

ART1과 Delta-Bar-Delta 방법을 이용한 개선된 자가 생성 지도 학습 알고리즘

Enhanced Self-Generation Supervised Learning Algorithm Using ART1 and Delta-Bar-Delta Method

백인호*, 김태경*, 김광백**

In-Ho Paek*, Tae-Kyoung Kim*, Kwang-Baek Kim**

*Dept. of Computer and Information Engineering, Silla University

**Dept. of Computer Engineering, Silla University

E-mail : paekho@hanmail.net, gbkim@silla.ac.kr

요 약

오류 역전과 학습 알고리즘을 이용하여 영상 인식에 적용 할 경우에는 은닉층의 노드 수를 경험적으로 설정하므로, 학습시간과 지역최소화 및 정체현상이 발생한다. 그리고 ART1 알고리즘은 입력 패턴과 저장 패턴간의 측정 방법인 유사성 검증 방법과 경계 변수의 설정에 따라 인식률이 좌우된다. 경계 변수의 값이 크면 입력 패턴과 저장 패턴 사이에 약간의 차이만 있어도 새로운 카테고리(Category)로 분류하고, 반대로 경계 변수의 값이 적으면 입력 패턴과 저장 패턴 사이에 많은 차이가 있더라도 유사성이 인정되어 입력 패턴들을 대략적으로 분류한다. 따라서 ART1 알고리즘을 영상 인식에 적용하기 위해서는 경계 변수를 경험적으로 설정하므로 인식률에 부정적인 영향을 갖는 문제점이 있다. 따라서 본 논문에서는 개선된 ART1 알고리즘과 지도 학습 방법을 결합하여 신경망의 은닉층 노드를 동적으로 변화시키는 자가 생성 지도 학습 알고리즘을 제안한다. 제안된 신경망에서 입력층과 은닉층의 학습 구조에는 ART1 알고리즘을 개선하여 적용하고, 은닉층과 출력층의 학습 구조에는 은닉층에서 승자로 선택된 노드와 출력층 노드와 연결된 가중치만을 조정하고 Delta-Bar-Delta 알고리즘을 적용한다. 제안된 방법의 학습 성능을 분석하기 위하여 학생증 영상에서 추출한 학번 패턴 분류에 적용한 결과, 기존의 신경망 학습 알고리즘보다 학습 성능이 개선됨을 확인하였다.

1. 서론

다층 신경회로망에서 일반적으로 사용하는 학습 알고리즘인 오류 역전파(error backpropagation) 알고리즘은 인공신경망의 지도 학습(supervised learning) 모델중의 하나이며 단층 퍼셉트론으로 해결하지 못했던 비선형 문제를 해결하기 위해 제시 되었던 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 역전과 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 영상 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 Capenter에 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 신경

* 신라대학교 컴퓨터정보공학과

** 신라대학교 컴퓨터공학과

망의 학습 모델이다[6]. 또한 저속 및 고속 학습이 가능한 장점을 가지고 있고, 지역 최소화(local minima) 문제가 발생하지 않는다. ART 학습 모델 중에서 ART1 알고리즘은 자동 학습 시스템(autonomous learning system) 구축에 널리 사용되고 있다. ART1 알고리즘에서 경계 변수보다 유사도가 작은 경우에 클러스터의 개수는 시간에 따라 점점 증가하게 되어 유사한 패턴이 다른 클러스터로 생성될 수 있고 경계 변수보다 유사도가 큰 경우에는 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 인식이 낮아지는 문제점이 있다.

본 논문에서는 오류 역전과 알고리즘에서 은닉층의 노드 수를 설정하는 문제와 ART1의 경계 변수의 설정에 따른 인식이 저하되는 문제점을 개선하기 위해 ART1 알고리즘과 delta-bar-delta 지도 학습 알고리즘을 결합한 ART1 기반 개선된 자가 생성 지도 학습 알고리즘을 제안한다.

