

## 論 文

## 신경회로망을 이용한 물체인식

正會員 金 亨 根\* 正會員 朴 承 圭\*\* 正會員 宋 鐵\*\*\* 正會員 崔 甲 石\*

## Object Recognition using Neural Network

Hyoung Geun KIM\*, Sung Kyu PARK,\*\* Chull SONG,\*\*\* Kap Seök CHOI\* *Regular Members*

## 要 約

본 논문은 신경회로망을 이용한 물체인식에 관한 연구로써, 인식은 물체의 경계점으로부터 추출된 국부특징들로 구성되는 각 선형선소들간의 매칭에 의해 이루어진다. 그러나 추출된 특징들은 물체를 구성하는 선형선소들간의 유사성때문에 특징공간상에서 다른 모델과의 경계가 불분명하게 되므로 인식의 애매성이 발생하고, 특징의 유사성에 기인한 신경 회로망의 경계분리능력의 한계에 따라 인식률의 저하를 가져온다.

따라서, 본 논문에서는 인식의 애매성을 해소하고, 인식율의 향상을 도모할 수 있도록 2개의 신경회로망을 다단결합한 물체인식 시스템을 구성하였으며, 물체를 효과적으로 기술할 수 있는 국부특징량을 사용하였다. 실험을 통하여 구성된 물체인식 시스템의 타당성을 확인하였으며, 중복물체 및 변형된 물체에 적용하여 그 결과를 고찰하였다.

## ABSTRACT

In this paper, object recognition using neural network is studied. The recognition is accomplished by matching linear line segments which are formed by local features extracted from the curvature points. Since there is similarities among segments, the boundary of models is not distinct in feature space. Due to these indistinctness the ambiguity of recognition occurs, and the recognition rate becomes degraded according to the limitation of boundary decision capability of neural network for similar of features. Object recognition system with two neural networks is constructed to make up for the ambiguity of recognition and to improve recognition rate. Local features are used to represent the object effectively. The validity of the object recognition system is demonstrated by experiments for the occluded and varied objects.

## I. 서 론

최근 생산자동화를 배경으로 물체의 2차원 영상으로부터 물체를 인식하는 비전 시스템의 연구가 급증

되고 있다. 이러한 로보트 비전이나 로보트 분야에서 활발히 이루어지고 있다. 이러한 비전 시스템이 효율적으로 사용되기 위해서는 복잡한 물체를 유통성있게 처리할 수 있는 능력을 가져야 한다. 즉 물체의 다양한 형태에 대한 인식과 주어진 환경속에서 물체가 놓인 방향 및 위치등을 감지할 수 있어야 한다<sup>[1]</sup>.

일반적인 물체인식 기법은 인식하고자 하는 물체가 특정정자는 물체의 특징에 의존한다. 그러나 이러한

\*明知大學校 電子工學科

Dept. of Electronics, Myeongji University.

\*\*全北產業大學 電子計算學科

\*\*\*朝鮮大學校 工科大學 機器工學科

論文番號 : 92-21 (接受1991. 6. 10)

불체의 특징은 불체가 다른 불체와 접해 있거나 깊이 짐에 의해 소실되므로 정확한 인식이 불가능하게 된다. 이러한 특징 소실 현상은 커스터 미션 응용 및 물체 자동화 분야에서 중요한 문제로 대두되고 있으며, 특징 소실 문제를 해결하기 위해 종복 불체인식에 관한 연구가 활발히 진행되고 있다<sup>[7]</sup>. 현재까지의 종복불체인식에 관한 연구는 살펴보면 크게 두 가지로 나눌 수 있다. 첫째, 불체의 유파선을 몇 개로 분할하고 분할된 각각의 유파선에 대해 일반화 Hough변환을 적용하는 것<sup>[8]</sup>과 둘째로, 불체의 유파선을 직선 또는 원으로 근사시켜 모멘트와 임력양상과의 대응에 따라 정합하는 것<sup>[9-10]</sup>이다. 그러나 이러한 방법들은 계산량이 빙대하거나, 불체의 크기 변화 등에 따른 차리 효율이 나쁘고, 불체 형태의 변형이나 접음 등에 대응하기 곤란하며, 진체적인 인식 결과가 좋지 못하는 등의 문제점이 발생하였다. 따라서 이러한 문제점에 효과적이며 유연하게 대응될 수 있고, 보다 영상된 인식 결과를 얻을 수 있는 불체 인식에 관한 연구가 필요하게 되며, 불체인식과 같은 패턴인식분야에의 새로운 접근방법으로 인간의 정보처리 방식을 도입한 연구들이 다양하게 제시되고 있다<sup>[11-13]</sup>. 즉, 오늘날 과학기술이 지향하고 있는, 인간에 가까운 능력을 갖고, 인간에 대체할 수 있는 기계의 실현이라는 목표에 도달할 수 있는 하나의 방향을 시사하며, 구체적 또는 유연한 방법론을 제공할 수 있을 것으로 기대되는 것 중의 하나가 신경회로망이다.

