

Self-generation을 이용한 퍼지 지도 학습 알고리즘

김 광 백[†]

요 약

본 논문에서는 하나의 은닉층을 가지는 다층 구조 신경망이 고려되었다. 다층 구조 신경망에서 널리 사용되는 오류 역전파 학습 방법은 초기 가중치와 불충분한 은닉층 노드 수로 인하여 지역 최소화에 빠질 가능성이 있다. 따라서 본 논문에서는 퍼지 단층 퍼셉트론에 ART1을 결합한 방법으로, 은닉층의 노드를 자가 생성(self-generation)하는 퍼지 지도 학습 알고리즘을 제안한다. 입력층에서 은닉층으로 노드를 생성시키는 방식은 ART1을 수정하여 사용하였고, 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.

Fuzzy Supervised Learning Algorithm by using Self-generation

Kwang-Baek Kim[†]

ABSTRACT

In this paper, we consider a multilayer neural network, with a single hidden layer. Error backpropagation learning method used widely in multilayer neural networks has a possibility of local minima due to the inadequate weights and the insufficient number of hidden nodes. So we propose a fuzzy supervised learning algorithm by using self-generation that self-generates hidden nodes by the compound fuzzy single layer perceptron and modified ART1. From the input layer to hidden layer, a modified ART1 is used to produce nodes. And winner take-all method is adopted to the connection weight adaptation, so that a stored pattern for some pattern gets updated. The proposed method has applied to the student identification card images. In simulation results, the proposed method reduces a possibility of local minima and improves learning speed and paralysis than the conventional error backpropagation learning algorithm.

Key words: Multilayer Neural Network, Modified ART1, Fuzzy Single Layer Perceptron, Fuzzy Supervised Learning Algorithm, Winner Take-All Method

1. 서 론

인공 신경망의 지도 학습 모델 중의 하나인 역전파(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 값

들을 어떤 값으로 설정하는가에 따라 학습 속도가 결정되어지고, 은닉층의 노드 수의 결정에 따라 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 영상 인

접수일 : 2003년 3월 31일, 완료일 : 2003년 5월 14일

[†] 정회원, 신라대학교 컴퓨터공학과 부교수

식 등과 같은 복잡한 문제의 경우에는 적당한 은닉층의 노드 수를 찾아내기가 어렵다.

Grossberg와 Carpenter에 의해 제안된 ART (Adaptive Resonance Theory) 신경망 모델은 뉴런들 간의 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[5]. 또한 저속 및 고속 학습이 가능한 장점을 가지고 있고, 지역 최소화(local minima) 문제가 발생하지 않는다[6]. 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 이 유사성이 경계 변수보다 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 영상 인식에 적용할 경우, 입력 벡터와 클러스터의 대표 벡터간의 유사성 측정 방법과 경계 변수에 따라 인식이 낮아지는 문제점이 있다.

본 논문에서는 오류 역전파 알고리즘에서 은닉층의 노드 수를 설정하는 문제와 ART1의 경계 변수의 설정에 따른 인식이 저하되는 문제점을 개선하기 위해 ART1 알고리즘과 퍼지 단층 퍼셉트론 알고리즘을 결합한 자가 생성(Self-generation)을 이용한 퍼지 지도 학습 알고리즘을 제안한다.

2. 관련 연구

2.1 오류 역전파 알고리즘

오류 역전파 알고리즘은 지도 학습 규칙으로서 주어진 입력에 대해 원하는 출력과 목표값 사이의 오류 값에 따라 정의되는 비용 함수(cost function)를 최소화하기 위하여 경사 추적(gradient descent)법을 사용한다. 이로 인해 오류 역전파 학습 구조는 경사 추

적법의 일반적인 단점인 학습의 수렴 속도가 느리다는 단점을 가진다[1,2]. 그리고 은닉층의 불충분한 노드 수나 부적절한 초기 연결 가중치로 인한 지역 최소화에 빠질 가능성이 있다. 학습 과정에서 은닉층의 노드는 그 노드의 목표값을 알 수 없기 때문에 출력층 노드의 오차를 역으로 은닉층 노드들로 책임 분담(credit assignment)하는 방법을 사용하여 정제 현상이 발생한다. 이것은 오차값이 큼에도 불구하고 학습이 진행되지 않는 현상으로 조기포화(premature saturation)현상에 해당된다[8].

