

영상 인식을 위한 개선된 자가 생성 지도 학습 알고리즘에 관한 연구

준회원 김태경*, 정회원 김광백**, 정회원 백준기***

A Study on Enhanced Self-Generation Supervised Learning Algorithm for Image Recognition

Tae-kyung Kim* Associate Member, Kwang-baek Kim** Regular Members, Joon-ki Paik*** Regular Members

요약

오류 역전과 알고리즘의 문제점과 ART 신경회로망의 문제점을 개선하기 위해 Jacobs가 제안한 delta-bar-delta 방법과 신경회로망을 결합한 자가 생성 지도 학습 알고리즘을 제안한다. 입력층과 은닉층에서는 ART-1과 ART-2 알고리즘을 이용하고, winner-take-all 방식은 완전 연결 구조이나 연결된 가중치만을 조정하도록 채택하였다. 실험을 위해 학생증, 주민등록증, 컨테이너의 영상으로 추출한 패턴을 신경회로망의 은닉층 노드에 대해 실험하였고, 실험결과 제안된 자가 생성 지도 학습알고리즘이 지역최소화, 학습 속도, 정체 현상이 기존의 방법보다 성능이 개선된 것을 확인하였다.

Key Words : Delta-bar-delta, ART-1, ART-2, Self-generation Supervised Learning Algorithm

ABSTRACT

we propose an enhanced self-generation supervised algorithm that by combining an ART algorithm and the delta-bar-delta method. Form the input layer to the hidden layer, ART-1 and ART-2 are used to produce nodes, respectively. A winner-take-all method is adopted to the connection weight adaption so that a stored pattern for some pattern is updated.

we test the recognition of student identification, a certificate of residence, and an identifier from container that require nodes of hidden layers in neural network. In simulation results, the proposed self-generation supervised learning algorithm reduces the possibility of local minima and improves learning speed and paralysis than conventional neural networks.

1. 서론

현재의 인공지능은 사람의 지능과 비교해서 많은 차이가 있고 제한된 분야에서만 사람의 지능을 모

방하고 있다. 이러한 제한된 문제를 극복하기 위해 인간의 뇌를 모방하는 접근 방법이 인공지능 분야의 주요 연구 분야로 관심의 대상이 되고 있다. 인간의 뇌를 모방하는 접근 방법에는 두가지 방법이

* 중앙대학교 첨단영상대학원 영상공학과 시각및지능시스템연구실(kimktk@wm.cau.ac.kr)

** 신라대학교 공과대학 컴퓨터공학과(gbkim@silla.ac.kr)

*** 중앙대학교 첨단영상대학원 영상공학과 시각및지능시스템연구실(paikj@cau.ac.kr)

논문번호 : KICS2004-07-103, 접수일자 : 2004년 7월 21일

※ 본 연구는 과학기술부 국가지정연구실 사업과 교육 BK21 사업, 대학IT 연구센터 육성/지원 사업(ITRC)으로 수행되었음.

있다. 인간의 뇌에 들어 있는 지식을 뇌의 기능에 의거하여 프로그래밍 하려는 기호처리 인공지능과, 뇌를 분석함으로써 얻은 뇌의 구조를 이용하여 지능을 구현하려는 인공지능으로 나눌 수 있다. 이들 방법들 중에 기호 처리 인공지능은 기능적 수준에서의 접근 방법인데, 이 접근 방법을 퍼지 논리(Fuzzy Logic)라고 한다. 그리고 생리학적 수준에서의 접근 방법을 인공 신경망(Artificial Neural Network)이라고 한다.

주어진 입력에 대하여 해당하는 출력을 내는 과정을 연산이라고 할 때 기존의 연산은 순차적인 절차에 의한 알고리즘에 근거하여 문제를 해결하는 방법인 반면, 인공 신경망은 인간의 뇌 신경 조직을 모델로 하여 처리기들의 상호 연결에 의한 학습을 통하여 문제를 해결하고자 하는 방법이다. 그러므로 인공 신경망은 생리학적 신경세포의 구조와 기능을 매우 간단하게 모형화한 처리 요소(processing element)들이 학습을 통하여 문제를 해결하고자 하는 분야로 정의된다.

인공 신경망은 입력 공간과 출력 공간 사이의 맵핑(mapping)의 특성에 따라 연산 기억, 필터, 변환, 분류, 인식 및 최적화 등의 다양한 기능 체계를 구성 할 수 있으며 시각 처리, 음성 인식, 의료 진단, 패턴 분류 및 인식, 로봇제어 등 기존의 인공지능 분야에서 비교적 해결하기 힘든 잡음이나 변형된 정보의 처리에 매우 유용하게 사용된다.

