

효과적인 패턴분류를 위한 개선된 FCM 기반

하이브리드 네트워크

김태형*, 차의영**, 김광백*

*신라대학교 컴퓨터정보공학부

**부산대학교 컴퓨터공학과

e-mail:ssbn0815@naver.com

eycha@pusan.ac.kr

gbkim@silla.ac.kr

Enhanced FCM Based Hybrid Network for Effective Pattern Classification

Tae-Hyung Kim*, Eui-Young Cha**, Kwang-Baek Kim*

*Division of Computer and Information Engineering, Silla University

**Dept. of Computer Engineering, Pusan National University

요 약

FCM 알고리즘은 입력 벡터와 각 클러스터의 유클리드 거리를 이용하여 구해진 소속도만을 비교하여 데이터를 분류하기 때문에 클러스터링 된 공간에서의 데이터들의 분포에 따라 바람직하지 못한 클러스터링 결과를 보일 수 있다. 이러한 문제점을 개선하기 위해 대칭적 성질을 이용하는 대칭성 측도에 퍼지 이론을 적용하여 군집간의 거리에 따른 변화와 군집 중심의 위치, 그리고 군집 형태에 따라 영향을 덜 받는 개선된 FCM이 제안되었다.

본 논문에서는 효과적으로 패턴을 분류하기 위해 개선된 FCM 알고리즘을 적용한 개선된 하이브리드 네트워크를 제안한다. 제안된 하이브리드 네트워크는 개선된 FCM 알고리즘을 입력층과 중간층의 학습구조 적용하고 중간층과 출력층의 학습구조는 일반화된 델타학습법을 적용한다.

제안된 방법의 인식성능을 평가하기 위해 2차원 좌표평면 상의 데이터를 기존의 Max_Min 신경망을 이용한 FCM 기반 RBF 네트워크와 FCM 기반 RBF 네트워크, HCM 기반 네트워크와 제안된 방법 간의 학습 및 인식 성능을 비교 및 분석하였다.

키워드 : FCM, HCM, 하이브리드 네트워크, 델타학습법

1. 서론

FCM(Fuzzy C-Means) 알고리즘은 데이터 클러스터링 방법으로 클러스터링 방법 중 가장 많이 사용하는 알고리즘 중 하나이다. FCM 알고리즘의 응용분야는 패턴 인식 뿐만 아니라 자동제어 및 영상처리 분야에서 다양하게 응용되고 있다. FCM 알고리즘은 입력벡터와 클러스터간의 유클리드 거리를 이용하여 구해진 각 클러스터에 대한 소속도를 기준으로 데이터를 분류하는 알고리즘이다. 하지만 FCM 알고리

즘은 입력벡터와 클러스터와의 거리의 정도가 반영되어 구해진 소속도만을 이용하여 데이터를 분류한다[1]. 따라서 유클리드 거리에 근거한 소속도만을 비교하여 데이터를 분류하기 때문에 클러스터링 된 공간에서의 데이터들의 분포에 따라 바람직하지 못한 클러스터링 결과를 보일 수 있다. 이러한 문제점을 개선하기 위해 대칭적 성질을 이용하는 대칭성 측도에 퍼지 이론을 적용하여 클러스터간의 거리에 따른 변화와 클러스터 중심의 위치, 그리고 클러스터 형태에 따라 데이터의 특징들을 분류하는 개선된 FCM이 제안되었다. 하지만 개

선된 FCM 알고리즘은 비지도 학습 구조이기 때문에 근접한 데이터들을 클러스터링 할 수는 있으나 정확히 패턴들의 특징을 분류할 수 없는 경우가 발생한다(2).

따라서 본 논문에서는 효과적인 패턴분류를 위해 입력층과 중간층의 학습구조로는 개선된 FCM 알고리즘이 적용되고, 중간층과 출력층의 학습구조로는 일반화된 델타학습법을 적용한 개선된 FCM 기반 하이브리드 네트워크를 제안한다.

