

## 가변 가중 평균 학습을 적용한 퍼지 ART 신경망의 성능 향상

이창주\*, 손병희\*

## Improvement of Properties of the Fuzzy ART with the Variable Weighed Average Learning

Chang joo Lee\*, Byounghee Son\*

## 요약

본 논문은 그로스버그(Grossberg)에 의해 개발된 퍼지 ART 신경 회로망의 성능을 향상시키기 위하여 가변가중 평균(VWA) 학습 방법을 제안한다. 기존의 방법인 고속수용저속부호화(FCSR)는 입력패턴이 임의의 카테고리 내에 포함될 때 카테고리를 대표하는 대표패턴의 갱신이 입력패턴과의 거리(유사성)와 관계없이 고정 학습률로 갱신되고, 또한 이를 개선한 가변학습(VL)은 대표패턴과 입력패턴 사이의 거리를 대표패턴의 갱신에 반영하여 카테고리 증식 문제와 패턴 인식률을 개선한다. 그러나 두 방법 모두 학습 시 퍼지 AND에 의한 과도한 학습이 필수적으로 발생하여 카테고리 증식 문제와 패턴 인식 향상에 한계를 갖는다. 제안된 방법은 카테고리를 대표하는 대표패턴의 갱신 시 대표패턴과 입력패턴 사이의 거리를 반영한 가중평균 학습을 적용하여 대표패턴의 과도한 학습을 억제한다. 시뮬레이션 결과 기존의 학습 방법인 고속수용저속부호화(FCSR)와 가변학습(VL) 보다 제안된 가변가중평균(VWA) 학습 방법이 잡음 환경에서 대표패턴의 과도한 학습을 억제하여 퍼지 ART 신경 회로망의 카테고리 증식 문제를 완화하고 패턴 인식률을 향상시키는 것을 보여준다.

**Key Words** : Neural Network, Fuzzy ART, Variable Learning, Category, FCSR

## ABSTRACT

In this paper, we propose a variable weighted average (VWA) learning method in order to improve the performance of the fuzzy ART neural network that has been developed by Grossberg. In a conventional method, the Fast Commit Slow Recode (FCSR), when an input pattern falls in a category, the representative pattern of the category is updated at a fixed learning rate regardless of the degree of similarity of the input pattern. To resolve this issue, a variable learning method proposes reflecting the distance between the input pattern and the representative pattern to reduce the FCSR's category proliferation issue and improve the pattern recognition rate.

However, these methods still suffer from the category proliferation issue and limited pattern recognition rate due to inevitable excessive learning created by use of fuzzy AND. The proposed method applies a weighted average learning scheme that reflects the distance between the input pattern and the representative pattern when updating the representative pattern of a category suppressing excessive learning for a representative pattern. Our simulation results show that the newly proposed variable weighted average learning method (VWA) mitigates the category proliferation problem of a fuzzy ART neural network by suppressing excessive learning of a representative pattern in a noisy environment and significantly improves the pattern recognition rates.

\* 본 연구는 2014학년도 동양미래대학교 학술연구비 지원으로 수행되었습니다.

•° First and Corresponding Author : Dongyang Mirae University Department of Information and Communications, cjlee@dongyang.ac.kr, 정희원

\* 인하공업전문대학, diana@inhac.ac.kr, 정희원

논문번호 : KICS2016-10-305, Received October 12, 2016; Revised January 9, 2017; Accepted January 9, 2017

## I. 서 론

적응 공명 이론은 1976년 그로스버그(Grossberg)와 카펜터(Carpenter)에 의해 개발되었고, 다수의 ART 모델이 이후 발표되었다<sup>[1]</sup>. ART 모델의 특징은 상향으로 감각 정보를 모아서 경쟁하고 하향으로 관찰을 통해 기대치를 충족하는지 판단하는 두 기능의 상호작용에 의해 개체 식별 및 인식을 한다. 대부분의 신경망 모델과 달리 ART 모델은 새로운 정보를 추가로 학습시킬 때, 이전에 학습한 정보를 다시 학습하지 않아도 되는 장점을 갖고 있다. ART 모델들은 학습에 적용되는 방법에 따라 자율학습 모델과 지도학습 모델들로 나눌 수 있다. 자율학습은 입력패턴의 집합을 카테고리별로 적절히 분류할 때 실행되고, 지도학습은 입력패턴과 관련된 출력 패턴 사이를 맵핑하기 위한 학습이 필요할 때 사용된다. 자율학습 모델로 ART1, ART2, ART3, 퍼지 ART 등이 있고, 지도학습 모델로 이진 ARTMAP과 퍼지 ARTMAP이 있다<sup>[2-8]</sup>.

