

자가 생성을 이용한 퍼지 다층 퍼셉트론

백인호* · 김광백**

Fuzzy Multilayer Perceptron by Using Self-Generation

In-Ho Paek* · Kwang-Baek Kim**

요 약

다층 구조 신경망에서 널리 사용되는 오류 역전파 알고리즘은 초기 가중치와 불충분한 은닉층의 노드 수로 인하여 지역 최소화에 빠질 가능성이 있다. 따라서 본 논문에서는 오류 역전파 알고리즘에서 은닉층의 노드 수를 설정하는 문제와 ART1에서 경계 변수의 설정에 따라 인식률이 저하되는 문제점을 개선하기 위하여 ART1과 Max-Min 신경망을 결합한 퍼지 다층 퍼셉트론을 제안한다. 제안된 자가 생성을 이용한 퍼지 다층 퍼셉트론은 입력층에서 은닉층으로 노드를 생성시키는 방식은 ART1을 적용하였고, 가중치 조정은 특정 패턴에 대한 저장 패턴을 수정하도록 하는 winner-take-all 방식을 적용하였다. 제안된 학습 방법의 성능을 평가하기 위하여 학생증 영상을 대상으로 실험한 결과, 기존의 오류 역전파 알고리즘보다 연결 가중치들이 지역 최소화에 위치할 가능성이 줄었고 학습 속도 및 정체 현상이 개선되었다.

Key Words : 오류역전파 알고리즘, ART1, Max-Min 신경망, 퍼지다층퍼셉트론, winner-take-all 방식

1. 서론

인공 신경망의 지도 학습(supervised learning) 모델 중의 하나인 오류 역전파(error backpropagation) 알고리즘은 단층 퍼셉트론으로 해결하지 못했던 비선형 문제를 해결하기 위해 제시되었던 다층 구조 신경망(multilayer neural network)의 대표적인 학습 알고리즘이다[1]. 이 학습 알고리즘은 적용되는 입력 패턴에 대해 파라미터 값들을 어떤 값으로 설정하는가에 따라 학습 속도가 결정되어지고, 은닉층의 노드 수의 설정에 따라 정체 현상과 지역 최소화(local minima) 문제가 발생한다[2]. 오류 역전파 알고리즘에서 은닉층(hidden layer)의 노드 수가 필요 이상으로 많으면 판별 성능에 영향을 거의 미치지 않는 부가적인 노드가 존재하여 학습 시간이 많이 소요되고 은닉층의 노드 수가 적으면 연결 가중치들이 지역 최소화에 위치할 가능성이 높아진다[3,4]. 그러므로 간단한 선형 분리 문제나 Exclusive OR 문제는 필요한 은닉층의 노드 수를 알기 쉽지만 패턴 인식 등과 같은 복잡한 문제의 경우에는 적당한 은닉층의 노드 수를 찾아내기가 어렵다. 그러므로 은닉층의 노드 수는 대부분 경험적(heuristic) 방법을 사용하여 반복 계산으로 근사해를 구하고 있다.

그리고 다른 측면으로는 수정된 코호넨에 기반한 퍼지 클러스터링 알고리즘을 사용하여 초기 은닉층의 노드 수와 초기 가중치를 결정하는 방법이 제안되었다[5]. Crossberg와 Carpenter에 의해 제안된