제안된 하이브리드 네트워크는 입력층과 중간층의 학습구조로 기존의 FCM 알고리즘의 단점인 유클리드 거리에 근거한 소속도만을 이용하여 클러스터링 하는 단점을 개선한 FCM 알고리즘을 적용하고, 중간층과 출력층의 학습 구조는 기존의 Max_Min 신경망 알고리즘 대신 지도학습에 일반적으로 가장 많이 사용되는 일반화된 델타 학습법을 적용한다.

본 논문에서 제안한 하이브리드 네트워크의 학습 및 인식 성능 평가를 위해 2차원 좌표평면상의 패턴 40개를 적용하여, Max_Min 신경망을 이용한 FCM 기반 RBF 네트워크(2)와 FCM 기반 RBF 네트워크(3), HCM 기반 RBF 네트워크와 학습 성능을 비교 분석한다.

2. FCM(Fuzzy C-Means) 알고리즘

FCM(Fuzzy C-Means)알고리즘은 입력벡터와 클러스터의 유클리드 거리를 이용하여 분류하는 HCM(Hard C-Means)알고리즘과 유사하다. 다만, 차이점은 데이터 개체들이 각 클러스터에 소속하는지(0 또는 1)에 대한 정보가 아니라, 각 클러스터에 소속하는 정도 (0과 1사이의 실수)를 분할 행렬로 표시한다는 점과 초기 중심을 지정할 때 임의로 설정한 초기분할 행렬을 가지며 전체 데이터 분포의 중간 정도에 초기 중심을 설정한다(4,5).

알고리즘의 구성은 우선, 초기화가 이루어지고, 이로부터 클러스터의 중심을 계산하여 얻은 중심과 각 개체사이의 유클리드 거리를 구한 뒤, 새로운 분할 행렬을 갱신한다. 이러한 반복적인 갱신과정을 거치면서, 점차 데이터의 특성에 맞는 중심점으로 수렴하게 된다.

FCM 알고리즘의 학습 단계는 다음과 같다.

- 단계 1 : 학습에 사용되는 인수를 초기화 한다.
- 단계 2 : 학습패턴을 설정한다.
- 단계 3 : 클러스터의 중심값을 식(1)과 같이 계산한다.

$$v_j = \frac{\sum_{i=1}^n (\mu_{ji})^m x_i}{\sum_{i=1}^n (\mu_{ji})^m} \dots\dots\dots (1)$$

식(1)에서 v_j 와 x_i 는 각각 클러스터의 중심과 입력 벡터이고, m 는 지수 가중치이다.

- 단계 4 : 중간층의 소속도를 식(2)와 같이 계산한다.

$$\mu_{ji} = 1 / \sum_{a=1}^c \left(\frac{|x_i - v_j|^2}{|x_i - v_a|^2} \right)^{2/m-1} \dots\dots\dots (2)$$

- 단계 5 : 오차 한계치를 식(3)과 같이 검사한다.

$$|U^{(p)} - U^{(p-1)}| \leq \epsilon \dots\dots\dots (3)$$

현재 소속도($U^{(p)}$)와 이전 소속도($U^{(p-1)}$)의 차이가 오차 한계치(ϵ) 보다 작거나 같으면 학습을 종료하고, 그렇지 않으면 단계 2로 가서 학습을 반복한다.

3. 제안된 FCM 기반 하이브리드 네트워크

본 논문에서 제안한 FCM 기반 하이브리드 네트워크는 입력층과 중간층의 연결 구조는 개선된 FCM 알고리즘을 적용한다. 중간층에서 개선된 FCM 알고리즘을 적용하여 1차적으로 특징을 분류하고 중간층의 노드에 속하는 정도를 나타내는 소속도를 계산한다. 계산된 소속도를 중간층의 입력벡터로 적용하여 중간층과 출력층 사이의 학습에 적용한다. 중간층과 출력층 사이의 학습구조는 일반화된 델타 학습법을 적용한다.

