

퍼지 동적 학습률 제어 기반 하이브리드 RBF 네트워크

김 광 백*, 박 충 식**

A Hybrid RBF Network based on Fuzzy Dynamic Learning Rate Control

Kwang-Baek Kim*, Choong-Shik Park**

요 약

FCM 기반 하이브리드 RBF 네트워크는 서로 다른 학습 구조가 결합된 혼합형 모델로서, 입력층과 중간층의 학습 구조는 FCM 알고리즘을 적용하고, 중간층과 출력층 사이의 학습 구조는 Max_Min 알고리즘을 적용한다. 입력층과 중간층의 학습시 입력 벡터와 중간층의 노드 중에서 중심과 입력 벡터간의 가장 가까운 노드를 승자 노드로 선택하여 출력층으로 전달한다. 그리고 중간층과 출력층 사이의 학습구조인 Max_Min 신경망은 중간층의 승자 뉴런이 입력벡터로 적용된다. 그러나 많은 패턴이 입력벡터로 제시될 경우에는 학습 성능이 저하되는 단점이 있다. 따라서 본 논문에서는 중간층과 출력층의 학습 구조인 Max_Min 알고리즘의 학습 성능을 향상시키기 위해 퍼지 논리 시스템을 이용한 학습률 자동 조정 방법을 제안한다. 제안된 방법은 목표값과 출력값의 차이에 대한 절대값이 0.1 보다 적거나 같으면 정확성으로 분류하고 크면 부정확성으로 분류한다. 정확성의 총 개수를 퍼지 제어 시스템에 적용하여 학습률을 동적으로 조정한다.

제안된 방법의 학습 및 인식 성능을 평가하기 위해 컨테이너에서 추출한 숫자, 영문 식별자를 인식 및 성능평가 실험에 적용한 결과, 제안된 방법이 문자 패턴 인식에 효과적임을 확인할 수 있었다.

▶ Keywords : FCM 기반 하이브리드 네트워크, Max_Min 신경망, 퍼지 논리, 학습률

Abstract

The FCM based hybrid RBF network is a heterogeneous learning network model that applies FCM algorithm between input and middle layer and applies Max_Min algorithm between middle layer and output. The Max-Min neural network uses winner nodes of the middle layer as input but shows inefficient learning in performance when the input vector consists of too many patterns. To

•제1저자 : 김광백 •교신저자 : 박충식

•투고일 : 2014. 8. 5, 심사일 : 2014. 8. 14, 게재확정일 : 2014. 8. 19.

* 신라대학교 컴퓨터공학과(Dept. of Computer Engineering, Silla University)

** 영동대학교 스마트IT학과(Dept. of Smart IT, Youngdong University)

overcome this problem, we propose a dynamic learning rate control based on fuzzy logic. The proposed method first classifies accurate/inaccurate class with respect to the difference between target value and output value with threshold and then fuzzy membership function and fuzzy decision logic is designed to control the learning rate dynamically. We apply this proposed RBF network to the character recognition problem and the efficacy of the proposed method is verified in the experiment.

▶ Keywords : FCM based hybrid network, Max-Min neural network, Fuzzy logic, Learning rate

I. 서 론

FCM 기반 하이브리드 RBF 네트워크는 서로 다른 신경망 구조가 결합된 혼합형 모델로서, 입력층과 중간층의 학습 구조는 FCM 알고리즘[1,2]을 사용하고, 중간층과 출력층 사이의 학습 구조는 Max_Min 알고리즘[3]을 사용한다.

입력층과 중간층의 학습시 입력벡터와 중간층의 노드 중에서 중심과 입력 벡터가 가장 가까운 노드를 승자 노드로 선택하여 출력층으로 전달한다. 그리고 중간층과 출력층 사이의 학습구조인 Max_Min 신경망은 중간층의 승자 뉴런을 입력 벡터로 적용한다. Max_Min 신경망은 퍼지의 기본 연산자를 사용하고, 0과 1사이의 값을 입력 패턴으로 적용하여 학습하는 알고리즘이다[4]. 이 알고리즘은 실제에 적용되어 패턴의 수가 많아지는 경우 수렴성이 떨어지는 단점을 가지고 있으며 n bit parity 문제에 대해서는 학습이 되지 않는 경우가 발생한다.

