

論文95-32B-10-12

퍼지 ART에서 雜音 餘裕度를 改善하기 위한 새로운 學習方法의 研究

(A Study on the New Learning Method to Improve Noise Tolerance in Fuzzy ART)

李昌柱 *, 李相研 **, 李忠雄 ***

(Chang Joo Lee, Sang Yun Lee, and Choong Woong Lee)

要 約

本論文에서는 퍼지 ART 회로에서 우수한 雜音 餘裕度를 갖는 새로운 學習方法을 提案한다. 기존의 퍼지 ART에서는 下向과 上向 連結强度ベタ 모두 같은 값으로修整된다. 이들 벡터는 入力ベタ와 自體의 連結强度ベタ 사이의 퍼지 AND 값에 의해修整되며 때문에 雜音 있는 入力ベタ의 學習에서 連結强度ベタ가過度하게修整되므로, 雜音 餘裕度가 작은 특성을 갖는다.

本研究에서는 이 문제점을 해결하기 위하여下向과上向 連結强度ベタ를 각각 다른 方法으로修整한다. 즉 雜音 있는 入力ベタ 때문에 連結强度ベ타가 급격히 변화하는 것을 막기 위하여下向 連結强度ベ타를 入力ベタ와自體 連結强度ベ타의 加重合에 의해修整되도록 하고, 安定된 시스템을 얻기 위하여上向 連結强度ベ타를 앞서修整된下向 連結强度ベ타와自體 連結强度ベ타 사이의 퍼지 AND 값에 의해修整되도록 한다. 實驗結果는 提案된 學習方法이 安定된 學習을 위해 필요한 學習回數를 늘리지 않고도 雜音 環境에서 카테고리增加問題를效果적으로 解決하고 있음을 보여준다.

Abstract

This paper presents a new learning method for a noise tolerant Fuzzy ART. In the conventional Fuzzy ART, the top-down and bottom-up weight vectors have the same value. They are updated by a fuzzy AND operation between the input vector and the current value of the top-down or bottom-up weight vectors. However, it can not prevent the abrupt change of the weight vector and can not achieve good performance for a noisy input vector.

To solve the problems, we update these vectors separately: To prevent the abrupt change, the top-down vector is updated using the weighted sum of the input vector and the current value of the top-down vector. To achieve stability, the bottom-up weight vector is updated using the fuzzy AND operation between the newly learned top-down vector and the current value of the bottom-up vector. Computer simulations show that the proposed method prominently resolves the category proliferation problem without increasing the training epoch for stabilization in noisy environments.

* 正會員, 東洋工業專門大學 電子通信科

(Dept. of Elec. Eng., Seoul Nat'l Univ.)

(Dept. of Elec. Comm., Dongyang Tech. Coll.)

接受日字: 1995年3月17日, 수정완료일: 1995年10月2日

** 正會員, 서울大學校 電子工學科

I. 序論

適應共鳴理論(ART: Adaptive Resonance Theory)은 생물체의 腦神經細胞의 學習과정을 연구하는 과정에서 1976년에 발표되었으며, 이것을 적용한 神經回路網 모델들이 계속해서 Carpenter와 Grossberg에 의해 발표되었다^{[11]-[17]}. 이들 ART모델들은 실시간 환경에서 監督者와 非監督者를 갖는 카테고리 學習과 패턴 認識을 행하고, 高速 또는 低速 學習을 통해 임의의 入力 열에 응답하여 안정된 認識 카테고리를 형성한다^{[3]-[7]}.

非監督 ART 모델로서, ART1, ART2, ART3, 퍼지 ART 등이 있다. ART1은 이진 入力패턴에만 응답해서 認識코드를 만드는 學習을 한다^{[11][2]}. ART2는 아날로그 入力패턴에도 응답해서 學習할 수 있도록 ART1의 短點을 극복했지만 入力패턴을 정규화하기 위해 구조가 복잡하다^[5]. ART3은 多層構造로서 분포하는 認識코드의 立列探求 또는 推測試驗을 수행한다^[5]. 퍼지 ART는 ART1과 같이 구조가 단순하면서도 이진이나 아날로그 入力패턴에 응답해서 카테고리 할 수 있는 學習능력이 있다^[5].

