

퍼지 제어 기법을 이용한 개선된 Max-Min 신경망

김광백* · 우영운**

An Enhanced Max-Min Neural Network using a Fuzzy Control Method

Kwang-Baek Kim* · Young-Woon Woo**

요 약

본 논문에서는 퍼지 제어 기법을 적용하여 학습률을 자동으로 조정하는 개선된 Max-Min 신경망을 제안하였다. 개선된 Max-Min 신경망은 경쟁 단계에서 필요한 학습 시간을 줄이기 위하여, 정확성의 수와 부정확성의 수를 퍼지 제어 시스템의 입력으로 적용하여 학습률을 동적으로 조정하는 기법이다. 본 논문에서 제안된 방법을 실제 콘크리트 표면 균열 영상에서 추출한 균열의 방향성 패턴을 대상으로 인식 실험한 결과, 개선된 Max-Min 신경망이 효과적임을 확인할 수 있었다.

ABSTRACT

In this paper, we proposed an enhanced Max-Min neural network by auto-tuning of learning rate using fuzzy control method. For the reduction of training time required in the competition stage, the method was proposed that arbitrates dynamically the learning rate by applying the numbers of the accuracy and the inaccuracy to the input of the fuzzy control system. The experiments using real concrete crack images showed that the enhanced Max-Min neural network was effective in the recognition of direction of the extracted cracks.

키워드

Max-Min Neural Network, Learning Rate, Competition Stage, Fuzzy Control System
Max-Min 신경망, 학습률, 경쟁 단계, 퍼지 제어 시스템

1. 서 론

퍼지 논리는 논리성(logicality)의 이점을 갖는 반면에 인공 신경망은 학습 능력의 장점을 갖고 있다. 이런 장점들은 서로 보완적이며 이들의 융합(fusion)은 좀 더 인간의 사고 능력에 가까운 지능의 구현을 가능하게 한다. 퍼지와 인공 신경망에 관한 연구는 두 이론의 장점을 결합하는 합성과 두 이론의 유사한 특성을 결합하는 융합이 있다[1].

유사한 특성은 첫째, 인공 신경망의 출력 특성과 퍼지 이론의 소속 함수(membership function)의 특성은 유사하다. 둘째, 인공 신경망을 구성하는 뉴런(neuron)들의 연산 기능과 퍼지 추론에서의 논리 연산 기능은 유사하다.

이러한 융합에 관한 연구 방향은 퍼지 논리에 신경망의 학습능력을 부여하는 방향과 신경망의 학습에 퍼지 논리를 부여하는 방향으로 크게 분류할 수 있다. 인공 신경망과 퍼지 논리의 장단점을 설명하면 다음

* 제1저자 : 신라대학교 컴퓨터공학과(gbkim@silla.ac.kr)

** 교신저자(corresponding author) : 동의대학교 멀티미디어공학과(ywwoo@deu.ac.kr)

접수일자 : 2013. 06. 10

심사(수정)일자 : 2013. 07. 23

게재확정일자 : 2013. 08. 23

과 같다[2].

인공 신경망은 첫째, 지능에 의한 인식 결과에 정확한 답을 요구한다. 둘째, 애매모호한 데이터 처리에는 부적합하다. 그러나 잡음 처리 등에는 적합하다. 셋째, 파라미터 값에 영향을 많이 받는다. 프로그래밍하기 어렵다. 넷째, 학습 모형 구조가 복잡하나 학습 능력을 가진다. 이에 반해 퍼지 논리는 첫째, 지능에 의한 정확한 답이 아닌 소속도(membership degree)와 가능성을 나타낸다. 둘째, 애매모호한 데이터 처리에 적합하다. 셋째, 파라미터 값에 영향을 적게 받는다. 프로그래밍하기 쉽다. 넷째, 모형 구조가 매우 간단하나 학습 능력이 없다. 이상의 장점을 융합하여 퍼지 신경망은 애매모호하고 잡음이 많은 데이터 처리에 적합하고 모형 구조가 간단하며 학습의 능력을 갖는다. 그러므로 상호 보완의 관계를 갖는 두 이론의 결합으로부터 좀 더 인간의 사고 능력에 접근 할 수 있으며 인공 신경망의 학습 능력을 향상시킬 수 있다.