2. 관련 연구

2.1 오류 역전과 알고리즘

오류 역전과 알고리즘은 지도 학습 규칙으로서 주어진 입력에 대해 목표값과 실제 출력값 사이의 오류 값에 따라 정의되는 비용 함수(cost function)를 최소화하기 위하여 경사 추적(gradient descent)법을 사용한다. 이로 인해 오류 역전과 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 큼에도 불구하고 학습이 진행되지 않는 현상으로 조기포화(premature saturation)현상에 해당된다[8]. 기존의 은닉층의 노드 수를 동적으로 조정하는 방법은 학습 과정 중에 지역 최소화에 빠졌을 때 은닉층에 하나의 새로운 노드를 첨가하였다. 여기서 총 오차 자승합의 변화량에 의해 지역 최소화를 판정하였다. 즉 일정한 epoch 수 마다 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 epoch 수 마다 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 역전과 학습 알고리즘에서 은닉층의 노드 수 문제를 해결하기 위한 방법으로 은닉층의 노드를 자가 생성하게 하는 방법에 착안하게 되었

고, 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 역전과 알고리즘에서 학습속도를 느리게 하는 정체 현상을 개선시킨다.

2.2 delta-bar-delta 알고리즘

오류 역전과 알고리즘의 성능 개선을 위한 방법 중에는 Jacobs 등에 의해 제안된 delta-bar-delta 알고리즘이 있다[9]. 다층 신경회로망이 입력층 i , 은닉층 j , 출력층 k 로 구성될 때, delta-bar-delta 알고리즘의 식(1)과 같이 연결강도의 변화를 갖는다.

$$w_{kj}(t+1) = w_{kj}(t) - \alpha_{kj}(t+1) \frac{\partial E}{\partial w_{kj}} \\ = w_{kj}(t) + \alpha_{kj}(t+1) \delta_k z_j \quad (1)$$

식(1)에서 α_{kj} 는 학습률, δ_k 는 출력층 오차이며, z_j 는 은닉층 뉴런의 출력이다. 각 출력층 뉴런에서 delta는 식(2)와 같으며, 각 은닉층 뉴런에서 delta는 식(3)과 같다.

$$\Delta_{kj} = \frac{\partial E}{\partial w_{kj}} = -\delta_k z_j \quad (2)$$

$$\Delta_{ji} = \frac{\partial E}{\partial w_{ji}} = -\delta_j x_i \quad (3)$$

delta-bar-delta 규칙은 각 출력 뉴런에 대하여 현재의 정보를 식(4)와 같이 delta-bar를 형성하기 위하여 파생된 과거의 정보를 조합하여 이용한다.

$$\bar{\Delta}_{kj}(t) = (1-\beta)\Delta_{kj}(t) + \beta\bar{\Delta}_{kj}(t-1) \quad (4)$$

식(4)에서 파라미터 β 의 값은 $0 < \beta < 1$ 사이의 고정된 상수이다. delta와 delta-bar 변화에 대한 학습률의 변화는 다음과 같다. 만약 연결강도의 변화가 연속된 학습과정에서 같은 방향으로 이루어진다면 학습률은 증가한다. 이것은 $\bar{\Delta}_{kj}(t-1)$ 과 $\Delta_{kj}(t)$ 가 같은 부호에서 발생하며, 이 때 학습률은 증가해야 한다. 만약 $\bar{\Delta}_{kj}(t-1)$ 과 $\Delta_{kj}(t)$ 의 부호가 반대 부호를 가지면 학습률은 현재값의 $(1-\gamma)$ 의 비율로 감소한다. 이러한 가변 학습률은 각 층에 대하여 다음과 같은 식으로 표현할 수 있다[9].

$$\alpha_{kj}(t+1) = \alpha_{kj}(t) + k \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) > 0 \\ = (1-\gamma)\alpha_{kj}(t) \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) < 0 \\ = \alpha_{kj}(t) \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) = 0 \quad (5)$$

$$\alpha_{ji}(t+1) = \alpha_{ji}(t) + k \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) > 0 \\ = (1-\gamma)\alpha_{ji}(t) \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) < 0 \\ = \alpha_{ji}(t) \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) = 0 \quad (6)$$

3. 개선된 자가 생성 지도 학습 알고리즘

기존의 ART1에서 유사성 검증은 입력 패턴에 대한 저장 패턴과 입력 패턴의 곱의 놈(norm)비율로서 구해지고, 식 (7)과 같다.

