

Underutilization 문제를 해결한 퍼지 신경회로망 모델

A Fuzzy Neural Network Model Solving the Underutilization Problem

김용수 · 함창현* · 백용선

Yong Soo Kim, Chang Hyun Ham and Yong Sun Baek

대전대학교 컴퓨터정보통신 공학부

* 543 미디어텍

요 약

본 논문에서는 underutilization 문제를 해결한 퍼지 신경회로망 모델을 제시한다. 이 퍼지 신경 회로망은 ART-1 신경회로망과 유사한 제어 구조를 가지고 있어 유연성이 있으면서도 안정성이 있다. 또한 연결강도의 초기화가 필요없고 ART-1 신경회로망에 비하여 잡음에 민감하지 않다. 이 퍼지 신경회로망의 학습법칙은 코호넨의 학습법칙을 변형하고 퍼지화 하였으며 누설 경쟁학습의 퍼지화와조건 확률의 퍼지화에 기반을 두고 있다. 출력 뉴런 중에서 승자를 정한 후에 행해지는 점 검 테스트에서는 유사적으로 상대적 거리를 사용하였다. 이 상대적 거리는 유클리디안 거리와 함께 데이터와 클러스터들의 대표값들 간의 상대적인 위치를 고려한 것이다. 본 논문에서 제안한 퍼지 신경회로망과 코호넨 자기 조직화 특징 지도의 성능을 비교하기 위하여 널리 사용되어온 IRIS 데이터와 가우시안 분포 데이터를 사용하였다.

Abstract

This paper presents a fuzzy neural network model which solves the underutilization problem. This fuzzy neural network has both stability and flexibility because it uses the control structure similar to ART(Adaptive Resonance Theory)-1 neural network. And this fuzzy neural network does not need to initialize weights and is less sensitive to noise than ART-1 neural network is. The learning rule of this fuzzy neural network is the modified and fuzzified version of Kohonen learning rule and is based on the fuzzification of leaky competitive learning and the fuzzification of conditional probability. The similarity measure of vigilance test, which is performed after selecting a winner among output neurons, is the relative distance. This relative distance considers Euclidean distance and the relative location between a datum and the prototypes of clusters. To compare the performance of the proposed fuzzy neural network with that of Kohonen Self-Organizing Feature Map the IRIS data and Gaussian-distributed data are used.

Key Words : Underutilization 문제, 퍼지 신경회로망, 학습 법칙, 유사 척도

1. 서 론

코호넨의 자기 조직화 특징 지도(Self-Organizing Feature Map)는 신경회로망 중에서 널리 사용되어온 신경회로망 중의 하나이다[1]. 이 신경회로망은 초기에 클러스터의 개수와 연결강도의 값을 초기화해야 한다. 그러나 실제 응용에 있어서 적절한 연결강도의 초기 값을 정하는 것이 쉽지 않을 뿐만 아니라 입력 데이터의 차원이 클 때에는 더욱 어려움이 있다. 따라서 데이터에 따라서는 선정한 연결강도의 초기 값이 적절치 않을 때는 underutilization 문제가 발생한다. Underutilization 문제는 클러스터의 개수를 원하는 값으로 초기화하였으나, 실제 클러스터링한 결과 원하는 개수의 클러스터보다 적게 클러스터가 형성되는 것이다.

반면에 ART(Adaptive Resonance Theory)-1 신경회로

망은 underutilization 문제는 없으나 잡음에 민감한 단점이 있다[2]. 이 신경회로망은 학습법칙을 유도하는 과정에서 빠른 학습(fast learning)을 사용하여 이진수만을 취급할 수 있으며 1에서 0으로 변한 잡음을 복구하지 못하는 단점을 가지고 있다. 그러나 이 신경회로망은 유연성이 있으면서도 안정성이 있다. 즉 과거에 배운 것을 기억하는 안정성이 있으면서도 새로운 것을 배우는 유연성이 있다. 다른 신경회로망들은 클러스터의 크기와 개수를 조절하기 위하여 초기에 클러스터의 개수를 고정하나 이 신경회로망은 클러스터의 크기와 개수를 vigilance parameter로 조절한다. 따라서 다른 신경회로망에서는 만족스럽지는 않지만 다른 클러스터에 비해서 상대적으로 유사하기 때문에 배정하는 것으로 인하여 outlier가 클러스터의 대표값을 저하시키는 문제가 발생한다. 그러나 이 신경회로망에서는 승자를 결정한 후에 재점검하는 vigilance test를 행하기 때문에 위와 같은 현상을 방지한다.