신경회로망은 인간의 특성을 활성화한 시스템으로서 고도의 복잡성이자 구조와 작용에 학습능력 그리고 결합수능력 및 모멘트식의 대체적 표현 능력을 갖고 있기 때문에 많은 응용 가능성을 내포하고 있다<sup>[14]</sup>. 특히 신경회로망을 이용한 패턴인식에는 두 가지 방법이 있다. 첫째는, 절차적 과정인 '주출주출' 단계를 가치지 않고 임의 패턴을 직접 신경회로망에 입력하여 패턴을 인식하는 방법이고, 또 다른 방법은 절차적 과정에서 그 패턴을 잘 표현해 줄 수 있는 특징 벡터를 구한 다음 인식을 위한 분류과정만을 신경회로망으로 대치하는 방법이다. 첫번째 방법은 이상식 이기는 하지만 영상의 해상도에 따라 많은 유니트의 수가 필요하며, 아울러 연결선의 갯수가 증가하기 때문에 어려움이 많은 반면, 두번째 방법은 소수의 입력만을 사용할 수 있기 때문에 유니트의 수와 연결선의 수를 줄일 수 있어서 현재 대부분의 패턴인식을 위한 신경회로망이 이를 선택하고 있다.

본 논문에서는 대부분의 영상인식 문제가 에너지의 최소화문제로서 고려되어질 수 있기 때문에 일종의 최소자승오차를 갖는 신경회로망인 역설과 학습모멘트 이용하여 불체인식을 하였다. 인식을 위해 사용된 특징량은 웨이브볼트특징으로써, 영상에 대한 각각의 사과에 의해 구성된 각 선형선소에 있어서 각 선형선소를 사이의 상대적인 정보를 나타내는 국부 특징량을 계산하여 사용하였다. 또한, 효과적인 불체인식을 위해 설계에 사용된 신경회로망은 두개의 신경회로단이 나란히 걸친 문제인식시스템을 구성하였으며, 구성된 문제인식 시스템에 의한 불체인식 방법의 다양성을 검증하기 위하여, 1개의 신경회로망만을 사용한 경우의 불체인식 결과와 비교, 고찰 하였으며, 단수불체 및 중복불체, 그리고 불체가 변형된 영상에 대해 각각 적용 설계하여 그 결과를 검토하였다.

## II. 특징추출 및 모델 형성

일반적인 불체인식, 특히 종복불체인식에 있어서 불체중복에 의한 특징 소실현상에 따라 정확한 인식이 곤란하게 되므로, 불체를 효과적으로 기술할 수 있는 특징의 주술이 중요한 문제로 대두된다.

본 논문에서 인식을 위해 주출되는 특징량은 이동 및 회전변화에 무관한 특성을 갖는 불체 특징량이며, 특징집합의 요소로서의 선형선소는 불체의 경계점으로부터 주출된 국부 특징점으로 구성된다. 즉, 경계점출 과정을 거친 영상에서 불체의 경계점들은 각각 영상화에 의해 여러개의 선형선소로 분리되며 모멘트 및 미지영상을 선형선소의 집합으로 변환된다. 따라서 불체를 효과적으로 기술하기 위해 본 논문에서 제안된 선형선소의 국부특징량은 식(1)과 같이 정의된다.

$$S_{k_1}(\theta, 1, \theta', 1, \Delta\theta, \Delta 1) \quad (1)$$

$$\theta : \angle P_{n+1}, P_n, P_{n+1}$$

$$1 : 1(P_{n+1}, P_n) + 1(P_n, P_{n+1})$$

$$\theta' : \angle P_{n+2}, P_n, P_{n+2}$$

$$1' : 1(P_{n+2}, P_n) + 1(P_n, P_{n+2})$$

$$\Delta\theta : \theta / \theta'$$

$$\Delta 1 : 1 / 1'$$

여기서  $P_n$ 은 n번째 광각점을 나타내고,  $\theta, \theta', \Delta\theta$ 는 선형선소 사이의 각도정보를 나타내며, 1, 1',  $\Delta 1$

은 선형선소 사이의 거리정보를 나타낸다. 이러한 선형선소의 추출은 부분적인 경계점들을 직선으로 균사화함으로서 이루어진다. 본 논문에서는 물체의 경계를 직선을 균사화하기 위해 경계점들의 거리를 계산하여 허용거리이내에 있는 경계점을 병합시키고, 허용거리 이상에 있는 경우는 분리시키는 다각형 균사방법을 사용하였으며, T.Pavlidis의 분리 및 합성 알고리즘을 수정하여 사용하였다<sup>[1]</sup>.