3.1 개선된 FCM 알고리즘

기존의 FCM 알고리즘은 유클리드 거리에 근거한 소속도만을 이용하여 데이터를 분류하는 문제점이 있다. 예를 들면, 클러스터 된 공간상에 분포된 패턴들이 타원의 형태를 가지는 경우이거나 패턴의 분포가 균집 경계면에 존재하고 그 기본형이 서로 교차하는 경우이다. 이러한 경우에는 클러스터의 중심으로부터 패턴간의 거리를 측정하는 유클리드 거리를 적용할 경우에는 올바르지 못한 균집화 결과의 원인이 될 수 있다(6,7). 따라서 본 논문에서는 대칭적 성질을 이용하는 대칭성 측도에 퍼지 이론을 적용하여 클러스터간의 거리에 따른 변화와 균집 중심의 위치, 그리고 균집 형태에 따라 영향을 덜 받는 개선된 FCM 알고리즘을 중간층의 클러스터링 방법에 적용하여 패턴의 특징을 분류한다. 개선된 FCM 알고리즘에서 적용하는 대칭성 측도는 식 (4)와 같다.

$$Symmetric(x_i, c) = \max_{j \in \forall pattern \neq i} \left(\begin{matrix} (1-\alpha)(1 - \frac{deg(x_i, x_j, c)}{180}) \\ -(\alpha \cdot ratio_{ij}(x_i, x_j, c)) \end{matrix} \right) \dots\dots\dots (4)$$

식 (4)에서 $deg(x_i, x_j, c)$ 는 점 c 를 중심으로 점 x_i 와 점 x_j 의 각도를 의미하며 $ratio_{ij}(x)$ 는 식 (5)와 같고, α 는 퍼지 이론을 이용한 가중치이다. 가중치 계산은 식 (6)과 같다.

$$ratio_d(x) = \begin{cases} \frac{d(x_i, c)}{d(x_j, c)} & \text{if } d_i > d_j \\ \frac{d(x_j, c)}{d(x_i, c)} & \text{if } d_i < d_j \end{cases} \dots\dots\dots (5)$$

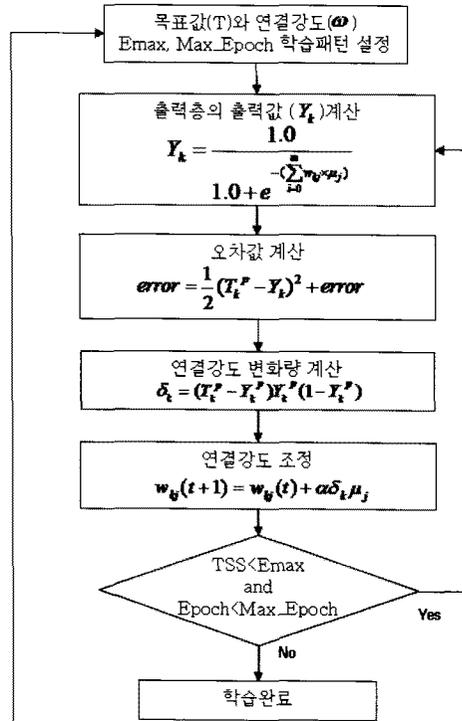
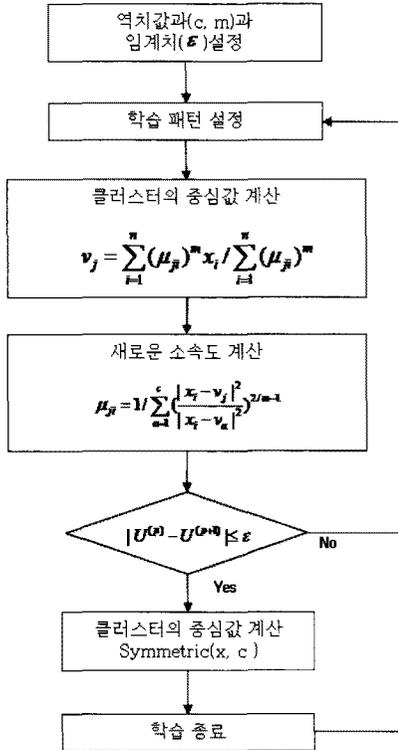
여기서 $d(x, c)$ 는 유클리드 거리를 의미한다.

$$\alpha = \frac{d(c_i, c_l)}{\sqrt{D_m}} \dots\dots\dots (6)$$

식 (4)을 이용하여 대칭성 측도를 구한 상수 값을 $\mu(x)$ 라고 정의한 후, 군집의 중심 값을 계산한다. 군집의 중심 값 계산은 식 (7)과 같다.

$$v^{(p)} = \mu(x)x_i / \mu(x) \dots\dots\dots (7)$$

개선된 FCM 알고리즘으로 군집화 된 각 군집들의 중심 값과 현재 패턴 사이의 유사도 U 를 식 (8)에 적용하여 계산한다.