Max-Min 신경망은 퍼지의 기본 연산자를 사용하고 0과 1사이의 값을 입력 패턴으로 적용하여 학습하는 알고리즘이다. 이 알고리즘의 장점은 기존의 단층 알고리즘이 이진 데이터를 학습하는데 중점을 둔 반면에 퍼지 값인 0과 1사이의 값을 학습하는데 효과적으로 학습할 수 있도록 퍼지 논리 연산자를 이용한 것이 큰 장점이다[3]. 그러나 기존의 Max-Min 신경망은 단층 학습 구조로서 학습 과정 중에 조기 포화 현상으로 학습의 수렴성이 낮아지는 문제점이 있다.

기존의 Max-Min 신경망은 연결 가중치들이 지역 최소화(local minima)에 위치하게 되는 원인을 분석해보면 오류 한계 설정 문제, 초기 연결 가중치 설정 문제, 학습률 설정 문제, 모멘텀 설정 문제 등이 있다[4]. 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, 학습이 되지 않은 패턴이 갑자기 학습되면서 오류가 급격히 줄어드는 우세 단계로 구분하였다[5]. 이 3단계 중 경쟁 단계에 의해 학습 시간이 많이 걸리며 조기 포화 현상(early saturation)이 발생한다. 조기 포화 현상이란 신경회로망이 학습 도중 일정한 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 실세계 적용에 있어 패턴의 수가 많아질수록 조기 포화 현상이 발생하여 학습의 수렴성이 낮아지는 문제점이 있다. 기존의 Mx-Min 신경망의 학습 성능을 개선하기 위해 Delta-bar-Delta 규칙을 학습률에 적용한 Delta-bar-Delta 기반 Mx-Min 신경망이 제안되었다[6]. 그러나 연결 가중치의 변화량을 기반으로 Delta-bar-Delta 규칙을 적용하는 단계에서 조기 포화 현상이 발생하면 연결 가중치의 변화가 거의 없다. 따라서 연결 가중치가 지역 최소화에 위치하는 경우가 발생하거나 각 학습 패턴들을 정확히 분류할 수 없어 인식률이 낮아지는 경우가 발생한다.

따라서 본 논문에서는 목표값과 출력값의 차이에 대한 절대값이 ε 보다 적거나 같으면 정확성으로 분류하고 크면 부정확성으로 분류하여 퍼지 제어 시스템의 입력으로 사용하여 학습률과 모멘텀을 동적으로 조정하여 학습의 수렴성을 개선한다.

II. Max-Min 신경망

Max-Min 신경망의 알고리즘은 다음과 같다.

<단계 1>

입력값 $V_k = (v_{k1}, \dots, v_{km})$ 과 목표값 $T_k = (t_{k1}, \dots, t_{kn})$ 을 제시한다.

<단계 2>

$O_k = (o_{k1}, \dots, o_{kn})$ 은 출력값을 나타내고 r_{ij} 은 가중치로서 임의의 값으로 초기화한다. θ_i 은 바이어스 항으로 임의의 값으로 초기값을 설정한다. w_{ki} 은 이 학습 알고리즘의 실제적인 초기 가중치를 계산하는 값으로 계산하는 식은 다음과 같다.

$$w_{ki} = \bigvee \{ \bigwedge \{v_{ki}, r_{1i}\}, \dots, \bigwedge \{v_{km}, r_{mi}\} \}$$

여기서, \bigvee 은 퍼지 논리합 연산자이고 \bigwedge 은 퍼지 논리곱 연산자이다.

$$o_{ki} = w_{ki} \bigvee \theta_i$$

<단계 3>

목표 값과 출력값 사이의 오류값을 계산한다. 여기서 Q는 Total Sum of Square이다.