Kavuri[4]의 은닉층 노드 수를 동적으로 조정하는 방법은 학습 과정 중에 지역 최소화에 빠졌을 때 은닉층에 하나의 새로운 노드를 첨가하였다. 이 방법에서는 총 오차자승합의 변화량에 의해 지역 최소화를 판정하였다. 즉 일정한 epoch마다 총 오차자승합의 변화량을 검사하여 총 오차자승합의 변화량이 정해진 값보다 적으면 신경망이 지역최소화에 빠졌다고 판단하여 은닉층에 하나의 새로운 노드를 첨가하는 방법을 적용하였다. 그러나 실제 응용 문제에 따라 일정한 epoch마다 총 오차자승합의 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. [9]의 방법에서는 학습 시간과 지역최소화 문제를 개선하기 위하여 학습에 필요한 최소의 은닉층 수를 $\log_2(\text{입력노드 수} + \text{학습패턴의 수})$ 로 계산하여 초기의 은닉층 노드 수를 설정하였다. 설정된 초기 은닉층의 노드 수를 기반으로 하여 목표값과 출력층의 실제 출력값의 차이의 절대값이 ϵ 보다 적거나 같으면 정확성으로 분류하고 크면 비정확성으로 분류하여 정확성으로 분류된 수가 정해진 횟수 이상으로 반복하고 총오차자승합의 변화량이 정해진 값보다 적으면 지역 최소화에 빠졌다고 판단하여 은닉층에 새로운 노드를 첨가하였다. 그러나 [9]의 방법은 목표 값의 설정에 따라 학습 시간에 큰 영향을 주는 문제점이 있다. 그리고 오류 역전파 알고리즘에서 전역 최소화 문제는 NP-complete 문제이다[10].

본 논문에서는 기존의 오류 역전파 학습 알고리즘에서 은닉층 노드의 수를 설정하는 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 적용된 winner-take all 방식 하의 가중치 조정 방법은 기존의 오류 역전파 알고리즘에서 학습속도를 느리게 하는 정체 현상을 개선시킨다.

2.2 ART1 알고리즘

ART1 알고리즘은 임의의 패턴을 학습할 수 있는 안정성(stability)과 적응성(plasticity)을 갖는 신경망의 자율 학습 알고리즘이다. 또한 저속 및 고속 학습이 가능한 장점을 가지고 있고, 지역 최소화(local minima) 문제가 발생하지 않는다. ART1 알고리즘에서 경계 변수(vigilance parameter)는 임의의 패턴과 저장된 패턴간의 불일치(mismatch) 허용도를 결정하는 기준이 된다. 이 경계 변수가 크면 입력 패턴과 저장된 패턴 사이에 약간의 차이가 있어도 새로운 카테고리(category)로 분류하게 된다. 반대로 경계 변수가 작으면 입력 패턴과 저장된 패턴 사이에 많은 차이가 있더라도 유사성이 인정되어 저장된 패턴의 카테고리로 분류한다[5]. 따라서 실제 영상 인식과 같은 분야에 ART1 알고리즘을 적용하기 위해서는 경계 변수를 경험적으로 설정해야 한다. 그리고 서로 다른 유사한 특징을 갖는 패턴들이 많을 경우에는 경계 변수의 설정에 따라 인식이 달라진다.

본 논문에서는 ART1 알고리즘의 문제점이 입력 패턴과 저장 패턴간의 유사성 측정과 경계 변수에 따라 좌우된다는 사실[6]을 바탕으로 유사성 측정 방법을 입력 패턴과 저장 패턴간의 Exclusive NOR의 놈(norm) 비율을 적용하여 ART1을 개선하고 개선된 ART1을 제안된 퍼지 지도 학습 알고리즘의 입력층과 은닉층의 학습 구조로 적용한다.

