

복합 특성의 분리 처리를 위한 모듈화된 Coupled-ART 신경회로망

正會員 禹容泰* 正會員 李南日** 正會員 安光善***

A Coupled-ART Neural Network Capable of Modularized Categorization of Patterns

Yong Tae Woo*, Nam Il Lee**, Gwang Seon Ahn*** *Regular Members*

要約

ART(Adaptive Resonance Theory) 신경회로망과 같은 자기조직망에서 신호와 잡음을 적절히 정의한다는 것은 어려운 문제이다. 즉, 한 입력 패턴의 일부분이 어떤 패턴에서는 입력 패턴의 신호로 다루어지나 다른 패턴에서는 잡음으로 취급되어야 할 때도 있다. ART 신경회로망 모델은 신호와 잡음의 정의를 문맥과 학습에 따라 적절하게 규정하기 위하여 계산 단위를 자동적으로 자기척도(Self-Scaling) 할 수 있는 기능을 가지고 있다. ART 모델에서의 이러한 자기 척도 기능은 입력 패턴들이 유사한 성질을 가진 경우에는 유효하게 잘 동작한다. 그러나 ART 모델은 기본적으로 하나의 경계 인수에 의해 패턴을 분류하기 때문에 여러가지 성질이 복합된 입력 패턴을 효율적으로 분류하기가 어렵다. 예를 들어 패턴들을 자세하게 분류하기 위하여 경계 인수의 값을 크게하면 잡음으로 취급되어야 할 부분이 신호로 취급되어 불필요한 인식 부류가 발생한다. 또한 경계 인수를 작게하면 패턴을 구별하기 위한 중요한 정보가 잡음으로 취급되는 경우가 발생하여 비효율적인 분류를 한다.

본 논문에서는 ART 모델의 이러한 문제점을 해결하기 위하여 복합 특성을 분리 처리할 수 있는 모듈화된 Coupled-ART 신경회로망 모델을 제안하였다. Coupled-ART 신경회로망 모델은 신경회로망의 구조를 기능별로 모듈화하고 이러한 모듈들을 서로 밀착된 구조로 결합하여 확장된 기능을 수행하는 형태로 구성하였다. 이러한 모듈화된 신경회로망을 통해 패턴 인식 과정에서 다양한 크기나 성질을 가진 특징들에 대한 분류를 비슷한 크기나 성질을 가진 특징들끼리 분리하여 분류를 하였다. 그리고 본 논문에서 제안한 상위층에서 각 모듈의 처리 결과를 종합하여 최종적인 분류를 함으로써 기존의 ART 모델보다 더 효율적으로 패턴을 분류할 수 있다.

* 昌原大學校 電子計算學科
Dept. of Computer Science, Changwon University.
** 安東大學校 컴퓨터工學科
Dept. of Computer Engineering, Andong University.
*** 慶北大學校 컴퓨터工學科
Dept. of Computer Engineering, Kyungpook University.

論文番號: 94177

接受日字: 1994年 7月 4日

Abstract

Properly defining signal and noise in a self-organizing system like ART(Adaptive Resonance Theory) neural network model raises a number of subtle issues. Pattern context must enter the definition so that input features, treated as irrelevant noise when they are embedded in a given input pattern, may be treated as informative signals when they are embedded in a different input pattern. The ART automatically self-scales their computational units to embody context and learning dependent definitions of a signal and noise and there is no problem in categorizing input patterns that have features similar in nature. However, when we have input patterns that have features that are different in size and nature, the use of only one vigilance parameter is not enough to differentiate a signal from noise for a good categorization. For example, if the value of vigilance parameter is large, then noise may be processed as an informative signal and unnecessary categories are generated; and if the value of vigilance parameter is small, an informative signal may be ignored and treated as noise. Hence it is not easy to achieve a good pattern categorization.

To overcome such problems, a Coupled-ART neural network capable of modularized categorization of patterns is proposed. The Coupled-ART has two layers of tightly coupled modules, the upper and the lower. The lower layer processes the global features of a pattern and the structural features, separately in parallel. The upper layer combines the categorized outputs from the lower layer and categorizes the combined output. Hence, due to the modularized categorization of patterns, the Coupled-ART classifies patterns more efficiently than the ART1 model.

I. 서 론

최근에 인간의 뇌를 구성하는 뉴런의 기본적인 구조와 동작을 분석하여 궁극적으로 인간의 뇌의 기능과 유사한 형태로 동작하는 신경회로망을 구현하기 위한 연구가 많이 이루어지고 있다. 현재 가장 많은 분야에서 응용되고 있는 Back Propagation 신경회로망 모델과 함께 Hopfield Memory, Neocognitron, Self-Organizing Map, ART(Adaptive Resonance Theory) 등과 같은 여러 가지 형태의 신경회로망 모델들이 제안되었고 현재에도 많은 연구가 이루어지고 있다[1]. 이러한 신경회로망 모델들의 주된 연구 방향은 신경회로망의 Topology, 노드들의 특성, 그리고 학습 규칙들로 특징 지워진다[2]. 그러나 현재까지 연구된 신경회로망 모델들은 주로 신경회로망을 구성하는 기본적인 뉴런의 구조나 연결 형태 그리고 학습 방법에 대한 모델들이 대부분이다. 그리고 단일 네트워크보다 학습 속도의 개선, 입력 영역의 분리 처리를 통한 일반화(Generalization) 등의 기능을 향상시키기 위하여 Ja-

cobs[3] 등에 의해 BP 모델을 기반으로 복잡한 작업을 여러개로 분리하여 기능별로 나누어 처리할 수 있는 모듈화된 네트워크에 대한 연구도 제안되었다.

본 논문에서 기본 모델로 사용한 ART 신경회로망 모델은 S. Grossberg와 G. Carpenter 등에 의해 제안되어 지난 20여년 동안 활발하게 연구가 진행되어왔다[4,5,6,7]. ART 모델은 화학적 시냅스모델(Cheical Synapse Model)에 기초하여 구성된 모델로써 실 세계에서 주어진 임의의 다수 이진 입력 패턴들에 대해 인식 코드를 자기 안정화 및 자기 조직화를 할 수 있다. 또한 이 모델은 주어진 입력 패턴을 학습하여 안정화된 후 제시된 입력 패턴에 대해 가장 큰 부분 패턴을 포함하는 인식부류로 직접 접근한다[4]. 특히 이 모델은 기존의 다른 형태의 신경회로망에서 해결하기 어려웠던 안정성과 적응성의 문제(Stability-Plasticity Dilemma) 즉, 이전에 학습했던 패턴을 잊어버리지 않고 새로운 변화에 대해 어떻게 자율적으로 적용할 수 있는

가에 대한 해결책을 제시하였다. 특히 ART 신경회로망은 신호와 잡음의 정의를 문맥과 학습에 따라 적절하게 정의하기 위해서 계산 단위를 자동적으로 자기 척도(Self Scaling)할 수 있는 기능을 가지고 있다[5]. 이러한 ART 모델은 문자 인식, 지문 인식 등과 같은 이진 데이터를 처리하는 응용 분야에 대한 적절한 해결 방법으로 이용할 수 있다[8,9,10].

그동안 이러한 ART 모델을 여러가지 형태로 변형하거나 확장하기 위한 연구가 많이 진행되어왔다. 입력 데이터의 형태나 처리 방법에 따라 ART1, ART2, ART3, Fuzzy-ART, ARTMAP 및 Fuzzy-ARTMAP 등의 모델들이 제시되었는데[11-15], ART1[4-7]은 2진 데이터만을 처리할 수 있는 가장 간단한 모델이며, ART2[11]는 2진 데이터 뿐만 아니라 아날로그 데이터도 처리할 수 있는 모델이다. ART3[12]은 부분적으로 압축되거나 분산된 패턴 인식 코드의 대한 병렬 탐색이 가능한 모델로 ART1이나 ART2보다 시뮬스 동작에 가깝다. 그리고 ART1을 상하나 좌우로 연결해서 지도학습(Supervised Learning)형태로 구성된 것이 ARTMAP[13]이며, 퍼지 집합 이론을 ART에 적용해서 아날로그나 2진 데이터를 처리할 수 있도록 한 모델이 Fuzzy-ART[14]이다. 또한 최근에는 ARTMAP에 Fuzzy-ART를 적용하여 만든 Fuzzy-ARTMAP[15]도 발표되었다.

