

FCM을 이용한 퍼지 RBF 네트워크

김재용* · 이상수* · 이준행** · 김광백*

*신라대학교 컴퓨터공학과

**신라대학교 컴퓨터정보공학부

Fuzzy RBF Network using FCM

Jae-Yong Kim* · Sang-Soo Lee* · Jun-Haeng Lee** · Kwang-Baek Kim*

*Dept. of Computer Engineering, Silla University

**Division of Computer and Information Engineering, Silla University

요 약

RBF 네트워크의 중간층은 클러스터링하는 층이다. 즉, 이 층의 목적은 주어진 자료 집합을 유사한 클러스터들(homogenous cluster)로 분류하는 것이다. 여기서 유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간사이에서 한 클러스터내의 벡터들 간에 거리를 측정하여 정해진 반경내에 존재하면 같은 클러스터로 분류하고 정해진 반경내에 존재하지 않으면 다른 클러스터로 분류한다. 그러나 정해진 반경 내에서 클러스터링하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다. 그러므로 중간층을 결정하는 것은 RBF 네트워크의 전반적인 효율성에 큰 영향을 준다. 따라서 본 논문에서는 효율적으로 중간층을 결정하기 위한 방법으로 퍼지 C-Means 클러스터링 알고리즘을 적용한 퍼지 RBF 네트워크를 제안한다. 제안된 퍼지 RBF 네트워크의 학습은 크게 두 단계로 구분된다. 첫 번째 단계는 입력층과 중간층 사이에 퍼지 C-Means 알고리즘이 수행되고, 두 번째 단계는 중간층과 출력층 사이에 지도학습이 수행된다.

제안된 방법의 학습 성능을 평가하기 위하여 실제 주민등록증에서 추출한 숫자패턴에 적용한 결과, 기존의 RBF네트워크 보다 학습 성능이 개선된 것을 확인하였다.

키워드

RBF네트워크, 퍼지 C-Means 클러스터링, 중간층, 지도 학습

1. 서 론

현재에 신경망 모델의 연결 상태에 관한 관심이 높은 상태다. 그 이유는 신경망 모델의 학습 능력 때문인데, 특히 신경망의 학습 속도 및 일반화 능력을 향상시키기 위해 많은 노력들이 이루어지고 있다[1].

RBF 네트워크는 입력(input), 중간(midden), 출력(output) 3개의 층으로 이루어진 전방향 신경망이다. 층간에 각기 다른 일을 수행하므로 각 층간에 서로 다른 알고리즘을 적용할 수 있으며 층간의 최적화를 분리하여 구성할 수 있다. 층간의 구성은 크게 3가지로 나눌 수 있는데 첫째는 중간층의 노드가 학습 데이터로부터 임의적으로 선택되는 방식이다. 둘째는 중간층이 자기조직화 형식에 따라 결정되고, 출력층에서는 지도학습을 적용하는 방

식이다. 마지막으로 중간층과 출력층 모두 지도 학습으로 학습을 시키는 방법이다[2].

RBF 네트워크의 중간층은 클러스터링하는 층이다. 즉, 이 층의 목적은 주어진 자료 집합을 유사한 클러스터들(homogenous cluster)로 분류하는 것이다. 여기서 유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간사이에서 한 클러스터내의 벡터들 간에 거리를 측정하여 정해진 반경내에 존재하면 같은 클러스터로 분류하고 정해진 반경내에 존재하지 않으면 다른 클러스터로 분류한다. 그러나 정해진 반경 내에서 클러스터링하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다[3]. 그러므로 중간층을 결정하는 것은 RBF 네트워크의 전반적인 효율성에 큰 영향을 준다.

따라서 본 논문에서는 퍼지 C-Means 알고리즘을 RBF 네트워크의 중간층으로 적용하는 퍼지

RBF 네트워크를 제안하여 주민등록증에서 추출한 숫자 패턴에 대해 기존의 RBF 네트워크와 학습 및 인식 성능을 비교 분석한다.

II. RBF 네트워크

RBF 네트워크는 빠른 학습 속도, 일반화, 단순화의 특징으로 데이터 분류, 비선형 시스템 모델링 등에 적용되고 있다. 신경망의 관점에서 RBF네트워크는 3개의 층으로 구성된 전방향 신경망 형태를 갖추고 있다. 이런 구조적 형태의 특징으로 각 계층이 개별적인 순서를 결정하기 때문에 학습 속도가 다층 퍼셉트론 보다 빠른 특징을 가지고 있다. 전형적인 RBF 네트워크의 구조는 그림1과 같다.




