

# 선택적 학습률을 활용한 학습법칙을 사용한 신경회로망

## Fuzzy Neural Network Using a Learning Rule utilizing Selective Learning Rate

백용선<sup>1</sup> · 김용수<sup>2\*</sup>

Young-Sun Baek and Yong-Soo Kim

<sup>1</sup> 대덕대학 컴퓨터웹정보과

E-mail : dodo029@ddc.ac.kr

<sup>2</sup> 대전대학교 컴퓨터공학과

E-mail : kystj@dju.kr

### 요 약

본 논문은 연결강도를 조정할 때 결정 경계선 근처에 있는 데이터를 더 반영하는 학습법칙을 제안하였다. 이 학습법칙은 outlier가 결정 경계선에 미치는 영향을 줄여 더 나은 결정 경계선을 형성하도록 한다. 제안하는 학습법칙을 IAFC(Integrated Adaptive Fuzzy Clustering) 신경회로망의 구조에 적용하였다. IAFC 신경회로망은 배운 것을 유지하는 안정성이 있으면서, 새로운 것을 배울 수 있는 안정성이 있다. 이 퍼지 신경회로망의 성능과 LVQ(Learning Vector Quantization) 신경회로망 및 오류역전과 신경회로망의 성능과 비교하였다. 실험결과 제안하는 퍼지 신경회로망의 성능이 우수함을 보여주었다.

**키워드 :** 선택적 학습률, 결정 경계선, 학습 법칙, 퍼지 신경회로망

### Abstract

This paper presents a learning rule that weights more on data near decision boundary. This learning rule generates better decision boundary by reducing the effect of outliers on the decision boundary. The proposed learning rule is integrated into IAFC neural network. IAFC neural network is stable to maintain previous learning results and is plastic to learn new data. The performance of the proposed fuzzy neural network is compared with performances of LVQ neural network and backpropagation neural network. The results show that the performance of the proposed fuzzy neural network is better than those of LVQ neural network and backpropagation neural network.

## 1. 서 론

신경회로망은 뇌가 동작하는 원리를 모방하는 것으로, 학습을 통하여 연결강도를 조절하여 성능을 개선한다. 신경회로망에서 연결강도를 조절하는 과정은 학습법칙에 의하여 제어되며, 이 학습법칙은 신경회로망의 성능에 중요한 역할을 한다. 학습법칙은 인간이 경험을 통하여 학습하는 원리를 모방하는 것으로 연결강도를 신경회로망의 성능을 개선하는 방향으로 조절한다. 학습법칙에서 학습률은 연결강도의 변화량을 조절하고, 연결강도의 수렴뿐만 아니라 연결강도가 적절한 값을 가질 수 있는나에 중요한 역할을 한다. 학습률에 따라 연결강도가 조절되는 양이 다르기 때문에 학습률이 학습과정에서 연결강도가 어떠한 값을 가지느냐에 중요한 영향을 미친다. 따라서, 학습이 진행되는 동안 학습률을 어떻게 조정하느냐가 학습법칙의 중요한 요소가 된다. 신경회로망에서 연결강도의 값은 결정 경계선(Decision

Boundary)를 결정하고, 형성된 결정 경계선이 얼마나 잘 형성 되었는 지가 신경회로망의 성능을 좌우한다. 본 논문에서는 학습률을 조절할 때, 단순히 연결강도의 수렴을 위하여 조절하기 보다는 연결강도의 수렴을 보장하면서 outlier가 결정경계선에 미치는 영향을 줄여서 적절한 결정 경계선이 형성되도록 학습률을 조절하는 학습법칙을 제안한다. 제안한 학습법칙은 결정 경계선 근처에 있는 입력 벡터는 결정 경계선에서 멀리 떨어져 있는 입력 벡터에 비해서 적절한 결정 경계선에 대한 정보를 더 많이 가지고 있기 때문에, 결정 경계선 근처에 있는 입력 벡터에 대해서 더 큰 학습률을 주는 것이다.

