

다중 Neocognitron 모듈을 이용한 표적 인식

準會員 朱 起 鉉* 正會員 徐 春 源*, 柳 忠 相*, 金 恩 洙*

Target Recognition using Multiple Neocognitron-Module

Gi-Hyoun Joo*, Choon-Weon Seo**, Chung-Sang Ryu**, Eun-Soo Kim** *Regular Members*

요 약

본 논문에서는 표적 영상의 효과적인 인식을 위한 다중 Neocognitron 모듈의 구성 방법을 제안하였다. 표적의 국부 특징을 이용하여 전체 패턴의 클래스를 식별할 수 있도록 설계된 Neocognitron은 순수 신경망으로 적응적인 패턴 인식을 행할 수 있는 독특한 방법으로 여겨지고 있지만 구조상 확장성이 좋지 않아 표적 인식 등과 같이 비교적 방대한 계산량과 많은 클래스 분류가 요구되는 경우에는 그 응용이 매우 제한적이다. 따라서, 본 논문에서는 Neocognitron 크기를 축소하여 여러 개의 모듈로 구성하고, 각 모듈을 단일 클래스의 표적에 대해 집중적으로 학습시킨 후 이를 클래스의 수만큼 병렬로 연결하여 사용하는 다중 모듈 방식을 새로이 제안하였다. 다중 모듈 방식의 경우 전체적인 신경망의 크기를 줄일 수 있고, Neocognitron의 기본 특징인 패턴의 크기, 위치 변동 및 미세 회전, 기타 왜곡 등에 적응적이면서도 클래스의 증가에 용이하게 대처할 수 있다. 본 논문에서는 시뮬레이션을 통해 제안한 방법의 유효성을 보이고 다중 모듈 구조로 인해 사라지는 억제성 연결고리의 영향을 분석하였다.

ABSTRACT

This paper introduces the multiple Neocognitron module approach for the effective target recognition. The Neocognitron which is designed to classify a pattern by extracting the local features from it, seems to be a unique method that can perform a pattern recognition using the neural networks. But due to its rigid structure, the Neocognitron must be reconstructed whenever there exists a variation on the number of classes. This is a quite difficult problem for the target recognition application that needs huge amount of computation and numerous classes to be classified. In this paper, we construct several smaller Neocognitron modules and train each module to adapt each class. After construction of the modules, we integrate them in parallel so as to adopt input at the same time and to produce each score that should be matched to the learned class. This approach can reduce the sizes of the networks and is adaptive to the increase of classes as well as the authentic distortion, shift, scale variation and

*光云大學校 電子工學科
Dept. of Electronics, Kwangwoon Univ.
論文番號: 96129-0424
接受日字: 1996년 4월 24일

slight rotation invariant properties of general Neocognitron. This paper shows the effectiveness of the proposed approach through some experience and performs analysis of the inhibitory interconnections in the architecture of the multiple module structure.

I. 서 론

최근, 군사 및 산업 기술의 발달과 더불어 부인 자동화 시스템의 요구가 높아짐에 따라 표적 인식에 대한 관심이 고조되고 있다. 지난 10여년 동안 신경망의 발전과 더불어 적응적인 표적 식별 알고리즘은 거듭 발전하고 있지만 아직도 신경망의 구현 방식이 완전히 정립되지 못하여 이동체 탐제형 시스템을 설계하는 데는 많은 어려움이 따르고 있다. 대뇌 시각 피질 내의 신경세포는 특정 방향의 선이나 가장자리와 같은 시각 패턴의 부분적인 특징에 선별적으로 반응하고 보다 높은 영역에서는 원, 도형, 얼굴과 같은 구체적인 특징에 반응하는 신경세포가 존재하여 보다 복잡한 하나의 특징으로 조합한다. 이러한 계층적인 구조에서 상위 단의 세포는 망막의 보다 넓은 영역의 신호에 반응하게 되고, 이로 인해서 입력 패턴의 위치 이동에 대해 적응성을 갖게 된다^[1]. 이 생리학적 신경망들은 발생 후에 점차적으로 영역을 확장하고 다른 신경세포와 연결하는 자체적인 성장을 통해 학습, 암기, 패턴 인식과 같은 정교하고 적응적인 부위 기능을 갖추게 되는 것으로 알려졌다^[2].