최근에는 모호성을 처리하는 데 뛰어난 퍼지 논리를 도입하여 신경회로망과 조합하는 연구가 활발히 진행되고 있다. Huntsberger와 Ajimarsangsee는 코호넨의 자기 조직화 특징 지도를 퍼지화 하였다. 그들은 임의의 학습률 대신에 퍼지 소

접수일자 : 2000년 12월 19일

완료일자 : 2001년 7월 23일

속도를 사용하였으나 수렴 여부를 증명하지 않았다[3]. Fuzzy Kohonen Clustering Network(FKCN)은 Fuzzy C-Means 모델을 Kohonen Clustering Network의 학습률과 주변 함수의 조정에 이용하였다[4]. 이 퍼지 신경회로망의 단점은 많은 메모리를 필요로 하는 것이다. Carpenter 등이 개발한 fuzzy ART는 ART 신경 회로망을 퍼지화한 것인데 아날로그 데이터를 처리할 수 있다[5]. 이 신경회로망은 클러스터의 모양이 min-max 점들에 의해 결정되는 hyper-box로 제한되어 있다. 그러나 데이터가 0과 1 사이의 값으로 정규화 되어야 하기 때문에 데이터에 따라서는 성능이 나쁠 수가 있다. Simpson의 fuzzy min-max 클러스터링 신경회로망은 ART-1 신경회로망을 hyper-box 소속 함수 등을 사용하여 퍼지화 하였다[6]. 이 퍼지 신경회로망은 fuzzy ART와 유사하게 클러스터의 모양이 제한되어 있고 입력 데이터를 0과 1사이의 값으로 정규화 되어야 하는 단점이 있다. Chung과 Lee는 코호넨의 자기 조직화 특징 지도를 퍼지화 하였는데 학습률과 퍼지 소속도의 조합을 학습률 대신에 사용하였다[7].

본 논문에서 제시하는 퍼지 신경회로망은 ART-1 신경회로망의 장점과 코호넨의 자기 조직화 특징 지도의 장점을 조합한 것으로 유연성과 안정성이 있으면서도 ART-1 신경회로망과 같이 잡음에 민감하지 않다. Moore는 ART-1 신경회로망을 유클리디안 영역에서 해석하였다. 이 해석에서는 하향지향(top-down) 연결강도를 조정하는 학습법칙을 논리적(logical AND)에서 코호넨 학습법칙으로 변환시킬 수 있음을 제시하였다. 원래의 ART-1 신경회로망의 학습법칙은 논리적으로서 pruning 효과가 있기 때문에 1에서 0으로 변환된 잡음이 있을 경우는 복구되지 않는다. 따라서 이러한 잡음이 있을 때에는 복구되지 않는 단점이 있다. Moore가 제시한 대로 이를 코호넨 학습법칙으로 변경하면 원래의 학습법칙과 같이 잡음에 민감하지 않게 된다[8]. 본 논문에서 제시하는 퍼지 신경회로망은 ART-1 신경회로망과 유사한 제어 구조를 가지고 있어 유연성이 있으면서도 안정성이 있다. 즉 현재까지와는 전혀 다른 데이터가 들어올 때는 vigilance test를 통하여 새로운 클러스터를 형성하는 유연성이 있으면서도 과거에 배운 것을 잊지 않는 안정성이 있다. 본 논문에서 제시하는 퍼지 신경회로망은 코호넨의 학습법칙을 변형한 것으로 누설 경쟁(leaky competitive)학습[9]을 퍼지화 한 것과 조건 확률을 퍼지화한 것에 근거를 두고 있다. 누설 경쟁학습은 경쟁에 이기던 지면간에 상관없이 모든 출력 뉴런의 연결강도를 조정한다. 그러나 승리한 출력 뉴런의 연결강도를 조정하는 양이 패배한 출력 뉴런의 연결 강도를 조정하는 양보다 큰 데 이 양을 퍼지 소속도를 사용하여 조절하는 것이다. 조건 확률은 여러 개의 클러스터 중에서 하나의 클러스터가 선택될 확률과 데이터가 선택된 클러스터에 존재할 확률을 곱한 것이다. 이 확률들을 퍼지화하여 퍼지 소속도들로 대체하였다. 하나의 클러스터가 선정될 확률은 Bezdek의 퍼지 소속함수[10]와 유사한 퍼지 소속함수를 사용하여 퍼지화 하였고 데이터가 선정된 클러스터에 존재할 확률은 Mitra와 Pal의 π -함수[11]를 사용하였다. 선정된 클러스터의 연결 강도(대표값)과 데이터 사이의 유사도가 사용자가 정한 값보다 큰 지를 비교하는 vigilance test에는 상대적 거리를 유사 척도로 사용하였다. 이전에는 유사 척도로서 유클리디안 거리와 Mahalanobis 거리가 많이 사용되어 왔다. Mahalanobis 거리는 두 점 사이의 유클리디안 거리에 통계적 성질을 고려한 것이다. 공분산이 큰 경우에는 유클리디안 거리에 작은 가중치를 두고 공분산이 작은 경우에는 유클리디안 거리에 큰 가중치를 준 것이다. 이에 비해 상대적