자율학습 모델 중 가장 눈에 띄는 모델은 퍼지 ART 모델로 데이터로부터 유사성을 테스트하고 퍼지 AND 연산자를 적용하여 학습하고, 퍼지 ART의 카테고리 증식을 데이터의 정규화에 의해 해결한다. 이 모델은 자기 조직화를 할 수 있으며 학습 방법으로 경쟁 학습을 하고, 경쟁 학습의 약점인 안정성을 보강하여 안정성과 유연성을 추구하는 신경회로망으로 학습을 통해 이진 또는 아날로그 입력패턴을 자율적으로 인식하고 카테고리를 구성하며 실시간으로 동작하는 특징을 가지고 있다<sup>[2]</sup>. 그로스버그의 퍼지 ART는 학습 방법으로 고속학습(FL : fast learning), 고속수용저속 부호화(FCSR : Fast-Commit Slow-Record), 저속학습(SL : Slow Learning) 방법이 있다<sup>[2-10]</sup>.

고속학습(FL : fast learning)을 하는 퍼지 ART의 경우 잡음 환경에서 카테고리 증식이 빠르게 발생하는 문제가 있고, 저속학습은 카테고리 증식은 억제되지만 패턴 인식률이 현저히 저하되는 문제가 있다. 고속수용저속부호화 방식은 고속학습과 저속학습의 장점을 수용한 방법으로 잡음 환경에서 카테고리 증식을 억제하면서 패턴 인식률을 높여 준다. 이후 개선된 방법인 가변학습(VL : Variable Learning)은 카테고리 증식 문제와 패턴 인식률 향상을 고속수용저속부호화보다 개선하였다. 그러나 기존의 학습 방법들은 퍼지 ART의 연결강도 갱신에 퍼지 AND 연산을 이용하기 때문에 과도한 갱신을 유발하는 문제가 발생한다<sup>[5,8]</sup>.

제안된 방법은 카테고리를 대표하는 대표패턴의 갱

신 시 가변학습(VL)과 같이 대표패턴과 입력패턴 사이의 거리를 반영하고 퍼지 AND 연산 대신 가중평균 연산을 적용하여 대표패턴의 과도한 학습을 억제하도록 한다. 2장에서는 퍼지 ART의 구조와 알고리즘에 대하여 기술하고 3장에서는 기존 학습 방법과 제안된 학습 방법의 차이점을 설명하며 4장에서는 시뮬레이션 결과를 보여주고 마지막으로 결론을 맺는다.

## II. 퍼지 ART

### 2.1 퍼지 ART 구성과 동작

퍼지 ART 신경회로망의 일반적 구조는 그림 1과 같이 나타낸다. 일반적으로 퍼지 ART의 구조는 입력층(F0), 비교층(F1), 출력층(F2) 등 3개 층으로 구성된다.

각 층의 노드를 구별하기 위하여 출력층의 임의의 노드를 인덱스  $j$ 로 나타내고, 비교층의 임의의 노드를  $j$ 로 나타낸다. 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<sup>[2-10]</sup>.

입력층(F0)에서는  $M$ 차원의 입력벡터( $\mathbf{a}$ )를 상보부호화하여  $2M$  차원의 입력벡터( $\mathbf{I} = (\mathbf{a}, \mathbf{a}^c)$ )로 변환한다. 출력층(F2)에서는 입력벡터( $\mathbf{J}$ )가 상향연결벡터( $\mathbf{b}$ )를 통하여 출력층(F2)의 각 노드에 모이는데 이들

