

論文96-33B-9-12

Fuzzy ARTMAP 神經回路網의 패턴 認識率 改善에 관한 研究

(A Study on the Improvement of Fuzzy ARTMAP for Pattern Recognition Problems)

李在 高 *, 全 鍾 老 **, 李 忠 雄 *

(Jae Sul Lee, Jong Ro Jeon, and Choong Woong Lee)

요 약

本 論文에서는 퍼지 ARTMAP 神經回路網에서 雜音環境에 강한 새로운 學習方法을 提案한다. 既存의 퍼지 ARTMAP에서는 連結強度의 學習과정에서 入力벡터와 連結強度벡터 사이의 퍼지 AND 演算을 이용하여 連結強度를 修整한다. 따라서 入力벡터에 雜音이 있는 경우에는 그 雜音成分에 의해서 連結強度벡터가 過度하게 修整되므로, 불필요한 카테고리가 發生하고 入力패턴의 認識率이 저하된다. 本 研究에서는 이러한 問題點을 해결하기 위하여 連結強度를 上,下向으로 분리한 다음 下向 連結強度는 入力벡터와 下向 連結強度의 加重平均으로 學習하여 過度한 변화를 방지하고, 上向 連結強度는 更新된 下向 連結強度와 上向 連結強度 사이의 퍼지 AND 演算에 의해 學習하여 빠르고 安定된 學習이 이루어지도록 한다. 電算模擬實驗 結果는 提案된 學習方法이 불필요한 카테고리가 生成되는 것을 抑制하면서도 認識率을 向上시키는 것을 보여준다.

Abstract

In this paper, we present a new learning method for the fuzzy ARTMAP which is effective for the noisy input patterns. Conventional fuzzy ARTMAP employs only fuzzy AND operation between input vector and weight vector in learning both top-down and bottom-up weight vectors. This fuzzy AND operation causes excessive update of the weight vector in the noisy input environment. As a result, the number of spurious categories are increased and the recognition ratio is reduced. To solve these problems, we propose a new method in updating the weight vectors: the top-down weight vectors of the fuzzy ART system are updated using weighted average of the input vector and the weight vector itself, and the bottom-up weight vectors are updated using fuzzy AND operation between the updated top-down weight vector and bottom-up weight vector itself. The weighted average prevents the excessive update of the weight vectors and the fuzzy AND operation renders the learning fast and stable. Simulation results show that the proposed method reduces the generation of spurious categories and increases the recognition ratio in the noisy input environment.

I. 서 론

適應共鳴理論(ART : adaptive resonance theory)

* 正會員, 서울大學校 電氣工學部

(School of Electrical Engineering, Seoul National University)

** 正會員, 東洋工業專門大學 電算事務自動化科

(Dept. of Computer and Office Automation, Dong-yang Technical College)

接受日字:1996年6月27日, 수정완료일:1996年9月6日

을 이용한 神經回路網 모델은 既存의 神經網 모델과는 달리 새로운 情報를 추가로 學習할 경우에 神經回路網 전체를 再學習할 필요가 없는 모델로서, Grossberg와 Carpenter 등에 의해 발표되었다^[1]. 이 모델은 끊임 없이 변화하는 環境 하에서 既存에 學習된 내용이 새로운 學習에 의해 지워지지 않으면서도, 새로운 지식을 실시간으로 빠르고 안정되며 일관성 있는 方法으로 學習, 통합할 수 있는 구조이다^[2]. 지금까지 발표된 여러 종류의 ART 모델 중에서 퍼지 ARTMAP은 監督 訓練 모델로서, 2개의 퍼지 ART 神經回路網(ART_a,

ART_b)과 그들을 連結하는 맵필드로 구성되어 있으며, 아날로그 入力에 대하여 동작할 수 있다^{[3]-[5]}.

