

## 論文

## 패턴 인식을 위한 신경 회로망 모델과 그 학습 알고리즘 개발

正會員 鄭成鍾\* 正會員 劉正守\*\* 正會員 朴貞姫\*

A Design of a Massively Parallel Model and its Learning  
 Algorithm for a Self-Organization Neural Network  
 Pattern Recognition System

Sung Jong Chung\*, Jeong Su You \*\* Jeong Hee Park\* *Regular Members*

## 要約

본 논문에서는 인간 두뇌와 같이 패턴을 인식할 수 있는 능력을 지닌 새로운 신경 회로망 모델과 Unsupervised 학습 알고리즘을 제안하였다. 제안된 모델은 이진 패턴 뿐만 아니라 비선형 패턴도 분류 가능하도록 하였다. 비선형 패턴도 분류할 수 있도록 하기 위해 제안된 알고리즘은 Scofield가 제안한 기존의 학습 알고리즘을 변형한 것이다.

인식 능력을 평가하기 위해서 숫자(2, 4), 영문자(A, B, F), 그리고 한글의 자음(ㄱ, ㄴ)을 training 패턴으로 사용하여 학습한 결과 정확하게 인식함을 입증할 수 있었다. 또한 기존의 방법으로는 분류하기가 어려웠던 비선형 패턴도 거의 완벽하게 분류됨을 시뮬레이션을 통해 입증하였다.

## ABSTRACT

We propose a neural network model and an unsupervised learning algorithm for pattern recognition of a task easily accomplished by human being. Our learning algorithm is based on modified Scofield's learning algorithm in order to calssify nonlinear patterns as well as binary patterns.

Training patterns for evaluation of recognition ability consist of numbers (2, 4), alphabets (A, B, F) and consonants of Hangeul (ㄱ, ㄴ). As a result of learning, our learning algorithm recognize training patterns correctly even nonlinear patterns.

## I. 서 론

점차로 과학 기술이 발달함에 따라 인간의 지적 능

\*全北大學校 工科大學 컴퓨터工學科

\*\*全州教育大學

論文番號：92-135 (接受1992. 4. 15)

력을 요구하는 일들을 컴퓨터에서 처리하는 경우가 늘고 있다. 그러나 아직까지도 컴퓨터는 수치 계산 처리 분야를 제외하고는 인간의 정보 처리 능력에 크게 미치지 못하고 있다. 예를 들면, 컴퓨터에서 인간과 같이 물체나 음성을 인식하는 등의 인식 작업 (recognition tasks)들을 처리하기 위해서는 여러 가

지 제약조건들이 동시에 수반되기 때문에 이를 동시에 처리할 수 있어야 한다. 그러나, 기존의 처리 방식인 순차(sequential) 방식으로는 이러한 처리가 매우 힘들다.

따라서, 이를 극복하기 위해서 동시에 제약조건들을 처리할 수 있는 병렬(parallel) 처리 방식에 관한 연구가 이루어지고 있다. 또한 인간 두뇌(brain)의 생물학적 구조를 모델링하여 인간 두뇌의 정보 처리 방식을 컴퓨터에서 구현해 보려는 신경 회로망(neural network)에 대해서도 많은 분야에서 활발히 연구가 진행되고 있다.

신경 회로망에 대한 적용 분야중에서도 특히, 패턴 인식(pattern recognition) 분야에서 성공을 거두고 있다. 패턴을 인식하는데 있어서 가장 중요한 부분이 패턴들을 분류(clustering, classification)하는 것이다. 이를 패턴 클러스터링(pattern clustering)이라 하는데, 이는 입력된 패턴에서 서로 다른 패턴들을 다른 class로 분류하는 것이다. 따라서 같은 class에 있는 패턴들은 서로 유사하다.

오늘날 패턴을 분류하기 위한 구조와 학습 알고리즘들이 많이 제안되어 영상(image)과 패턴 인식(pattern recognition), 제어(control), 전문가 시스템(expert system) 및 그 밖의 여러 분야에 적용되고 있다. 학습 알고리즘의 대표적인 예로는 supervised 학습 알고리즘인 NEOCOGNITRON[7, 8, 9, 10]과 unsupervised 학습 알고리즘인 ART1[3, 6, 12, 14, 15] 등이 있다. 또한, 겹쳐진(overlap) 패턴이나 비선형(nonlinear) 패턴들도 인식할 수 있도록 Restricted Coulomb Energy(RCE)회로망으로 구성된 Nestor 시스템[13]이 있는데, 이 시스템은 인식률이 좋지 못하다.