Neocognitron은 이러한 생리학적 특성을 모방하여 Fukushima 박사가 창안한 계층 구조 신경망으로, 입력 패턴의 왜곡, 크기 변화, 위치 이동에 적응성을 가지고 있다^[3]. 이러한 특징으로 인해 Neocognitron은 필기체 문자 인식, 수화 인식, 음성 인식 등 여러 분야에 응용되어 왔으며, 순수 신경망으로 적응적인 패턴 인식을 행할 수 있는 유일한 방법으로 여겨지고 있다. 하지만 망 자체가 너무 방대하여 하드웨어 구현과 실시간적 패턴 인식에의 응용이 크게 제한되어 왔다^[4]. 광학적 신호 처리나 VLSI에 의한 시스템의 구현 연구가 지속되고 있으나 인식하고자 하는 대상이 추가될 경우에는 시스템 전체를 다시 학습시켜야 하고 클래스의 수가 더욱 증가한 경우에는 학습된 영상의 중첩에 의해 인식 성능이 현저히 저하되어 그 기능을 잃게 된다. 이러한 경우에는 망 자체를 다시 설

계해서 구현해야 하는데 원하는 성능을 얻기 위해서는 클래스의 증가에 따라 망의 크기를 기하급수적으로 확장시켜 주어야 하므로 일반적인 응용이 불가능하게 된다^[5,6].

본 논문에서는 Neocognitron의 각 층을 이루는 세포 평면의 갯수와 세포 평면의 크기를 축소하여 하나의 클래스 모듈로 구성하고, 이를 클래스의 수만큼 병렬로 연결하여 각 모듈마다 단일 클래스의 표적에 대해 집중적으로 학습시키는 방식을 새로이 제안하고자 한다. Neocognitron 모듈을 클래스마다 할당할 경우 언뜻 단일 Neocognitron을 사용할 경우 보다 방대한 신경망이 형성되는 것처럼 보이지만 실제로 클래스의 증가에 따라 억제성 연결고리의 부가적인 증가가 발생하지 않기 때문에 클래스 수가 많아진 경우 신경세포와 연결고리를 크게 절약할 수 있다. 따라서, 망의 하드웨어적 구현이 용이해지고 특히, 클래스의 증가에 따른 망의 세구성 및 학습이 요구되지 않으므로 확장성이 매우 유리하게 된다. 다중 모듈 방식의 도입으로 인한 억제성 연결고리의 감소가 망에 미치는 영향은 실제로 단일 Neocognitron에 있어서 클래스 수가 많아졌을 때 학습 패턴 중첩에 의해 인식 기능을 상실할 수 있는 모험에 비해 훨씬 미약하다. 본 논문에서는 이러한 사실을 이론적 분석과 항공기 패턴 인식 실험을 통해 검증하고, 제안한 다중 모듈 방식에 대한 유효성을 보이고자 한다.

II. Neocognitron의 기본 구조

Neocognitron은 계층적 병렬 구조의 다층 신경망으로 임출력 연산 방법과 연결 가중치의 종류에 따라 S세포, C세포, V세포로 구별되어 불리는 세 종류의 기본 세포들로 구성되어 있다. 따라서, 각 구성 세포는 서로 다른 종류의 이웃 세포의 출력들로부터 각기 다른 방식으로 영향을 받기 때문에 다양한 입력 형태를 취하게 된다^[4]. Neocognitron의 처리 요소인 세포는 연속되는 상위 계층 속으로 조직화되는데 각 계층은




그림 1. Neocognitron의 세포 연결 특성
Fig. 1 Interconnections between the cells in a Neocognitron

S세포층과 C세포층으로 구성되어 있고 각 세포층 또 한 여러 개의 세포 평면으로 이루어져 있다^{3,7)}.

그림 1은 Neocognitron내의 한 계층을 구성하는 각 세포들의 연결 관계를 보인 것으로 각 세포에 연결되는 연결고리의 역할을 각기 다른 종류의 화살표로 표기하였다. 가는 화살표는 가변적인 자극성 연결고리로 C세포에서 다음 계층의 V세포에 연결되는 고리와 S세포에서 C세포로 연결되는 고리가 이에 해당하고, 굵은 화살표는 고정값의 자극성 연결고리로 C세포에서 다음 계층의 S세포로 연결되는 고리가 이에 해당한다. 또한 종단형 화살표는 가변적인 억제성 연결고리로 V세포로부터 S세포로 연결되는 고리가 이에 해당한다. 이전 층의 여러 세포를 감응하도록 계층적 구조를 설계함으로써 상위 계층으로 올라갈수록 세포는 입력단의 세포 평면에 대해서 점차적으로 더 넓은 감응 영역을 확보하게 되고 시스템은 더욱 복잡한 특징을 통합하여 반응하게 된다. 최종 출력층은 입력단의 세포 평면보다 훨씬 넓은 감응 영역을 확보하게 되므로 패턴의 이동과 크기 변화 및 왜곡에 적응성을 갖게 된다.

