

가변 학습을 적용한 퍼지 ART 신경망의 패턴 인식 능력 향상

이 창 주*, 손 병 희*, 홍 희 식**

Improvement of Pattern Recognition Capacity of the Fuzzy ART with the Variable Learning

Chang joo Lee*, Byounghee Son*, Hee sik Hong**

요 약

본 논문은 퍼지ART의 학습 방법의 하나인 FCSR(Fast Commit Slow Recode)에서 패턴 인식을 향상시키기 위해 가변 학습을 이용하는 새로운 학습방법을 제안하였다. 기존의 학습 방법은 연결 강도(대표패턴)의 갱신에 고정된 학습률이 사용된다. 이 방법은 같은 카테고리 내의 입력패턴과 대표패턴의 유사성의 정도와 관계없이 고정된 학습률로 연결 강도를 갱신한다. 이 경우 카테고리 경계에 있는 유사성이 낮은 입력패턴이 연결강도의 갱신에 크게 영향을 주게 된다. 따라서 잡음 환경에서 이것은 불필요한 카테고리 증식의 원인이 되고, 패턴 인식 능력을 낮추는 문제가 된다. 제안된 방법에서는 대표 패턴과 입력 패턴 사이에 유사성이 적을수록 연결강도의 갱신에 입력 패턴의 기여를 낮추어간다. 그 결과 잡음환경에서 퍼지 ART의 불필요한 카테고리 증식을 억제하였고, 패턴 인식 능력을 향상시켰다.

Key Words : Neural network , Fuzzy ART, FCSR, Category, Recognition

ABSTRACT

In this paper, we propose a new learning method using a variable learning to improve pattern recognition in the FCSR(Fast Commit Slow Recode) learning method of the Fuzzy ART. Traditional learning methods have used a fixed learning rate in updating weight vector(representative pattern). In the traditional method, the weight vector will be updated with a fixed learning rate regardless of the degree of similarity of the input pattern and the representative pattern in the category. In this case, the updated weight vector is greatly influenced from the input pattern where it is on the boundary of the category. Thus, in noisy environments, this method has a problem in increasing unnecessary categories and reducing pattern recognition capacity. In the proposed method, the lower similarity between the representative pattern and input pattern is, the lower input pattern contributes for updating weight vector. As a result, this results in suppressing the unnecessary category proliferation and improving pattern recognition capacity of the Fuzzy ART in noisy environments.

1. 서 론

스스로 배우는 시스템을 개발하는 데 있어서 유연성과 안정성이 가장 중요한 문제가 된다. 즉, 기

※ 본 연구는 2011학년도 동양미래대학교 학술 연구비 지원으로 수행되었습니다.

• First Author : 동양미래대학교 정보통신과, cjlee@dongyang.ac.kr, 정희원

* 동양미래대학교 정보통신과, diana@yonsei.ac.kr, 정희원

** 동양미래대학교 정보통신과, hshong@dongyang.ac.kr, 종신회원

논문번호 : KICS2013-09-397, 접수일자 : 2013년 9월 9일, 심사일자 : 2013년 10월 29일, 최종논문접수일자 : 2013년 12월 9일

존의 기억을 그대로 유지하면서 새로운 경험을 해도 안정될 수 있어야 한다. 인간은 과거에 배웠던 것들을 잊지 않고도 새로운 것들을 계속해서 배울 수 있는 능력을 갖고 있다. 이러한 인간 두뇌의 특징을 인공적인 신경회로망에 적용한 것이 1976년 카펜터(Carpenter)와 그로스버그(Grossberg)에 의해 소개된 ART(Adaptive Resonance Theory)이다^[1-3]. ART는 감독자 없이 자기 조직화를 하고 경쟁 학습을 할 수 있다. 지금까지 개발된 대부분의 신경회로망은 학습된 것 이외의 새로운 정보를 추가로 학습시키려 할 때, 전부를 다시 학습시켜야 하는 문제가 있다^[1-3]. 그러나 ART는 새로운 정보를 추가로 학습시킬 때 모든 정보를 다시 학습시킬 필요가 없다. 끊임없이 변하는 환경에서 자신의 메모리 용량을 전부 소모할 때까지는 제한 없이 새로운 입력 정보에 대해 실시간으로 빠르고 안정되게 학습하는 구조이다^[1-3].