따라서, 본 논문에서는 비선형 패턴을 인식할 수 있는 새로운 신경회로망 모델을 제안하였다. 제안된 모델은 Scofield가 제안한 기존의 Coulomb energy network에 적용한 학습 알고리즘을 변형한 것이다.

제안된 모델의 성능을 평가하기 위해서 한글의 자음(ㄱ, ㄴ), 영문자(A, B, F) 그리고 숫자(2, 4) 및 비선형 패턴을 예를 들어 시뮬레이션 하였다.

## II. 패턴 인식을 위한 Unsupervised 신경 회로망 모델

시각 시스템(visual system)은 인간의 시각 시스템

중에서 가장 많이 연구되어온 시스템이다. 이 시스템의 특징은 눈에 가해진 시각 자극(visual stimulus)이 전처리 과정에서부터 시작하여 상위단계로 진행되면서 처리되어 가는 단계적 처리특성을 가지고 있다. 즉, 명암차나 edge와 같은 단순한 형태의 국부적 특징은 초기단계에서 해석되고, 삼각형이나 원, 사람얼굴 같은 더욱 복잡한 특징은 시각 대뇌 피질(visual cortex)보다 더 높은 단계에서 해석된다. 따라서 시각 시스템은 자극 패턴의 단순한 특징을 먼저 추출하여 이것으로부터 더 복잡한 것으로 종합하는 계층적 처리구조를 갖는다고 생각되고 있다. 이러한 계층적 시각 시스템에서는 순방향 신호 흐름과 역방향 신호 흐름이 동시에 존재한다.

시각 시스템을 고찰해 보면, 시각 시스템을 이루고 있는 많은 세포들은 전기적 펄스(action potential)를 firing함으로서 입력 자극에 반응하며, 이 action potential을 출력 fiber, 즉 축색돌기를 따라 전파하여 뇌에 정보를 전달한다. 이 경우 출력 응답은 입력 신호에 대응해서 action potential pulse를 발생하는 firing rate가 된다.

망막이나 대뇌피질은 모두 세포로 이루어져 여러 층으로 구성되어 있고, 각 층내에서 또는 층과 층 사이에서 세포들이 상호 연결되어 있다. 대뇌 피질은 여러개의 세포들이 한개의 군을 형성하는 구조를 가지며 각 군이 입력자극에 대해 똑같은 처리를 행한다. 이러한 세포들의 집합을 filter array로 생각할 수 있으며, 물체의 기하학적인 형태(geometrical form)가 직접 분류되고 인식되는 것은 이 filter의 작용에 의한 것으로 생각되어진다. 각 세포는 receptive field라는 망막의 제한된 영역으로부터 입력을 받아 처리한다. 대뇌 피질이나 다른 시각 영역에 있는 세포들은 그들의 반응함수 특성(response function property)에 따라 simple, complex, hyper complex로 분류한다. 대뇌피질 세포의 반응함수(response function)는 quasi-linear 시스템으로 생각될 수 있으나 visual 시각신경 생리학자들은 많은 세포들에 대해서는 선형적인 근사가 적당하다는 것을 발견하였다.

따라서, 본 연구에서는 인간의 두뇌와 같은 인식 능력을 지닌 새로운 신경망 모델과 학습 알고리즘을 제안하였다.

### 1. 제안된 Unsupervised 신경 회로망 모델

기존의 Coulomb potential energy는 M개의 memory

site  $X_1, \dots, X_M$ 을 갖고 있는 시스템에서 memory site들은 각각 다른 class의 패턴을 나타내는 클러스터로 나누어진다고 가정할 때 다음 식과 같다.

$$\psi = 1 / (2L) \sum_{i=1}^M \sum_{j=1}^M Q_i Q_j |X_i - X_j|^{-L} \quad (1)$$

식(1)에서의 파라메터  $L$ 을 적당하게 선택함으로써 memory 수에 관계없이 입력 패턴이 가장 가까운 memory에 수렴할 수 있게 된다.

