



PSO 알고리즘을 이용한 퍼지 Extreme Learning Machine 최적화

Optimization of Fuzzy Learning Machine by Using Particle Swarm Optimization

노석범* · 王繼紅* · 김용수** · 안태천*[†]
Seok-Beom Roh, Yong-Soo Kim, and Tae-Chon Ahn[†]

*원광대학교 전자융합공학과, **대전대학교 컴퓨터공학과

*Department of Electronics Convergence Engineering, Wonkwang University

**Department of Computer Engineering, Daejeon University

요약

본 논문에서는 일반적인 신경회로망의 단점인 느린 학습속도를 획기적으로 개선한 네트워크인 Extreme Learning Machine과 전문가들의 언어적 정보들을 기술 할 수 있는 퍼지 이론을 접목한 퍼지 Extreme Learning Machine을 최적화하기 위하여 Particle Swarm Optimization 알고리즘을 이용하였다. 퍼지 Extreme Learning Machine의 활성화 함수를 일반적인 시그모이드 함수를 사용하지 않고, 퍼지 C-Means 클러스터링 알고리즘의 활성화 레벨 함수를 이용하였다. Particle Swarm Optimization 알고리즘과 같은 최적화 알고리즘을 통하여 퍼지 Extreme Learning Machine의 활성화 함수의 파라미터들을 최적화 한다. Particle Swarm Optimization과 같은 최적화 알고리즘을 통한 제안된 모델의 최적화 하고 최적화된 모델의 분류성능을 평가하기 위하여 다양한 머신 러닝 데이터 집합을 사용하여 평가한다.

키워드 : 퍼지 Extreme Learning Machine, 패턴 분류기, 최적화 기술, 퍼지 클러스터링, Particle Swarm Optimization

Abstract

In this paper, optimization technique such as particle swarm optimization was used to optimize the parameters of fuzzy Extreme Learning Machine. While the learning speed of conventional neural networks is very slow, that of Extreme Learning Machine is very fast. Fuzzy Extreme Learning Machine is composed of the Extreme Learning Machine with very fast learning speed and fuzzy logic which can represent the linguistic information of the field experts. The general sigmoid function is used for the activation function of Extreme Learning Machine. However, the activation function of Fuzzy Extreme Learning Machine is the membership function which is defined in the procedure of fuzzy C-Means clustering algorithm. We optimize the parameters of the membership functions by using optimization technique such as Particle Swarm Optimization. In order to validate the classification capability of the proposed classifier, we make several experiments with the various machine learning datas.

Key Words : Fuzzy Extreme Learning Machine, Pattern Classifier, Optimization Technique, Fuzzy Clustering, Particle Swarm Optimization.

Received: Nov. 20, 2015
Revised : Jan. 7, 2016
Accepted: Jan. 14, 2016
[†]Corresponding author
tcahn@wku.ac.kr

1. 서론

ICT(Information, Communication, Technology)의 발달로 인하여 데이터를 생산 · 유통 할 수 있는 매우 다양한 수단들이 사용되고 있다. 이와 같이 데이터를 생산하고 유통 할 수 있는 수단들이 다양해짐으로 인해 매우 다양한 형태를 가진 데이터들이 매일 생산 유통되어지고 있다.

이와 같이 생산되는 데이터들은 사회현상을 이해하거나 공공의 이익을 위한 정책결정에 사용될 수 있는 유용한 정보를 내포하고 있다.

최근 화제가 되고 있는 기술들은 이와 같은 대규모의 데이터를 처리하고 가공 · 분류하여 의미가 있는 정보를 얻어내는 기술들이다. 이러한 기술들을 확보하기 위하여 다양한 측면에서 연구가 진행되고 있다.

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.

특히 모바일 기기를 통하여 생산되는 데이터들은 정형 데이터뿐만 아니라 비정형 데이터가 섞여서 생산된다. 이러한 종류의 데이터들은 데이터의 차원이 매우 큰 경우가 대부분이다. 데이터의 차원이 매우 클 경우, 이러한 데이터 분류하기 위한 분류기를 학습시키기 위한 학습시간과 계산 복잡도가 매우 커지며, 분류기의 데이터 패턴 분류 성능도 좋지 않은 결과를 보인다 [1].

소프트 컴퓨팅의 일종인 신경회로망은 매우 큰 입력 공간을 가지는 데이터로 인하여 발생하는 문제를 해결하기 위하여 진화된 형태의 신경회로망인 깊은 구조를 가진 신경회로망 (Deep Neural Networks; DNNs)로 변형되어 이용되어지고 있다 [2].

