



퍼지 RBFNNs와 증분형 주성분 분석법으로 실현된 숫자 인식 시스템의 설계

Design of Digit Recognition System Realized with the Aid of Fuzzy RBFNNs and Incremental-PCA

김봉연* · 오성권*† · 김진율**

Bong-Youn Kim, Sung-Kwun Oh[†], and Jin-Yul Kim

*수원대학교 전기공학과, **수원대학교 전자공학과

*Department of Electrical Engineering, The University of Suwon

**Department of Electronic Engineering, The University of Suwon

요약

본 연구에서는 퍼지 RBFNNs와 증분형 주성분 분석법으로 실현된 숫자인식 시스템의 설계를 소개한다. 주성분 분석법은 차원축소를 위해 사용되는 알고리즘으로 학습데이터의 차원 수가 고차원이거나 데이터의 양이 많을 때 특징 추출을 위한 많은 계산 시간을 필요로 한다. 따라서 고차원 데이터의 효율적인 차원축소와 점진적인 학습을 위해 증분형 주성분분석법을 적용하는 방법을 제안한다. 방사형 기저함수 신경회로망의 구조는 조건부, 결론부, 추론부의 3가지 기능적 모듈로서 구분이 가능하다. 조건부에서는 FCM 클러스터링 알고리즘의 도움으로 실현된 퍼지 클러스터링의 사용으로 입력 공간을 분할한다. 또한 가우시안 함수 대신 FCM(Fuzzy C-Means)클러스터링 알고리즘의 멤버십 값을 사용함으로써 입력 데이터의 특성을 좀 더 잘 반영할 수 있도록 개선하였으며, 결론부에서 연결가중치는 상수항에서 일차식과 이차식, 그리고 변형된 이차식과 같은 다항식의 형태로 확장하여 사용한다. 실험 결과는 공인 숫자 데이터인 MNIST 필기체 숫자 데이터를 사용하여 제안된 숫자 인식 시스템의 효율성을 다른 연구와의 비교를 통해 입증한다.

키워드 : 숫자 인식, 퍼지 RBFNNs 패턴 분류기, 증분형 주성분분석법(IPCA), Fuzzy C-Means(FCM), Least Square Estimation(LSE), MNIST 필기체 숫자 데이터

Abstract

In this study, we introduce a design of Fuzzy RBFNNs-based digit recognition system using the incremental-PCA in order to recognize the handwritten digits. The Principal Component Analysis (PCA) is a widely-adopted dimensional reduction algorithm, but it needs high computing overhead for feature extraction in case of using high dimensional images or a large amount of training data. To alleviate such problem, the incremental-PCA is proposed for the computationally efficient processing as well as the incremental learning of high dimensional data in the feature extraction stage. The architecture of Fuzzy Radial Basis Function Neural Networks (RBFNN) consists of three functional modules such as condition, conclusion, and inference part. In the condition part, the input space is partitioned with the use of fuzzy clustering realized by means of the Fuzzy C-Means (FCM) algorithm. Also, it is used instead of gaussian function to consider the characteristic of input data. In the conclusion part, connection weights are used as the extended diverse types in polynomial expression such as constant, linear, quadratic and modified quadratic. Experimental results conducted on the benchmarking MNIST handwritten digit data-base demonstrate the effectiveness and efficiency of the proposed digit recognition system when compared with other studies.

Key Words : Digit Recognition, Fuzzy RBFNNs Pattern Classifier, Incremental-PCA, Fuzzy C-Means(FCM), Least Square Estimation(LSE)

1. 서론

생체인식은 인간이 가지는 신체적 특징과 글씨체, 음성과 같은 행동학적 특성 등 고유한 특성을 사용하여 보안시스템에 활용하는 기술이다. 오늘날 사용되고 있는 대부분의 생체인식 기술은 분실 및 도용과 같은 상황에 노출이 될 수 있는 단점을 가진다. 따라서 인간의 고유한 특징을 사용하는 생체인식 기술은 분실 및 도난과 같은 문제가 발생하지 않아 다양한 분야에 적용되어지고 있으며, 인간의 뇌신경세포 및 구조를 모방하여 처리하려

Received: Jan, 19, 2016

Revised : Feb, 13, 2016

Accepted: Feb, 22, 2016

†Corresponding author

ohsk@suwon.ac.kr

본 연구는 미래창조과학부의 정보통신·방송 연구개발사업 [과제번호 : I0144-14-1016]과 창조비타민 프로젝트 그리고 2015년도 정부(미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임 (NRF-2015R1A2A1A15055365).

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.

는 신경회로망 연구 또한 활발히 진행되고 있다. 그 중에서 수기로 작성된 필기체 숫자 인식은 수표, 서명, 우편물 등과 같은 다양한 분야에 적용이 가능하여 패턴인식 관련 분야에서 중요성이 더욱 대두되고 있다[6]. 하지만 숫자 인식을 위한 데이터베이스는 고차원의 이미지로 이를 사용하는데 있어 많은 양의 계산을 필요로 하며, 전체 데이터베이스를 한 번에 차원 축소하므로 많은 양의 메모리를 요구한다.