신경회로망(Neural Networks)은 신경세포의 네트워크로서 신경 세포들 간에는 연결강도(weight)에 의해 연결 되어있다. 신경 세포의 각 층들 간에는 병렬로 연결되어 있어 병렬처리가 가능하여 수치 계산 능력이 뛰어나고 많은 신경세포들로 이루어져 있어서 잡음에 강건하다. 신경회로망은 학습 결과를 연결강도에 저장하며 추론 할 수 있는 능력이 있다. 이러한 학습 및 추론 능력은 기존의 방법에 비해 신경회로망의 성능을 우수하게 하는 요인이다. 신경회로망은 상호 연결된 신경(neuron)에 의해 임의의 N차원 입력공간을 M차원 출력 공간으로 사상하는 것으로 생각 할 수 있으며, 입력 및 출력 공간과 사상 특성에 따라 연상기억(associative memory), 분류(classification), 패턴인식 및 영상처리 분야 등에 응용 될 수 있다^[1,2].

다층 신경회로망에서 일반적으로 사용하는 학습 알고리즘인 오류 역전파(Error Backpropagation) 알고리즘은 신경회로망의 지도학습(supervised learning) 모델중의 하나이며, 단층 퍼셉트론으로 해결하

지 못했던 비선형 문제를 해결하기 위해 제시되었던 다층 구조 신경망(multilayer neural network)의 대표적인 학습 알고리즘이다^[3]. 오류 역전파 알고리즘에서 은닉층(hidden layer)의 노드수가 필요 이상으로 많으면 판별 성능에 영향을 거의 미치지 않는 부가적인 노드가 존재하여 학습 시간이 많이 소요 되고 은닉층의 노드 수가 적으면 연결 가중치들이 지역 최소화에 위치할 가능성이 높아진다^[4]. 그리고 간단한 선형 분리 문제나 Exclusive OR 문제는 필요한 은닉층의 노드 수를 알기 쉽지만 영상 인식등과 같은 복잡한 문제의 경우에는 적당한 은닉층의 노드 수를 찾아내기가 어렵다. 일반적인 경우 은닉층의 노드 수는 대부분 경험적(heuristic) 방법을 사용하여 반복 계산으로 근사해를 구하고 있다.

Carpenter와 Grossberg가 개발한 적응공진이론(Adaptive Resonance Theory; ART) 신경회로망은 자율적으로 패턴들을 분류하는 네트워크 구조로서, 임의의 패턴을 학습 할 수 있는 안정성과 적응성을 갖는 신경망의 학습 모델이다^[5]. 또한 저속 및 고속 학습이 가능한 장점을 가지고 있고, 지역 최소화(local minima)문제가 발생하지 않는다. ART 학습 모델 중에서 ART-1 알고리즘은 자동 조정 학습 시스템(autonomous learning system) 구축에 널리 사용되고 있다. ART-1 알고리즘에서 유사도가 경계 변수보다 작은 경우에 클러스터 개수는 시간에 따라 점점 증가하게 되어 유사한 패턴이 다른 클러스터로 생성 될 수 있다^[6]. 따라서, ART-1 알고리즘을 패턴 인식에 적용할 경우, 입력 벡터와 클러스터의 대표 벡터간의 유사성 측정 방법과 경계 변수에 따라 인식이 낮아지는 문제점이 있다. 또한, ART 신경회로망은 안정성과 적응성 대해 딜레마를 해결하는데^[7] 중점을 두어 개발되었으나 고속 학습을 사용함으로써 2진수만을 취급하고 잡음에 약한 단점이 있다^[8].

본 논문에서는 오류 역전파 알고리즘의 문제점과 ART 신경회로망의 문제점을 개선하기 위해 Jacobs^[9]가 제안한 delta-bar-delta 방법과 신경회로망을 결합한 자가 생성 지도 학습 알고리즘을 제안하고, 학습 성능을 분석하기 위해 학생증 영상, 주민등록증 영상, 컨테이너 영상에서 추출한 문자와 숫자 패턴을 적용하여 학습 성능을 분석한다.

II. Delta-Bar-Delta 알고리즘

다층 신경회로망의 학습 알고리즘으로는 오류 역

전과 알고리즘이 주로 사용되고 있으며, 오류 역전파 알고리즘의 성능 개선을 위한 방식 중에 Jacobs 등에 의해 제안된 delta-bar-delta 알고리즘이 있다⁹⁾. 다층 신경회로망이 입력층 i , 은닉층 j , 출력층 k 로 구성될 때, delta-bar-delta 알고리즘은 아래의 식(1)과 같은 연결강도(weight)의 변화를 갖는다¹⁰⁾.

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

$$= W_{kj}(t) \alpha_{kj}(t+1) \delta_k Z_j,$$

여기서, 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 뉴런에서는 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 식(4)와 같이 delta-bar를 형성하기 위하여 파생된 과거의 정보와 현재의 정보를 조합하여 이용된다.