매우 복잡한 구조를 가진 DNNs과 같은 신경회로망은 매우 우수한 패턴 분류 성능을 보이는 한편, 네트워크의 구조가 매우 복잡하기 때문에 네트워크의 파라미터를 학습시키기 위하여 매우 오랜 시간 학습과정을 거쳐야 한다. 이와 같은 일반적인 신경회로망의 단점인 느린 학습속도를 개선하기 위하여 Extreme Learning Machine (ELM)이 제안되었다.

ELM은 일반적인 신경회로망의 파라미터를 학습시키기 위하여 사용되는 Gradient Decent 기반의 Back-propagation 학습방법을 사용하지 않는다. 반복학습 방법의 일종인 Back-propagation 알고리즘은 학습 완료 시까지 오랜 시간을 소모한다는 단점이 있다.

이와 달리 ELM은 일반적인 신경회로망에서 학습을 통해 결정되는 은닉층의 파라미터를 랜덤하게 설정하고, 은닉층과 출력층 사이의 파라미터는 pseudo-inverse를 이용하여 결정한다. 이와 같은 학습 방식을 채택함으로써 일반적인 신경회로망의 반복학습방법이 가진 오랜 학습 시간이라는 단점을 극복하고 네트워크의 학습속도를 매우 빠르게 개선하였으며, 네트워크의 일반화 성능도 개선하였다 [3, 6, 8].

제안된 패턴 분류기의 또 다른 축인 퍼지 집합 이론은 일반적으로 전문가의 언어적 정보를 수학적으로 표현 할 수 있다는 장점을 가진 것으로 알려져 있다. 특히 퍼지 모델은 노이즈에 매우 강한 특성을 보인다고 알려져 있다. 본 연구에서는 앞서 기술한 특성을 가진 퍼지 논리의 장점과 신경회로망의 장점을 결합하기 위하여 퍼지 ELM을 이용하였다.

본 연구에서는 제안된 퍼지 ELM의 일반적인 네트워크 구조와 학습방법에 대해 설명하고, 퍼지 ELM의 변경된 부분을 기술한다. 패턴 분류기로 이용되는 퍼지 ELM의 은닉층 파라미터를 최적화하기 위하여 사용되는 PSO 알고리즘에 대하여 설명한다.

마지막으로, 제안된 패턴 분류기의 패턴 분류 성능을 평가하기 위하여 다양한 기계학습 데이터를 이용하여 실험하고 패턴 분류 결과를 비교 한다.

2. 퍼지 Extreme Learning Machine

본 연구에서는 일반적인 신경회로망 구조와 빠른 학습 능

력을 가진 ELM과 노이즈에 강한 특성을 가진 퍼지 모델을 결합한 퍼지 Extreme Learning Machine을 패턴 분류기로 사용한다.

2.1 Extreme Learning Machine

일반적인 신경회로망의 경우, 다수의 은닉층을 가진 네트워크를 설계 할 수 있으나, 네트워크의 복잡도를 줄이기 위하여, 한 층의 은닉층을 가진 신경회로망을 선호한다. 이와 같이 한층의 은닉층을 가진 신경회로망을 단일 은닉층 피드포워드 신경회로망 (Single Hidden Layer Feed Forward Networks; SLNFs)라고 부른다.

그림 1은 단일 은닉층 피드포워드 신경회로망의 구조를 보인다.




그림 1. 단일 은닉층 피드포워드 신경회로망의 기본 네트워크 구조

Fig. 1. Basic structure of single hidden layer feed-forward neural networks

그림 1과 같은 구조를 가진 신경회로망의 출력 식은 (1)과 같다.

$$O_j = \sum_{i=1}^C \beta_{ji} \cdot g_i(\mathbf{x}) = \sum_{i=1}^C \beta_{ji} \cdot g(\mathbf{w}_i \cdot \mathbf{x} + b_i) \quad (1)$$

여기서 O_j 는 j번째 출력 노드의 출력을 의미하며, C는 은닉층의 노드들의 수를 나타낸다. 그리고 $g_k(\mathbf{x})$ 는 k번째 은닉노드의 출력을 나타낸다.

$\mathbf{w}_i = [w_{1i} \ w_{2i} \ \dots \ w_{mi}]$ 는 입력층의 노드와 은닉층의 i번째 노드 사이의 연결 하중을 의미한다. 마지막으로 b_i 는 은닉층의 i번째 은닉 노드의 바이어스 값을 나타낸다.