거리는 유클리디안 거리에 데이터와 클러스터들의 상대적 위치를 고려한 것이다. 즉 경쟁이 심한 곳에서는 유클리디안 거리에 큰 가중치를 주고 경쟁이 심하지 않은 곳에서는 유클리디안 거리에 작은 가중치를 주었다.

2. 퍼지 신경회로망 모델

본 논문에서 제시하는 퍼지 신경회로망은 ART-1 신경회로망과 유사한 구조를 가지고 있다. 따라서 과거의 데이터와 전혀 다른 데이터가 들어왔을 때 vigilance test를 통하여 새로운 클러스터를 형성하는 유연성이 있으면서도 과거에 배운 내용을 잊어버리지 않는 안정성을 가지고 있다.

첫 번째 데이터가 들어왔을 때 첫 번째 클러스터를 형성하고 이 데이터를 첫 번째 클러스터의 연결강도로 사용한다. 두 번째 데이터는 첫 번째 클러스터의 연결강도와 vigilance test를 하여 만족하면 첫 번째 클러스터에 배정하고 연결강도를 조정한다. 만족하지 않으면 두 번째 클러스터를 형성하고 데이터를 두 번째 클러스터의 연결강도로 사용한다. 만약 클러스터의 개수가 두 개 이상이면 다음과 같이 클러스터들 간의 경쟁을 통하여 승자를 결정하고 vigilance test를 행한다.

데이터가 퍼지 신경회로망에 주어졌을 때 출력 뉴런들은 상호 경쟁을 하는데, 데이터와 출력 뉴런의 대표값 사이의 유클리디안 거리가 제일 작은 출력 뉴런이 승리한다. 즉 I번째 출력 뉴런

$$I = \min_i \| \mathbf{x} - \mathbf{v}_i \|$$

이 경쟁에서 승리한다.

승자를 결정한 후에 선택된 I번째 출력 뉴런의 대표값과 데이터 사이의 유사도가 vigilance parameter보다 큰지를 점검하는데, 현재의 클러스터의 개수가 한 개 일 때는

$$\| \mathbf{x} - \mathbf{v}_1 \| \leq T$$

일 때 만족하는 것으로 한다. 여기서 x 는 데이터이고, v_1 은 첫 번째 출력뉴런의 연결강도 값이며, T 는 vigilance parameter이다.

현재의 클러스터의 개수가 2개 이상일 때는

$$e^{-\gamma u_i} \| \mathbf{x} - \mathbf{v}_i \| \leq T$$

이런 만족하는 것으로 한다. 여기서 γ 는 클러스터의 경계선을 조절하는 상수이고 실험적으로 1로 놓았다.

u_i 는

$$u_i = \frac{\left[\frac{1}{\| \mathbf{x} - \mathbf{v}_1 \|^2} \right]^{\frac{1}{m-1}}}{\sum_{j=1}^m \left[\frac{1}{\| \mathbf{x} - \mathbf{v}_j \|^2} \right]^{\frac{1}{m-1}}}$$