학습법칙은 무감독 학습(Unsupervised Learning), 감독 학습(Supervised Learning), 강화 학습(Reinforcement Learning)으로 나뉜다 [1]. 감독 학습은 입력 벡터와 함께 원하는 출력을 신경회로망에 제공하여 원하는 출력과 실제 출력의 차이를 줄여 가는 방향으로 연결강도를 조정한다. LVQ는 학습률을 임의의 작은 값으로 초기화한 후 시간이 지나감에 따라서 감소시킨다. 학습률을 어떤 값으로 초기화했느냐에 따라서 일부 클래스가 선정되지 않는 문제점이 있다. 한편으로는, 퍼지 소속도를 활용하여 클래스의 대표값

접수일자 : 2010년 7월 27일

완료일자 : 2010년 10월 11일

+ : 교신저자

을 좀 더 세밀하게 조정하고자 하는 연구가 이루어져 왔다 [2-9]. 퍼지 소속도는 입력 벡터가 특정 클래스에 소속되어 있는 정도를 나타낸다. 클래스의 대표값을 조절할 때 입력 벡터가 반영되는 정도를 그 입력 벡터가 특정 클래스에 소속되어 있는 정도를 활용하여 조절하는 것이다. 기존의 학습법칙에서 학습률은 연결강도를 수정시키는 데 주안점을 두고 있으나, 퍼지 소속도를 활용하는 방법들은 입력 벡터가 특정 클래스에 소속되어 있는 정도를 반영하였다. Chung과 Lee는 LVQ에 퍼지 소속도를 도입한 Fuzzy LVQ (FLVQ)를 제안하였다 [2, 3]. 이 FLVQ는 목표 소속도와 실제 소속도의 차이를 입력 벡터와 클래스의 대표값의 차이와 곱한 것만큼 클래스의 대표값을 조정하였다. 이 FLVQ의 문제는 실제 상황에서 목표 소속도를 얻기가 쉽지 않다는 것이다. Karayiannis도 LVQ를 퍼지화한 FLVQ를 제안하였다 [4, 5]. Kim은 분류가 맞느냐 또는 틀리느냐에 따라서 다른 학습률을 사용하는 FLVQ를 제안하였다 [6]. Kim은 또한 분류가 맞을 때 입력 벡터와 클래스들의 대표값들 간의 상대적인 위치를 고려하는 FLVQ를 제안하였다 [7-9].

본 논문에서는 퍼지 소속도와 함께 결정 경계선으로부터 입력 벡터가 얼마나 멀리 떨어져 있는가를 고려하는 학습법칙을 제안한다. 결정 경계선 근처에 있는 데이터는 outlier에 비해서 적절한 결정 경계선에 대한 정보를 더 가지고 있다. outlier가 하나의 클래스에 치우쳐 있을 때는 비록 치우쳐 있는 클래스에 배정하는 것은 맞으나, 클래스의 대표값을 조절할 때 많이 반영을 하면 결정 경계선이 적절한 값을 가지지 못하게 된다. outlier가 많이 반영되는 것을 방지하기 위하여 퍼지 소속도 외에 입력 벡터가 결정 경계선에서 얼마나 멀리 떨어져 있는가를 고려한다. 클래스의 대표값을 조절할 때 입력 벡터가 결정 경계선 근처에 있으면 큰 가중치를 주고, 입력 벡터가 결정 경계선에서 멀리 떨어져 있으면 작은 가중치를 준다. 3개 이상의 클래스들이 형성되어 있으면, 승자와 제2의 승자 사이에 형성된 결정 경계선으로부터 입력 벡터가 얼마나 떨어져 있는지를 고려한다. 이는 능동적 학습(Active Learning)에서 모호한 지역에 있는 데이터를 중요시 하는 것과 유사하다. 능동적 학습에서는 모호한 지역에 있는 데이터를 중요시 하여 그 지역에 있는 데이터의 클래스 정보를 제공하여 성능을 개선하는 반면에 본 논문에서는 모호한 지역에 있는 데이터를 중요시 하는 방법은 클래스의 대표값을 조절할 때 모호한 지역에 있는 데이터의 반영도를 높이는 것이다 [10, 11].