일반적으로 ELM의 경우 은닉층과 관련된 파라미터 \mathbf{W} 과 \mathbf{b} 는 의의 확률 분포 함수를 이용하여 랜덤하게 추출하여 사용된다. 그리고 은닉층과 출력층 사이의 파라미터 β 는 최소 제곱법 (least square)을 사용하여 결정한다. 파라미터 β 를 결정하기 위한 목적함수는 (2)와 같이 정의 된다.

$$J = \min_{\beta} \| H\beta - T \| \quad (2)$$

여기서,

$$H = \begin{bmatrix} g(w_1 \cdot x_1 + b_1) & \dots & g(w_C \cdot x_1 + b_C) \\ \vdots & \dots & \vdots \\ g(w_1 \cdot x_N + b_1) & \dots & g(w_C \cdot x_N + b_C) \end{bmatrix} \quad (3)$$

$$\beta = [\beta_1 \ \beta_2 \ \dots \ \beta_C]^T \quad (4)$$

$$T = [t_1 \ t_2 \ \dots \ t_N]^T \quad (5)$$

목적함수 (2)를 최소화 시키는 해는 (6)과 같다.

$$\hat{\beta} = H^+ T \quad (6)$$

여기서, H^+ 는 행렬 H 의 Moore-Penrose generalized inverse 행렬이다 [3].

2.2 퍼지 Extreme Learning Machine

ELM을 기반으로 퍼지 모델을 접목한 퍼지 ELM에서 사용되는 퍼지 모델은 일반적인 TSK 퍼지 추론 시스템이다[7].

일반적인 TSK 퍼지 추론 시스템의 퍼지 규칙의 전반부 조건식은 해당 분야 전문가의 전문 지식을 언어적 규칙으로 기술되어 있거나 축적된 데이터의 분포를 분석하여 퍼지 집합을 정의한다. 이와 같이 입력 공간에서 데이터의 분포를 분석하기 위한 다양한 퍼지 클러스터링 알고리즘이 제안 되어졌다 [9].

그러나 ELM은 입력층과 은닉층 사이의 연결하중 값을 랜덤하게 생성하여 사용한다. 퍼지 ELM은 ELM의 연결하중 랜덤 생성 과정을 모사하여, 퍼지 규칙의 전반부 퍼지 집합을 랜덤하게 생성한다.

ELM의 경우 은닉층의 활성화 함수는 (7)과 같은 시그모이드 함수를 사용한다.

$$g(x) = \frac{1}{1 + \exp(-x)} \quad (7)$$

그러나 퍼지 ELM에서 사용되는 활성화 함수는 퍼지 C-Means 클러스터링 알고리즘 [5]에서 사용되는 멤버십 함수로 (8)과 같이 정의 하여 사용한다.

$$g_i(x) = \frac{1}{\sum_{k=1}^C \left(\frac{\|x - v_i\|}{\|x - v_k\|} \right)^{2/p-1}} \quad (8)$$

여기서, v_k 는 은닉층의 k번째 노드의 파라미터를 의미한다.

데이터의 분포를 분석하기 위하여 반복적 최적화 과정을 거치는 일반적인 퍼지 클러스터링 과정을 거쳐 클러스터의 중심값을 결정하는 방법과 달리 퍼지 ELM의 활성화 함수인 클러스터의 중심값은 랜덤하게 생성하여 설정하게 된다. 본 연구에서는 균일 분포 함수를 사용하였다.

퍼지 ELM 기반 퍼지 패턴 분류기의 퍼지 규칙은 (9)와 같다.

$$\text{If } x \text{ is } g_k \text{ then } y_1 \text{ is } \beta_{1j}, \dots, y_m \text{ is } \beta_{mj} \quad (9)$$

(9)와 같은 퍼지 규칙을 가진 퍼지 ELM 기반 퍼지 패턴 분류기의 파라미터를 학습시키기 위한 목적함수는 (10)과 같이 정의한다.

$$\min_{\beta} \| WH\beta - WT \| \quad (10)$$

목적함수 (10)을 최소화하는 $\hat{\beta}$ 는 (11)과 같다.

$$\hat{\beta} = ((WH)^T WH)^{-1} (WH)^T WT \quad (11)$$

3. Particle Swarm Optimization을 이용한 퍼지 Extreme Learning Machine 최적화

3.1 Particle Swarm Optimization

PSO는 물고기 혹은 새떼와 같은 무리를 이루는 동물들의 행동 양식을 모사하여 최적화 문제를 해결하기 위한 방법으로 복잡하고 불확실한 영역에서 최적해 탐색이 가능하다.