Supervised 알고리즘의 경우에는 동일한 class에 속하는 memory site들은 attractive potential energy를 갖도록 하기 위해서 class  $c$ 인 memory site  $i$ 의 charge는 다음과 같이 정의하였다.

$$\begin{aligned} \text{sign}(Q(c)) &\neq \text{sign}(Q(c')), c=c' \\ \text{sign}(Q(c)) &= \text{sign}(Q(c')), c \neq c' \end{aligned} \quad (2)$$

위와 같이 정의함으로써  $\psi$ 는 같은 class에 속하는 모든 memory site들의 쌍들과 서로 다른 class의 memory site 쌍들의 electrostatic potential의 합으로 표현되며, 같은 class의 memory site끼리는 서로 당기게 되어 더욱 가까이 모이게 되고, 서로 다른 memory site들은 서로 밀어내게 되어 더욱 멀어지게 된다.

그러나 본 연구는 외부에서 class( $c, c'$ )에 관한 정보를 전혀 제공하지 않는 unsupervised 모델을 제시하고자 하므로 식(2)를 변경하여  $Q_i$ 는 memory site  $i$ 의 charge로 class( $c, c'$ )에 관한 정보를 주지 않는다. 따라서, 입력 패턴들은 서로 같지 않다고 가정하고 시작한다[식3].

$$\text{sign}(Q(c)) = \text{sign}(Q(c')), c \neq c' \quad (3)$$

1번 째 memory site  $X_i$ 는

$$X_i = \sum_{n=1}^N e_n F_n \left( \sum_{m=1}^K \omega_{nm} f_m \right)$$

이다 여기에서 function  $F$ 는 sigmoid function을 사용하였다.  $e_n$ 는 unit vector로  $n$ 번째 cell을 나타낸다.

$\omega_{nm}$ 은 afferent synaps의 matrix이고  $f_m$ 은 해당 synaps에 연결되어 있는 입력 패턴을 나타낸다. 따라서  $X_i$ 는 afferent 패턴  $f_m$ 과 weight matrix  $\omega_{nm}$ 과의 mapping에 의하여 생기는 회로망의 activity이다.

우리의 energy function은 sigmoid function을 사용하였다. 또한 본 연구에서는 식(1)을 변형하여 비선형 패턴을 분류할 수 있게 하기 위한 objective function을 개발하였다.

$$\psi = 1 / (2L) \sum_{i=1}^M \sum_{j=1}^M y_{ij} |X_i - X_j|^{-L} \quad (4)$$

여기에서,  $y_{ij}$ 는 랜덤 수(random number)를 발생하여 선택된 임의의 두 패턴들 간의 측정을 Euclidean measure를 사용해서 계산한다. 그 결과를 보고 두 패턴들이 어느 정도 유사한지를 알아낸다. 그리고 같은 class의 memory site들은 서로 끌어당기고 다른 class의 memory site들은 서로 밀어낸다. 어느 정도로 끌어당기고 밀어낼 것인지를 결정하기 위해서 식(5), (6) 방법을 제안하였다.

$$t_{ij} = \text{Euclidean\_dist}(f_i, f_j) \quad (5)$$

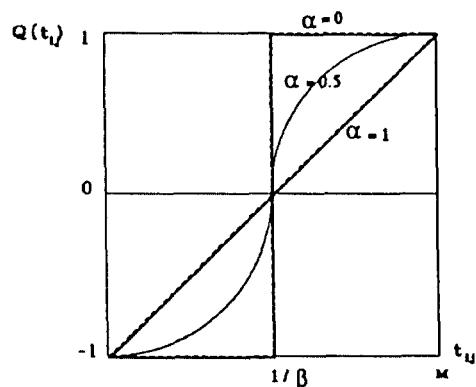
$$y_{ij} = Q(t_{ij}) |1 - \beta t_{ij}|^\alpha \quad (6)$$

여기에서,

$$Q(t_{ij}) = -1, \quad t_{ij} < 1/\beta$$

$$Q(t_{ij}) = |M\beta - 1|^{-1}, \quad t_{ij} > 1/\beta$$

파라메터  $\alpha$ 는 [0, 1] 사이의 값으로  $\alpha=0.5$  일 때 식(6)은 가장 일반적으로 사용하고 있는 sigmoid function이 되고  $\alpha=0$ 인 경우는 hard limiter,  $\alpha=1$  일 때는 linear function이 되게 하였다. (6)식에서 중요한 파라메터가  $\beta$ 이다. 파라메터  $\beta$ 값은 항상  $\text{Max}(t_{ij})$ 보다 작게 할당해야 한다. 식(6)을 도식화 하면 그림 1과 같다.