입력되는 표적 영상을 최초로 감응하게 되는 S세포의 연결 방식은 두 가지로 분류된다. 즉, C세포를 감응하는 S세포에는 출력을 증폭시키는 자극성 연결 신호가 전송되고 억제성 연결 신호를 출력하는 세포(Vc)로부터 출력값을 감소시키는 억제성 연결 신호를 받게 된다. 이 Vc세포는 자극성 신호를 출력하는 C세포와 궁극적으로 같은 세포이다. 계층 안의 S세포 평면들은 하나의 Vc세포 평면에 동일한 연결 강도로 연결되어 있다. 이러한 구조로 S세포와 Vc세포는 모든 C세포 평면 내의 감응 영역으로부터 신호를 입력받

게 되고, S세포는 이전 계층에서 추출된 특징들을 인식하게 된다. l 번째 계층의 k_l 번째 세포 평면 있는 n 번째 S세포 하나의 출력 $U_{S_l}(k_l, n)$ 를 수식으로 나타내면 다음 식(1)과 같다.

$$U_{S_l}(k_l, n) = r_l \cdot \varphi(A) \quad (1)$$

여기에서 $\varphi(x)$ 는 0 이하의 값을 0으로 치환해 주는 활성 함수로 식(2)와 같은 선형 임계 함수이다.

$$\varphi(x) = \begin{cases} x & (x \geq 0) \\ 0 & (x < 0) \end{cases} \quad (2)$$

식(1)에서 내부 변수 A 는 식(3)과 같이 이전 계층의 C세포층으로부터 자극성 연결 강도로 이어지는 신호의 합을 나타낸다.

$$A = \left\{ \frac{1 + \sum_{k_{l-1}=1}^{K_{l-1}} \sum_{v \in S_l} a_l(k_{l-1}, v, k_l) \cdot U_{C_{l-1}}(k_{l-1}, n+v)}{1 + \frac{2r_l}{1+r_l} \cdot b_l(k_l) \cdot V_C(n)} - 1 \right\} \quad (3)$$

즉, $U_{C_{l-1}}(k_{l-1}, n+v)$ 는 k_{l-1} 번째 C세포 평면에서 $n+v$ 에 위치한 세포의 자극성 출력 신호를 나타내고 $a_l(k_{l-1}, v, k_l)$ 은 이전 계층의 C세포층의 출력에 가해지는 가변적 자극성 가중치이다. 억제성 출력을 내는 Vc세포의 출력 $V_C(n)$ 은 식(4)와 같고 이에 대한 가변적 억제성 가중치가 $b_l(k_l)$ 이다.

$$V_C(n) = \sqrt{\sum_{k_{l-1}=1}^{K_{l-1}} \sum_{v \in S_l} c_l(v) \cdot U_{C_{l-1}}^2(k_{l-1}, n+v)} \quad (4)$$

$c_l(v)$ 은 세포의 감응 영역 v 를 위한 연결 가중치로 그 값은 식(5)와 같이 정규화된다.

$$\sum_{k_{l-1}=1}^{K_{l-1}} \sum_{v \in S_l} c_l(v) = 1. \quad (5)$$

Neocognitron은 식(3)의 $a_l(k_{l-1}, v, k_l)$ 와 $b_l(k_l)$ 와 같은 가변성 가중치를 보완함으로써 서로 다른 입력 패턴을 식별하도록 학습된다. 자극성 연결을 위한 가중

치(a_i)는 임의의 입력 신호에 대해 S세포 평면이 명확한 응답을 하도록 적용되는 작은 값으로 초기화시키고, 억제성 가중치(b_i)의 초기값은 0에 가까운 값으로 설정된다. 이러한 두 가지 유형의 가중치에 대한 증가는 가장 큰 응답을 보이는 S세포에 의해 결정되는데, 최대 반응 세포가 포함된 세포 평면을 \hat{k}_i 로 나타내고 그 세포 내에서 최대 감응 영역의 위치를 \hat{n} 라 한다면 세포 평면의 입력 가중치의 변화량은 다음 식(6)과 식(7)로 쓸 수 있다^[4].

$$\Delta a_i(k_{i-1}, v, \hat{k}_i) = q_i \cdot c_{i-1}(v) \cdot U_{C_{i-1}}(k_{i-1}, \hat{n} + v) \quad (6)$$

$$\Delta b_i(\hat{k}_i) = q_i \cdot v_{C_{i-1}}(\hat{n}) \quad (7)$$

여기에서 변수 q_i 는 각 계층에서의 학습량을 조절하는 이득 계수이며 일반적으로 상위 계층으로 올라갈수록 큰 값을 설정한다. C세포층과 Vs세포층의 세포는 이전 S세포층으로부터 입력을 받는데 감응 영역은 입력을 받는 세포와 인접하도록 설정된다. C세포의 출력을 수식으로 나타내면 식(8)과 같이 표현되는데

$$U_C(k_i, n) = \psi \left[\frac{1 + \sum_{v \in D_i} d_i(v) \cdot U_{S_i}(k_i, n + v)}{1 + V_{S_i}(n)} \right] \quad (8)$$