$$Q = \frac{1}{2} \sum_{k=1}^K \sum_{i=1}^n (o_{ki} - t_{ki})^2$$

<단계 4>

가중치와 바이어스 항을 조정한다.

$$r_{ij}(l+1) = r_{ij}(l) + \eta \Delta r_{ij}(l+1) + \beta \Delta r_{ij}(l),$$

$$\theta_i(l+1) = \theta_i(l) + \eta \Delta \theta_i(l+1) + \beta \Delta \theta_i(l),$$

$$\Delta r_{ij} = 1, \text{ when } o_{ki} = r_{ij} \\ = 0, \text{ otherwise.}$$

$$\Delta \theta_i = 1, \text{ if } o_{ki} = \theta_i \\ = 0, \text{ otherwise.}$$

<단계 5>

모든 패턴이 학습 패턴에 대하여 부정확성의 수가 0보다 크면 < 단계 2 >로 가서 반복한다.

III. 제안된 학습률 조정 방법

본 논문에서는 Max-Min 신경망의 성능을 개선하기 위해서 퍼지 논리 시스템을 이용하여 학습률과 모멘텀을 자동으로 조절하는 방식을 제안한다. 각 패턴에 대한 출력층의 실제 출력값과 목표값의 차이의 절대값이 ϵ 보다 적거나 같은 경우에는 정확성으로 분류하고 큰 경우에는 부정확성으로 분류하여 퍼지논리 시스템의 입력으로 사용한다. 퍼지 논리 시스템을 이용한 학습률의 조절은 식(1)과 같다.

$$\eta = Fuzzy(Correct, Incorrect) \quad (1)$$

모든 패턴의 출력층 출력값이 정확성으로 분류되면 학습을 종료한다. 모멘텀은 1에서 퍼지 시스템에서 구한 학습률을 감하여 구한다. 식 (2)는 모멘텀을 동적으로 조정하는 식이다.

$$\beta = 1 - \eta \quad (2)$$

제안된 방법에서 정확성의 소속 함수는 그림 1과 같고, 부정확성의 소속 함수는 그림 2와 같다.




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




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

그림 1에서 정확성의 소속 함수 구간 $[C_{low}, C_{high}]$ 는 다음과 같이 계산한다.

$$C_{low} = \log_2(\text{입력노드수} + \text{출력노드수}) \quad (3)$$

$$C_{high} = C_{lim} - C_{low} \quad (4)$$

여기서 C_{lim} 는 정확성의 한계치를 의미한다.

학습에 적용될 학습률을 계산하는 출력 소속 함수

는 그림 3과 같다.




그림 3. 출력 η의 소속 함수
Fig. 3 Membership functions for output η

제안된 방법에서 퍼지 제어 규칙은 다음과 같다.

- R₁ : If correct is F, incorrect F Then η is B
- R₂ : If correct is F, incorrect A Then η is B
- R₃ : If correct is F, incorrect M Then η is B
- R₄ : If correct is A, incorrect F Then η is M
- R₅ : If correct is A, incorrect A Then η is M
- R₆ : If correct is A, incorrect M Then η is M
- R₇ ; If correct is M, incorrect F Then η is S
- R₈ : If correct is M, incorrect A Then η is S
- R₉ : If correct is M, incorrect M Then η is S

여기서 F(Few), A(Average), M(Many), S(Small), M(Medium), B(Big)는 퍼지 소속 함수이다. 정확성과 부정확성이 퍼지 시스템의 입력값으로 정해지면 각 소속 함수에 대한 정확성과 부정확성의 소속도를 구한다. 각 소속 함수에 대하여 소속도가 구해지면 퍼지 제어 규칙을 이용하여 Max-Min 방법을 적용하여 추론한다. 퍼지 추론 후에는 비퍼지화 하여 학습에 사용될 학습률을 구한다. 비퍼지화에는 무게중심법을 사용하는데, 식 (5)와 같다[7,8].