## 2. 제안된 알고리즘

제안된 학습 알고리즘은 기존의 Coulomb energy network와 같이 network가 ground state, 즉 minimize energy를 갖도록  $\omega_{nm}$ 을 조정하여 반복 계산함으로써 학습이 이루어진다. 이를 위하여 weight  $\omega_{nm}$ 에 대한 potential energy의 descent gradient를 계산하여  $\omega_{nm}$ 의 변화량으로 삼는다.

$$\begin{aligned}\delta\omega_{nm} &= \partial\psi / \partial\omega_{nm} \\ &= 1/(2L) \sum_{i=1}^M \sum_{j=1}^M Q_i Q_j |R_{ij}|^{-(L+2)} R_{ij} \partial\psi \\ &\quad / \partial\omega_{nm} R_{ij} \\ R_{ij} &= X_i - X_j\end{aligned}\quad (7)$$

그러나, 이 식에서는 weight 변화량이 memory site의 쌍( $X_i, X_j$ )의 총합으로 표현되기 때문에 각 node에서는 모든 memory site의 위치 값을 알아야  $R_{ij}$ 를 계산할 수 있고  $\delta\omega_{nm}$ 도 계산할 수 있다. 따라서 본 연구에서는 랜덤하게 memory site의 쌍을 선택하여 각각 계산한 뒤 누적시키는 방법을 사용하였다. 이 방법에 관한 식은 다음과 같다.

$$\begin{aligned}\delta\omega_{nm} &= \partial\psi / \partial\omega_{nm} \\ &= 1/(2L) \sum_{i=1}^M \sum_{j=1}^M Q_i Q_j |R_{ij}|^{-(L+2)} R_{ij} \partial\psi \\ &\quad / \partial\omega_{nm} R_{ij}\end{aligned}\quad (8)$$

식(4)에 대한  $\omega_{nm}$ 의 변화량은 다음과 같다.

$$\begin{aligned}\delta\omega_{nm} &= \partial\psi / \partial\omega_{nm} \\ &= 1/(2L) \sum_{i=1}^M \sum_{j=1}^M Q(t_i) |R_{ij}|^{-(L+2)} R_{ij} \partial\psi \\ &\quad / \partial\omega_{nm} R_{ij}\end{aligned}\quad (9)$$

식(8)(9)은 memory site가 존재하지 않은 상태에서도 적용시킬 수 있다. 다시 말해서 M개의 패턴이 준비되어 있는 상태에서 그 중 2개를 랜덤하게 선택하여 입력층의 afferent line에 연결하여  $\delta\omega_{nm}$ 의 계산을 반복함으로써 신경 회로망의 학습이 이루어지게 된다.

$f(t)$  패턴이 입력으로 들어온에 따른 activity는

$$X(t) = \sum_{n=1}^N e_n F_n \left( \sum_{m=1}^K \omega_{nm} f_m \right)$$

$$\sum_{n=1}^N e_n F_n(f(t)) \quad (10)$$

이다.

앞에서  $\omega$ 에 대한 relaxation procedure를 정의하였으나 이것을 패턴 environment에서의 activity function으로 바꾸어 생각해 보면, 연속된 입력 패턴 ( $f(t), f(t+1)$ )에 대하여

$$\delta\omega_{nm} = (+/-)\eta |X(t) - X(t+1)|^{-(L+2)} \delta_{nm}(f(t), f(t+1)) \quad (11)$$

이다. 여기서 2개의 입력 패턴이 같은 class이면 ‘-’ sign을 서로 다른 class이면 ‘+’ sign을 갖게 된다.  $\eta$ 는 학습률(learning rate)이다.  $\eta$  값이 너무 크면 학습 속도는 빠르나 global minima에 도달하지 못하는 경우가 있다. 또,  $\eta$  값이 너무 작으면 학습 시간이 너무 오래 걸리게 된다. 따라서  $\eta$  값을 적당히 조절해야 한다.

## III. 시뮬레이션

본 장에서는 II 장에서 제안한 알고리즘을 이진 패턴과 비선형 패턴에 적용하여 보았다.