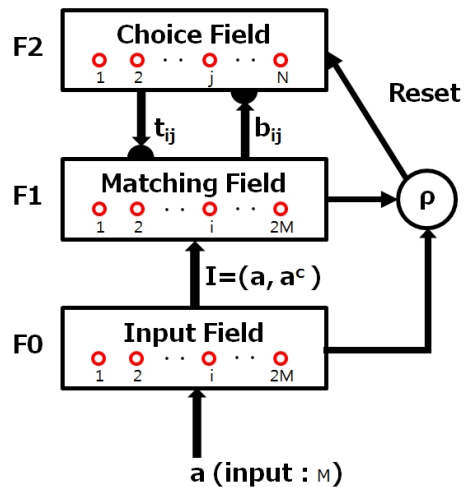


그림 1. 퍼지 ART의 구조  
Fig. 1. Architecture of Fuzzy ART

사이에 상호 경쟁을 통해 오직 하나의 노드( $J$ )가 선택된다. 비교층(F1)에서는 출력층(F2)에서 선택된 노드( $J$ )와 연결된 하향연결벡터( $t_j$ )와 입력벡터( $I$ ) 사이의 정합 테스트를 행한다. 이 값이 경계값( $\rho$ )을 넘으면 주어진 카테고리에 포함시키고 두 연결벡터를 갱신한다. 만약 정합 테스트가 경계값을 못 넘으면 출력층에서 선택된 노드( $J$ )가 리셋되고 다시 앞의 과정이 되풀이 하게 된다<sup>[2-10]</sup>.

**2.2 퍼지 ART 알고리즘**

**입력벡터:**

각각의 입력벡터  $\mathbf{a}$  는  $M$  차원 벡터  $a_1, a_2, \dots, a_M$ 이고, 각 요소  $a_i$ 는  $[0, 1]$  범위의 값을 갖는다. 입력벡터  $\mathbf{a}$  가 입력층(F0)에 제공되면 입력층은 식 (1)과 같은 상보부호화 입력벡터  $I$ 를 만든다<sup>[2-10]</sup>.

$$I = (\mathbf{a}, \mathbf{a}^c) = (a_1, a_2, \dots, a_M, a_1^c, a_2^c, \dots, a_M^c) \quad (1)$$

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

**연결강도의 초기화:**

비교층(F1)과 출력층(F2) 사이에 상향연결강도벡터( $\mathbf{b}$ )와 하향연결강도벡터( $\mathbf{t}$ )가 있는데 이를 구분하지 않고 연결강도벡터( $\mathbf{w}$ )로 표시하고 대표패턴이라 부른다. 연결강도벡터( $\mathbf{w}$ )는 다음 식 (2)와 같이 초기화된다<sup>[2-10]</sup>.

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

여기서  $w_{ij}$ 는 비교층(F1)  $i$ 번째 노드와 출력층(F2)  $j$ 번째 노드 사이의 상향과 하향연결강도벡터이다.

**승리 카테고리의 선택:**

출력층(F2)의  $j$ 번째 노드에서 입력벡터  $I$ 에 대한 선택 함수  $T_j(I)$ 가 다음 식 (3)과 같이 계산된다<sup>[2-10]</sup>.

$$T_j(I) = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (3)$$

여기서  $\alpha(0 < \alpha)$ 는 선택 파라미터이고, 연산자  $\wedge$

는 퍼지 AND 연산자이고, 정규화  $|\cdot|$  는 벡터의 크기를 나타내는 벡터 성분들의 합이다. 그리고 출력층은 연결강도를 통해 집중된 가장 큰 선택 함수  $T_j(I)$ 를 갖는 노드  $J$ 를 식 (4)와 같이 선택한다<sup>[2-10]</sup>.

$$T_J(I) = \max \{ T_j(I) : j = 1, 2, 3, \dots, N \} \quad (4)$$

만약 가장 큰 선택함수  $T_J(I)$ 가 2개 이상 존재할 때 가장 작은 인덱스를 갖는 카테고리가 선택된다<sup>[2-10]</sup>.

**경계 범위의 테스트:**

비교층에서는 입력벡터  $I$ 가 출력층 노드  $J$ 를 대표로 하는 카테고리 안에 소속되는지 정합 테스트 식 (5)을 이용하여 경계범위 테스트를 행한다<sup>[2-10]</sup>.

$$m_J = \frac{|I \wedge w_J|}{I} \geq \rho \quad (5)$$

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

위의 식 (5)를 만족하지 못하면 출력층의 노드  $J$ 를 경쟁에서 제외시키고 앞에서 행한 카테고리의 선택과정을 다시 시작한다. 한편 위의 식 (5)를 만족하면 연결강도벡터를 다음 단계에서 갱신하게 된다.