제안하는 학습법칙을 IAFC 신경회로망의 구조에 적용하였다 [6, 12-14]. 학습을 하는 도중에 새로운 데이터가 입력되면 기존의 신경회로망들은 현존하는 클래스 중 하나의 클래스에 배정해야 하지만, IAFC 신경회로망은 새로운 데이터가 현존하는 클래스의 대표값과 충분히 유사하지 않으면 현존하는 클래스에 배정하지 않고 새로운 클래스를 형성하는 점이 다르다. 이는 기존의 신경회로망들에서 데이터가 현존하는 클래스들의 대표값들과 충분히 유사하지 않더라도 존재하는 클래스들 중 하나의 클래스에 배정해야 하는 방법 때문에 outlier에 의해서 발생하는 클래스의 대표값의 악화를 방지할 수 있는 장점이 된다. 기존의 신경회로망은 초기에 원하는 클래스의 개수를 정하고, 이에 따라서 클래스들의 대표값들을 임의의 작은 수들로 초기화 해야 한다. 선정한 초기 값에 따라서 성능의 변화가 있고, 코호넨의 자기 조직화 특징 지도 [15]의 경우에는 초기값에 따라서 원

하는 개수의 클래스가 형성되지 않는 Underutilization 문제가 있다. 이에 비해, IAFC 신경회로망은 ART-1 신경회로망 [16]과 유사하게 클래스의 개수를 초기화하지 않고, 동적으로 증가시킨다. 즉, 데이터가 존재하는 클래스들의 대표값들과 충분히 유사하지 않으면, 새로운 클래스를 형성함으로써 클래스의 개수를 동적으로 증가시킨다. 따라서, IAFC 신경회로망은 클래스의 대표값을 초기화 할 필요가 없다. 첫번째 입력되는 데이터를 첫번째 클래스의 대표값으로 사용하고, 다음부터 입력되는 데이터 부터는 존재하는 클래스의 대표값과 비교하여 충분히 유사하면 그 클래스에 배정하고, 그 클래스의 대표값을 조절한다. 만약 존재하는 클래스의 대표값과 입력된 데이터가 충분히 유사하지 않으면, 새로운 클래스를 형성하고 입력된 데이터를 새로운 클래스의 대표값으로 한다. 그림 1은 IAFC 신경회로망의 구조이다.

