결가중치는 1차 선형식으로 구성하였으며 식(7)과 같다.

$$\text{Linear } f_i(Y') = a_{i0} + \sum_{j=1}^n a_{ij}y_j \quad (7)$$

1차 선형식의 다항식 계수를 추정하는 방식으로 WLSE(weighted Least Square Estimation)^[6]을 사용하여 각 파라미터를 독립적으로 구하여 로컬 학습을 하였으며 독립적으로 구하기 때문에 실제 출력과 비교가 쉽고 해석능력도 향상된다는 장점이 있다.

$$a_j = (X_j^T U_j X_j)^{-1} X_j U_j Y, \quad (a_j = a_{j0}, a_{j1}, \dots, a_{jk}) \quad (8)$$

여기서 a_j 는 추정하고자 하는 j번째 다항식의 계수, Y는 출력데이터, U_j 는 j번째 입력공간에 대한 입력 데

이터들의 소속값을 의미한다. X_j 는 j번째 국부 모델의 계수를 추정하기 위한 입력 데이터 행렬을 의미한다. 본 논문에서 사용한 1차 선형식일 경우 다음 식 (9)처럼 정의 된다.

$$X_j = \begin{pmatrix} 1 & x_{11} & \cdots & x_{1k} \\ 1 & x_{21} & \cdots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{p1} & \cdots & x_{pk} \end{pmatrix} \quad U_j = \begin{pmatrix} u_{j1} & 0 & \cdots & 0 \\ 0 & u_{j2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & u_{jp} \end{pmatrix} \quad (9)$$

여기서 p는 전체 데이터의 수이다. 분류기의 최종 출력은 은닉층에서 구한 소속행렬과 다항식의 선형 조합으로 구성하였으며 식(10)과 같다.

$$g_q(Y) = \sum_{i=1}^c \dot{R}_i(Y) f_{iq}(Y) \quad (10)$$

\dot{R}_i 는 정규화된 적합도를 의미하며, $q(q=1, \dots, class)$ 는 출력층의 노드를 가리키는 동시에 클래스를 나타낸다.

나. 제안된 지능형 패턴분류기 최적화

진화알고리즘은 컴퓨터가 다룰 수 있는 모든 문제를 해결 할 수 있다. 하지만 문제 영역에 대한 지식이 충분치 않고, 해결 방안이 알려져 있지 않은 문제나 국부적인 탐색에 의존했던 문제에서 전역 해를 찾고자 할 때 진화알고리즘을 사용하는 것이 바람직하다. 즉, 반복적이고 경험적인 발견을 통해 해를 찾아야하는 문제에 사용한다. 본 논문에서는 차분 진화 알고리즘을 적용하여 제안된 지능형 패턴분류기의 성능을 결정하는 파라미터를 동조하였다.

차분 진화 알고리즘(DE : Differential Evolution)^[9-11]은 Price와 Storn에 의해 벡터 차분을 사용하여 Chebychev 다항곡선의 내삽문제를 해결하는 과정에서 개발되었다. 차분 진화 알고리즘은 통계적 임의 탐색법인 유전자 알고리즘과 유사한 알고리즘이다. 유전자 알고리즘과 차분진화 알고리즘은 초기 개체를 샘플링하고, 교배(Crossover), 변이(Mutation), 선택(Selection)과정을 거쳐 적합도가 개선되는 새로운 개체들을 추출해낸다는 공통점이 있다. 하지만 유전자 알고리즘에서 발생하는 지역극소를 해결하였고, 또한 구조와 연산이 단순하여 수렴성이 뛰어나고 알고리즘의 제어 파라미터가 적어 병렬처리에 적합하다는 장점을 가지고 있다. 다음은 차분 진화 알고리즘의 수행 단계이다.