ART(Adaptive Resonance Theory) 신경망 모델은 뉴런들 간에 경쟁 학습(competitive learning)에 의하여 자율적으로 패턴들을 분류하는 네트워크 구조로서, 임의의 패턴을 학습할 수 있는 안정성(stability)과 적응성(plasticity)을 갖는 신경망의 학습 모델이다[6]. 또한 저속 및 고속 학습이 가능한 장점을 가지고 있고, 지역 최소화(local minima) 문제가 발생하지 않는다. ART 신경망 모델 중에서 ART1 알고리즘은 자동 학습 시스템(autonomous learning system) 구축에 널리 사용되고 있다. ART1 알고리즘은 첫 번째 입력을 첫 번째 클러스터의 대표 패턴으로 선택하고 다음 입력이 들어오면 첫 번째 대표 패턴과의 유사성을 측정하여 경계 변수 보다 크거나 같으면 첫 번째 클러스터로 분류하고, 그렇지 않으면 새로운 클러스터를 생성하게 된다. 이러한 과정이 모든 입력 패턴들에 적용되면 클러스터의 개수는 시간에 따라 점점 증가하게 된다. 그리고 ART1 알고리즘은 경계 변수 설정에 따라 유사한 패턴이 다른 클러스터로 생성되는 경우와 서로 다른 패턴이 같은 클러스터로 분류되는 경우가 발생한다[7]. 따라서 ART1 알고리즘을 패턴 인식에 적용할 경우, 입력 벡터와 클러스터의 대표 벡터간의 유사성 측정 방법과 경계 변수에 따라 인식률이 낮아지는 문제점이 있다.

본 논문에서는 오류 역전파 알고리즘에서 은닉층의 노드 수를 설정하는 문제와 ART1의 경계 변수의 설정에 따른 인식률이 저하되는 문제점을 개선하기 위해 ART1 알고리즘과 Max-Min 신경망을 결합한 자가 생성(Self-generation)을 이용한 퍼지 다층 퍼셉트론을 제안한다.

* 신라대학교 컴퓨터정보공학부

** 신라대학교 컴퓨터공학과

2. 관련 연구

2.1 오류 역전파 알고리즘

오류 역전파 알고리즘은 지도 학습 규칙으로서 주어진 입력에 대해 목표값과 실제 출력값 사이의 오류값에 따라 정의되는 비용 함수(cost function)를 최소화하기 위하여 경사 추적(gradient descent)법을 사용한다. 이로 인해 오류 역전파 학습 구조는 경사 추적법의 일반적인 단점인 학습의 수렴 속도가 느려지는 단점을 가진다[1,2]. 그리고 은닉층의 불충분한 노드 수나 부적절한 초기 연결 가중치로 인한 지역 최소화에 빠질 가능성이 있다[3,4]. 또한 학습 과정에서 은닉층 노드는 그 노드의 목표값을 알 수 없기 때문에 출력층 노드의 오차를 역으로 은닉층 노드들로 책임 분담(credit assignment)하는 방법을 사용하기 때문에 정체 현상이 발생한다[4,5]. 이것은 오차값이 크어도 불구하고 학습이 진행되지 않는 현상으로 조기포화(early saturation)현상에 해당된다[8]. 기존의 은닉층의 노드 수를 동적으로 조정하는 방법은 학습 과정 중에 지역 최소화에 빠졌을 때 은닉층에 하나의 새로운 노드를 첨가하였다[3]. 여기서 총 오차 자승합의 변화량에 의해 지역 최소화를 판정하였다. 즉 일정한 epoch마다 총 오차자승합의 변화량을 검사하여 총 오차 자승합의 변화량이 정해진 값보다 적으면 신경망이 지역최소화에 빠졌다고 판단하여 은닉층에 하나의 새로운 노드를 첨가하는 방법을 적용하였다. 그러나 응용 문제에 따라 일정한 epoch마다 총 오차 자승합의 변화량을 검사하는 것은 객관성이 없으며 은닉층의 노드 수가 필요 이상으로 증가하면 판별 성능에 영향을 거의 미치지 않는 부가적인 노드가 존재하여 학습 시간이 많이 소요되는 단점이 있다. 따라서 본 논문에서는 기존의 오류 역전파 학습 알고리즘에서 은닉층의 노드 수 문제를 해결하기 위한 방법으로 은닉층의 노드를 자가 생성하게 하는 방법에 착안하게 되었고, 그 구체적인 방법으로는 ART1의 노드 생성 방법과 노드 선정 방법을 입력층과 은닉층 사이에 도입하였다. 그리고 본 논문에서 제안할 winner-take-all 방식의 가중치 조정 방법은 기존의 오류 역전파 알고리즘에서 학습속도를 느리게 하는 정체 현상을 개선시킨다.