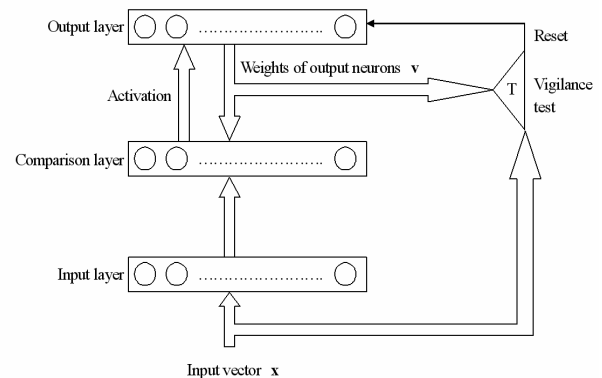


그림 1. IAFC 신경회로망의 구조 [14]  
Fig. 1. The structure of IAFC neural network

새로운 학습법칙을 IAFC 신경회로망의 구조에 적용하여, 클래스의 대표값을 조절할 때 입력 벡터가 있는 위치에 따라서 입력 벡터의 반영도를 조절하는 신경회로망을 본 논문에서 제안한다. 승자를 유클리디안 거리를 사용하여 결정한 후, vigilance 테스트를 하여 선정된 클래스의 대표값이 입력 벡터와 충분히 같으면 입력 벡터를 선정된 클래스에 배정하고 클래스의 대표값을 조절한다. 이때 충분히 같은지는 vigilance parameter에 의해서 결정된다. 충분히 같지 않으면 새로운 클래스를 형성하고 입력 벡터를 새로운 클래스의 대표값으로 한다. 클래스의 대표값을 조절할 때, LVQ와 유사하게 분류가 맞으면 선정된 클래스의 대표값을 입력 벡터쪽으로 보내고, 분류가 틀리면 선정된 클래스의 대표값을 입력 벡터쪽으로부터 멀리 보낸다. 분류가 맞았을 때 입력 벡터가 결정 경계선으로부터 얼마나 떨어져 있느냐를 반영하여 클래스의 대표값을 조절한다. 입력 벡터가 결정 경계선에서 멀리 떨어져 있는 경우는 입력 벡터가 결정 경계선 근처에 있는 경우에 비하여 작은 학습률을 가진다. 이 신경회로망은 감독학습을 사용하기 때문에, 분류가 제대로 되었다면 결정 경계선 근처에 있는 입력 벡터는 적절한 결정 경계선에 대한 많은 정보를 가지고 있다. 따라서, 입력 벡터가 결정 경계선 근처에 있는 경우에 더 큰 학습률을 갖도록 함으로써 결정 경계선 근처에 있는 입력 벡터의 클래스의 대표값에 대한 반영도를 높이는 것이다. 결정 경계선에서 멀리 떨어져 있는 입력 벡터에 대해서는 작은 학습률을 사용함으로써 outlier가 결정 경계선에 미치는 영향을 줄이도록 하였다. 분류가 틀렸을 때는, 입력 벡터가 틀린 클레

스에 소속되어 있는 정도를 반영하여 클래스의 대표값을 조정한다.

## 2. 퍼지 신경회로망 [17]

입력 벡터가 퍼지 신경회로망에 가해진 후, 출력 뉴런들 간의 경쟁은 winner-take-all 식으로 일어난다. 입력 벡터와의 유클리디안 거리가 제일 작은 연결강도를 가진 출력 뉴런이 경쟁에서 승리한다. 즉 I번째 출력 뉴런,

$$I = \min_i \| \mathbf{x} - \mathbf{v}_i(t) \|, \quad (1)$$

이 경쟁에서 승리한다. 여기서  $\mathbf{x}$  는 입력 벡터이고,  $\mathbf{v}_i(t)$  는 i번째 출력 뉴런의 연결강도이다.

출력 뉴런들 중에서 승자를 결정한 후에 퍼지 신경회로망은 다음의 vigilance 기준에 의해 vigilance 테스트를 한다 :

$$e^{-u_i} \| \mathbf{x} - \mathbf{v}_i(t) \| \leq T, \quad (2)$$

여기서 T는 vigilance parameter이다. 퍼지 소속도  $u_i$  는 다음과 같이 정의된다.

$$u_i = \frac{\left[ \frac{1}{\| \mathbf{x} - \mathbf{v}_i(t) \|^2} \right]^{\frac{1}{m-1}}}{\sum_{j=1}^n \left[ \frac{1}{\| \mathbf{x} - \mathbf{v}_j(t) \|^2} \right]^{\frac{1}{m-1}}}, \quad (3)$$

여기서 n은 존재하는 committed 출력 뉴런의 개수이고,  $m \in [1, \infty]$  는 weight exponent이며 실험적으로 2로 놓는다.

만약 승자가 vigilance 테스트를 만족하면 퍼지 신경회로망은 승자의 연결강도를 다음의 학습법칙을 사용하여 조절한다 :

$$\begin{aligned} \mathbf{v}_i(t+1) &= \mathbf{v}_i(t) + \frac{1-u_i}{t} \cdot e^{-\alpha \cdot d_{X,middle}} (\mathbf{x} - \mathbf{v}_i(t)) && \text{if } \mathbf{x} \text{ is classified correctly,} \\ \mathbf{v}_i(t+1) &= \mathbf{v}_i(t) - \frac{u_i}{t} \cdot (\mathbf{x} - \mathbf{v}_i(t)) && \text{if } \mathbf{x} \text{ is classified incorrectly,} \\ \mathbf{v}_i(t+1) &= \mathbf{v}_i(t) && \text{for } i \neq I, \end{aligned} \quad (4)$$