### 1. 마우스 입력 장치를 통한 이진 패턴

본 모델은 마우스로 입력된  $5 \times 5$  이진 패턴을 인식하기 위해서 그림 2와 같은 구조를 구성하였다. 이진 패턴은 비선형성을 지니고 있기 때문에 단일 층으로는 패턴을 분류할 수 없으므로 3개의 층으로 구성하였으며, 여기에는 입력층 25개( $5 \times 5$ ), 각각의 중간층 7개, 5개의 cell(neuron)을 갖도록 신경 회로망을 구성하였다.

신경 회로망에서 학습을 하기 위한 training 패턴으로는 한글의 자음(ㄱ, ㄴ)과 alphabet(A, B, F), 숫자(2, 4) 10개씩을 준비하였다. 이를 마우스 입력 패턴은 그림 3에서 그 중 일부를 보여주고 있다. 이들은 training 패턴의 일부이다.

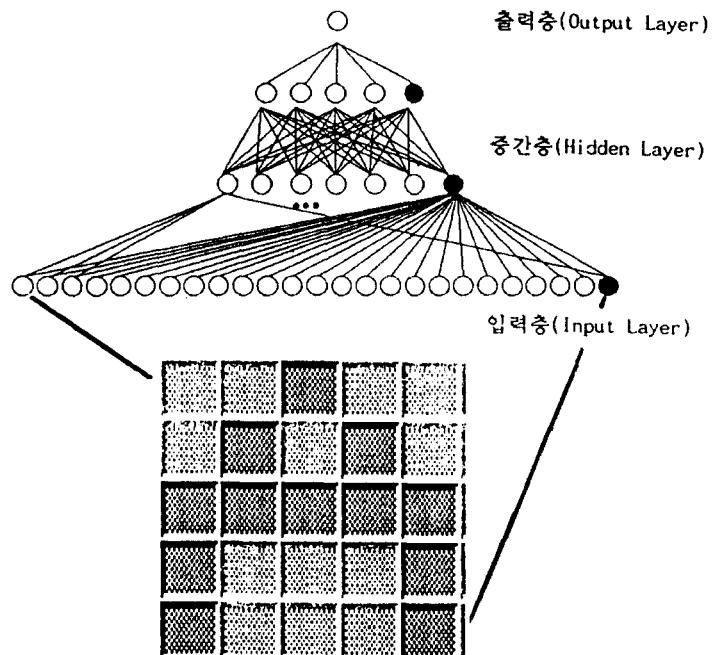


그림 2. 시각 패턴 인식을 위한 신경 회로망 모델

Fig.2. The Neural network model for recognition a visual patterns

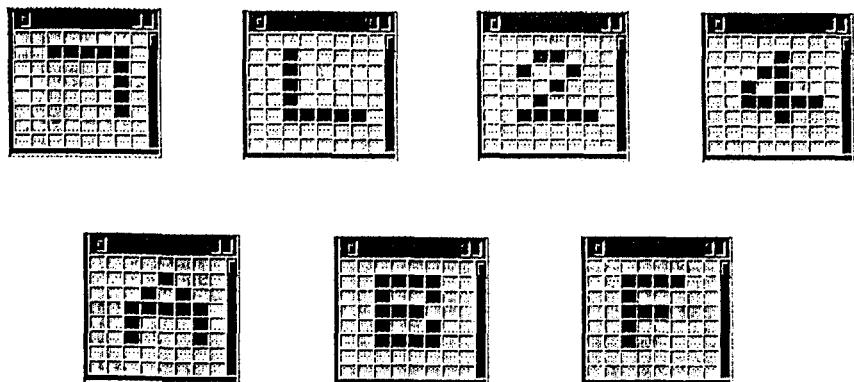


그림 3. Training 패턴의 일부

Fig.3. Some of training patterns

학습하기 위해서 미리 준비된 training 패턴 중에서 임의로 2개를 선택하여 weight변화량을 구하고 이를 조정해 나간다. 초기 weight 값으로 -0.3에서 0.3사이의 랜덤 값을 주었다. 학습률은 0.005,  $\beta$ 는 각 층마다 2.5를 주었다. 그러나 학습을 효과적으로 하기 위해서  $\beta$ 를 학습 과정에서 각 층마다 적절하게 조절해 주어야 한다. 그러나 이는 쉬운 문제는 아니다. 그리고 각 층마다 입력 패턴의 중심을 잘 잡아 상위 층으로 가야 한다. 그렇지 않으면 상위 층으로 학습을 해 나아감에 따라 다른 패턴으로 인식될 수 있기 때문이다. 그림 4는 training 패턴으로 학습한 후 임의의 테스트 패턴 10개에 대한 인식 결과를 보여주는 것이다.