그림1. RBF 네트워크 모형

여기서 입력층과 중간층간에는 클러스터링하는 역할을 수행하게 된다. 중간층에 있는 노드는 그 자신의 중심을 가지고, 입력 $X = \{x_1, x_2, x_3, \dots, x_n\}$ 에 대하여 자신과의 중심간의 거리벡터를 구한다. 이 노드의 출력은 거리 벡터에 대한 일정한 형태의 비선형함수로 얻어진다. 입력이 노드의 중심에 가까울수록 그 출력값은 커지게 된다. 중간층을 구하는 것은 식(1)과 같다.

$$\rho_k = \exp\left(\frac{-\|X - C_k\|^2}{\sigma_k^2}\right) \quad (1)$$

여기서 c 는 각 클러스터의 중심값이고 σ 는 중심에 대한 넓이값이 된다. 중간층과 출력층간에는 일반적인 학습 과정을 수행한다. RBF 네트워크의 출력노드는 각 중간층 노드의 출력값에 학습과정 중 가변인 연결가중치를 곱한 후 이들을 더한 값을 그 출력값으로 갖는다. 그리고 식(2)와 같이 지도학습과 동일한 형태로서 목표값과 출력값 간의 오차 값을 최소화하는 방향으로 학습한다.

$$y_i = \sum_{k=1}^M \rho_k w_{kj} \quad (2)$$

1. RBF 네트워크의 문제점

RBF 네트워크는 학습이 완료된 상태 즉, 연결강도가 특정값으로 고정된 상태에서 새로운 패턴을 학습시키게 되면 이미 설정된 모든 연결 강도에 영향을 주므로 RBF 네트워크를 다시 학습시키는데 상당한 시간이 소요되는 단점과 RBF 네트워크에 학습되지 않은 전혀 새로운 형태의 패턴이 들어오는 경우 이전에 학습된 유사한 패턴으로 분류해버리는 단점이 있다[4].

III. Fuzzy C-Means 알고리즘을 이용한 퍼지 RBF 네트워크

제안된 퍼지 RBF 네트워크에서 중간층의 클러스터링 방법은 기존의 이분법과는 달리 퍼지 분류인 1개의 데이터가 2가지 이상의 클러스터에 속하는 것을 허용한다. 퍼지 논리의 특징을 이용하여 이분법에 의한 ART1 알고리즘을 적용한 방법보다 효율적이고 정확성이 높은 중간층을 구성하기 위하여 본 논문에서는 퍼지 C-Means 알고리즘을 적용한 퍼지 RBF 네트워크를 제안한다.

제안된 RBF 네트워크의 중간층에 FCM 알고리즘을 적용하였는데, FCM 알고리즘은 각각의 데이터와 각각의 클러스터 중심과의 거리에 대한 유사도 측정값을 기반으로 목적함수 식(3)을 최적화시키기 위한 알고리즘이다[5]. 본 논문에서 적용한 FCM알고리즘은 식(4), 식(5)와 같다.

$$J_m(U, v) = \sum_{k=1}^n \sum_{i=1}^c (u_{ki})^m |x_k - v_i|^2 \quad (3)$$

$$u_{ki} = 1 / \sum_{j=1}^c \left(\frac{|x_k - v_i|^2}{|x_k - v_j|^2} \right)^{1/m-1} \quad (4)$$

$$v_i = \frac{\sum_{k=1}^n (u_{ki})^m x_k}{\sum_{k=1}^n (u_{ki})^m} \quad (5)$$

여기서 $X = \{x_1, x_2, x_3, \dots, x_n\}$ 는 입력 데이터이며 u_{ik} 는 x_k 가 클러스터 i 에 속한 정도를 나타낸다. 그리고 v_i 는 i 번째 클러스터의 중심이다. FCM 알고리즘은 다음과 같다.

- step 1. c, m, ϵ (역치값)를 설정
- step 2. $U^{(0)}$ 값을 초기화
- step 3. 클러스터의 중심값 $v_i^{(p)}$ 를 식(5)에 따라 설정
- step 4. $U^{(p+1)}$ 를 식(4)에 따라 설정.
- step 5. $|U^{(p)} - U^{(p+1)}| \leq \epsilon$ 이 될 때까지 step 3부터 반복한다.