$$\eta = \frac{\sum \mu(y)y}{\sum y} \tag{5}$$

IV. 실험 및 결과 분석

기존의 Max-Min 신경망들과 개선된 Max-Min 신경망의 학습 및 인식 성능을 분석하기 위해 입력 패턴으로는 참고문헌[6]의 방법을 이용하여 콘크리트 균열 영상에서 추출한 25개의 균열 패턴을 적용하였고, 출력층의 노드 수는 5개로 설정하였다. 그리고 기존의 Max-Min 신경망에서는 학습률과 모멘텀을 0.5, 0.75로 설정하는 것이 학습의 수렴성이 효율적이었다. 참고문헌[6]의 Max-Min 신경망과 개선된 Max-Min 신경망에서는 초기 학습률과 모멘텀을 각각 0.1로 설정하였다. 표 1 은 기존의 Max-Min 신경망들과 개선된 Max-Min 신경망간의 학습 및 인식 결과를 나타내었다.

표 1. 특정 균열의 방향성 학습 및 인식 결과
Table 1. Learning and recognition results of specific cracks

	Epoch Number	Recognition Rate	TSS
Conventional Max-Min Neural Network	211	20 / 25	0.024751
Delta-bar-Delta based Max-Min Neural Network[6]	117	24 / 25	0.00981
Proposed Max-Min Neural Network	106	25 / 25	0.00031

표 1에서 기존의 Max-Min 신경망과 Delta-bar-Delta 기반 Max-Min 신경망이 균열 인식에서 실패한 경우는 학습 패턴 중에서 일부 균열의 특징이 잡음으로 분류되어 기존의 Max-Min 신경망과 Delta-bar-Delta 기반 Max-Min 신경망에서는 서로 다른 균열의 특징들이 학습하는 과정에서 조기 포화 현상이 발생하여 정확히 분류되지 않았다. 그러나 제안된 Max-Min 신경망은 총오차자승합 대신에 정확성의 수와 부정확성의 수를 기반으로 학습의 분류 성능 기준을 설정하고 정확성 수와 부정확성의 수를 기반으로 퍼지 제어 기법을 적용하여 학습률을 조정하였기 때문에 조기포화현상이 발생하지 않았다. 따라서 학습 패턴들의 특징을 정확히 분류할 수 있어 인식률

이 개선된 것을 표 1에서 확인할 수 있다.

그리고 기존의 Max-Min 신경망과 Delta-bar-Delta 기반 Max-Min 신경망보다 제안된 Max-Min 신경망이 조기 포화 현상이 발생하지 않기 때문에 학습 시간도 적게 소요되는 것을 표 1에서 확인할 수 있다.

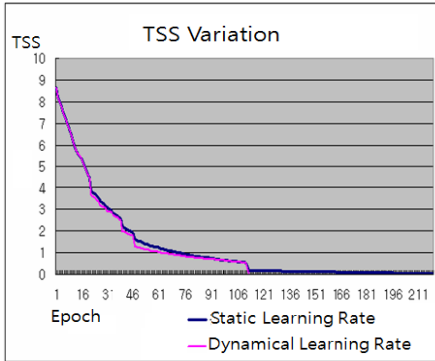


그림 4. Epoch 수와 TSS 변화
Fig. 4 The number of Epoch and TSS variation

그림 4는 두 알고리즘 간의 Epoch 수에 따른 TSS 변화량을 나타내었다. 그림 4에서와 같이 제안된 Max-Min 신경망은 학습률을 동적으로 조정하기 때문에 기존의 Max-Min 신경망보다 학습의 수렴성이 빠른 것을 확인할 수 있다.

그림 5는 추출된 특정 부분 균열의 방향성을 제안된 Max-Min 신경망을 이용하여 인식한 결과이다.