기존의 패턴 인식 분야에서는 패턴을 효율적으로 분류하기 위하여 패턴에서 추출된 여러가지 형태의 특징들을 사용해 왔다. 이러한 특징들은 각 패턴에 대한 전체적인 영상으로부터 추출 가능한 Global 특징들과 구조적인 형태로부터 얻어지는 Local 특징들로 나뉘어진다. 그리고 인식 효율을 향상시키기 위하여 집단 방법에 따라 Global 특징 또는 Local 특징들 중에서 몇가지의 특징을 결합한 다차원적인 특징을 사용해 왔다. 그러나 ART 모델은 기본적으로 일차원적인 방법으로 유사도를 측정하여 패턴을 분류하기 때문에 크기가 다르고 여러가지 성질이 혼합된 고차원적인 패턴에 대한 처리가 비효율이다[16]. 즉, 기존의 ART 신경회로망을 이용하여 패턴 분류를 하기 위해서는 이러한 다차원적인 입력 특징들을 혼합하여 복잡한 형태의 일차원적인 입력 벡터로 재구성하여 분류한다. 이 과정에서 하나의 경계 인수(Vigilance Parameter)에 의해 분류하기 때문에 효율적인 경계 인수 조정, 학습 과정의 복잡화, 학습 시간의 지연 등과 같은 여러가지 문제점들이 발생한다. 특히, Global 특징과 상대적으로 크기가 매우 작

은 Local 특징을 함께 결합하여 분류할 경우, 계산 단위를 자동적으로 자기 척도하는 과정에서 패턴을 분류하는데 중요한 신호를 잡음으로 처리하거나 잡음을 신호로 처리하여 불필요한 부류(Category)를 생성하는 문제점이 발생한다.

본 논문에서는 이러한 문제점을 해결하기 위하여 기존의 ART1 모델을 확장하여 신경회로망의 기능을 지식적인 관점에서 구성하였다. 즉, 신경회로망의 구조를 기능별로 모듈화하고 이러한 모듈들을 서로 밀착된 구조로 결합하여 확장된 기능을 수행하는 형태로 구성하였다. 이러한 모듈화된 신경회로망을 통해 패턴 인식 과정에서 다양한 크기나 성질을 가진 특징들에 대한 분류를 비슷한 크기나 성질을 가진 특징들끼리 분리하여 분류하게 된다. 그리고 본 논문에서 제안한 상위층에서 각 모듈의 처리 결과를 종합하여 최종적인 분류를 함으로써 패턴 분류의 효율을 개선할 수 있다.

제안된 Coupled ART 신경회로망 모델의 기본적인 구조는 ART1 모델을 이용하여 좌우 대칭적인 구조를 가지는 두개의 ART1 모듈에 의해 구성되는 하위층과 하위층을 제어하기 위한 상위층 E3층으로 구성된다. 하위층은 Dual Type으로 구성된 ARTa와 ARTb 모듈로 구성된다. ARTa와 ARTb 모듈의 기본적인 구조와 동작 방정식은 기존의 ART1 모델과 동일하며 별도의 관련 기준에 의해 서로 독립적이고 병렬적으로 동작한다. ARTa 모듈의 기능은 패턴의 구조적인 형태에서 얻어지는 특징에 의해 패턴을 분류하며 ARTb 모듈의 기능은 패턴의 전체적인 영상으로부터 구성되는 특징에 의해 패턴을 분류한다. 그리고 본 논문에서 제안된 상위층 E3층은 ARTa와 ARTb 모듈에서 병렬적으로 처리된 결과를 종합하여 최종적인 분류를 한다. 이 E3층의 기본구조는 ART1 모델과 유사하다. 그러나 E3층에 입력되는 패턴의 형태가 일정한 형태로 주어지기 때문에 E3층의 학습 방정식은 기존의 ART1 모델보다 단순하게 구성될 수 있으며 아울러 학습 시간도 개선할 수 있다.

II. ART1 신경회로망 모델의 개념

1. ART1 신경회로망 모델의 특징 및 기본 구조

Carpenter와 Grossberg는 ART 신경회로망 모델 중에서 가장 기본적인 구조를 가지는 ART1 신경회로망 모델을 화학적 시뮬스 모델을 이용하여 구성하였다.

ART 모델의 기본 개념은 다음 그림 1의 화학적 시냅스 모델(chemical synapse model)로부터 유도된다[4].

전시냅스(presynaptic) 신호 s_i 는 가중치가 z_{ij} 인 시냅스에 도착되며, 여기서 z_{ij} 는 가능한 전달자(transmitter)의 최대치를 나타낸다. 일반적으로 '1'로 간주되어 신호가 가득차게 되면 내부전달자 u_{ij} 의 값이 증가하게 된다.

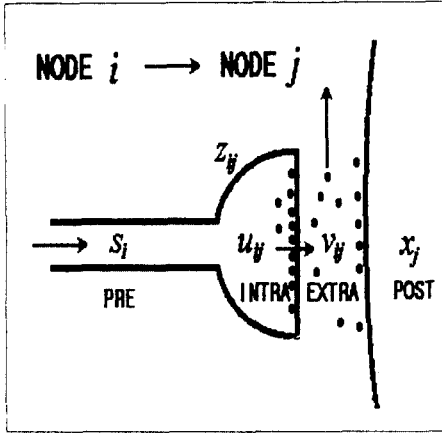


그림 1. 화학적 시냅스 모델
Fig. 1. Chemical synapse model

계속적으로 s_i 가 들어오게 되면 전달자는 내부전달자를 방출하게 되어 외부전달자 v_{ij} 가 된다. x_j 는 후시냅스(postsynaptic) 세포막의 활동을 나타내며 위 변수들의 동작은 다음 식과 같이 정의된다. 즉, 내부전달자의 동작식은

$$\frac{du_{ij}}{dt} = (z_{ij} - u_{ij}) [\text{production / mobilization rate}] - u_{ij} [\text{release rate}] \quad (1)$$

이며, 외부 전달자의 동작식은

$$\frac{dv_{ij}}{dt} = -v_{ij} [\text{removal rate}] - u_{ij} [\text{release rate}] \quad (2)$$

이고 후시냅스(postsynapse) 동작식은 다음과 같다.

