

신경회로망을 이용한 손으로 작성된 논리회로 도면
인식 알고리듬

(A Recognition Algorithm for Handwritten Logic Circuit
Diagrams Using Neural Network)

金 德 鈴*, 朴 成 漢**

(Dug Ryung Kim and Sung Han Park)

要 約

본 논문에서는 CAD 시스템의 신경망을 이용한 자동 입력기 구축을 위한 논리 심볼 인식방법을 제시한다. 손으로 작성한 도면을 인식하기 위해 특징 추출과 log mapping, 그리고 패턴 인식의 다단계 과정을 거친다.

각 논리 심볼의 형태 정보를 추출하기 위해 억제 가중치를 학습할 수 있는 경쟁 학습법을 제안하고 회전과 크기의 변화를 명진된 결과로 나타내는 log mapping을 하고 형태가 변한 심볼을 인식할 수 있도록 겹쳐지는 수용야(Receptive field)를 준비하여 error back propagation을 이용한 다층망으로 심볼을 인식한다.

Abstract

In this paper, a neural pattern recognition method for the automatic circuit diagram reading system is proposed. The proposed procedure to recognize a deformed logic symbols is composed of three stages: feature detection, log mapping, and pattern classification.

In the feature detection stage, a modified competitive learning algorithm where each pattern has the inhibition weight as well as the activation weight is developed. The global information of handwritten logic symbols is obtained by the feature detection neural network having both the inhibition and activation weights. The obtained global data is then transformed into a log space by the conformal mapping where according to the Schwartz's theory about the human visual signal processing, the degree of rotation and the scale change are mapped into the translation change. Logic symbols are finally classified by a three layer perceptron trained by the error back propagation algorithm.

The computer simulation demonstrates that the proposed multistage neural network system can recognize well the deformed patterns of hand-written logic circuit diagrams.

*正會員, 金星社 情報機器研究所
(Information System R&D Lab.)

**正會員, 漢陽大學校 電子計算學科
(Dept. of Computer Eng., Hanyang Univ.)
接受日字: 1990年 2月 28日

I. 서 론

컴퓨터 기술의 발달과 인공지능의 연구로 인간의 물체 식별 능력과 유사한 기능을 갖는 시작 시스템의 개발이 오랫동안 활발히 진행되고 있다. 그러나

똑같은 물체의 여러가지 다른 모양을 같은 물체로 인식하거나 자연언어를 처리하거나 하는 인지적인 작업(cognitive task)은 기존의 컴퓨터로는 매우 힘들다.

이런 일들은 인간의 두뇌에서는 아주 자연스럽게 처리된다. 이는 인간의 두뇌가 기존의 von neumann 구조와는 달리 몇 백억개의 신경(neuron)으로 구성되고 병렬 구조를 가지고 있으며 또한 연상 메모리(associative memory) 기능을 갖고 self-adaptation 및 self-organization의 특징을 갖고 있기 때문이다. 따라서 인간 두뇌의 생물학적 구조를 모방한 신경회로망의 연구가 최근 급속히 진전되고 있다. 특히 인간의 두뇌는 자발적으로 정보를 회수하고 처리할 수 있으며 결함이 많고 불완전한 자료로부터 완전하고 가장 근접하게 matching되는 반응을 이끌어 낼 수 있으므로 이를 모방한 신경회로망은 임의성이 많은 영상신호처리, 실제 환경에서의 패턴인식, fuzzy pattern matching, combinatorial optimization 등에 응용될 수 있다.^[1-7]

최근, 반도체 기술의 향상과 전자 산업의 발달로 시스템이 소량 단품종화 되고 있으며 VLSI의 설계에 CAD system의 사용이 그 중요성을 더하고 있다. 그러나 초기 단계의 작업은 숙련된 엔지니어가 도면 위에 직접 설계하게 된다. 이 설계한 내용이 상당히 복잡하거나 양이 많을 때 이것을 CAD system에 입력시키는 작업은 시간이 오래 걸리고 실수를 유발할 경우도 있다. 이 어려움을 극복하기 위해서 도면상의 각 심볼을 인식하고 각 심볼사이의 입출력 관계를 정립하는 자동적인 VLSI-CAD data 입력장치의 연구가 요구되고 있다.^[8-9] 이를 해결하기 위하여 Akio okazaki는 template matching과 특징 추출을 결합한 hybrid 방법을 개발하였다.^[10] 그러나 이 자동적인 회로 도면 입력 장치에서는 인식의 정확성을 높이기 위해 작성률(drawing rule)을 제안하여 논리회로 도면을 작성할 때 각 심볼의 임의성을 줄였고 논리 심볼을 x, y축에 투영(projection)하여 특징을 추출하고 인식하는 방법을 사용했다. 따라서 이 작성률에서 벗어난 심볼을 그리거나 scanner를 사용하여 도면을 입력할 때 도면의 부정확한 위치 선정때문에 전체적인 오인식이 발생하는 어려움이 있다. 이런 문제를 해결하기 위해 본 논문에서는 예러 허용(error tolerance)의 능력이 있는 신경망을 도입한다.

이를 위하여 본 논문에서는 동물의 시각 시스템을 모델로 한 일반적인 경쟁 학습 형태를 갖고 억제성 가중치를 사용하여 특징을 검출하는 변형시킨 경쟁 학습법을 제안한다.^[11]이 제안한 학습법으로 기본적인

특징(primitive feature)을 추출하고 이것을 바탕으로 각 심볼의 형태를 결정하는 특징을 구한다. 또한 각 논리 심볼을 위치와 크기 그리고 회전에 관계없이 인식하기 위하여 동각 로그 사상(conformal log mapping)을 취한다. 이는 망막과 시각 대뇌 피질 사이에서 시각정보는 복잡한 지수적인 변환형태를 취한다는 schwartz의 이론에 따른 것으로 동각 로그 사상을 하면 크기와 회전의 특징이 병진(translational)된 결과로 나타나기 때문에 크기 및 회전에 불변인 특징을 얻는다.^[12] 그리고 형태가 변한 심볼을 인식할 수 있도록 겹쳐지는 수용야 패턴을 입력으로 하는 다단 perceptron을 사용한다.^[13] 이렇게 하여 논리회로 도면상에 나타나는 각 심볼중 논리 심볼 즉 AND, NAND, OR, NOR, NOT, BUFFER gate를 위치와 크기 그리고 회전에 관계없이 인식하는 시스템을 구성한다.