여기에서 $\psi(x)$ 는 식(9)와 같은 비선형 임계 함수이고 d_i 는 입력 영역 내의 감응 영역의 세포와 연결되는 가중치로서 식(5)와 유사한 방법으로 정해진다. 또한 D_i 는 C세포에 대응하는 S세포의 감응 영역을 나타내고 U_{S_i} 는 S세포 출력을 나타낸다^[4].

$$\psi(x) = \begin{cases} \frac{x}{\beta + x} & (x \geq 0) \\ 0 & (x < 0) \end{cases} \quad (9)$$

식(9)에서 β 는 포화도를 결정하는 변수로 각 계층에 대해 임의의 값으로 설정할 수 있는데 일반적으로 1.0으로 사용한다^[3, 4]. 이러한 처리 결과로 C세포는 평균 신호량보다 강하게 반응하는 특징만을 선택하게 된다. l 번째 V_{S_i} 세포 평면의 세포는 식(10)과 같이 가중치가 적용된 S세포 출력의 산술적인 평균값을 출력한다.

$$V_{S_i} = \frac{1}{K_i} \sum_{k_j=1}^{K_i} \sum_{v \in D_i} d_i(v) \cdot U_{S_i}(k_i, n + v) \quad (10)$$

III. 다중 Neocognitron 모듈의 구성

Neocognitron의 설계에 있어서 감응 영역의 크기는 시스템의 성능에 결정적인 영향을 주게 되므로 시스템의 규모와 복잡도에 부합되도록 설정되어야 한다^[7, 8]. 감응 영역의 크기와 중복도는 입력 표적의 크기와 전체 시스템의 크기를 고려하여 설정하게 되는데 각 층 사이의 감응 영역의 중복도를 크게 할수록 세포 평면의 크기는 완만하게 줄어들고 결국, 시스템의 계층이 많아지게 된다. 즉, 감응 영역의 중복도와 시스템의 크기는 비례한다. 감응 영역의 중복도가 증가하게 되면 세포간의 연결이 복잡하게 되지만 표적의 위치 이동에 대한 허용도를 유지할 수 있다^[9]. 표 1과 같이 감응 영역의 크기를 설정하면 각 층에 속해 있는 하나의 세포가 감응하게 되는 입력단의 크기는 그림 2와 같은 피라미드 효과를 이루게 된다. 본 논문에서 사용한 Neocognitron은 최상위 계층을 제외하면 모든 계층에서의 C세포는 9개의 S세포에 감응하기 때문에 같은 계층의 S세포 평면과 C세포 평면의 크기는 같게 된다.

그림 3은 시스템을 구성하는 단일 모듈의 구조를 나타낸 것이고 그림 4는 이의 병렬 배치를 나타낸다. 각각의 모듈은 4개의 계층과 22개의 C세포 평면, 23개의 S세포 평면으로 구성하였다. 임의의 표적 영상이 입력되면 각 모듈은 학습에 의해 이미 기억하고 있는 표적에 대한 유사도를 출력하게 된다. 결국 입력 영상은 가장 큰 유사도를 나타낸 모듈의 클래스로 분류된다. 그림 5는 각 계층에서 표적 영상의 특징이 추출되어 수렴되는 과정을 나타내고 있다.




그림 2. 감응 영역의 피라미드 효과
Fig. 2 Pyramid effect of the receptive fields

표 1. 시스템의 모듈 구성

Table 1. The structure of a Neocognitron module.

	C0	S1	C1	S2	C2	S3	C3	S4	C4
감응 영역의 크기		5×5	3×3	5×5	3×3	5×5	3×3	5×5	5×5
감응 영역의 확장		3×3	7×7	15×15	23×23	39×39	55×55	65×65	65×65
세포 평면의 크기	65×65	65×65	33×33	17×17	17×17	9×9	9×9	5×5	1×1
세포 평면의 갯수	1	8	8	8	8	4	4	3	1




그림 3. 시스템의 모듈 구조
Fig. 3 The structure of a Neocognitron module




그림 4. 다중 Neocognitron의 병렬 배치 형태
Fig. 4 The parallel combination of the multiple Neocognitron module.




그림 5. Neocognitron 모듈 내에서의 특징 추출과 인식 과정
Fig 5. The feature extraction and recognition process in the Neocognitron module.

이전 층에서 추출된 특징은 C세포의 번짐 효과에 의해서 다음 계층에서는 특징의 위치가 조정되게 된다. 이러한 과정이 여러 계층에 걸쳐 반복되면서 시스템은 표적의 위치 이동에 대한 불변 특성을 얻게 되는 것이다⁹⁾.