또한 모델 및 미지영상에 대한 선형선소의 집합을 각각 MD(Model Description) 및 SD(Scene Description)라 하면 이들은 각각 식(2), (3)으로 표현된다.

$$\text{MD} = \{M_i | M_i = (M\theta_{i,i+1}, Ml_{i,i+1}, M\theta'_{i,i+2}, \\ Ml'_{i,i+2}, M\Delta\theta_{i,i+2}, M\Delta l_{i,i+2})\} \quad (2)$$

$$\text{SD} = \{S_i | S_i = (S\theta_{i,i+1}, S1_{i,i+1}, S\theta'_{i,i+2}, \\ S1'_{i,i+2}, S\Delta\theta_{i,i+2}, S\Delta l_{i,i+2})\} \quad (3)$$

$$i=1, 2, \dots, N$$

여기서  $M_i$ 와  $S_i$ 는 각각 모델과 미지영상으로부터 추출된 i번째 선형선소이며, N은 각각 모델과 미지영상으로부터 추출된 선형선소의 갯수이다. 또한  $(M\theta_{i,i+1}, S\theta_{i,i+1})$ ,  $(Ml_{i,i+1}, S1_{i,i+1})$ 는 각각 모델과 미지영상에 있어서 i번째와 i+1번째 선형선소 사이의 각도와 누적길이이다. 특히 본 논문에서는 물체의 형태에 관한 정보를 나타내기 위해 인접선소간의 상대적인 정보를 추출하여 사용하였다. 즉,  $(M\theta'_{i,i+2}, S\theta'_{i,i+2})$  및  $(Ml'_{i,i+2}, S1'_{i,i+2})$ ,  $(M\Delta\theta_{i,i+2}, S\Delta\theta_{i,i+2})$ ,  $(M\Delta l_{i,i+2}, S\Delta l_{i,i+2})$ 는 각각 i+1번째에서 i+2번째까지의 선형선소들 사이의 상대적인 정보를 나타내며, 각각의 특징량은 그림 1과 같이 정의된다.

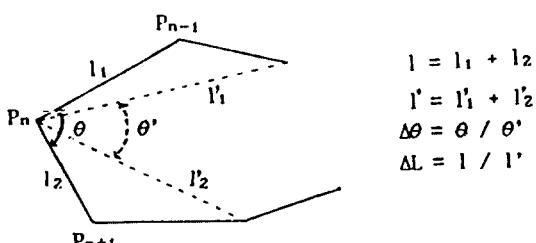


그림 1. 특징량의 정의  
Fig. 1. Definition of features.

따라서 모델영상은 다각근사화에 의해 국부특징값이 포함된 선형선소들의 집합으로 모델링되고, 새로 입력되는 미지영상 역시 동일 과정을 거쳐 선형선소들의 집합으로 모델링되어 모델과 미지영상의 선형선소들 간의 매칭에 의해 유사성을 측정하면서 미지영상 내의 모델을 인식하게 된다.

### III. 신경회로망에 의한 물체인식

본 논문에서 인식을 위해 사용되는 특징은 물체를 구성하고 있는 각 선형선소에 대한 국부특징량이므로 각 모델을 구성하고 있는 선형선소들 사이에는 서로 유사한 선형선소들이 다수 존재하게 되어 인식의 애매성이 발생한다. 또한, 유사한 국부특징량들로 이루어져 있기 때문에 각 특징들이 특징 공간상에 혼재해 있게 되어 신경회로망의 학습시 수렴특성이 좋지 못하게 되고, 더불어 신경회로망의 특성을 길정짓는 경계 구분능력의 저하를 가져오게 되어 인식율이 저하되는 문제점이 발생한다<sup>[12][13]</sup>. 따라서, 본 논문에서는 이와 같은 문제점을 보완하여 보다 효과적인 인식을 위해 그림 2와 같은 2개의 신경회로망이 단연결된 물체인식시스템을 구성하였다. 구성된 물체인식 시스템은 2개의 신경회로망으로 이루어져 있으며, 첫 번째 회로망(NET 1)에서는 개략적인 인식을 위한 과정으로서 대구적인 모델 단위의 정보를 출력하도록 한다. 또한, 두 번째 회로망(NET 2)은 첫 번째 신경회로망의 출력을 입력층의 입력으로 하므로써, 첫 번째 회로망의 개략적인 인식에서 발생하는 오인식의 영향을 최소화하고, 보다 향상된 인식 결과를 얻도록 하는 최종인식과정 회로망이 된다. 그림에서 첫 번째 신경회로망의 입력층에 주어지는 입력은 식 (1)로 정의된 선형선소의 국부 특징량이며, 첫 번째 신경회로망과 두 번째 신경회로망의 출력층에 나타난 출력  $M1, M2, M3$ 는 각 모델을 표현한 것이며, 인식된 결과를 나타낸다.

따라서, 본 논문에서의 물체인식 시스템에 의한 물체인식 과정은 크게 ①NET 1의 출력결정, ②NET 2의 출력 결정으로 나눌 수 있으며, 세부적으로 살펴보면 다음과 같다.