본 논문은 다음과 같은 내용으로 구성된다. 2장에서 제안한 경쟁 학습법을 설명하고 3장에서는 논리회로 도면의 논리 심볼 인식과정을 설명하고 4장에서는 simulation 및 결과를 보이고 5장에서는 결론을 내린다.

II. 경쟁 학습법

1. 경쟁학습의 일반적 형태

모든 신경회로망은 입력패턴을 신경망에 보여주고 그 결과에 따라 가중치를 바꾸어 주는 학습법이 필요하다. 경쟁학습은 출력 신호에 따라 가중치의 값을 바꾸어 주는 것이 아니라 각 신경 노드가 자율적으로 경쟁에 의해 학습하는 방법이다. 따라서 입력 패턴과 출력 패턴의 연관성을 찾기가 무척 힘들기 때문에 경쟁 학습법에 의해 학습된 신경망은 패턴분류기 보다는 특징 검출기의 성격이 더 강하다고 볼 수 있다.

동물 시각 시스템의 특징을 모델로 한 경쟁 학습법은 몇 개의 층으로 이루어져 있으며 각 층은 자극성 연결(excitatory connection)을 통해 상위층으로 연결되는 일반적인 구조를 갖는다. 각 층의 unit들은 몇 개의 cluster로 분류되고 같은 cluster안의 unit은 서로 상대방을 억제한다. 따라서 어떤 층의 cluster 안에 있는 unit들은 아래층에 나타나는 패턴에 응답하기 위해 서로 경쟁하며 어떤 특정한 unit가 입력패턴에 강하게 반응할수록 같은 cluster안의 다른 unit들은 강한 억제 신호를 받는다. 각 cluster는 cluster가 갖고 있는 unit 수 만큼의 특징 group으로 입력 패턴 집합을 분류하며 입력 패턴 집합에 어떤 구조가 있

으면 unit들은 입력·패턴 구조에 맞도록 가중치를 변화시킨다.^[11]

2. 제안한 경쟁학습법

이와 같은 구조의 경쟁학습법에 의해 학습받은 신경망은 입력 패턴들의 자극 위치에 관한 통계적인 특징에 의해 입력 패턴을 몇개의 집합으로 분류하게 된다. 그러나 이 자극성 가중치에 의한 정보의 전달만으로는 특징검출에 의한 패턴 분류기로서 바람직한 인식 결과를 얻을 수 없다. 그것은 입력패턴의 형태를 결정짓는 자극되는 노드의 위치가 비슷하지만 각 패턴에 부여된 의미가 상당히 다른 패턴이 존재할 수 있기 때문이다. 예를들면 그림 1의 (a)는 알파벳의 t를 의미하고 그림 1의 (b)는 아라비아 숫자의 1을 의미하지만 자극성 가중치에 의한 통계적인 특징을 검출하는 신경망에서는 두 패턴을 같은 그룹으로 구분할 경우가 있을 수 있다. 또한 다른 그룹으로 구분한다 해도 그림(c)와 같이 (a)와 (b)의 형태를 포함한 패턴 혹은 두 패턴의 특징을 반 씩 가지고 있는 패턴이 입력으로 들어온 경우 많은 어려움이 따른다. 이런 문제의 해결 방법으로서 신경망이 어떤 패턴을 분류할 때 다른 패턴을 적절히 억제하는 억제 가중치를 갖고 있다면 서로 다른 패턴을 적절히 억제하여 정확한 분류가 가능하게 된다. 따라서 억제성 가중치를 갖도록 하기 위하여 학습할 입력패턴의 노드값에 억제값(음수값 -1)을 포함하는 패턴을 학습하여 다른 패턴들을 서로 적절히 억제하도록 한다.

본 논문에서 사용되는 특징 패턴을 추출하기에 적합한 경쟁 학습법은 다음과 같다.

○Unit들은 서로 겹치지 않는 cluster로 구분된다.

가장 큰 입력을 받는 unit는 active value 1을 가지며 가장 작은 입력을 받는 unit는 active value -1을 가지며 다른 unit는 inactive value 0를 갖는다.

○Cluster내의 모든 unit는 똑같은 입력 line에서 input을 배운다.

1	1	1
0	1	0
0	1	0

(a)

0	1	0
0	1	0
0	1	0

(b)

1	1	1
0	0	0
0	1	0

(c)

그림 1. “t”와 “1”的 패턴

Fig. 1. The pattern of “t” and “1”

○입력 자극 패턴의 각 요소는 1, -1, 0의 값을 갖는다.

○입력층과 출력층 사이의 연결은 억제 및 자극가중치를 갖는다.

○입력층의 unit i에서 출력층의 unit j사이의 가중치를 W_{ij} 라하면 가중치 W_{ij} 는 그 절대값이 1보다 크지 않게 한다.

모든 양의 가중치의 합은 1, 모든 음의 가중치의 합은 -1이 되도록 한다.

즉 $\sum W_{ij} > 0$ 이면

$$\sum_i W_{ij} = 1 \quad (1)$$

이고 $\sum W_{ij} < 0$ 이면

$$\sum_i W_{ij} = -1 \quad (2)$$

이다.