〈그림 1〉 제안한 개선된 FCM 기반 하이브리드 네트워크

$$U = \sqrt{\sum_{i=0}^{k-1} (x_i - c_i)^2} \dots\dots\dots (8)$$

$$error = \frac{1}{2} (T_k^p - Y_k)^2 + error \dots\dots\dots (10)$$

3.2 일반화된 델타 학습법

지도 학습에서 일반적으로 가장 많이 사용되는 일반화된 델타 학습법은 출력층의 오차 신호를 이용하여 연결강도를 변경하는 학습 방법이다. 일반화된 델타 학습법의 출력값 계산식은 식 (9)와 같다.

$$Y_k = \frac{1.0}{1.0 + e^{-\sum_{i=0}^m w_{kj} \times \mu_j}} \dots\dots\dots (9)$$

식 (9)에서 e 는 시그모이드 함수를 나타낸다.

식 (9)를 통해 출력값이 계산되면 오차 값을 계산하게 된다. 오차값을 계산하는 식은 식 (10)과 같다.

식 (10)에서 T_k^p 는 목표값이다.

식 (11)은 중간층과 출력층 사이의 연결강도 변화량을 계산하는 식이다.

$$\delta_k = (T_k^p - Y_k^p) Y_k^p (1 - Y_k^p) \dots\dots\dots (11)$$

식 (11)를 적용하여 중간층과 출력층 사이의 연결 강도를 조정하는 식은 다음과 같다.

$$w_{kj}(k+1) = w_{kj}(k) + \alpha \delta_k \mu_j \dots\dots\dots (12)$$

본 논문에서 제안한 개선된 FCM 기반 하이브리드 네트워크의 학습 알고리즘은 그림 1과 같다.

4. 실험 및 결과 분석

본 논문에서 제안된 방법의 학습 및 인식 성능을 평가하기 위하여 Intel PentiumIV 2.8GHz CPU와 2GB RAM 이 장착된 IBM 호환 PC상에서 Visual Studio 6.0으로 구현하였다. 제안된 방법과 기존의 Max_Min 신경망을 이용한 FCM기반 RBF 네트워크[2]와 FCM 기반 RBF 네트워크[3], HCM 기반 네트워크 간의 학습 및 인식 성능을 비교하기 위해 2차원 좌표평면상의 데이터를 대상으로 실험하였다. 표 1은 제안된 방법에 사용된 학습 파라미터이다.

〈표 1〉 제안된 방법에 사용된 학습 파라미터

	c	m	ϵ	Max_Epoch
제안된 방법	10	2	0.01	500000

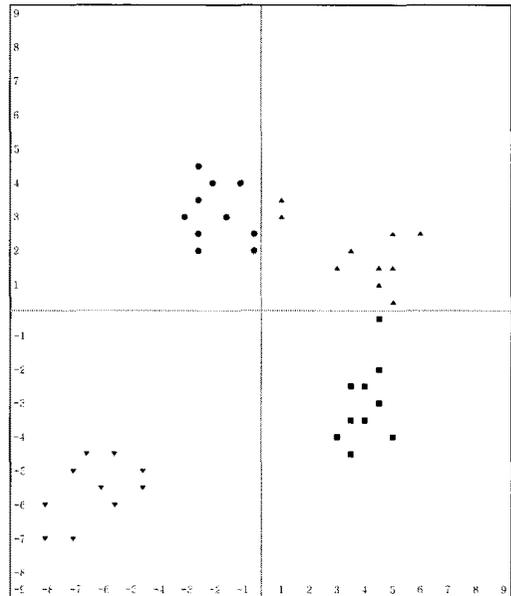
표 1에서 c 는 클러스터를 나타내고 m 은 지수가중치, ϵ 은 오류한계치, Max_Epoch는 최대반복횟수이다.