**연결강도벡터의 갱신:**

노드  $J$ 가 이미 한 번 이상 선택된 경우 기존 방식의 연결강도벡터 갱신에 식 (6)을 사용한다<sup>[2-10]</sup>.

$$w_J = (1 - \beta)w_J + \beta(I \wedge w_J) \quad (6)$$

여기서 파라미터  $\beta$ 는 학습률( $\beta \in (0, 1)$ )을 나타낸다.

**새로운 카테고리의 생성:**

노드  $J$ 가 이전에 한 번도 선택된 적이 없으면 입력 패턴을 대표패턴으로 받아들이고 식 (7)과 같이 연결강도를 입력패턴에 맞춘다<sup>[2-10]</sup>.

$$w_J = I \quad (7)$$

### III. 퍼지 ART의 학습 방법

#### 3.1 퍼지 ART의 기초 학습방법

퍼지 ART의 학습 방법은 대표패턴과 입력패턴의 특징이 어느 정도 유사한가를 기준으로 입력패턴을 인식하고 분류한다. 즉 입력패턴이 퍼지 ART에 들어 오면 어떤 대표패턴과 가장 크게 일치하는가를 판정한 후 가장 크게 일치하는 대표패턴의 값을 식 (6)과 같이 갱신한다. 이 식에서 학습 속도는 학습률( $\beta$ )에 따라 차이가 나는데 고속학습(FL)은  $\beta = 1$ 인 경우이고, 저속학습(SL)은  $0 < \beta < 1$ 인 경우이다. 고속수용저속부호화(FCSR)는 출력층의 선택된 노드가 사전에 수용되지 않은 노드일 때 고속학습을 하고 사전에 수용된 노드일 때 저속학습을 한다<sup>[2-8,10]</sup>.

고속수용저속부호화(FCSR)는 잡음 환경에서 고속 학습의 단점인 카테고리 증식을 억제하며 저속학습의 단점인 인식을 저하를 개선해주는 역할을 한다. 그러나 기존의 퍼지 ART의 학습 방법은 입력패턴에 잡음이 첨가되면 카테고리 수가 급격히 증가하고 인식이 떨어지는 문제가 발생한다<sup>[5-8,10]</sup>. 입력패턴이 임의의 카테고리에 포함될 때 대표패턴과 입력패턴의 일치도( $m_j$ ) (식 (5))의 크기와 관계없이 입력패턴이 대표패턴 갱신에 같은 비율(그림 2의 FCSR)로 참여하게 된다<sup>[10]</sup>. 결과적으로 대표패턴과 입력패턴의 거리(패턴 일치도)가 멀수록 입력패턴이 대표패턴의 갱신에 더 많은 영향을 주게 되어 과도한 학습의 원인이 된다. 이 문제를 개선한 방법이 가변학습(VL : Variable Learning)으로 그림 2와 같이 입력패턴과 대표패턴의 일치도( $m$ )에 따라 가변적으로 입력패턴을

대표패턴의 갱신에 반영한다<sup>[10]</sup>. 즉 대표패턴과 입력패턴의 거리가 멀수록 입력패턴이 대표패턴의 갱신에 참여하는 비율을 적게 하여 과도한 학습을 억제한다<sup>[10]</sup>.

식 (8)과 식 (9)는 각각 가변학습1(VL1)과 가변학습2(VL2)를 적용한 대표패턴을 갱신하는 식이다<sup>[10]</sup>.

$$w_j = (1 - \beta)w_j + \beta((1 - \mu_j)w_j + \mu_j I) \wedge w_j \tag{8}$$

$$w_j = (1 - \beta)w_j + \beta((1 - \mu_j^2)w_j + \mu_j^2 I) \wedge w_j \tag{9}$$

여기서 파라미터  $\mu_j$  ( $\mu_j \in [0,1]$ )는 학습 반영률을 나타내고 다음 식 (10)으로 정의된다.

$$\mu_j = \frac{m_j - \rho}{1 - \rho} \tag{10}$$

여기서 입력패턴과 대표패턴이 정확히 일치하면 학습 반영률( $\mu_j$ )은 1이 되고, 패턴 일치가 경계값( $\rho$ )에서 일어나면 학습 반영률( $\mu_j$ )은 0이 된다. 가변학습 1(VL1)은 그림 2와 같이 패턴 일치도가 1차식에 비례하여 학습에 반영되고, 가변학습2(VL2)는 2차식에 비례하여 학습에 반영된다<sup>[10]</sup>.