監督 ART 모델로서 이진 ARTMAP, 퍼지 ARTMAP 등이 있다. 이진 ARTMAP은 2개의 ART1을 기본으로 구성되고, 이진 入力패턴과 출력 패턴 사이의 카테고리 맵을 만들며 自體적으로 안정된다. 퍼지 ARTMAP은 퍼지 ART를 기초로 구성되며 이진 入力패턴뿐만 아니라 아날로그 入力패턴에 대해서도 동작한다^{[4][5]}.

學習 동안에, 이들 모델들은 代表패턴(連結强度ベタ)이 入力패턴(入力ベタ)과 代表패턴 사이의 일치 값에 의해 修整된다. 이와 같은 學習方法은 雜音이 없는 入力패턴의 學習에서는 잘 수행되지만 약간의 雜音에도 문제가 발생한다. 즉 雜音 있는 入力패턴을 계속 學習하면, 認識을 잘못하여 발생하는 불필요한 카테고리의 수가 급격히 증가한다. 따라서 雜音에 강한 새로운 學習方法이 필요하다.

본 논문에서는 퍼지 ART 모델을 대상으로 위의 문제점을 개선하는 새로운 學習方法을 提案한다. 제 2장에서는 기존의 퍼지 ART 學習方法에 대해 서술하고 雜音에 강한 새로운 學習方法을 提案한다. 제 3장에서는 提案된 學習方法을 적용한 퍼지 ART 알고리듬에 대해 서술하고, 제 4장에서는 시뮬레이션 結果에 대

해 서술하고, 마지막으로 제 5장에서 結論을 짓는다.

II. 퍼지 ART에서 學習方法

이 장에서는 먼저 퍼지 ART의 기본 구조에 대해 간략히 설명하고 뒤이어 퍼지 ART의 기존 學習方法과 提案된 學習方法에 대해 서술한다.

그림 1은 퍼지 ART의 구조를 나타낸다. 이 모듈은 入力층(F0), 比較층(F1), 認識층(F2) 등 3층으로 구성되어 있으며 각각 2M, 2M, N개의 노드를 갖고 있다. F1층과 F2층 사이에는 下向連結强度와 上向連結强度로 연결돼 있다. F0층은 入力ベタ a 를 相補符號化 入力ベタ a^c 로 변환하고, F1층은 下向연결 베터와 入力ベタ a 사이의 일치 정도를 비교하고, F2층은 上向連結强度를 통해 집중된 가장 큰 값을 갖는 노드를 선택한다^{[5]-[7]}.

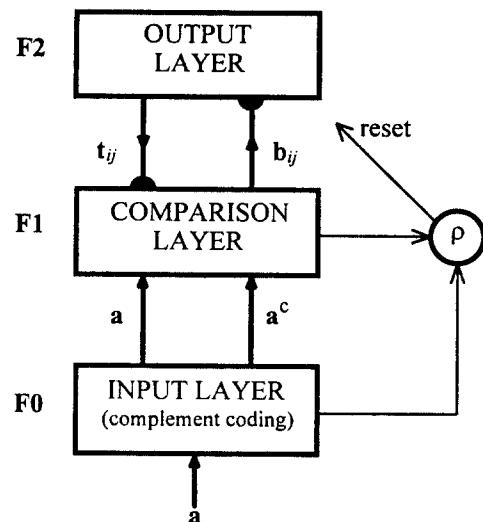


그림 1. 퍼지 ART의 構造

Fig. 1. Architecture of Fuzzy ART.

기존 퍼지 ART에서 學習 중에 선택된 F2층의 노드 j 와 관련된 下向連結强度ベタ t_j 및 上向連結强度ベタ b_j 의 修整은 다음 식과 같이 동일한 方法을 사용한다^[5].

$$t_j^{(new)} = \beta (I \wedge t_j^{(old)}) + (1 - \beta) t_j^{(old)} \quad (1)$$

$$b_j^{(new)} = \beta (I \wedge b_j^{(old)}) + (1 - \beta) b_j^{(old)} \quad (2)$$