표 2는 제안된 방법의 학습 성능 평가에 사용된 2차원 좌표평면상의 데이터를 나타낸 것이다. 표 2에서 배경색이 회색을 띠는 패턴은 제안된 방법의 성능을 테스트를 위해 사용한 잡음이 있는 패턴이다.

〈표 2〉 제안된 방법에 적용된 학습 패턴

X좌표	Y좌표	목표값	X좌표	Y좌표	목표값
3.0	1.0	1	-4.5	-5.0	3
1.0	3.5		-4.5	-5.5	
3.5	2.0		-5.5	-6.0	
0.5	3.0		-5.5	-4.5	
4.5	1.5		-6.0	-5.5	
4.5	1.0		-6.5	-4.5	
5.0	1.5		-7.0	-5.0	
5.0	2.5		-7.0	-7.0	
5.0	0.5		-8.0	-6.0	
6.0	2.5		-8.0	-7.0	
-0.5	2.0	2	2.5	-4.0	4
-0.5	2.5		3.0	-2.5	
-1.0	4.0		3.0	-3.5	
-1.5	3.0		3.0	-4.5	
-2.0	4.0		3.5	-2.5	
-2.5	2.0		3.5	-3.5	
-2.5	2.5		4.0	-2.0	
-2.5	3.5		4.0	-3.0	
-2.5	4.5		4.0	-0.5	
-3.0	4.0		4.5	-4.0	

그림 2는 제안된 방법의 학습 성능을 테스트하기 위해 적용된 패턴을 2차원의 좌표평면상에 나타낸 그림이다. 1에서 4까지 사분면에 패턴이 분포되어 있는데 패턴의 목표값은 패턴이 위치하고 있는 각 분면이다.



〈그림 2〉 학습에 적용된 2차원 좌표평면상의 패턴 분포

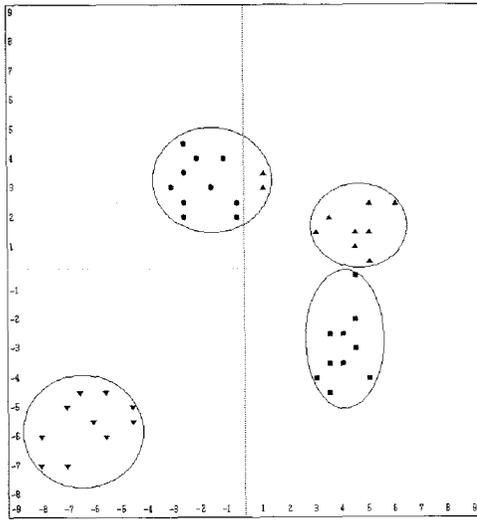
표 3은 잡음이 있는 패턴들에 대해 제안된 하이브리드 네트워크의 중간층에 적용된 개선된 FCM 알고리즘과 기존의 RBF 네트워크의 중간층에 각각 적용되는 FCM과 HCM의 분류 결과를 나타내었다.

〈표 3〉 개선된 FCM과 FCM, HCM의 중간층에서의 잡음이 있는 패턴의 분류결과

	입력벡터		
	1사분면		4사분면
	(1.0,3.5)	(0.5,3.0)	(4.0,-0.5)
개선된FCM	2	2	4
FCM	2	2	1
HCM	2	2	1