기존의 Max-Min 신경망은 연결 가중치들이 지역 최소화(local minima)에 위치하게 되는 원인을 분석해 보면 오류 한계 설정 문제, 초기 연결 가중치 설정 문제, 학습률 설정 문제, 모멘텀 설정 문제 등이 있다[5]. Cheung 등은 학습 단계를 다음과 같이 구분하였다. 학습 초기에 오류(error)가 급격히 줄어드는 오류 수렴 단계, 특정 학습 패턴에 대한 연결 가중치의 변화가 다른 패턴에 의한 연결 가중치의 변화와 상치되기 때문에 오류의 변화가 거의 없는 경쟁 단계, 학습 안된 패턴이 갑자기 학습되면서 오류가 급격히 줄어드는 우세 단계로 구분하였다[6,7]. 이 3단계 중 경쟁 단계에 의해 학습 시간이 많이 걸리며 조기 포화 현상(early saturation)이 발생한다. 조기 포화 현상이란 신경회로망이 학습 도중 일

정한 기간 동안 오류가 일정하게 유지되면서 학습이 진전되지 않는 것을 의미한다. 한편 포화 영역에 있는 출력 노드의 실제 출력값과 그 노드의 목표값이 상치되면 이 출력 노드는 오포화(incorrect saturation)되었다고 한다. 이 경우, 오포화된 출력 노드에 연결된 가중치들의 변화량은 매우 작다. 따라서 이 출력 노드들이 이 상황에서 빠져 나오지 못하면 신경망은 오류가 큰 상태에서 더 이상 학습이 되지 않으므로 연결 가중치들이 지역 최소화에 위치하게 된다. 따라서 기존의 Max-Min 신경망은 실제에 적용되어 패턴의 수가 많아질수록 조기 포화 현상이 발생하여 학습의 수렴성이 낮아지는 문제점이 있다.

따라서 본 논문에서는 중간층과 출력층 사이의 학습구조인 Max_Min 신경망의 학습 성능을 개선하기 위해 퍼지 제어 기법을 적용하여 학습률을 동적으로 조정하는 방법을 제안한다. 제안한 방식은 목표값과 출력값의 차이의 절대값이 0.1보다 적거나 같으면 정확성으로 분류하고 크면 부정확성으로 분류한다. 정확성의 총 개수를 퍼지 논리 시스템에 적용하여 학습률을 조정한다. 제안한 방식의 유용성을 확인하기 위하여 컨테이너에서 추출된 숫자와 영문 식별자를 대상으로 ART2 기반 RBF 네트워크 방식과 성능을 비교 분석한다.

II. 제안된 FCM 기반 하이브리드 RBF 네트워크

제안된 FCM 기반 하이브리드 RBF 네트워크의 학습 단계는 다음과 같다.

단계 1 : 학습에 사용되는 인수를 초기화 한다.

단계 2 : 학습패턴과 목표패턴을 설정한다.

단계 3 : 클러스터의 중심값을 식(1)과 같이 계산한다.

$$v_{ij} = \frac{\sum_{k=1}^n (\mu_{ik})^m x_{kj}}{\sum_{k=1}^n (\mu_{ik})^m} \quad (1)$$

식(1)에서 v_{ij} 와 x_{kj} 는 클러스터의 중심과 입력벡터이고, m 는 지수가중치이다.

단계 4 : 중간층의 소속도를 식(2)와 같이 계산한다.

$$\mu_{ik} = 1 / \sum_{y=1}^c \left(\frac{|x_{kj} - v_{ij}|}{|x_{kj} - v_{yj}|} \right)^{2/m-1} \quad (2)$$

단계 5 : 오차 한계치를 식(3)과 같이 검사한다.

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

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

단계 6 : 중간층의 승자 노드(O_i^*)를 식(4)와 같이 계산하여 선택한다.

$$\begin{aligned} O_i &= \sqrt{v_{ij}^2 - x_{kj}^2} \\ O_i^* &= \min(O_i) \\ \text{if } O_i &= O_i^* \text{ then } O_i = 1 \\ &\text{else } O_i = 0 \end{aligned} \quad (4)$$

단계 7 : 출력층의 출력벡터(O_i)를 식(5)와 같이 계산한다.

$$\begin{aligned} Net_i &= \vee \{ \{O_i \wedge w_{i1}\}, \dots, \{O_i \wedge w_{in}\} \} \\ O_i &= Net_i \vee \theta_i \end{aligned} \quad (5)$$

단계 8 : 오류를 식(6)과 같이 계산한다.

$$error = \frac{1}{2} (O_i - T_i)^2 \quad (6)$$

단계 9 : 단계 8에서 구해진 목표값(O_i)과 출력값(T_i)의 차이를 이용하여 퍼지 제어 기법으로 학습률을 조정한다.