여기서 β 는 $(0, 1]$ 범위를 갖는 學習率 파라미터이다. 위의 下向連結强度ベタ와 上向連結强度ベ타는 같은 값을 갖기 때문에 어느 것이나 노드(또는 카테고리) J 를 代表하는 代表패턴으로 볼 수 있다. $\beta = 1$ 인 高速學習(fast learning)의 경우 代表패턴은 入力ベタ와 連結强度ベ타 사이의 퍼지 AND값만으로 修整되므로 빠르게 안정되지만 入力ベタ에 의해 직접 영향을 받아 급격한 변화를 갖는다. 따라서 雜音 있는 入力ベタ를 學習할 때, 잘못 認識하여 원하지 않는 새로운 카테고리가 급격히 증가한다. $0 < \beta < 1$ 인 低速學習(slow learning)의 경우 代表패턴은 入力ベタ의 영향을 적게 받지만 더디게 안정되는 문제가 있다. 위의 두 學習方法을 절충한 高速拘束 低速再符號(fast-commit slow recode) 方法은 非拘束 노드(uncommitted node)에 대해서는 高速 學習을 하고 拘束 노드(committed node)에 대해서는 低速 學習을 한다. 이 方法은 代表 패턴이 雜音 있는 入力ベタ의 영향을 적게 받으면서 빠르게 안정화 할 수 있다^[5]. 그러나 이상 서술한 方法들은 雜音환경에서 원하지 않는 카테고리 증가 문제를 효과적으로 해결할 수 없다. 따라서 우리는 새로운 學習方法을 提案 한다.

提案된 學習方法은 노드 $J \neq$ 非拘束 노드이면 連結强度ベタ를 高速學習으로 修整하고, 拘束 노드이면 두 連結强度ベ타를 각각 다음과 같은 方法으로 修整한다. 즉 下向 連結强度ベタ(下向패턴) t_j 는 다음 식(3)과 같이 入力ベ터와 自體ベ터의 加重合에 의해 修整되고, 上向 連結强度ベ터(上向패턴) b_j 는 다음 식(4)와 같이 앞서 修整된 下向 連結强度ベ터와 自體ベ터 사이의 퍼지 AND값에 의해 修整된다.

$$t_j^{(new)} = \eta \mathbf{I} + (1 - \eta) t_j^{(old)} \quad (3)$$

$$b_j^{(new)} = t_j^{(new)} \wedge b_j^{(old)} \quad (4)$$

여기서 η 는 $(0, 1]$ 범위를 갖는 學習率 파라미터이다. 식(3)의 加重合은 雜音 있는 入力ベ터에 대해 下向 連結强度ベ터의 갑작스런 변화를 막는 완충 역할을 하고, 식(4)의 퍼지 AND는 下向 連結强度ベ터에 의해 上向 連結强度ベ터가 불안정하게 되는 것을 막는다. 提案된 學習方法에서는 上向 連結强度ベ터만이 단조 감소하여 안정화되므로 이 베터를 代表패턴으로 간주한다. 이와 같이 提案된 學習方法은 雜音 있는 入力ベ터에

의한 連結强度ベ터의 급격한 변화를 막을 수 있어 雜音 환경에서 카테고리 증가 문제를 효과적으로 해결할 수 있다.

III. 提案된 學習方法을 利用한 퍼지 ART 알고리듬

다음은 提案된 學習方法을 이용한 퍼지 ART 알고리듬을 보여준다. 이 알고리듬의 중요 점은 連結强度ベ터를 새로운 學習方法으로 修整하는 것이다.

連結强度의 初期化: 連結强度는 다음과 같이 初期化된다.

$$b_{ij} = t_{ij} = 1, \text{ for } 1 \leq i \leq 2M, \text{ and } 1 \leq j \leq N \quad (5)$$

여기서 b_{ij} 와 t_{ij} 는 F1층의 j 번째 노드와 F2층의 j 번째 노드 사이의 上向과 下向 連結强度이다.