2.3 퍼지 단층 퍼셉트론

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[11]. 두 번째 접근 방법은 두 이론의 유사한 특징을 중첩시키는 것이다. 첫째, 추론 규칙의 조건부의 퍼지 변수와 입력간의 Min 연산은 뉴런의 입력과 연결선에 부여된 가중치의 곱셈 연산에 대응된다. 둘째, 여러 추론 규칙의 결론 부분

에 대한 Max 연산은 뉴런의 입력과 가중치를 곱한 것을 합하는 연산과 대응된다[12]. 퍼지 단층 퍼셉트론은 두 번째 접근 방법에 해당되는 학습 알고리즘으로 이진 패턴뿐만 아니라 퍼지 데이터도 효율적으로 학습 할 수 있는 장점이 있다[13]. 그러나 이 알고리즘은 패턴 인식과 같은 실세계 문제에 적용할 경우에는 지역 최소화 문제가 발생하여 수렴이 되지 않는 경우가 발생한다.

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

$$NET = \bigvee \{ \bigwedge \{ x_1, w_{j1} \}, \dots, \bigwedge \{ x_m, w_{jm} \} \} \quad (1)$$

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

$$w_{ji}(n+1) = w_{ji}(n) + \alpha \Delta w_{ji}(n+1) + \beta \Delta w_{ji}(n) \quad (3)$$

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

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

$$\frac{\partial o_j}{\partial \theta_j} = 1, \text{ when } o_j = \theta_j, \quad \frac{\partial o_j}{\partial w_{ji}} = 1, \text{ when } o_j = w_{ji}, \\ = 0 \text{ otherwise.} \quad = 0 \text{ otherwise.}$$

여기서, α 는 학습율이고 β 는 모멘트이다. 퍼지 단층 퍼셉트론에서 학습 종료는 총 오차 자승합(TSS : total sum of squares)이 오류 한계보다 적을 때까지 학습한다.

3. Self-generation에 의한 퍼지 지도 학습 알고리즘

은닉층의 노드를 자가 생성하도록 구성된 제안된

학습 구조는 그림 1과 같다. 제안된 학습 구조에서 입력층과 은닉층간의 연결 구조는 수정된 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 퍼지 단층 퍼셉트론을 적용한다.




그림 1. 제안된 Self-generation에 의한 퍼지 지도 학습 모형

3.1 은닉층 노드의 동적인 생성과 대표 패턴 선정 문제

은닉층 노드의 생성은 제시된 패턴들로 결정될 클래스 수에 기반한다. 본 논문에서는 ART1을 기반한 방법에 은닉층의 초기 최대 노드 수를 클래스 수로 설정하여 생성 되도록 한다. 하나의 노드로 시작하여 그 노드를 입력층에서 처음 제시된 패턴에 해당하는 클래스로 할당한다. 그 다음부터 제시될 패턴들은 현 상태에서 존재하는 노드들에 대해서 승자를 채택하고 승자 노드 선정에 실패할 경우에는 노드를 하나 증가하여 해당 패턴에 대한 클래스로 할당한다. 이런 방식으로 모든 패턴들이 제시되면 클래스에 따른 노드가 동적으로 생성된다. 그러나 입력 패턴이 제시되어 선정된 승자 노드가 그 패턴에 대한 대표 클래스가 되는 것은 아니다. 여기서 승자 노드의 저장 패턴과 유사성을 측정하여 유사성이 인정되면 승자 노드

로 채택되고, 대표 클래스가 된다. 만약 유사성이 인정되지 않으면 새로운 노드를 할당한다. 기존 ART1에서 유사성 측정은 입력 패턴에 대한 저장 패턴인 하향 가중치와 입력 패턴간의 곱의 놈(norm)비율로서 구해지고, 식 (4)와 같다.

$$\frac{\|T \cdot X\|}{\|X\|} \tag{4}$$

여기서, T는 저장 패턴인 하향 가중치이고, X는 입력 패턴이다. 식 (4)에서 $\|T \cdot X\|$ 와 $\|X\|$ 는 다음과 같이 계산된다.

$$\begin{aligned} \|T \cdot X\| &= \sum_{j=1}^m t_{j,i} x_i \\ \|X\| &= \sum_{i=1}^m x_i \end{aligned} \tag{5}$$