따라서 본 연구에서는 이와 같은 단점을 보완하기 위해 주성분 분석법(PCA)[5] 대신에 증분형 주성분분석법(IPCA)[3][4]을 사용하여 차원 축소를 수행한다. 이를 방사형 기저함수 신경회로망(Radial Basis Function Neural Networks: RBFNN)[1][2] 패턴 분류기의 입력으로서 사용한다. 기존 퍼지 RBFNNs 패턴분류기에서 확장한 다항식 기반 퍼지 RBFNNs 패턴분류기는 FCM(Fuzzy C-Means)알고리즘을 사용해 은닉층의 활성화함수 형태를 표현한다. 그리고 상수항으로 사용하는 다항식 파라미터 계수의 값은 일차식, 이차식, 변형된 이차식과 같은 다양한 다항식 형태로 확장되고, 이는 최소 자승법(LSE)를 통해 추정된다. 이와 같이 다항식 형태의 연결가중치를 사용함으로써 퍼지 규칙과 같은 언어적 관점에서의 해석이 가능해졌다. 마지막으로 숫자 인식 시스템의 성능평가를 위해 공인 숫자 데이터베이스인 MNIST 데이터베이스[7]를 사용하였으며, 기존에 제안된 Linear Classifier, Quadratic Classifier, Neural Networks, Convolutional Net 등의 분류기 성능과 비교한다.

본 논문의 구성 순서는 다음과 같다. 2장에서는 데이터의 전 처리 과정으로서 PCA와 Incremental-PCA를 사용한 이미지의 차원축소 방법에 대하여 설명한다. 3장에서는 숫자 인식을 위한 다항식 기반 퍼지 RBFNNs 패턴 분류기의 구조 및 전반적인 방법에 대해 설명한다. 4장에서는 시뮬레이션 및 결과 고찰로 실험의 전체 개요와 실험에서 사용되는 MNIST 숫자 데이터베이스에 대해 설명한다. 또한 실험에서 사용하는 패턴분류기의 파라미터 설정을 통해 인식 성능을 평가 및 비교한다. 마지막으로 5장에서는 결론에 대하여 설명을 한다.

2. 숫자 이미지를 위한 전 처리 알고리즘

영상에서 획득한 이미지는 2차원의 이미지로서 고차원의 데이터로 이루어져 있기 때문에 학습 속도 및 성능을 향상시키기 위해 차원축소 알고리즘인 주성분분석법(PCA)과 PCA가 가지는 일괄(Batch)학습 방식의 단점을 보완하기 위해 증분형 주성분분석법(IPCA)을 사용하여 차원 축소를 수행한다.

2.1 주성분 분석법 (Principal Component Analysis : PCA)

PCA알고리즘[4]의 수행을 위한 숫자 이미지의 크기가 $N \times N$ 이고, 인식을 위한 이미지의 개수가 M 개 일 때 각 숫자 영상을 M 개의 $N^2 \times 1$ 행 벡터로 이미지의 숫자벡터 집합을 구성한다. 그리고 구성된 인식 이미지들의 숫자벡터 집합을 사용하면 평균영상을 구할 수 있다. 공분산 행렬을

구하기 위해 학습영상 벡터와 평균 얼굴영상 벡터의 차 영상 벡터를 구한다. 이러한 결과로 $N^2 \times M$ 행렬이 구성되며 공분산 행렬은 $N^2 \times N^2$ 의 차원을 갖는다. 공분산 행렬로부터 M 개의 고유 값 λ_i 와 이에 대응하는 고유벡터를 계산한다. 여기에 고유 값에서 얻어진 고유벡터를 $N \times N$ 로 재배열하면 숫자 이미지와 닮은 고유 이미지를 획득할 수 있다. 고유 이미지는 아래와 같은 식으로 표현되며, 고유 이미지가 구성되면 숫자 인식을 위한 학습 준비가 마무리 된다. 새로운 인식 이미지가 들어오게 되면 인식 이미지들의 평균 벡터를 이용하여 이미지의 차 벡터를 생성하고, 학습 단계에서 만든 고유 이미지에 투영하여 각 인식 이미지들과의 유클리디안 거리가 가장 작게 나오는 숫자를 인식 대상으로 판정한다. 주성분 분석법의 수행단계는 다음과 같다.