퍼지 ARTMAP에서는 訓練期間 동안에 ART_a에는 認識, 분류하고자 하는 패턴이 入力되고, ART_b에는 그 入力패턴에 대한 올바른 추정패턴이 入力된다. ART_b는 ART_a가 올바른 패턴을 추정하기 위해 學習하는 과정을 監督한다. ART의 學習과정은 주어지는 入力패턴과 ART 내에 기억되어 있는 代表패턴과의 一致도에 의해서 代表패턴이 更新되도록 동작하고, 이 代表패턴은 주어진 入力を 하나의 代表되는 패턴(카테고리)으로 분류하는 역할을 한다.

이와 같은 學習方法은 入力패턴에 雜音이 없는 環境에서는 잘 동작하지만, 入力패턴에 雜音이 포함되어 있는 경우에는 代表패턴이 급격히 손상되어 원하지 않는 카테고리가 발생하거나 패턴의 認識率이 저하된다는 問題點이 있다^{[2],[6]}. 本 論文에서는 이러한 問題點을 해결하기 위한 方法을 提示한다. 2 장에서 既存의 퍼지 ARTMAP의 구성과 동작에 대하여 서술하고, 3 장에서는 雜音環境에 강한 새로운 學習方法에 대하여 설명한다. 4 장에서는 電算模擬實驗을 통하여 既存의 방식에 대한 提案된 學習方法의 性能改善을 확인하고, 5 장에서 결론을 맺는다.

II. 퍼지 ARTMAP 神經回路網의 구성과 동작^[5]

그림 1은 퍼지 ARTMAP 神經回路網의 구조를 나타낸 것이다. 퍼지 ARTMAP은 두 개의 퍼지 ART 神經回路網과, 이들 사이를 연결하는 學習網인 맵필드 F^{ab}로 구성되어 있다. ART_a에서는 認識學習이 이루어지며 認識하고자 하는 패턴인 벡터 **a**가 入力되고, ART_b는 監督 神經回路網으로서 **a**로부터 추정되어야 하는 올바른 패턴인 벡터 **b**가 入力된다.

벡터 **a**, **b**의 원소의 수는 각각 M_a, M_b이며, 모두 [0,1] 사이의 값을 가진다. ART_a와 ART_b는 모두 入力층인 F₀, 비교층인 F₁, 출력층인 F₂로 구성되어 있으며, 각 층은 각각 2M_a와 2M_b, 2M_a와 2M_b, 그리고 N_a와 N_b 개의 노드를 가진다. F₀ 층은 **a**, **b**를 相補符號化 前處理를 하고, F₁ 층은 入力와 F₂ 층의 패턴 認識 결과가 一致하는 정도인 x^a와 x^b를 출력한다. F₁ 층의 모든 노드와 F₂ 층의 j번째 카테고리(노드)를 연결하는 連結強度 벡터 **w**_j는 入力패턴을 하나의 패턴으

로 분류(카테고리화)하는데 필요한 계산과 一致度 검사를 위한 계수를 제공하며, 入力패턴이 하나의 패턴(카테고리)으로 對應되는 관계(代表패턴이라고 한다)를 나타낸다.

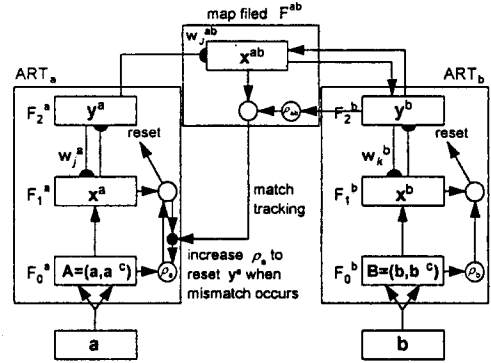


그림 1. 퍼지 ARTMAP의 구성도
Fig. 1. The architecture of a fuzzy ARTMAP system.