○Unit가 경쟁에서 우세하면 가중치는 각 active line이 강화되는 방향으로 증가한다. 이때 각 input line은 학습율 (learning rate) σ 만큼씩 자기 가중치를 포기하여 각 active line에 똑같이 분배한다.

$$\Delta W_{ij} = \begin{cases} \phi(\text{zero}) & \text{unit } j \text{가 경쟁에} \\ & \text{졌을 때} \\ \frac{\sigma_{\text{(element)}_{ik}}}{\sigma_{\text{(inactive)}_k}} - \sigma W_{ij} & \text{unit } j \text{가 경쟁에서} \\ & \text{이겼을 때} \end{cases} \quad (3)$$

이때 ΔW_{ij} 는 학습할 때 각 가중치의 변화치이며 $(\text{element})_{ik}$ 는 입력패턴 k에서 i번째 요소의 값이고 $(\text{inactive})_k$ 는 $(\text{element})_{ik}$ 가 1일 때는 1인 line의 갯수이고, $(\text{element})_{ik}$ 가 -1일 때는 -1인 line의 갯수이다. 식(3)의 $(\text{inactive})_k$ 에 의해 각 가중치의 절대값이 결정되며 $(\text{element})_{ik}$ 에 의해 양의 가중치와 음의 가중치로 분리된다.

이 제안한 경쟁 학습법은 학습시 positive unit에의 한 특징 검출과 negative unit에 의한 특징 검출의 이원적인 구조를 이루고 있다. 따라서 규칙성을 찾는 신경망을 학습할 때 양(positive)의 요소와 음의 요소가 서로 다른 구조를 갖는 패턴의 경우 학습의 어려움을 겪을 수도 있으나 우리가 실제로 필요한 어떤 패턴의 특징을 학습할 때는 그런 경우가 거의 드물다.

학습할 패턴에 억제 요소를 삽입하므로 학습이 완료된 후에 억제성 가중치가 존재하기 때문에 검출하고자 하는 패턴 이외의 모양에 대해서 상당한 억제를 가하게 된다.

본 논문에서는 바로 이런 특성을 이용하여 특징패턴을 검출한다.

III. 논리회로로 도면 인식 시스템

논리 회로로 도면 인식의 목적은 도면상의 각 심볼을 인식하고 심볼간의 입출력 관계를 정립하여 전송하는 CAD시스템의 자동 입력 장치를 구현하는 것이다. 이를 위한 회로로 도면 인식 시스템의 전반적인 구조는 그림 2와 같다.^[8-10]

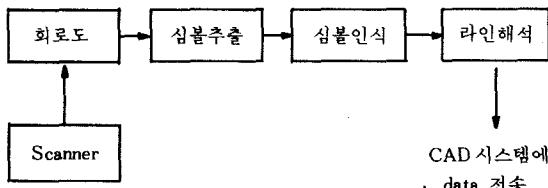


그림 2. 회로로 도면 인식 시스템 구성도

Fig. 2. The block diagram of the circuit diagram reading system.

회로로 도면 인식 과정 중 도면상의 심볼을 인식하는 과정이 필수적이다. 그러나 일반적으로 엔지니어들이 회로도면을 그릴 때 습관에 따라 AND심볼도 그 형태나 크기가 다른 여러 종류로 그리게 된다. 따라서 회로도 입력 시스템(circuit diagram reading system)의 개발에 있어서 도면 작성자에 무관한 인식체계가 필요하다. 이를 위하여 패턴 분류와 특징 추출에 적합한 신경망 개념을 도입한다.

본 논문에서 AND OR NAND NOR NOT BUFFER 등의 각 논리 심볼을 인식하는 논리 심볼 인식은 그림 3의 구성을 거친다.

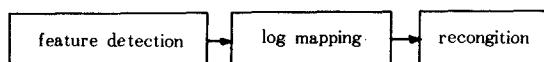


그림 3. 각 논리 심볼 인식 과정

Fig. 3. The recognition procedure of a symbol.

1. 특징 추출을 위한 기본 특징(primitive feature) 패턴 선택

각 심볼을 인식하는 방법은 국부적인(local) 정보로서 각 심볼을 대표하는 독특한 특징을 이용하여 인식하는 방법과 전체적인(global) 정보로서 각 심볼을 결정하는 기하학적인 특징을 이용하여 회로를 인식하는 방법이 있다. 전자의 경우는 인식 방법이 간단하지만 회전과 noise로 인해서 대표적인 특징 패턴이 왜곡된 경우 인식이 어렵다. 따라서 본 논문에서는

왜곡이나 회전, 그리고 크기가 변한 경우라도 각 심볼의 특징을 잃지 않고 전체적인 형태를 유지하는 후자의 방법을 택한다. 또한 이 방법은 엔지니어가 아무리 다르게 심볼을 표시한다 해도 그 심볼을 인식할 수 있는 특징이 남아 있다면 그 심볼을 인식할 수 있는 최소한의 공통적인 특징을 검출하는 방법이기도 한다.

본 논문에서 인식하고자 하는 심볼들은 페루프로 구성되어 있기 때문에 각 심볼의 특징점은 선의 각도가 변하는 위치와 라인이 교차되거나 분리되는 위치를 점으로 구성한 패턴을 특징 패턴으로 정의했다. 그러나 각도가 변하는 패턴은 수없이 많기 때문에 그쳤을 모두 학습할 수 없어서 각 심볼을 5×5 마스크 상의 0도 45도 90도 135도의 4방향 성분과 각 방향에 수직인 두 방향으로 각 선의 성분을 분리하고, 검출한 각 선의 4방향 성분이 다른선의 성분과 간섭을 일으키는 점을 찾기 위해서 모든 선의 성분을 각각의 방향으로 확산시켜 각 선의 성분이 연결하여 겹쳐지는 점을 심볼을 인식할 특징점으로 삼았다.