새로운 入力ベ터의 提供: 만약 $\mathbf{a} = (a_1, a_2, \dots, a_M)$ 가 $[0, 1]$ 범위의 값을 갖는 원래의 入力ベ터가 제공되면, F0층은 아래 식과 같이 相補符號化를 통해 실질적인 相補符號化 入力ベ터 \mathbf{I} 를 만든다.

$$\mathbf{I} = (\mathbf{a}, \mathbf{a}^c) = (a_1, a_2, \dots, a_M, a_1^c, a_2^c, \dots, a_M^c) \quad (6)$$

여기서 $a_k^c = 1 - a_k$ 이고, 相補符號化 入力ベ터 \mathbf{I} 는 $2M$ 차원을 갖는다. 이 相補符號化 入力ベ터 \mathbf{I} 가 F1층에 공급된다.

카테고리의 選擇: 入力ベ터 \mathbf{I} 에 대해 F2층의 j 번째 노드에서 다음 식의 選擇函數 $t_j(\mathbf{I})$ 가 계산된다.

$$T_j(\mathbf{I}) = \frac{|\mathbf{I} \wedge \mathbf{b}_j|}{\alpha + |\mathbf{b}_j|} \quad (7)$$

여기서 α 는 $(0, \infty)$ 범위를 갖는 選擇 파라미터이고, \mathbf{b}_j 는 F2 층의 j 번째 노드로 집중하는 上向 連結强度로 이루어진 베터이고, 퍼지 AND기호 \wedge 는 $(x \wedge y) i \equiv \min(x_i, y_i)$ 로 정의되고, 정규화 기호 $|\cdot|$ 는 M 차원 베터 \mathbf{x} 에 대하여 식 $|\mathbf{x}| = \sum_{i=1}^M |x_i|$ 로 정의된다. 그리고 최대 選擇函數 값을 갖는 노드(또는 카테고리) J 가 F2 층에서 選擇된다.

境界範圍의 테스트: 아래 식을 이용하여 境界範圍 테스트를 행한다.

$$\frac{|\mathbf{I} \wedge \mathbf{t}_j|}{|\mathbf{I}|} \geq \rho \quad (8)$$

여기서 ρ 는 [0, 1] 범위를 갖는 境界 파라미터이고, t_j 는 F2층의 J 번째 노드로부터 放射하는 下向 連結強度로 이루어진 벡터이다. 식 (8)을 만족하면 連結强度 벡터의 修整을 행하고, 만족하지 못하면 J 번째 노드를 경쟁에서 제외시키고 새로운 최대 選擇函數 값을 갖는 노드를 다시 찾는다. 이 과정은 식 (8)을 만족하는 새로운 J 번째 노드가 選擇될 때까지 계속된다.

連結强度ベクター의 修整: 提案된 學習方法에서, 非拘束 노드에 대하여 高速學習을 하고, 拘束 노드에 대하여 각각의 連結强度 벡터 t_j 와 b_j 는 각각 앞의 식 (3)와 (4)에 따라 學習한다. 그런데 输入ベク터가 서서히 단조 증가할 때, 代表폐턴(여기서 b_j 를 나타냄)이 선택된 카테고리 領域밖에 놓이는 문제가 발생한다. 이 문제를 해결하기 위하여 아래 식과 같은 境界 領域 테스트를 한다.

$$\frac{|\mathbf{b}_j^{(new)} \wedge \mathbf{t}_j^{(new)}|}{|\mathbf{I}|} \geq \rho \quad (9)$$

만약 식 (9)의 境界 領域 테스트를 만족하지 못하면 b_j 는 선택된 카테고리 領域밖에 존재하게 되므로 아래 식과 같이 b_j 를 다시 修整하여 카테고리 領域 안에 존재하도록 한다.

$$\mathbf{b}_j^{(new)} = \mathbf{t}_j^{(new)} \quad (10)$$

IV. 實驗 및 結果

이 장에서 우리는 7×7 흑백 畫素를 갖는 26개의 알파벳 A-Z를 기본 输入폐턴으로 사용하여 실험하였다. 이 输入폐턴을 그림 2에 보여준다.



그림 2. 基本 Input폐턴

Fig. 2. Original input patterns.

입力폐턴의 畫素 값은 흑을 1.0으로 백을 0.0으로 했고, 각 畫素의 흑백 구별은 문턱값(threshold value) 0.5를 기준으로 했다. 선택 파라미터 α 는 값 0.0001로 정했다. F1층의 노드 수는 相補符號化 入力ベク터의 차원과 같도록 98개로 정했고, F2층의 노드 수는 學習 할 때 拘束 노드 수가 포화되지 않도록 충분히 크게 하였다.