식 (8)과 식 (9)에서 학습 반영률( $\mu_j$ )이 1에 가까우면 입력패턴과 대표패턴이 매우 유사하다고 볼 수 있으므로 입력패턴을 연결강도 학습에 최대로 반영하고, 학습 반영률( $\mu_j$ )이 0에 가까우면 입력패턴과 대표패턴이 차이가 많이 난다고 볼 수 있어 입력패턴을 연결강도 학습에 최소로 반영하여 대표패턴이 급격하게 변하는 것을 막는다<sup>[10]</sup>.

#### 3.2 제안된 학습 방법

기존의 학습 방법인 고속수용저속부호화(FCSR)는 대표패턴과 입력패턴의 유사성(거리)의 정도와 관계없이 일률적으로 학습이 진행되었다. 가변학습(VL)은 대표패턴과 입력패턴의 유사성(거리)의 정도를 학습에 반영하여 대표패턴의 급격한 갱신을 억제하였다. 그러나 기존의 두 학습방법 모두 학습 시 대표패턴과 입력패턴의 공통 특징을 퍼지 AND 연산에 의해 추출하고 이것을 대표패턴의 갱신에 이용하게 되어 과도한 학습의 원인이 되고 있다.

제안된 방법은 기존의 가변학습(VL)을 개선한 것

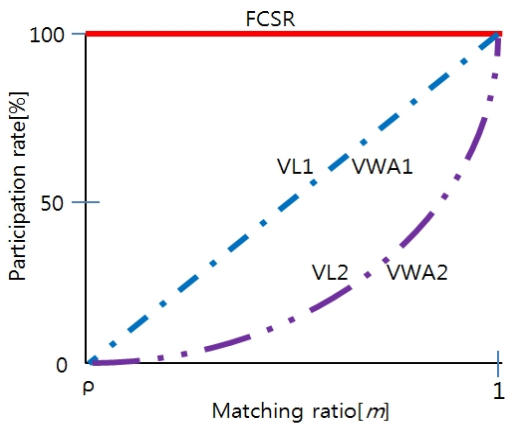


그림 2. 패턴 일치도에 따른 입력패턴의 학습 반영률  
Fig. 2. Participation rate of input pattern according to pattern matching ratio

으로 카테고리를 대표하는 대표패턴의 갱신 시 대표 패턴과 입력패턴의 유사성(거리)을 학습에 반영할 때 퍼지 AND 연산 대신에 가변적 가중 평균만을 적용한다. 이 방법은 퍼지 AND에 의한 과도한 학습을 억제할 수 있어서 카테고리 증식 문제를 완화하고 인식률 향상을 얻을 수 있다.

다음 식 (11)과 식 (12)는 각각 가변가중평균 1(VWA1)과 가변가중평균2(VWA2)를 나타낸다.

$$w_J = \mu_J I + (1 - \mu_J) w_J \quad (11)$$

$$w_J = \mu_J^2 I + (1 - \mu_J^2) w_J \quad (12)$$

가변가중평균1(VWA1)은 그림 2와 같이 패턴 일치도가 1차식에 비례하여 학습에 반영되고, 가변가중평균2(VWA2)는 2차식에 비례하여 학습에 반영된다. 학습 반영률( $\mu_J$ )이 1에 가까우면 입력패턴과 대표패턴이 매우 유사하다고 볼 수 있으므로 입력패턴을 연결강도 학습에 최대로 반영하고, 학습 반영률( $\mu_J$ )이 0에 가까우면 입력패턴과 대표패턴이 차이가 많이 난다고 볼 수 있어 입력패턴을 최소로 반영하여 두 패턴의 평균을 취한 값으로 대표패턴을 변경한다.