5×5 마스크상의 4방향 성분은 각각 45도 방향의 성분을 A, 90도 방향의 성분을 B, 135도 방향의 성분을 C, 0도 방향의 성분을 D라 할당하고 마스크의 중심에 각 성분 A, B, C, D 패턴을 표시하면 그림 4와 같다.

또한 4방향 성분이 어떤 물체의 에지를 이루거나 각 선의 두께가 5 pixel을 넘는 경우에 각 방향에 수직인 두 방향으로 분리되어 도합 8개의 패턴으로 구분되어 그림 5와 같은 모양을 갖는다.

2. 특징 추출 신경망

심볼의 특징을 추출하는 신경망의 전체적인 구조는 그림 6과 같다. 40×60 의 입력노드로 이루어진 입력층과 이진 영상의 경계점을 추출하는 40×60 의 8개의 층과 각 게이트의 꿀꺽을 추출하는 40×60 의 4개의 층으로 독립되게 구성되고 40×60 의 출력층은 8개의 층으로부터 억제신호를 4개의 층으로부터 자극신호를 받는다. 출력층은 억제성 입력 및 자극성 입력을 12개의 층으로부터 받아서 그 결과를 다시 입력층에 가한다. 입력층은 8개의 에지 추출층과 억제성 및 자극성 가중치로서 연결되어 있고 4개의 꿀꺽층과는 자극성 가중치로 연결되어 있다.

또한 심볼의 특징을 검출할 때 출력층은 4방향의 꿀꺽을 검출하는 4개의 층으로부터 검출된 각 방향으로 확산된 신호를 받는다. 이 확산된 신호가 겹쳐지는 점을 특징점으로 추출한다.

각 패턴은 25개의 입력노드와 8개의 출력노드로

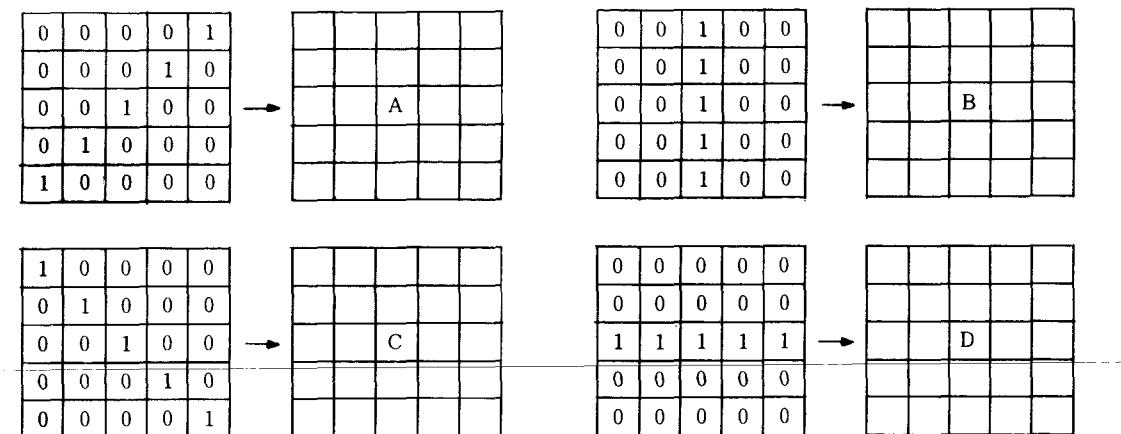


그림 4. 4방향 성분 표시

Fig. 4. Four-directional components.

1	1	1	1	1
1	1	1	1	0
1	1	1	0	0
1	1	0	0	0
1	0	0	0	0

1	1	1	0	0
1	1	1	0	0
1	1	1	0	0
1	1	1	0	0
1	1	1	0	0

1	0	0	0	0
1	1	0	0	0
1	1	1	0	0
1	1	1	1	0
1	1	1	1	1

0	0	0	0	0
0	0	0	0	0
1	1	1	1	1
1	1	1	1	1
1	1	1	1	1

0	0	0	0	1
0	0	0	1	1
0	0	1	1	1
0	1	1	1	1
1	1	1	1	1

0	0	1	1	1
0	0	1	1	1
0	0	1	1	1
0	0	1	1	1
0	0	1	1	1

1	1	1	1	1
0	1	1	1	1
0	0	1	1	1
0	0	0	1	1
0	0	0	0	1

1	1	1	1	1
1	1	1	1	1
1	1	1	1	1
0	0	0	0	0
0	0	0	0	0

그림 5. 8종류의 에지 형태

Fig. 5. The edge pattern of 8 class.

구성된 단층 신경망에서 경계점을 검출하기 위해서 24종류의 패턴을 경쟁 학습법에 의해 배우고 또한 25개의 입력 노드와 4개의 출력 노드로 구성된 단층 신경망에서 4방향 성분을 검출하기 위해서 12개의 패턴을 경쟁 학습법에 의해 배운다. 따라서 학습이 끝난 후 경계점을 추출하기 위해 각 출력 노드가 경쟁을 할 때는 오직 같이 학습받은 8개만이 경쟁하고 골격을 추출할 때는 오직 같이 학습받은 4개만이 경쟁하게 된다.

8개의 경계점 출력 노드는 학습된 각 패턴의 억제 가중치에 의해 각 심볼의 경계점을 추출한다. 이때 추출되는 경계점은 각 계이트를 구성하는 골격의 두께가 2화소 이상인 경계점이다. 경쟁 학습법은 각 노드에 가해지는 자극 신호의 횟수에 대한 통계적인 특성이 있으므로 학습시킬 패턴을 선정함에 있어서 에지를 추출하기 적합한 24개 패턴을 차례로 학습한다. 24개의 패턴 중 A성분의 에지를 검출하기 위해 사용한 6개의 패턴은 그림 7과 같다. 또한 4방향 성

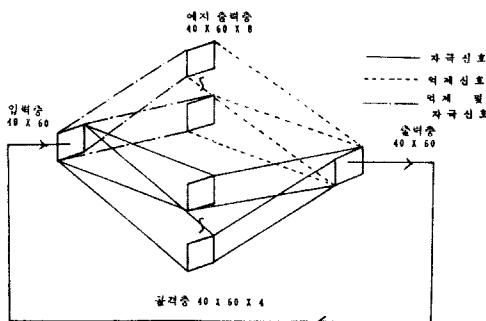


그림 6. 제안한 특징 추출 신경망

Fig. 6. The proposed neural network model for feature detection.