① 먼저 첫 번째 신경회로망에 의해 모델단위의 출력을 결정한다. 즉, 출력  $y$ 에 관련하는 어떤 입력변수  $x_1, x_2, \dots, x_n$ 을 설정하면, 회로망의 입력층에 주어지는 입력데이터  $x = (x_1, x_2, \dots, x_n)$ 가 되고, 여기서  $x$

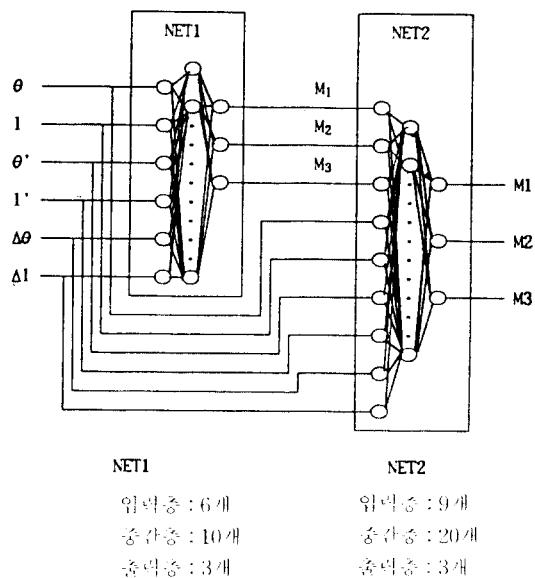


그림 2. 신경회로망에 의한 물체인식시스템의 구조  
Fig. 2. Topology of object recognition system by Neural Network.

는 입력변수의 1번 째 데이터가 된다. 다음으로 입력 변수에 대한 출력데이터를 설정하기 위해 입력 출력 데이터를  $n$ 개로 분할하고 신경회로망에 의해 학습시킨다. 즉, 예들 들어 2개의 입력변수에 대한 3개의 출력 변수를 결정하는 NET 1의 출력 결정과정 예를 그림 3에 나타내었으며 다음과 같다.

먼저 3층 신경회로망의 입력층의 입력데이터 중의 하나를  $x_1 = (0.2, 0.15)$ 라 하면 이 입력데이터를 3개의 모드 단위로 분류하기 위해서 출력 데이터의 분할을 3개로 하여,  $(M_1, M_2, M_3) = (1, 0, 0)$ 으로 하므로서 신경회로망의 입력층과 출력층의 데이터가 설정된다. 다음으로, 결정된 입력데이터와 출력데이터를 각각 신경회로망의 입력과 출력층의 교차 데이터로 주어 오차 역신경 학습 알고리즘으로 학습을 행한다. 따라서, 학습이 끝난 후 주어진 데이터(학습데이터)이외의 미지 데이터를 신경회로망의 입력층에 넣으면, 미지 데이터에 대한 출력값이 결정된다. 즉, 미지 데이터  $x_1 = (0.4, 0.2)$ 에 대한 NET 1의 출력  $(M_1, M_2, M_3) = (0.4, 0.1, 0.2)$ 가 얻어지게 된다.

② 다음으로, 첫번째 신경회로망에 의해 결정된 출력값을 이용하여, 두번째 신경회로망의 출력을 결정한다.

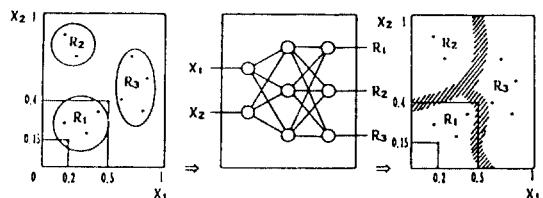


그림 3. 출력변수의 결정 예  
Fig. 3. Decision of output variables.

두번째 신경회로망에 있어서 입력은 첫번째 신경회로망의 출력인 모드 정보와 선형전소의 누적특성량을 동시에 이용한다. 또한, 출력은 모드단위의 인식결과를 나타내도록 하며, 첫번째 개장과 같이 오차역신경 학습 알고리즘에 의해 학습한 후 미지데이터에 대한 두번째 신경회로망의 출력을 결정하도록 한다.

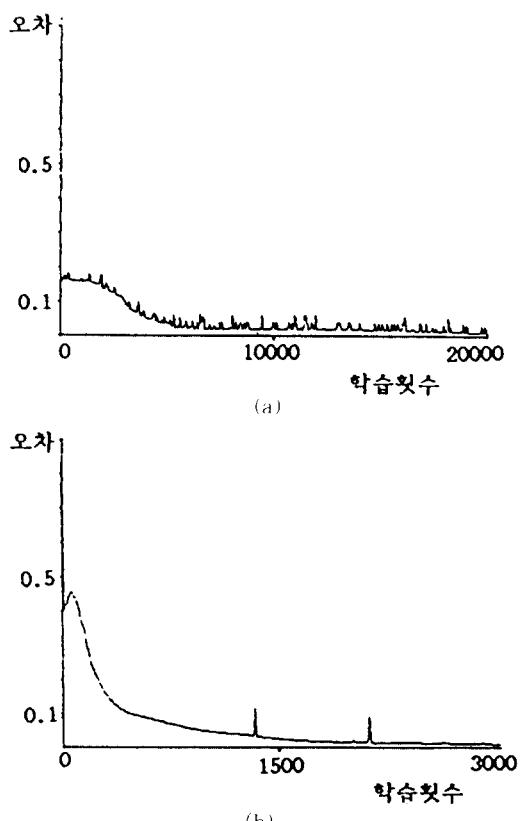


그림 4. 신경회로망의 수렴특성  
Fig. 4. Convergence characteristics of neural network.  
(a) NET 1 (b) NET 2

최종 인식결과를 나타내도록 한다.