$$\epsilon \frac{dv_j}{dt} = -x_j + (1 - Ax_j) [\text{excitatory input}] - (B + Cx_j) [\text{inhibitory input}] \quad (3)$$

$$= -x_j + (1 - Ax_j)$$

$$[\sum v_{ij} + \{FEEDBACK\}] - (B + Cx_j) [FEEDBACK]$$

ART1 모델은 그림 1을 이용하여 구성되었고 실시 간에서 주어진 임의의 이전 입력 패턴에 대해 자율적으로 적응 학습하여 패턴 분류를 하는 신경회로망 모델이다. 또한 노드의 복잡도에 관계없이 학습된 패턴에 대하여 항상 직접 접근(Direct Access)이 가능하며 불일치(Mismatch)가 아닌 근사대조(Approximate Match)에 의해 학습이 이루어지므로 빠르고 안정된 학습이 가능하다. 그리고 ART모델은 자율 신경회로망에서 해결하기 어려웠던 안정성과 적응성의 문제(Stability-Plasticity Dilemma) 즉, 이전에 학습했던 패턴을 잊어버리지 않고 새로운 변화에 대해 어떻게 자율적으로 적응할 수 있는가에 대한 해결책을 제시하였다. ART 신경회로망 모델에서는 함수적으로 모순적인 관계를 갖는 두 개의 서브시스템 사이의 상호작용에 의해서 안정성과 적응성 문제를 해결하고 있다. 이 두 가지 서브시스템은 주의 서브시스템(Attentional Subsystem)과 적응 서브시스템(Orienting Subsystem)이다. 주의 서브시스템은 유사한 문제에 대해서 동작을 하고 이에 대한 정확한 내적 표현을 나타낸다. 그러나 그것은 유사한 문제에 대한 안정된 표현을 유지하면서 동시에 유사성이 없는 패턴에 대한 새로운 부류를 만들어 내지는 못한다. 그래서 이와 같이 유사성이 없는 입력이 발생할 경우에는 주의서브시스템을 동작하지 못하게 하는 새로운 적응 서브시스템이 필요하다. 적응 서브시스템은 새로운 패턴이 유사성은 있지만 이미 존재한 인식층 노드에 의해서 나타낼 수 있는지 여부와 유사성이 없기 때문에 새로운 노드를 만들 필요성이 있는가를 나타내는 서브시스템이다. 따라서 많은 기존의 다른 신경회로망 모델은 학습을 많이 하면 할수록 내부 표현이 복잡하게 되어 결국은 불안정한 상태까지 가는데 비해 ART 신경회로망 모델은 내부 표현이 복잡함에도 불구하고 안정성 적응성 문제에 대해서 균형을 유지하게 된다.

주의 서브시스템은 비교층 F1과 인식층 F2로 구성되는데, 단기 메모리인 STM(Short Term Memory)에 활성화된 패턴을 저장한다. 그리고 F1층과 F2층 사이에는 학습된 패턴들이 기억되는 적응형 장기 메모리인 LTM(Long Term Memory)이 있다. 이 LTM은 F1층과 F2층 간에 양방향의 상, 하향길로 표현되는데 상향

또는 하향 패턴들이 이 길을 통과할때 마다 기억된 값들과 곱해져서 더하는 형태로 패턴을 학습한다. 이득 제어(Gain Control)는 F1으로 하여금 상향 패턴과 하향 패턴을 구별할 수 있도록 해준다. 적응 서브시스템은 입력 패턴인 상향 패턴과 학습된 템플릿(Template) 패턴간의 불일치가 발생할 때마다 F2층에 지속적인 차단 신호(Reset Signal)를 보내어 F2노드의 활성화를 억제한다. 다음 그림 2에서는 ART1 모델의 기본적인 구조를 보여준다[5].

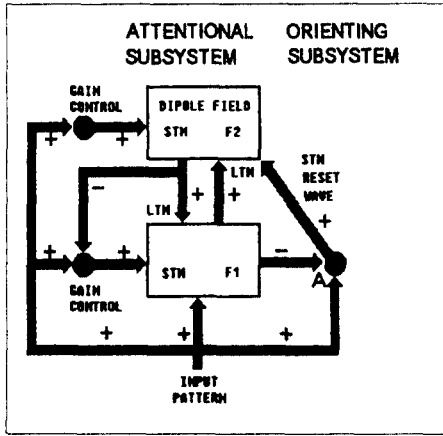


그림 2 ART1 신경회로망 모델의 기본적인 구조
Fig. 2. The basic architecture of ART1 model

2. ART1 신경회로망 모델의 동작 원리

ART1 신경회로망의 기본 동작은 그림 1의 화학적 시냅스 모델에서 유도된 내부전달자의 동작식, 외부전달자의 동작식 그리고 후 시냅스 동작식을 미분 방정식의 형태로 모델링한 STM 및 LTM 방정식과 입력 패턴과 학습된 패턴간의 일치정도에 따라 F2노드를 억제 또는 활성화하기 위한 경계인수의 동작식으로 구성된다[5].

1) STM 방정식

F1 또는 F2에서의 임의노드 x_k 의 STM 활성(Activity) x_k 는 다음과 같은 방정식을 따른다.

$$\epsilon \frac{d}{dt} x_k = -x_k + (1 - Ax_k)J_k^+ - (B + Cx_k)J_k^- \quad (4)$$

여기서, J_k^+ 는 x_k 에 대한 총 흥분입력이며 J_k^- 는

x_k 에 대한 총 억제 입력이고, A, B, C는 양의 상수이다.

F1 노드를 v_i ($i=1, 2, \dots, M$)이라 하면 (4)식에 의해 다음과 같이 F1 STM 방정식이 된다.

$$\epsilon \frac{d}{dt} x_i = -x_i + (1 - A_1x_i)J_i^+ - (B_1 + C_1x_i)J_i^- \quad (5)$$

여기서 F1 노드 v_i 에 대한 활성 입력 J_i^+ 및 억제 입력 J_i^- 는 각각 다음과 같다.

$$J_i^+ = I_i + V_i \text{ 단, } V_i = D_1 \sum_j f(x_j)z_{ji} \quad (6)$$

$$J_i^- = \sum_j f(x_j) \quad (7)$$

F2 노드를 v_i ($i=M+1, M+2, \dots, N$)이라 하면 (4)식에 의해 다음과 같은 F2 STM 방정식이 된다.

$$\epsilon \frac{d}{dt} x_i = -x_i + (1 - A_2x_i)J_i^+ - (B_2 + C_2x_i)J_i^- \quad (8)$$

여기서 F2 노드 v_i 에 대한 활성 입력 J_i^+ 는 다음과 같다.

$$J_i^+ = g(x_j) + T_j \text{ 단, } T_j = D_2 \sum_j h(x_j)z_{ji} \quad (9)$$

J_i^+ 는 v_i 에서 자기 자신으로 되돌아오는 양의 Feedback신호 $g(x_i)$ 와 상향 적응 필터 입력 T_j 를 합한 값이다.

그리고 F2 노드 v_i 에 대한 억제 입력 J_i^- 는 다음과 같다.

$$J_i^- = \sum_{k \in F_1} g(x_k) \quad (10)$$

J_i^- 는 F2에서 자신을 제외한 다른 노드에서 자기 자신으로 되돌아오는 음의 피드백 신호 $g(x_k)$ 를 모두 합한 값이다. 그리고 인식층 F2의 뉴런들은 양의 피드백 신호 $g(x_i)$ 와 음의 피드백 신호 J_i^- 를 통하여 입력 패턴 T에 대한 반응으로 F2의 STM 활성 패턴을 대비

-항상하기 위하여 On-Center Off-Surround Feedback 작용을 하는 측면 억제(Lateral-Inhibition)네트워크 구조를 가진다.

2) LTM 방정식

F1의 v_i 와 F2의 v_j 노드간의 상향 LTM Trace z_{ij} 는 다음과 같은 방정식을 따른다.

$$\frac{d}{dt} z_{ij} = K_1 f(x_i) [-E_{ij} z_{ij} + h(x_i)] \quad (11)$$

여기서, $f(x_i)$ 는 Postsynaptic sampling이다.

그리고 F2의 v_j 노드와 F1의 v_i 노드간의 하향 LTM Trace z_{ji} 는 다음과 같은 학습 방정식을 따른다.

$$\frac{d}{dt} z_{ji} = K_2 f(x_j) [-E_{ji} z_{ji} + h(x_j)] \quad (12)$$

3) STM 차단 시스템

각 활성 입력 경로는 적응 서브시스템 A에 P크기 만큼 흥분 신호를 보낸다. 그리고 0을 초과하는 F1의 x_i 전위는 A에 Q크기 만큼 억제 신호를 보낸다. 이러한 조건은 다음과 같은 차단 규칙을 유도한다.