ART를 적용한 신경회로망으로 비감독 학습과 감독 학습 신경회로망으로 나눌 수 있다. 비 감독 학습 신경회로망으로는 2진 입력만 사용하는 ART1(1987년), 아날로그 입력까지 확장시킨 ART2(1987년), ART2의 성능을 향상시킨 ART2-A(1991년), 병렬검색을 수행하는 다층망 구조의 ART3(1990년), 퍼지 로직을 ART에 적용한 Fuzzy ART(1991년) 등이 있다. 감독 학습을 하는 신경회로망으로는 ART1을 기반으로 구성된 ART MAP(1991년), Fuzzy ART를 기반으로 구성된 Fuzzy ARTMAP(1992년) 등이 있다^[2-9]. 이런 신경회로망을 다양한 분야에서 이용하는 연구가 꾸준히 진행되고 있다^[10].

일반적으로 ART 신경회로망은 입력 패턴에 잡음 신호가 포함되어 있지 않은 경우 최소한의 출력 카테고리 형성하면서 최적의 인식 성능을 나타내는 것으로 알려져 있다. 그러나 실 상황에서 입력 패턴은 잡음이 부가되거나 왜곡이 되는 경우가 많다. 예를 들어 문자 인식의 경우 인식하기 위한 전 단계에서 센서를 통한 입력과정이 필요한 데 이 과정에서 데이터에 잡음이 부가되거나 왜곡이 발생하는 것이 불가피하다. 이와 같이 입력 데이터에 잡음이 부가될 때 ART 신경회로망은 카테고리 수가 급격하게 증가되고, 패턴 인식률도 현저히 떨어지게 된다.

이러한 문제를 해결하기 위해서 신경회로망의 연결강도를 학습시킬 때 일반적으로 사용하는 고속학습(FL: Fast Learning) 방법 대신에 학습 속도를 늦추어 연결강도의 변화를 적게 하는 저속학습(SL:

Slow Learning) 방법이 있다. 이 방법은 카테고리 증식 문제를 해결해 주지만, 신경회로망의 수렴 속도가 늦어지고, 학습시간이 길어지며, 인식률이 떨어지는 등 문제가 많다. 다른 방법으로 고속학습과 저속학습을 절충한 고속수용저속부호화(FCSR: Fast-Commit Slow-Recode)가 있는데 이 방법은 저속학습보다는 카테고리 증식을 더 많이 하지만, 신경회로망의 수렴 속도가 고속학습에 가깝고, 인식률이 상당히 개선된다^[3-9]. 다른 방법으로 경계 문턱값을 훈련 과정에서 달리 하는 방법이 있으나, 이 역시 카테고리 증식 억제에 약간의 효과만 있다. 또한 퍼지 ART 신경 회로망에서 연결강도의 학습에 가중합을 이용하는 방법으로 잡음의 영향을 줄이고 카테고리가 불필요하게 증식되는 것을 방지하는 방법이 제안되었으나 이 방법은 가중치의 값에 따라 신경망의 학습 속도와 연결 강도의 수렴 값이 영향을 받게 되는 문제점이 있다^[3-9,11].

본 논문은 비감독 시스템인 퍼지 ART 신경 회로망에서 잡음이 포함된 패턴이 입력되었을 때 기존의 학습 방법에 비하여 잡음의 영향을 효과적으로 감소시킬 수 있는 새로운 학습방법을 제안한다. 제 2 장에서는 기존의 퍼지 ART에 대하여 서술하고, 제 3 장에서는 제안된 학습 방법인 가변 학습을 적용한 퍼지 ART에 서술하고, 제 4 장에서는 실험 결과와 검토에 대해 서술하고, 마지막으로 제 5 장에서 결론을 내린다.

II. 퍼지 ART

2.1. 퍼지 ART의 구조

그림 1은 퍼지 ART의 구조를 나타낸다. 이 모듈은 입력층(F0), 비교층(F1), 출력층(F2)등 3층으로 구성되어 있으며 각각 2M, 2M, N개의 노드를 갖고 있다. F0층과 F1층의 노드를 나타내는데 인덱스 i 가 사용되고, F2층의 노드를 나타내는데 인덱스 j 가 사용된다. F1층과 F2층 사이에는 상향연결강도(b_{ij})와 하향연결강도(t_{ij})로 연결돼 있다. 상향연결은 F1층의 노드로부터 방사적으로 퍼져서 F2층의 각 노드에 연결되어 있다. 하향연결은 반대로 F2층의 노드로부터 방사적으로 퍼져서 F1층의 각 노드에 연결되어 있다. 입력층은 입력벡터(\mathbf{a})를 상보부호화 입력벡터($\mathbf{I}=(\mathbf{a}, \mathbf{a}^c)$)로 변환하고, 비교층은 하향연결벡터와 상보부호화 입력벡터 사이의 일치 정도를 비교하고, 출력층은 상향연결강도를 통해 집중된 가

장 큰 값을 갖는 노드를 선택한다²⁻¹¹⁾. 이 그림에서 이득제어 회로는 생략했다.