[Step 1] 인식을 위한 숫자 이미지의 벡터 집합 구성

$$S = \Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_M \quad (1)$$

[Step 2] 평균과 분산을 기준으로 정규화 수행

$$\Gamma_{ij} = (\Gamma_{ij} - \mu_i) \times \frac{\sigma}{\sigma_i} + \mu \quad (2)$$

[Step 3] 평균 숫자 벡터 계산

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n \quad (3)$$

[Step 4] 인식후보 숫자 벡터와 평균 숫자 벡터의 차 벡터를 계산

$$\Phi_i = \Gamma_i - \Psi \quad (4)$$

[Step 5] 인식후보 숫자의 공분산 행렬을 계산

$$C = \frac{1}{M} \sum_{n=1}^M \Phi_n \cdot \Phi = A \cdot A^T \quad (5)$$

[Step 6] M 개의 고유벡터에서 가장 큰 고유 값을 갖는 M' 개만을 선택

$$C = U\Lambda U^T \quad (6)$$

[Step 7] 각 인식후보 숫자와 고유벡터의 사영을 통하여 가중치를 획득

$$\Omega^T = [w_1, w_2, w_3, \dots, w_M] \quad (7)$$

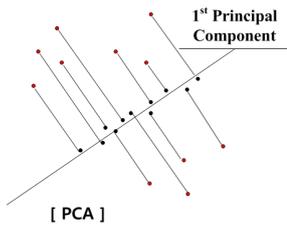


그림 1. 주성분 분석법(PCA)의 차원축소
Fig. 1. Dimensional reduction of Principal Component Analysis

2.2 증분형 주성분 분석법 (Incremental PCA)

대부분의 고차원 데이터는 각 데이터의 분포형태를 알기 어렵고, 고차원의 데이터 처리를 위해 많은 양의 메모리와 계산량을 필요하다. 따라서 고차원의 데이터를 저차원으로 축소하는 절차를 수행함에 따라 본래 데이터의 특징을 최대한 반영하여 추출하는 방법이 필요로 하다. 그 중에 대표적으로 주성분 분석법이 데이터의 특징 추출 및 차원축소에 사용되고 있다. 일반적으로 주어진 데이터셋을 학습하고자 할 때 일괄(Batch)처리 방법으로 학습이 수행되어 새로운 학습데이터가 추가되면 연산을 다시 수행해야 하는 단점이 있다. 또한 데이터가 고차원이거나 크기가 증가하게 되면 많은 양의 메모리를 필요로 하고 RBF 신경망 추론부의 파라미터가 많아져 인식 속도의 저하가 발생한다. 따라서 증분형 주성분 분석법[3]을 적용하여 학습된 데이터셋 이외의 새로운 데이터셋이 발생해도 일괄(Batch)처리 방법으로 학습을 수행하지 않고, 데이터를 그룹으로 분할하거나 또는 온라인으로 데이터 집합을 업데이트하여 수행한다. 다시 말해, PCA는 입력 데이터가 하나씩 증가하거나 새로운 데이터에 대하여 점진적인 학습과정이 필요한 애플리케이션에서의 사용이 어렵다. 또한 한 번에 많은 양의 데이터를 학습하는 방식은 많은 계산 양과 시간이 문제가 된다. 이러한 문제를 해결하고, 새로운 입력데이터에 대해서도 처리가 가능하도록 전처리 과정으로서 증분형 주성분 분석법을 적용한다. 아래는 증분형 주성분 분석법[4]의 차원축소 방법과 알고리즘을 나타낸다.

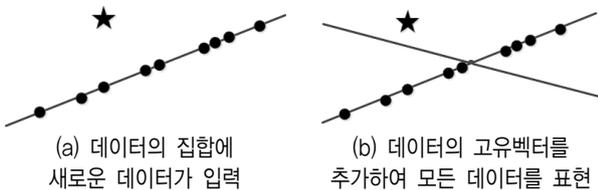


그림 2. Incremental-PCA를 이용한 차원축소
Fig. 2. Dimensional reduction using IPCA

[Step 1] N개의 데이터의 공분산으로 초기 고유 벡터와 고유 값을 계산하고, PCA를 사용하여 k차원의 특징 정보를 추출

[Step 2] 데이터 y가 추가적으로 들어왔을 때, 현재의 고유벡터 $U_{m \times k}$ 와 고유 값 λ 를 생성하기 위해 IPCA를 적용
(m : 전체영상의 차원, k : 선택된 차원)

[Step 3] 추가 입력데이터 y에 대해 식 (8)로 평균을 갱신

$$\bar{x}' = \frac{1}{N+1} (N\bar{x} + y) \tag{8}$$

여기서, \bar{x} 는 초기 입력의 평균값, \bar{x}' 는 새로운 입력을 포함한 업데이트된 평균, N은 초기 입력 영상의 개수

[Step 4] 추가 입력데이터 y에 대한 고유공간의 업데이트를 하기 위해서 현재 고유공간의 차원을 증가시킬지 아닐지에 대하여 확인

$$h = (y - \bar{x}) - U_{mk}g \tag{9}$$

$$g = U^{Tmk}(y - \bar{x}) \tag{10}$$

[Step 5] 차원의 증가여부를 결정하고 고유벡터의 업데이트를 위해 식 (11)을 풀면 $(k+1)(k+1)$ 차원의 회전벡터 R을 계산

$$\left(\frac{N}{N+1} \begin{bmatrix} A & 0 \\ 0 & T^0 \end{bmatrix} + \frac{N}{(N+1)^2} \begin{bmatrix} gg^T & \gamma g \\ \gamma g^T & \gamma^2 \end{bmatrix} \right) R = RA' \tag{11}$$

$$(\gamma = h^T(y - \bar{x}), A' : \text{업데이트 된 고유값})$$

[Step 6] U' 를 획득하기 위해 회전 벡터 R을 사용하여 기존 고유벡터 U를 업데이트한다.