F₂ 층의 각 노드는 入力패턴이 속하게 되는 카테고리를 표현하게 된다. 예를 들어서 ART_a에 주어진 入力패턴에 대하여 F₂^a 층의 j 번째 노드의 출력이 최대가 되어 選擇되었다면 그 入力は j 번째 카테고리에 속하는 것으로 간주된다. 그 결과 F₂^a 층의 출력 y^a는 다음 식과 같이 정의된다.

$$y^a = \{y_j^a\}, y_j^a = 1 \text{ and } y_{j \neq j}^a = 0, j = 1, \dots, N_a \quad (1)$$

맵필드 F^{ab}는 ART_b가 ART_a의 學習을 監督할 수 있는 채널을 제공한다. $w_j^{ab} \equiv (w_{j1}^{ab}, \dots, w_{jN_a}^{ab})$ 는 F₂^a 층의 j 번째 카테고리라 이것이 추정하는 ART_b의 카테고리로서의 대응(map)관계를 나타낸다. 맵필드의 出力벡터 $x^{ab} = (x_1^{ab}, \dots, x_{N_a}^{ab})$ 는 이 추정의 정확도를 나타낸다.

퍼지 ARTMAP 神經回路網은 訓練期間 동안에 다음과 같은 指導學習이 이루어진다. ART_a에는 認識하고자 하는 入力패턴 $a \equiv (a_1, \dots, a_{M_a})$ 가 入力되고, ART_b에는 이에 대응하는 정확한 추정패턴인 $b \equiv (b_1, \dots, b_{M_b})$ 가 入力된다. ART_a에서는 入力 **a**를 相補符號化 하여 그 결과인 $A = (a, a^c)$ 를 F₁^a 층으로 出力한다. 여기서 相補符號化는 다음 식과 같이 정의된다.

$$a^c \equiv (1 - a_1, \dots, 1 - a_{M_a}) \quad (2)$$

F_1^a 층에 入力된 \mathbf{A} 와 $F_1^a \rightarrow F_2^a$ 로 연결되는 連結強度 \mathbf{w}_j^a 에 의하여 F_2^a 층의 각 노드에서 다음과 같은 選擇 함수 T_j 를 발생시킨다.

$$T_j = \frac{|\mathbf{A} \wedge \mathbf{w}_j^a|}{\alpha + |\mathbf{w}_j^a|} \quad (3)$$

여기서 \wedge 는 퍼지 AND 연산자로서 두 개의 벡터 \mathbf{x} , \mathbf{y} 에 대해서

$$(\mathbf{x} \wedge \mathbf{y})_i = \min(x_i, y_i) \quad (4)$$

와 같이 정의되고, 양수 α 는 選擇 파라미터로서 F_2^a 의 노드 중 유일한 최대값이 발생하도록 하며, $|\cdot|$ 연산자는 벡터성분의 합으로 정의된다. F_2^a 층은 다음 식에 의해서 選擇함수가 최대가 되는 최적의 카테고리 J 를 選擇한다.

$$T_j = \max \{T_j; j=1, \dots, N_a\} \quad (5)$$

選擇된 카테고리는 連結強度 \mathbf{w}_j^a 를 통해 다시 F_1^a 층으로 전달되어 入力패턴과 一致하는 정도로써 그 選擇의 適合성을 검증하는 정합 테스트를 행한다. 즉, F_2^a 층에서 選擇된 카테고리에 J 에 대해,

$$\frac{|\mathbf{x}^a|}{|\mathbf{A}|} = \frac{|\mathbf{A} \wedge \mathbf{w}_j^a|}{|\mathbf{A}|} \geq \rho_a \quad (6)$$

이면 入力패턴은 그 카테고리로 인정되지만, 그렇지 않으면 식 (5), (6)을 만족하는 새로운 카테고리를 선정하는 작업이 再開된다. 여기서 ρ_a 는 $[0,1]$ 사이의 값을 갖는 境界 파라미터로서, 入力 벡터가 하나의 카테고리로 분류되기 위하여 유사한 정도의 臨界값을 나타낸다. 따라서 이 값을 크게 설정할수록 入力 벡터를 분류하는 카테고리의 수는 증가하며, 하나의 카테고리가 포함하는 領域은 감소한다. ρ_a 는 하나의 入力 \mathbf{a} 가 주어질 때마다 초기값인 $\bar{\rho}_a$ 를 가지며, 아래에서 설명할 一致追跡 과정에서 그 값이 증가한다.