$$\frac{\|T \cdot X\|}{\|X\|} \quad (7)$$

여기서 T는 저장 패턴이고, X는 입력 패턴이다. 이 유사성 검증에서 계산된 값이 경계 변수보다 크거나 같으면 그 유사성이 인정된다. 그러나 기존의 방식은 이진 입력일 경우 1의 개수 비율과 같으므로, 패턴의 1의 값만 유사성 비교에 영향을 미치고 0의 값은 전혀 영향을 미치지 못한다. 따라서 실제 가지적으로 분명하게 분리 인식되는 패턴들에 대해서 명확히 분류해 주지 못하고 같은 패턴으로 인식하게 되는 문제가 발생하고 학습 패턴의 순서에 따라 학습의 성능이 좌우된다. 따라서 1의 개수 비율에 의한 유사성 구분을 하지 않고, 같은 값을 가진 노드의 수를 기준으로 사용하여 유사도를 검증하는 개선된 ART1 제안하여 입력층과 은닉층 사이의 학습 구조로 적용한다. 즉 논리 연산 형식적으로 생각할 때, 입력 패턴에 대한 저장 패턴과 입력 패턴간의 Exclusive NOR의 놈(norm) 비율을 사용하고 식(8)과 같다.

$$\frac{\|T \oplus X\|}{M} \quad (8)$$

식(8)에서 M은 입력 노드의 수이다.

따라서 제안된 자가 생성 지도 학습 알고리즘에서 입력층과 은닉층 간의 학습 구조에는 개선된 ART1을 적용하고, 은닉층과 출력층의 연결 가중치 조정에는 delta-bar-delta 알고리즘을 적용한다. ART1의 출력층이 제안된 구조의 은닉층이다. 은닉층의 노드는 각 클래스를 나타낸다. 따라서 전체적으로는 완전 연결 구조이나 출력층에서 목표 벡터와 실제 출력 벡터를 비교하여 역전파 시킬때는 대표 클래스와 연결된 가중치만을 역전파하는 승자 뉴런 방식(winner-take-all method)을 채택한다. 출력층에서 은닉층으로의 연결 가중치 조정에는 delta-bar-delta 알고리즘을 적용한다. 제안된 자가 생성 지도 학습 알고리즘을 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 간의 유사도를 계산한다.

$$\frac{\|T \odot X\|}{M}$$

단계 6 : 만약 계산된 유사도가 $\frac{\|T \odot X\|}{M} \geq \rho$ 이면

현재의 승자 노드를 대표 클래스로 선택하고 단계 8로, 그렇지 않으면 단계 7로 간다. 여기서, ρ 는 경계변수로서 0.5와 1사이의 값이다.

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

$$NET = \sum_{k=0}^4 w_{kj} \times o_j^* + \theta_k$$

$$o_k = \frac{1}{1 + e^{-NET}}$$

단계 10 : 연결 가중치(w_{kj}), 바이어스항(θ_k)과 학습률(α_{kj})을 조정한다. 여기서 δ_k 는 출력층의 오차이며 o_j^* 는 은닉층의 승자 노드이다.

$$w_{kj}(t+1) = w_{kj}(t) + \alpha_{kj}(t+1) \delta_k o_j^*$$

$$\bar{\Delta}_{kj}(t) = (1 - \beta) \Delta_{kj}(t) + \beta \bar{\Delta}_{kj}(t-1)$$

$$\text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) > 0$$

$$\alpha_{kj}(t+1) = \alpha_{kj}(t) + k,$$

$$\text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) < 0$$

$$\alpha_{kj}(t+1) = (1 - r) \alpha_{kj}(t),$$

$$\text{if } \bar{\Delta}_{k_j^*}(t-1) \cdot \Delta_{k_j^*}(t) = 0$$

$$\alpha_{k_j^*}(t+1) = \alpha_{k_j^*}(t)$$

단계 11 : 총오차 자승합(TSS)이 오류 한계(ϵ) 보다 크면 단계 3으로 가고 오류 한계 보다 작거나 같으면 학습을 종료한다.

3. 실험 및 성능 분석

본 논문에서 제안된 방법의 성능을 평가하기 위하여 Intel Pentium-1.0GHz 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 50개의 학번 패턴을 대상으로 ART1 기반 자가 생성 지도 학습 알고리즘, SGSL with Momentum, 그리고 개선된 자가 생성 지도 학습 알고리즘간의 학습 반복 횟수와 수렴성을 비교 및 분석하였다. 그림 1은 개별 학번 문자 추출에 사용된 학생증 영상이다.