단계 10 : 조정된 학습률을 이용하여 연결가중치(w_{li})와 바이어스항(θ_l)을 식(7)과 같이 계산한다.

$$\begin{aligned} w_{li}(n+1) &= w_{li}(n) + \alpha \Delta w_{li}(n+1) + \beta \Delta w_{li}(n) \\ \theta_l(n+1) &= \theta_l(n) + \alpha \Delta \theta_l(n+1) + \beta \Delta \theta_l(n) \\ \text{if } O_l &= w_{li} \text{ then } \Delta w_{li}(n+1) = \Delta w_{li}(n) + 1 \times error \\ &\text{else } \Delta w_{li}(n+1) = \Delta w_{li}(n) + 0 \times error \\ \text{if } O_l &= \theta_l \text{ then } \Delta \theta_l(n+1) = \Delta \theta_l(n) + 1 \times error \\ &\text{else } \Delta \theta_l(n+1) = \Delta \theta_l(n) + 0 \times error \end{aligned} \quad (7)$$

식(7)에서 α 는 학습률이고, β 는 모멘텀 계수이다.

III. 퍼지 제어 기법을 이용한 제안된 학습률 조정 방법

본 논문에서는 Max-Min 신경망의 학습 성능을 개선하기 위해 퍼지 제어 기법을 적용하여 학습률을 자동으로 조정한다[8,9]. 각 패턴에 대한 실제 출력값과 목표값의 차이가 0.1보다 적거나 같은 경우 정확성으로 분류하고, 큰 경우에는 부정확성으로 분류하여 퍼지 제어 기법의 입력으로 사용한다. 정확성에 대한 소속 함수는 그림 1과 같고 부정확성에 대한 소속 함수는 그림 2와 같다. 그림 1에서 정확성의 소속 함수 구간 [C_{low} , C_{high}]는 다음과 같이 계산한다.

$$C_{low} = \log_2(\text{입력 노드 수} + \text{입력 패턴 개수}) \quad (8)$$

$$C_{high} = C_{lim} - C_{low}$$

여기서 C_{lim} 는 정확성의 한계치를 의미한다.

$$C_m = \frac{(C_{high} + C_{low})}{2}$$




그림 1. 정확성의 소속 함수
Fig. 1. Membership functions for correctness




그림 2. 부정확성의 소속 함수
Fig. 2. Membership functions for incorrectness

부정확성에 대한 소속 함수 구간은 정확성의 소속 함수 구간과 동일한 수식으로 구한다. 그림 3은 학습에 적용될 학습률을 계산하는 소속 함수이다.




그림 3. 학습률 출력 소속 함수
Fig. 3. Membership Function for Learning Rate Output

제안된 방법에서 퍼지 제어 규칙을 if~than 형식의 퍼지 관계로 표현하면 다음과 같다.

- R_1 : If correct is F, Incorrect is F Then α is B
- R_2 : If correct is F, Incorrect is A Then α is B
- R_3 : If correct is F, Incorrect is T Then α is B
- R_4 : If correct is A, Incorrect is F Then α is M
- R_5 : If correct is A, Incorrect is A Then α is M
- R_6 : If correct is A, Incorrect is T Then α is M
- R_7 : If correct is T, Incorrect is F Then α is S
- R_8 : If correct is T, Incorrect is A Then α is S
- R_9 : If correct is T, Incorrect is T Then α is S

정확성과 부정확성에 대한 퍼지 제어 기법의 입력 값을

정하고 정확성과 부정확성의 소속 함수에 대한 소속도를 구한 후, 퍼지 제어 규칙을 적용하여 Max-Min 방법으로 추론한다. 무게 중심법을 이용하여 비퍼지화를 수행하고 최종 학습률을 구한다. 무게중심은 식(9)와 같이 계산한다. 식 (9)에서 y 는 그림 3의 학습률이다.

$$\alpha = \frac{\int y \cdot \mu(y) dy}{\int \mu(y) dy} \tag{9}$$

IV. 실험 및 결과 분석

본 논문에서 제안된 방법의 학습 및 인식 성능을 평가하기 위하여 Intel Pentium-IV 3.0GHz CPU와 1GB RAM이 장착된 IBM 호환 PC상에서 Visual Studio 2008로 구현하였다. 제안된 방법과 ART2 기반 RBF 네트워크의 학습 및 인식 성능을 비교하기 위해 컨테이너에서 추출된 숫자, 영문 식별자를 실험에 사용하였다. 표 1은 제안된 방법에 사용된 학습 파라미터이다. 표 2는 ART2 기반 RBF 네트워크에 사용된 파라미터이다.

