Journal of Korean Institute of Intelligent Systems
Vol. 25, No. 5, October 2015, pp. 509-514
http://dx.doi.org/10.5391/JKIIS.2015.25.5.509

ISSN(Print) 1976-9172
ISSN(Online) 2288-2324

Extreme Learning Machine 기반 퍼지 패턴 분류기 설계

Design of Fuzzy Pattern Classifier based on Extreme Learning Machine

안태천* · 노석범* · 황국연* · 王繼紅* · 김용수**†
Tae-Chon Ahn, Sok-Beom Roh, Kuk-Yeon Hwang, Jihong Wang, and Yong Soo Kim

*원광대학교 전자 융합공학과, Department of Electronics Convergence Engineering, Wonkwang University
**대전대학교 컴퓨터공학과, Department of Computer Engineering, Daejeon University

요 약

본 논문에서는 인공 신경망의 일종인 Extreme Learning Machine의 학습 알고리즘을 기반으로 하여 노이즈에 강한 특성을 보이는 퍼지 집합 이론을 이용한 새로운 패턴 분류기를 제안 한다. 기존 인공 신경망에 비해 학습 속도가 매우 빠르며, 모델의 일반화 성능이 우수하다고 알려진 Extreme Learning Machine의 학습 알고리즘을 퍼지 패턴 분류기에 적용하여 퍼지 패턴 분류기의 학습 속도와 패턴 분류 일반화 성능을 개선 한다. 제안된 퍼지 패턴 분류기의 학습 속도와 일반화 성능을 평가하기 위하여, 다양한 머신 러닝 데이터 집합을 사용한다.

키워드 : 퍼지 패턴 분류기, Extreme Learning Machine, 퍼지 클러스터링, 학습 알고리즘, 신경회로망

Abstract

In this paper, we introduce a new pattern classifier which is based on the learning algorithm of Extreme Learning Machine the sort of artificial neural networks and fuzzy set theory which is well known as being robust to noise.
The learning algorithm used in Extreme Learning Machine is faster than the conventional artificial neural networks. The key advantage of Extreme Learning Machine is the generalization ability for regression problem and classification problem.
In order to evaluate the classification ability of the proposed pattern classifier, we make experiments with several machine learning data sets.

Key Words : Fuzzy Pattern Classifier, Extreme Learning Machine, Fuzzy Clustering Algorithm, Learning Algorithm, Artificial Neural Networks

Received: Mar. 22, 2015
Revised : Apr. 5, 2015
Accepted: Aug. 4, 2015
†Corresponding author
kystj@dju.kr

1. 서 론

현재는 스마트 폰과 태블릿 컴퓨터와 같은 모바일 기기들의 폭발적인 보급 증가로 인하여 이와 같은 모바일 기기들을 이용한 SNS와 같은 네트워크를 통해 다양한 형태의 데이터들이 대량으로 생산되고 있다. 일반적으로 SNS를 통해 생산되는 데이터들은 영상, 이미지, 텍스트 형태의 비정형 데이터 들이며, 이와 같은 대량의 비정형 데이터들을 분류하고 가공하여 사용자들이 원하는 정보를 얻기 위하여 고차원의 데이터를 신속하게 가공하고 분류할 수 잇는 새로운 형태의 처리기술의 도입이 시급한 실정이다. 그리하여 이를 위한 다양한 연구들이 시도되어지고 있다.

그러나 획득된 데이터의 차원이 매우 커짐에 따라, 패턴 분류를 위한 계산 시간뿐만 패턴 분류 성능에 좋지 않은 영향을 주고 있다 [1].

데이터를 가공하고 분류하기 위하여 다양한 알고리즘이 연구되어져 왔고 이들 중에서 신경회로망과 퍼지 집합 이론에 기반을 둔 퍼지 추론 시스템은 서로의 장단점을 보완하며 패턴 분류 분야에서 우수한 성과를 나타내 왔다.

신경회로망의 경우 우수한 학습 능력을 보유하고 있는 반면, 최종적으로 얻게 되는 네

본 논문은 2015학년도 원광대학교의 교비지원에 의해서 수행 됨.
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.

트워크의 구조가 블랙박스(black box) 형태를 취하게 되어 설계자가 네트워크의 구조들의 의미를 파악할 수 없다는 단점을 가지고 있다. 이와 달리, 퍼지 집합에 기반을 둔 퍼지 추론 시스템은 전문가의 전문 지식을 기반으로 퍼지 규칙을 설정하고 그 규칙에 따라 나타내고자 하는 시스템을 규정 할 수 있는 장점이 있으나 학습 방법에는 제약이 있다.