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

여기서, 파라미터의 값은 $0 < \beta < 1$ 사이의 고정된 상수이다. delta와 delta-bar 변화에 대한 학습의 변화는 다음과 같다. 만약 연결강도의 변화가 연속된 학습 과정에서 같은 방향으로 이루어진다면 학습률은 증가하여야 한다.

이것은 $\bar{\Delta}_{kj}(t-1)$ 과 $\Delta_{kj}(t)$ 가 같은 부호에서 발생하며, 이때 학습률은 증가하여야 한다. 만약

$\bar{\Delta}_{kj}(t-1)$ 과 $\Delta_{kj}(t)$ 의 부호가 반대 부호를 가지면 학습률은 현재 값의 $(1-\gamma)$ 의 비율로 감소한다. 이러한 가변 학습률은 각 층에 대하여 아래의 식으로 표현할 수 있다⁹⁾.

$$\alpha_{kj}(t+1) = \alpha_{kj}(t) + K, \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) > 0$$

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

$$= \alpha_{kj}(t), \quad \text{if } \bar{\Delta}_{kj}(t-1) \cdot \Delta_{kj}(t) = 0 \quad (5)$$

$$\alpha_{ji}(t+1) = \alpha_{ji}(t) + K, \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) > 0$$

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

$$= \alpha_{ji}(t), \quad \text{if } \bar{\Delta}_{ji}(t-1) \cdot \Delta_{ji}(t) = 0 \quad (6)$$

여기서, 파라미터 K 와 γ 는 미리 정해진 상수이다. 식(5), (6)와 같이 delta-bar-delta 규칙은 학습률이 초기값에 따라, K , γ 등의 파라미터에 의해 좁은 범위에서 변화되므로, 좀 더 좋은 성능을 가지기 위해서는 초기 학습률에 상관없이 넓은 범위에서 자동으로 조정하는 것이 좋다¹¹⁾.

2.1 가중치 조정

개선된 구조는 가중치 조정을 위해 기존의 오류 역전파와 학습에 승자 뉴런 (winner-take-all) 방식을 채택한다. 입력층과 은닉층간의 연결과 은닉층과 출력층간의 연결로 구분해서 살펴보면, 은닉층에서 채택된 승자 노드는 제시된 패턴의 대표 클래스가 되는 것이다. 따라서 대표 클래스의 저장 패턴에 제시된 패턴을 반영하기 위해서는 은닉층에서 입력층으로의 승자 노드와 연결된 시냅스의 가중치를 조정해준다(그림 1). 또한 제시된 패턴에 대한 목표값을 대표 클래스에 의한 실제 출력값에 반영하기 위해 출력층 노드와 그 대표 클래스와 관련된 연결 가중치만 조정해 주도록 한다(그림 2).




그림 1. 은닉층에서 입력층으로의 연결 가중치 조정




그림 2. 출력층에서 은닉층으로의 연결 가중치 조정

제안된 구조에서 zero 패턴의 경우 전방향 활성화 과정은 그냥 통과하고, 역방향 과정에서 가중치 조정을 모든 은닉층 노드에 대해 영향을 주도록 조

정한다. 이는 오류 역전파 학습 구조에 수정된 ART-1 구조를 적용할 경우 은닉층의 net값이 "0"이 되어 항상 승자 선택에 실패하게 되는 경우를 해결하기 위해서이다. 따라서 본 논문에서는 delta-bar-delta 방법과 ART 기반 자가 생성 지도 학습 알고리즘을 제안한다.

Ⅲ. 제안된 신경망 알고리즘

3.1 delta-bar-delta 방법과 ART-1기반 자가 생성 지도 학습 알고리즘

오류 역전파 학습 알고리즘은 은닉층의 노드 수를 경험적으로 설정해야 하는 문제점이 있다. 이에 본 논문에서는 오류 역전파 알고리즘의 은닉층 노드 수를 동적으로 변화시키기 위하여 delta-bar-delta 방법과 ART-1 알고리즘을 결합한 자가 생성 지도 학습 알고리즘을 제안한다.

제안된 구조를 뒷받침해 주는 생리학적 뉴런 구조는 억제 구조를 기반으로 한다. 억제 구조 중에서 제안된 구조는 자기 자신을 활성화시킨 세포에 되 작용하는 되먹임 억제(feedback inhibition) 구조에 의한 처리에 기반 하여 노드를 생성하고 정보를 저장한다.




그림 3. 제안된 ART-1기반 자가 생성 지도 학습 구조

은닉층의 노드를 자가 생성하도록 제안된 구조는 그림 3과 같고, 제안된 ART-1 자가 생성 지도 학습 구조에 대한 내용을 아래와 같이 요약 할 수 있다.

- ① 입력층과 은닉층의 연결 구조는 수정된 ART-1의 구조와 같고, 수정된 ART-1의 출력층은 제안된 구조의 은닉층이다.
- ② 은닉층의 노드는 각 클래스(class)를 나타낸다.