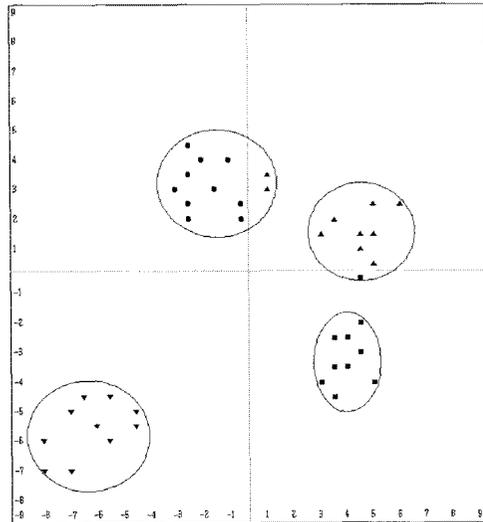
표 3에서 확인할 수 있듯이 1로 분류되어야 하는 두 개의 패턴((1.0, 3.5),(0.5, 3.0))은 3가지 모델 모두 2로 분류했고, 4로 분류되어야 하는 하나의 패턴((4.0, -0.5))는 개선된 FCM 알고리즘만 제대로 분류한 것을 확인할 수 있다.

그림 3은 제안된 하이브리드 네트워크에서 입력층과 중간층의 학습 구조인 개선된 FCM 알고리즘의 데이터 분류 결과이다.



〈그림 3〉 개선된 FCM 알고리즘의 패턴 분류 결과

그림 4는 기존의 FCM과 HCM 알고리즘의 패턴 분류를 나타낸 결과이다.



〈그림 4〉 FCM과 HCM 알고리즘의 패턴 분류 결과

그림 3과 4를 비교 분석하면 개선된 FCM 알고리즘이 기존의 FCM 알고리즘이나 HCM 알고리즘보다 효과적으로 클러스터링 하는 것을 확인할 수 있다.

표 4는 개선된 FCM과 FCM, HCM의 패턴 분류 후 클러스터의 중심값을 나타내었다.

〈표 4〉 개선된 FCM과 FCM, HCM의 클러스터 중심값표

신경망 모델	클러스터	X좌표	Y좌표
개선된 FCM	1	3.947	2.850
	2	-1.372	3.262
	3	-6.288	-5.643
	4	3.551	-3.444
FCM	1	3.947	1.287
	2	-1.427	2.948
	3	-5.996	-5.347
	4	3.129	-2.830
HCM	1	4.500	1.333
	2	-1.416	3.208
	3	-6.250	-5.600
	4	3.444	-3.277

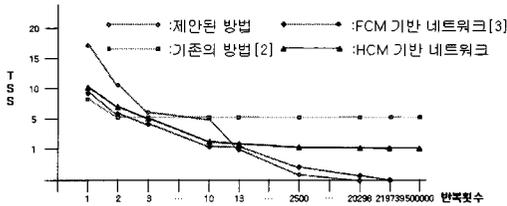
표 5는 제안된 하이브리드 네트워크와 기존의 Max_Min 신경망을 이용한 FCM 기반 RBF 네트워크[2], FCM 기반 RBF 네트워크[3], HCM 기반 네트워크의 학습 성능 및 인식 결과를 나타낸 결과이다.

〈표 5〉 제안된 방법과 기존의 FCM 기반 RBF 네트워크의 결과 비교

	제안된 방법	기존의 FCM 기반 RBF	FCM 기반 RBF	HCM 기반 RBF
클러스터	10	10	10	10
Epoch	20298	500000	219739	500000
인식률	40/40	29/40	40/40	37/40
TSS	0.01	5.361697	0.01	1.735934

표 5에서 Epoch는 반복횟수를 의미하고 TSS는 총 오차 자승합이다. 표 5에서 알 수 있듯이 제안된 방법이 기존의 방법들 보다 학습 속도 및 인식 성능이 개선된 것을 확인할 수 있다.

그 이유는 제안된 하이브리드 네트워크는 입력층과 중간층의 학습구조로 개선된 FCM 알고리즘을 적용함으로써 기존의 FCM의 단점인 유클리드 거리에 근거한 소속도만을 적용하여 클러스터링 하는 단점을 개선하여 입력 벡터들의 특징이 중복되는 부분을 최소화하여 분류의 정확성을 높여 중간층의 입력벡터로 적용하였고, 기존의 방법[2]에서 사용하였던 Max_Min 신경망 알고리즘은 서로 다른 패턴들의 특징이 중복되는 부분이 많은 경우에는 패턴들의 분류성이 낮아졌으나 본 논문에서는 Max_Min 신경망 알고리즘 대신 지도학습에서 가장 일반적으로 사용되는 일반화된 델타 학습법을 적용함으로써 중간층과 출력층에서 패턴의 분류 성능이 개선되어 인식 성능이 향상되었다. 그림 5는 제안된 방법과 기존의 방법[2], FCM 기반 RBF 네트워크[3], HCM 기반 네트워크의 오차 자승합의 변화 과정을 나타내었다.