이고, 여기서 n 은 현재 존재하는 클러스터의 개수이고, m 은 fuzziness를 조절하는 상수로 실험적으로 2로 놓았다. 유클리디안 거리 $\| \mathbf{x} - \mathbf{v}_i \|^2$ 에 $e^{-\gamma u_i}$ 를 곱한 것은 경쟁이 심한 곳에서는 퍼지 소속도가 작아 큰 가중치를 주고 경쟁이 심하지 않은 곳에서는 퍼지 소속도가 커서 작은 가중치를 주도록 한 것이다. 즉 같은 유클리디안 거리라도 데이터가 클러스터들 간의 경쟁이 심한 곳에 있느냐 경쟁이 심하지 않은 곳에 있느냐

나에 따라서 가중치가 달라져 다른 값을 갖게 되는 것이다.

선정된 출력 뉴런이 위의 점진 기준을 만족하면, 출력 뉴런의 연결강도를 아래와 같이 조정한다.

$$v_i(t+1) = v_i(t) + f(t) \text{CDOT } \lambda_{\text{fuzzy}} (\mathbf{x} - v_i(t))$$

for all i,

여기서 f(t)는 반복횟수의 함수이고 λ_{fuzzy} 는

$$u_i^2 \cdot \Pi(\mathbf{x}, v_i(t), T) \text{이다.}$$

f(t)는 $\frac{1}{k(t-1)+1}$ 이고, k는 상수이고, t는 반복횟수이다.

$\Pi(\mathbf{x}, v_i(t), T)$ 는

$$\Pi(\mathbf{x}, v_i(t), T) = \begin{cases} 1 - 2 \left(\frac{\|\mathbf{x} - v_i(t)\|}{T} \right)^2, & \text{when } 0 \leq \|\mathbf{x} - v_i(t)\| \leq \frac{T}{2} \\ 2 \left(1 - \frac{\|\mathbf{x} - v_i(t)\|}{T} \right)^2, & \text{when } \frac{T}{2} \leq \|\mathbf{x} - v_i(t)\| \leq T \\ 0, & \text{otherwise} \end{cases}$$

이다.

반복횟수의 함수 f(t)는 연결강도의 수렴을 위한 것이고 [12], λ_{fuzzy} 는 조건 확률을 퍼지화한 것이다. 즉 u_i^2 은 여러 개의 클러스터 중에서 특정 클러스터를 선정할 확률을 퍼지화한 것이고, $\Pi(\mathbf{x}, v_i(t), T)$ 는 데이터가 선정된 클러스터에 존재할 확률을 퍼지화한 것이다. 또한 모든 출력의 연결강도를 조정하되 조정하는 량을 λ_{fuzzy} 로 조정하는 것은 누설 경쟁학습을 퍼지화한 것이다.

본 논문에서 제시하는 퍼지 신경회로망의 알고리즘을 요약하면 아래와 같다.

- [1 단계] 파라미터들과 입력 뉴런들과 출력 뉴런들을 초기화한다.
- [2 단계] 입력 데이터 x를 가한다.
- [3 단계] 출력 뉴런중에 승자를 구한다.
- [4 단계] 승리한 출력 뉴런이 vigilance test를 만족하면 6단계로 가고, 그렇지 않으면 5단계로 간다.
- [5 단계] 새로운 클러스터를 형성한다. 입력 데이터 x를 새로운 출력 뉴런의 연결강도로 한다. 2단계로 가서 반복한다.
- [6 단계] 모든 출력 뉴런의 연결강도를 갱신한다. 2단계로 가서 반복한다.

3. 실험 및 고찰

본 논문에서 제시하는 퍼지 신경회로망과 코호넨의 자기조직화 특징 지도의 성능을 비교하기 위하여 IRIS 데이터와 가우시안 분포의 데이터를 사용하였다. IRIS 데이터는 클러스터링 알고리즘들의 성능 비교를 위하여 널리 사용되어 왔고 가우시안 분포의 데이터도 인위적인 데이터로 많이 사용되어 왔다.

IRIS 데이터는 150개의 4차원 데이터로 구성되어 있으며 3개의 클러스터로 이루어져 있다. 또한 1개의 클러스터는 50개의 데이터로 이루어져 있다. 가우시안 분포의 데이터는 200개의 2차원 데이터로 구성되어 있고 2개의 클러스터로 이루어져 있다. 또한 1개의 클러스터는 100개의 데이터로 이루어져 있다. 첫 번째 클러스터의 평균값은 (2,5)이고 표준편차는 1이다. 두 번째 클러스터의 평균값은 (5,2)이고 표준편차는 1이다[그림 1].