이와 같은 두 알고리즘의 장점을 결합하여 신경 회로망의 학습 이론과 퍼지 추론 시스템의 의미 있는 규칙을 접목한 뉴로 퍼지 뉴럴 네트워크가 연구되어져 왔다.

일반적으로 신경회로망에서 사용되는 학습 규칙인 오류 역전파 알고리즘 (Back Propagation Learning Algorithm)은 학습 시간이 오래 걸린다는 단점을 가지고 있으며, 신경회로망의 학습 알고리즘을 계승한 뉴로 퍼지 네트워크의 학습도 비록 신경회로망의 학습속도에 비해 빠른 편이지만, 여전히 학습 속도가 느리다는 단점을 가지고 있다.

이와 같은 신경망의 느린 학습 속도 문제를 해결하기 위하여 신경회로망의 입력층의 노드과 은닉층의 은닉 노드를 연결하는 연결 하중의 학습을 생략한 Extreme Learning Machine(ELM)이 제안되었다 [1].

Guang-Bin Hwang에 의해 제안된 FLM은 신경회로망의 입력 층과 은닉 층 사이의 연결 하중 값을 랜덤하게 설정하고, 은닉 층과 출력 층의 연결 하중은 Moore-Penrose generalized inverse matrix를 이용하여 학습을 하게 된다. 이와 같은 학습 기법으로 인하여 일반적인 신경회로망이 가지고 있는 반복 학습 (iterative learning)과정을 생략함으로써 학습속도를 대폭 향상 시킬 수 있다.

본 논문에서 ELM의 학습 구조를 뉴로 퍼지 회로망에 적용함으로써, 학습 속도를 높이며, 뉴로 퍼지 회로망의 일반화 성능을 개선 하고자 한다.

제안된 Extreme Learning Machine 기반 퍼지 패턴 분류기의 일반화 성능을 평가하기 위하여 다양한 형태의 머신 러닝 데이터 집합들을 이용하여 패턴 분류 성능을 비교한다.

2. Extreme Learning Machine

본 논문에서는 신경 회로망의 학습 속도를 대폭 높이고 신경 회로망의 일반화 성능을 개선한 Extreme Learning Machine을 기반으로 한 퍼지 패턴 분류기를 제안한다.

일반적으로 한 층의 은닉층을 가진 신경회로망을 Single Hidden Layer Feed-foward Networks (SLFNs)라고 부른다.

그림 1은 SLFNs의 기본 구조를 나타낸다.

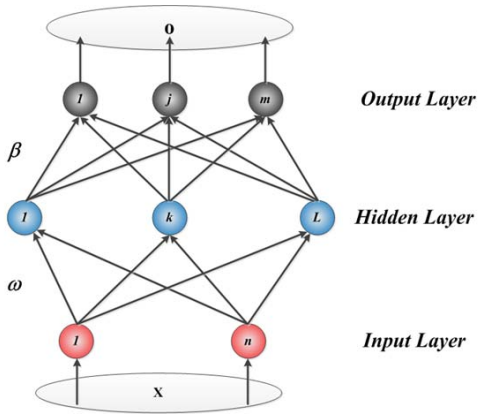

그림 1. Single hidden layer feed-forward networks의 기본구조
Fig. 1. Basic structure of single hidden layer feed-forward networks

데이터 쌍 $(\boldsymbol{x_i}, \boldsymbol{t_i})$가 주어졌을 경우, 일반적인 SLFNs의 출력식은 (1)과 같다. 여기서 $\boldsymbol{x_i} = [x_{i1}, x_{i2}, \cdots, x_{\in}]^T \in R^n$ 이며 $\boldsymbol{t_i} = [t_{i1}, t_{i2}, \cdots, t_{im}]^T \in R^m$ 이다.

$$\boldsymbol{o_j} = \sum_{i=1}^{C} \beta_i \cdot g_i(\boldsymbol{x_j}) = \sum_{i=1}^{C} \beta_i \cdot g(\boldsymbol{w_i} \cdot \boldsymbol{x_j} + b_i) \tag{1}$$

여기서, $\boldsymbol{o_j}$는 j번째 출력 노드의 출력 값을 의미하며, C는 은닉층의 노드 수를 나타낸다. 그리고 $g_i(\boldsymbol{x_j})$는 은닉층의 i번째 은닉 노드의 출력을 나타내며, $\boldsymbol{w_i} = [\{w_{1i} w_{2i} \cdots w_{mi}]$는 입력층의 노드와 은닉층의 i번째 노드 사이의 연결 하중을 의미한다. b_i는 은닉층의 i번째 노드의 스레스홀드 값이다.