차단 규칙 : A 집단은 다음 조건이 성립될 때마다 F2에 총체적인 차단 신호를 발생한다.

$$\frac{|X|}{|I|} < \rho = \frac{P}{Q} \quad (13)$$

여기서 I는 현재의 입력 패턴이고 |X|는 F1을 통해 $x_i > 0$ 을 만족하는 노드의 수이다. 총체적인 차단 신호는 탐색이 끝나거나 입력 패턴이 차단될 때까지 활성 F2 노드들을 순차적으로 차단한다. 경계 인수 ρ 는 입력 패턴과 학습된 패턴간의 일치정도를 판별하기 위한 인수이다.

3. ART1 신경회로망 모델에서 자기 척도

ART 신경회로망 모델과 같은 자기 조직 신경회로망에서 신호와 잡음을 정확하게 정의한다는 것은 어려운 문제이다. 즉, 한 입력 패턴의 일부분이 어떤 패턴에서는 신호로 다루어지나 다른 패턴에서는 잡음으로 처리되어야 할 때도 있다. 이 ART 모델은 신호와 잡음의 정의를 문맥과 학습에 따라 적절하게 규정하기

위해서 계산 단위를 자동적으로 자기 척도 할 수 있는 기능을 가지고 있다. 다음 그림 3은 ART 모델에서 자기 척도의 기능을 보여준다[5]. 그림 3(a)에서 두 개의 패턴에 대하여 3개의 요소중 2개의 위치는 서로 일치하나, 1개는 서로 일치하지 않는다. 3개의 요소 중에서 1개의 불일치는 두 패턴을 서로 다른 패턴으로 분류할 만큼 중요하므로 ART 모델에 의해서 유효한 것으로 작용한다. 따라서 이 불일치 되는 부분은 신호로써 동작을 하게 되어 두가지 입력 패턴에 대해서 서로 다른 인식 부류를 발생시킨다. 그러나 그림 3(b)의 경우, 2개의 패턴은 각각 31개의 단위 요소로 구성되어 있는데 그림 3(a)에서와 마찬가지로 1개씩이 서로 불일치하고 있는 상태이다. 그러나 이 불일치 되는 부분은 패턴의 전체 크기에 비해 그림 3(a)에서 보다 훨씬 작아서 이 부분은 잡음으로 처리하게 된다. 따라서 두 가지 입력 패턴에 대해서 인식 부류는 1개를 발생시키게 된다. 위 두 경우를 서로 구별해서 처리하는 원리가 바로 ART 신경회로망 모델의 자기 척도 기능이다.




그림 3. ART 신경회로망 모델의 자기 척도 원리
Fig. 3. Self-scaling property in ART model

III. Coupled-ART 신경회로망 모델의 제안

ART 모델에서의 자기 척도 기능은 입력 패턴들이 유사한 성질을 가진 경우에는 유효하게 잘 동작한다. 그러나 ART 모델은 기본적으로 하나의 경계 인수에 의해 패턴을 분류하기 때문에 여러가지 성질이 복합된 입력 패턴을 효율적으로 분류하기가 어렵다. 예를들어 패턴들을 자세하게 분류하기 위하여 경계 인수의 값을

크게하면 잡음으로 취급되어야 할 부분이 신호로 취급되어 불필요한 인식 부류가 발생한다. 경계 인수를 작게하면 패턴을 구분하기 위한 중요한 정보가 잡음으로 취급되는 경우가 발생하여 비효율적인 분류를 한다. 또한 ART 모델은 하나의 경계 인수에 의해 분류하기 때문에 효율적인 경계 인수 조정, 학습 과정의 복잡화, 학습 시간의 지연 등과 같은 여러가지 문제점들이 발생한다.

본 논문에서는 ART 모델의 이러한 문제점을 해결하기 위하여 복합 특징을 분리 처리할 수 있는 모듈화된 Coupled ART 신경회로망 모델을 제안하였다. Coupled ART 신경회로망 모델은 기존의 ART1 신경회로망 모델을 확장하여 신경회로망의 기능을 가시적인 관점에서 구성하였다. 즉, 신경회로망의 구조를 기능별로 모듈화 하고 이러한 모듈들을 서로 연결된 구조로 결합하여 확장된 기능을 수행하는 형태로 구성하였다. 이러한 모듈화된 신경회로망을 통해 패턴 분류 과정에서 여러 특징을 가진 특징들에 대한 처리를 비슷한 특징을 가진 특징들끼리 분리하여 별도의 판별 기준에 의해 분류하게 된다. 그리고 본 논문에서 제안된 상위층에서 각 모듈에서 독립적으로 처리된 결과를 종합하여 최종적인 분류를 함으로써 ART1 신경회로망에서의 자기 지도의 문제점을 해결하여 패턴분류의 효율을 개선할 수 있다.

1. Coupled-ART 신경회로망 모델의 구조

제안된 Coupled ART 신경회로망 모델에 대한 기본적인 구성도는 다음 그림 4와 같다. Coupled ART 신경회로망 모델의 기본 구조는 서로 병렬적인 한 쌍의 ARTa와 ARTb 모듈로 구성되는 하위층과 하위층을 결합된 형태로 결합하여 통제하기 위하여 본 논문에서 제안된 상위층 F3층으로 구성된다.

ARTa와 ARTb 모듈의 기본 구조는 ART1 신경회로망 모델과 동일한 구조를 가지며 별도의 판별 기준이 되는 별도의 경계 인수 ρ_a 및 ρ_b 에 의해 병렬적으로 패턴을 분류한다. 그리고 본 논문에서 제안한 F3층의 기본 구조는 ART1 모델과 유사하다. 그러나 F3층에 대한 학습 방정식과 경계 인수 ρ_{F3} 는 ART1 모델과는 다르게 구성하였다. F3 layer의 기능은 하위층 ARTa와 ARTb 모듈을 서로 결합하여 각 모듈에서 처리된 정보에 의해 종합적인 판단을 한다.

따라서 Coupled ART 모델은 이전 입력 벡터를 처리하는 기존의 ART1 모델을 병렬적인 Dual Type으로

구성하여 다차원 입력 벡터를 일차원 벡터의 결합된 형태로 분리하고 하위 레벨의 각 ART 모듈에 따로 입력하여 별도의 분류 기준에 의해 1차 분류를 한다. 그리고 상위층 F3층에서는 하위층 ARTa, ARTb 모듈에서 병렬적으로 처리된 정보를 종합하여 최종적인 분류를 한다.

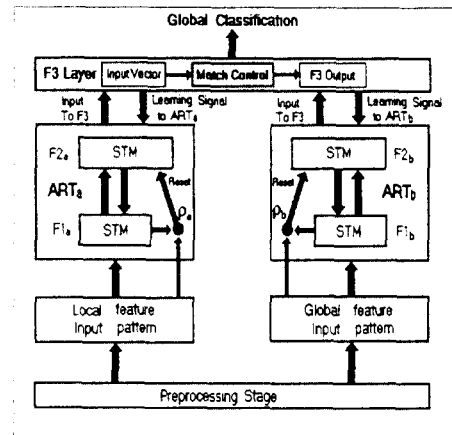


그림 4. Coupled ART 신경회로망 모델의 기본적인 구성도

Fig. 4. The architecture of the Coupled ART model

2. Dual type ART1으로 구성된 하위층의 동작

주어진 입력 패턴에 대해 하위층을 구성하는 ARTa와 ARTb 모듈은 별도의 판별 기준에 의해 서로 독립적으로 동작한다. 이때 ARTa와 ARTb는 ART1 모델과 동일한 과정에 의해 입력 패턴을 분류하고 학습한다. 각 모듈이 입력 패턴을 분류하게 되면 인식층 F2a, F2b의 노드들에서 하나씩 활성화하여 다음과 같은 출력 형태를 가지게 된다.

$$F2_a \text{ Output } (V_i) : 0 \sim 10^3, F2_b \text{ Output } (V_j) : 0 \sim 10^3$$

단, V_i 는 P개의 노드들 가지는 벡터이고, V_j 는 Q개의 노드들 가지는 벡터이다.