따라서, 전체적으로 완전연결구조이나 목표값과 실제 출력값을 비교하여 역전파 시킬때는 대표 클래스와 연결된 시냅스의 가중치만 역전파하는 승자 뉴런 방식을 채택한다.

- ③ "0"인 학습 데이터 (모든 입력값이 0인 데이터) 만은 승자 선택 없이 모든 은닉층에 영향을 끼친다.

제안된 ART-1 자가 생성 지도 학습 알고리즘의 수행 단계는 다음과 같다.

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

$$t_{ji}=1, w_{ji} = \frac{1}{m+1}.$$

- Step 2. 입력 벡터 X_i 와 목표 벡터 T_k 를 제시한다.
- Step 3. 은닉층의 출력 벡터 O_j 를 계산한다.

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

- Step 4. 승자 노드 O_{j^*} 를 선택한다.

$$O_{j^*} = \text{Max}[O_j]$$

- Step 5. 승자 노드의 하향 t_{j^*i} 가중치와 입력 패턴 간의 유사도를 계산한다.

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

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

- Step 7. 현재 승자 노드 O_{j^*} 의 출력 벡터를 "0"으로 하고, 새로운 노드를 할당하여 대표 클

래스로 선택한 다음 Step 8.로 간다.

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

$$t_{j \cdot i}(n+1) = t_{j \cdot i}(n) \times x_i$$

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

Step 9. 은닉층의 대표 클래스 O_j^* 와 출력층의 연결 가중치 w_{kj} 그리고 바이어스항 θ_k 를 이용하여 NET를 계산하고, 시그모이드 함수를 이용하여 출력층의 출력 벡터 O_k 를 계산한다.

$$NET = \sum_{j=1}^n w_{kj^*} \times O_{j^*} + \theta_k, \quad O_k = \frac{1}{1 + e^{-net}}$$

Step 10. 연결가중치 w_{kj^*} , 바이어스항 θ_k , 학습률 α_{kj} 를 조정한다. 여기서 δ_k 는 출력층의 오차이며, O_j^* 는 은닉층의 승자 노드이다.

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

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

$$\Delta_{kj} = -\frac{\partial E}{\partial w_{kj}} = -\delta_k z_j$$

$$\Delta_{kj^*}^-(t) = (1 - \beta) \Delta_{kj^*}^-(t) + \beta \Delta_{kj^*}^-(t-1)$$

if $\Delta_{kj^*}^-(t-1) \cdot \Delta_{kj^*}^-(t) > 0$

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

if $\Delta_{kj^*}^-(t-1) \cdot \Delta_{kj^*}^-(t) < 0$

$$\alpha_{kj^*}(t+1) = (1 - \gamma) \alpha_{kj^*}(t),$$

if $\Delta_{kj^*}^-(t-1) \cdot \Delta_{kj^*}^-(t) = 0$

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

Step 11. 총오차 자승합(TSS)이 오류 한계(ϵ)보다 크면 Step 3.으로, 오류 한계 보다 적거나 같으면 학습을 종료한다.

3.2 delta-bar-delta 방법과 ART-2 기반 자가 생성 지도 학습 알고리즘
제안된 ART-2 기반 자가 생성 지도 학습 알고리

즘의 입력층과 은닉층사이의 출력 벡터 계산은 식 (7)이다. 은닉층의 출력 벡터는 입력패턴과 클러스터들과의 오차를 계산한다. 그러므로, 승자 노드의 벡터는 식(8)과 같이 계산되고, 가장 작은 출력 벡터를 승자노드로 설정한다.

$$O_j = \sum_{i=1}^N (\|x_i - w_{ji}(t)\|), \quad (7)$$

$$O_j^* = \text{Min}\{O_j\} \quad (8)$$

Min는 최소값을 계산하는 함수이고, w_{ji} 는 입력층과 은닉층사이의 연결 가중치를 의미한다. 여기서 제안된 ART-2 기반 자가 생성 지도 학습 알고리즘의 연결가중치 w_{ji} 는 하나이지만, 제안된 ART-1 기반 자가 생성 지도 학습 알고리즘의 연결 가중치는 두 종류로, 전방향 연결가중치 w_{ji} 와 역방향 연결가중치 t_{ji} 로 구분된다. ART 알고리즘들의 연결가중치의 개수는 입력 패턴의 유형에 따라 달라진다. 이진 패턴만을 입력받는 ART-1 알고리즘의 경우, "0"과 "1"의 값을 입력받는데, 입력노드벡터가 "0"인 경우는 의미 없는 값을 의미하고, "1"인 경우는 의미를 두어 "1"의 가중치를 부여할 수 있다. 그 가중치를 역방향 가중치라고 표현하는데, "1"이라는 값을 가지는 노드가 입력패턴에 미치는 영향을 표현한다. 그러나 ART-2 알고리즘은 이진 패턴이 아니라 아날로그 값을 받아서 처리하기 때문에 각 노드에 가중치를 부여할 수가 없다. 그러므로 제안된 ART-1 기반 자가 생성 지도 학습 알고리즘은 두 종류의 연결 가중치를 가지고, 제안된 ART-2 기반 자가 생성 지도 학습 알고리즘은 하나의 연결 가중치를 가진다. 제안된 ART-2 기반 자가 생성 지도 학습 알고리즘에서는 입력 벡터와 은닉층의 출력 벡터사이의 차이가 최소인 값을 계산하여 승자노드로 선정한다. 선정된 승자노드에 대한 유사성의 검증은 다음 식(9)와 같다.