특히 PSO 알고리즘에 사용되는 연산자가 간단한 수학 연산자이기 때문에 알고리즘의 계산속도 측면에서 복잡한 연산자를 사용하는 다른 최적화 알고리즘에 비해 유리하며, 확률적인 방법에 기반을 둔 최적화 알고리즘에 비해 안정적이고 빠른 수렴 특징을 가진다 [10].

PSO 알고리즘은 다음과 같은 단계를 통해 파라미터 최적화를 수행한다.

단계 1: 초기화

n개의 particle을 탐색 공간 내에 균등 분포 함수를 이용하여 랜덤하게 생성한다. 이들이 최적화 알고리즘을 수행하게 될 초기 Swarm으로 정의된다.

단계 2: pBest와 gBest 선정

초기 particle들의 적합도 값을 적합도 함수를 이용하여 결정하고 pBest를 선정하고 이것들 중 가장 우수한 적합도 값을 가지는 particle을 gBest로 선정한다.

단계 3: 관성하중과 속도 갱신

(12)를 이용하여 관성하중 값을 계산하고 (13)을 이용하여 particle의 속도를 결정한다.

$$w(t) = w_{\max} - \frac{w_{\max} - w_{\min}}{t_{\max}} \cdot t \quad (12)$$

$$v_{jk}(t+1) = w(t) \cdot v_{jk}(t) + c_1 \cdot r_1 (pbest_{jk}(t) - x_{jk}(t)) + c_2 \cdot r_2 (gbest_{jk}(t) - x_{jk}(t)) \quad (13)$$

단계 4: particle 위치 갱신

(14)를 이용하여 particle의 위치 정보를 계산한다.

$$\begin{aligned} x_{jk}(t) &= v_{jk}(t) + x_{jk}(t-1) \\ x_k^{\min} &\leq x_{jk}(t) \leq x_k^{\max} \end{aligned} \tag{14}$$

단계 5: pBest와 gBest 재설정

각 particle의 적합도 값과 이전 세대의 pBest 적합도 값을 비교하여 재설정하고, 최적해의 pBest와 gBest값을 비교하여 재설정 한다.

단계 6: 종료 조건

종료 조건이 만족될 때까지 탐색을 계속 수행하며, 최종적으로 최적의 위치정보를 가지는 gBest를 해당 문제의 해로 설정한다.

3.2 PSO 기반 퍼지 ELM 패턴 분류기 최적화

퍼지 ELM은 (8)과 같은 형태의 함수를 은닉층의 활성화 함수로 사용한다. 은닉층의 활성화 함수 파라미터 v_k 는 특정 확률 분포 함수를 이용하여 랜덤하게 생성하여 설정한다. 그러나 본 연구에서는 활성화 함수의 파라미터를 랜덤하게 생성하지 않고 PSO 알고리즘을 이용하여 최적화 한다.

PSO를 이용하여 제안된 패턴 분류기를 최적화하기 위한 적합도 함수 F 를 (15)와 같이 정의 하였다.

$$\begin{aligned} F &= \frac{1}{N_t} \sum_{k \in L_t} f(t_k, \hat{y}_k) + \frac{1}{N_v} \sum_{l \in L_v} f(t_l, \hat{y}_l) \\ f(a, b) &= \begin{cases} 0, & \text{if } a = b \\ 1, & \text{if } a \neq b \end{cases} \end{aligned} \tag{15}$$

여기서, L_t 는 학습데이터 집합의 색인 집합을 의미하며, N_t 는 학습데이터 색인집합의 원소 개수를 의미한다. L_v 는 확인데이터 집합(Validation data set)의 색인 집합을 의미하며, N_v 는 집합 L_v 의 원소 개수를 의미한다.

데이터 집합을 학습 데이터 집합과 확인 데이터 집합을 나누는 이유는 최적화 알고리즘을 통한 패턴 분류기의 과적합(overfitting) 현상을 방지하기 위해서이다.

PSO 알고리즘을 이용하여 퍼지 ELM 패턴 분류기를 최적화하기 위하여 우수한 일반화 성능을 가지는 퍼지 클러스터의 중심 값을 결정한다.

그림 2는 퍼지 클러스터의 중심 값을 최적화시키기 위한 PSO 알고리즘의 기본 구조인 particle의 구성을 보여준다. 그림 2에 보인 것처럼 particle은 설계자에 의해 미리 결정된 "C" 개의 클러스터의 중심값으로 구성되며 이를 이용하여 각 퍼지 클러스터의 중심벡터를 최적화 시킨다.