2.2 Max-Min 신경망

퍼지 이론과 신경망을 접목하기 위한 두 가지 방법이 있다. 첫째 접근 방법은 두 이론의 장점을 결합시키는 것이다. 여기에는 규칙 형태로 논리를 표현하는 퍼지 논리의 특성과 학습에 의해 패턴을 분류하는 신경망의 특징을 이용한다[9]. 두 번째 접근 방법은 두 이론의 유사한 특징을 중첩시키는 것이다[10]. 첫째, 추론 규칙의 조건부의 퍼지 변수와 입력간의 Min 연산은 뉴런의 입력과 연결선에 부여된 가중치의 곱셈 연산에 대응된다. 둘째, 여러 추론 규칙의 결론 부분에 대한 Max 연산은 뉴런의 입력과 가중치를 곱한 것을 합하는 연산과 대응된다. Max-Min 신경망은 두 번째 접근 방법에 해당되는 학습 알고리즘으로 이진 데이터 뿐만 아니라 아날로그 데이터도

효율적으로 학습 할 수 있는 장점이 있다[11]. 그러나 이 알고리즘은 패턴 인식과 같은 실세계 문제에 적용할 경우에는 지역 최소화 문제가 발생하여 수렴이 되지 않는 경우가 발생한다.

Max-Min 신경망에서 NET는 입력 벡터(x_i)와 연결 가중치(w_{ji})의 최대-최소 합성(max-min composition) 연산에 의해 식 (1)과 같이 계산된다.

$$NET = \bigvee \{ \bigwedge \{ x_i, w_{ji} \}, \dots, \bigwedge \{ x_m, w_{jm} \} \} \quad (1)$$

여기서 i 는 입력층이고 $j=0, \dots, n$ 는 출력층이다. 식 (2)와 같이 출력 벡터(o_j)는 NET와 바이어스항(θ_j)간의 퍼지 논리합 연산에 의해 계산된다.

$$o_j = NET \bigvee \theta_j \quad (2)$$

연결 가중치(w_{ji})는 출력 벡터(o_j)와 목표 벡터(t_j)가 동일한 경우에는 연결 가중치(w_{ji})와 바이어스항(θ_j)를 변경하지 않고, 출력 벡터가 목표 벡터와 다른 경우에는 다음 식을 이용하여 가중치와 바이어스항을 조정한다.

$$\begin{aligned} w_{ji}(n+1) &= w_{ji}(n) + \alpha \Delta w_{ji}(n+1) + \beta \Delta w_{ji}(n) \\ \theta_j(n+1) &= \theta_j(n) + \alpha \Delta \theta_j(n+1) + \beta \Delta \theta_j(n) \end{aligned} \quad (3)$$

$$\Delta w_{ji} = \sum_{j=1}^n (t_j - o_j) \frac{\partial o_j}{\partial w_{ji}}, \quad \Delta \theta_j = \sum_{j=1}^n (t_j - o_j) \frac{\partial o_j}{\partial \theta_j}$$

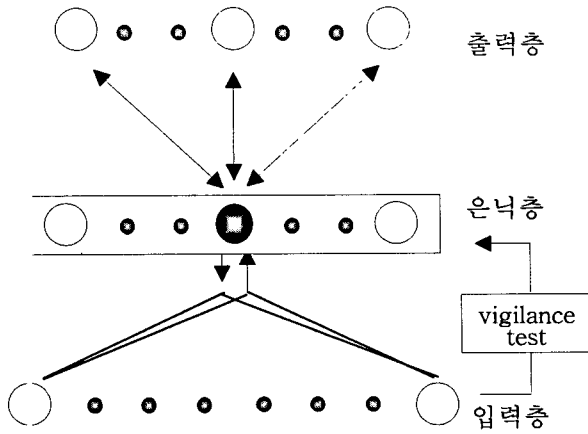
$$\begin{aligned} \frac{\partial o_j}{\partial w_{ji}} &= 1, \text{ when } o_j = w_{ji} \\ &= 0 \text{ otherwise.} \end{aligned}$$

$$\begin{aligned} \frac{\partial o_k}{\partial \theta_k} &= 1, \text{ when } o_k = \theta_k \\ &= 0 \text{ otherwise.} \end{aligned}$$

여기서, α 는 학습율이고 β 는 모멘트이다. Max-Min 신경망에서 학습 종료는 총 오차 자승합(TSS : total sum of squares)이 오류 한계보다 적을 때까지 학습한다.