Neocognitron을 다중 모듈 형태로 구성하면 모듈 간에 다른 클래스의 특징 추출을 위한 연결이 존재하지 않기 때문에 시스템의 모듈 수가 증가하여도 연결 고리 수가 크게 증가하지 않는다. 식 (11)은 다중 모듈 형태로 구성한 Neocognitron의 연결 고리 수를 수식적으로 나타낸 것이다.

$$N_{Total} = \sum_{l=1}^4 S_{Sl} \cdot (N_{Sl} \cdot N_M) \cdot R_{Sl} \cdot (N_{Cl-1} \cdot N'_M) + \sum_{l=1}^4 S_{Cl} \cdot (N_{Cl} \cdot N_M) \cdot R_{Cl} \quad (11)$$

S_{Sl} : l번째 레벨의 S세포평면의 크기(노드수)
 N_{Sl} : 단일 모듈내의 l번째 레벨의 S세포평면의 갯수
 N_M : 모듈의 갯수(표적의 갯수)
 R_{Sl} : l번째 레벨의 S세포평면의 감응영역 크기

다중 Neocognitron모듈의 경우에 $N'_M = 1$ 인 반면, 기존의 Neocognitron은 최초의 계층($l=1, N'_M=1$)을 제외한 다른 계층에 대해서는 $N'_M = N_M$ 으로 간주한다. 이러한 차이는 클래스간의 억제성 연결의 유무에 기인한다. 3개의 모듈로 구성된 다중 Neocognitron모듈은 동일한 학습 패턴이 적용되는 단일 Neocognitron에 비해 약 55.6%의 감소 효과는 얻을 수 있고 모듈의 수가 15개로 되면 약 90%의 감소 효과를 볼 수 있다. 그림 6에는 Neocognitron을 모듈 구조로 사용하였을 경우의 연결고리 수를 단일 망으로 사용하였을 경우와 비교하여 클래스의 증가에 따른 연결고리 수의 감소 효과를 나타내었다.

S세포로 감응되는 세포와의 연결은 가변적이며 학




그림 6. 세포 연결 수의 감소 효과
 Fig. 6 The effect of connection saving of the multiple Neocognitron approach.

습 과정 동안에 시스템에 입력되는 학습 패턴에 의해 점차적으로 조직화된다. 임의의 작은 영역 안에 위치한 세포들 중 가장 강한 반응을 보이는 세포의 연결 강도는 보다 강화된다. 최대출력을 보이는 S세포는 학습 과정 동안에 제공되었던 학습 패턴의 특징을 추출하는 능력을 익히게 된다. 최대출력 세포는 성장할 뿐만 아니라 이웃하는 세포들의 성장을 유도한다. 즉, 최대출력 세포는 크리스털의 시드(seed)와 같은 역할을 한다. 이웃하는 세포는 시드 세포와 같은 방식으로 보완된 입력 연결을 가진다^{13,14}. 세포의 반응을 출력하는 과정에서 0으로 나뉘는 것을 방지하고 시드 세포를 유도하기 위해 가변 가중치에 적절한 초기화가 필요하다. 본 논문에서는 자극성 가중치(a_i)와 억제성 가중치(b_i)를 각각 0.03, 0.0001로 설정하였다. 각 계층의 파라미터는 그 계층의 기능과 학습 패턴에 따라 결정되는데 본 논문에서 사용한 파라미터 값들을 표 2에 나타내었다. 한 번의 학습에 의한 시스템의 학습량을 결정하는 q 는 모든 모듈에 대해서 동일하게 설정하였다. 시스템 내에서 두 번째 계층이 특징 추

출을 하는데 결정적인 역할을 하므로 학습량을 크게 하였다. 즉, 국부적인 특징을 추출하는 하위 계층에서는 충분히 큰 값을 사용하고 반면, 특징 추출보다는 조합된 특징을 분류하게 되는 상위 계층에서는 작은 값을 사용하게 된다¹⁵. 시스템의 학습 과정에 이용되는 패턴과 입력되는 표적 영상의 특징 사이의 상관도를 제시하는 r 은 모듈별로 최적화 되는 과정에 의해 각 계층마다 다른 값을 취하게 된다. Neocognitron의 출력은 자극성 입력 값과 억제성 입력 값의 비율에 의해 결정된다. 자극성 입력 값과 억제성 입력 값의 균형이 이루어지지 못한 경우에는 가중치가 무한정 커져서 출력값이 아주 큰 값으로 나타날 수 있다. 따라서, r 을 조정하여 두 입력의 증가 비율을 비슷하게 함으로써 출력을 제한할 수 있다¹⁶. 그리고 고정된 자극성 가중치인 c_i 과 d_i 은 다음식 (12)와 같이 표현된다¹⁵.

$$c_i(v) = \gamma_i^{|v|}, \quad d_i(v) = \delta_i \cdot \delta_i^{v_i} \quad (12)$$

c_i 과 d_i 의 정도는 이동 불변 특성과 밀접한 관계에 있기 때문에 이들의 미세한 변화는 시스템의 성능과 직접적으로 연결된다. 본 논문에서는 이러한 영향을 최소화하기 위해 S세포를 감응하는 C세포의 감응 영역에 대해서 50%의 중복도를 갖도록 설계하여 이전 계층에 대해서 번짐 효과를 유지하도록 하였다. 이 경우에는 두 가지 변수 γ_i, δ_i 의 영향은 크게 줄게 된다. 가중치 d_i 의 중복도를 나타내는 δ 는 가중치의 분포보다는 S세포의 억제성 출력의 크기에 영향을 주게 된다.