$$U' = [U, \hat{h}]R, U' \in R^{m(k+1)} \tag{12}$$

$$\hat{h} = \begin{cases} \frac{h}{\|h\|^2}, & \text{if } \|h\| > \eta \\ 0 & \text{otherwise} \end{cases} \tag{13}$$

η 은 기존의 IPCA에서 사용하는 임계 값

[Step 7] IPCA의 단점을 보완하기 위해 고유벡터를 적응적으로 업데이트되는 새로운 임계 값 $A(k)$ 를 획득

$$A'(k) = \frac{N(N+1) \sum_{i=1}^k \lambda_i + N \| U_k^T(y - \bar{x}) \|^2}{N(N+1) \sum_{i=1}^n \lambda_i + N \| (y - \bar{x}) \|^2} \tag{14}$$

[Step 8] $A(k)$ 값이 특정 임계값 θ 보다 적으면 새로운 축이 기존의 고유벡터에 더해지고, $A(k)$ 값이 θ 보다 크면 기존의 차원을 유지

$$\hat{h} = \begin{cases} \frac{h}{\|h\|^2}, & \text{if } A(k) < \theta \\ 0 & \end{cases} \quad (15)$$

[Step 9] 전자에서 획득한 고유벡터를 이용하여 분류를 위한 프로토타입을 식 (16)과 같이 구성

$$\tilde{p}_j = U^T(p_j - \bar{x}) \quad (16)$$

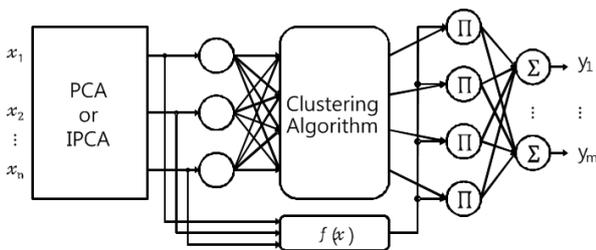
위와 같이 구성된 프로토타입은 다음 식 (17)과 같이 갱신

$$\tilde{p}_j \approx R^T[p_j^T, 0]^T + \frac{1}{N+1} U^T(\bar{x} - y) \quad (17)$$

3. 인식을 위한 PCA기반 퍼지 RBFNNs 패턴분류기의 설계

숫자인식 시스템의 인식 성능을 확인하기 위해 퍼지 RBFNNs 패턴분류기[1][2]에 대하여 설명한다. 기본적인 신경 회로망의 구조는 인간의 두뇌와 뇌 신경을 모방한 알고리즘으로 크게 입력층, 은닉층, 출력층의 3가지로 구분할 수 있다. 입력층의 노드는 인간의 감각세포와 같은 역할을 수행하며, 은닉층의 노드는 인간의 뉴런과 같이 신경세포의 역할을 한다. 이때 은닉층 노드의 활성화수로 시그모이드(Sigmoid) 함수가 사용된다. 마지막으로 출력층의 노드는 뇌세포로서의 역할을 수행함으로써 신경회로망이 동작한다.

본 논문에서 사용하는 다항식 기반 퍼지 RBFNNs 패턴분류기는 기본적인 신경회로망과 비교했을 때 구조적 모듈로서 동일하게 입력층, 은닉층, 출력층의 3가지로 구분되나, 기능적 모듈로서 조건부, 추론부, 결론부의 3가지로 구분이 가능하다. 먼저 패턴분류기의 전처리 과정으로 PCA 또는 IPCA를 사용하여 데이터의 차원축소를 수행하며, 축소된 입력 데이터는 분류기의 입력으로 사용된다. 조건부 활성화수로는 FCM(Fuzzy C-Means)클러스터링 알고리즘의 멤버십 값을 사용함으로써 입력 데이터의 특성을 보다 더 잘 반영할 수 있도록 개선하였다. 또한 결론부의 연결가중치를 기존의 상수항에서 일차식, 이차식, 그리고 변형된 이차식과 같이 확장된 다항식의 형태로 적용하는 특징을 가지고 있다.



[RBFNNs]

그림 3. PCA 기반 퍼지 RBFNNs의 구조

Fig. 3. Overall architecture of Fuzzy RBFNNs pattern classifier

표 1. 다항식의 구조
Table 1. Structure of polynomial type

Type	Polynomial Type
Constant	$f_i(x) = a_i 0$
Linear	$f_i(x) = a_i 0 + \sum_{j=1}^n a_{ij} x_j$
Quadratic	$f_j(x_1, \dots, x_n) = \sum_{i=0}^n a_{ji} x_i + \sum_{i=1}^n a_{j(n+i)} x_i^2 + a_{(2n+1)} x_1 x_2$

여기서 $x = [x_1, x_2, \dots, x_k]$, k 는 입력변수의 수, R^j 는 j 번째 퍼지 규칙 ($j = 1, \dots, c$), c 는 퍼지 규칙 수이며, $f_j = (x_1, \dots, x_k)$ 는 j 번째 규칙에 대한 후반부로서 j 번째 퍼지 규칙에 대한 로컬 모델이다.