0	1	1	1	1
1	1	1	1	-1
1	1	1	-1	-1
1	1	-1	-1	-1
1	-1	-1	-1	-1

-1	-1	-1	-1	1
-1	-1	-1	1	1
-1	-1	1	1	0
-1	1	1	1	0
1	1	1	0	0

0	1	1	0	0
1	1	1	0	0
1	1	1	0	0
0	0	0	-1	-1
0	0	0	-1	-1

-1	-1	0	0	0
-1	-1	0	0	0
0	0	0	1	1
0	0	1	1	0
0	0	1	0	0

0	1	1	0	0
1	1	0	0	0
1	0	1	0	0
0	0	0	-1	0
0	0	0	0	-1

-1	0	0	0	0
0	-1	0	0	0
0	0	1	0	1
0	0	0	1	0
0	0	1	0	0

그림 7. A성분의 경계점을 구하기 위해 학습한 6개의 패턴

Fig. 7. The six class of patterns learned for finding the edge point of A-directional component.

분을 추출하기 위해 학습하는 패턴은 5×5 마스크상의 중심점이 큰 가중치를 갖도록 12개 패턴을 차례로 학습한다. 12개의 패턴 중 A성분을 검출하기 위해 사용한 3개의 패턴은 그림 8과 같다.

0	0	0	0	1
0	0	0	1	0
0	0	1	0	0
0	0	1	0	0
0	1	0	0	0

0	0	0	0	0
0	0	0	1	0
0	0	1	0	0
0	0	1	0	0
0	1	0	0	0

0	0	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	0
0	0	0	0	0

그림 8. 골격선의 A성분을 구하기 위해 학습한 3 패턴

Fig. 8. The three patterns learned for finding the skeleton of A)directional component.

각 패턴을 학습한 후에 신경망에 심볼 패턴을 가하면 각 노드들은 경쟁을 하게 된다. 경쟁에서 이긴 노드의 출력값은 적당한 문턱치(threshold)를 갖는다. 신경망을 패턴 인식에 적용할 때 입력 패턴의 임의 성 때문에 출력값의 문턱치 적용은 필연적이다. 또한 골격의 두께가 2화소 이상인 패턴을 검출하기 위해서 8개의 경계선을 검출하는 노드의 문턱치(threshold)는 전체의 가중치 합의 2/3이상인 0.79로 했고 4방향의 골격선을 찾는 노드의 문턱치는 0.6으로 했다. 또한 출력층은 0을 문턱치로 사용했다.

입력 패턴이 특정 추출 신경망을 한번 거치게되면 8개의 경계점 추출층에서 경계점을 추출하여 억제신호 -1을 출력층에 출력하고 4개의 골격 추출층에서 입력 패턴의 골격을 추출하여 자극신호 1을 출력층에 출력한다. 출력층에서 억제신호와 자극신호를 합한 결과로 나타나는 패턴은 패턴의 경계점이 한 화소씩 없어지게 되고 이것이 다시 입력층으로 가해지게 된다.

이런 과정은 8개의 출력층의 출력값의 합이 0이 될 때까지 계속된다. 따라서 임의의 패턴은 위의 과정을 한번씩 거칠 때마다 골격선의 두께가 2화소씩 감소하게 되어 1내지 2화소의 두께로 thinning 및 4 방향으로 근사화된 결과가 된다. 1내지 2의 두께로 구해진 패턴은 4개의 층에서 구해진 방향 성분을 가지고 있다. 따라서 특징점을 구하기 위해 자신의 각 방향으로 확산을 한다. 이때 확산될 수 있는 조건은 연속해서 같은 방향의 특성이 나타날 때이다.

4방향의 확산이 끝나면 4개의 층에서 1의 값을 출력하여 문턱치를 2로하여 겹쳐진 부분을 구하고 이것을 특징점으로 구하게 된다.

3. Log mapping^[12]

크기와 회전에 불변인 데이터를 얻기 위해 log polar mapping을 시도한다. 경쟁 학습에 의해 얻은 특

정점들은 각 심볼을 대표하는 특징점으로서 이들 특징점 상호간의 상대적인 위치 관계에 의해서 각 심볼이 구분될 수 있다.

각 특징점의 상대적인 위치 관계는 기하학적인 중심점을 기준점으로 하여 구할 수 있다. 이때 기하학적인 중심점은 각 특징점을 모두 다각형 내에 포함하도록 하는 특징점을 꼭지점으로서 연결한 다각형의 중심점을 사용한다. 패턴의 기하학적인 중심점을 실수축 x 와 허수축 y 의 원점으로 잡고 중심점으로부터 각 특징점의 거리 R 과 각도 σ 를 구하면 각 특징점의 위치는 $Z = X + iY$, 또는 $Z = R \exp i\sigma$ 로 표시될 수 있다. 이때 $R = |Z|$, 그리고 $\sigma = \arg Z$ 이다. Z 에 \ln 을 취한 등각 사상은 크기와 회전을 $i\sigma$ 축과 R 축 영역에서 각각 병진된 결과로 나타낸다.

$$\begin{aligned} \ln Z &= \ln(\alpha R) \exp i(\sigma + \beta) \\ &= (\ln \alpha + \ln R) + i(\sigma + \beta) \end{aligned} \quad (4)$$

로 표현된다.