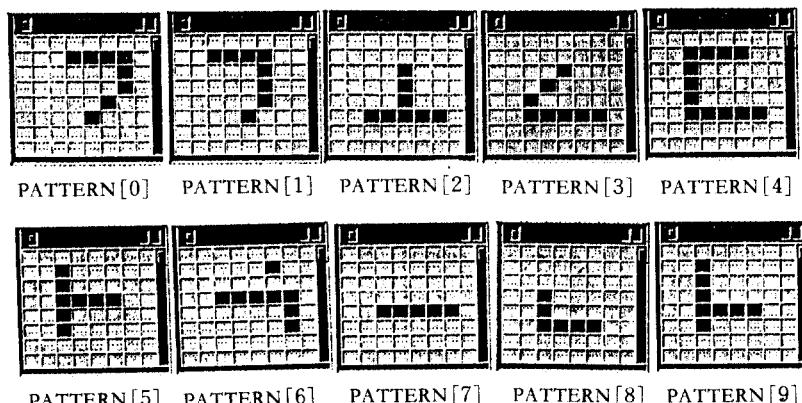
0. PATTERN[0] IS 'ㄱ'
1. PATTERN[1] IS 'ㄱ'
2. PATTERN[2] IS 'NON'
3. PATTERN[3] IS 'ㄴ'
4. PATTERN[4] IS 'NON'

5. PATTERN[5] IS 'NON'
6. PATTERN[6] IS 'ㄱ'
7. PATTERN[7] IS 'NON'
8. PATTERN[8] IS 'ㄴ'
9. PATTERN[9] IS 'ㄴ'

## 2. 비선형(Nonlinear) 패턴

본 장에서는 Ⅱ장에서 제안한 학습 알고리즘을 먼저 그림 5와 같은 비교적 단순한 패턴과 nest된 복잡한 비선형 패턴에 적용해 보았다. 그림 5의 패턴을 분류하기 위한 구조(architecture)는 그림 6과 같다.

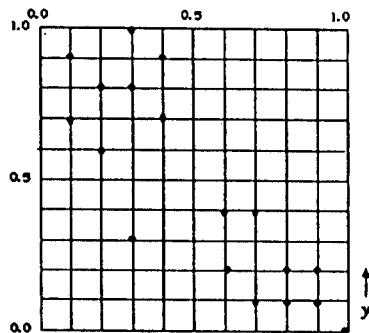
그림 5의 패턴을 분류하기 위해서 20개의 training 패턴을 가지고 학습을 하였다. 초기온도는 0.5로 주고 initial weight는 랜덤하게 -0.3에서 0.3 사이의 값으로 주었다. 학습률은 0.0005로 하고  $\alpha=0.5$ ,  $\beta=2.5$ 를 모든 층에 모두 동일하게 주었다. Training 패턴과 결과는 다음과 같다.



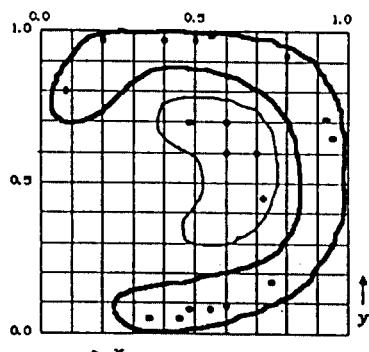
0. PATTERN[0] IS 'ㄱ'
1. PATTERN[1] IS 'ㄱ'
2. PATTERN[2] IS 'NON'
3. PATTERN[3] IS 'ㄴ'
4. PATTERN[4] IS 'NON'
5. PATTERN[5] IS 'NON'
6. PATTERN[6] IS 'ㄱ'
7. PATTERN[7] IS 'NON'
8. PATTERN[8] IS 'ㄴ'
9. PATTERN[9] IS 'ㄴ'