모델의 출력은 아래 식처럼 구해진다.

$$\hat{y} = \sum_{j=1}^c u_j f_j(x_1, \dots, x_k) \quad (18)$$

이와 같이 다항식 형태의 연결가중치를 사용함으로써 아래 식의 퍼지 규칙 표현과 같은 언어적 관점에서의 해석이 가능해졌다.

$$IF \ x \ is \ A_i \ Then \ f_{ij}(x) \quad (19)$$

여기서 x 는 입력벡터, A_i 는 FCM 클러스터링에 의한 $j(j = 1, \dots, c)$ 번째 그룹의 소속 함수, $f_{ji}(x)$ 는 $i(i = 1, \dots, s)$ 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 최종출력은 퍼지 규칙의 추론 결과로서 구해진다. 이와 같이 개선된 퍼지 RBFNNs 구조는 퍼지 규칙을 기반으로 한 네트워크 구조를 가지며, 조건부, 결론부, 추론부와 같이 세 가지 기능적 모듈로 분리되어 동작한다. 이러한 다항식 퍼지 RBFNNs의 구조 동정과정이 전부분 동정과 후반부 동정 방법에 대해서 설명한다.

3.1 FCM (Fuzzy C-Means) 클러스터링

FCM(Fuzzy C-Means) 클러스터링 알고리즘은 데이터와 각 클러스터와의 거리를 기준으로 소속정도를 측정하여, 비슷한 패턴, 속성, 형태 등의 기준을 통해 데이터를 분류하는 알고리즘이다. 이와 같은 FCM 클러스터링 알고리즘은 다항식 기반 퍼지 RBFNNs 패턴분류기의 은닉층 활성화수 형태를 표현하며, 아래와 같은 단계를 통해 수행된다.

[Step 1] 클러스터의 개수, 퍼지화 계수를 선택하고, 소속함수($U^{(0)}$)를 초기화 한다.

$$U^{(0)} = \left\{ \begin{array}{l} u_{ik} \in [0, 1], \sum_{i=1}^c u_{ik} \\ = 1 \forall k, 0 < \sum_{k=1}^n u_{ik} < n \forall i \end{array} \right\} \quad (20)$$

[Step 2] 각 클러스터에 대한 중심 벡터를 구한다.

$$u_{ij} = \frac{\sum_{k=1}^n (u_{ik})^m X_{Kj}}{\sum_{k=1}^n (u_{ik})^m} \quad (21)$$

[Step 3] 중심과 데이터와의 거리를 계산하며, 이를 통해 새로운 소속함수($U^{(1)}$)를 계산한다.

$$d_{ik} = d(x_k - v_i^{(r)}) = \left[\sum_{j=1}^l (x_{kj} - v_{ij}^{(r)})^2 \right]^{1/2} \quad (22)$$

$$u_{ik} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}} \right)^{2/(m-1)}} \quad (23)$$

[Step 4] 오차가 허용범위 안에 도달하면 알고리즘을 종료하고, 그렇지 않으면 [Step 2]로 돌아간다.

$$\| U^{(r+1)} - U^{(r)} \| \leq \epsilon \quad (24)$$

3.2 최소자승법(Least Square Estimation)

다항식기반 퍼지 RBFNNs 패턴분류기의 다항식 파라미터 계수는 최소 자승법(LSE)을 사용하여 추정한다. 최소자승법은 오차제곱의 합이 최소가 되도록 계수를 추정하며, 다항식 파라미터 계수를 한 번에 구하기 때문에 전역 모델의 학습이 수행 가능하다. 최소자승법에서는 성능평가함수 Q_L 의 행렬 형식을 표현하면 다음의 식 (25)와 같다.

$$Q_L = (Y - XA)^T (Y - XA) \quad (25)$$

여기서 A 는 다항식 파라미터 계수, Y 는 출력 데이터, X 는 FCM의 소속행렬이 곱해진 입력데이터의 행렬로 x 는 입력 행렬, u 는 소속행렬을 의미한다. 다항식 구조가 Linear일 경우 X, Y, A 행렬은 다음과 같은 식 (26)로 표현되며, 여기서 m 은 데이터의 수이며, k 는 입력수의 수, c 는 규칙 수(클러스터 수)가 된다.

$$A = [a_{10}, a_{11}, \dots, a_{1k}, \dots, a_{c0}, a_{c1}, \dots, a_{ck}]^T \quad Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix} \quad (26)$$

$$X = \begin{bmatrix} u_{11} \dots u_{c1} & x_{11}u_{11} \dots x_{11}u_{c1} & \dots & x_{k1}u_{11} \dots x_{k1}u_{c1} \\ \vdots & \vdots & \ddots & \vdots \\ u_{1m} \dots u_{cm} & x_{1m}u_{1m} \dots x_{1m}u_{cm} & \dots & x_{km}u_{1m} \dots x_{km}u_{cm} \end{bmatrix}$$