이와 같은 方法으로 ART_a 에서는 J 번째 카테고리가 選擇되어 \mathbf{y}^a 가 출력되고, ART_b 에서는 K 번째 카테고리가 選擇되어 \mathbf{y}^b 가 출력된다. 맵필드에서는 F_2^a 층의 출력 \mathbf{y}^a 가 ART_b 의 특정 패턴을 추정하도록 學習된 \mathbf{w}_j^{ab} 를 통하여 \mathbf{y}^a 에 의해 추정된 패턴과 \mathbf{y}^b 가 一致하는 정도인 $\mathbf{x}^{ab} = \mathbf{y}^b \wedge \mathbf{w}_j^{ab}$ 를 출력한다. 만일 一致도가 어느 한계 이하가 되면, 즉

$$|\mathbf{x}^{ab}| = |\mathbf{y}^b \wedge \mathbf{w}_j^{ab}| < \rho_{ab} |\mathbf{y}^b| \quad (7)$$

이면 ART_a 에서 추정된 패턴은 指導監督을 행하는 ART_b 에서 提示하는 올바른 패턴과 不一致하는 것으로 간주되어 다음과 같은 一致追跡(match tracking) 과정이 시작된다. 여기서 ρ_{ab} 는 $[0,1]$ 사이의 값을 가지는 맵필드 境界 파라미터이다.

一致追跡 과정에서 맵필드는 選擇된 카테고리 J 가 식 (6)을 만족하지 못하도록 境界값 ρ_a 를 증가시킴으로써 ART_a 로 하여금 J 가 아닌 다른 카테고리를 選擇하도록 제어한다. 만일 既存의 카테고리 중에서 만족하는 카테고리가 없을 경우에는 새로운 하나의 카테고리가 생성될 수 있다.

하나의 入力에 대하여 최적의 카테고리가 選擇되면, 連結強度 \mathbf{w}_j^a 는 다음의 식에 의해서 更新된다.

$$\mathbf{w}_j^{a(new)} = (1 - \beta) \mathbf{w}_j^{a(old)} + \beta (\mathbf{A} \wedge \mathbf{w}_j^{a(old)}) \quad (8)$$

여기서 β 는 $(0,1]$ 사이의 값을 갖는 學習率 파라미터이다. 식 (8)에서 $\beta = 1$ 이면 高速學習(FL ; fast learning)이라고 하고, $\beta < 1$ 이면 低速學習(SL ; slow learning)이라고 한다. 하나의 카테고리가 최초로 選擇된 경우에는 高速學習을, 그 이후에 다시 選擇되었을 때에는 低速學習을 하는 경우에는 高速受容 低速符號化(FCSR ; fast commit slow recode)라고 한다. 맵필드 連結強度 \mathbf{w}_j^{ab} 는 최초에는 모든 성분이 1로 초기화되며, ART_a 에서 選擇된 노드 J 가 최초로 選擇되어 ART_b 의 노드 K 를 추정하게 되면 $j=J$, 그리고 $k=K$ 를 제외한 모든 성분 w_{jk}^{ab} 은 0으로 學習된다.

III. 加重平均을 이용한 Fuzzy ARTMAP의 學習

앞장에서 설명한 퍼지 ARTMAP은 入力패턴에 雜音이 없는 環境에서는 入力패턴을 분류하는 카테고리의 수를 最小化하면서도 그 카테고리가 정확한 패턴을 추정하도록 학습된다. 그러나, 入力패턴에 雜音이 혼재되어 있는 경우에는 카테고리의 수가 증가하면서 認識 추정의 정확도가 감소하여 認識率이 저하되는 단점이 있다. 이러한 특성은 퍼지 ART 神經回路網의 代表패턴을 나타내는 連結強度인 \mathbf{w}_j^a 를 學習하는 과정에서 식 (8)과 같이 퍼지 AND 연산만을 이용하기 때문이다.^{[8],[19]} 다시 말하면, 入力패턴과 連結強度와의 퍼지 AND 연산으로 連結強度를 學習하면 雜音이 혼입된 入力이 인가되었을 경우에 入力패턴에 대한 代表패턴

을 나타내는 連結強度 벡터가 불규칙적인 雜音에 의하여 불필요하게 更新되어 손상된다. 따라서, 入力패턴에 대응되는 카테고리의 選擇에 오류가 발생하거나 불필요한 새로운 카테고리가 생성되어 認識率이 저하된다. 이 장에서는 앞에서 논의한 문제점을 해결하기 위하여 ART_a의 F₁ 층과 F₂ 층을 연결하는 連結強度에 대한 새로운 學習方法을 提案한다.