[그림 1] 개별 학번 문자 추출에 사용된 학생증 영상

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 2와 같은 50개의 학번 패턴을 학습 데이터로 사용하였다.

```

0001111000 0000011100 0001111100 0001111100 0000111100
0011001100 0001111100 0111001110 0110000110 0001101100
0110000110 0111111100 1100000011 1100000011 0011001100
1100000011 0000011100 0000000011 0000000011 0110001100
1100000011 0000011100 0000001110 0000111111 1100001100
1100000011 0000011100 0000011100 0000001111 1111111111
1100000011 0000011100 0001100000 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
0000001111 1000000011 0000110000 1100000011 0000001110
0000001111 1100000110 0001100000 1000000001 0000011100
0000011100 0110001100 0111000000 1100000110 0001110000
1111110000 0011111000 1110000000 0011111000 0111000000
    
```

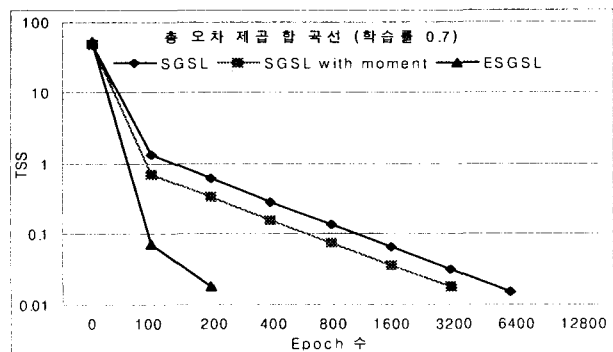
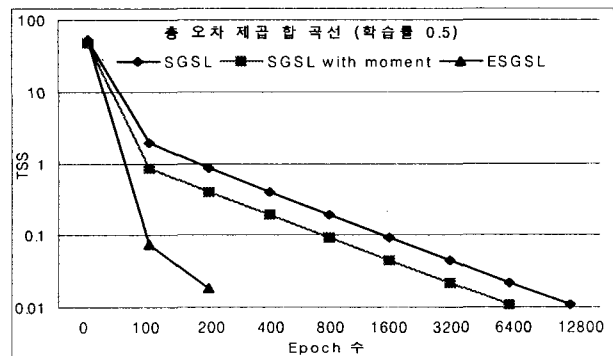
[그림 2] 학번 학습 데이터


그림 2와 같은 50개의 학번 패턴을 자가 생성 지도 학습 알고리즘에 적용하여 초기 학습률에 따른 epoch 수와 TSS를 표 1로 나타내었다.

<표 1> 학습률에 따른 epoch수와 TSS

| | 초기학습률 | Epoch 수 | TSS |
|--------------------|-------|---------|--------|
| SGSL method | 0.3 | 23103 | 0.0100 |
| | 0.5 | 13860 | 0.0100 |
| | 0.7 | 9900 | 0.0099 |
| | 0.9 | 7699 | 0.0099 |
| SGSL with Momentum | 0.3 | 8613 | 0.0099 |
| | 0.5 | 6897 | 0.0100 |
| | 0.7 | 5752 | 0.0099 |
| | 0.9 | 4932 | 0.0099 |
| ESGSL method | 0.3 | 271 | 0.0099 |
| | 0.5 | 269 | 0.0099 |
| | 0.7 | 268 | 0.0099 |
| | 0.9 | 267 | 0.0099 |

표 1에서 SGSL 방법은 ART1 알고리즘 만을 적용한 자가 생성 지도 학습 알고리즘이고 SGSL with Momentum은 자가 생성 지도 학습 알고리즘에 모멘텀 항이 추가된 자가 생성 지도 학습 알고리즘이다. 그리고 ESGSL(Enhanced Self-Generation Supervised Learning) 방법은 ART1과 delta-bar-delta 알고리즘을 이용하여 개선된 자가 생성 지도 학습 알고리즘이다. 표 1의 결과는 오류 한계를 0.01로 설정하여 학습한 결과이다. SGSL 방법과 SGSL with Momentum은 초기 학습률 설정에 따라 학습 반복 횟수에 민감하게 반응하였으나 ESGSL 방법은 학습 반복 횟수에 민감하게 반응하지 않았다. ESGSL 방법에서 경계 변수를 0.9로 설정했을 때 학습 후의 은닉층 노드 수는 33개가 생성되었다. 표 1에서 알 수 있듯이 50개의 학습 패턴들에 대해서 ESGSL 방법이 SGSL 방법과 SGSL with Momentum보다 학습 성능이 개선되었다. SGSL 방법 및 SGSL with Momentum과 ESGSL 방법간의 초기 학습률 설정에 따른 epoch 수와 TSS의 변화 과정을 그림 3로 나타내었다.





