

論文96-33B-5-8

Hopfield 신경회로망을 이용한 모델 기반형 3차원 물체 인식

(Model-based 3-D Object Recognition Using Hopfield Neural Network)

|鄭宇翔*, 宋浩根*, 金泰銀*, 崔宗秀***
 (Woo Sang Jung, Ho Keun Song, Tae Eun Kim, and Jong Soo Choi)

요약

본 논문에서는 Hopfield 신경회로망을 이용한 모델 기반형 3차원(3-D) 물체 인식 방법을 제안하였다. 제안된 방식에서는 3-D 회전 변화에 따르는 특징 변화량을 최소화하기 위하여 회전 변화에 강건한 3-D 형상 특징들과 3-D 관계 특징들을 선별 사용하였다. 위 특징들은 정규화되어 크기 변화에도 강건하도록 개선하였다. 그리고 입력 특징들은 2차원 배열 구조를 가지는 Hopfield 신경회로망의 최적화 기능을 이용하여 각 모델 특징들과 매칭하였다. 3-D 회전, 스케일 변화 그리고 부분적으로 중첩된 입력 물체에 대한 물체 분류 실험과 매칭 실험의 결과를 통하여 제안하는 방법의 성능이 우수함을 확인하였다.

Abstract

In this paper, a new model-based three-dimensional(3-D) object recognition method using Hopfield network is proposed. To minimize deformation of feature values on 3-D rotation, we select 3-D shape features and 3-D relational features which have rotational invariant characteristic. Then these feature values are normalized to have scale invariant characteristic, also. The input features are matched with model features by optimization process of Hopfield network in the form of two dimensional arrayed neurons. Experimental results on object classification and object matching with the 3-D rotated, scale changed, and partial occluded objects show good performance of proposed method.

I. 서론

과거 수십여년동안 컴퓨터 시각(computer vision) 분야에서 컴퓨터에 시각 기능을 부여해 주고자 많은 연구가 이루어져 왔다. 그 결과 항공 사진이나 2차원 패턴과 같은 영상의 이해는 많은 발전이 이루어졌지만 아직도 3차원의 실세계 장면을 보고 그 안에 존재하는 물체들을 효과적으로 인식해 내지 못하고 있다. 이는 3

차원 물체의 인식이 2차원 물체의 인식과는 달리, 보는 시각에 따라 물체의 형상이 다양하게 변화하므로 그만큼 많은 어려움들을 내포하고 있기 때문이다. 따라서 3 차원 물체 인식을 위해서는 물체의 3차원적 형상에 대한 충분한 지식 표현과 그에 따르는 정교한 인식 기법이 필요하다^[1]. 3차원 물체 인식 기법들 중에서 모델 기반형 인식(model-based recognition) 기법은 인식하고자 하는 모델 물체의 특징(feature)을 기술(description)하고, 입력 영상으로부터 추출된 특징들과 모델 특징들을 비교하여 영상 내에 존재하는 물체의 종류와 위치 및 자세등을 인식해 내는 방법이다^[2]. 모델 기반형 인식을 위해서는 인식하고자 하는 물체의 물리적 특징과 그들의 기하학적 연관 관계를 표현하는 특징들의 기술 문제 그리고 입력된 영상 특징들과 모델 물체들간의 매칭문제에 대하여 고찰하여야 한다. 이때

* 正會員, 中央大學校 電子工學科

(Dept. of Electro. Eng. Chung Ang Univ.)

** 正會員, 韓國科學財團 制御計測新技術研究센터

(Engineering Research Center for Advanced Control and Instrumentation by KOSEF)

接受日字:1995年10月13日, 수정완료일:1996年3月30日

매칭 기법은 보통 모델의 표현 형태에 따라 달라지며, 입력 영상과 모델 특징간의 비교 매칭을 가능한한 빠른 시간에 효율적으로 해결할 수 있는 기법이 요구된다^[3]. 이러한 연구들 중 신경회로망을 사용해서 기하학적인 변형에 강건한 모델 기반형 인식 기법에 관한 연구가 활발하다. 다양한 분야에 적용되고 있는 여러 종류의 신경회로망은 제각기 각 분야에서 효과적으로 일을 수행할 수 있도록 구성되어 응용된다. 특히 영상 처리나 패턴 인식 분야에서는 입력 영상과 특징 기술 형태에 따라 입력 및 출력 노드의 구성이 다양하게 변화하기 때문에, 신경회로망의 뉴우런(neuron) 개수 변화에 대해 비교적 쉽게 적용할 수 있는 Hopfield 신경망이 적합하다. 또한 Hopfield 신경회로망은 여타 신경망에 비하여 수렴 속도가 빠르며 하드웨어 구성을 수 행속도가 매우 빠른 장점이 있다. 따라서 영상 처리와 패턴 인식에는 일반적으로 Hopfield 신경회로망이 적용되고 있다^[4,5].