2.2. 퍼지 ART의 학습방법

퍼지 ART의 F1층과 F2층 사이의 연결강도는 상향연결강도(b_{ij})와 하향연결강도(t_{ij})를 구분하지 않고 이들을 연결강도벡터 $W_j = (w_{1j}, w_{2j}, \dots, w_{(2M)j})$ 로 표시하고, 대표 패턴으로 부른다. 출력층의 노드




그림 1. 퍼지 ART의 구조
Fig. 1. Architecture of Fuzzy ART

J가 활성 노드로 선택되었을 경우 연결강도벡터 (W_j)의 갱신은 다음 식(1)과 같다²⁻¹¹⁾.

$$W_j = (1 - \beta) W_j + \beta (I \wedge W_j) \quad (1)$$

여기서 I는 상보부호화입력벡터이고, 파라미터 β 는 학습률($\beta \in (0, 1)$)을 나타내고, 기호 \wedge 는 퍼지 AND 연산을 나타낸다¹¹⁻⁵⁾.

학습 속도는 β 값에 따라 차이가 나는데 만약 $\beta=1$ 이면 고속학습(FL)이라 부르고, 만약 $0 < \beta < 1$ 이면 저속학습(SL)이라 부른다. 만약 임의의 노드가 사전에 입력패턴에 의해 선택된 적이 있으면 수용(commit)되었다고 말하고, 반대로 선택된 적이 없었으면 비수용(uncommit)되었다고 말한다. 고속수용저속부호화(FCSR)는 출력층의 선택된 노드가 사전에 수용되지 않은 노드일 때 고속학습을 하고 사전에 수용된 노드일 때 저속학습을 한다²⁻¹¹⁾.

III. 가변 학습을 적용한 퍼지 ART

3.1. 퍼지 ART의 가변 학습방법

기존의 퍼지 ART의 학습 방법은 신경회로망의 연결강도(대표패턴) 갱신에 식(1)을 이용한다. 이 학습 방법은 일률적으로 연결강도 학습이 진행되기 때문에 입력 패턴이 임의의 카테고리에 소속되지만 카테고리 중심에서 먼 곳에 위치하는 경우 입력 패턴에 의해 연결강도가 과도하게 갱신된다. 반면 입력패턴이 대표패턴과 가까우면 연결강도가 과도하게 갱신되지 않는다. 그런데 입력 패턴이 대표 패턴과 거리가 멀수록 입력 패턴에 잡음이 유입되거나 또는 왜곡이 되었을 확률이 높다. 따라서 잡음의 영향을 적게 받기 위해서, 입력패턴이 대표패턴과 유사성이 작을수록 연결강도의 갱신에 적게 기여하게 하고, 유사성이 클수록 연결강도의 갱신에 많이 기여할 필요가 있다¹¹⁾.

본 논문에서는 기존의 퍼지 ART의 학습 방법의 문제점을 해결하기 위하여 입력패턴과 대표패턴의 일치도(m_j)를 연결강도 학습에 적용하였다. 그림 2는 입력패턴과 대표패턴의 일치도(m_j)에 따른 입력 패턴의 연결강도 학습 반영률을 나타낸다. 기존의 방식인 FCSR는 경계값(ρ) 이상에서 입력 패턴이 연결강도 학습에 100% 반영되지만, 제안된 방법인 가변학습 1(VL-1)은 패턴 일치도(m_j)에 따라 1차식에 비례하여 연결강도 학습에 반영되고, 가변학습2(VL-2)는 2차식에 비례하여 연결강도 학습에 반영된다. 즉 제안된 방법은 입력패턴이 대표패턴으로부터 먼 곳인 경계값(ρ) 가까이에 있으면 입력패턴을 연결강도 학습에 거의 반영하지 않고, 입력패턴이 대표패턴 가까운 곳에 있으면 입력패턴을 연결강도 학습에 대부분 반




그림 2. 패턴 일치도에 따른 입력 패턴의 학습 반영률
Fig. 2. Participation rate of input pattern according to pattern matching ratio

영한다.