그림 4. 테스트 패턴에 대한 인식 결과

Fig.4. The result of recognition for test patterns



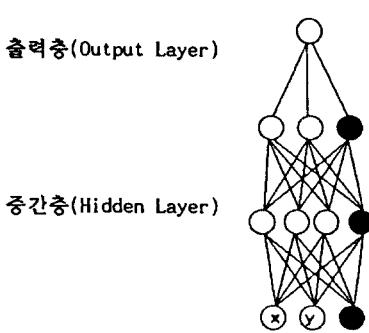
(I)



(II)

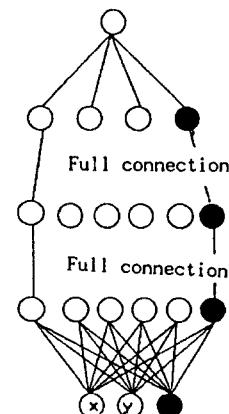
그림 5. 비선형 training 패턴들

Fig.5. Nonlinear training patterns



입력층(Input Layer)

(I)



(II)

그림 6. 비선형 패턴 분류를 위한 구조

Fig.6. The architecture for the classification of nonlinear patterns

[그림5 I] [그림5 II] (\*\*error)

Learning data	Class	Learning data	Class
x	y	x	y
0.6	0.2	0	0.94
0.6	0.4	0	0.95
0.7	0.1	0	0.75
0.8	0.1	0	0.55
0.9	0.1	0	0.6
0.8	0.2	0	0.45
0.9	0.2	0	0.35
0.7	0.4	0	0.71
0.3	0.3	0	0.6
0.2	0.6	1	0.2
0.4	0.7	1	0.4
0.1	0.7	1	0.5
0.3	0.8	1	0.48
0.2	0.8	1	0.6
0.1	0.9	1	0.8
0.4	0.9	1	0.07
0.3	1.0	1	0.48
0.99	0.0	1	0.7
			0**
			0
			1**

시뮬레이션 결과 완벽하게 두 개의 class로 패턴을 분류함을 알 수 있었다. 다음으로 그림 5의(II) 패턴에

대해서도 학습을 했다. (Ⅱ)번 패턴은 (Ⅰ)패턴보다 중간층을 하나 더 추가함으로써 신경 회로망의 성능을 향상시켰다. 이 신경 회로망을 학습시키는데 각 층마다 서로 다른  $\beta$ 값을 부여했다. 그 이유는 입력층에서 출력층으로 학습을 진행하는 과정에서 입력층에 coding된 입력 패턴을 가지고 계산한  $Q(t_i)$ 의 결과를 중간과 출력 층에 동일하게 사용하면서 유사한 패턴은 같은 class로 유사하지 않은 패턴은 다른 class로 분류하기 위함이다. 시뮬레이션 결과 (Ⅱ) 신경 회로망에 크게 영향을 미치는 파라미터는  $\beta$ 인 것을 알 수 있었다. (Ⅱ)신경 회로망은 첫번째 중간층에서 충분히 학습(learning count=9460000)을 하였다. 초기온도는 0.5로 학습률은 0.0005,  $\beta$ 는 4.5, distance는 1.01로 주었다. 층(Layer) 2, 3, 4에서는  $\beta$ 를 동일하게 5.0으로 주었다.

## V. 결 론

기존의 Coulomb Energy Network를 변형하여 제안한 새로운 패턴 인식 모델에 이진패턴(한글 자음, 숫자, 영문자)과 비선형 패턴을 적용하여 제안된 모델의 performance를 측정하여 보았다. 그 결과 intersection부분이 적은 패턴에 대해서는 완벽하게 분류함을 볼 수가 있었다. 그러나, 그럼 5의 (Ⅱ) 패턴과 같이 복잡한 패턴에서는 class가 다르면서 가까이 있는 부분에 대해서는 제대로 인식하지 못함을 볼 수가 있었다. 이 문제는 앞으로 고려해야 할 부분으로  $\beta$ 값을 어느 정도 조정하여 정확한  $\beta$ 의 추정치를 찾으면 해결될 수 있으리라 본다.