3. 자가 생성을 이용한 퍼지 다층 퍼셉트론

제안된 방법에서 은닉층의 노드를 자가 생성하도록 구성된 학습 구조는 그림 1과 같다. 제안된 학습 알고리즘에서 입력층과 은닉층간의 연결 구조는 ART1의 구조와 같고, ART1의 출력층이 제안된 구조의 은닉층이다. 은닉층의 노드는 각 클래스를 나타낸다. 따라서 전체적으로는 완전 연결 구조이나 출력층에서 목표 벡터와 실제 출력 벡터를 비교하여 역전파시킬 때는 대표 클래스와 연결된 가중치만을 역전파하는 승자 뉴런 방식(winner-take-all method)을 채택한다. 출력층에서 은닉층으로의 연결 가중치 조정 방식은 Max-Min 신경망을 적용한다.



[그림 1] 제안된 자가 생성 퍼지 다층 퍼셉트론 학습 모형

제안된 구조는 가중치 조정을 위해 기존의 Max-Min 신경망에 승자 뉴런 방식을 채택한다. 입력층과 은닉층간의 연결과 은닉층과 출력층간의 연결로 구분해서 살펴보면 은닉층에서 채택된 승자 노드는 제시된 패턴의 대표 클래스가 된다. 따라서 대표 클래스의 저장 패턴에 제시된 패턴을 반영하기 위해서는 은닉층에서 입력층으로의 승자 노드와 연결된 가중치만을 조정한다. 또한 제시된 패턴에 대한 목표 벡터를 대표 클래스에 의한 실제 출력 벡터에 반영하기 위해 출력층 노드와 그 대표 클래스와 관련된 가중치만을 조정한다. 제안된 자가 생성 방법을 이용한 퍼지 다층 퍼셉트론을 단계별로 정리하면 다음과 같다.

단계 1 : 입력층과 은닉층 사이의 상향 가중치인 w_{ji} 와 하향 가중치인 t_{ji} 를 초기화하고, 은닉층과 출력층 사이의 가중치인 w_{kj} 와 바이어스항 θ_k 를 임의의 값으로 초기화한다. 여기서 $i(i=1, \dots, m)$ 는 입력층이고 $j(j=1, \dots, n)$ 는 은닉층, $k(k=1, \dots, p)$ 는 출력층이다.

$$t_{ji}(0) = 1, w_{ji}(0) = \frac{1}{m+1}$$

단계 2 : 입력 벡터 x_i 와 목표 벡터(t_k)를 제시한다.

단계 3 : 은닉층의 출력 벡터(o_j)를 계산한다.

$$o_j = \sum_{i=1}^m w_{ji} \times x_i$$

단계 4 : 승자 노드(o_j^*)를 선택한다.

$$o_j^* = \text{Max}[o_j]$$

단계 5 : 승자 노드의 하향(t_{ji}) 가중치와 입력 패턴 x_i 의 유사성을 검증한다.

$$\frac{\|T \cdot X\|}{\|X\|}$$

단계 6 : 만약 계산된 유사도가 $\frac{\|T \cdot X\|}{\|X\|} \geq \rho$ 이면 현재의 승자 노드를 대표 클래스로 선택하고 단계 8로, 그렇지 않으면 단계 7로 간다. 여기서, ρ 는 경계 변수로서 0.5와 1사이의 값이다.

단계 7 : 현재 승자 노드(o_j^*)의 출력 벡터를 0으로 하고 새로운 노드를 할당하여 대표 클래스로 선택하고 단계 8로 간다.