제안된 방식은 식(2)와 같이 입력패턴과 대표패턴의 일치도(m_j)를 찾으면, 같은 카테고리 내에서 부분 일치($m_j = \rho$)부터 완전 일치($m_j = 1$)까지 범위에서 입력 벡터의 학습 반영률(μ_j)을 식(3)과 같이 계산한다.

$$m_j = \frac{|\mathbf{I} \wedge \mathbf{t}_j|}{\mathbf{I}} \quad (2)$$

$$\mu_j = \frac{m_j - \rho}{1 - \rho} \quad (3)$$

여기서 경계값(ρ)은 입력패턴이 정해진 카테고리 안에 속하는지 결정하는 파라미터이다. 식(3)에서 입력패턴과 대표패턴이 정확히 일치하면 학습 반영률(μ_j)은 1이 되고, 패턴 일치도가 경계값(ρ)에서 일어나면 학습 반영률(μ_j)은 0이 된다.

연결강도의 갱신을 위한 기존의 식(1)을 대신해서 학습 반영률(μ_j)이 적용되는 가변 학습이 가능한 식(4)와 식(5)를 제안한다.

$$W_j = (1 - \beta) W_j + \beta(((1 - \mu_j) W_j + \mu_j \mathbf{I}) \wedge W_j) \quad (4)$$

$$W_j = (1 - \beta) W_j + \beta(((1 - \mu_j^2) W_j + \mu_j^2 \mathbf{I}) \wedge W_j) \quad (5)$$

여기서 두 식의 연결강도 갱신에 가장 큰 영향을 주는 항이 두 번째 항이다. 이 두 번째 항에서 입력패턴과 대표패턴의 일치도에 따라 가변적으로 입력패턴이 학습에 반영되도록 한 것이다. 즉, 식(4)의 두 번째 항 $(1 - \mu_j) W_j + \mu_j \mathbf{I}$ 와 식(5)의 두 번째 항 $(1 - \mu_j^2) W_j + \mu_j^2 \mathbf{I}$ 는 각각 식(1)의 두 번째 항의 입력 \mathbf{I} 를 대치한 것으로, 학습 반영률(μ_j)이 1에 가까우면 입력패턴과 대표패턴이 매우 유사하다고 볼 수 있으므로 입력패턴을 연결강도 학습에 최대도 반영하고, 학습 반영률(μ_j)이 0에 가까우면 입력패턴과 대표패턴이 차이가 많이 난다고 볼 수 있어 입력패턴을 연결강도 학습에 최소로 반영하여 대표패턴이 급격하게 변하는 것을 막는다.

여기서 식(4)를 가변학습1(VL-1)으로 부르고, 식(5)를 가변학습2(VL-2)로 부르기로 한다. 가변학습1(VL-1)은 입력패턴이 패턴 일치도(ρ 부터 1까지)에 따라 학습 반영률(μ_j)의 1차식에 비례하여 학습에 반영되고, 가변학습2(VL-2)는 입력패턴이 학습 반영률(μ_j)의 2차식에 비례하여 학습에 반영된다.

기존의 학습 방법인 식(1)은 대표패턴과 입력패턴

의 유사성의 정도와 관계없이 일률적으로 연결강도 학습이 진행된다. 한편 제안된 학습 방법에서는 식(4)와 식(5)와 같이 입력패턴이 카테고리 내의 대표패턴과 멀리 떨어져 있으면 연결강도의 갱신에 영향을 적게 주도록 한다. 이에 따라 불필요한 카테고리 증식을 억제하고, 패턴의 인식률을 향상시킬 수 있다.

3.2. 시뮬레이션 알고리즘

3.2.1. 연결강도의 초기화

연결강도는 다음 식(6)과 같이 초기화된다.

$$t_{ij} = b_{ij} = 1 \text{ for } 1 \leq i \leq 2M, \text{ and } 1 \leq j \leq N \quad (6)$$

여기서 t_{ij} 와 b_{ij} 는 비교층 i 번째 노드와 출력층 j 번째 노드 사이의 하향과 상향연결강도이다.