[step 1] 초기집단 생성 (랜덤 값으로 μ 개의 개체를 초기화, 각 개체는 n개의 목적 변수로 구성)

$$P(t) = a_1(t), a_2(t), \dots, a_\mu(t) \quad (11)$$

[step 2] 집단내의 모든 개체의 목적함수를 평가

$$\Phi(t) = \Phi(a_1(t)), \dots, \Phi(a_\mu(t)) \quad (12)$$

[step 3] 모든 개체($i=1, \dots, \mu$)에 대하여 차분 변화를 위한 개체 a_{r1}, a_{r2}, a_{r3} 를 선택하여 교배용 벡터(13)를 만들고 이를 교배 대상 벡터와 교배(14)

$$v_i(t) = a_{r3}(t) + F \cdot (a_{r2}(t) - a_{r1}(t)) \quad (13)$$

$$x'_i(t) = v_i(t) \times a_i(t) \quad (14)$$

[step 4] 모든 개체의 목적함수를 평가

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

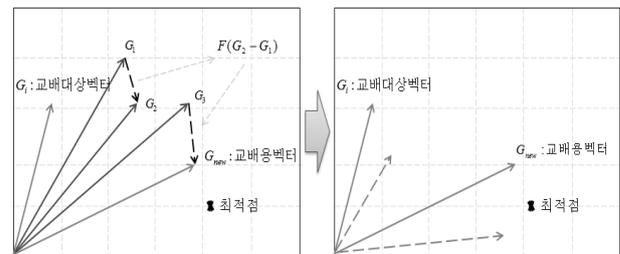


그림 6. 교배용 벡터의 생성
Fig. 6. Creation of Crossover Vector.

III. 실험

클래스 분류를 위해 판별함수를 사용하였다. 식(10)의 모델의 출력이 판별함수가 되며 클래스 수만큼의 판별함수가 존재한다. 만약 클래스가 두 개 이상으로 이루어져 있으면 식(15)을 사용하여 가장 큰 값을 나타내는 판별함수의 클래스를 선택한다.

$$g_i(x) > g_j(x) \quad (15)$$

표 1. 데이터의 분할 및 이미지 사이즈
Table 1. Image Size And Division of Dataset.

DB	Image Size	Division of Dataset		
		Total	TR	TE
Yale	178×236	165	132	33
AT&T	92×112	400	320	80
IC&CI	200×200	170	136	34

표 2. 실험 파라미터
Table 2. Experiment Parameter.

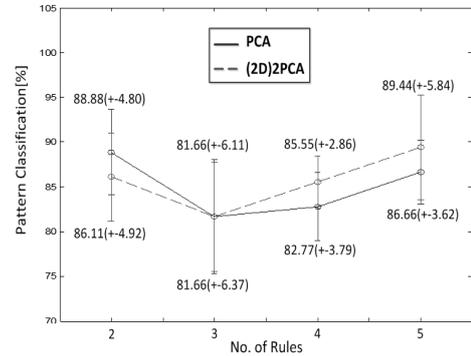
		Parameter	Value
DE	No. of Generations		60
	No. of Populations		30
	Searching Range	Fuzzification Coefficients	[1.1 3]
		No. of Inputs	Yale[1 15]
			AT&T[1 20]
IC&CI[1 5]			

여기서 i, j 는 클래스의 번호를 나타내며 $i \neq j$ 를 만족한다.

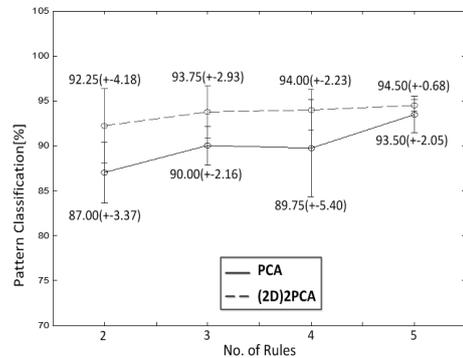
제안된 분류기의 성능을 평가하기 위해 얼굴인식에 많이 사용되는 대표적인 Open Source인 Yale Data와 AT&T Data, 그리고 수원대학교 지능 제어 컴퓨터 지능 연구실(IC&CI) Data를 사용하였다. 표1에서는 이미지의 크기와 k-Fold Cross Validation의 따른 데이터 수를 나타내었다.

k-Fold Cross Validation을 이용하여 전체 데이터를 테스트로 한번 씩 사용하여 수행을 하였고, 제안된 지능형 패턴분류기의 성능을 결정해주는 전처리 과정을 거친 입력데이터의 수와 FCM클러스터링의 퍼지화 계수를 최적화 파라미터로 동조하였다. 입력데이터의 수를 몇 개로 사용하느냐에 따라 성능의 결정적인 영향을 미친다.