단계 8 : 입력 패턴과 승자 노드간의 유사성이 인정된 단계 6의 대표 클래스와 단계 7에서 새로 생성된 대표 클래스의 하향과 상향 가중치를 조정한다.

$$t_{ji}(n+1) = t_{ji}(n) \times x_i$$

$$w_{ji}(n+1) = \frac{t_{ji}(n+1) \times x_i}{0.5 + \sum_{i=1}^m w_{ji} \times x_i}$$

단계 9 : 은닉층의 대표 클래스(o_j^*)와 출력층의 연결 가중치(w_{kj})를 이용하여 NET를 계산하고 NET와 바이어스항(θ_k)를 이용하여 출력층의 출력 벡터(o_k)를 계산한다.

$$NET = \sqrt{\wedge\{o_j^*, w_{1j}\}, \dots, \wedge\{o_j^*, w_{pj}\}}$$

$$o_k = NET \sqrt{\theta_k}$$

단계 10 : 연결 가중치(w_{kj})와 바이어스항(θ_k)을 조정한다. 여기서 $\alpha(k)$ 는 학습율이고 β 는 모멘트이다.

$$w_{kj}(n+1) = w_{kj}(n) + \alpha \Delta w_{kj}(n+1) + \beta \Delta w_{kj}(n)$$

$$\theta_k(n+1) = \theta_k(n) + \alpha \Delta \theta_k(n+1) + \beta \Delta \theta_k(n)$$

$$\Delta w_{kj} = \sum_{k=1}^p (t_k - o_k) \frac{\partial o_k}{\partial w_{kj}}$$

$$\Delta \theta_k = \sum_{k=1}^p (t_k - o_k) \frac{\partial o_k}{\partial \theta_k}$$

$$\frac{\partial o_k}{\partial w_{kj}} = 1, \text{ when } o_k = w_{kj}$$

$$= 0 \text{ otherwise.}$$


$$\frac{\partial o_k}{\partial \theta_k} = 1, \text{ when } o_k = \theta_k$$

$$= 0 \text{ otherwise.}$$

단계 10 : 총오차 자승합(TSS)이 오류 한계(ϵ)보다 크면 단계 3으로 가고 오류 한계보다 적거나 같으면 학습을 종료한다.

4. 실험 및 성능 분석

본 논문에서 제안된 알고리즘의 성능을 평가하기 위하여 Intel Pentium-1GHz CPU와 256 MB RAM이 장착된 IBM 호환 PC상에서 Visual C++로 실험하였다. 실험에 사용된 데이터는 HP Scanjet 4200C 스캐너를 이용하여 600 × 400 크기를 가진 학생증 영상에서 추출한 10개의 학번 패턴을 대상으로 기존의 오류 역전과 알고리즘과 제안된 방법을 비교하였다.



[그림 2] 개별문자 추출에 사용된 학생증 영상

개별 학번 추출은 참고 문헌 [12]의 방법을 적용하여 개별 학번 패턴을 추출하였다. 학번 영역 추출은 평균 밝기 값을 적용하여 학생증 영상을 이진화하고 이진화된 학생증 영상에서 수평 방향 히스토그램을 수행하여 학번 영역을 추출하였다. 그리고 개별 학번은 추출된 학번 영역에서 수직 방향 히스토그램과 위치 정보를 이용하여 추출하였다. 추출된 학번 패턴들 중에서 그림 3과 같은 10개의 학번 패턴을 학습 데이터로 사용하였다.

```

0001111000 0000111100 0001111100 0001111100 0000111100
0011001100 0001111100 0111001110 0110000110 0001101100
0110000110 0111111100 1100000011 1100000011 0011001100
1100000011 0000111100 0000000011 0000000011 0110001100
1100000011 0000111100 0000001110 0000111111 1100001100
1100000011 0000111100 0000011100 0000001111 1111111111
1100000011 0000111100 0001110000 0000000011 1111111111
0110000110 0000011100 0111000000 1100000110 0000001100
0011001100 1111111111 1110000000 0110001100 0000001100
0001111000 1111111111 1111111111 0011111000 0000001100

1111111111 0000111100 1111111111 0011111100 0001111000
1111111111 0011100000 1111111111 0110000110 0110000110
1100000000 0110000000 0000000111 1100000011 1100000011
1100000000 1100000000 0000000111 0110000110 1100000011
1111111100 1111111100 0000001100 0011111100 0110000111
0000001110 1110000110 0000011000 0110000110 0011111110
0000000111 1000000011 0000110000 1100000011 0000001110
0000000111 1100000110 0001100000 1000000001 0000011100
0000011100 0110001100 0111000000 1100000110 0001110000
1111110000 0011111000 1110000000 0011111000 0111000000
    
```


[그림 3] 학번 학습 데이터

그림 3과 같은 10개의 학번 패턴을 제안된 방법과 오류 역전과 알고리즘에 적용하여 모멘트에 따른 Epoch 수와 TSS를 표 1로 나타내었다.