여기서 t는 반복횟수이고,  $\alpha$ 는 입력 벡터가 승자의 대표값과 제2승자의 대표값의 평균값에서 멀어질수록 가중치가 감소하는 정도를 조절하는 상수이고,  $d_{X,middle}$  은 입력 벡터와 승자의 대표값과 제2승자의 대표값의 평균값과의 유클리디안 거리이다. 식(4)에서  $e^{-\alpha \cdot d_{X,middle}}$  은 입력 벡터가 결정 경계선에서 멀어질수록 가중치를 작게 주기 위한 것이다. 식 (4)는 본 논문에서 제안하는 새로운 학습법칙으로 퍼지 신경회로망의 구조가 감독 학습법칙을 사용하는 것과 능동적 학습에서 모호한 지역에 있는 입력 벡터들을 중요시

한다는 것에 주안점을 두고 있다. 즉, 감독 학습을 사용하기 때문에 입력 벡터가 어떤 클래스에 속해야 하는 지 정확히 알고 모호한 지역에 있는 입력 벡터는 중요도가 높다는 것을 활용하는 것이다. 따라서, 결정 경계선 근처에 존재하는 입력 벡터는 적절한 결정 경계선에 대한 정보를 많이 가지고 있다. 이에 비해 결정 경계선에서 멀리 떨어진 입력 벡터는 적절한 결정 경계선에 대한 정보가 적다. 이를 활용하여 결정 경계선 근처에 있는 입력 벡터의 반영도를 결정 경계선에서 멀리 떨어진 입력 벡터의 반영도에 비해 크게 하는 것이다. 입력 벡터가 결정 경계선 근처에 있으면,  $d_{X,middle}$  이 작고  $e^{-\alpha \cdot d_{X,middle}}$  은 크다. 반면에, 입력 벡터가 결정 경계선에서 멀리 떨어져 있으면,  $d_{X,middle}$  이 크고  $e^{-\alpha \cdot d_{X,middle}}$  은 작다.

## 3. 실험 및 결과

제안한 퍼지 신경회로망의 성능과 LVQ 알고리즘과 오류 역전파 신경회로망의 성능을 비교하기 위해서 클러스터링 알고리즘의 성능을 비교하는데 많이 쓰이는 Iris 데이터를 사용하였다. Iris 데이터는 150개의 4차원 데이터로 구성되어 있다. 이 데이터는 3개의 클래스를 가지고 있고, 각 클래스는 50개의 데이터를 가지고 있다. 150개의 데이터 중 임의로 75개의 데이터를 선정해 훈련 데이터로 사용했는데, 각 클래스로부터 25개의 데이터를 사용하였다. 나머지 75개의 데이터는 테스트 데이터로 사용하였다.

반복 학습을 하는 중에 현재의 연결강도와 이전의 연결강도의 차이인  $\| \mathbf{v}(t) - \mathbf{v}(t-1) \|$  이 0.01보다 작으면 연결강도들이 실험적으로 수렴한 것으로 보고, 제안하는 퍼지 신경회로망의 훈련을 끝내도록 하였다. 훈련을 끝낸 후 테스트 데이터를 사용하여 제안하는 퍼지 신경회로망을 테스트 하였다. 그림 2와 같이 제안하는 퍼지 신경회로망은 4개의 오류를 발생시켰으며, 오류역전파 신경회로망은 5개의 오류를 발생시켰고, LVQ 신경회로망은 7개의 오류를 발생시켰다.