3.2.2. 새로운 입력 벡터 제공

만약 입력벡터 $\mathbf{a} = (a_1, a_2, \dots, a_M)$ 의 각 요소가 $[0, 1]$ 범위의 값을 갖고 입력층에 제공되면 입력층은 식(7)과 같은 상보부호화 입력벡터 \mathbf{I} 를 만든다^[2-11].

$$\mathbf{I} = (\mathbf{a}, \mathbf{a}^c) = (a_1, a_2, \dots, a_M, a_1^c, a_2^c, \dots, a_M^c) \quad (7)$$

여기서 $a_m^c = 1 - a_m$ 이고, 상보부호화 입력벡터 \mathbf{I} 는 $2M$ 차원 벡터 값을 갖는다.

3.2.3. 카테고리의 선택

입력벡터 \mathbf{I} 에 대해 출력층의 j 번째 노드에서 다음 식(8)과 같은 선택 함수 $T_j(\mathbf{I})$ 가 계산된다^[2-11].

$$T_j(\mathbf{I}) = \frac{|\mathbf{I} \wedge \mathbf{b}_j|}{\alpha + |\mathbf{b}_j|} \quad (8)$$

여기서 $\alpha (0 < \alpha)$ 는 선택 파라미터이고, 연산자 \wedge 는 퍼지 AND 연산자이고, 정규화 $|\cdot|$ 는 벡터의 크기를 나타내는 벡터 성분들의 합이다.

그리고 출력층은 상향 연결강도를 통해 집중된 가장 큰 선택 함수값 $T_j(\mathbf{I})$ 를 갖는 노드 J 를 식(9)와 같이 선택한다^[2-11].

$$T_j(\mathbf{I}) = \max\{T_j(\mathbf{I}) : j = 1, 2, 3, \dots, N\} \quad (9)$$

3.2.4. 경계 범위의 테스트

비교층에서는 입력벡터 \mathbf{I} 가 출력층 노드 J 를 대표

로 하는 카테고리 안에 소속되는지 정합 테스트 식 (10)을 이용하여 경계범위 테스트를 행한다²⁻¹¹⁾.

$$\frac{|I \wedge t_j|}{I} \geq \rho \quad (10)$$

여기서 $\rho(\rho \in [0,1])$ 는 경계범위 파라미터이다.

위의 식(10)을 만족하지 못하면 출력층의 노드를 경쟁에서 제외시키고 앞에서 행한 카테고리의 선택과정을 다시 시작한다. 한편 위의 식을 만족하면 연결강도벡터를 다음 단계에서 갱신하게 된다.

3.2.5. 연결강도벡터의 갱신

노드 J가 이전에 한 번도 선택된 적이 없으면 입력 패턴을 대표패턴으로 받아들이고 상향 및 하향 연결 강도를 입력패턴에 맞춘다. 한편 이미 선택된 노드인 경우 기존 방식의 연결강도벡터 갱신에 식(1)을 사용하고, 제안된 방식의 경우 가변학습1(VL-1)에는 식(4)를, 가변학습2(VL-2)에는 식(5)를 사용한다.

IV. 실험 결과 및 분석

4.1. 실험 환경

모의실험은 그림 3의 7×7 화소로 이루어진 영문 알파벳 패턴^[4-6,11)]을 대상으로 기존의 학습 방법으로 고속학습(FL)과 고속수용저속부호화(FCSR)를, 제안된 학습 방법으로 식(4)을 이용하는 가변학습1(VL1) 및 식(5)를 이용하는 가변학습2(VL2)를 비교하였다. 알파벳의 기본 패턴이 26개이므로 이들을 각각의 카테고리별로 인식할 수 있는 최소 경계값(ρ)을 0.919로 정하였다^[4-6,11)]. 이 경계값에서 앞의 학습방법 모두 잡음 없는 환경에서 반복학습 없이 1회 학습만으로도 안정된 26개의 카테고리를 만들기 때문에 잡음 없는 입력 패턴에 대하여 1회 학습하였다. 테스트 패턴은 잡음 없는 패턴에 가우시안 분포의 잡음을 첨가하였고, 각각의 PSNR 마다 잡음 있는 알파벳 패턴 100 세트를 만들어서 2,600개의 패턴을 테스트하였다.