<표 1> 모멘트에 따른 Epoch 수와 TSS

	모멘트	Epoch 수	TSS
BP	0.1	6320	0.01
	0.5	6034	0.01
	0.9	5410	0.01
제안된 방법	0.1	204	0.009861
	0.5	57	0.002735
	0.9	57	0.002735

표 1의 결과는 오류 한계를 0.01로 설정하여 학습한 결과이다. 오류 역전과 알고리즘에서 초기의 은닉층 노드 수를 5개부터 10개 사이로 설정하여 실험한 결과, 10개로 설정하는 것이 학습 시간이 적게 소요되고 학습의 수렴성도 우수하였다. 따라서 표 1에서는 오류 역전과 알고리즘의 초기 은닉층의 노드 수를 10개로 설정하여 학습한 결과이다. 제안된 방법에서는 입력층과 은닉층 사이의 학습 구조로 ART1을 적용하므로 학습 후의 은닉층 노드 수는 10개가 생성되었다. 표 1과 같이 제안된 방법이 오류 역전과 알고리즘 보다 모멘트에 민감하게 반응하지 않았고 학습 시간도 적게 소요되었다. 따라서 10개의 학습 패턴들에 대해서 제안된 방법이 오류 역전과 알고리즘보다 학습에 있어서 효율적인 것을 확인하였다. 오류 역전과 알고리즘에서 모멘트에 따른 Epoch 수와 TSS의 변화 과정을 그림 4로 나타내었고 제안된 방법에서 모멘트에 따른 Epoch 수와 TSS의 변화 과정은 그림 5와 같다.



[그림 4] BP에서 모멘트에 따른 Epoch 수와 TSS 변화 과정



[그림 5] 제안된 방법에서 모멘트에 따른 Epoch 수와 TSS 변화 과정

제안된 알고리즘에서 은닉층의 노드를 생성 또는 갱신하는데 사용되는 초기 경계 변수를 0.5에서부터 0.9로 설정하여 학습한 결과는 표 2와 같다. 표 2에서 모멘트는 0.95로 설정하였다.

<표 2> 경계 변수에 따른 epoch 수와 생성된 노드수

	경계 변수	Epoch 수	생성된 은닉층의 노드수
제안된 방법	0.5	46	5
	0.6	52	7
	0.7	56	8
	0.75	56	9
	0.8	57	10
	0.85	57	10
	0.9	57	10
	0.95	57	10

표 2와 같이 제안된 방법은 경계 변수의 설정에 따라 은닉층의 노드 수가 달라지나 학습 시간에는 민감하게 반응하지 않는 것을 확인할 수 있다.

실험 결과를 통해 제안된 방법은 기존의 학습 방법 보다 학습 시간이 적게 소요되고 수렴성이 보장됨을 알 수 있다. 그 이유는 winner-take-all 방식의 가중치 조정에 의해 계산량이 감소하였고 그에 의한 정보의 전달 방식으로 유사한 패턴에 의해 가중치가 조정되었기 때문에 조기포화현상인 경쟁 단계가 줄어들기 때문으로 분석된다. 또한 이 이유인해서 제안된 방법이 오류 역전파 알고리즘 보다 전체 현상과 지역 최소화에 빠질 가능성이 줄어들었다.