그림 2는 提案된 學習方法을 이용한 퍼지 ART 神經回路網의 구조를 나타낸다. 既存의 방식에서는 連結強度 w_j^a 를 구분하지 않고 단일화하여 사용한다. 提案된 方法에서는 連結強度를 F₁ 층에서 F₂ 층으로 연결하는 上向 連結強度 $w_j^{a,u}$ 와 F₂ 층에서 F₁ 층으로 연결하는 下向 連結強度 $w_j^{a,d}$ 로 구분하여 上向 連結強度는 식 (3)에서 選擇함수를 계산하기 위해 사용하고, 下向 連結強度는 식(5)의 정합 테스트를 위한 一致度の 계산에 사용한다. 또한, 下向 連結強度 벡터를 學習할 때 既存의 방식과 같이 퍼지 AND 연산이 아닌 加重平均을 이용하여 更新이 되도록 한다.

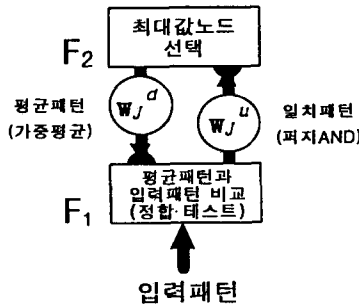


그림 2. 提案된 퍼지 ART 神經回路網의 連結強度 學習方法

Fig. 2. Block diagram of proposed learning method for fuzzy ART in fuzzy ARTMAP.

그림 2에서 下向 連結強度 벡터는 入力패턴과 자신과의 加重平均에 의하여 更新하고, 上向 連結強度 벡터는 자기 자신과 갱신된 下向 連結強度 벡터와의 퍼지 AND 연산에 의해 更新한다. 이것을 식으로 표현하면 다음과 같다.

$$w_j^{a,d(new)} = \frac{\eta}{1+n_j} A + (1 - \frac{\eta}{1+n_j}) w_j^{a,d(old)} \quad (9)$$

$$w_j^{a,u(new)} = (w_j^{a,d(new)} \wedge w_j^{a,u(old)}) \quad (10)$$

여기서 n_j 는 지금까지 F₂층의 카테고리 J 가 選擇된 횟수이다. η 는 현재의 入力벡터 A와 이전의 連結強度의

加重平均을 구하기 위한 가중값으로서, $\eta = 1$ 이면 算術平均이 되고 $\eta < 1$ 이면 加重平均이 된다. 따라서 η 는 下向 連結強度의 學習率을 나타내며, 그 값이 0에 가까울수록 현재의 入力벡터가 學習에 기여하는 비율이 감소하여 學習率이 낮아지게 된다.

식 (9)의 加重平均에 의한 下向 連結強度 벡터의 更新은 適應的으로 패턴의 온전한 형태를 기억하는 기능을 담당하고, 식 (10)의 퍼지 AND에 의한 上向 連結強度 벡터의 更新은 패턴의 特徵點만을 기억하는 역할을 한다. 따라서 提案된 學習方法에서는 入力패턴의 特徵을 가장 잘 나타내고 있는 上向 連結強度 벡터에 의해 카테고리가 선정되고, 이 선정된 카테고리가 믿을 수 있는 것인지를 下向 連結強度 벡터에 의해 확인한다. 또한 加重平均 방식으로 連結強度를 學習하면 이전의 連結強도와 雜音이 혼재된 入力벡터가 加重平均되어 更新되므로 連結強度가 入力雜音에 의해 원하지 않는 값으로 급격히 변화하는 것을 방지할 수 있으며, 퍼지 AND에 의한 更新은 퍼지 ART 시스템이 빠르고 안정된 동작을 할 수 있게 한다. 따라서 雜音環境에서도 認識率의 저하와 불필요한 새로운 카테고리의 형성을 억제할 수 있다.