본 논문에서는 중심점에서부터 가장 거리가 먼 특징점의 거리 R_1 을 구한 후 이 특징점을 기준으로하여 다른 특징점의 거리를 정규화한다. 수식으로 표현하면 다음 (5)식과 같다.

$$\begin{aligned} \ln Z_1 &= 100 * \ln(1 + (R_1 / R_{max})) E_{xp} i \sigma \\ &= 100 * (\ln(R_{max} + R_1) - \ln R_{max}) + i \sigma \end{aligned} \quad (5)$$

이것은 log map상에서 R 축에 대해서 $\ln R_{max}$ 만큼 각 특징점의 위치를 원점으로 이동시킨 결과를 낸다. 이때 비례 상수 100은 정규화한 특징점들의 $\ln R$ 값이 1에서 69까지 범위를 한정하는 역할을 한다. 로그매핑한 결과 크기에 관계없이 회전된 범위가 병진된 결과로 나타난다. 따라서 회전된 패턴을 학습할 때 모든 각도에 대해서 특징점을 찾을 필요없이 패턴을 병진시켜서 회전된 패턴의 특징을 구한다.

4. Error back propagation을 이용한 인식^[13]
Log mapping된 패턴은 논리 심볼의 형태에 관한 전체적인 정보이다. 그러나 여러가지 AND 심볼은 어느 정도 변화된 패턴이 나타나게 된다. 이 변화된 패턴에 임의성을 주기 위하여 거리와 각도 범위가 겹친 10×8 의 수용야(receptive field) 패턴을 준비한다. $\ln r$ 축과 $i\sigma$ 축을 표 1과 같이 서로 겹치게 수용야를 설정한다. 특징점의 변화된 좌표가 $r + i\theta$ 일 때 수용야에 0과 1의 패턴 값이 결정된다. 즉 $15 + i35$ 은 수용야 패턴 $pat[1][2]$ 에 1의 값을 할당하고, $26 + i66$ 은 수용야 패턴 $pat[2][2]$, $pat[3][2]$, $pat[2][3]$, $pat[3][3]$ 에 1의 값을 할당한다.

표 1. 겹쳐진 수용야 패턴

Table 1. The overlaped receptive field.

(1 < r < 22) $p = 1$	(330 < θ < 360) or (0 < θ < 30) $pat[p][1] = 1$
(20 < r < 27) $p = 2$	(15 < θ < 75) $pat[p][2] = 1$
(25 < r < 32) $p = 3$	(60 < θ < 120) $pat[p][3] = 1$
(30 < r < 37) $p = 4$	(105 < θ < 165) $pat[p][4] = 1$
(35 < r < 42) $p = 5$	(150 < θ < 210) $pat[p][5] = 1$
(40 < r < 47) $p = 6$	(195 < θ < 255) $pat[p][6] = 1$
(45 < r < 52) $p = 7$	(240 < θ < 300) $pat[p][7] = 1$
(50 < r < 57) $p = 8$	(285 < θ < 345) $pat[p][8] = 1$
(55 < r < 62) $p = 9$	
(60 < r < 70) $p = 10$	

심볼을 인식할 신경망은 다층망을 이용하여 error back propagation 방식으로 학습을 한다. 입력층의 노드수는 80이고 첫 번째 숨은층의 노드수는 30이고 두 번째 숨은층의 노드수는 24이며 각 심볼을 인식하는 출력층의 갯수는 인식할 패턴의 갯수 6에 맞춘 표 2의 hot코드를 사용한다.

표 2. 각 심볼의 출력 패턴

Table 2. The desirable output pattern of each symbols.

AND	1	0	0	0	0	0
NAND	0	1	0	0	0	0
OR	0	0	1	0	0	0
NOR	0	0	0	1	0	0
BUFFER	0	0	0	0	1	0
NOT	0	0	0	0	0	1

IV. 시뮬레이션 및 고찰

본 논문에서 사용한 영상 데이터는 PC-IN502 스캐너를 이용하여 1인치 당 90 dot의 해상도로 얻은 것이다. 이때 noise를 제거할 목적으로 각 라인상의 dot와 연속적인 바로 아래 라인의 dot를 or하는 ORing option은 사용하지 않는다. 비록 noise가 나타난다 해도 ORing하지 않은 영상이 각 심볼의 특징을 명확히 표시하기 때문이다.

시뮬레이션에서 사용한 데이터는 스캐너로부터 6 심볼 3 set를 0도 방향과 45도 방향 그리고 180도 방향에 대해서 40×60 의 해상도로 취득한 것이고 이때 취득한 논리 심볼의 두께는 그림 9와 같이 보통 3 내지 6화소로 나타낸다.

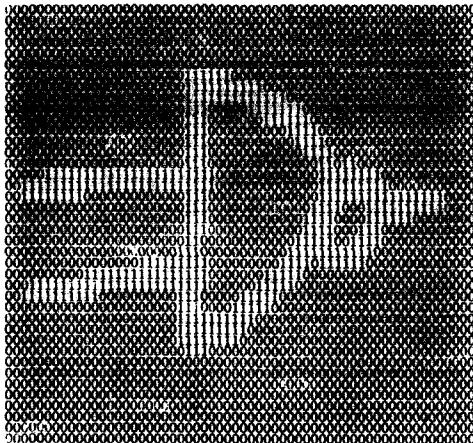


그림 9. 스캐너로 부터 얻은 NAND 심볼 패턴
Fig. 9. The NAND symbol pattern obtained from scanner.