따라서, 이 과정은 첫번째 신경회로망의 출력을 두 번째 신경회로망의 입력으로 다시 적용하기 때문에 결과적으로는 입력으로 제시되는 입력패턴에 대한 특징량의 증가를 가져온다. 이것은 인식대상에 대한 특징표현의 다양화를 가져오기 때문에 인식의 효율성을 제공한다. 또한, 다만 결합된 신경회로망의 성능을 살펴보기 위해 각각의 신경회로망에 대한 수렴특성을 그림 4에 학습횟수대 오차의 관계로서 나타내었다. 그림에서 알 수 있듯이 NET 1에서의 열화된 수렴특성이 NET 2를 거치면서 향상된 특성을 보이고 있다.

#### IV. 실험 및 고찰

실험은 크게 전처리과정과 인식과정으로 나눌 수 있으며, 전처리과정은 물체인식을 위한 특징추출과 모델형성으로 이루어 지고, 인식과정은 신경회로망에 의한 물체인식시스템에 의해 이루어진다. 본 실험의 전체적인 흐름도를 그림 5에 나타내었다.

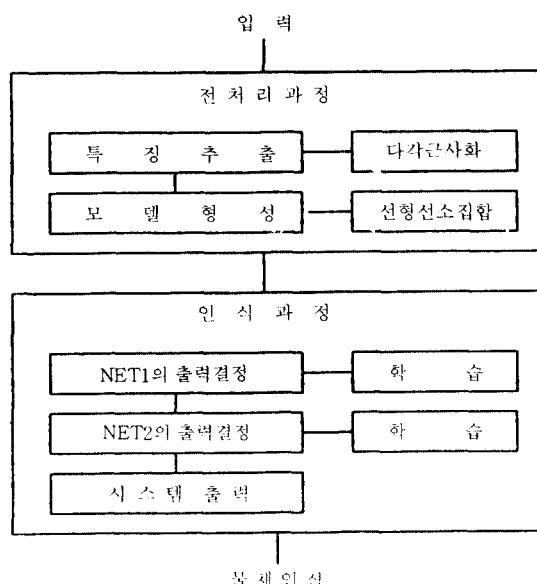


그림 5. 실험의 전체 흐름도

Fig. 5 Overall flowchart of experiments.

인식실험을 위한 영상의 입력은 그림자 및 물체 표면의 반사와 같은 잡음의 영향을 허용 하기 위해 자연조명하에서 받아들여졌으며, 실험은 IBM PC-AT 호환기종에서 C언어로 수행되었다. 본 논문에서의 물체인식은 단독 물체인식과 중복 물체인식으로 나누어 실험하였으며, 물체인식시 물체의 변형에 따른 인식결과를 알아보기 위해 크기 및 형태 변형이 일어난 미지영상에 대해서도 실험하였다. 실험에 사용된 3개의 모델영상은 프라이어, 가위 및 스파너와 같은 공구로서  $256 \times 256$ 화소 크기로 구성되었다. 구성된 모델영상에 대해 물체의 경계를 추출한 후 추출된 경계점들은 다각형 근사 알고리즘을 이용하여 선형 선소들의 집합으로 근사화 한다. 따라서 본 논문에서 인식대상으로 하는 프라이어, 가위, 스파너모델은 각각 18, 15, 16개의 선형선소로 근사화된다.

그림 6과 그림 7에 모델과 미지영상에 대한 전처리 결과 예를 나타내었다. 그림 6(a)와 그림 7(a)는 2진 영상을 나타냈으며, 그림 6(b)와 그림 7(b)는 경계검출결과를, 그림 6(c)와 그림 7(c)는 다각형 근사결과를 나타낸 것이다. 실험에 사용된 미지영상은 모델영상에서와 같은 처리를 거쳐 선형선소들의 집합으로 변환된다. 실험에서 사용된 미지영상은 200개의 모델이 포함된 100개의 영상이며, 이중 단독 모델영상이 20개, 2개의 모델과 3개의 모델이 중복된 영상이 각각 40개씩이다. 또한, 100개의 미지영상 중 50개의 영상은 대상물체가 변형되지 않은 영상이고, 나머지 50

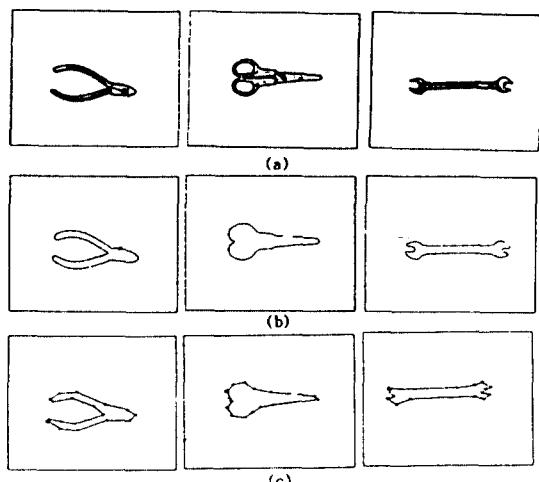


그림 6. 모델영상.

Fig. 6. Model image.