본 논문에서 제안한 Dual type ART 모듈에서의 학습 과정은 ART1 모델과는 다른 형태가 된다. 즉, ART1 모델에서는 입력 패턴과 템플릿 패턴간의 일치 정도가 (13)식을 만족하는 즉시 F1 LTM과 F2 LTM값을 수정하여 학습한다. 반면에 Coupled ART 모델의 하위층은 두 개의 ART1이 병렬로 구성되어 상호 작용을 하는 관계로 각 모듈이 활성화 되더라도 ART1 모델처럼 즉시 학습하지 않는다. 즉, 각 ART

모듈의 출력층이 모두 활성화 되면 각 모듈은 출력 결과를 결합하여 상위층에 대한 입력 벡터를 구성하여 상위층에 제시한다. 그리고 상위층에서 학습 신호가 올 때까지 기다리게 된다.

3. 상위층 F3층의 동작

상위층 F3층은 하위층 ARTa, ARTb 모듈과 F3층 간의 상호 작용 과정을 통제하는 Coordinator의 역할을 수행하며 기본적인 구조는 ART1 모델과 유사하다. 그러나 학습 방정식 및 입력 패턴과 템플릿 패턴간의 유사도를 판별하기 위한 경계 인수 ρ_c 는 규칙적인 형태로 주어지는 입력 벡터로 인하여 ART1 모델보다 단순하게 구성할 수 있으며 아울러 학습 시간을 개선할 수 있다.

Lemma 1. F3층의 입력 벡터는 $V_i = (|V_a| |V_b|) = (|0^*10^* \ 10^*10^*)$ 와 같다. 단, V_a 는 P개의 노드를 가지는 F2a의 출력 벡터이고, V_b 는 Q개의 노드를 가지는 F2b의 출력 벡터이다.

Proof : 하위층 ARTa와 ARTb 모듈의 출력은 각각 F2a 및 F2b의 노드 중에서 하나만 Commit된다. 따라서 F3층의 입력 벡터는 ARTa와 ARTb 모듈의 출력 결과가 결합된 형태로 주어지므로 Lemma 1을 만족한다.

Lemma 1로부터 F3층의 입력 벡터에서 1의 값은 가지는 노드의 수는 2개이다.

Lemma 2. F3층의 입력 벡터들간에는 자기 자신을 제외하고는 서로 포함 관계가 없다.

Proof : F3 층의 모든 입력 벡터들의 집합을 V_i 라 하자. 즉, $V_i = (|V_a| |V_b| : V_a \in (0^*10^*)$ 인 P-tuple 벡터, $V_b \in (0^*10^*)$ 인 Q-tuple 벡터)이다. 여기서 $X = (X_a | X_b)$ 를 V_i 의 한 원소라 하자. 단, $X_a = (0, \dots, 0, 1, 0, \dots, 0)$, $X_b = (0, \dots, 0, 1, 0, \dots, 0)$ 그리고 $Y = (Y_a | Y_b) \in V_i$ 가 X의 부분 집합이라 하면 i번째 성분을 제외한 Y_a 의 모든 성분은 0이 되어야 한다. 그런데 Y_a 의 성분중 하나는 반드시 1이 되어야 하므로 Y_a 의 i번째 성분은 1이 된다. 그러므로 $Y_a = X_a$ 이다. 마찬가지로 $Y_b = X_b$ 가 된다. 그러므로 $X=Y$ 이다. 따라서 위 Lemma는 성립한다.

Lemma 3. F3층의 안정적인 유사도 검사를 위해 경계 인수 ρ_c 는 다음과 같은 조건을 가진다.

Proof : F3층에 대한 입력 벡터에서 1의 개수인 Lemma 1에 의해 2개가 되고 학습된 템플릿 패턴에서의 1의 개수 또한 2개가 된다. 따라서 식(13)에서 $|I|$ 와 $|X|$ 는 입력 벡터 전체 크기에 비해서 크기가 매우 작고 동일한 크기를 가진다. 그러므로 입력 패턴과 템플릿 패턴간의 유사도 비교는 크기 비교 보다 1의 위치에 따른 분류를 하기 위하여 매우 세밀하게 비교해야 한다. 따라서 F3층에서의 경계 인수는 $\rho_c \cong 1$ 조건을 만족한다.

ART1 모델의 입력 벡터에서 1의 개수인 0에서 최대 n개까지 랜덤하게 가질 수 있다. 여기서 n은 F1노드의 개수이다. 따라서 ART1 모델에서의 경계 인수 ρ 는 입력 패턴과 학습된 패턴간의 일치정도에 따라 0에서 1사이의 값을 가진다. 이 값이 큰 수록 보다 세밀한 분류를 하게 되며 작은 경우에는 개관적인 분류를 한다. 따라서 ART1 모델에서는 입력 패턴들에 대한 분류가 입력 패턴의 1의 개수와 1의 분포에 의해 이루어지는 반면에 F3층에서는 Lemma 1과 Lemma 3에 의해 크기 차이에 따른 분류는 무의미하며 1의 분포에 따른 분류를 하여 F3 출력 노드를 활성화하여 분류한다. 특히, ART1 모델에서는 입력 패턴들이 서로 모집합과 부분 집합의 관계로 주어질 수 있다. 따라서 부분 집합과 모집합의 상이도가 충분히 커서 다른 패턴으로 분류하기 위하여 상향 LTM 가중치 w_{ij} 는 다음 식(15)처럼 입력 패턴과 템플릿 패턴간의 일치하는 노드 수가 많을수록 w_{ij} 값이 작아지는 반비례 함수의 형태로 주어진다.

$$w_{ij}(t+1) = \frac{v_{ij}(t)x_j}{0.5 + \sum_{i=1}^n v_{ij}(t)x_i} \tag{15}$$

그러나 Lemma 1과 Lemma 2에 의해 F3층의 입력 벡터들간에는 서로 포함 관계가 없으므로 상향 학습 방정식을 다음과 같이 구성할 수 있다.

Lemma 4. F3 층에서의 상향 LTM 학습 방정식은 다음과 같이 단순화 되고 학습 시간이 단축된다.

$$w_{ij}(t+1) = v_{ij}(t)x_i \tag{16}$$

Proof : Lemma 1과 Lemma 2로부터 F3층의 입력

벡터는 1의 값을 가지는 노드의 수가 2개이며 입력 벡터들간에 포함 관계가 없다.

이 성질로 부터 F3 층에서의 상향 LTM 학습 방정식은 위 식(16)처럼 입력 패턴과 템플릿 패턴간의 일치하는 노드 수에 비례하는 함수의 형태로 단순화 할 수 있다. 또한 F3 층에서는 식(15)의 ART1 상향 LTM 학습 방정식에서 분모 부분에 대한 계산이 생략되므로 학습 시간이 단축된다.

4. Coupled-ART 신경회로망 모델의 동작

1) Coupled-ART 신경회로망 모델의 동작 과정

Coupled-ART 신경회로망 모델의 전체적인 동작 과정은 Dual-type의 구성된 ARTa 및 ARTb 모듈과 F3 층이 상호 작용을 하는 형태로 동작하며 분산 데이터 베이스 시스템에서 사용되는 Two Phase Commit Protocol[17]과 유사한 형태로 동작한다.

여기서 F3 층의 Match Control은 ARTa, 및 ARTb 모듈의 상호 작용 과정을 제어하는 Coordinator의 역할을 담당한다. 다음 그림 5에서는 Coupled-ART 신경망 모델의 전체적인 동작 과정을 보여준다.