[그림 3] 초기 학습률에 따른 epoch 수와 TSS 변화 과정

그림 3에서와 같이 우수한 학습 성능을 보인 ESGSL 알고리즘에서 은닉층의 노드를 생성 또는 갱신하는데 사용되는 초기 경계 변수를 0.8에서 1.0로 설정하여 학습한 결과는 표 2와 같다. 표 2에서 모멘트는 0.5로 설정하였다.

<표2> 경계 변수에 따른 epoch 수와 생성된 노드수

| 50개 패턴 | 경계변수 | Epoch 수 | 생성된 은닉층의 노드수 |
|--------------|------|---------|--------------|
| ESGSL method | 0.8 | 125 | 13 |
| | 0.85 | 162 | 17 |
| | 0.9 | 193 | 22 |
| | 0.95 | 269 | 33 |
| | 1.0 | 367 | 50 |

표 2에서 ESGSL 방법은 경계 변수의 설정에 따라 은닉층의 노드 수는 달라지나 학습 성능에는 민감하게 반응하지 않는 것을 확인할 수 있다.

4. 결론 및 향후과제

오류 역전파 알고리즘에서 은닉층의 노드 수를 설정하는 문제를 개선하기 위해 개선된 ART1 알고리즘과 delta-bar-delta 알고리즘을 결합한 개선된 자가 생성 지도 학습 알고리즘을 제안하였다. 제안된 학습 구조는 입력층과 은닉층간의 학습 구조로는 ART1을 개선하여 적용하였고 개선된 ART1의 출력층을 제안된 구조의 은닉층으로 적용하였다. 따라서 제안된 학습 구조는 완전 연결 구조이나 목표값과 실제 출력값을 비교하여 역전파시킬때는 대표 클래스와 연결된 가중치만을 역전파하는 winner-take-all 방식을 채택하였다. 그리고 은닉층과 출력층의 연결 가중치 조정에 delta-bar-delta 알고리즘을 적용하였다. 제안된 알고리즘은 가중치 조정에 승자 뉴런 방식을 도입하여 은닉층에 해당하는 클래스에 영향을 끼친 패턴들의 정보만을 저장하게 하여 은닉층 노드로의 책임 분담에 의한 정체 현상이 일어날 가능성을 줄였고, 학습 시간과 학습의 수렴성을 개선하였다. 제안된 자가 생성 지도 학습 알고리즘의 학습 성능을 평가하기 위하여 학생증 영상에서 추출한 학번 패턴을 분류하는데 적용한 결

과, 개선된ART1과 delta-bar-delta 알고리즘을 이용한 자가 생성 지도 학습 방법이 다른 자가 생성 지도 학습 알고리즘 보다 학습 시간이 적게 소요되고 수렴성이 개선된 것을 확인하였다. 그러나 제안된 자가 생성 지도 학습 알고리즘은 입력 패턴의 크기에는 민감하지 않았으나 경계 변수의 설정에 따라 은닉층의 노드 수가 증가하거나 감소하였다.

향후 연구 과제는 패턴의 수에 민감하지 않게 은닉층의 노드를 생성하는 방법에 대해 연구할 것이고 제안된 자가 생성 지도 학습 알고리즘을 다양한 영상 인식에 적용하여 RBF 네트워크와 비교 분석하여 학습 및 인식의 성능을 평가 할 것이다.

6. 참고문헌

- [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. Cga, "A Fuzzy Competitive Backpropagation using Nervous System," *Proceedings of WCSS*, pp.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] R. A. Jacobs, "Increased rates of convergence through learning rate adaptation," *IEEE Transactions on Neural Networks*, Vol. 1, No. 4, pp. 295-308, 1988.