IV. 모의실험 및 결과

提案한 方法에 대한 性能을 확인하기 위하여 컴퓨터 모의실험을 실시하였다. 모의실험에서는 雜音이 혼재된 入力 環境에서 Grossberg의 퍼지 ARTMAP과 提案된 方法에 대하여 각각 認識率과 F₂^a층의 카테고리 생성 수를 비교하였다. 既存의 퍼지 ARTMAP은 高速學習(FL)과 高速受容 低速符號化(FCSR)의 두가지 學習方法에 대하여 실험을 하였으며, FCSR의 경우 學習率은 0.4로 하였다. 提案된 방식(WA ; weighted averaging)의 경우에는 學習率 η 를 1과 0.4의 두 경우에 대하여 실험하였다. 境界 파라미터의 초기값 $\bar{\rho}_a$ 은 모두 0.5로 하였다. 入力패턴으로는 7×7 畫素의 흑백 숫자(0~9) 및 영문자(A~Z) 글꼴을 사용하였으며, 入力패턴에 인가된 雜音은 0~12 [dB] 인 加算性 가우시안 雜音이다. 그림 3에 숫자의 경우에 雜音이 혼입된 入力패턴을 나타내었다.

訓練 기간 동안에 雜音이 혼입된 1000개의 임의의 숫자(또는 문자) 入力패턴이 ART_a에 순차적으로 인가되고, 동시에 그 패턴에 對應하는 올바른 추정값이

ART_b에 주어져서 神經回路網을 學習시킨다. 學習이 종료되면 雜音이 혼입된 入力패턴을 ART_a에 인가하여 패턴을 추정하도록 한다.




그림 3. 雜音이 혼입된 숫자 入力패턴(SNR = 3 [dB])
Fig. 3. Noisy numeric input patterns(SNR = 3 [dB]).




그림 4. 숫자 入力패턴에 대한 認識率
Fig. 4. Recognition ratio for numeric input patterns.




그림 5. 숫자 入力패턴에 대한 F₂^a층의 카테고리 생성 수
Fig. 5. Number of generated categories in F₂^a for numeric input patterns.

그림 4, 5에 雜音이 인가된 숫자패턴에 대한 두 시스템의 認識率 및 카테고리 수를 比較하여 나타내었고,

그림 6, 7에 알파벳 패턴에 대한 性能을 比較하여 나타내었다. 그림을 보면 提案된 方法을 사용하였을 때 認識率이 더 높으면서도 F₂^a층의 카테고리 수는 더 적게 발생하는 것을 알 수 있다. 예를 들면 숫자패턴과 알파벳 패턴에 대한 認識率이 약 95 [%]일 때 SNR 利得은 각각 3.5~4 [dB]와 3.5~5.5 [dB] 가량 된다. 또한 SNR이 4 [dB]일 때 F₂^a 층의 카테고리의 수는 既存의 방식에 비하여 각각 60~190 개, 20~150 개가 적게 발생하며, 이는 既存 방식에서 발생하는 카테고리 수의 10 [%]에서 43 [%]에 불과한 것이다. 따라서 提案된 방식에서는 既存의 방식에 비해서 雜音環境에서 패턴의 認識率이 向上되었고, 불필요한 카테고리가 생성되는 것을 억제함으로써 카테고리와의 연결강도를 저장하는데 필요한 기억소자의 양을 줄일 수 있었다.




그림 6. 알파벳 入力패턴에 대한 認識率
Fig. 6. Recognition ratio for alphabet input patterns.




그림 7. 알파벳 入力패턴에 대한 F₂^a층의 카테고리 생성 수
Fig. 7. Number of generated categories in F₂^a for alphabet input patterns.