이에 전역 모델에 대한 행렬은 식 (27)과 같으며, 다항식의 계수행렬 A 는 확장행렬을 구하고 가우스 소거법(Gaussian elimination)을 이용하여 구하거나 식 (28)와 같이 역행렬에 의해 구해진다.

$$(X^T X)A = X^T Y \quad (27)$$

$$A = (X^T X)^{-1} X^T Y \quad (28)$$

4. 시뮬레이션 및 결과고찰

본 논문에서 사용한 MNIST 필기체 데이터는 아래의 그림 4와 같이 구성된 데이터 집합으로 하나의 이미지는 가로와 세로 각각 28 픽셀로 구성된다. MNIST 데이터[7]의 수는 총 70000개이며, 각각 학습 및 테스트 데이터로 60000개, 10000개로 구성하였다. 그리고 입력 차원 수는 784개로 구성되어 있으며, 본 논문에서는 784개의 입력 차원을 68개로 차원 축소하여 사용하였다. 또한 성능 평가를 위한 방법으로 식(29),(30)와 같은 분류율을 사용한다.

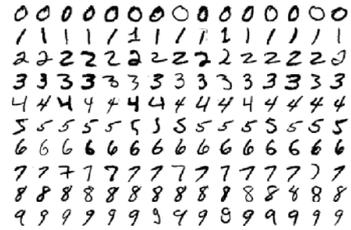


그림 4. MNIST 숫자 데이터의 구성

Fig. 4. Configuration of MNIST digit database

$$\text{분류율} = \frac{\sum_{i=1}^N f(y_i - \hat{y}_i)}{N} \times 100 \quad (29)$$

$$f(y_i - \hat{y}_i) = \begin{cases} 0, & y_i \neq \hat{y}_i \\ 1, & y_i = \hat{y}_i \end{cases} \quad (30)$$

그리고 학습에 사용된 FCM의 퍼지화 계수는 일반적으로 사용되는 2.0을 사용하였으며, 클러스터의 수를 의미하는 룰의 수 등 퍼지 RBFNNs 패턴분류기의 초기 파라미터는 아래의 표 2에 나타내었다.

표 2. 초기 파라미터의 설정

Table 2. Setting of initial parameter

Parameter	Value
Fuzzification Coefficient	2.0
Number of Inputs	68
Number of Rules	10
Polynomial Type	Linear

MNIST 숫자데이터는 실험을 위해 그림 5과 같이 구성된 인식 시스템을 수행하며, 다음의 그림 6과 같이 세 가지로 구성된 실험을 통해 성능을 확인한다. 그림 6에서 학습 및 테스트 데이터를 위한 70000개의 데이터베이스 중에서 학습 데이터 60000개를 위한 실험 데이터를 그룹으로 구성한다.

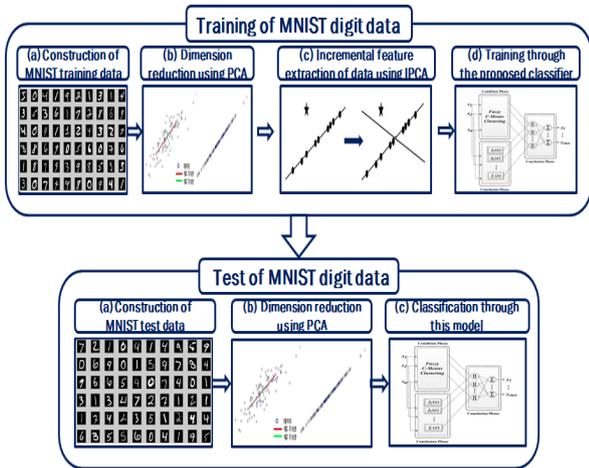
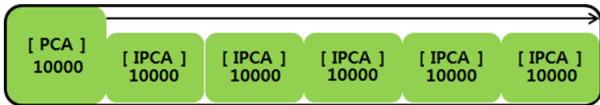


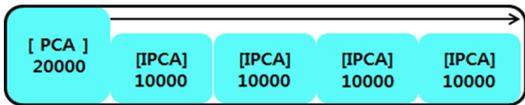
그림 5. IPCA기반 숫자 인식 시스템의 절차
Fig. 5. Procedure of digit recognition system using IPCA

Expt. 1은 10000개의 데이터를 PCA로 선 차원 축소하고, 이 후에 입력되는 50000개의 데이터를 각각 10000개씩 5번으로 나누어 Incremental-PCA를 수행한다. 마찬가지로 Expt. 2와 Expt. 3에서도 20000개의 학습 데이터에 대해 PCA를 사용하여 차원축소를 수행하고, 이후에 들어오는 데이터에 대하여 10000개씩 4번 또는 20000개씩 2번의 IPCA 과정을 수행하게 된다. 이와 같이 IPCA를 이용하여 차원 축소를 수행하면 데이터의 특징을 효율적으로 분할하고 새로운 데이터를 원하는 만큼 추가적으로 학습하여 사용할 수 있고, 메모리의 사용량을 효율적으로 조절할 수 있다.