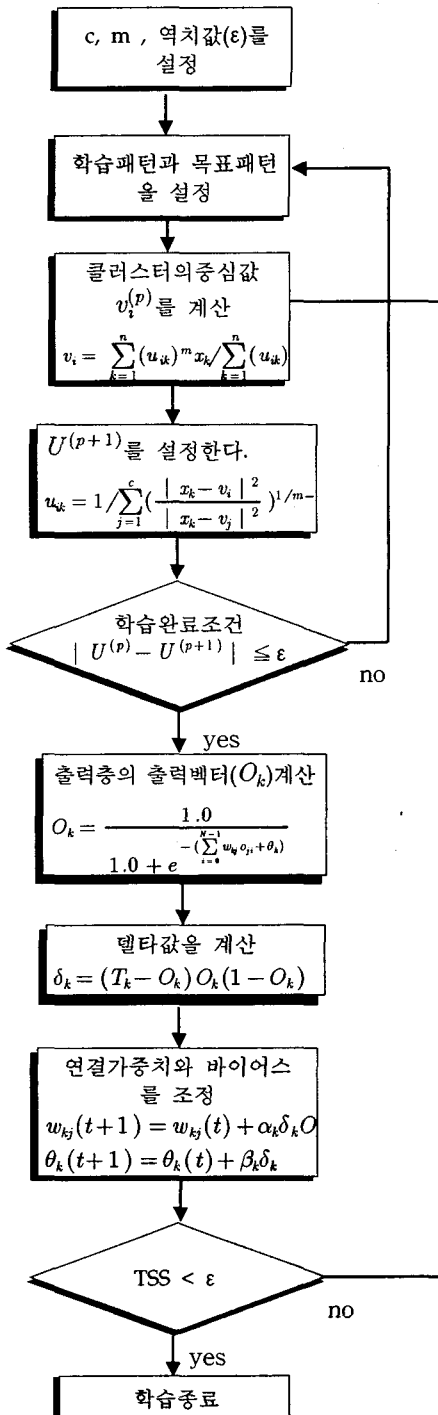


그림2. FCM 기반 퍼지 RBF 네트워크

FCM을 통하여 클러스터링 된 중간층의 클러스터들은 출력층의 입력 벡터로 사용하게 된다. 중간

층과 출력층의 출력 벡터는 식(6)과 같이 계산한다.

$$O_k = \frac{1.0}{1.0 + e^{-\sum_{i=1}^n w_{ki} o_i + \theta_k}} \quad (6)$$

출력 벡터와 목표 벡터를 비교하여 식(7)을 사용하여 오차신호를 구하고, 식(8), 식(9)을 적용하여 연결강도와 바이어스를 조정한다.

$$\delta_k = (T_k - O_k) O_k (1 - O_k) \quad (7)$$

$$w_{kj}(t+1) = w_{kj}(t) + \alpha \delta_k z_j \quad (8)$$

$$\theta_k(t+1) = \theta_k(t) + \beta \delta_k \quad (9)$$

여기서 T값은 목표 벡터이고 w와 θ은 연결강도와 바이어스이다. 제안된 FCM 기반 퍼지 RBF 네트워크의 알고리즘은 그림2와 같다.

IV. 실험 환경 및 실험 결과

본 논문에서 실험 환경은 Intel Pentium-IV 2GHz CPU와 512MB RAM이 장착된 IBM호환 PC 상에서 비주얼 C++ 6.0으로 구현하였다.

실험에 사용된 학습 패턴은 주민등록증에서 추출한 숫자 패턴을 적용하였으며, 숫자 패턴의 크기는 15×10으로 구성하였으며, 주민등록증에서 추출한 50개의 학습 패턴을 참고 문헌[6]에서 제안한 ART1 기반 RBF 네트워크와 제안된 FCM 기반 퍼지 RBF 네트워크에 적용하여 학습 및 인식 성능을 비교 분석하였다. 학습에 적용된 학습 패턴은 그림 3과 같다.




그림3. 학습에 적용한 숫자 패턴

50개의 학습 패턴에 대한 ART1 기반 RBF 네트워크와 제안된 FCM 기반 퍼지 RBF 네트워크간의 학습 및 인식 결과는 표 1과 같다. 표 1에서 기존의 ART1 기반 RBF 네트워크에서는 경계변수를 0.9로 설정하였고 제안된 FCM 기반 퍼지 RBF에서는 m과 역치값(ε)을 각각 2와 0.09로 설정하였다. 표1의 결과에서 알 수 있듯이 ART1 기반 RBF 네트워크보다 제안된 FCM 기반 RBF 네트워크의 학습 성능이 개선된 것을 확인할 수 있다.