$$O_j^* < \rho \quad (9)$$

ρ 는 ART-2 알고리즘의 경계 변수이고, 승자노드의 출력 벡터가 경계 변수보다 작으면 같은 패턴으로 아니면 다른 패턴으로 분류한다. 같은 패턴으로 분류되면, 입력 패턴의 유사한 특징을 연결 강도에 반영하기 위해 연결 강도를 조정하게 된다. ART-2 알고리즘의 연결강도의 조정은 식(10)과 같다.

$$W_{j,i}(t+1) = \frac{W_{j,i}(t) \times cluster_j + X_i}{cluster_{j+1}} \quad (10)$$

여기서, $cluster_j$ 은 생성된 클러스터에 갱신된 패턴들의 개수를 의미한다.

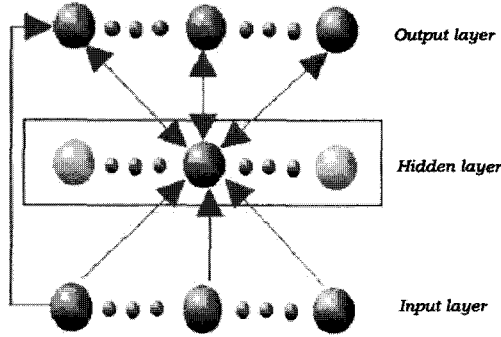


그림 4. 제안된 ART-2 자가 생성 지도 학습 구조

제안된 ART-2 기반 자가 생성 지도 학습은 그림 4와 같은 구조를 가진다. 제안된 ART-2 기반 자가 생성 지도 학습 알고리즘의 수행 단계는 다음과 같다.

Step 1. 은닉층과 출력층 사이의 가중치인 w_{kj} 를 초기화한다.

여기서, j ($j=1, \dots, m$)는 입력층이고, k ($k=1, \dots, n$)는 출력층이다.

Step 2. 입력 벡터 X_i 를 제시한다.

Step 3. 출력층의 출력 벡터 O_j^* 를 계산한다.

$$O_j = \frac{1}{N} \sum_{i=1}^N (||X_i - W_{ji}(t)||)$$

Step 4. 승자 노드 O_j 를 선택한다.

$$O_j^* = \text{Min}\{O_j\}$$

Step 5. 승자 노드가 $O_j^* < \rho$ 이면 현재의 승자 노드를 대표 클래스로 선택하고, Step 7.로, 그렇지 않으면 Step 6.으로 간다.

Step 6. 승자 노드 O_j^* 의 출력 벡터를 "0"으로 하고, 새로운 노드를 할당하여 대표 클래스로 선택하고, Step 7.로 간다.

Step 7. 입력 패턴과 승자 노드간의 유사성이 인정된 Step 6.의 대표 클래스 또는 Step 7.에

서 새로 생성된 대표 클래스의 가중치를 조정한다. 모든 입력 벡터에 대해 반복 수행한다. 여기서, $cluster_j$ 은 생성된 클러스터에 갱신된 패턴들의 개수를 의미한다.

$$W_{j,i}(t+1) = \frac{W_{j,i}(t) \times cluster_j + X_i}{cluster_{j+1}}$$

Step 8. 은닉층의 대표 클래스 O_j^* 와 출력층의 연결 가중치 w_{kj} 그리고 바이어스 항 θ_k 를 이용하여 NET를 계산하고, 시그모이드 함수를 이용하여 출력층의 출력 벡터 O_k 를 계산한다.

$$NET = \sum_{j=1}^n w_{kj} \times O_j^* + \theta_k, \quad O_k = \frac{1}{1 + e^{-net}}$$

Step 9. 연결 가중치 w_{kj} , 바이어스항 θ_k , 학습률 α_{kj} 을 조정한다. 여기서, δ_k 는 출력층의 오차이며, O_j^* 는 은닉층의 승자 노드이다.