PC-AT로 특징 추출 신경망을 학습시켰으며 이때 학습율은 (learning rate) 0.05로 했다. 그림10은 특징추출 신경망에 의한 0도 방향에 있는 NAND 심볼의 4방향 근사화 및 thinning된 결과이고 그림11은 이 정보를 바탕으로 각 4방향으로 확산하여 얻은 NAND 심볼의 특징이다. 그림12는 그림 9의 NADN 심볼의 특징 패턴을 로그 매핑한 결과이다. 마지막으로 그림13은 AND 심볼과 NOR심볼 OR심볼을 로그 매핑한 결과이다.

그림12의 log mapping된 NAND 심볼을 1화소 씩 명진시켜 얻은 8개의 패턴을 모두 NAND 심볼로 학습한다. 각 심볼 3 set의 특징 패턴을 구하고 1화소 씩 명진된 패턴 144개를 담은 신경망의 입력 패턴으로 학습시켰다. 이때 gain term은 0.6, momentum 은 0.5의 값으로 했으며 학습 완료 조건으로서 각 노드의 출력값이 1의 값은 0.7이상, 0의 값은 0.3이하일 경우 각각 1과 0으로 근사화하여 학습했다. 학습결과 학습한 패턴의 인식율은 당연히 100%로 나타났지만 학습하지 않은 패턴은 학습율이 떨어졌다. 그러나 인식율을 산출할때 문턱치를 고정시켜 놓고 최고값을 갖는 화소위치를 산출하지 않고 다만 최고값을 가지는 화소의 위치만을 검출한 경우에는 인식율이 92%로 나타났다.

표 3은 각 방향에 대해 학습된 논리 심볼의 인식 결과이다. 그리고 표 4는 학습받지 않은 논리 심볼의 인식 결과이다. 이 결과에서 학습받지 않은 논리 심볼은 그 출력값이 크게 분산되어 나타나는 것을

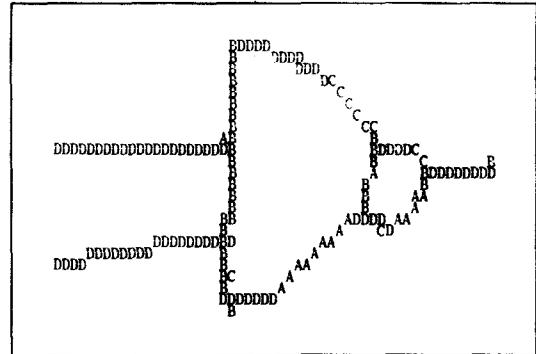


그림10. 특징추출 신경망을 통과한 NAND 심볼 패턴
Fig. 10. The NAND symbol pattern that pass the feature detection neural network.

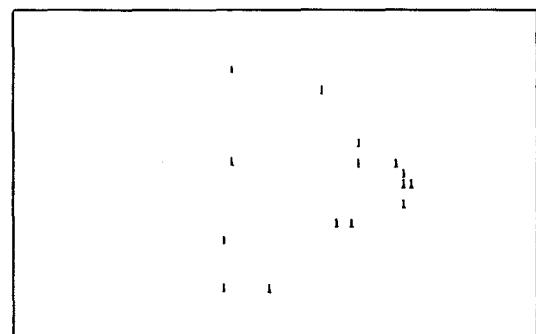


그림11. 4방향 확산에 의한 NAND 심볼 패턴의 특징점
Fig. 11. The feature point of NAND symbol pattern by 4-directional expantion.

0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
1	1	0	0	0	0	0	0	0
0	1	0	0	0	0	0	0	0
0	0	1	1	1	0	0	0	0
0	0	0	1	1	1	1	0	0
1	0	0	0	1	1	0	0	0
1	0	0	0	1	0	0	0	0

그림12. NAND심볼의 log mapping한 결과
Fig. 12. The log mapping result of the NAND symbol pattern.

0 0 0 0 0 0 0 0 0	0 0 1 1 0 0 0 0 0	0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0	0 0 0 0 0 0 0 1 0	0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 1 0	0 0 1 1 0 1 1 0	0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0	0 0 1 1 0 1 1 0	0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 1 1	0 0 0 0 0 1 1 0	0 0 0 1 0 1 0 1 0
0 0 0 0 0 0 0 1	0 0 0 0 0 0 0 0 0	1 0 0 1 0 0 0 0 1
1 1 1 1 0 0 0 0	0 0 0 0 0 0 0 0 0	1 0 0 0 0 0 0 0 1
0 1 1 1 1 0 0 0	0 1 1 0 0 0 0 0 0	1 1 0 1 1 0 1 0
0 0 1 1 0 0 1 0	0 0 0 0 0 0 1 0	1 0 1 1 0 0 1 0
0 0 0 1 0 0 1 0	1 0 0 1 0 1 1 0	0 0 0 1 1 0 0 0 0

(a) (b) (c)

그림13. Log mapping 결과

- (a) AND 심볼
- (b) NOR 심볼
- (c) OR 심볼

Fig. 13. The log mapping result.

- (a) the AND symbol pattern,
- (b) the NAND symbol pattern,
- (c) the OR symbol pattern.

표 3. 학습한 논리 심볼의 출력값

Table 3. The output of the learned logical symbols.

	AND	NAD	OR	NOR	BUF	NOT
AND1($\angle 0^\circ$)	0.98	0.20	0.29	0.23	0.12	0.04
AND2($\angle 0^\circ$)	0.82	0.00	0.01	0.28	0.16	0.18
NAD1($\angle 0^\circ$)	0.29	0.85	0.25	0.00	0.00	0.13
OR1 ($\angle 0^\circ$)	0.21	0.05	0.91	0.24	0.11	0.25
NOR1($\angle 0^\circ$)	0.01	0.05	0.00	0.97	0.28	0.23
BUF1($\angle 0^\circ$)	0.00	0.25	0.27	0.07	0.91	0.10
NOT1($\angle 0^\circ$)	0.24	0.28	0.04	0.06	0.17	0.86
AND1($\angle 45^\circ$)	0.76	0.43	0.10	0.30	0.13	0.23
AND1($\angle 90^\circ$)	0.82	0.45	0.32	0.28	0.23	0.12
OR1 ($\angle 135^\circ$)	0.35	0.31	0.75	0.50	0.34	0.29

표 4. 학습받지 않은 논리 심볼의 출력값

Table 4. The output of the unlearned logical symbols.