표 1. 제안된 방법에 사용된 학습 파라미터
Table 1. Learning parameters for the proposed method

	c	m	ϵ	β
숫자	10	2	0.01	0.7
영문	24	3	0.01	0.7

제안된 방법에서는 입력층과 중간층 사이의 학습 구조로 FCM을 적용하므로 표 1에서 c 는 초기 클러스터의 수이고 m 은 지수 가중치이다. 그리고 중간층과 출력층 사이의 학습 구조로 Max-Min 신경망을 적용하므로 ϵ 은 정확성과 비정확성을 구분하는 기준 값이고 β 는 학습률을 동적으로 조정하기 전의 초기 학습률이다.

표 2. ART2기반 RBF 네트워크에 사용된 학습 파라미터
Table 2. Learning parameters for the ART2 based RBF network

	ρ	ϵ	β
숫자	0.14	0.01	0.7
영문	0.1	0.01	0.7

ART2 기반 RBF 네트워크에서는 입력층과 중간층 사이의 학습 구조로 ART2를 적용하므로 표 2에서 ρ 는 경계 변수이다. 그리고 ε 은 중간층과 출력층 사이의 학습 구조로 일반화된 델타 학습 방법을 적용하므로 Max-Min 신경망과 같이 정확성과 비정확성을 구분하는 기준 값이고 β 는 학습률이다.

표 3과 4는 제안된 방법과 ART2기반 RBF 네트워크간의 학습 및 인식 성능을 비교하기 위해 숫자와 영문 식별자의 실험 결과를 각각 나타낸 것이다.

표 3과 표 4에서와 같이 제안된 방법이 같은 패턴을 대상으로 실험한 결과, ART2 기반 RBF 네트워크보다 학습 속도나 인식 성능 면에서 효과적임을 확인 할 수 있었다. ART2 기반 RBF 네트워크는 경계 변수의 설정에 따라 생성된 클러스터의 수가 달라지고 서로 다른 패턴들이 같은 클러스터로 분류된 상태에서 출력층으로 전달되어 학습하므로 패턴들이 정확히 분류되지 않는 경우가 발생하여 숫자에서는 1개와 영문에서는 7개가 오인식되었다.

표 3. 제안된 방법과 ART2 기반 RBF 네트워크의 숫자 식별자에 대한 학습 및 인식결과

Table 3. Comparative numeric character recognition results

	제안된 방법	ART2 기반 RBF 네트워크
클러스터 수	10	48
Epoch 수	2237	53549
인식률	300/300	299/300
TSS	0.0042	0.0082

표 4. 제안된 방법과 ART2 기반 RBF 네트워크의 영문 식별자에 대한 학습 및 인식결과

Table 4. Comparative alphabet character recognition results

	제안된 방법	ART2 기반 RBF 네트워크
클러스터 수	24	173
Epoch 수	3899	87542
인식률	479/480	473/480
TSS	0.0067	0.00987

그러나 제안된 방법은 중간층으로 FCM을 적용하므로 각각 패턴들의 유사한 특징들을 소속도로 분류하고 이 소속도를 출력층으로 전달하여 소속도가 높은 패턴들로 분류하는 과정에서 제안된 퍼지 제어 기법을 이용하여 학습률을 동적으로

조정하므로 분류 성능이 ART2 기반 RBF 네트워크보다 향상된 것을 확인할 수 있었다.

V. 결 론

FCM 기반 하이브리드 RBF 네트워크는 서로 다른 학습 모델이 결합된 혼합형 모델로서, 입력층과 중간층의 학습 구조는 FCM 알고리즘을 적용하였고, 중간층과 출력층 사이의 학습 구조는 Max_Min 신경망을 적용하였다.

입력층과 중간층의 학습시 입력 벡터와 중간층의 노드 중에서 중심과 입력 벡터가 가장 가까운 노드를 승자 노드로 선택하여 출력층으로 전달하였다. 그리고 중간층과 출력층 사이의 학습 구조인 Max_Min 신경망은 중간층의 승자 뉴런을 입력 벡터로 적용하였다. Max_Min 신경망은 퍼지의 기본 연산자를 사용하고, 0과 1사이의 값을 입력 패턴으로 적용하여 학습하는 알고리즘이다. 하지만 이 알고리즘은 실제에 있어 패턴의 수가 많아지는 경우 수렴성이 떨어지는 단점을 가지고 있으며 n bit parity 문제에 대해서는 학습이 되지 않는 경우가 발생한다.