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

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

$$\Delta_{kj} = \frac{\partial E}{\partial w_{kj}} = -\delta_k Z_j$$

$$\Delta_{kj}^- = (1 - \beta)\Delta_{kj}(t) + \beta \Delta_{kj}^-(t-1)$$

IV. 실험 및 결과

4.1 실험 환경

본 논문에서는 800×600 픽셀 크기를 가진 학생증 영상, 주민등록증 영상, 컨테이너 영상에서 추출한 문자와 숫자 패턴을 대상으로 실험하였다.

학생증 영상에서 추출한 숫자 패턴 50개, 주민등록증 영상에서 추출한 숫자 패턴 50개, 그리고 컨테이너 영상에서 추출한 영문자 패턴 50개를 각 알고리즘에 적용하여 성능을 비교 분석하였다.

실험 환경은 IBM 호환 기종의 PC 상에서 C++ Builder 6.0으로 구현하였고, 그리고 학생증 영상에서 추출한 숫자 패턴은 그림 5와 같고, 주민등록증 영상에서 추출한 숫자 패턴은 그림 6과 같고, 컨테이너 영상에서 추출한 영문자 패턴은 그림 7과 같다.




그림 5. 학생증 영상에서 추출된 숫자 패턴




그림 6. 주민등록증 영상에서 추출된 숫자 패턴




그림 7. 컨테이너 영상에서 추출된 영문자 패턴

4.2 실험 결과 및 성능 평가

본 논문에서 적용된 알고리즘에 공통으로 적용되는 파라미터들은 다음과 같다.

초기 학습률은 0.3이고, momentum은 0.5, delta-bar-delta 알고리즘에서 파라미터는 B(0.7), K(0.005), R(0.2)으로 설정하고, ART-1 알고리즘에서 경계변수는 0.95, 그리고 ART-2 알고리즘에서 경계변수는 0.1로 설정하였다. 학습수렴판정은 epoch 수를 20000번으로 수행하였고, 총오차제곱 합(TSS)

값은 0.04로 설정하였다.

4.2.1 학생증 영상에 관한 실험 및 분석

학생증 영상에서 추출된 숫자 패턴에 대해서 delta-bar-delta 방법과 모멘텀 방법에서 실험 횟수를 10회 반복 수행하여, 각각 4회 학습에 성공하고, 평균 epoch수는 delta-bar-delta방법이 3952번, 모멘텀 방법에서의 평균 epoch수는 2769번으로 나타났다. 제안된 ART-1 기반 자가 생성 지도 학습 방법과 제안된 ART-2 기반 자가 생성 지도 학습 방법에서는 실험 횟수를 10회 반복하여 10회 모두 성공하였고, 평균 epoch 수도 기존의 방법들보다 적게 나타났다. 따라서, 기존의 방법들보다 제안된 학습 방법이 학습 속도와 수렴성에서 개선된 것을 확인하였다.

표 1. 기존의 방법과 제안된 방법 간의 학습 상태 비교

학습 방법	실험 횟수	성공 횟수	은닉층 노드수	평균반복 횟수 (Epoch)
delta-bar-delta	10	4	10	3952
momentum+BP	10	4	10	2769
ART-1 SGSL	10	10	23	670
ART-2 SGSL	10	10	18	411

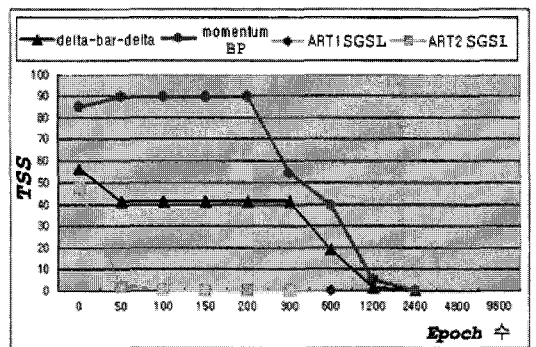


그림 8. 기존의 방법들과 제안된 방법들간의 오차 제곱합 곡선

5.2.2 주민등록증 영상에 관한 실험 및 분석

주민등록증 영상에서 추출된 숫자 패턴에 대해서 10회의 실험을 수행한 결과 delta-bar-delta 방법, 모멘텀 방법에서는 학습이 되지 않았고, 제안된 ART-1과 ART-2 기반 자가 생성 지도 학습 방법에서는 10회 수행하여 학습이 모두 성공하였고, 평균 epoch 수도 679, 651번으로 양호한 결과를 보였다.