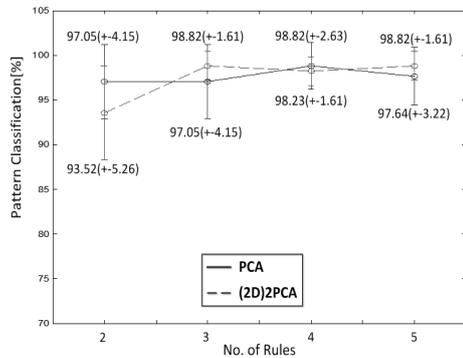
실험 파라미터에서 모두가 사용한 데이터들의 입력의 개수는 모두 다르다. 지능형 패턴 분류기를 통해 초기 세대의 Training의 인식률과 100%일 경우를 제외 입력의 개수이다. 초기 Training의 인식률이 100%일 경우 Testing이 충분히 되지 않기 실제 최적화 알고리즘을 사용한 의미가 없어진다. 밑에 그림 7은 각각의 데이터들의 인식률을 예러바로 표시한 그림이다.



(a) Yale data



(b) AT&T data



(c) IC&CI data

그림 7. 전처리 기법에 따른 인식률 결과 비교
Fig. 7. Comparison of Recognition Rate According to preprocessing method.

IV. 결 론

본 실험은 (2D)²PCA 알고리즘 이용해 지능형 패턴 분류기로 테스트 데이터 인식률을 산출하였다. 입력받은 데이터의 전처리 과정으로 adaboost를 이용해 얼굴 영역을 추출한 뒤 히스토그램 평활화를 이용하여 모든

영상의 명암도를 고르게 분포하였다. 선형특징 추출기 법인 PCA를 다르게 해석한 (2D)²을 통해 차원을 축소 하였다. 모든 전처리 과정을 거친 데이터를 입력으로 하여 제안된 pRBFNNs로 인식률을 산출하였다. 제안된 분류기의 다항식 차수로는 Linear로 고정시켰으며 노드의 수만 증가시키면서 실험을 하였다. 2차원의 이미지를 1차원으로 축소하여 사용하는 PCA 알고리즘보다 2차원의 이미지를 열과 행의 두 방향으로 모두 저차원 특징데이터를 추출하는 (2D)²PCA 알고리즘 방법이 전체적으로 모든 데이터의 인식률이 높게 나왔다.

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] H. Addi and L. J. Williams, "Principal component analysis," Wiley Interdisciplinary Reviews: Computational Ststicstics, vol. 2, no. 4, pp. 433-459, 2010.
- [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] S. P. Lloyd, "Least squares quantization in PCM," IEEE Tran. on Information Theory, vol. 28, no. 2, pp. 129-137, 1992.
- [8] 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.
- [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] R. Storm, K. V. Price, "Differential Evolution-a fastand efficient heuristic for global optimization over continuous spaces," Journal of Global Optimization, vol. 11, pp. 341-359, 1997.

저 자 소 개



오 성 권(정회원)-주저자
1981년 연세대학교 전기공학과 졸업
1983년 동 대학원 석사
1993년 동 대학원 박사
1983년~1989년 금성산전연구소 (선임연구원).

1996년~1997년 캐나다 Manitoba 대학 전기 및 컴퓨터공학과 Post-Doc.
1993년~2005년 원광대학교 전기전자 및 정보공학부 교수.
2005년~현재 수원대학교 전기공학과 교수,
2002년~현재 대한전기학회, 제어로봇시스템학회, 퍼지 및 지능시스템학회 편집위원, Information Sciences 편집위원.
<주관심분야: 퍼지시스템, 퍼지-뉴럴네트워크, 자동화 시스템, 고급 computational intelligence, 지능제어 등.>



진 용 탁(학생회원)-공동저자
2013년 수원대학교 전기공학과 졸업.
2013년~현재 동 대학원 석사과정.
<주관심분야: 퍼지추론 시스템, 뉴럴 네트워크, 패턴 인식, 진화론적 최적화 알고리즘, 얼굴인식 시스템>