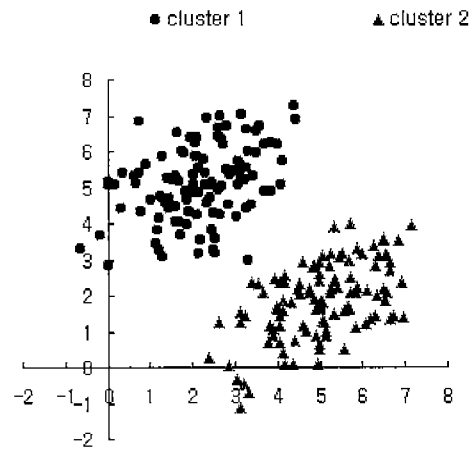


그림 1. 가우시안 분포 데이터의 모양
Fig 1. A shape of Gaussian-distributed data

성능 비교를 위하여 사용한 첫 번째 데이터는 IRIS 데이터이다. 본 논문에서 제시하는 퍼지 신경회로망은 K가 0.5일 때 vigilance parameter T가 1.2와 1.8 사이에서 3개의 클러스터들로 분류하였고 K가 1.0 일 때는 vigilance parameter T가 1.2와 1.9 사이에서 3개의 클러스터로 분류하였다[그림 2].

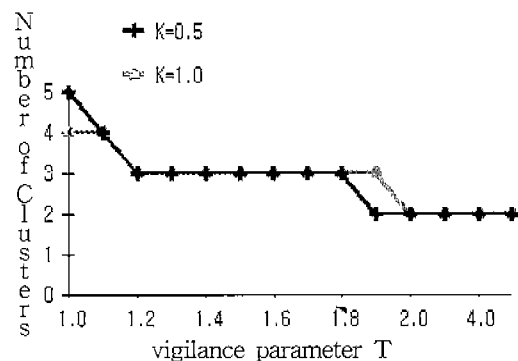


그림 2. IRIS 데이터에 대한 K와 vigilance parameter T에 따른 클러스터의 개수
Fig 2. Number of clusters versus K and the vigilance parameter T for the IRIS data

따라서 반복 횟수의 함수에 사용한 K에 따라서 성능이 좌우됨을 알 수 있었다.

본 실험에서는 $\sqrt{\|v(t+1) - v(t)\|^2}$ 이 임의로 정한 $\epsilon = 0.001$ 보다 작으면 실험적으로 수렴한 것으로 보고 반복을 중단하였다. 본 논문에서 제시하는 신경회로망은 K가 0.5이고 T가 1.3일 때 11개의 error가 발생하였고 실험적으로

수렴하기 위하여 36번의 반복을 필요로 하였다[그림 3]. 코호넨의 자기 조직화 특징 지도의 경우는 학습률을 $\frac{1}{1+(l-1)}$ (l은 반복횟수)로 놓았다. 연결강도의 초기값은 일반적으로 연결강도를 초기화하는 방법을 따라서 (0.8346, 0.1092, 0.41114, 0.1747), (0.4639, 0.9600, 0.8192, 0.4563), (0.0913, 0.4666, 0.6711, 0.0181)등과 같이 0과 1사이의 임의의 작은 수로 초기화했는데 원하는 클래스의 개수를 3으로 했음에도 불구하고 1개의 클러스터가 형성되었다. 초기화 값의 범위를 바꿔서 (3.263, 5.010, 2.520, 4.226), (2.891, 4.028, 2.765, 5.101), (4.224, 3.211, 3.253, 5.020)등과 같이 0과 7사이의 임의의 수로 초기화 해 본 결과 2개의 클러스터가 형성되었다. 따라서 초기화하는 방법을 바꿔서 IRIS 데이터 중에서 임의로 선정한 것을 연결 강도의 초기값으로 사용하였더니 3개의 클러스터가 형성되었다.