5. 결론

오류 역전파 알고리즘에서 은닉층의 노드 수를 설정하는 문제를 개선하기 위해 ART1 알고리즘과 Max-Min 신경망을 결합한 자가 생성을 이용한 퍼지 다층 퍼셉트론을 제안하였다. 제안된 학습 구조는 입력층과 은닉층간의 연결 구조로 ART1을 적용하였고 ART1의 출력층을 제안된 구조의 은닉층으로 적용하였다. 따라서 제안된 학습 구조는 완전 연결 구조이나 목표값과 실제 출력값을 비교하여 역전파 시킬때는 대표 클래스와 연결된 가중치만을 역전파하는 winner-take-all 방식을 채택하였다. 그리고 은닉층과 출력층 사이의 학습 구조로 Max-Min 신경망을 적용하였다. 제안된 알고리즘은 가중치 조정에 승자누른 방식을 도입하여 은닉층에 해당하는 클래스에 영향을 끼친 패턴들의 정보만을 저장하게 하여 은닉층 노드수의 책임 분담에 의한 정체 현상이 일어날 가능성을 줄였고, 학습 시간과 학습의 수렴성을 개선하였다. 제안된 방법의 학습 성능을 평가하기 위하여 학생증 영상의 학번 패턴을 분류하는데 적용한 결과, 제안된 방법이 오류 역전파 알고리즘보다 모멘트에 민감하게 반응하지 않았으며 학습 시간도 적게 소요되었고 수렴성도 개선된 것을 확인하였다. 그러나 제안된 알고리즘은 입력 패턴의 크기에는 민감하지 않았으나 경계 변수의 설정에 따라 은닉층의 노드 수가 증가하거나 감소하였다.

향후 연구과제는 경계 변수의 설정에 따라 은닉층의 노드 수가 증가하는 부분을 개선할 것이고

다양한 영상 인식에 적용하여 RBF 네트워크와 성능 평가 할 것이다.

참고 문헌

- [1] A. James and Freeman, Neural Networks : Algorithm, Application and Programming Techniques, Addison-Wesley, 1991.
- [2] R. Hecht-Nielsen, "Theory of Backpropagation Neural Networks," Proceedings of IJCNN, Vol.1, pp.593-605, 1989.
- [3] Y. Hirose, K. Yamashita, S. Hijiya, " Back-Propagation Algorithm Which Varies the Number of Hidden Units", Neural Networks, Vol.4, pp.61-66, 1991.
- [4] K. B. Kim, M. H. Kang and E. Y. Cha, "Fuzzy Competitive Backpropagation using Nervous System ," Proceedings of WCSS, p.188-193, 1997.
- [5] S. N. Kavuri, V. Ventatasubramanian, "Solving the Hidden Node Problem in Neural Networks with Ellipsoidal Units and Related Issues," Proceedings of IJCNN, Vol. 1, pp.775-780, 1992.
- [6] M. Georipoulos, G. L. Heileman and J. Huang, Properties of Learning Related to Pattern Diversity in ART1," Neural Networks, Vol.4, pp.751-757, 1991.
- [7] K. B. Kim and K. C. Kim "A Study on Face Recognition using New Fuzzy ART," Proceedings of ITC-CSCC, Vol.2, pp.1057~1060, 1998.
- [8] 김광백, 전지애, 차의영, "신경 시스템에 의한 오류 역전파 학습의 학습 속도 및 지역 최소화 해결 방안," 인공지능 · 신경망 및 퍼지 시스템 학술발표논문집, pp.592, -601, 1992.
- [9] M. M. Gupta and J. Qi , "On Fuzzy Neuron Models," Proceedings of IJCNN, Vol.2, pp.431-435, 1991.
- [10] T. Saito and M. Mukaidono, " A Learning algorithm for Max-Min Network and its Application to Solve Relation Equations, "Proceedings of IFSA, pp.184-187, 1991.
- [11] Y. Hayashi, E. Czogala and J. J. Buckley, " Fuzzy Neural Controller," Proceedings of IEEE Fuzzy Systems, pp.197-202, Vol.1, 1992.
- [12] 김태경, 윤형근, 노영욱, 김광백, "영상 인식을 이용한 웹 환경에서의 학사 관리 시스템," 한국 지능 정보시스템학회 춘계학술대회 논문집, pp. 203-209, 2002.