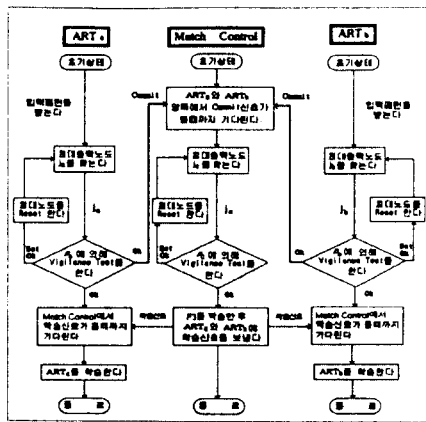


그림 5. Coupled-ART 신경회로망 모델의 전체적인 동작 과정

Fig. 5. Overview of the Coupled-ART operations

2) Coupled ART 신경회로망 모델의 동작 알고리즘

제한된 Coupled ART 신경회로망 모델의 전체적인 동작 과정은 하위층 ARTa, ARTb 모듈에 의한 Participant Stage와 F3 층의 Match Control에 의한 Coordinator Stage로 나뉘어진다.

1. Participant Stage : ARTa와 ARTb모듈이 병렬 동작하는 단계

이 단계는 그림 3에서 ARTa와 ARTb가 병렬로 동작하는 단계로 기본적인 동작 과정은 ART1 모델과 같다. 그러나 경계 인수 검사를 통과하여 상, 하향 LTM 값을 수정하기 위하여 Match Control과 상호 작용하는 과정을 거친다.

Step 1 : 경계 인수 ρ_a, ρ_b 및 상, 하향 LTM의 초기화

a. ARTa, ARTb의 경계 인수값: $0 < \rho_a, \rho_b < 1$ 값을 가지며 입력 벡터의 특성에 따라 서로 다르게 정의된다.

b. 다음 식 (17)에 의해 ARTa, ARTb의 상향 LTM의 초기화 한다.

$$W = \left[\frac{1}{1+n} \right] \tag{17}$$

c. ARTa, ARTb의 하향 LTM의 초기화 한다.

여기서 ARTa, ARTb의 입력 벡터는 각각 M-tuple, N-tuple이고 M과 N은 각각 F1a 및 F2a의 노드 수이다. 그리고 상향 LTM W 및 하향 LTM V는 M×N Matrix이다.

Step 2: ARTa와 ARTb은 이진 벡터로 표현된 서로 다른 입력 패턴을 각각 받는다.

Step 3: 주어진 입력 패턴에 대해 F2a 및 F2b 노드들의 출력 값을 구한다. 그리고 F2a 및 F2b의 출력 노드 중에서 최대 값을 가지는 노드 ja와 jb를 구한다.

Step 4: 승리 뉴런 ja, jb에 대한 경계 인수 검사를 한다. 만일, 경계 인수 검사를 통과하면 Step 5로 간다.

실패하면

Case 1: F2a, F2b의 출력 노드 중에서 활성화된 노드가 하나 이상 남아있는 경우에는 Step 7로 간다.

Case 2: F2a, F2b의 출력 노드 중에서 활성화된 노드가 하나도 없는 경우에는 Step 5로 간다.

Step 5: 하위층 ARTa 또는 ARTb에서 입력 패턴에 대한 분류가 된 모듈에서 Match Control에 Commit 신호와 함께 F2a Output=(V_{ja}0¹⁰) 또는 F2b Output = (V_{jb}0¹⁰)을 보낸다. 그리고 Match Control로부터 Learning 신호가 올 때까지 상, 하향 LTM값을 수정하지 않고 기다린다.

Step 6: Match Control로부터 ARTa 또는 ARTb에

Learning 신호가 오면 해당되는 ART 모듈의 상향 및 하향 LTM 값을 수정하고 학습을 종료한다. 그리고 Step 2로 간다.

Step 7: y_j 값을 0로 주어 $F2_a$ 또는 $F2_b$ 의 출력 노드 j 를 차단한다. 따라서 이 노드는 현재의 Cluster 탐색 과정에서는 제외된다. 그리고 Step 3.으로 간다.

2. Coordinator Stage: 상위층에서 ARTa, ARTb의 동작을 제어하는 단계

이 단계에서는 그림 4에서 F3 층의 Match Control에 의해 하위층 ARTa, ARTb의 동작을 제어하고 각 모듈의 출력을 종합하여 최종적인 분류를 하는 단계이다. 초기 상태에서 F3층의 Match Control은 ARTa와 ARTb 양쪽에서 Commit 신호가 올때까지 기다린다. ARTa와 ARTb 양쪽에서 Commit 신호가 오면 F3 층의 상향 및 하향 LTM 값을 수정하여 학습한다. 그리고 하위층 ARTa와 ARTb 양쪽에 학습신호를 보낸다.

Step 1: F3 층은 ARTa, ARTb의 양쪽에서 Commit 신호가 올 때까지 기다린다.

Step 2: 하위층 ARTa, ARTb의 양쪽에서 Commit 신호가 오면 Match Control은 F3층 동작 알고리즘에 의해 F3 층의 출력 노드를 결정하고 F3 층의 상, 하향 LTM값을 각각 수정한다.

Step 3: Match Control은 ARTa, ARTb 양쪽에 학습 신호를 보낸다. 그리고 Step 1.로 간다.

IV. 실험 및 고찰

ART1 신경회로망 모델에서 자기 척도 기능은 입력 패턴들의 크기가 유사할 경우에는 유효하게 잘 동작한다. 그러나 다양한 크기나 성질의 특징들이 혼합된 입력 패턴을 분류할 경우, 계산 단위를 자동적으로 자기 척도하는 과정에서 패턴을 분류하는데 중요한 역할을 하는 신호가 잡음으로 처리하거나 잡음을 신호로 처리하여 불필요한 부류를 생성하는 문제점이 발생한다. 본 실험에서는 테스트 패턴에 대한 컴퓨터 시뮬레이션을 통하여 ART1 모델의 이러한 문제점을 지적하고 Coupled-ART 모델에 대한 실험 결과를 통하여 ART1 모델의 자기 척도 기능에 대한 문제점을 해결하였다.

그림 6에서 사용된 입력 패턴 P0, P1, P2는 'B', 'E', 'F'를 단순화한 이진 영상이고 P3, P4, P5는 각각 'B', 'E', 'F'의 분기점으로 구성된 Local 특징이다. 그리고 하향 틀(Top Down Template)은 제시된 입력 패턴을

학습하여 LTM에 기억된 패턴들을 의미하며 새로운 입력 패턴이 제시될 때마다 식(13)에 의해 입력 패턴과 기억된 하향 틀간의 유사도를 비교하여 이미 기억된 패턴으로 학습하거나 새로운 패턴으로 분류하게 된다. 그림 6(a)는 P0, P1, P2를 ART1 신경회로망에 의해서로 다른 패턴으로 분류하며 학습한 결과이다. 여기서 ρ_a 는 P0, P1, P2를 서로 다른 패턴으로 분류하기 위한 최소의 경계 인수 값이다. 그림 6(b)는 같은 실험에 의해 P3, P4, P5를 서로 다른 패턴으로 분류한 결과이며 ρ_b 는 P3, P4, P5에 대한 최소 경계 인수 값이다. 이때 경계 인수 $\rho_a=0.85$, $\rho_b=0.67$ 값이 서로 다른 것은 ART1 모델에서 크기가 다른 두 종류의 입력 패턴에 대하여 계산 단위를 자동적으로 다르게 조절하는 자기 척도 기능이 유효하게 동작함을 보여준다.




그림 6. ART1 신경회로망에 의한 자기 척도 실험 결과
Fig. 6. Self-scaling results using ART1 model

그림 7은 그림 6)의 입력 패턴에 대하여 같은 크기의 특징을 추가하여 분류한 결과이다. 그림 7(a)에서 추가된 특징은 학습된 패턴의 크기에 비해 상대적으로 크기가 작아서 잡음으로 간주되어 새로운 인식 부류를 발생하지 않는다. 그러나 그림 7(b)에서 추가된 특징은 학습된 패턴에 영향을 주는 중요한 신호로 간주되어 새로운 인식 부류가 발생함을 알 수 있다.