잡음 없는 패턴의 경우 화소 값은 회색은 0으로 검정색은 1로 설정하고, 잡음이 첨가된 패턴의 화소 값은 0과 1사이의 범위를 갖도록 제한하였다. 입력 패턴에 첨가되는 잡음은 가우시안 분포를 이루는 불규칙 잡음으로 식(11)과 같이 정의하여 사용하였다^[5)].

$$PSNR [dB] = \log_{10} \frac{1}{\delta^2} \quad (11)$$

여기서 δ^2 는 가우시안 잡음의 평균 전력을 나타내

고, 가우시안 잡음의 평균전력이 많을수록 PSNR 값이 적어진다.





그림 3. 7×7 화소의 영문 알파벳 기본 패턴
Fig. 3. Alphabet basic pattern with 7×7 pixels


4.2. 실험 결과

그림 4는 가우시안 잡음에 따른 기존의 학습 방법인 고속학습(FL)과 고속수용저속부호화(FCSR)와 제안된 학습 방법인 가변학습1(VL-1) 및 가변학습2(VL-2)의 패턴 인식률을 비교하였다. 학습률(β)에 따라 고속수용저속부호화(FCSR)와 가변학습1(VL-1) 및 가변학습2(VL-2)는 인식률 결과가 변하므로, 학습률(β)을 두 가지 값으로 놓고 비교실험을 하였다. 즉, 그림 4의 (a)는 학습률 $\beta=0.5$ 에서 실험하였고, (b)는 학습률 $\beta=0.1$ 에서 실험하였다. 단, 고속학습(FL)은 $\beta=1.0$ 일 때의 학습 방법이므로 $\beta=1.0$ 로 고정되어 있다.

그림 4의 (a)를 보면 기존 학습 방법인 고속학습(FL)의 경우 PSNR 28[dB]부터 패턴 인식률이 저하하기 시작하고, 급격히 나빠진다. 학습률 $\beta=0.5$ 에서 고속수용저속부호화(FCSR)는 PSNR 26[dB]부터 패턴 인식률이 급격히 저하한다. 반면, 가변학습1(VL-1)은 22[dB]부터 패턴 인식률이 서서히 저하하고, 가변학습2(VL-2)는 18[dB]부터 패턴 인식률이 서서히 저하하고 있다.



(a) $\beta=0.5$



(b) $\beta=0.1$

그림 4. 가우시안 잡음에 따른 패턴 인식률 (a) $\beta=0.5$ (b) $\beta=0.1$

Fig. 4. Pattern recognition rate according to Gaussian noise at (a) $\beta=0.5$ (b) $\beta=0.1$

그림 4의 (b)를 보면 학습률 $\beta=0.1$ 에서 고속수용저속부호화(FCSR)는 PSNR 22[dB]부터 패턴 인식률이 저하하기 시작하고, 급격히 나빠진다. 반면, 가변학습 1(VL-1)은 18[dB]부터 패턴 인식률이 서서히 저하하고, 가변학습2(VL-2)는 16[dB]부터 패턴 인식률이 서서히 저하하고 있다.

표 1은 가우시안 잡음에 따른 기존의 학습 방법인 고속학습(FL)과 고속수용저속부호화(FCSR)와 제안된 학습 방법인 가변학습1(VL-1) 및 가변학습2(VL-2)의 카테고리 증식을 비교하였다. 이 실험에서 알파벳 패턴의 종류가 26개 이므로 카테고리 수가 이보다 많은 것은 잡음에 의해 불필요한 카테고리가 발생한다는 것을 의미한다. 고속학습(FL)은 PSNR 28[dB]까지 안정된 26개의 카테고리를 유지하다가 잡음의 양이 많아지면서 카테고리 수가 급격히 증가되고 있다. 학습률 $\beta=0.5$ 에서 고속수용저속부호화(FCSR)는 26[dB] 까지 안정된 카테고리 수를 유지하다가 이후 급격히 증가되고 있다. 반면 가변학습1(VL-1)은 22[dB] 까지 안정된 카테고리 수를 유지하다가 급격히 증가되고 있다. 또한 가변학습2(VL-2)는 20[dB]까지 안정된 카테고리 수를 유지하고 있다. 학습률 $\beta=0.1$ 에서 고속수용저속부호화(FCSR)는 22[dB] 까지 안정된 카테고리 수를 유지하다가 이후 급격히 증가되고 있다. 반면 가변학습1(VL-1)은 20[dB] 까지 안정된 카테고리 수를 유지하다가 급격히 증가되고 있다. 또한 가변학습2(VL-2)는 18[dB]까지 안정된 카테고리 수를 유지하고 있다.