		Output		
		1	2	3
Desired	1	18	7	
	2		25	
	3			25

(a) LVQ 신경회로망  
(a) LVQ neural network

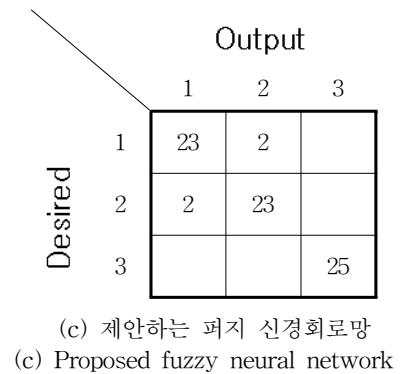
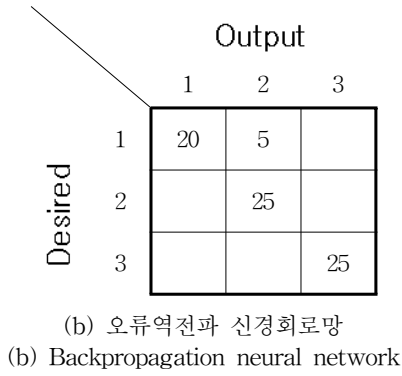




그림 2. Iris 데이터를 사용한 결과 비교  
Fig. 2. Comparison of results using Iris data

그림 3은 T가 2.5일 때 학습시  $\alpha$ 에 따른 반복 횟수에 대한 오류의 개수를 나타낸다. 그림 3에서 알 수 있는 바와 같이 실험적으로 수렴하는데 필요한 반복횟수가 다른 신경회로망들에 비하여 아주 적다. T가 2.5이고  $\alpha$ 가 0.2일 때 테스트 데이터에 대한 오류의 개수는 2개이고, T가 2.5이고  $\alpha$ 가 0.3일 때 테스트 데이터에 대한 오류의 개수는 2개이다.



(a)  $\alpha$ 가 0.2 일 때  
(a) When  $\alpha$  is 0.2.



(b)  $\alpha$ 가 0.3 일 때  
(b) When  $\alpha$  is 0.3.

그림 3. T가 2.5일 때 훈련시  $\alpha$ 에 따른 반복 횟수에 대한 오류의 개수

Fig. 3. Number of errors versus number of iterations during training when T is 2.5.

#### 4. 결론

입력 벡터가 결정경계선에서 부터 떨어져 있는 정도에 따라서 학습률을 정하는 학습법칙을 제안하였고, 제안하는 학습법칙을 IAFC 신경회로망에 적용하였다. 제안하는 퍼지 신경회로망의 성능을 비교하기 위해서 Iris 데이터를 사용하여 LVQ 신경회로망과 오류역전파 신경회로망의 성능들과 비교하였다. 실험을 한 결과 제안하는 퍼지 신경회로망이 LVQ 신경회로망과 오류역전파 알고리즘에 비하여 적은 수의 오류를 내서 성능의 우수함을 보여 주었다. 또한 제안하는 퍼지 신경회로망은 실험적으로 수렴하는데 필요한 반복 횟수가 적었다.

#### 참고 문헌

- [1] S. Haykin, *Neural Networks - A Comprehensive Foundation, 2nd Ed.*, Prentice Hall, Upper Saddle River, NJ, 1999.
- [2] F.-L. Chung and T. Lee, "A Fuzzy Learning Model for Membership Function Estimation and Pattern Classification," *Proceedings of the Third IEEE Conference on Fuzzy Systems*, pp. 426-431, 1994.
- [3] F.-L. Chung and T. Lee, "Fuzzy Learning Vector Quantization," *Proceedings of 1993 International Joint Conference on Neural Networks*, pp. 2739-2743, 1993.
- [4] N. B. Karayiannis, "Weighted Fuzzy Learning Vector Quantization and Weighted Fuzzy C-Means Algorithms," *IEEE International Conference on Neural Networks*, pp. 1044-1049, 1996.
- [5] N. B. Karayiannis and J. C. Bezdek, "An

Integrated Approach to Fuzzy Learning Vector Quantization and Fuzzy C-Means," *IEEE Trans. on Fuzzy Systems*, pp. 626-629, 1997.