실험 결과는 提案된 方法(NEW: $\eta = 0.85$)을 기준의 學習 方法인 高速學習(FL: fast learning, $\beta = 1.0$), 低速學習(SL: slow learning, $\beta = 0.85$), 高速拘束 低速再符号(FCSR: fast commit slow recode, $\beta = 1.0$ 과 0.85) 方法들과 비교하였다. 표 1은 雜音 없는 기본 输入폐턴 A-Z들을 學習하여 14개와 26개의 안정된 認識 카테고리를 얻는데 필요한 최소 境界값과 반복 學習 數를 나타낸다. 여기서 반복 學習 數는 리셋 신호가 발생하지 않을 때까지 주어진 输入폐턴들을 되풀이 學習한 回數이다. 이 결과를 보면 提案된 方法은 3회 이하의 學習으로 안정되므로 기존의 方法들과 유사한 정도로 빠르고 안정된 學習을 한다.

표 1. 安定된 認識 카테고리 14개와 26개를 만드는데 필요한 最小 境界값과 반복 學習 數

Table 1. Minimum vigilance value and the number of training for stable recognition categories 14 and 26.

Classified Categories	Training Epochs/Min. Vigilance Value(ρ)			
	FL	SL	FCSR	NEW
14	1/0.7150	4/0.5920	3/0.7150	3/0.7520
26	1/0.9190	3/0.9190	1/0.9190	1/0.9190

그림 3과 그림 4는 표 1에서 각각 14와 26의 안정된 認識 카테고리를 얻은 후 雜音 있는 输入폐턴을 學習 할 때마다 발생하는 원하지 않는 카테고리의 累積된 數를 나타낸다. 여기서 雜音 있는 输入폐턴은 매 學習 마다 완전한 기본 输入폐턴에 無作爲로 한 개의 畫素 값을 反轉시켜 만든 것이다. 이 결과를 보면 기존의 學習方法들은 雜音 输入폐턴에 대해 원하지 않는 카테고리가 크게 증가하고 있음을 보여준다. 한편 提案된 學習方法은 원하지 않는 카테고리가 그림 3에서는 2개 발생하고 그림 4에서는 전혀 발생하지 않았다.

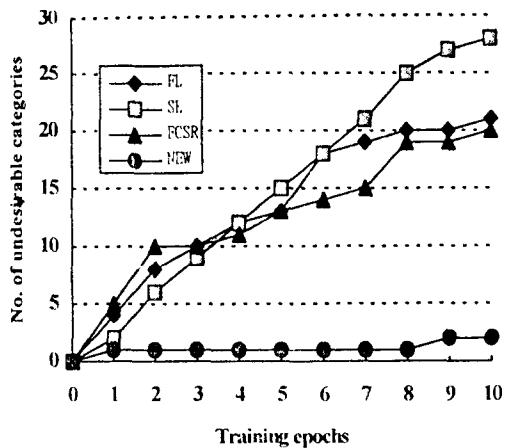


그림 3. 그림 1에서 14개의 안정된 카테고리를 얻은 후 雜音 输入 패턴을 學習할 때 學習回數에 따른 원치 않는 카테고리의 累積 발생 個數의 比較

Fig. 3. Comparison of undesired categories according to the number of training for a set of noisy input patterns applied to the 14 categories in the Table 1.

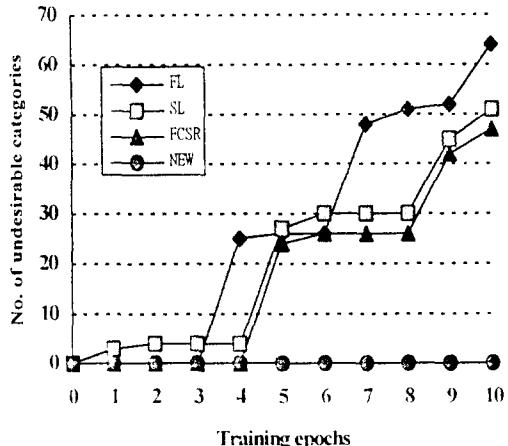


그림 4. 그림 1에서 26개의 안정된 카테고리를 얻은 후 雜音 Input 패턴을 學習할 때 學習回數에 따른 원치 않는 카테고리의 累積 발생 個數의 比較

Fig. 4. Comparison of undesired categories according to the number of training for a set of noisy input patterns applied to the 26 categories in the Table 1.