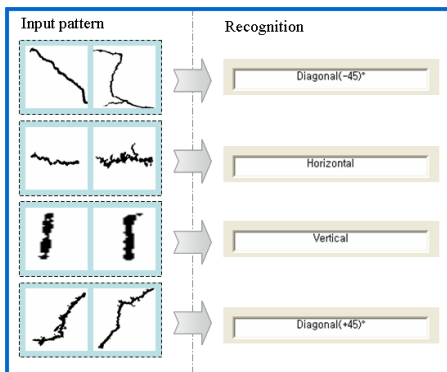


그림 5. 개선된 Max-Min 신경망을 이용한 특정 부분 균열의 방향성 인식 결과

Fig. 5 Results of direction recognition on specific partial crack using the enhanced Max-Min neural network

V. 결 론

기존의 Max-Min 신경망 알고리즘은 다양한 패턴 인식에 적용할 경우에 학습의 수렴성이 낮아져서 인식에 적용할 수 없는 경우가 발생한다. 그 원인은 학습 단계 중에서 경쟁 단계에서 조기 포화 현상이 발생하기 때문이다. 따라서 본 논문에서는 학습의 수렴성에 영향을 주는 학습률과 모멘텀을 동적으로 조정하여 경쟁 단계에서 조기 포화 현상을 감소시켜 학습 패턴들의 분류 성능과 수렴성을 개선하였다. 제안 기법에서는 총오차차승합 대신 목표값과 출력값 차이의 절대값이 ϵ 보다 적으면 정확성으로 분류하여 퍼지 제어 기법에 적용하였다. 따라서 모든 학습 패턴들이 정확성으로 분류되면 학습을 종료하므로 학습의 분류 성능과 인식률이 향상되는 것을 실험을 통하여 확인하였다. 그러나 제안된 Max-Min 신경망은 단층 구조로서 복잡하고 다양한 패턴들을 분류하는 데에는 한계가 있다.

참고 문헌

- [1] K. B. Kim, J. H. Cho, and E. Y. Cha, "A New Single Layer Perceptron using Fuzzy Neural Controller", Simulations International XII, Vol. 27, No. 7, pp. 341-343, 1995.
- [2] K. B. Kim, C. K. Yuk and E. Y. Cha, "A New Fuzzy Supervised Learning Algorithm", AFSS'98, pp. 399-403, 1998.
- [3] M. 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.
- [4] K. B. Kim, Y. W. Woo, "Detection of Flaws in Ceramic Materials Using Non-Destructive Testing", The Journal of The Korea Institute of Electronic Communication Sciences, Vol. 5, No. 3, pp. 321-326, 2010.
- [5] K. B. Kim, M. H. Kang and E. Y. Cha, "A Fuzzy Competitive Backpropagation Using Nervous System", Proceedings of WCSS'97, pp. 188-193, 1997.
- [6] K. B. Kim, W. J. Lee, Y. W. Woo, "Automatic Recognition and Performance of Printed

Musical Sheets Using Fuzzy ART", The Journal of The Korea Institute of Electronic Communication Sciences, Vol. 6, No. 1 pp. 84-69, 2011.

- [7] J. H. Cho, "Enhanced Fuzzy Binarization Method for Car License Plate Binarization", The Journal of The Korea Institute of Electronic Communication Sciences, Vol. 6, No. 2, pp. 231-236, 2011.
- [8] K. B. Kim, H. J. Park, "Recognition of Concrete Surface Using Enhanced Max-Min Neural Networks", The Journal of The Korea Society of Computer and Information, Vol. 12, No. 2, pp. 77-82, 2007.

저자 소개



김광백(Kwang-Baek Kim)

1999년 부산대학교 전자계산학과 졸업(이학박사)
1997년~현재 신라대학교 컴퓨터공학과 교수

2010년~현재 한국컴퓨터정보학회 영문지 편집위원장
2010년~현재 The Open Artificial Intelligence Journal (USA), Editor.
2012년~현재 한국멀티미디어학회 국제운영부위원장 (운영이사)
※ 관심분야 : 퍼지 논리, 영상 처리, 유전자 알고리즘, 의료정보시스템, 생물정보학



우영운(Young-Woon Woo)

1991년 8월 연세대학교 본대학원 전자공학과(공학석사)
1997년 8월 연세대학교 본대학원 전자공학과(공학박사)

동의대학교 멀티미디어공학과 교수
※ 관심분야 : 지능시스템, 패턴인식, 퍼지이론, 의료정보