그림 2. PSO 파티클의 구성

Fig. 2. Structure of particle of PSO

4. 시뮬레이션 및 결과 고찰

본 논문에서는 단일 은닉층 피드포워드 신경회로망의 학습 속도를 개선시킬 수 있는 ELM에 퍼지 활성화 함수를 결합한 퍼지 ELM을 패턴 분류기로 이용하였다.

퍼지 ELM은 노이즈에 강인한 특성을 가진 퍼지 논리를 ELM과 결합하여 노이즈에 강인하고 빠른 학습 속도를 가지며, 패턴 분류기의 일반화 성능도 우수한 신경회로망을 구현하였다.

전형적인 ELM의 연결하중 랜덤 설정 초기화 방법을 사용하지 않고, 퍼지 ELM에서는 신경회로망의 활성화 함수인 퍼지 클러스터의 각 중심 값을 최적화하기 위하여 PSO 알고리즘을 사용하였다.

제안된 패턴 분류기의 패턴 분류 성능을 검증하기 위하여 여러 개의 기계학습 데이터 집합들을 사용하여 패턴 분류를 수행하였다. 패턴 분류 성능을 검증하기 위하여 사용된 데이터는 기계학습 분야의 대표적인 성능기준평가 데이터인 UCI machine learning repository에서 얻은 다양한 데이터 집합들이다.

제안된 패턴 분류기의 성능 평가를 위하여 10fold 교차 확인 방법을 통해 검증하였다. 이는 전체 데이터 집합을 10개의 그룹으로 나누고 각 그룹을 테스트 데이터 집합으로 설정하고 나머지 9개의 그룹들을 학습데이터 집합과 확인 데이터 집합으로 나누어 학습과 최적화 과정을 진행한다.

이와 같은 과정을 10번 반복하여 10개의 모든 그룹들이 테스트 데이터 집합으로 모두 한 번씩 사용되도록 반복한다.

표 1은 퍼지 ELM 패턴 분류기의 활성화 함수의 파라미터를 최적화하기 위한 PSO 알고리즘의 초기 파라미터들을 나타낸다.

표 1. PSO 파라미터

Table 1. The parameters of particle swarm optimization

Parameter	Value
Max. generation number	100
Swarm Size	200
w_{\min}	0.4
w_{\max}	0.9
C_1	2.0
C_2	2.0

실험에 적용된 기계학습 데이터 집합들의 특징 파라미터는 표 2와 같다.

표 2. 실험에 사용된 데이터 특성

Table 2. Characteristics of Machine Learning Datasets used in the experiments

Data	Number of Classes	Number of features	Number of patterns
Australian	2	42	690
Balance	3	4	625
Bupa	2	6	347
German	2	24	1000
Glass	6	9	214
Hayes	3	5	132
Ionosphere	2	34	351
Iris	3	4	150
Pima	2	8	768

패턴 분류 성능 비교를 위하여 패턴 분류기의 오분류율을 평가 지수로 선택하였다.

패턴 분류기의 패턴 오분류율은 (13)과 같이 정의된다.

$$\text{오분류율} = \frac{1}{N} \sum_{k=1}^N f(t_k, \hat{y}_k) \cdot 100 \quad (13)$$

$$f(a,b) = \begin{cases} 0, & \text{if } a=b \\ 1, & \text{if } a \neq b \end{cases}$$

여기서, N은 데이터의 크기를 나타내고, \hat{y}_k 는 k번째 입력 데이터에 대한 퍼지 ELM의 출력 값을 의미한다.

표 3은 학습 데이터 집합, 확인 데이터 집합과 테스트 데이터 집합을 이용하여 실험한 결과를 보인다.

제안된 PSO 알고리즘을 이용하여 최적화된 퍼지 ELM 과 신경회로망의 활성화 함수 파라미터를 랜덤하게 설정한 퍼지 ELM의 패턴 분류 성능을 비교 하였다.

본 연구에서 학습 데이터 집합, 확인 데이터 집합과 테스트 데이터 집합의 크기 비율은 6 : 3 : 1을 사용하여 데이터를 분할하였다.

표 3에 보인 결과에 따르면, 랜덤하게 활성화 함수의 위치를 결정하는 전형적인 ELM의 방법을 따른 퍼지 ELM 패턴 분류기의 패턴 분류 성능에 비해 최적화 알고리즘인 PSO 알고리즘을 이용하여 최적화 된 퍼지 ELM 패턴 분류기의 분류 성능의 우수함을 알 수 있었다.