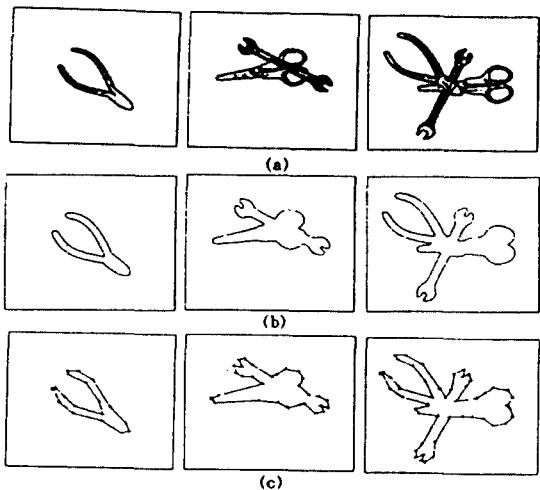


그림 7. 미지영상  
Fig. 7. Unknown image.

개의 미지영상은 대상불체의 크기 및 형태의 변형이 일어난 영상이다.

구성된 신경회로망에 오차 역전과 학습 알고리즘을 이용하여 학습을 행한다음 인식실험을 하였으며, 학습에 이용된 학습 파라메타는 시행착오를 거쳐 결정되었고, 다음과 같다.

판정율 : 0.9

학습율 : 0.01

총오차 : 0.001

실험에 사용된 입력 데이터는 표 1에 나타낸 6개의 국부특징량을 이용하였으며, 출력층에 나타난 출력 결과는 모델에 대한 정보를 나타낸다. 그림 8(a)는 미지영상에 대해 나타난 다각형 판사결과이며, 그림 중 '+' 표시는 영상의 군락점을 나타낸다. 그림 8(b)는 단독불체 및 두개의 모델이 중복된 경우, 세개의 모델이 중복된 영상에 대해 실험결과로써 나타난 인식결과이다. 본 실험에서 인식결과에 대한 모델의 인식여부의 판정은 선소인식율이 50% 이상인 것을 모델 판정의 대상으로 하였으며, 대상중 다시 원 모델 영상 선소수의 50% 이상의 것을 모델에 대한 정인식으로 하였다. 즉, 선소의 인식율은 다음과 같이 정의하였다.

표 1. 실험에서 사용된 특징량의 예.

Table. 1. Input features used experiment.

선소	입력데이터					
	$\theta_{i,i+1}$	$I_{i,i+1}$	$\theta'_{i,i+1}$	$I'_{i,i+1}$	$\Delta\theta_{i,i+1}$	$\Delta I_{i,i+1}$
1	176	62	123	124	1.43	0.50
2	120	15	132	63	0.91	0.24
3	205	30	157	118	1.31	0.25
.	.	.	.	.	.	.
.	.	.	.	.	.	.
.	.	.	.	.	.	.

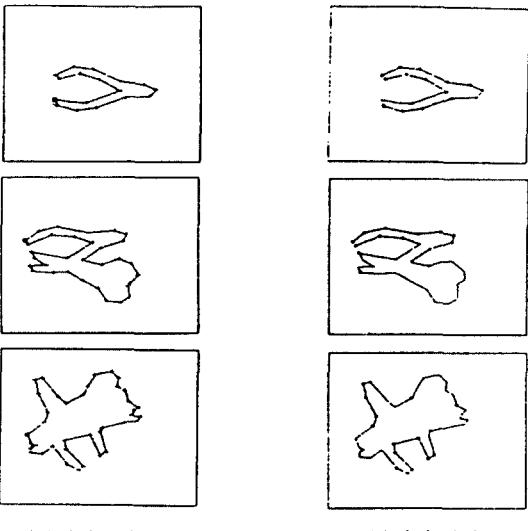


그림 8. 정인식 결과

Fig. 8. Correct Recognition results.

$$\text{선소인식율} = \frac{\text{모델별위 내에 존재하는 정인식 선소수}}{\text{모델별위 내에 존재하는 선소수}}$$

여기서 모델이 위치한 범위 밖에 나타난 인식결과는 무시하였다. 또한, 선소의 인식율 50%를 기준으로 하므로써 발생하는 인식판정의 불합리성을 보완하기 위하여 선소의 정인식이 50% 이상인 것만을 대상으로 하여, 대상중 정인식 선소수가 원 모델영상의 선소수의 50% 이상의 것을 모델에 대한 정인식, 50% 이하의 것을 오인식으로 하여 최종 모델의 인식여부를 판정하는 방법을택하였다. 인식결과 그림 8(b)에 표시된 '+'은 신경회로망에 의한 실험결과로써 나타난