Expt. 1. PCA : 10000개, IPCA : 10000개씩 5번 수행



Expt. 2. PCA : 20000개, IPCA : 10000개씩 4번 수행



Expt. 3. PCA : 20000개, IPCA : 20000개씩 2번 수행

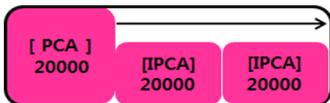


그림 6. 실험 데이터의 구성
Fig. 6. Configuration of Experimental database

PCA와 IPCA를 사용하여 데이터베이스의 차원이 축소된 숫자이미지의 특징을 퍼지 RBFNNs 패턴분류기의 입력으로 사용하여 인식성능을 비교한다. 본 논문에서 사용하는 숫자 인식 시스템의 성능 평가를 하기 위해 기존에 제안된 패턴 분류기의 성능들을 같이 비교 및 평가한다. 표 3은 그림 6과 같이 구성된 실험 데이터를 사용하여 퍼지 RBFNNs 패턴 분류기를 통해 성능을 확인한 결과이다. 데이터의 구성을 바꾸면서 인식성능을 비교하기 위해 패턴 분류기의 규칙 수는 3으로 고정하였고, Iteration은 2 또는 10을 사용하였다. 위 실험데이터를 이용한 인식 성능을 비교한 결과 Expt. 2의 Iteration : 10을 사용하였을 때 가장 좋은 성능을 보였지만, PCA의 차원 수의 증가로 인식 성능에 큰 효과를 보이지 않음을 알 수 있었다.

MNIST 숫자데이터를 이용한 이전 논문에서 제안된 10개의 분류기에 대한 인식성능을 표 4에 순차적으로 나열하였으며, 본 논문에서 제안한 숫자인식 시스템의 성능은 PCA, (2D)²PCA[5] 그리고 IPCA 순서로 나타내었다. 인식 성능의 산출을 위해 이미지의 차원 수는 68개로 축소하고, 규칙 수는 45개를 사용하며, PCA와 (2D)²PCA를 패턴 분류기에 적용하였다. IPCA를 사용하였을 때 데이터를 그룹으로 분할하여 사용해도 인식성능의 저하 없이 동일한 인식성능을 출력하였으며, Convolutional net 이외의 다른 분류기보다는 향상된 인식 성능을 확인할 수 있었다.

표 3. 실험 데이터를 이용한 인식성능의 비교

Table 3. Comparison of classification rates for experimental data

	Configuration of Experimental data No. of rules : 3	Classification Rate(%)
Expt 1	PCA:10000개 IPCA:10000개×5회 (Iteration:2)	91.37
	위와 동일한 조건 (Iteration:10)	91.35
Expt 2	PCA:20000개 IPCA:10000개×4회 (Iteration:2)	91.59
	위와 동일한 조건 (Iteration:10)	91.67
Expt 3	PCA:20000개 IPCA:20000개×2회 (Iteration:2)	91.66
	위와 동일한 조건 (Iteration:10)	91.63

5. 결론 및 향후 연구

본 논문에서는 고차원 데이터의 효과적인 처리와 새롭게 입력되는 데이터에 대한 점진적 학습을 필요로 하는 문제를 해결하고자 IPCA 알고리즘을 적용하였고, 간단한 구조의 퍼지 RBFNNs 패턴 분류기와 결합하여 숫자 인식 시스템을 설계하였다. 이와 같이 적용된 패턴 분류기는 PCA와 동일한 성능을 출력하였고, (2D)²PCA를 사용한 경우와 유사한 성능을 출력하는 것을 확인하였다. 또한 일괄 처리(Batch)방법을 갖

는 PCA와는 달리 IPCA는 새로운 데이터에 대하여 점진적인 학습이 가능하고, 일괄 처리방법에서 생기는 많은 양의 메모리와 계산시간 면에서 효과적인 것을 확인하였다. 본 논문에서 데이터베이스를 PCA를 사용한 그룹과 IPCA를 사용한 그룹으로 분할하여 인식을 수행하고 실시간적으로 파라미터의 최신회가 불가능하지만, 향후 연구에서는 실시간 데이터 처리가 가능하도록 On-line모드를 적용하여 연구를 진행할 예정이다.

표 4. MNIST 숫자데이터를 이용한 분류기의 성능평가

Table 4. Performance evaluation of classifier using MNIST digit database

Classifier	Pre-processing	Classification rate(%)
Linear Classifier(1-layer NN) [6]	None	88.0
Linear Classifier(1-layer NN) [6]	Deskewing	91.6
K-nearest neighbors, Euclidean [6]	None	95.0
K-nearest neighbors, Euclidean [6]	Deskewing	97.6
PCA(40)+Quadratic Classifier [6]	PCA	96.7
1000RBF+Linear Classifier [6]	None	96.4
2-layer NN, 1000 Hidden units [6]	None	95.5
3-layer NN, 500+150 Hidden units[6]	None	97.1
Convolutional nets LeNet-1 [6]	Subsampling 16×16pixels	98.3
Convolutional nets LeNet-4 [6]	None	98.9
Proposed recognition system (No. of dimensional reduction : 68, No. of rules : 45)		
PCA(68) + Fuzzy RBFNNs(45)	PCA	98.18
(2D) ² PCA(68) + Fuzzy RBFNNs(45)	(2D) ² PCA	98.21
IPCA(68) + Fuzzy RBFNNs(45)	IPCA	98.18

[5] D. Zhang and Z. H. Zhou, "(2D)²PCA : Two-directional two-dimensional PCA for efficient face representation and recognition," *Neurocomputing*, vol. 69, pp. 224-231, 2005.