여기서 $t_{j,i}$ 는 j번째의 승자 노드의 저장 패턴인 하향 가중치이고 x_i 는 i번째의 입력 노드이다. 식(4)에서 계산된 유사성이 경계 변수(vigilance parameter)보다 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. 저장 패턴에 0의 값이 많은 경우에는 식 (4)에 의해서 유사성이 계산되므로 입력 패턴의 정보가 손실되는 문제점이 발생한다. 따라서 실제 가시적으로 분명하게 분리 인식되는 패턴들에 대해서 명확히 클러스터를 분류하지 않고 같은 클러스터로 분류하는 문제점이 발생하고 입력 패턴들의 순서에 따라 생성되는 클러스터의 수가 달라지는 문제점이 발생한다. 따라서 제안된 구조에서는 1의 개수 비율에 의한 유사성 구분을 하지 않고, 같은 값을 가진 노드의 수를 기준으로 유사성을 구분한다. 즉 논리 연산 형태로 생각할 때, 식 (6)과 같이 입력 패턴에 대한 저장 패턴과 입력 패턴간의 Exclusive NOR의 놈(norm) 비율을 사용한다.

$$\frac{\|T \oplus X\|}{\|X \oplus X\|} = \frac{\sum_{i=1}^m (\bar{t}_{j,i} \bar{x}_i + t_{j,i} x_i)}{\sum_{i=1}^m (\bar{x}_i \bar{x}_i + x_i x_i)} \tag{6}$$

식 (6)을 이용하여 입력 패턴들의 순서에 따라 생성되는 클러스터의 수가 달라지는 문제점을 해결할 수 있고 기존의 방법보다 더 정확한 유사성을 측정할 수 있다. 이것을 그림 2와 같은 예제로 분석하면 다음과 같다. 그림 2의 패턴(a)와 패턴(b)가 학습되어 있




그림 2. (a),(b) 학습 패턴, (c) 테스트 패턴

고 패턴(a)에 유사한 패턴(c)가 테스트 패턴으로 입력되는 경우에 유사성을 측정하면, 식 (4)에 의해 패턴(a)와 패턴(b)가 모두 1로서 같은 값을 가진다. 그러나 제안된 식 (6)에 의해서 패턴(a)는 0.92이고 패턴(b)는 0.76으로, 패턴(c)는 패턴(a)에 더 유사함을 알 수 있다.

3.2 가중치 조정 문제

제안된 구조는 가중치 조정을 위해 기존의 퍼지 단층 퍼셉트론에 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 연결 가중치만을 조정한다.

3.3 ART1 기반 퍼지 지도 학습 알고리즘

제안된 Self-generation에 의한 퍼지 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 1로 초기화한다.

여기서 $i (i=1 \dots m)$ 는 입력층, $j(j=1 \dots n)$ 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.

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

단계 4: 승자 노드(o_j^*)를 선택한다.

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

단계 5: 승자 노드의 하향($t_{j,i}$) 가중치와 입력 패턴간의 유사성을 측정한다.

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

단계 6: 만약 계산된 유사성이 $\frac{\|T \odot X\|}{\|X \odot X\|} \geq \rho$ 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.

$$t_{j,i}(n+1) = t_{j,i}(n)x_i$$

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

단계 9: 은닉층의 대표 클래스(o_j^*), 은닉층의 대표 클래스와 출력층의 연결 가중치 (w_{kj})를 이용하여 출력층의 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 α 는 학습율이고 β 는 모멘트이다.

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

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

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

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

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

단계 10: 총오차 자승합(TSS)이 오류 한계(ϵ) 보

다 크면 단계 3으로 가고 오류 한계보다 적거나 같으면 학습을 종료한다.


4. 실험 및 성능 분석

본 논문에서 제안된 알고리즘의 성능을 분석하기 위하여 Intel Pentium-1GHz CPU와 256 MB RAM이 장착된 IBM 호환 PC상에서 C++ 빌더로 구현하였고, 실험에 사용된 데이터는 HP Scanjet 4200C 스캐너를 이용하여 600×400 크기를 가진 10개의 학생증 영상에 추출한 90개의 개별 학번을 대상으로 기존의 오류 역전과 알고리즘, Kavuri[4]와 [9]의 방법, 그리고 제안된 방법간의 학습 성능을 비교 분석하였다.