〈그림 4〉 FCM과 HCM 알고리즘의 패턴 분류 결과

그림 4에서 알 수 있듯이 제안된 방법은 조기 포화 현상이 일어나지 않아 비교적 적은 반복 횟수로 학습이 완료된 것을 확인할 수 있다. 하지만 다른 네트워크 모델들은 조기 포화 현상으로 반복횟수가 제안된 방법보다 월등히 높은 상태에서 학습이 완료되거나 총 오차 자승 합이 최대반복횟수를 넘어설 때까지 학습이 완료되지 않음을 확인할 수 있다.

5. 결론

본 논문에서는 효과적으로 패턴을 분류하기 위해 기존의 FCM 기반 RBF 네트워크에서 입력층과 중간층의 학습구조인 FCM 알고리즘 대신에 개선된 FCM 알고리즘을 적용하였고, 기존의 연구에서 중간층과 출력층의 학습구조로 적용되었던 Max_Min 알고리즘 대신에 일반화된 델타 학습법을 적용하여 개선된 FCM 기반 하이브리드 네트워크를 제안하였다. 입력층과 중간층의 학습구조로 입력벡터와 클러스터의 유클리드 거리에 근거한 소속도만을 적용하여 클러스터링 하는 단점을 대칭적 성질을 이용하는 대칭성 측도에 퍼지 이론을 적용하여 클러스터간의 거리에 따른 변화와 군집 중심의 위치, 그리고 군집 형태에 따라 영향을 덜 받는 개선된 FCM 알고리즘을 적용하였고, 중간층과 출력층의 학습 구조로는 비교적 단순한 패턴 분류에 적용되었던 Max_Min 신경망 알고리즘 대신에 지도학습에서 일반적으로 사용되는 일반화된 델타 학습법을 적용함으로써 중간층과 출력층의 패턴 분류의 정확성을 개선하였다.

제안된 학습 방법의 학습 및 인식 성능을 평가하기 위해 2차원 좌표평면상에서 잡음이 포함된 패턴 40개를 적용한 결과, Max_Min 신경망 알고리즘을 이용한 기존의 FCM 기반 RBF 네트워크[2]와 FCM 기반 RBF 네트워크[3], HCM 기반 RBF 네트워크보다 학습 성능 및 인식 성능이 개선되어 다양한 패턴 인식에 적용할 수 있는 것을 확인하였다.

참고문헌

- [1] M. L. Kothari, S. Madhani and R. Segal, "Orthogonal Least Square Learning Algorithm Based Radial Basis Function Network Adaptive Power System Stabilizer," Proceeding of IEEE SMC, Vol.1 pp.542-547, 1997.
- [2] 김광백, "퍼지 RBF 네트워크의 학습 성능 개선," 멀티미디어학회논문지, 9권 3호, pp.369-376, 2006.
- [3] K. B. Kim, J. H. Cho, C. K. Kim, "Recognition of Passports Using FCM-Based RBF Network," Lecture Notes in Artificial Intelligence, LNAI 3809, Springer, pp.1241-1245, 2005.
- [4] R. Babuska, Fuzzy Modeling for Control, Kluwer Academic Publishers, 1998.
- [5] Arun D. K., Computer Vision and Fuzzy Neural Systems, Prentice Hall PTR, 2001.
- [6] J. Bezdek, "A convergence theorem for the fuzzy ISODATA clustering algorithm," IEEE Trans. Pattern Anal. Machine Intell., Vol.PAMI2, No.1, pp.1-8, 1998.
- [7] K. B. Kim, D. U. Lee, K. B. Sim, "Performance Improvement of Fuzzy RBF Networks", Lecture Notes in Computer Science, LNCS 3610, Springer, pp.237-244, 2005.