#### IV. 실험

##### 4.1 실험환경

그림 3은 실험에 이용한 영문 알파벳 ‘A’에서 ‘Z’까지 26개의 기본 입력패턴이다. 각각의 기본 입력패턴은 7×7 화소로 이루어져 있고 패턴의 검은 부분은 화소 값 1을 흰 부분은 화소 값 0을 갖도록 하였다.

입력패턴에 첨가되는 잡음은 가우시안 분포를 이루는 불규칙 잡음을 사용하였다. 그림 4는 PSNR 14[dB]의 가우시안 잡음이 첨가되고 그레이 레벨이 10% 감소한 테스트 입력패턴을 나타낸다.

가우시안 잡음의 양을 나타내는 PSNR을 다음 식 (13)과 같이 정의하여 사용한다<sup>[5-7,10]</sup>.



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



그림 4. 7×7 화소의 영문 알파벳 잡음 패턴  
Fig. 4. Alphabet noise patterns with 7×7 pixels

$$PSNR [dB] = \log_{10} \frac{1}{\delta^2} \quad (13)$$

여기서  $\delta^2$ 는 가우시안 잡음의 평균 전력을 나타내고, 가우시안 잡음의 평균 전력이 커질수록 PSNR 값이 작아진다.

영문 알파벳 패턴 [3-5]을 대상으로 기존의 학습 방법인 고속수용저속부호화(FCSR), 가변학습1(VL1) 및 가변학습2(VL2)와 제안된 학습 방법인 가변가중평균 1(VWA1)과 가변가중평균2(VWA2)의 학습 결과를 비교하였다. 알파벳의 기본 입력패턴을 26개의 카테고리로 분류하는데 필요한 최소 경계값( $\rho$ )은 0.919<sup>[5-7,10]</sup>이고, 위에 언급한 모든 학습 방법이 1회의 학습만으로 안정된 값을 갖기 때문에 잡음 없는 입력패턴에 대하여 1회 학습한 후 가우시안 잡음을 첨가한 알파벳 입력패턴 100 세트(2,600 패턴)를 테스트하였다. 또한 가우시안 잡음을 첨가하고 그레이 레벨을 0.1%씩 최대 10%까지 단조 감소시킨 알파벳 입력패턴 100 세트(2,600 패턴)를 테스트하여 카테고리 증식과 패턴 인식률을 조사하였다. 여기서 고속수용저속부호화(FCSR)와 가변학습1(VL1) 및 가변학습2(VL2)는 학습률  $\beta = 0.1$ 에서 비교하였다.

##### 4.2 실험결과

그림 5는 기존의 학습 방법인 고속수용저속부호화(FCSR), 가변학습1(VL1), 가변학습2(VL2)와 제안된 학습 방법인 가변가중평균1(VWA1), 가변가중평균2(VWA2)을 적용한 퍼지 ART의 학습에서 얻을 수 있는 패턴 인식률을 가우시안 잡음 환경에서 비교하였고 그림 6은 가우시안 잡음과 단조 감소 잡음 환경에서 비교하였다.

그림 5의 결과는 고속수용저속부호화(FCSR)가 PSNR 22[dB]부터 인식률이 저하하기 시작하고 가변학습1(VL1)은 18[dB]부터, 가변학습2(VL2)는 16[dB]부터 저하하기 시작한다. 한편 제안된 방법인 가변가중평균1(VWA1)과 가변가중평균2(VWA2)는 14[dB]부터 인식률이 저하되는 것을 알 수 있다.




그림 5. 가우시안 잡음에 따른 패턴 인식률  
Fig. 5. Pattern recognition rate according to Gaussian noise




그림 6. 가우시안 잡음과 단조 감소 잡음에 따른 패턴 인식률  
Fig. 6. Pattern recognition rate according to Gaussian noise and monotonically decreasing gray level

그림 6의 결과는 고속수용저속부호화(FCSR)가 PSNR 30[dB]부터 인식률이 저하하기 시작하고 가변 학습1(VL1)은 26[dB]부터, 가변학습2(VL2)는 24[dB]부터 저하하기 시작한다. 한편 제안된 방법인 가변가중평균1(VWA1)은 16[dB]부터, 가변가중평균 2(VWA2)는 14[dB]부터 인식률이 저하되는 것을 알 수 있다.