학생증 영상에서 학번 패턴을 추출하기 위해[14]의 방법을 적용하여 개별 학번 패턴을 추출하였다. 학생증 영상은 학번의 위치가 고정되어 있다는 사전의 정보를 이용하여 이진화된 학생증 영상 전체를 대상으로 히스토그램을 수행하지 않고 학번 영역이 포함된 일부 영역 부분만을 수행하였다. 이진화된 학생증 일부 영역에서 수평 방향으로 히스토그램을 나타내면 특징 영역은 그림 3과 같이 5개 영역으로 구



(a) 원 영상



(b) 학번 영역 추출 결과

그림 3. 학번 영역 추출 과정

분되고 학번 영역은 위에서 4번째 부분에 위치해 있으므로 4번째 영역을 학번 영역으로 추출하였다. 학번 영역 추출 단계를 표현하면 그림 4와 같다.

추출된 학번 영역의 잡음을 제거하기 위하여 3×3 마스크를 이용한 최빈수 평활화(smoothing)를 수행하였고 잡음이 제거된 학번 영역에 대해서 각 문자 영역을 추출하기 위해 수직 방향 히스토그램을 이용하여 개별 문자를 추출하였다. 추출된 개별 문자는 10×15 크기의 패턴으로 정규화 하였다. 학생증 영상의 개별 학번 추출 단계는 그림 5와 같다.

10개의 학생증 영상에서 추출 및 정규화된 그림 6과 같은 90개의 개별 학번을 기존의 오류 역전과 알고리즘, Kavuri[4]와 [9]의 방법 그리고 제안된 방법에 적용하여 epoch 수와 TSS를 표 1로 나타내었다.

표 1의 결과는 학생증 영상에서 추출한 90개의 학번 데이터를 10×15 크기로 구성하여 학습한 결과이다. 여기서 학습률과 모멘트는 각각 0.5와 0.7로 설정하였다.

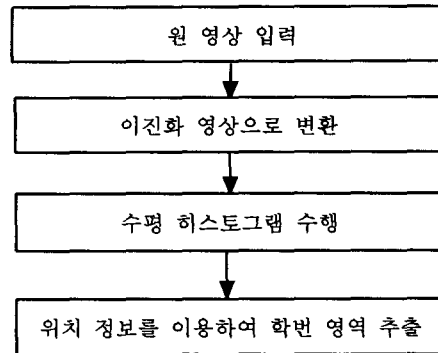


그림 4. 학번 영역 추출 단계

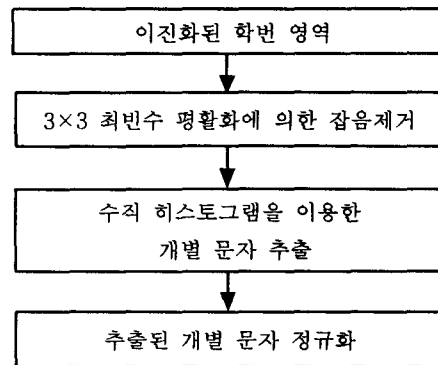


그림 5. 개별 학번 추출 단계




그림 6. 학생증의 학습 패턴

표 1. 각 알고리즘간의 Epoch수와 TSS

	은닉층의 노드 수	epoch 수	TSS
오류 역전파	42	3515	0.035764
Hayashi[4]방법	46	4432	0.029126
[9]방법	39	3194	0.033274
제안된 방법	41	534	0.025470