점(dot)이며, 선형 선소들 사이의 매칭에 의해 인식대상 모델을 인식한 결과로써 나타난다. 즉, ‘·’은 인식된 선소에 대한 꼭지점을 표시하고 있으며, 그림의 결과는 미지영상에 있어서 프라이어모델에 대한 인식결과이다. 본 실험에서는 인식결과에 대한 판정 기준으로써, ‘·’으로 표시된 선형선소의 꼭지점의 갯수를 기준으로 한다. 즉, 인식대상 모델의 선형선소에 대해 표시된 ‘·’의 갯수를 정인식 갯수로 하고, 대상모델의 선형선소 범위를 벗어난 위치에 표시된 ‘·’의 갯수를 오인식 갯수로 하였으며, 또한, 내상모델의 범위를 벗어난 위치에 나타난 결과와 대상모델과 다른 모델과의 중복에 의해 나타난 경계점들은 무시하였다. 예를들어, 그림 8(b)에서는 프라이어 모델에 대한 인식결과를 나타낸 것이며, 그림에서 단두불체인 경우 표시된 ‘·’의 수가 16개이고, 표시되지 않은 꼭지점의 수가 2개 이므로 18개중 16개를 정인식으로 보아 약 89%의 인식율을 보인다. 역시, 두개의 모델이 중복된 영상에서 보면, 프라이어라고 판정한 선형선소의 총 갯수는 15개이고, 그림중 대상모델이 위치한 범위외에 나타난 갯수와 다른 모델과의 경계점을 무시하면, 이중 프라이어가 위치한 범위내에 표시된 갯수는 12개이며, 프라이어가 위치한 범위내에 인식여부가 표시되지 않은 갯수는 3개이므로, 정인식 선소수는 12개로 하고, 오인식된 선소수는 3개로 한다. 따라서 이경우 프라이어 모델에 대한 선소의 정인식율은 15개중 12개로써 약 80%가 된다. 또한, 3개의 모델이 중복된 경우는 프라이어로 인식한 정인식 갯수가 10개이고, 오인식 갯수는 2개를 나타내고 있으므로, 프라이어에 대한 선소의 정인식율은 12개중 10개로서 약 83%를 보이고 있다. 따라서 선소의 정인식율 50%를 기준으로 하여, 50%이상의 것을 대상으로 최종 모델의 인식 판정을 할 경우 정인식 수가 원 모델영상의 선소수(18개)의 50%이상이므로 그림에서 나타난 결과는 모두 프라이어 모델을 정인식한 결과를 나타낸다.

그림 9는 모델이 오인식된 경우의 결과를 나타내며, 그림 9(b)에서 맨 위쪽 그림은 스패너 모델을 인식한 결과이고, 이 경우 선소의 정인식 갯수는 7개, 오인식 갯수는 2개이므로 선소의 정인식율은 약 78%를 나타내고 있으나 정인식 선소수가 원 모델영상의 선소수(18개)의 50%이하에 해당되므로 모델 판정에 있어서 오인식으로 된 경우이다. 또한, 나머지 두 그림의 인식결과는 모두 가위 모델을 인식할 것으로 역

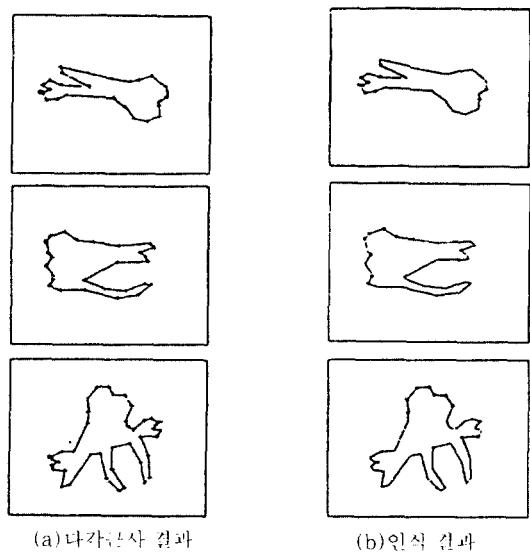


그림 9. 오인식결과

Fig. 9. Ill Recognition results.

시 위의 경우와 마찬가지로써 나타난 오인식 결과이다.

그림 10과 그림 11은 크기 및 형태의 변형이 일어난 경우의 인식결과이다. 그림 10(a)와 그림 11(a)는 다각형사결과를 나타내었으며, 그림 10(b)와 그림 11(b)는 각각 물체의 크기가 변화된 경우의 인식결과와 형태의 변형이 일어난 경우의 인식결과로써, 각각 가위와 프라이어를 인식한 경우이다. 따라서 실험을 통하여 나타난 각 모델에 대한 전체의 실험결과를 표 2와 표 3에 나타내었으며, 1개의 신경회로망만을 사용한 경우의 물체인식 결과와 본 논문에서 사용된 물체인식 시스템에 의한 물체인식 결과를 비교하여 나타내었다.

표 2. 실험결과(물체변형이 안된 경우).

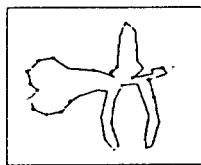
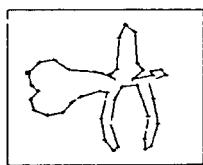
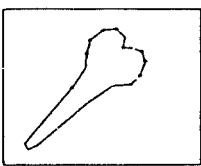
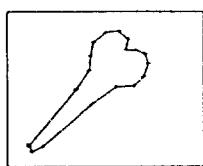
Table. 2. Experimental results(case of no variation).

방법	영상	프라이어	가위	스패너	TOTAL
1개 신경회로망에 의한 방법	89	89	83	87	
본 논문에서 사용된 방법	95	92	86	91	

표 2. 실험 결과(물체가 변형된 경우)

Table. 2. Experimental results(case of variation).