표 1. 가우시안 잡음에 따른 카테고리 증식
Table 1. Category proliferation according to Gaussian noise

PSNR[dB] Learning	30	28	26	24	22	20	18	16	14	12	10
FL ($\beta=1.0$)	26	26	49	109	250	472	733	1018	1291	1551	2196
FCSR ($\beta=0.5$)	26	26	26	52	109	219	382	606	934	1461	2182
VL-1 ($\beta=0.5$)	26	26	26	26	26	52	70	130	343	1045	2022
VL-2 ($\beta=0.5$)	26	26	26	26	26	26	32	79	253	898	1767
FCSR ($\beta=0.1$)	26	26	26	26	26	52	92	185	432	1138	2084
VL-1 ($\beta=0.1$)	26	26	26	26	26	26	30	71	253	890	1768
VL-2 ($\beta=0.1$)	26	26	26	26	26	26	26	30	135	603	1537

4.3. 실험 분석

기존의 학습방법에서 패턴 인식 능력이 고속학습(FL)보다 고속수용저속부호화(FCSR)이 더 개선된 것을 알 수 있다. 또한 학습률(β)이 작을수록 패턴 인식률이 개선되는 모습을 보이고 있다. 한편 제안된 방법의 효과를 살펴보면 학습률 $\beta=0.5$ 에서 제안된 가변학습1(VL-1)이 기존의 학습방법인 고속수용저속부호화(FCSR)보다 4[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났고, 가변학습2(VL-2)는 8[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났다. 또한 학습률 $\beta=0.1$ 에서도 제안된 가변학습1(VL-1)이 기존의 학습방법인 고속수용저속부호화(FCSR)보다 4[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났고, 가변학습2(VL-2)는 6[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났다. 따라서 전체적으로 제안된 방법이 기존의 방법보다 4[dB]이상 패턴 인식 능력을 개선하였다.

카테고리 증식의 문제에서 기존의 학습방법인 고속학습(FL)보다 고속수용저속부호화(FCSR)이 더 개선된 것을 알 수 있다. 또한 학습률(β)이 작을수록 카테고리 증식의 문제가 개선되는 모습을 보이고 있다. 한편 제안된 방법의 효과를 살펴보면 학습률 $\beta=0.5$ 에서 제안된 가변학습1(VL-1)이 기존의 학습방법인 고속수용저속부호화(FCSR)보다 4[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났고, 가변학습2(VL-2)는 6[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났다. 또한 학습률 $\beta=0.1$ 에서도 제안된 가변학습

1(VL-1)이 기존의 학습방법인 고속수용저속부호화(FCSR)보다 2[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났고, 가변학습2(VL-2)는 4[dB] 이상의 잡음을 개선한 효과가 있는 것으로 나타났다. 따라서 전체적으로 제안된 방법이 기존의 방법보다 2[dB] 이상 카테고리 증식의 문제를 개선하였다.

잡음 환경에서 개선된 학습 방식이 기존의 학습 방식보다 패턴 인식 능력 저하와 불필요한 카테고리 증식 문제를 효과적으로 개선하고 있음을 실험을 통해 보여주고 있다.

V. 결 론

이 연구에서는 비감독 시스템인 퍼지 ART 신경 회로망에서 카테고리 증식을 낮추면서 인식 능력을 높여줄 수 있는 새로운 학습 방법을 제안하였다. 기존의 방법은 카테고리를 대표하는 대표 패턴이 이 카테고리에 속하는 입력 패턴의 유사성의 정도와 관계없이 고정된 학습률로 갱신되었다. 이 경우 카테고리 경계에 있는 유사성이 낮은 입력패턴이 대표패턴의 갱신에 크게 영향을 주게 되어 대표패턴이 과도하게 갱신이 되었다. 제안된 방법은 기존의 퍼지 ART 신경 회로망의 구조적인 변형 없이 입력 벡터의 학습 반영을 패턴 일치도에 따라 가변하도록 하여 과도한 학습을 억제하였고, 이로 인하여 인식 능력 저하 문제와 카테고리 증식 문제를 효과적으로 개선하였다.

모의실험을 통해 제안된 학습 방법인 가변학습이 기존의 학습 방법인 고속수용저속부호화보다 가우시안 잡음 환경에서 패턴 인식률을 4-8[dB] 개선하였고, 불필요한 카테고리의 증식 문제를 2-4[dB] 개선한 것으로 나타났다. 즉 제안된 학습 방법인 가변 학습은 잡음 환경에서 기존 학습 방법보다 불필요한 카테고리의 증식을 억제하면서 패턴 인식 능력을 효과적으로 향상시켰다.