그리고 학습을 위해 오류 역전파 알고리즘과 Kavuri[4]와 [9]의 방법에서는 초기 연결 가중치의 범위를 -1과 1사이의 범위로 설정하였으며, 제안된 방법에서는 입력층과 은닉층 사이의 학습 구조로 수정된 ART1 알고리즘을 사용하므로 ART1 알고리즘 방식으로 설정하였다. 그리고 제안된 방법에서 은닉층과 출력층 사이의 학습 구조로는 퍼지 단층 퍼셉트론을 사용하므로 은닉층과 출력층 사이의 초기 가중치를 1로 설정하였다. 그리고 제안된 방법에서 은닉층의 노드를 생성 또는 갱신하는데 사용되는 경계 변수를 0.7로 설정하였다. 본 실험에서 Kavuri[4]의 방법을 적용 할 때는 초기 은닉층 노드 수를 1개로 설정하였고 50번째의 epoch마다 총오차자승합을 검사하여 총오차자승합이 1.0 이상에서는 총오차자승합의 변화량이 전의 총오차자승합에 비해 10% 이하의 변화가 있을 경우에만 국부 극소점에 빠졌다고 판단하여 은닉층에 새로운 노드를 하나 할당하였고 총오차자승합이 1.0 미만에서는 총오차자승합의 변

화량이 전의 총오차자승합에 비해 1% 미만의 변화가 있을 경우에만 은닉층에 새로운 노드를 하나 첨가하였다. [9]의 방법에서는 초기의 은닉층 수를 $\log_2(150+90) \geq 7$ 로 계산하여 초기의 은닉층 수를 8개로 설정하였다. 그리고 목표값과 출력층의 실제 출력값의 차이의 절대값이 0.1보다 적거나 같으면 정확성으로 분류하고 크면 비정확성으로 분류하여 정확성으로 분류된 개수가 20번 이상 반복하고 총오차자승합의 변화량이 1%보다 적거나 같으면 지역 최소화에 빠졌다고 판단하여 은닉층에 새로운 노드를 첨가하였다. 표 1에서 알 수 있듯이 기존의 오류 역전파 알고리즘 보다 제안된 방법이 학습 시간이 적게 소요되었고 Kavuri[4]의 방법보다 은닉층의 노드수가 적게 생성되었다. 그리고 제안된 방법에서 은닉층의 노드 수를 많이 생성되었으나 학습 시간은 적게 소요되었다. 제안된 방법에서 은닉층의 노드를 생성 또는 갱신하는데 사용되는 경계 변수를 각각 0.95에서 0.7로 설정하여 학습한 결과는 표 2와 같다. 표 2에서 학습률과 모멘트는 각각 0.5와 0.7로 설정한 경우이다.

실험 결과를 통해 제안된 방법은 기존의 학습 방법들 보다 학습 시간이 적게 소요되고 수렴이 보장됨을 알 수 있다.

그 이유는 winner-take-all 방식하의 가중치 조정 에 의해 줄어든 계산량과 그로 인한 정보의 전달 방식으로 유사한 패턴에 의해 가중치가 조정되었기 때문에 조기포화현상인 경쟁 단계가 줄어들었고 정체 현상과 지역 최소화에 빠질 가능성이 줄어들었다. 제안된 퍼지 지도 학습 알고리즘에 의한 학번 패턴의 학습 결과 화면과 인식 화면을 각각 그림 7과 그림 8로 나타내었다.

표 2. 경계 변수에 따른 생성된 노드 수와 인식 개수

	경계변수	epoch 수	생성된 은닉층의 노드수	인식 개수 (인식수/ 총수)
제안된 알고리즘	0.95	781	45	90/90
	0.90	724	44	90/90
	0.85	684	44	90/90
	0.80	645	43	90/90
	0.75	577	42	90/90
	0.70	534	41	90/90