일반적으로 활성화 함수 $g(x)$를 가진 C개의 은닉 노드로 이루어진 SLFNs N개의 샘플데이터를 근사화 알 수 있다고 알려져 있다[1].

$$\sum_{i=1}^{C} \beta_i \cdot (\boldsymbol{w_i} \cdot \boldsymbol{x_j} + b_i) = t_j, \ j = 1, \cdots, N \tag{2}$$

여기서, N은 데이터 샘플의 수를 의미한다.
식(2)를 행렬로 표현하면 (3)과 같다.

$$\boldsymbol{H\beta} = \boldsymbol{T} \tag{3}$$

$$\boldsymbol{H} = \begin{bmatrix} g(\boldsymbol{w_1} \cdot \boldsymbol{x_1} + b_1) & \cdots & g(\boldsymbol{w_C} \cdot \boldsymbol{x_1} + b_C) \\ \vdots & \cdots & \vdots \\ g(\boldsymbol{w_1} \cdot \boldsymbol{x_N} + b_1) & & g(\boldsymbol{w_C} \cdot \boldsymbol{x_N} + b_C) \end{bmatrix} \tag{4}$$

$$\boldsymbol{\beta} = [\beta_1 \cdots \beta_C]^T \tag{5}$$

$$\boldsymbol{T} = [\boldsymbol{t_1} \cdots \boldsymbol{t_N}]^T \tag{6}$$

위와 같은 SLFNs의 학습 위하여, ELM은 w_1 , ⋯ , w_C과 b_1 , ⋯ , b_C를 임의의 확률 분포 함수를 통해 추출하여 사용한다. 일반적인 SLFNs는 w_k와 b_k를 학습을 통해 결정하게 된다.

ELM에서는 β를 결정하기 위하여 least square 방법을 이용하여 아래와 같은 목적함수를 최소화 하는 β를 결정하게 된다.

$$J = \min_{\beta} \| H\beta - T \| \tag{7}$$

(4)를 최소화 시키는 smallest norm least squares의 해는 (5)와 같다.

$$\hat{\beta} = H^{+}T \tag{8}$$

여기서, H^{+}는 Moore-Penrose generalized inverse of Matrix H [2]이다.

3. Extreme Learning Machine 기반 퍼지 패턴 분류기

위에 설명한 Extreme Learning Machine의 학습 알고리즘에 기반 한 퍼지 패턴 분류기는 일반적인 TSK 퍼지 추론 시스템이다. 일반적인 TSK 퍼지 추론 시스템의 퍼지 규칙의 전반부는 일반적으로 전문가들의 전문적인 지식에 의해 기술 되거나 퍼지 클러스터링 알고리즘을 이용하여 데이터를 분석하여 퍼지 규칙의 전반부 구조를 결정한다.

그러나 ELM 기반 퍼지 패턴 분류기에서는 전반부 퍼지 규칙을 ELM 설계 방법과 마찬가지로 랜덤하게 분포하도록 설정 할 것이며, 후반부 구조의 계수들은 (7)과 같이 결정한다.

본 논문에서는 퍼지 클러스터의 정의를 위해서 반복 최적화 과정을 거치지 않고 랜덤하게 v값을 결정하여 사용하여 은닉 노드의 활성화 함수는 Fuzzy C-Means Clustering [3] 의 출력식과 같은 (9)을 통해 얻게 된다.

$$g(w_1, \cdots, w_C) = \frac{1}{\sum_{j=1}^{c} \left(\frac{\|x_k - w_i\|}{\|x_k - w_j\|} \right)^{2/p-1}} \tag{9}$$

위와 같이 정의된 은닉층을 사용하는 ELM기반 퍼지 패턴 분류기를 구성하는 퍼지 규칙은 (10)과 같다.

$$If\ \mathbf{x}\ is\ g_k\ then\ o_1\ is\ \beta_{1j}, \cdots, o_m\ is\ \beta_{mj} \tag{10}$$

위와 같은 퍼지 규칙을 확장하여 퍼지 규칙의 후반부 구조를 상수 형태가 아닌 선형 다항식 형태로 확장한 퍼지패턴 분류기를 생성할 수 있다.