표 2. 기존의 방법과 제안된 방법 간의 학습 상태 비교

학습 방법	실험 횟수	성공 횟수	은닉층 노드수	평균반복 횟수 (Epoch)
delta-bar-delta	10	0	10	학습안됨
momentum+BP	10	0	10	학습안됨
ART-1 SGSL	10	10	40	679
ART-2 SGSL	10	10	40	651

표 3. 기존의 방법과 제안된 방법 간의 학습 상태 비교

학습 방법	실험 횟수	성공 횟수	은닉층 노드수	평균반복 횟수 (Epoch)
delta-bar-delta	10	0	10	학습안됨
momentum+BP	10	0	10	학습안됨
ART-1 SGSL	10	10	46	939
ART-2 SGSL	10	10	46	840





그림 9. 기존의 방법들과 제안된 방법들간의 오차 제곱합 곡선

그림 10. 기존의 방법들과 제안된 방법들간의 오차 제곱합 곡선

5.2.3 컨테이너 영상에 관한 실험 및 분석

컨테이너 영상에서 추출된 영문자 패턴에 대해서 10회의 실험을 수행한 결과 delta-bar-delta 방법, 모멘텀 방법은 10회 모두 학습에 성공하지 못하였지만, 제안된 ART-1과 ART-2 기반 자가 생성 지도 학습 방법은 10회 모두 학습에 성공하였으며, 평균 epoch 수도 각각 939, 840번으로 기존의 방법들보다 수렴성과 학습속도에서 개선된 것을 확인하였다.

제안된 ART 기반 자가 생성 지도 학습 알고리즘의 경계변수와 epoch 수, 그리고 생성된 은닉층 노드 수에 대한 결과는 표 4와 같고, ART-1 기반 자가 생성 지도 학습 방법보다 ART-2 기반 자가 생성 지도 학습 방법이 학습의 성능이 우수한 것을 알 수 있다. ART-1 기반 자가 생성 지도 학습 구조에서는 승자 뉴런을 Max 연산에 의해서 채택하고, ART-2 기반 자가 생성 지도 학습 구조에서는 승자 뉴런 선택의 경우는 Min 연산을 사용하는 방법을 채택한다. 또한 ART-1 기반 자가 생성 학습 구조는 이진 패턴만 사용되지만, ART-2 기반 자가 생성 지도 학습 구조에서는 이진 패턴 뿐만 아니라, 연속적인 아날로그 값을 가질 수 있기 때문에 ART-1 기반 자가 생성 지도 학습 방법보다 ART-2 기반 자가 생성 지도 학습 방법에서 경계변수에 따라 학습 성능에 영향을 주는 주요한 요인으로 작용되었다.

표 4. 제안된 방법에서 경계변수 설정에 따른 학습 결과(컨테이너 영문자 패턴으로 적용)

학습 방법	경계변수 설정	평균반복 횟수 (Epoch)	성공된 은닉층 노드 수
ART-1 SGSL	0.85	학습안됨	34
	0.9	학습안됨	37
	0.95	939	46
	1.0	998	50
ART-2 SGSL	0.15	학습안됨	33
	0.1	840	40
	0.05	870	48
	0	1000	50

제안된 ART 기반 자가 생성 지도 학습 알고리즘에서는 경계변수가 낮으면 다른 패턴도 같은 패턴으로 분류하는 문제가 발생하여 학습이 되지 않은 경우도 있었고, 경계변수가 높으면 은닉층 노드 수가 많이 생겨서 같은 패턴도 다른 패턴으로 분류하는 문제가 발생하였다. 이에 따라 학습 속도도 느려지는 결과를 보였다. 제안된 학습 방법에서 생성된 은닉층 노드 수를 기존의 방법에 적용하여 학습 성능을 분석한 결과를 표 6에 나타내었다. 표 6은 기존의 방법에서 은닉층의 노드 수에 따라서 학습이

한번도 성공하지 못하였으며, 평균 반복 횟수도 초기의 20000번으로 설정된 값보다 좋은 않은 학습 판정을 확인 할 수 있었다.

표 5. 제안된 방법에서 생성된 은닉층 노드 수를 기존의 방법의 은닉층으로 적용한 학습 결과

학습 방법	실린 횟수	성공 횟수	은닉층 노드수	평균 반복 횟수 (Epoch)
ART-1	10	0	46	30000
SGSL	10	0	46	40000
ART-2	10	0	40	30000
SGSL	10	0	40	40000

V. 결론

오류 역전과 알고리즘에서 은닉층의 노드 수를 설정하는 문제를 개선하기 위해 delta-bar-delta 방법과 ART 신경회로망에서의 ART-1, ART-2 알고리즘을 결합한 자가 생성 지도 학습 알고리즘을 제안하였다.

delta-bar-delta 방법과 ART 기반 자가 생성 지도 학습 알고리즘에서 입력층과 은닉층간의 연결 구조는 ART-1, ART-2 알고리즘을 각각 적용하였고, 자가 생성 지도 학습 알고리즘의 은닉층과 출력층간에는 delta-bar-delta 방법을 적용하였다.

따라서, 제안된 학습 구조는 완전 연결 구조이나 목표값과 실제 출력값을 비교하여 역전과 시킬 때 대표 클래스와 연결된 가중치만을 조정하는 winner-take-all 방식을 채택하였다.