표 3. 제안된 패턴 분류기와 기존 패턴 분류기 성능 비교

Table 3. Result of Comparative analysis

Data	PSO_FELM		FELM	
	PI	EPI	PI	EPI
Australian	24.06	28.12	44.42	44.49
Balance	8.12	9.28	9.88	10.88
Bupa	25.07	32.46	41.88	40.87
German	25.63	28.20	29.72	29.70
Glass	25.82	31.33	45.32	50.51
Hayes	31.07	44.02	51.69	56.92
Ionosphere	9.93	12.46	20.22	21.16
Iris	2.33	3.33	1.33	3.33
Pima	30.08	30.46	34.89	34.89

5. 결론 및 향후 연구

본 논문에서는 단일 은닉층을 가진 피드포워드 신경회로망 구조를 기반으로 네트워크의 학습 속도를 개선하고 모델의 일반화 성능을 개선한 Extreme Learning Machine을 기반으로 노이즈에 강한 특성을 가지는 퍼지 집합 이론을 결합한 퍼지 ELM을 제안하고, 최적화 알고리즘의 일종인 PSO 알고리즘을 이용하여 제안된 퍼지 ELM의 활성화 함수의 위치를 최적화하는 패턴 분류기를 제안하였다.

제안된 최적화된 퍼지 ELM 패턴 분류기의 성능을 평가하기 위하여 기계학습 데이터 집합들을 사용하였고, 실험결과를 통해서 균등 확률 분포를 이용하여 은닉층의 파라미터를 결정하는 패턴 분류기에 비해 PSO 알고리즘을 이용하여 은닉층의 파라미터를 최적화된 패턴 분류기가 더욱 우수한 패턴 분류 성능을 보임을 알 수 있었다.

향후 연구에서는 네트워크의 복잡도를 증가시켜 패턴 분류기의 성능을 개선하고자 하는 연구가 필요할 것으로 보인다.

References

- [1] Y. J. Lin, J. J. Li, P. R. Lin, G. P. Lin, and J. K. Chen, "Feature Selection via Neighborhood Multi-Granulation Fusion," *Knowledge Based Systems*, Vol. 67, pp. 162-168, 2014.
- [2] G. E. Hinton, S. Osindero, and Y. The, "A fast learning algorithm for deep belief nets," *Neural Computation*, Vol. 18, pp. 1527-1554, 2006.
- [3] G. B. Hwang, Q. U. Zhu, and C. K. Siew, "Extreme learning machine: Theory and application," *Neurocomputing*, Vol. 70, pp. 489-501, 2006.
- [4] J. Kennedy and R. Everhart, "Particle Swarm Optimization," *Proc. of IEEE International Conference on Neural Networks*, Vol. 4, pp. 1942-1948, 1995.
- [5] W. Pedrycz, "Conditional fuzzy C-Means," *Pattern Recognition Letters*, Vol. 17, No. 6, pp. 625-632, 1996.
- [6] Tae-Chon Ahn, Sok-Beom Roh, Kuk-Yeon Hwang, Jihong Wang and Yong Soo Kim, "Design of Fuzzy Pattern Classifier based on Extreme Learning Machine," *Journal of Korean Institute of Intelligent Systems*, Vol. 25, No. 5, pp. 509-514, 2015.
- [7] Gil-Sung Kim, Byoung-Jun Park and Sung-Kwun Oh, "The Design of Polynomial Network Pattern Classifier based on Fuzzy Inference Mechanism and Its Optimization," *Journal of Korean Institute of Intelligent Systems*, Vol. 17, No. 7, pp. 970-976, 2007.

[8] J.H. Cho, D.J. Lee and M. G. Chun, "Parameter Optimization of Extreme Learning Machine Using Bacterial Foraging Algorithm," *Journal of Korean Institute of Intelligent Systems*, Vol. 17, No. 6, pp. 807-812, 2007.

[9] Sung-Suk Kim, Sung-Soo Kim and Jeong- Woong Ryu, "Improved Fuzzy Clusteirng," *Journal of Korean Institute of Intelligent Systems*, Vol. 15, No. 1, pp. 6-11, 2005.

[10] R. E. Perez and K. Behdinan, Particle swarm approach for structural design optimization," *Computers & Structures*, vol. 85, Issues 19-20, pp. 1579-1588, 2007.

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



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 전기및전자공학과 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