[6] Y. LeCun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-Based Learning Applied to Document Recognition," *IEEE*, vol. 86, pp. 2278-2324, 1998.

[7] S. C. Lee, S. K. Oh and H. K. Kim, "Design of PCA-based pRBFNNs Pattern Classifier for Digit Recognition," *Korea Institute of intelligent systems*, vol. 25, no. 4, pp. 355-360, 2015.

[8] S. H. Lee, S. Y. Choi, S. Y. Lee and Y. S. Kim, "Licence Plate Recognition Using Improved IAFC Fuzzy Neural Network," *Korea Institute of intelligent systems*, vol. 19, no. 1, pp. 6-12, 2009.

[9] S. S. Yoon, H. S. Chung, K. O. Yi, Y. B. Lee and S. H. Lee, "A Study on Human Recognition Experiments with Handwritten Digit for Machine Recognition of Handwritten Digit," *Korea Institute of intelligent systems*, vol. 18, no. 3, pp. 373-380, 2008.

[10] In-Cheol Kim, "Word Separation in Handwritten Legal Amounts on Bank Check by Measuring Gap Distance Between Connected Components," *Korea Institute of intelligent systems*, vol. 14, no. 1, pp. 57-62, 2004.

[11] W. Y. Choi, S. K. Oh and H. K. Kim, "Design of RBFNN-Based Pattern Classifier for the Classification of Precipitation/Non-Precipitation," *Korea Institute of intelligent systems*, vol. 24, no. 6, pp. 586-591, 2014.

[12] Yann LeCun, Corinna Cortes and Christopher J.C. Burges, "The MNIST DATABASE of handwritten digits," Available:<http://yann.lecun.com/exdb/mnist>

References

[1] S. K. Oh, W. Pedrycz, B. J. Park, "Polynomial-based Radial Basis Function Neural Networks realized with the Aid of Particle Swarm Optimization," *Fuzzy Sets and Systems*, vol. 163, pp. 54-77, 2011.

[2] S. K. Oh, W. D. Kim, and W. Pedrycz, "Fuzzy Radial Basis Function Neural Networks with information granulation and its parallel genetic optimization," *Fuzzy Sets and Systems*, vol. 237, pp. 96-117, February 2014.

[3] H. H. Lee, X. Cui, H. R. Kim, S. W. Ma, J. H. Lee and H. I. Kim, "Robust Object Tracking in Mobile Robots using Object Features and On-line Learning based Particle Filter," *Journal of Institute of Control*, vol. 18, pp. 562-570, 2012.

[4] Byoung-Joo Kim, "Feature Extraction on High Dimensional Data Using Incremental PCA," *KIICS Integrated Conference*, vol. 8, no. 7, pp. 1475-1479, 2004.

저자 소개



김 봉 연 (Bong-yeon Kim)

2014년 : 수원대학교 전기공학과 졸업

2014년~현재 : 동 대학원 석사과정

관심분야 : Fuzzy Inference System, Neural Network, Pattern Recognition, Face Recognition System, Evolutionary Optimization

Phone : +82-31-222-6544

E-mail : zillot07@suwon.ac.kr



오성권(Sung-Kwun Oh)

1981년 : 연세대학교 전기공학사
1983년~1989년 : 금성산전 연구소
(선임연구원)
1993년 : 연세대학교 전기공학과 공학박사
1996년~1997년 : 캐나다 Manitoba 대학
전기 및 컴퓨터 공학과
Post-Doc

1993년~2004년 : 원광대학교 전지전자 및 정보 공학부 교수
2005년~현재 : 수원대학교 전기공학과 교수
2002년~현재 : 대한전기학회, 퍼지 및 지능시스템학회
편집위원
2013년~현재 : Information Sciences 편집위원

관심분야 : Fuzzy System, Fuzzy-Neural Network,
Automatic System, Advanced Computational
Intelligence, Intelligent Control

Phone : +82-31-222-6544
E-mail : ohsk@suwon.ac.kr



김진율(Jin-Yul Kim)

1986년 : 서울대학교 전자공학과 졸업,
1988년 : 한국과학기술원 전기 및
전자공학과 공학 석사
1993년 : 한국과학기술원 전기 및
전자공학과 공학박사
1994~현재 : 수원대학교 전자공학과
부교수

관심분야 : 신호처리시스템 설계, 영상 내 객체 추적
Phone : +82-31-220-2323
E-mail : jykim@suwon.ac.kr