따라서 실험 결과를 분석해 보면 인식률 100[%]를 기준으로 제안된 학습 방법인 가변가중평균1(VWA1)과 가변가중평균2(VWA2)가 기존의 학습방법인 고속수용저속부호화(FCSR), 가변학습1(VL1), 가변학습 2(VL2) 보다 가우시안 잡음 환경에서 최소 2[dB] 이상의 잡음을 개선한 것으로 나타났고, 가우시안 잡음과 함께 그레이 레벨이 단조 감소하는 환경에서는 기존의 학습 방법 모두가 패턴 인식률이 현저히 떨어지지만 제안된 학습 방법은 변화가 미미한 것을 볼 수 있으며 기존의 학습방법보다 최소 8[dB] 이상의 잡음을 개선한 것으로 나타났다.

표 1은 기존의 학습 방법인 고속수용저속부호화(FCSR), 가변학습1(VL1), 가변학습2(VL2)와 제안된

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

Learning	PSNR [dB]										
	30	28	26	24	22	20	18	16	14	12	10
FCSR	26	26	26	26	26	52	93	180	435	1125	2077
VL1	26	26	26	26	26	26	28	73	253	867	1749
VL2	26	26	26	26	26	26	26	32	130	600	1517
VWA1	26	26	26	26	26	26	26	26	59	621	1787
VWA2	26	26	26	26	26	26	26	26	37	358	1441

학습 방법인 가변가중평균1(VWA1), 가변가중평균 2(VWA2)을 적용한 퍼지 ART의 학습에서 발생하는 카테고리 증식을 가우시안 잡음 환경에서 비교하였고, 표 2는 가우시안 잡음과 단조 감소 잡음 환경에서 비교하였다. 이 실험에서 알파벳 패턴의 종류가 26개 이므로 기본 카테고리가 26개 이다. 이보다 더 카테고리가 발생하는 것은 잡음의 영향으로 불필요한 카테고리가 발생한다는 것을 의미한다.

표 1의 결과는 기존의 학습 방법인 고속수용저속부호화(FCSR)가 PSNR 20[dB]부터, 가변학습1(VL1)이 18[dB]부터, 가변학습2(VL2)는 16[dB]부터 카테고리 증식이 시작된다. 한편 제안된 방법인 가변가중평균 1(VWA1)과 가변가중평균2(VWA2)는 14[dB]부터 카테고리 증식이 시작되는 것을 알 수 있다.

표 2의 결과는 기존의 학습 방법인 고속수용저속부호화(FCSR)가 PSNR 30[dB]부터, 가변학습1(VL1)이 26[dB]부터, 가변학습2(VL2)는 24[dB]부터 저하하기 시작한다. 한편 제안된 방법인 가변가중평균1(VWA1)은 16[dB]부터, 가변가중평균2(VWA2)는 14[dB]부터 카테고리 증식이 시작되는 것을 알 수 있다.

따라서 실험 결과를 분석해 보면 기본 카테고리 수

표 2. 가우시안 잡음과 단조 감소 그레이 레벨에 따른 카테고리 증식  
Table 2. Category proliferation according to Gaussian noise and monotonically decreasing gray level

Learning	PSNR [dB]										
	30	28	26	24	22	20	18	16	14	12	10
FCSR	27	28	32	40	51	68	115	221	542	1307	2174
VL1	26	26	27	29	35	45	53	104	341	1048	1926
VL2	26	26	26	27	30	36	46	77	265	870	1785
VWA1	26	26	26	26	26	26	26	26	88	780	1929
VWA2	26	26	26	26	26	26	26	26	69	687	1761



26을 기준으로 제안된 학습 방법인 가변가중평균 1(VWA1)과 가변가중평균2(VWA2)가 기존의 학습방법인 고속수용저속부호화(FCSR), 가변학습1(VL1), 가변학습2(VL2) 보다 가우시안 잡음 환경에서 최소 2[dB] 이상의 잡음을 개선한 것으로 나타났고, 가우시안 잡음과 함께 그레이 레벨이 단조 감소하는 환경에서는 기존의 학습 방법 모두가 카테고리 증식이 더 낮은 잡음에서 발생하기 시작하였고 제안된 학습 방법은 변화가 없는 것을 볼 수 있다. 따라서 기존의 학습 방법보다 최소 8[dB] 이상의 잡음을 개선한 것으로 나타났다.