방법	영상	프라이어	가위	스캐너	TOTAL
1개 신경회로 방에 의한 방법	73	70	67	70	
본 논문에서 사용된 방법	78	80	77	78	

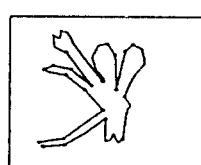
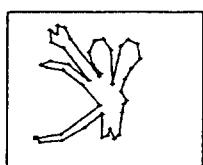
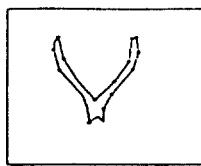
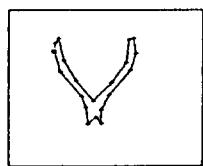


(a) 다각분사 결과

(b) 인식 결과

그림 10. 물체변형에 따른 인식결과(크기변형)

Fig. 10. Recognition result according to object variation(change of scale).



(a) 다각분사 결과

(b) 인식 결과

그림 11. 물체변형에 따른 인식결과(형태변형)

Fig. 11. Recognition result according to object variation(change of shape).

## V. 결 론

본 논문은 효과적인 물체인식을 위해 2개의 신경회로망이 다만 결합된 물체인식 시스템을 구성하였다. 구성된 물체인식 시스템을 이용하여 단독물체 및 중복물체, 그리고 변형된 물체에 대해 각각 실험한 결과, 첫번째 신경회로망의 출력을 두번째 신경회로망의 입력으로 이용하기 때문에 인식대상을 표현하는 특징량의 증가효과를 가져와 인식의 애매성을 해소할 수 있었으며, 한개의 신경회로망만을 이용한 경우와 비교한 결과, 다만 결합된 신경회로망을 이용한 방법이 보다 효과적이었다. 특히, 본 연구에서 사용된 물체인식시스템에 의한 인식방법이 변형된 물체인식에 있어서도 유연히 적용됨을 알 수 있었다.

## 참 고 문 헌

- W.A.Perkins, "A model based vision system for industrial parts," IEEE Trans. on Computer, Vol.C-27, No.2, pp.126-143, Feb. 1978.
- M. W. Koch and R. L. Kashyap, "Using polygons to recognition and locate partially occluded objects" IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol. PAMI-9, No.4, Jul., 1987.
- J. L. Turney, T. N. Mudge and R. A. Volz, "Recognizing partially occluded parts", IEEE Trans. on Pattern Analysis and Machine Intelligence, Vol.PAMI-7, No.4, pp.410-421, Jul., 1985.
- D. H. Ballard, "Generalizing hough transform to detect arbitrary shapes", Pattern Recognition, Vol.13, pp.111-122, 1981.
- G. Stockman, S.Kopstein and S.Benett, "Matching images to models for registration and object detection via clustering", IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.PAMI-4, pp.229-241, May, 1982.
- B. Bhanu and O.D.Faugeras, "Shape matching of two-dimensional objects", IEEE Trans. on Pattern Analysis and Machin Intelligence, Vol. PAMI-6, No.2, pp.137-155, Mar., 1984.
- G.A. Carpenter, "Neural network models for

- pattern recognition and associative memory", Neural Networks, Vol.2, pp.243-257, 1989.
8. D.J.Burr, "Experiments on neural network recognition of spoken and written text", IEEE Trans. on Acoustics, Speech, and Signal Processing, Vol.36, No.7, pp.1162-1168, (Jul), 1988.
9. Y.H.Pao, Adaptive pattern recognition and neural networks, Addison Wesley Pub., 1989.
10. D.S.Touretgkz, Advances in neural information processing system I, Morgan Kaufmann Pub., 1989.
11. T. Pavlidis, Algorithms for graphics and image processing, Computer Science Press, 1982.
12. R.P.Lipmann, "An introduction to computing with neural nets", IEEE ASSP Margazine, pp.4 22, Apr., 1987.
13. B. Widrow, R.G.Winter and R.A.Baxter, "Layered neural nets for pattern recognition", IEEE Trans. on Acoustics, Speech, and Signal Processing; Vol.36, No.7, pp.1109-1118, Jul., 1988.



**金亨根 (Hyo-Geun KIM)** 정회원  
1958년 4 월12일생  
제16권 1 호 참조

**宋 鐵 (Chull SONG)** 정회원  
1961년 : 조선대학교 전기공학과(공학사)  
1977년 : 조선대학교 대학원 전기공학과(공학석사)  
1985년 : 전북대학교 전기공학과(공학박사)  
현재 : 조선대학교 공과대학 컴퓨터공학과 교수  
※ 관심분야 : 신호처리



**朴承圭 (Sung Kyu PARK)** 정회원  
1983년 : 조선대학교 전자공학과(공학사)  
1985년 : 조선대학교 대학원 전자공학과(공학석사)  
1987년 : 조선대학교 전기공학과 전산기 전공 박사과정  
현재 : 신북산업대학 전자계산학과조교수  
※ 관심분야 : 신호처리, 음성인식 및 영상처리



**崔甲石 (Kap Seok CHOI)** 정회원  
1930년 9 월30일생  
제16권 1 호 참조