IV. 실험 및 결과 분석

본 논문에서는 제안 알고리즘의 분석을 위해 Thunderbolt(A10-A), Tomcat(F14-A), Lightning(P38J) 등

표 2. 각 모듈의 변수
 Table 2. Used variables of each module.

변 수	모듈 A: Thunderbolt			모듈 B: Tomcat			모듈 C: Lightning		
	q	r	δ	q	r	δ	q	r	δ
LEVEL1	3000	1.2	4.0	3000	1.2	2.5	3000	1.0	1.0
LEVEL2	10000	2.0	5.0	10000	1.8	5.0	10000	3.0	5.0
LEVEL3	5000	2.5	2.5	5000	3.5	5.0	5000	2.0	2.5
LEVEL4	500	1.0	1.0	500	1.0	1.0	500	1.0	1.0

세 가지 모형 비행기에 대한 인식 실험을 행하였다. 시뮬레이션은 Pentium-120MHz 컴퓨터 상에서 C 언어를 이용하여 행하였으며, 무작위로 움직이는 모형 비행기를 CCD 카메라로 포착하여 DT2867 그래픽을 통해 입력받고, 이로부터 표적을 중심으로 65×65 크기의 표적 영상을 추출하여 입력으로 사용하였다. 또한 왜곡에 대한 적응성을 검사하기 위해 임의로 잡음과 클러터를 분포시켜 입력 데이터의 일부로 사용하였다. 그림 7은 실험에 사용된 150개 표적 데이터중 일부를 나타내고 있는데, 상단 3개 행의 가장 왼쪽 표적 영상이 각 모듈의 학습에 이용된 기준 패턴이며 나머지 표적 영상중 위의 세 줄은 회전 및 왜곡된 표적 영상들의 예이고 아래 세 줄은 위치나 크기가 변화된 표적 영상들의 예이다.

그림 8과 그림 9는 시뮬레이션 과정의 모니터 화면을 예시한 것인데 모듈 A에 표적 영상(Thunderbolt)이 입력되었을 때 각 모듈의 출력 결과를 나타낸다. 각 단의 출력은 같은 계층에 소속된 세포 평면이 포함하는 C세포의 반응 결과를 나타낸다.

그림의 상단 왼쪽의 실루엣 영상이 입력되는 영상이고 입력 영상의 오른쪽에는 그 모듈에 학습된 표적을 도시하였으며 맨 아래 사각형의 밑도는 입력된 표적 영상의 인식 결과로써 학습된 표적일 확률을 나타낸다. 그림 8(a)~(c)는 기준 표적 크기의 약 68%로 축소된 표적(Tomcat)이 입력되었을 때의 모듈별 출력 결과이다. 150개의 표적 영상에 대해 이상과 같은 실험을 계속한 결과 표적의 크기 변화에 따른 불변 특성은 다른 왜곡 표적에 비해서 일관된 인식 성능을 보여주었다. 즉, 학습 표적을 기준으로 한 약 140%~60%의 크기 변화에는 정인식된 결과를 나타내었다. 그리고 그림 9(a)~(c)는 약 12° 정도 회전된 학습 표적(Lightning)에 대한 인식 결과를 예시한 것이다. 회전된 표적의 입력에 대해서 시스템은 학습 패턴을 기준으로 약 15° 내에서 회전된 표적에 대해서만 효과적인 인식 결과를 보여주었다. 또한, 입력 평면의 크기를 기준으로 했을 경우 약 20%내의 위치 이동에 대해서는 불변 특성을 유지하였다. 그리고 잡음의 강도와 정보의 손실량에 따른 결과는 일관되지는 못하지




그림 7. 실험에 이용된 표적 영상의 예

Fig. 7 The sample examples of target images used in the simulation.

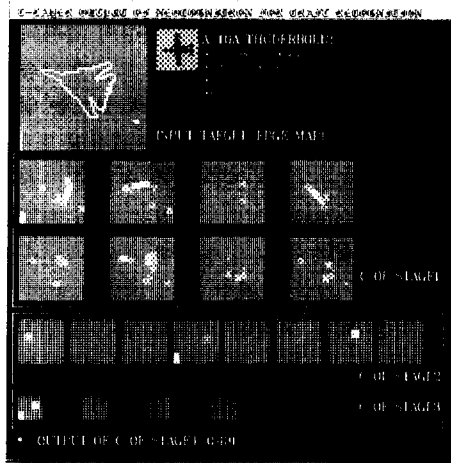


그림 8(a)