### V. 결 론

이 연구는 비감독 시스템으로 동작하는 퍼지 ART 신경 회로망의 성능을 개선하였다. 잡음 환경에서 발생하는 퍼지 ART 신경 회로망의 카테고리 증식 문제를 완화하고 패턴 인식률을 높여줄 수 있는 학습 방법으로 가변가중평균을 제안하였다. 기존의 방법인 고속수용저속부호화(FCSR)는 입력패턴이 임의의 카테고리 내에 포함될 때 카테고리를 대표하는 대표패턴의 갱신이 입력패턴과의 거리(유사성)와 관계없이 고정된 학습률로 갱신되었고, 가변학습(VL)은 입력패턴과의 거리를 반영하여 거리에 따른 가변학습률로 갱신하여 카테고리 증식 문제와 패턴 인식률을 개선하였다. 그러나 두 방법 모두 학습 시 퍼지 AND에 의한 과도한 학습이 필수적으로 발생하여 카테고리 증식 문제와 패턴 인식 향상에 한계가 있었다. 제안된 방법은 기존의 가변학습(VL)을 개선하여 카테고리를 대표하는 대표패턴의 갱신 시 대표패턴과 입력패턴을 거리에 따른 가변적 가중 평균을 적용하여 과도한 학습을 억제하였고, 이로 인하여 카테고리 증식 문제를 완화하고 인식률 향상을 얻을 수 있었다.

실험을 통해 기존의 학습 방법인 고속수용저속부호화(FCSR)와 가변학습(VL) 보다 제안된 가변가중평균(VWA)이 잡음 환경에서 카테고리 증식 문제를 개선하였고, 패턴 인식률도 개선한 것으로 나타났다. 앞으로 잡음 환경에서 퍼지 ART의 카테고리 증식 문제와 패턴 인식률 저하를 향상시킬 필요가 있으며 자율 학습을 하는 시스템에 적용하는 연구가 필요하다.

### 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 and S. Grossberg, "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, S. Grossberg, N. Markuzon, J. Reynolds, and D. Rosen, "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of multidimensional maps," *IEEE Trans. Neural Networks*, vol. 3, pp. 698-713, Sept. 1992.

[4] G. A. Carpenter and M. N. Gjata, "Fuzzy ART choice functions," in *Proc. WCNN*, pp. 713-722, San Diego, USA, Jun. 1994.

[5] 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.

[6] 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. IEK*, vol. 32-B, no. 10, pp. 112-117, Oct. 1995.

[7] 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.

[8] 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.

[9] J. Lee, "Fuzzy-ARTMAP based multi-user detection," *J. KICS*, vol. 37A no. 3. pp. 172-178, Mar. 2012.

[10] C. J. Lee, B. Son, and H. S. Hong "Improvement of pattern recognition capacity of the fuzzy ART with the variable learning," *J. KICS*, vol. 38B, no. 12. pp. 954-961, Nov. 2013.

이 창 주 (Chang joo Lee)



1980년 2월 : 서울대학교 전자  
공학과 졸업  
1983년 2월 : 서울대학교 전자  
공학과 석사  
1996년 2월 : 서울대학교 전자  
공학과 박사  
1983년 3월~1985년 2월 : 한국  
방송공사 기술연구소 근무

1985년 3월~현재 : 동양미래대학교 정보통신공학과 교수  
<관심분야> 통신방식, 신경회로망, 패턴인식

손 병 희 (Byounghee Son)



1995년 2월 : 우석대학교 계산  
통계학과 졸업  
2003년 2월 : 연세대학교 전기  
공학과 석사  
2012년 2월 : 연세대학교 전기  
전자공학과 박사  
2012년 9월~2015년 2월 : 한솔  
로봇 기술연구소 소장

2013년 3월~2015년 2월 : 동양미래대학 정보통신과  
겸임교수

2015년 3월~현재 : 인하공업전문대학 컴퓨터시스템  
과 조교수

<관심분야> 융합 기술, 기계 학습, 인공 지능, 자동  
제어