채택된 승자 뉴런 방식은 대표 클래스에 영향을 끼친 패턴들의 정보만을 저장하게 하여 은닉층 노드들의 책임 분담에 의한 정체 현상이 일어날 가능성을 줄였고, 학습 시간과 학습의 수렴성을 개선하였다.

본 논문에서 제안한 방법들의 학습 성능을 평가하기 위하여 학생중, 주민등록중, 컨테이너 영상으로부터 추출한 영문자와 숫자 패턴을 적용한 결과, 기존의 delta-bar-delta 방법과 모멘텀 방법이 제안된 ART 기반 자가 생성 지도 학습 방법보다 좋지 않은 결과를 알 수 있었고, 제안된 ART 기반 자가 생성 지도 학습 방법에서 생성된 은닉층 노드 수를

기존의 방법에 적용한 결과 기존의 방법에서는 학습이 되지 않은 결과를 알 수 있었다.

따라서, delta-bar-delta 방법과 ART 기반 자가 생성 지도 학습 알고리즘이 학습시간과 수렴성에 대해서 민감하게 반응하지 않았고, 총오차제곱합도 기존의 학습 방법에 비해 현저히 감소하여 학습 성능이 개선된 것을 확인하였다.

참고 문헌

- [1] Rumelhart, D. E., Hinton, G. E., & Williams, R. J., "Learning representation by back propagation errors." *Nature*, 323, 533-536, 1986.
- [2] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, Addison-Wesley, 1992.
- [3] Rumelhart, D. E. McClelland, J. L. and the PDP Research Group(Eds), parallel distributed processing, vol. 1, pp. 318-536, Cambridge, MA: MIT Press.
- [4] James A. Freeman, David M. Skapura, *Neural Networks Algorithms, applications, and Programming Techniques*, Addison-Wesley, pp. 89-125, 1991.
- [5] M. Georopoulos, G. L. Heileman and J. Huang, "Properties of Learning Related to Pattern Diversity in ART1," *Neural Networks*, vol. 1, pp. 751-757, 1991.
- [6] 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.
- [7] Gail A. Carpenter and Stephen Grossberg, "The ART of Adaptive Pattern Recognition by a Self-Organizing Neural Networks," *IEEE Computers*, pp. 77-88, 1988.
- [8] Gail A. Carpenter and Stephen Grossberg, "A Massively Parallel Architecture for a Self-organizing Neural Pattern Recognition Machine," *Computer Vision, Graphics, and Image Processing*, vol. 37, pp. 54-115, 1987.
- [9] R. Allen, "Several Studies on Natural Language and Back Propagation," *IEEE ICNN*, vol. II, pp. 335-342, 1987.

- [10] R. A. Jacobs, "Increased rates of convergence through learning rate adaptation," *Neural Networks*, vol. 1, no. 4, pp. 295-308, 1988.
- [11] J. W. Kim, et, al., "Auto-Tuning Method of Learning Rate for Performance Improvement of Back propagation Algorithm," *The Institute of Electronics Engineers of Korea*, vol. 39, no. 4, pp. 19-26, 2002.
- [12] T. K. Kim, et, al., "An Educational Matters Administration System on The web by Using Image Recognition," *Korea Intelligent Information Systems Society*, pp. 203-209, 2002.
- [13] J. U. Ryu, T. K. Kim, K. B. Kim, "An Enhanced Fuzzy ART Algorithm for The Identifier Recognition form Shipping Container image," *Korea Fuzzy Logic and Intelligent Systems Society*, vol. 12, no. 2, pp. 365-369, 2002.
- [14] Y. H. Ju, T. K. Kim, K. B. Kim, "A Study on Auto-Tuning Method of Learning Rate by Using Fuzzy Logic System," *Korea Fuzzy Logic and Intelligent Systems Society*, pp. 484-489, 2003.

김 광 백(Kwang-baek Kim)

정회원



생체신호처리

1999년 2월 부산대학교 전자계산학과 이학석사
 1999년 2월 부산대학교 전자계산학과 이학박사
 1997년 3월~현재 신라대학교 컴퓨터공학과 부교수
 <관심분야> 신경망, 퍼지이론,

백 준 기(Joon-ki Paik)

정회원




학박사

현재 중앙대학교 첨단영상대학원 영상공학과 교수
 <관심분야> 영상복원, 신호처리, 반도체

1984년 서울대학교 제어계측공학과 공학사
 1987년 노스웨스턴대학교 전기 및 컴퓨터 공학과 공학석사
 1990년 노스웨스턴대학교 전기 및 컴퓨터 공학과 공

김 태 경(Tae-kyung Kim)

정회원



2002년 2월 신라대학교 컴퓨터공학과 공학사
 2004년 2월 신라대학교 컴퓨터정보공학과 공학석사
 2004년 3월~현재 중앙대학교 첨단영상대학원 영상공학과 박사과정

<관심분야> 신경망, 비디오해석, 영상처리