선형 다항식을 퍼지 규칙의 후반부로 가지는 퍼지 패턴 분류기의 퍼지 규칙은 (11)과 같다.

$$\begin{aligned} If\ \mathbf{x}\ is\ g_k\ then\ o_1\ is\ f(a_{k1}, \mathbf{x}), \\ \cdots, o_m\ is\ f(a_{km}, \mathbf{x}) \end{aligned} \tag{11}$$

(11)과 같은 퍼지 규칙을 가진 ELM 기반 퍼지 패턴 분류기의 네트워크 구조는 그림 2와 같다.

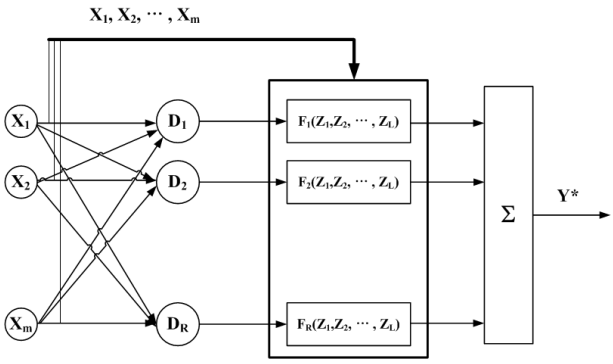

그림 2. 선형다항식 구조를 가진 Single hidden layer feed-forward networks의 기본구조

Fig. 2. Basic structure of single hidden layer feed-forward networks with linear regression

4. 실험 연구 및 결과 고찰

본 연구에서는 제안된 분류기의 성능을 평가하기 위하여 제안된 분류기를 모의 데이터 집합 (synthetic dataset)과 기계 학습 데이터 집합 (machine learning dataset)에 적용하여 분류기로서의 성능을 평가 및 분석한다. 기계 학습 데이터 집합은 UCI machine learning repository로부터 획득한 데이터 집합들을 이용하여 기존 논문에서 제안된 분류기 기법들과 비교 평가한다. 제안된 패턴 분류기의 성능을 평가하기 위하여 10-fold cross validation 기법을 사용하여 테스트 하였다.

제안된 제어기의 분류 성능 평가를 위한 성능 평가 지수는 식(12), (13)과 같이 패턴 분류기의 분류(classification rate) 비율로 한다.

$$\text{분류율} = \frac{\sum_{i=1}^{N} f(y_i, \hat{y_i})}{N} \times 100 \tag{12}$$

여기서, N은 데이터의 수를 의미한다.

$$f(a, b) = \begin{cases} 0, a \neq b \\ 1, a = b \end{cases} \tag{13}$$

제안된 분류기를 설계할 때 필요한 파라미터들을 표 1에 나타내었다.

표 1. 제안된 분류기의 설계 파라미터
Table 1. Design parameters of the proposed classifier

Parameter	Value
Polynomial Order (O)	0(constant), 1(Linear)
Number of hidden nodes (C)	2, 3, 5, 7, 9, 15, 20, 30, 40, 50
Fuzzification Coefficient Mutation rate (m)	In the range of 1.2~30 varying with step 0f 0.2

위와 같은 설계 파라미터를 기반으로 기계 학습 데이터 집합은 대표적인 Benchmark 데이터 집합인 UCI machine learning repository로부터 얻은 image segmentation 데이터이다. 표 1은 학습 데이터와 테스트 데이터를 이용하여 실험한 실험 결과를 분석, 비교한 결과이다. 패턴 분류 성능을 위하여 패턴 분류기의 분류율을 평가 지수로 선택 하였다.

표 2. 제안된 분류기와 기존 패턴 분류기 성능 비교
Table 2. Result of comparative analysis

	C=5		C=10		C=15		C=20		C=40	
	PI	EPI	PI	EPI	PI	EPI	PI	EPI	PI	EPI
ELM based Classifier	56.67	54.03	72.86	69.19	86.67	81.10	89.52	85.86	91.43	87.95
FCM based Classifier	59.52	60.29	80.95	75.95	82.86	76.76	83.81	75.57	87.62	81.14

그림 1은 제안된 ELM 퍼지 패턴 분류기와 FCM을 이용하여 퍼지 규칙의 위치를 결정한 패턴 분류기의 성능을 비교한 그림이다. 그림 1과 표 1에 보인바와 같이 퍼지 규칙의 수가 적을 경우엔 FCM 기반 패턴 분류기가 우수한 성능을 보이는 반면 규칙의 수가 증가 할수록 ELM 기반 패턴 분류기가 더 우수한 성능을 보임을 알 수 있다.