	AND	NAD	OR	NOR	BUF	NOT
AND1($\angle 0^\circ$)	0.78	0.20	0.29	0.23	0.12	0.04
AND2($\angle 0^\circ$)	0.80	0.23	0.01	0.28	0.16	0.18
NAD1($\angle 0^\circ$)	0.50	0.66	0.64	0.20	0.45	0.56
OR1 ($\angle 0^\circ$)	0.40	0.34	0.65	0.12	0.49	0.05
NOR1($\angle 0^\circ$)	0.14	0.43	0.20	0.74	0.23	0.65
BUF1($\angle 0^\circ$)	0.11	0.35	0.26	0.13	0.59	0.17
NOT1($\angle 0^\circ$)	0.64	0.28	0.53	0.16	0.14	0.84
AND1($\angle 45^\circ$)	0.71	0.43	0.28	0.30	0.43	0.53
AND1($\angle 90^\circ$)	0.69	0.55	0.18	0.54	0.21	0.12
OR1 ($\angle 135^\circ$)	0.35	0.31	0.67	0.50	0.34	0.24

알 수 있다. 특히 회전된 경우는 4 방향으로 균사화 하였으므로 이에 따른 오차로 출력값이 명확하지 않게 나타났다. 그러나 대체로 심한 왜곡이 없는 일반적인 형태의 각 논리 심볼을 잘 인식할 수 있었다.

좀더 확실한 결과를 얻기 위해서는 수용야에 패턴을 코딩할 때 2진수가 아닌 실수 값으로 표현하는 방법을 개발해야 하겠다.

V. 결 론

본 논문에서는 논리 회로 도면을 인식하기 위해 여러 허용(error tolerance) 기능이 있는 신경망을 이용했다. 각 심볼에서 원하는 형태의 특징을 찾기 위해 억제 가중치를 학습할 수 있는 변형시킨 경쟁 학습법을 제안했다. 이 경쟁 학습법을 이용하여 학습된 신경망은 영상을 4방향 구조로 균사화 및 thinning을 할 수 있다.

이 매핑에 의해 얻어진 데이터를 병진시켜 학습한 신경망은 크기와 회전에 관계없이 어느 정도 모양이 변화된 각 논리 심볼을 인식할 수 있었다. 그러나, 세 set의 학습된 심볼만으로는 다양하게 모양이 변한 심볼을 완벽하게 인식할 수 없으므로 더 많은 심볼을 학습해야 실제 CAD시스템의 자동 입력기에 응용될 수 있을 것이다.

参考文献

- [1] J.L. McClelland, D.E. Rumelhart, and G.E. Hinton, "The appeal of parallel distributed processing," *PDP: Explorations in the Microstructures of Cognition*, vol. 1, D.E. Rumelhart and J.L. McClelland Eds., MIT press, pp. 3-44, 1985.
- [2] D.H. Achley, G.E. Hilton and T.J. Sejnowski, "A learning algorithm for Boltzmann machine," *Cognitive Science*, vol. 9, pp. 147-169, 1985.
- [3] K. Fukushima, "Neural network model for selective attention in visual pattern recognition and associative recall," *Applied Optics*, vol. 26, no. 23, pp. 4985-4992, December 1987.
- [4] M.R. Saych, "Neural networks for plane shape classification," *ICASSP*, vol. 2, pp. 936-939, 1988.
- [5] Y.T. Zhou, "Stereo matching using a neural network," *IEEE International Conference on Neural Network*, vol. 1, pp. 593-600, 1988.

- [6] R.P. Gorman, "Learned classification of sonar targets using a massively parallel network," *IEEE Trans. ASSP*, vol. 36, no. 7, July 1988.
- [7] S.E. Troxel, S.K. Rogers, and M. Kabrisly, "The use of neural network in PPRSI target recognition," *IEEE International Conference on Neural Network*, vol. 1, pp. 593-600, 1988.
- [8] S. Simizu, "Logic circuit diagram processing system," in *Proc. 6th Int. Conf. PAMI*, pp. 717-719, 1982.
- [9] F.C.A. Gron, "Topology based analysis of schematic diagram," in *Proc. 7th Int. Conf. PAMI*, pp. 1310-1312, 1984.
- [10] Akio okazaki, "An automatic circuit diagram reader with loop structure based symbol recognition," *IEEE Trans. PAMI*, vol. 10, no. 3, May 1988.
- [11] D.E. Rumelhart and D. Zipser, "Feature discovery by competitive learning," *PDP*, vol. 1, pp. 151-193, 1987.
- [12] E.L. Schwartz, "Spatial mapping in the primate sensor projection, analytic structure and relevance to perceptron," *Biol. Cybern.*, vol. 25, pp. 181-193, 1977.
- [13] D.E. Rumelhart, G.E. Hilton and R.J. Williams, "Learning internal representations by error propagation," *PDP*, vol. 1, pp. 318-362, 1985.

著 者 紹 介



金 德 鉉 (正會員)
 1964年 7月 10日生. 1988年 2月
 한양대학교 전자공학과 공학사
 학위취득. 1990年 2月 한양대학
 교 전자공학과 공학석사 학위취
 득. 1990年 3月~현재 금성사 정
 보기기 연구소 근무. 주관심분야
 는 신경망, 패턴인식 및 G3, G4 facsimile 등임.

朴 成 漢 (正會員) 第25卷 第12號 參照
 현재 한양대학교 전자계산학
 과 부교수