이상의 실험 결과를 보면 提案된 方法은 雜音이 없는

환경에서 빠르고 안정된 認識 능력을 가지면서 雜音이 있는 환경에서 카테고리 증가 문제를 다른 어떤 方法보다 잘 解決하고 있음을 보여 주고 있다.

V. 結論

本研究에서는 퍼지 ART에서 보다 좋은 雜音 餘裕度를 갖기 위하여, 下向 및 上向連結强度ベタ를 각각 다른 方法으로 學習하는 方法을 提案했다. 즉 下向連結强度ベタ는 入力패턴과 下向패턴의 加重合에 의해 修整하였고 上向連結强度ベタ는 下向패턴과 上向패턴 사이의 퍼지 AND에 의해 修整하였다. 따라서 下向連結强度ベタ의 修整을 통해 雜音이 있는 入力패턴의 영향을 완충하였고, 上向連結强度ベ타의 修整을 통해 안정된 上向패턴(代表패턴)을 얻을 수 있었다. 提案된 方法은 부가적인 計算 과정을 갖지만 既存의 方法과 유사한 정도로 빠르고 안정된 學習을 하였으며 특히 雜音이 있는 환경에서 既存의 學習方法들이 가지고 있는 카테고리 增加 問題를 매우 效果的으로 解決하였다.

참 고 문 헌

- [1] G. A. Carpenter and S. 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.
- [2] R. P. Lippmann: "An Introduction to computing with neural nets". *IEEE ASSP Magazine*, April, pp. 4-22, 1987.
- [3] G. A. Carpenter, S. Grossberg, and D. B. Rosen: "ART 2-A: An Adaptive Resonance Algorithm for Rapid Category Learning and Recognition" *Neural Networks*, Vol. 4, pp. 493-504, 1991.
- [4] G. A. Carpenter, S. Grossberg, and J. H. Reynolds: "ARTMAP: Supervised Real-Time Learning and Classification of Nonstationary Data by a Self-Organizing Neural Network". *Neural Networks*, Vol. 4, pp. 565-588, 1991.
- [5] 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, pp. 759-771, 1991.
- [6] G. A. Carpenter, M. N. Gjaja: "Fuzzy ART Choice Functions", *WCNN*, San Diego, 1B, pp. 713-722, 1994.
- [7] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen: "Fuzzy ARTMAP: An adaptive resonance architecture for incremental learning of analog maps", *WCNN*, San Diego, 3B, pp. 309-314, 1994.

저자소개



李昌柱(正會員)

1957年 1月 31日生, 1980年 2月 서울大學校 電子工學科 卒業(工學士), 1983年 2月 서울大學校 大學院 電子工學科 卒業(工學碩士), 1988年 3月 ~ 現在 서울大學校 大學院 電子工學科 博士課程, 1983年 3月 ~ 1985年 3月 KBS 技術研究所 研究員, 1995年 3月 ~ 現在 東洋工業専門大學 電子通信科 副教授, 主 관심 분野는 神經回路網, 패턴 認識, 디지털 通信 등임.



李相研(正會員)

1961年 2月 11日 生, 1983年 2月 韓國航空大學 電子工學科 卒業(工學士), 1985年 2月 서울大學校 大學院 電子工學科 卒業(工學 碩士), 1988年 9月 ~ 現在 서울大學校 大學院 電子工學科 博士課程, 1983年 3月 ~ 1985年 3月 金星電氣(株) 研究所 研究員, 1985年 4月 ~ 1994年 10月 (주)LG情報通信 研究所 研究員, 主 관심 분野는 디지털 通信, 神經回路網 등임.

李忠雄(正會員) 第31卷 B編 第7號 參照
현재 서울대학교 전자공학과 교수