그림 8은 크기가 다른 두 종류의 특징이 혼합되어 분류를 할 경우에 ART1의 자기 척도의 기능이 제대로 동작하지 않음을 보여준다. 그림 8(a)는 두 특징을 혼합하여 단일 패턴으로 구성한 후 ART1 모델에 의해 분류 실험을 한 결과이다. 여기서 ρ_c 값이 ρ_a 값과 비슷

IO	IP	ART1 Top Down Template				
P0						$P_a = 0.85$
P1						
P2						
P6						
P7						
P8						

(a) 추가 특징의 학습 자리

IO	IP	ART1 Top Down Template				
P3						$P_b = 0.67$
P4						
P5						
P9						
P10						
P11						

(b) 추가 특징에 의한 새로운 분류 생성

그림 7. 자기 척도에 의한 신호와 잡음의 분리
 Fig. 7. Discrimination of signal and noise by self-scaling

한 것은 P3, P4, P5의 크기가 P0, P1, P2보다 매우 작아서 ART1 모델의 자기 척도에 의해 계산 단위를 크기가 큰 패턴에 의존적으로 조절되었기 때문이다. 그림 8(b)는 그림 8(a)의 입력 패턴에 그림 7(a)와 같은 형태로 새로운 특징을 추가하여 분류 실험을 한 경우이다. 이 경우에 추가된 특징은 그림 7(a)와 마찬가지로 학습으로 귀납되어 학습된 패턴에 영향을 미치지 않는다. 그리고 그림 8(c)는 그림 8(a)의 입력 패턴에 그림 7(b)와 같은 형태로 새로운 특징을 추가하여 분류 실험을 한 경우이다. 그러나 이 경우에는 그림 7(b)와 다른 결과를 보여준다. 즉, 그림 7(b)에서는 추가된 특징이 패턴을 구별하는 중요한 신호로 동작하여 새로운 인식

부류를 발생하는데 반해 그림 8(c)에서는 그림 8(b)와 마찬가지로 학습으로 간주되어 새로운 인식 부류를 생성하지 않는다. 그 이유는 자기 척도의 기준이 되는 P_0 의 값의 크기가 큰 패턴에 의존되게 조절되었기 때문이다. 반면 그림 8(c)의 입력 패턴은 그림 7(b)와 같이 분류하기 위해서는 그림 8(c)에서와 같이 P_0 의 값을 0.02 정도로 크게 해주면 된다. 그러나 그림 8(c)의 결과에서 보면 그림 8(c)에서 학습으로 간주되었던 추가 특징이 이번에는 실제로 동작하여 불필요한 부류를 생성한다. 그림 8(c), (c)의 결과에서 알 수 있는 것처럼 ART1 모델은 크거나 정적이 다른 특징들이 혼합된 패턴을 분류할 경우에서 직간하게 동작하지 않을 수 있다.

IO	IP	ART1 Top Down Template				
P0 P3						$P_a = 0.85$
P1 P4						
P2 P5						

(a) 2층 구조에 의한 분류

IO	IP	ART1 Top Down Template				
P0 P3						$P_a = 0.85$
P1 P4						
P2 P5						
P6 P3						
P7 P4						
P8 P5						

(b) 추가 특징의 학습 자리

IO	IP	ART1 Top Down Template				
P0 P3						$P_a = 0.85$
P1 P4						
P2 P5						
P6 P3						
P7 P4						
P8 P5						

(c) 학습 거리의 분배점 1 : 중요 특징의 학습 자리

IO	IP	ART1 Top Down Template						
P0 P3		■	■	■	■			$\rho_0 = 0.92$
P1 P4		■	■	■	■	■		
P2 P5		■	■	■	■	■		
P6 P3		■	■	■	■	■	■	
P7 P4		■	■	■	■	■	■	
P8 P5		■	■	■	■	■	■	

(d) 경계 인수 증가에 의한 새로운 부류 생성

IO	IP	ART1 Top Down Template						
P0 P3		■	■	■	■			$\rho_0 = 0.92$
P1 P4		■	■	■	■	■		
P2 P5		■	■	■	■	■		
P6 P3		■	■	■	■	■	■	
P7 P4		■	■	■	■	■	■	
P8 P5		■	■	■	■	■	■	

(e) 자기 척도의 문제점 2 : 불필요한 부류 생성

그림 8. ART1 신경회로망에서 자기 척도의 문제점
Fig. 8. Problems of self-scaling in ART1 model

그림 9는 제한된 Coupled-ART 신경회로망에 의한 실험 결과이다. 그림 9(a)는 입력 패턴 P0, P1, P2를 Coupled-ART의 하위층의 ARTb 모듈에 입력하고 P3, P4, P5를 ARTa 모듈에 각각 별도로 입력하여 분류 실험한 결과를 보여준다. 여기서 ρ_0 , ρ_1 는 각각 ARTa, ARTb 모듈에서 별도의 판별 기준이 되는 경계 인수 값이다. 그림 9(b)는 그림 9(a)에서 학습된 패턴에 대하여 그림 7(a)와 같은 형태로 실험한 결과를 보여준다. 실험 결과에서 알 수 있는 것처럼 추가된 특징은 ARTb 모듈에 학습된 패턴의 크기에 비해 매우 작아서 잡음으로 간주되어 새로운 부류를 발생하지 않는다. 그림 9(c)는 그림 9(a)에서 학습된 패턴에 대하여 그림 7(b)와 같은 형태로 실험한 결과를 보여준다. 여기서 추가된 특징은 ARTa 모듈에서 학습된 패턴과 차이가 커서 새로운 부류를 발생하기 위한 중요한 신호로 동작하여 새로운 패턴을 생성한다. 그 이유는 ρ_0 와 ρ_1 가 각각 서로 다른 모듈 ARTa 및 ARTb에서 서로 다른

계산 단위를 가지기 때문이다. 그림 9(d)는 그림 9(a)의 입력 패턴에 대하여 같은 크기의 특징을 추가하여 각각 ARTa와 ARTb에 의해 분리하여 분류한 결과이다. ARTa에서 추가된 특징은 ARTa에서 학습된 패턴의 크기에 비해 매우 작아서 잡음으로 간주되어 새로운 부류를 발생하지 않는다. 그러나 ARTb에서 추가된 특징은 ARTb에서 학습된 패턴과 차이가 커서 새로운 부류를 발생하기 위한 중요한 신호로 동작하여 새로운 패턴을 생성한다. 이 결과에서 알 수 있는 것처럼 제한된 Coupled-ART 모델에 의해 복합 특징을 분리하여 처리함으로써 ART1 모델의 자기척도의 문제점을 해결하였고 효율적인 패턴 분류를 할 수 있었다.

IO	IP	CART Top Down Template			
		ARTa	ARTb	ARTa	ARTb
P6 P3		■	■	■	■
P7 P4		■	■	■	■
P8 P5		■	■	■	■

(a) Coupled-ART 에 의한 모듈화된 분류

IO	IP	CART Top Down Template			
		ARTa	ARTb	ARTa	ARTb
P6 P3		■	■	■	■
P7 P4		■	■	■	■
P8 P5		■	■	■	■

(b) 추가 특징의 잡음 처리

IO	IP	CART Top Down Template			
		ARTa	ARTb	ARTa	ARTb
P0		■	■	■	
P1		■	■	■	
P2		■	■	■	

(c) 추가 특징에 의한 새로운 부류 생성

IO	IF		CAET Top Down Template										
	ARTa	ARTb	ARTa				ARTb						
P6 P5	■	■	■	■	■	■	■	■	■	■	■	■	■
P7 P4	■	■	■	■	■	■	■	■	■	■	■	■	■
P8 P3	■	■	■	■	■	■	■	■	■	■	■	■	■