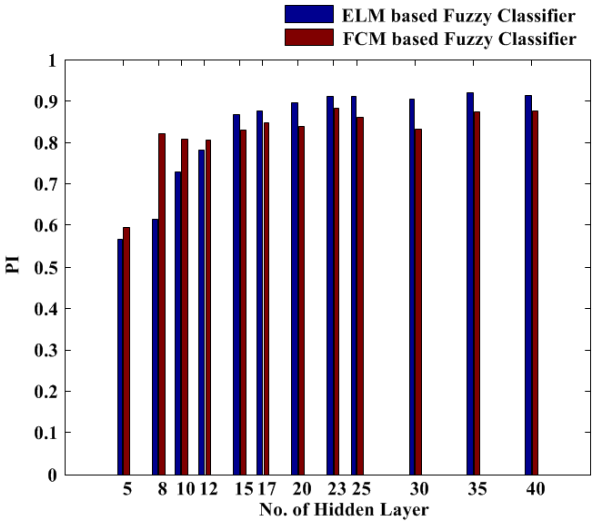

(a) Training Data

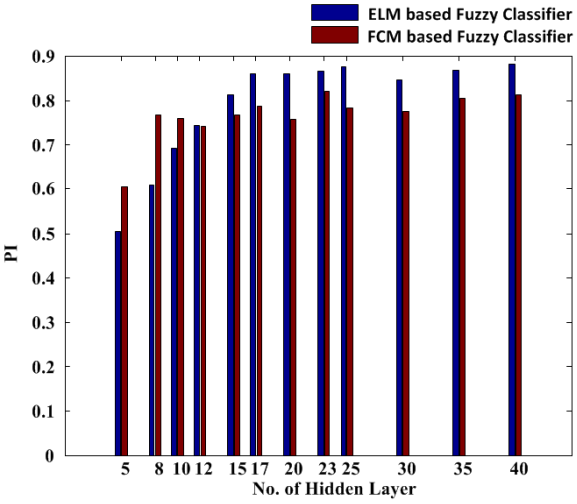

(b) Test Data

그림 3. ELM 기반 패턴분류기와 FCM 기반 패턴 분류기의 성능 비교
Fig. 3. Comparative analysis of classification performances between ELM based pattern classifier and FCM based pattern classifier

다양한 데이터에 대한 제안된 패턴 분류기의 성능을 파악하기 위하여 아래와 같은 기계학습 데이터 집합들에 대하여 실험을 수행하였다. 선정된 데이터 집합에 대한 일반적인 설명을 표 3에 나열하였다.

표 3. 실험에 사용된 기계 학습 데이터 집합
Table 3. Machine learning dataset used in the experiments

Dataset	Number of features	Number of patterns	Number of class
australian	14	690	2
balance	4	625	3
german	24	1000	2
iris	4	150	3
wine	13	178	3
sonar	60	208	2
pima	8	768	2
vehicle	18	846	4
hayes	5	132	3
bupa	6	345	2

표 4는 위 표에 주어진 각각의 모의 데이터 집합에 대해 제안된 패턴 분류기를 적용하여 얻은 결과들 중 가장 좋은 결과들을 보인다.

표 4. 기계 학습 데이터 집합 대한 제안된 패턴 분류기의 성능
Table 4. Classification performance of the proposed pattern classifier for the given machine learning data set

Dataset	0	C	m	PI	EPI
australian	0	50	2.4	88.78	86.96
	1	3	3.0	88.04	86.67
balance	0	40	1.4	92.66	91.84
	1	9	2.0	93.23	91.99
german	0	40	1.4	76.7	74.8
	1	2	1.4	79.2	77.0
iris	0	15	2.2	97.93	98.0
	1	3	1.8	98.37	98.0
wine	0	30	2.6	99.25	97.78
	1	2	1.2	100.0	99.44
sonar	0	40	2.4	79.65	71.62
	1	2	1.6	98.56	70.19
pima	0	40	2.6	77.58	77.48
	1	2	2.8	78.43	78.0
vehicle	0	50	2.8	85.17	82.15
	1	9	1.6	93.07	85.23
hayes	0	40	1.2	89.06	79.56
	1	5	2.0	87.63	85.53
bupa	0	15	1.4	73.72	72.48
	1	5	2.2	76.07	72.45

위 실험 결과로부터, 선형 회귀 다항식을 가진 퍼지 패턴 분류기의 경우, 패턴 분류 성능이 은닉노드의 수가 많지 않을 경우 우수함을 알 수 있었다.