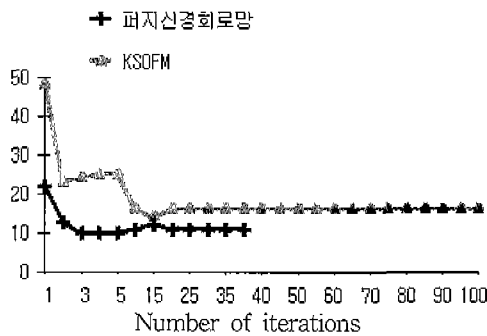


그림 3. IRIS 데이터에 대한 성능 비교
Fig 3. Performance comparison for the IRIS data

초기화 값을 (6.3, 3.6, 5.6, 2.3), (5.6, 2.5, 4.8, 1.4), (4.4, 3.9, 1.7, 0.2)로 선정하였을 때 16개의 error가 발생하였고 실험적으로 수렴하기 위하여 약 100번의 반복을 필요로 하였다 [그림 3]. 초기값에 따라서 14개에서 16개의 error가 발생하였고 실험적으로 수렴하기 위하여 약 100번의 반복을 필요로 하였다. 따라서 본 실험결과는 IRIS 데이터에 대해서 코호넨의 자기 조직화 특징 지도는 underutilization 문제가 있음을 보여준다.

성능 비교를 위하여 두 번째로 사용한 데이터는 가우시안 분포의 데이터이다. 본 논문에서 제시하는 퍼지 신경회로망은 vigilance parameter T가 3.5이고 K가 0.5일 때 9개의 error가 발생하였고 실험적으로 수렴하기 위하여 약 70번의 반복을 필요로 하였다[그림 4]. 코호넨의 자기 조직화 특징 지도의 경우는 학습률을 $\frac{1}{1+(l-1)}$ (l은 반복횟수)로 놓았다. 연결강도의 초기값을 일반적으로 연결강도를 초기화하는 방법을 따라서 (0.17, 0.53), (0.66, 0.31)등과 같이 0과 1사이의 임의의 작은 수로 초기화했는데 2개의 클러스터가 형성되었고 error의 개수는 약 10개가 발생하였고 실험적으로 수렴하는데 약 70번의 반복을 필요로 하였다. 초기화 값의 범위를 바꾸어서 (1.58, 4.92), (6.12, 2.70)등과 같이 0과 7사이의 임의의 수로 초기화했을 때도 2개의 클러스터가 형성되었고 error의 개수는 10개가 발생하였고 실험적으로 수렴하는데 약 70번의 반복을 필요로 하였다. 또한 초기화하는 방법을 바꿔서 가우시안 분포의 데이터 중에서 임의로 선정한 것을 연결강도의 초기값으로 사용하였다. (2.63, 4.22), (5.36, 2.42) 등과 같이 초기화했을 때도 마찬가지로 error의 개수는 10개

가 발생하였고 실험적으로 수렴하는데 약 70번의 반복을 필요로 하였다[그림 4]. 따라서 가우시안 분포의 데이터의 경우는 코호넨의 자기 조직화 특징 지도도 underutilization 문제가 발생하지 않음을 보여주었다.

위의 두 종류의 테스트 데이터를 사용한 결과로부터 본 논문에서 제시하는 퍼지 신경회로망은 연결강도의 초기화를 필요로 하지 않는 구조 때문에 어느 경우에도 underutilization 문제가 발생하지 않음을 알 수 있고 error의 개수와 실험적으로 수렴하기 위해 필요한 반복 횟수도 코호넨의 자기 조직화 특징 지도에 비해 적음을 알 수 있다.

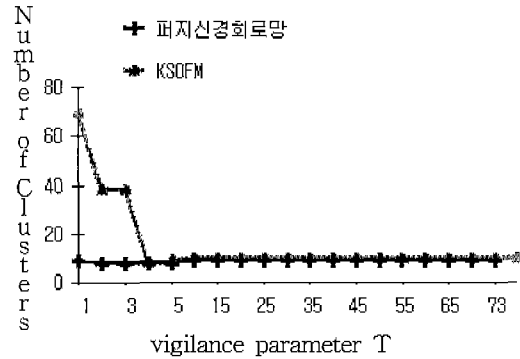


그림 4. 가우시안 분포의 데이터에 대한 성능 비교
Fig 4. Performance comparison for Gaussian-distributed data

4. 결론

본 논문에서는 underutilization 문제를 해결한 퍼지 신경회로망을 제시하였다. 이 퍼지 신경회로망은 ART-1 신경회로망과 같이 유연성과 안정성이 있으나 ART-1 신경회로망에 비하여 잠움에 민감하지 않다. 이는 학습법칙을 ART-1 신경회로망과는 달리 코호넨의 학습법칙을 변형 및 퍼지화했기 때문이다. 데이터에 따라서 코호넨의 자기 조직화 특징 지도는 underutilization 문제가 발생함을 보였고 error 수와 실험적으로 수렴에 필요한 반복 횟수면에서 본 논문에서 제시하는 퍼지 신경회로망이 코호넨의 자기 조직화 특징 지도보다 우수함을 보였다.