V. 결 론

본 논문에서는 監督學習 기능을 가지는 퍼지 ARTMAP 神經回路網 시스템에서 雜音이 혼입된 入力패턴이 인가될 경우에 불필요한 카테고리 발생되어 기억장치의 소요량이 증가하고 전체적인 認識性能이 저하되는 단점을 改善하기 위한 方法을 提案하였다. 既存의 방식에서 퍼지 AND 연산만을 이용하여 퍼지 ART 神經回路網의 F_1^a 층과 F_2^a 층간의 連結強度를 更新하는 것과는 달리, 提案된 방식에서는 連結強度를 上向과 下向으로 구분하여 각각 퍼지 AND 연산과 加重平均을 사용하여 更新함으로써 불필요한 카테고리가 발생하는 것을 억제하는 동시에 認識率을 向上할 수 있음을 電算模擬實驗을 통하여 보였다. 따라서 본 논문에서 提案한 방식을 적용하여 퍼지 ARTMAP 神經回路網을 구현할 경우에 雜音環境에서 既存의 방식에 비하여 소요되는 기억소자의 양을 감소시키면서도 認識性能을 向上시킬 수 있음을 확인하였다.

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] 김대수, *神經網 理論과 응용(1)*, 하이테크정보, 6장, pp. 191-210, 1992
- [3] 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.
- [4] G. A. Carpenter, S. Grossberg, and J. H. Reynolds, "ARTMAP: Supervised real-time learning and classification of non-stationary data by a self-organizing neural network", *Neural Networks*, vol. 4, pp. 565-588, 1991.
- [5] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen, "Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps", *IEEE Trans. Neural Networks*, vol. 3, No. 5, pp. 698-713, Sept. 1992.
- [6] R. P. Lippmann, "An Introduction to computing with neural nets", *IEEE ASSP Magazine*, pp. 4-22, April 1987.
- [7] J. A. Freeman and D. M. Skapura, *Neural Networks: Algorithms, Applications, and Programming Techniques*, Addison-Wesley press, pp. 291-339, 1991.
- [8] Chang Joo Lee, Sang Yun Lee, Choong Woong Lee, "Improvement of noise tolerance in fuzzy ART using a weighted sum and a fuzzy AND operation", *IEICE Trans. Fundamentals*, vol. E78-A, No. 10, pp. 1432-1434, Oct. 1995.
- [9] 이창주, 이상연, 이충용, "퍼지 ART에서 잡음 여유도를 개선하기 위한 새로운 학습방법의 연구", *대한전자공학회논문지 제32권 B편 제10호*, pp. 112-117, 1995년 10월

— 著 者 紹 介 —



李 在 高(正會員)

1962年 8月 15日生. 1985年 2月 서울 大學校 電子工學科 卒業(工學士). 1987年 2月 서울大學校 大學院 電子工學科 卒業(工學碩士). 1987年 3月 ~ 現在 서울大學校 大學院 電子工學科 博士課程

1888年 5月 ~ 1994年 2月 韓國通信 研究開發院 專任研究員. 1994年 3月 ~ 現在 東洋工業專門大學 電子通信科 專任講師. 主關心分野는 神經回路網, 디지털 通信 等임

李 忠 雄(正會員)

1935年 5月 3日生. 1983年 ~ 1985年 IEEE(國際電氣電子工學會) 韓國支部 會長. 1988年 大韓醫用生體工學會 會長. 1989年 大韓電子工學會 會長. 1989年 ~ 現在 IEEE(國際電氣電子工學會) Fellow. 1994年 ~ 現在 서울大學校부설 뉴미디어通信共同研究所 所長. 1966 ~ 現在 서울大學校 電氣工學部 教授. 主關心分野는 通信方式, 映像 및 HDTV 信號處理, 醫用生體工學, 未來 通信 等임



全 鍾 老(正會員)

1957年 12月 29日生. 1980年 2月 서울大學校 電氣工學科 卒業(工學士). 1982年 2月 서울大學校 大學院 電子計算機工學科 卒業(工學碩士). 1982年 10月 ~ 1991年 2月 (주)LG情報 通信 研究所 研究員. 1991年 3月 ~

現在 東洋工業專門大學 電算事務自動化科 助教授. 主關心 分野는 客體指向 DB, 神經回路網 等임