[6] Yong Soo Kim, "Fuzzy Neural Network Model Using Asymmetric Fuzzy Learning Rates," *Journal of Fuzzy Logic and Intelligent Systems*, Vol. 15, No. 7, pp. 800-804, 2005.

[7] Yong Soo Kim, "Fuzzy Learning Rule Using the Distance between Datum and the Centroids of Clusters," *Journal of Fuzzy Logic and Intelligent Systems*, Vol. 17, No. 4, pp. 472-476, 2007.

[8] Y. S. Kim et al., "Supervised IAFC Neural Network Based on the Fuzzification of Learning Vector Quantization." *Lecture Notes in Artificial Intelligence 4253*, Part III, pp. 248-254, 2006.

[9] Y. S. Kim and S. I. Kim, "Fuzzy Neural Network Model Using a Fuzzy Learning Vector Quantization with the Relative Distance," *Proceedings of the Seventh International Conference on Hybrid Intelligent Systems*, pp. 90-94, 2007.

[10] M. Plutowski and H. White, "Selecting Concise Training Sets from clean Data," *IEEE Trans. on Neural Networks*, Vol. 4, No. 2, pp. 305-318, 1993.

[11] J. - N. Hwang, J. J. Choi, S. Oh, R. J. Marks II, "Query-Based Learning Applied to Partially Trained Multilayer Perceptrons," *IEEE Trans. on Neural Networks*, Vol. 2, No. 1, pp. 131-136, 1991.

[12] Y. S. Kim and S. Mitra, "An Adaptive Integrated Fuzzy Clustering Model for Pattern Recognition," *Fuzzy Sets and Systems*, Vol. 65, pp. 297-310, 1994.

[13] Y. S. Kim, "An Unsupervised Neural Network Using a Fuzzy Learning Rule," *Proceedings of 1999 IEEE International Fuzzy Systems Conference*, Vol. 1, pp. 349-353, 1999.

[14] Y. Kim, and Z. Bien., "Integrated Adaptive Fuzzy Clustering (IAFC) Neural Networks Using Fuzzy Learning Rules," *Iranian Journal of Fuzzy Systems*, Vol. 2, No. 2, pp. 1-13, 2005.

[15] T. Kohonen, *Self-Organizing and Associative Memory*, 3rd ed., Springer-Verlag, 1989.

[16] G. A. Carpenter and S. Grossberg, "A Massively Parallel Architecture for A Self-Organizing Neural Pattern Recognition Machine," *Computer Vision, Graphics, and Image Processing*, Vol. 37, pp. 54-115, 1987.

[17] Young-Sun Baek, *Fuzzy Neural Network Model Using a Supervised Learning Rule*, Ph. D. Thesis, Daejeon University, 2009.

## 저 자 소 개



### 백용선(Yong-Sun Baek)

1998년 : 우송대학교 컴퓨터학과와 공학사  
 1999년 : 대전대학교 대학원 컴퓨터공학과  
 공학석사  
 2003년~현재 : 대덕대학 컴퓨터웹정보과  
 초빙교수  
 2009년 : 대전대학교 대학원 컴퓨터공학과  
 공학박사

관심분야 : 신경회로망, 퍼지 논리 등  
 Phone : +82-42-866-0394  
 Fax : +82-42-866-0399  
 E-mail : dodo029@ddc.ac.kr



### 김용수(Yong-Soo Kim)

1981년 : 연세대학교 전기공학과 공학사  
 1983년 : KAIST 전기 및 전자공학과  
 공학석사  
 1986년 : 삼성전자 종합연구소 주임연구원  
 1993년 : Texas Tech Univ. 공학박사  
 1995년~현재 : 대전대학교 컴퓨터공학과  
 교수

관심분야 : 신경회로망, 퍼지 논리, 패턴인식, 영상처리, 침  
 입탐지 등  
 Phone : +82-42-280-2547  
 Fax : +82-42-284-0109  
 E-mail : kystj@dju.kr