표1. ART1 기반 RBF 네트워크와 FCM기반 RBF 네트워크간의 학습 및 인식 결과

	ART1 기반 RBF 네트워크	FCM 기반 퍼지 RBF 네트워크
반복 회수	243	184
생성된 중간층 노드 수	14	10
인식 수	42/50	50/50

그리고 제안된 FCM 기반 퍼지 RBF 네트워크가 기존의 ART1 기반 RBF 네트워크 보다 중간층의 노드 수가 적게 생성되었다. 이것은 같은 패턴들이 서로 다른 클러스터로 분류되는 부분이 개선된 것을 의미한다. 그리고 제안된 FCM 기반 퍼지 RBF 네트워크가 기존의 ART1 기반 RBF 네트워크보다 패턴 인식이 있어서도 효율적인 것을 확인할 수 있다. 기존의 ART1 기반 RBF 네트워크에서는 유사성 검증 단계에서 서로 다른 패턴들이 같은 클러스터로 분류하여 학습된 이전의 패턴의 정보가 손실되어 제안된 FCM 기반 퍼지 RBF 네트워크보다 인식 성능이 저하되었다. 그림4는 제안된 FCM 기반 RBF 네트워크와 ART1 기반 RBF 네트워크 간의 학습 반복 횟수에 따른 TSS 변화 과정을 나타내었다. 그림4에서와 같이 ART1 기반의 RBF 네트워크보다 FCM기반의 RBF 네트워크가 안정성 있게 학습되는 것을 확인할 수 있다.




그림4. 반복횟수에 따른 TSS의 변화율

V. 결 론

RBF 네트워크 모델에서의 은닉층은 클러스터링하는 층이다. 즉, 이 층의 목적은 주어진 자료 집합을 유사한 클러스터들로 분류하는 것이다. 여기서

유사하다는 것은 입력 데이터들에 대한 특징 벡터 공간사이에서 한 클러스터내의 벡터들간에 거리를 측정하여 정해진 반경 내에 존재하면 같은 클러스터로 분류하고 존재하지 않으면 다른 클러스터에 분류한다. 그러나 정해진 반경 내에서 클러스터링하는 것은 잘못된 클러스터를 선택하는 단점을 가지게 된다. 그러므로 중간층을 결정하는 것은 RBF 네트워크의 전반적인 효율성에 큰 영향을 준다.

본 논문에서는 퍼지 C-Means 클러스터링 알고리즘을 적용한 퍼지 RBF 네트워크를 제안하였다. 제안된 퍼지 RBF 네트워크의 학습은 크게 두 단계로 구분된다. 첫 번째 단계는 입력층과 중간층 사이에 퍼지 C-Means 알고리즘을 적용하였고, 두 번째 단계는 중간층과 출력층 사이에 지도학습을 적용하였다. 제안된 FCM 기반 RBF 네트워크의 학습 성능을 분석하기 위해 주민등록증 영상에서 주민등록 번호를 추출하여 학습에 적용한 결과, 기존의 ART1 기반 RBF 네트워크보다 학습 및 인식 성능이 개선되었다. 향후 연구과제는 제안된 FCM 기반 퍼지 RBF 네트워크를 다양한 패턴 인식에 적용하여 학습 성능을 분석할 것이다.

참고문헌

- [1] A. S. Pandya, R. B. Macy, Pattern Recognition with Recognition with Neural Networks in C++, IEEE PRESS, 1995.
- [2] 황영섭, 방승양, "RBF 신경망 분류기의 효율적 구성 방법," 한국정보과학회 논문지, 제21권, 5호, pp.451-460, 1997.
- [3] M. Waranbe, K. Kuwata and R. Katayma, "Adaptive Tree-Structured Self Generating Radial Basis Function and its Application to Nonlinear Identification Problem," Proceedings of IIZUKA, pp.167-170, 1994.
- [4] M. L. Kothari, S. Madnani and R. Segal, "Orthogonal Least Square Learning Algorithm Based Radial Basis Function Network Adaptive Power System Stabilizer," Proceedings of IEEE SMC, Vol. 1, pp.542-547, 1997.
- [5] R. L. Cannon, J. V. Dave, and J. C. Bezdek, "Efficient Implementation of Fuzzy C-Means Clustering Algorithm," IEEE Trans. Pattern Anal. & Machine Int., Vol. PAMI-8, No.2, pp.248-255, 1986.
- [6] 김태경, 김광백, "개선된 ART 알고리즘을 기반으로 한 학생증 인식과 웹 환경에서의 학사관리 시스템," 한국산학연 논문집, 제3권, 2호, pp.129-138, 2003.