따라서 본 논문에서는 FCM 기반 하이브리드 RBF 네트워크의 중간층과 출력층 사이의 Max_Min 알고리즘의 성능을 개선하기 위해서 퍼지 제어 기법을 적용하여 학습률을 동적으로 조정하는 방법을 제안하였다. 출력값과 목표값의 차이가 0.1보다 적거나 같으면 정확성으로 분류하고, 그렇지 않은 경우에는 부정확성으로 분류하였다. 정확성과 부정확성의 수를 퍼지 제어 기법에 적용하여 학습률을 동적으로 조정하였고 동적으로 조정된 학습률을 이용하여 연결 가중치와 바이어스 값을 조정하였다. 제안된 학습 방법의 학습 및 인식 성능을 평가하기 위해 컨테이너에서 추출된 숫자와 영문 식별자를 대상으로 학습 및 인식 실험에 적용하여 ART2 기반 RBF 네트워크와 비교 분석한 결과, 학습 및 인식 성능에서 ART2 기반 RBF 네트워크보다 우수한 결과를 보여 패턴 인식에 효율적인 것을 확인하였다.

따라서 향후 연구 방향은 제안된 방법을 한방 자가 진단 시스템에 적용하여 제안된 방법의 분류 및 인식 성능의 우수성을 입증할 것이다.

참고문헌

[1] D. K. Arun, Computer Vision and Fuzzy-Neural Systems, Prentice Hall PTR, 2001.

- [2] D. Q Zhang, S. C. Chen, "Clustering Incomplete Data Using Kernel-Based Fuzzy C-means Algorithm," Neural Processing Letters, Vol.18, Issue 3, pp.155-162, 2003.
- [3] L. S. Hsu, et als, "Fuzzy Neural-Logic System", Proceedings of IJCNN, Vol.1, pp.254-250, 1992.
- [4] A. Blanco, N. Delgado, I. Requena, "Solving fuzzy relational equations by max-min neural networks," Proceedings of IEEE World Congress on Computational Intelligence, Vol. 3, pp.1737 - 1742, 1994.
- [5] K. B. Kim, M. H. Kang, E. Y. Cha, "A Fuzzy Competitive Backpropagation using Nervous System," Proceedings of World Congress on Systems Simulation, pp.188-193, 1997.
- [6] K. B. Kim, Y. H. Joo, J. H. Cho, "An Enhanced Fuzzy Neural Network, Lecture Notes in Computer Science, Vol. 3320, pp.176-179, 2005.
- [7] K. B. Kim, S. Kim, "Hierarchical Recognition of English Calling Card by Using Multiresolution Images and Enhanced Neural Network," Lecture Notes in Computer Science, Vol. 3801, pp.785-792, 2005.
- [8] K. B. Kim, A. S. Oh, Y. W. Woo, "Enhanced FCM-based Hybrid Network," INFORMATION-AN INTERNATIONAL INTERDISCIPLINARY JOURNAL, Vol.16, No. 2B, pp.1509-1515, 2013.
- [9] K. B. Kim, C. K. Kim, "Performance Improvement of RBF Network using ART2 Algorithm and Fuzzy Logic System," Lecture Notes in Artificial Intelligence, LNAL 3339, Springer, pp.853-860, 2004.

저 자 소 개



김 광 백

1999년 : 부산대학교
전자계산학과졸업(이학박사)
현재 : 신라대학교 컴퓨터공학과 교수
1999년 : Biomedical Fuzzy
Systems Association,
Editor(Japan)
2009년 : Journal of Digital
Imaging (Springer: SCI),
Guest Editor
현재 : 한국정보통신학회 수석부회장
현재 : The Open Artificial
Intelligence Journal(USA),
Editor.
현재 : 한국지능정보시스템학회 편집위원
2013년 : International Journal of
Computational Vision
and Robotics (SCOPUS),
Guest Editor
2013년 : International Journal of
Information and
Communication
Technology (SCOPUS),
Guest Editor
관심분야 : 퍼지 논리, 영상 처리,
유전자 알고리즘,
의료정보시스템,
생물정보학
Email : gbkim@silla.ac.kr



박 충 식

1993년 : 연세대학교 대학원
전자공학과(공학박사)
현재 : 영동대학교 스마트IT학과 교수
현재 : 한국지능정보시스템학회 감사
현재 : 한국지능정보시스템학회 편집위원
관심분야 : 컴퓨터비전,
지식기반시스템,
재난정보시스템,
디지털교과서, 등
Email : leciel@yd.ac.kr