이와 같은 결과는 제안된 선형 회귀다항식을 가진 패턴 분류기의 구조가 상수를 퍼지 규칙의 후반부 구조로 가지는 패턴 분류기에 비해 복잡하여 과학습이 이루어진 결과로 추론된다.

5. 결론 및 향후 연구

본 논문에서는 입력 층과 은닉 층 사이의 연결 하중을 랜덤하게 결정하고 은닉층과 출력층 사이의 연결 하중은 Moore-Penrose generalized inverse를 이용하여 결정하는 ELM을 기반으로 하는 퍼지 패턴 분류기를 제안한다.

또한 제안된 퍼지 패턴 분류기의 후반부 구조를 상수 형태의 구조에서 확장된 선형 회귀다항식을 가진 퍼지 패턴 분류기도 제안 하였다.

실험을 통해 주어진 데이터의 대부분의 경우 선형 회귀다항식을 가진 패턴 분류기의 성능이 우수함을 알 수 있었으나 일부 데이터의 경우 단순한 구조를 가진 퍼지 패턴 분류기의 성능이 더 우수함을 나타내었다.

제안된 ELM 퍼지 패턴 분류기는 기존의 FCM을 이용하여 RBF를 결정하는 퍼지 패턴 분류기에 비해 우수한 성능을 보임을 알 수 있다.

References

[1] G. B. Hwang, Q. U. Zhu, C. K. Siew, "Extreme learning machine: Theory and applications," *Neurocomputing*, Vol. 70, pp. 489-501, 2006.

[2] D. Serre, *Matrices: Theory and Applications*, Springer, New York, 2002.

[3] J. C. Bezdek, R. Ehrlich and W. Full, "FCM: The fuzzy c-means clustering algorithm," *Computers & Geoscience*, Vol. 10, pp. 191-203, 1984.

저 자 소 개

안태천(Tae-Chon Ahn)
1978년 : 연세대학교 전기공학과 공학사
1980년 : 연세대학교 전기공학과 공학석사
1986년 : 연세대학교 전기공학과 공학박사
1981년 ~현재 : 원광대학교 전자융합공학과 교수
2013년~현재 : 한국지능시스템학회 이사

관심분야 : Computational Intelligence, Soft Computing Fuzzy Control, Pattern Recognition
Phone : +82-63-850-6344
E-mail : tcahn@wku.ac.kr

노석범(Seok-Beom Roh)
1994년 : 원광대학교 제어계측공학과 공학사
1996년 : 동 대학원 컴퓨터공학과 공학석사
2006년 : 동 대학원 제어계측공학과 공학박사.
2007년 ~현재 : 원광대학교 전자융합공학과 연구교수

관심분야 : 퍼지이론, 신경회로망, Pattern Recognition, Bio-inspired optimization algorithm,
Phone : +82-63-850-6344
E-mail : nado@wku.ac.kr

황국연(Kuk-Yeon Hwang)
2006년 : 원광대학교 전자전기공학부 공학사
2011년 : 원광대학교 전자융합공학과 공학석사
2011년~현재 : 원광대학교 전자융합학과 박사과정
1997년~현재 : 한빛전자 대표

관심분야 : Lightning Impulse Generator
Phone : +82-63-851-9868
E-mail : pwrsou@kornet.net

王繼紅(Jihong Wang)
2000 : Tongji University, Electronic and Information Engineering School, Bachelor's Degree
2005 : Tongji University, Graduate School, Master's Degree
2005~Currently : Depart. of Electronics Convergence Engineering, Wonkwang University, Doctorial Course
2014~Currently : Depart. of Electronics and Information Engineering, Hengshui University, Lecturer

관심분야 : Fuzzy, Computational Intelligence, Soft Computing, Pattern Recognition
Phone : +82-63-850-6344
E-mail : wonkwang2014@126.com

김용수(Yong Soo Kim)
1981년 : 연세대학교 전기공학과 공학사
1983년 : KAIST 전자공학과 공학석사
1986년 : 삼성전자종합연구소 주임연구원
1993년 : Texas Tech Univ. 공학박사
1995년~현재 : 대전대학교 컴퓨터공학과 교수

관심분야 : 신경회로망, 퍼지논리, 패턴인식, 영상처리, 침입탐지 등
Phone : +82-42-280-2547
E-mail : kystj@dju.kr