그림 9(a)

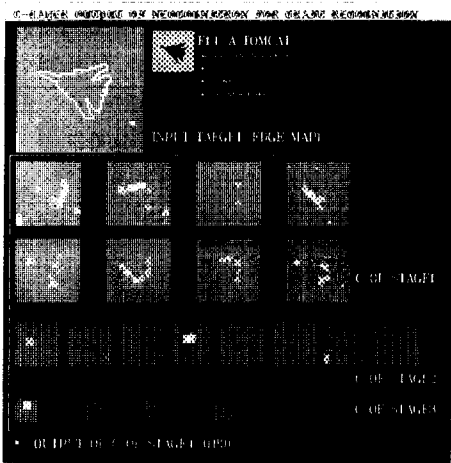


그림 8(b)




그림 9(b)



그림 8(c)




그림 9(c)

그림 8. 축소된 표적에 대한 각 모듈의 출력

그림 9. 회전된 표적에 대한 각 모듈의 출력

Fig. 8 A recognition result for an scaled input image
2746

Fig. 9 A recognition result for an rotated input image

만 왜곡된 표적 인식에 대한 가능성을 충분히 제시해 주었다. 즉, 학습 표적과의 유사도가 없거나 왜곡 정도가 심한 표적에 대해서는 기각 처리를 직용함으로써 신뢰도를 높일 수 있었다. 다중 Neocognitron 모듈의 클래스 선택은 마지막 계층의 출력값이 가장 큰 모듈을 선택하는 방법으로 하였는데 이 때, 최대 출력력이 0.3 이하로 너무 미약하거나, 다음으로 큰 출력값의 크기가 최대 출력값의 90% 이상인 경우의 입력 표적에 대해서는 기각 처리하였다. 그림 10과 그림 11에 정인식된 표적 영상과 오인식된 표적 영상의 예를 보였다. 그림에서 보이 듯이 오인식된 결과들은 모두가 3차원적 회전에 의해 모형의 변화가 심한 표적들과 회전 및 크기 변화가 심한 표적 영상들이다. 위치 이동에 대해서는 전체 입력 영역에 대해서 매우 적극적인 것으로 분석되어 망의 감응 영역 설정은 적절했음을 보이고 있다.




그림 10. 정인식된 표적 영상의 예
Fig. 10 The example target images recognized correctly



그림 11. 오인식된 표적 영상의 예
Fig. 11 The example target images recognized uncorrectly

기존의 모델과 인식 성능을 비교하기 위해 세 개 모듈의 전체 크기와 동일한 단일 망을 구성하고 동일한 표적으로 실험한 결과를 다중 모델의 인식 결과와 함께 정인식률, 오인식률, 기각처리율, 신뢰율의 순으로 도표화하여 그림 12에 보였다. 그림에서 짙은 색 막대는 다중화 모델의 인식 성능을 나타내고 흰색 막대는 동일 표적에 대한 기존 모델의 인식 성능을 나타




그림 12. 다중화 모델과 기존의 모델의 인식 성능 비교
Fig. 12 A Recognition capability comparison of multiple Neocognitron module and conventional model

내며 옅은 색 막대로 다중화 모델과 기존 모델의 성능 비를 보인 것으로 다중화 모델이 기존 모델에 비해 정인식률은 21% 개선되고 기각처리율은 53% 정도로 낮아졌다. 기각 처리될 표적 영상이 기각 처리되지 않고 오인식에 포함되는 경우가 있어 오인식률이 3% 정도 증가하였지만 정인식률이 크게 증가하여 전체적인 신뢰도는 5% 향상되는 것으로 나타났다. 또한 구조면에서 본 논문에서 제안한 다중 Neocognitron 모듈은 학습 패턴과 변수값의 차이를 제외하면 각 모듈의 구성이 모두 같다. 따라서 하나의 모듈 구성이 완료되면 클래스의 증가에 따라 학습 과정에 이용되는 패턴 그룹과 변수만 설정하여 병렬 배치하는 것으로 시스템을 확장시킬 수 있다.

V. 결론

본 논문에서는 계층 구조 신경망인 Neocognitron을 표적 인식 문제에 효과적으로 접목시키기 위해 다중 모듈 형태로 구성하는 방법을 제시하고 이의 당위성을 분석하였다. 즉, 구조상 확장성이 좋지 않아 클래스의 수가 변경될 경우에는 전체 시스템을 재구성하고 학습시켜야 하는 기존의 단일 신경망 구조의 Neocognitron을 소규모의 모듈로 구성하고, 각 모듈마다 한 개 클래스의 표적에 대해 집중적으로 학습시킨 후 이를 클래스의 수만큼 병렬로 연결하여 사용하는 방

식을 제안하므로써 클래스의 수가 변경될 경우에는 해당 모듈만 삭제하거나 삽입할 수 있도록 개선하였다. 기존의 단일 신경망 형태의 경우 망의 크기를 늘리지 않고 클래스 수를 늘리면 연결고리에 학습된 특징 패턴들이 중화되어 식별 기능이 상실될 수 있으며, 식별 성능을 유지하려면 클래스에 비례하여 망의 크기를 늘려야 하는데 이 때, 억제성 연결고리는 기하급수적으로 증가하게 된다. 하지만 제안한 다중 모듈 구조의 신경망은 언뜻 망의 크기가 훨씬 방대해졌 것처럼 보이지만 실제적으로 클래스간의 억제성 고리의 부가적인 증가가 발생하지 않으므로 전체적인 신경망의 크기가 기존 방식에 비해 감소되었다.