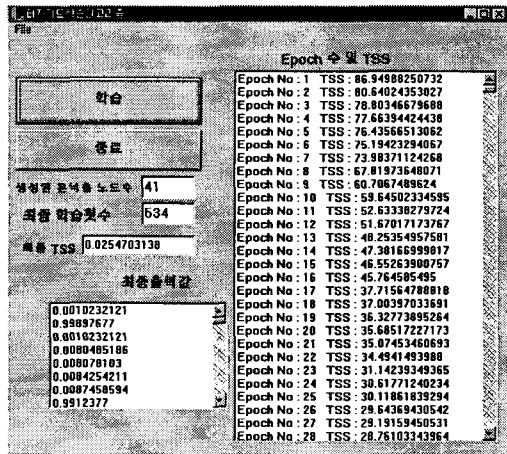


그림 7. 학습 결과 화면



그림 8. 학번 추출 및 인식 화면

5. 결론 및 향후 연구 방향

본 논문에서는 오류 역전과 알고리즘에서 은닉층의 노드 수를 설정하는 문제와 ART1의 경계 변수의 설정에 따른 인식률이 저하되는 문제점을 개선하기 위해 ART1 알고리즘과 퍼지 단층 퍼셉트론을 결합한 Self-generation을 이용한 퍼지 지도 학습 알고리즘을 제안하였다. 제안된 알고리즘은 가중치 조정에서 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 알고리즘의 학습 성능을 분석하기 위하여 학생증 영상의 학번 패턴을 분류하는데 적용한 결과, 제안된 방법이 기존의 ART1과 오류 역전과 알고리즘보다 경계 변수나 파라미터에 민감하게 반응하지 않으며 학습 시간도 적게 소요되고

수렴성도 개선된 것을 확인하였다. 그러나 제안된 알고리즘은 입력 패턴의 크기에는 민감하지 않으나 패턴 크기에 상관없이 패턴의 수가 많아질수록 은닉층에서 생성되는 노드가 증가하였다.

향후 연구과제는 패턴의 수에 민감하지 않게 은닉층의 노드를 생성하는 방법에 대해 연구할 것이고 더 나아가서 제안된 방법을 기반으로 하여 주민등록증 인식 시스템을 개발 할 것이다.

참고 문헌

[1] R. Hecht-Nielsen, "Theory of Backpropagation Neural Networks," Proceedings of IJCNN, Vol.1, pp.593-605, 1989.

[2] A. James and Freeman, Neural Networks : Algorithm, Application and Programming Techniques, Addison-Wesley, 1991.

[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] S. N. Kavuri, V. Venkatasubramanian, "Solving the Hidden Node Problem in Networks with Ellipsoidal Units and Related Issues," Proceedings of IJCNN, Vol.1, pp.775-780, 1992.

[5] 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.

[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] 임은경, 김광백, "개선된 퍼지 ART 알고리즘을 이용한 차량 번호판 인식에 관한 연구," 한국멀티미디어학회 논문지, 제3권 5호, pp.433-443, 2002.

[8] K. B. Kim, M. H. Kang and E. Y. Cha, "Fuzzy Competitive Backpropagation using Nervous System," Proceedings of WCSS, pp.188-193, 1997.

[9] 김광백, 차의영, "신경 시스템에 의한 오류 역전

과 학습의 학습 속도 및 지역 최소화 해결 방안,” 인공지능, 신경망 및 퍼지시스템 종합 학술대회 논문집, pp.592-601, 1992.

- [10] Blum, A. and Rivest, R. L, “Training a 3-node neural net is NP-complete,” In D. S. Touretzky, Advance in Neural Information Processing Systems, pp.494-501, 1989.
- [11] M. M. Gupta and J. Qi, “On Fuzzy Neuron Models,” Proceedings of IJCNN, Vol.2, pp. 431-435, 1991.
- [12] 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.
- [13] Y. Hayashi, E. Czogala and J. J. Buckley, “Fuzzy Neural Controller,” Proceedings of IEEE Fuzzy Systems, pp.197-202, Vol.1, 1992.
- [14] 김태경, 윤형근, 노영욱, 김광백, “영상 인식을 이용한 웹 환경에서의 학사 관리 시스템,” 한국 지능정보시스템학회 춘계학술대회 논문집, pp. 203-209, 2002.



김 광 백

1993년 부산대학교 전자계산학과(이학석사)
 1999년 부산대학교 전자계산학과(이학박사)
 1996년~1997년 동의공업대학 사무자동화과 전임강사
 1999년~2000년 Biomedical

Fuzzy Systems Association Associate Editors (Japan)

1997년~현재 신라대학교 컴퓨터공학과 부교수
 2003년~현재 한국퍼지 및 지능시스템학회 이사
 관심분야 : Neural Networks, Image Processing, Fuzzy Logic, Biological Signal Processing and Biomedical System

E-mail : gbkim@silla.ac.kr

교신저자

김 광 백 617-736 부산광역시 사상구 괘법동 산1-1
 번지 신라대학교 컴퓨터공학과 퍼지 신경망
 및 의료 영상 처리 연구실