참고 문헌

- [1] T. Kohonen, Self-Organization and Associative Memory, 3rd ed., Springer-Verlag, Berlin, 1984.
- [2] 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.
- [3] T. L. Huntsberger and P. Ajjimarangsec, "Parallel Self-Organizing Feature Maps for Unsupervised Pattern Recognition," *Int. J. General Systems*, vol. 16, no. 4, pp. 357-372, 1990.
- [4] J. C. Bezdek, E. C. Tsao, and N. R. Pal, "Fuzzy Kohonen Clustering Networks," *Proceeding of the First IEEE Conference on Fuzzy Systems*, pp.

1035-1043, San Diego, March 1992.

- [5] G. A. Carpenter, S. Grossberg, and D. B. Rosen, "Fuzzy ART: Fast Stable Learning and Categorization of Analog Pattern by an Adaptive Resonance Systems," *Neural Networks*, vol. 4, pp. 759-772, 1992.
- [6] P. K. Simpson, "Fuzzy Min-Max Neural Network-part2: Clustering," *IEEE Trans. on Fuzzy Systems*, vol. 1, no. 1, Feb 1993.
- [7] F. L. Chung and T. Lee, "Fuzzy Competitive Learning," *Neural Networks*, vol. 7, no. 3. pp. 539-551, 1992.
- [8] B. Moore, "ART1 and Pattern Clustering," Proceedings of the 1988 Connectionist Models Summer School, pp. 174-185, San Mateo, 1988.
- [9] C. -T. Lin and C. S. G. Lee, *Neural Network Systems-A Neuro-Fuzzy Synergism to Intelligent Systems*, Prentice-Hall, Upper Saddle River, 1996.
- [10] J. C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum Press, New York, 1981.
- [11] S. K. Pal and S. Mitra, "Fuzzy Dynamic Clustering Algorithm," *Pattern Recognition Letters*, vol. 11, pp. 525-535, 1990.
- [12] H. Robbins and S. Monro, "A Stochastic Approximation," *The Annals of Mathematical Statistics*, vol. 22, no. 3, pp. 400-407, Sept. 1951.

저 자 소 개



김 용 수 (Yong-soo Kim)

1959년 1월 16일생

1981년 2월 : 연세대학교 전기공학과 졸업 (공학사)

1983년 2월 : 한국과학기술 전기 및 전자 공학과 졸업(공학석사)

1986년 7월 : 삼성전자

1993년 12월 : Texas Tech Univ. 졸업(공학박사)

현재 : 대전대학교 컴퓨터정보통신 공학부 조교수

관심분야 : 신경회로망, 퍼지 논리, 패턴인식, 영상 처리, 칩 입 탐지

E-mail : kyslj@dragon.taejon.ac.kr



백 용 선 (Yong-sun Baek)

1970년 8월 12일생

1998년 2월 : 우송대학교 컴퓨터학과 졸업(이학사)

2000년 8월 : 대전대학교대학원 컴퓨터공학과 졸업(공학석사)

1998년~현재 : 대전대학교 시간강사

관심분야 : 퍼지신경회로망, 퍼지논리, 패턴인식 및 영상처리

E-mail : ysbaek@zeus.taejon.ac.kr



함 창 현 (Chang-hyun Ham)

1971년 9월 16일생

1998년 2월 : 영동대학교 전자공학과 졸업 (공학사)

2001년 2월 : 대전대학교대학원 컴퓨터공학과 졸업(공학석사)

2001년 2월~현재 : (주) 543미디어텍 연구원

2001년 3월~현재 : 대전대학교대학원 박사과정

관심분야 : 퍼지신경회로망, 퍼지논리, 패턴인식 및 영상처리, 입체음향

E-mail : mk48@zeus.taejon.ac.kr