컴퓨터 실험 결과에서 보였듯이 동일 표적 영상들에 대해 다중 모듈 형태의 Neocognitron이 동일 크기의 기존 방식의 Neocognitron에 비하여 신뢰도 면에서 5%정도 향상된 결과를 나타내어 모듈 구조의 도입으로 인한 억제성 연결고리의 감소가 망의 성능에 미치는 영향은 실제적으로 미약함을 알 수 있었다. 이는 모듈 구조를 도입함에 따라 각 모듈마다 학습 패턴을 달리 사용할 수 있어, 각 모듈에 해당 클래스의 표적 패턴만 학습시키므로써 자극성 연결고리들이 그 클래스에 가장 최적으로 반응하여 억제성 연결고리의 감소로 낮아지는 식별 능력을 다시 매가시키기 때문인 것으로 분석된다. 결론적으로 제안된 다중 모듈 방식의 Neocognitron 신경망은 기존의 단일 Neocognitron에 비해 확장성도 좋을 뿐만 아니라, 같은 성능을 얻는데 있어 망의 크기도 작게 설계할 수 있어 하드웨어 구현성이 좋아 자동화 장비가 요구되는 여러 분야에 응용될 수 있을 것으로 기대된다.

참 고 문 헌

1. Bruce C., Desimone R. and Gross C. G., "Visual Properties of Neurons in a Polysensory Area in Superior Temporal Sulcus of the Macaque", *Journal of Neurophysiology*, vol. 46, no. 2, 369-384, 1981.
2. Sato T., Kawamura T. and Iwai E., "Responsiveness of Inferotemporal Single Units to Visual Pattern Stimuli in Monkeys Performing Discrimination", *Experimental Brain Research*, vol. 38, no. 3, 313-319, 1980.

3. K. Fukushima. "Neocognitron: A Hierarchical Neural Network Capable of Visual Pattern Recognition", *Neural Networks*, vol. 1, pp. 119~130, 1988.
4. Murali M. Menon and Karl G. Heinemann "Classification of Pattern Using a Self-Organizing Neural Network", *Neural Networks*, vol. 1, pp. 201~215, 1988.
5. Brain A. White and Mohamed I. Elmasry, "The Digi-Neocognitron: A Digital Neocognitron Neural Network Model for VLSI", *IEEE Trans. on Neural Network*, vol. 3, no. 1, January, 1992.
6. Tien-Hsin Chao, "Optical Implementation of a Feature-Based Shift-Invariant Multiplane Neural Network", *IJCNN*, vol. 3, pp. 376-381, 1992.
7. Yu Lihau and Diao Yimin, "Analysis of Neocognitron Parameter and A Revised Method of Network Training", *IJCNN*, vol. 2, pp. 821-825, 1992.
8. Autony Y. cheng and Daniel S. Yeung, "Analyzing Sensitivity of Neocognitron to Weight Errors", *WCNN*, vol. 1, pp. 23-26, 1995.
9. Etienne Barnard and David Casasent, "Shift Invariance and Neocognitron", *Neural Networks*, vol. 3, pp. 403-410, 1990.



朱 起 鉉(Gi Hyoun Joo) 준회원
 1995년 2월: 광운대학교 전자공학과 졸업(공학사)
 1995년 3월~현재: 광운대학교 대학원 전자공학과 석사과정 재학중
 ※주관심분야: 자동표적인식, 신경회로망, 패턴인식 등

徐 春 源(Choon Weon Seo) 정회원
 현재: 광운대학교 대학원 전자공학과 박사과정 재학중
 제17권 7호 참조



柳 忠 相(Chung Sang Ryu)정회원

1990년 2월:국립서울산업대학 전
자공학과 졸업(공학
사)

1993년 8월:광운대학교 대학원 전
자공학과 졸업(공학
석사)

1993년 9월~현재:광운대학교 대
학원 전자공학과 박사과정 재학중

※주관심분야:자동표적인식, 광정보처리, 신경회로
망, 패턴인식 등

金 恩 洙(Eun Soo Kim)

정회원

현재:광운대학교 전자공학과 교수(신기술 연구처)

제21권 7호 참조