(d) 분리 처리에 의한 자기 척도의 문제점 해결

그림 9. Coupled-ART 모델에 의한 효율적인 패턴 분류 결과

Fig. 9. Efficient pattern classification results using Coupled-ART

V. 결 론

전형적인 패턴 인식 과정에서는 패턴을 효율적으로 분류하기 위하여 패턴에서 추출된 여러가지 형태의 특징들을 추출하여 사용해 왔다. 이러한 특징들은 각 패턴에 대한 전체적인 영상으로부터 추출 가능한 Global 특징들과 구조적인 형태로부터 얻어지는 Local 특징들로 나뉘어진다. 그리고 인식 효율을 향상시키기 위하여 접근 방법에 따라 Global 특징 또는 Local 특징들 중에서 몇가지의 특징을 결합한 다차원적인 특징을 사용해 왔다. 기존의 ART 신경회로망 모델을 이용하여 패턴 분류를 하기 위해서는 다차원적인 입력 특징들을 혼합하여 복잡한 형태의 일차원적인 입력 벡터로 재구성하여 분류한다. 이 과정에서 하나의 경계 인수에 의해 분류하게 됨에 따라 효율적인 경계 인수 조정, 학습 과정의 복잡화, 학습 시간의 지연 등과 같은 여러가지 문제점을 발생한다. 특히, Global 특징과 상대적으로 크기가 매우 작은 Local 특징을 함께 결합된 패턴을 ART1 모델에 의해 분류할 경우, 계산 단위를 자동적으로 자기 척도하는 과정에서 패턴을 분류하는데 중요한 신호를 잡음으로 처리하거나 잡음을 신호로 처리하여 불필요한 부류를 생성하는 문제점이 발생한다.

본 논문에서는 이러한 문제점을 해결하기 위하여 기존의 ART1 모델을 확장하여 신경회로망의 기능을 거시적인 관점에서 구성한 Coupled-ART 모델을 제안하였다. 즉, 신경회로망의 구조를 기능별로 모듈화하고 이러한 모듈들을 서로 밀착된 구조로 결합하여 확장된 기능을 수행하는 형태로 구성하였다. 이러한 모듈화된


신경회로망을 통해 패턴 인식 과정에서 다양한 크기나 성질을 가진 특징들에 대한 분류를 비슷한 크기나 성질을 가진 특징들끼리 분리하여 별도의 판별 기준에 의해 분류하게 된다. 그리고 본 논문에서 제안한 상위층에서 각 모듈의 처리 결과를 종합하여 최종적인 분류를 함으로써 패턴 분류의 효율을 개선할 수 있다. 또한 Coupled ART 모델의 기본 구조를 ART 모델을 이용하여 구성함으로써 기존의 ART 모델이 가지는 자율 학습, 실시간 학습 및 학습된 패턴에 대한 직접 접근 등의 장점을 살릴 수 있다.

테스트 패턴에 대한 분류 실험을 통하여 단일 모듈의 ART 모델에서 패턴을 분류하는 과정에서 중요한 신호를 잡음으로 처리하거나 잡음을 신호로 처리하여 불필요한 부류를 생성하는 자기 척도의 문제점을 지적하였다. 그리고 모듈화된 Coupled ART 모델을 이용한 분류 실험을 통하여 입력 패턴을 비슷한 성질의 특징으로 분리하여 별도의 판별 기준에 의해 분류를 함으로써 ART1 모델보다 효율적인 분류를 할 수 있었다.

VI. 참 고 문 헌

- [1] J. A. Freeman, D. M. Skapura, *Neural Networks : Algorithms, Application, and Programming Techniques*, Addison Wesley Publishing Company, 1991.
- [2] 김 대수, *신경망 이론과 응용*, 하이테크정보, pp. 17-22, 1992.
- [3] R. A. Jacobs, M.I. Jordan and A.G. Barto, "Task decomposition through competition in a modular connectionist architecture: the what and where vision tasks," *Cognitive Science*, vol.15, pp.219-270, 1991.
- [4] S. Grossberg, "Adaptive Pattern Classification and Universal Recording: I. Parallel Development and Coding of Neural Feature Detectors," *Biological Cybernetics*, vol.23, pp.121-134, 1976.
- [5] G. A. Carpenter and S. Grossberg, "A Massively Parallel Architecture for a Self-Organizing Neural Pattern Recognition Machines," *Computer Vision, Graphics, and Image Processing*, vol.37, pp.54-115, 1987.
- [6] G. A. Carpenter and S. Grossberg, "The ART of Adaptive Pattern Recognition by a Self-organizing Neural Network," *IEEE Computer*,

- vol.21, no.3, pp.77-88, 1988.
- [7] G. A. Carpenter and S. Grossberg, "Search Mechanisms for Adaptive Resonance Theory (ART) Architectures," *IJCNN*, Baltimore, Maryland, vol.1, pp.201-205, 1989.
- [8] T. Wang, Q. Xu and X. Xing, "Character Recognition Using Adaptive Resonance Theory(ART)," *IJCNN*, Beijing, China vol.2, pp.761-766, 1982.
- [9] Yannis A. Dimitriadis et al. "On-line Handwritten Symbol Recognition, Using an ART-based Neural Network Hierarchy," *IEEE Int. Conf. on Neural Networks*, San Francisco, California, vol.2, pp.944-949, 1993.
- [10] 이남일, 김향준, 안광선, "확장된 ART 인공 신경망," *정보과학회 논문지*, vol.19, no. 2, pp.140-150, 1992.
- [11] G. A. Carpenter and S. Grossberg, "ART2:Self organization of Stable Category Recognition Codes for Analog Input Patterns," *Applied Optics*, vol.26, no.23, pp.4919-4930, 1989.
- [12] G. A. Carpenter and S. Grossberg, "ART3:Hierarchical Search Using Chemical Transmitter in Self-organizing Recognition Architectures," *Neural Networks*, vol.3, pp.129-152, 1990.
- [13] 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.
- [14] 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.
- [15] A. H. Tan, "Adaptive Resonance Associative Map:A Hierarchical ART System for Fast Stable Associative Learning," *IJCNN*, Beijing, China, vol.1, pp. 860-865, 1992.
- [16] B. Moore, "ART1 and Pattern Clustering," *Proceedings of the 1988 Connectionist Models Summer School*, pp.174-185, Morgan Kaufmann, 1988.
- [17] C. J. Date, *An Introduction to Database Systems*, vol.1, 5th eds. Addison-Wesley Publishing Company, pp.407-408, 1990.



禹容泰(Yong Tae Woo) 정회원
 1982년 : 경북대학교 공과대학
 전자공학과 학사
 1984년 : 경북대학교 대학원 전
 자공학과(전산전공) 석
 사
 1988년 : 경북대학교 대학원 전
 자공학과(전산전공) 박
 사 수료

1987년 ~ 현재 : 창원대학교 전자계산학과 부교수
 ※주관심분야 : 객체지향데이터베이스, 멀티미디어, 신
 경회로망



李南日(Nam Il Lee) 정회원
 1981년 : 경북대학교 공과대학
 전자공학과 졸업
 1986년 : 경북대학교 대학원 전
 자공학과(전산전공) 졸
 업 (석사)
 1993년 : 경북대학교 대학원 전
 자공학과(전산전공) 졸
 업(박사)

1989년 ~ 현재 : 안동대학교 컴퓨터공학과 조교수
 ※주관심분야 : 신경회로망, 패턴인식, 알고리즘



安光善(Kwang Seon Ahn) 정회원

1972년 : 연세대학교 전기공학과
졸업

1975년 : 연세대학교 전자공학과
졸업 (석사)

1980년 : 연세대학교 전자공학과
졸업 (박사)

1977년 ~ 현재 : 경북대학교 컴퓨터
공학과 정교수

1981년 ~ 1982년 : 미국 아리조나주립대학 객원교수

1990년 ~ 1991년 : 미국 텍사스주립대학 객원교수

*주관심분야 : 분리회로, 자동설계, VLSI Testing,
Testable Design