향후 연구로는 감독 시스템인 퍼지 ARTMAP에 이 방법을 적용하여 다양한 패턴의 인식에 응용하고, 다양한 잡음원에 대하여 성능 분석을 할 예정이다.

References

[1] G. A. Carpenter and S. Grossberg, "A massively parallel architecture for a self-organizing neural pattern recognition machine," *Comput. Vision, Graphics, Image Process.*, vol. 37, no. 1, pp. 54-115, Jan. 1987.

[2] G. A. Carpenter, S. Grossberg, and D. B. Rosen, "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system," *Neural Networks*, vol. 4, no. 6, pp. 759-771, Dec. 1991.

[3] G. A. Carpenter and M. N. Gjaja, "Fuzzy ART choice functions," in *Proc. World Congr. Neural Networks (WCNN)*, pp. 713-722, San Diego, U.S.A., June 1994.

[4] C. J. Lee, S. Y. Lee, and C. W. Lee, "Improvement of noise tolerance in fuzzy ART using a weighted sum and a fuzzy AND operation," *IEICE Trans. Fundamentals Electron., Commun., Comput. Sci.*, vol. E78-A, no. 10, pp. 1432-1434, Oct. 1995.

[5] C. J. Lee, S. Y. Lee, and C. W. Lee, "A study on the new learning method to improve noise tolerance in fuzzy ART," *J. Inst. Electron. Eng. Korea (IEEK)*, vol. 32-B, no. 10, pp. 112-117, Oct. 1995.

[6] C. J. Lee, C. G. Yoon, and C. W. Lee "A new learning method to improve category proliferation problem in fuzzy ART," in *Proc. IEEE Int. Conf. Neural Network*, vol. 3, pp. 1393-1396, Perth, Australia, Nov. 1995.

[7] J. S. Lee, C. J. Lee, and C. W. Lee, "Improvement of fuzzy ARTMAP performance in noisy input environment using weighted-average learning," *IEICE Trans. Fundamentals Electron., Commun., Comput. Sci.*, vol. E80-A, no. 5, pp. 932-935, May 1997.

[8] J. S. Lee, C. G. Yoon, and C. W. Lee, "New learning method for fuzzy ARTMAP in the noise environment," *IEE Electron. Lett.*, vol. 34, no. 1, pp. 95-97, Mar. 1998.

[9] J. S. Lee, C. J. Lee, and C. W. Lee, "Improvement of recognition performance for fuzzy ARTMAP using average learning and slow learning," *IEICE Trans. Fundamentals Electron., Commun., Comput. Sci.*, vol. E81-A, no. 3, pp. 514-516, Mar. 1998.

[10] J. Lee, "Fuzzy-ARTMAP based multi-user detection," *J. Korea Inform. Commun. Soc. (KICS)*, vol. 37A no. 3, pp. 172-178. Mar.

2012.

- [11] C. J. Lee, B. H. Son “A study on the improvement of the noise adaptability for fuzzy ART using a variable learning rate,” in *Proc. Workshop Image Process. Image Understanding (IPIU)*, P-104, Jeju Island, Korea, Feb. 2012.

이 창 주 (Chang joo Lee)



1980년 2월 서울대학교 전자
공학과 졸업
1983년 2월 서울대학교 전자
공학과 석사
1996년 2월 서울대학교 전자
공학과 박사
1985년 3월~현재 동양미래

대학교 정보통신과 교수
<관심분야> 통신방식, 신경망

손 병 희 (Byounghee Son)



2003년 2월 연세대학교 전기
공학과 석사
2012년 2월 연세대학교 전기
전자공학과 박사
2012년 9월~현재 한솔로봇
기술연구소 소장
2013년 3월~현재 동양미래대

학교 정보통신학과 겸임교수
<관심분야> 감성공학, 지능형시스템, 미래기술연구

홍 희 식 (Hee sik Hong)



1980년 2월 한국항공대학교
전자공학과 졸업
1982년 2월 한국항공대학교
전자공학과 석사
1992년 8월 한양대학교 전자
통신공학과 박사
1985년 3월~현재 동양미래대

학교 정보통신과 교수
<관심분야> 디지털통신방식, 음성인식