학습결과 이진패턴은 완벽하게 분류함을 보았다. 그러나 한글의 경우는 자음, 모음, 받침이 조합되어 있는 패턴이므로 본 모델에서는 이러한 패턴을 인식하기가 어려우리라 본다. 따라서 앞으로는 이러한 문제를 추가하여 모델을 확장하려고 한다. 또한 각 층에서 특징(feature)을 정확하게 감지(detection)할 수 있도록 하고, 정확한 학습 방법에 관한 연구도 병행되어야 한다.

본 모델은 IBM personal computer에서 Turbo C 언어를 사용하여 구현하였다.

이 논문은 1990년도 한국 통신학회의 지원을 받아 수행된 연구임.

## 참 고 문 헌

- Amari S. and Maginu K., "Statistical Neurodynamics of Associative Memory." *Neural Networks*, pp. 63~73, 1988.
- Amit D. J., Gutfreund, H., and Sompolinsky, H., "Spin-grass models of neural networks," *Physics Rev. A2*, pp.1007~1018, 1985.
- Gail A. Carpenter and S. Grossberg, "A Massively Parallel Architecture for a Self-Organizing Neural Network Pattern Recognition Machine. "Computer Vision, Graphics, and Image Processing 37, pp. 54~115, 1987.
- Scofield, C. L., "Learning internal representations in the Coulomb energy networks." *ICON*, vol.1, pp. 271~275, 1988.
- Scofiled, C. L., "Unsupervised Learning in the N-Dimensional Coulomb Network." 1989.
- David M. Clark and K. Ravidhankar, "A Convergence Theorem for Grossberg Learning." *Neural Networks*, vol.3, pp.87~92, 1990.
- A. C. C. Coolen and F. W. Kuijk, "A Learning Mechanism for Invariant Pattern Recognition in Neural Network." *Neural Networks* vol.2, pp.495~506, 1989.
- Fukushima K., "A Neural Network model for selective attention in visual pattern recognition. " *Biological Cybernetics*, 55(1), pp.5~15, 1986.
- Fukushima K., S. Miyake and T, Ito, "Neocognitron : A neural network model for a mechanism of visual recognition, " *IEEE Trans., SMC*, 13, 5, pp.826~834, 1983.
- Fukushima K., "Analysis of the Process of Visual Pattern Recognition by the Neocognition," *Neural Network*, vol.2, pp.413~420, 1989.
- A. D. Gordon, Classification, Chapman and Hall, 1981.
- G. Grossberg, The Adaptive Brain, vol. I, II, North-Holland, 1989.
- MIT / Lincoln Laboratory, DARPA NEURAL NETWORK STUDY, AFCFA International Press, 1987.
- Barbara Moore "ART1 and Pattern Clustering."

- Proc. of the 1988 Connectionist Models, pp.174 ~ 185, 1988.
15. T. D. Sanger, "An Optimality Principle for Unsupervised Learning," Mogan Kaufmann Publishers, pp.11 ~ 19, 1989.
16. Bernard Widrow, Rodney G. Winter and Robert A. Baxter, "Layered Neural Nets for Pattern Recognition," IEEE Trans. on Acoustics, Speech, and Signal Processing, vol.36, No.7, pp.1109 ~ 1118, 1988.

鄭 成 鍾(Sung Jong Chung) 정회원  
1971년 ~ 1975년 : 한양대학교 공학  
사  
1980년 ~ 1982년 : Houston대학교  
공학 석사  
1982년 ~ 1984년 : Houston대학교  
박사과정 수료  
1986년 ~ 1989년 : 충남대학교 공학  
박사  
1991년 : Pennsylvania State University Post Doctor  
1985년 ~ 현재 : 전북대학교 공과대학 컴퓨터 공학과 부교수  
※ 관심분야 : 그래픽스, 문자인식

劉 正 守(Jeong Su You) 정회원  
1980년 ~ 1984년 : 전북대학교 이학  
사  
1984년 ~ 1986년 : 전북대학교 이학  
석사  
1989년 ~ 1992년 : 충남대학교 계산  
통계학과 박사과정 수료  
1992년 ~ 현재 : 전주교육대학 전임  
강사

※ 관심분야 : 문자인식, 신경회로망

朴 貞 姬(Jeong Hee Park) 정회원  
1986년 ~ 1990년 : 전북대학교 공학  
사  
1991년 ~ 현재 : 전북대학교 대학원  
컴퓨터공학과  
※ 관심분야 : 그래픽스, VLSI De-  
sign