기존의 2차원적 물체 인식 방법을 살펴보면 Nasrabadi et al.^[6]은 Hopfield 신경회로망을 이용한 2차원 물체 인식 방법을, Young et al.^[7]은 유사한 2차원 물체를 인식하기 위하여 Hopfield 신경회로망을 두 층으로 구성하였다. 그러나 위 연구들은 2차원 물체 인식에 한정되었기 때문에 시점 변화에 따른 입력 형상의 변화에는 적용할 수 없었다. 3차원 물체 인식으로는 Lin et al.^[8]이 한 물체에 대하여 다중 관찰 방향(multiple-view)에서 얻어진 여러 개의 2차원 영상을 모델화하고 Hopfield 신경회로망을 이용한 인식 방법을 제안하였다. 하지만 위 논문도 물체 인식을 위해 2차원 특징을 사용하고 있고, 하나의 3차원 물체를 인식하기 위해서는 다중 관찰 방향에서 얻어진 여러개의 모델들과 비교해야 하는 번거로움을 감수해야만 했다. 한편 Hongbin et al.^[9]은 Hopfield 신경회로망을 이용하여 3차원 곡면체를 인식하는 방법을 제안하였다. 하지만 위 논문은 3차원 곡면체를 인식하기 위한 특징으로 면의 유형만을 고려했기 때문에 유사한 형태의 곡면체나 같은 유형의 면이 2개 이상으로 이루어진 물체의 경우 인식할 수 없는 문제점이 있다. 결국, 위 고찰들을 통하여 볼때 시점 변화에 따라 물체의 형상이 다양하게 변화하는 실세계의 물체를 보다 효과적으로 인식하기 위해서는 3차원 입력 거리 영상으로부터 3차원 불변 특징들을 추출하여 사용하고, 물체 인식의 정확성을 높이기 위해서는 물체를 표현하는 여러가지 특

징들을 복합적으로 사용해야 할 필요가 있음을 알 수 있다.

따라서, 본 논문에서는 3차원 입력 거리 영상으로부터 3차원 불변 특징들을 추출하여 Hopfield 신경회로망으로 모델 특장들과 비교, 평가하므로써 시점 변화에 따른 물체의 기하학적 변형에 강건한 모델 기반형 3차원 물체 인식 방법을 제안한다. 제안된 방식에서는 모델 베이스를 구축하기 위하여 면의 3차원 면적과 3차원 장, 단축과 같은 3차원 형상 특징과 면간 거리와 면간 접합 각도와 같은 3차원 관계 특징을 복합적으로 사용하였다. 특히 본 논문에서는 위 특징들을 정규화하여 크기 변화에도 불변토록 하였다. 입력된 3차원 거리 영상으로부터는 3차원 불변 특징들을 추출하고 Hopfield 신경회로망의 반복 학습에 의하여 각 모델들과 비교하였다. 사용한 Hopfield 신경회로망의 뉴우런들은 2차원적으로 배열하며, 행(row)은 입력 영상의 각 면을, 열(column)은 모델의 각 면을 할당하여 입력 영상과 모델을 비교하였다.

본 논문은 II장에서 기존의 신경회로망을 이용한 물체 인식 방법들에 대해 설명한다. 그리고 III장에서 매칭을 위한 Hopfield 신경회로망에 대해 설명하고, 물체 인식을 위해 필요한 물체의 특징들과 Hopfield 신경회로망을 이용하여 매칭하는 방법을 설명한다. IV장에서는 합성 거리 영상과 실제 거리 영상, 그리고 일부 가려짐이 있는 합성 거리 영상에 대한 모의 실험 결과를 보이고 V장에서 결론을 맺는다.

II. 기존의 신경회로망을 이용한 물체 인식 방법

본 장에서는 기존의 Hopfield 신경 회로망을 이용한 물체 인식 방법과 그들의 문제점에 대하여 고찰하고자 한다.

1. 기존의 신경회로망을 이용한 2차원 물체 인식 방법

Nasrabadi et al.^[6]은 입력 명암 영상내의 2차원 물체에 대하여 윤곽선과 그 불연속점(break point)들을 추출하고 Hopfield 신경회로망을 이용하여 모델과 매칭시킴으로써 2차원 물체들을 인식하였다. 실험 물체는 렌치(wrench)와 같은 일반 공구로써 입력 명암 영상을 문턱값 처리를 하여 이진 영상(binary image)으로 변환시킨 후 공구의 윤곽선을 추출해 내었다. 추출

된 공구의 유팍선에서는 Pavlidis polygonal fitting algorithm을 이용하여 유팍선의 불연속점들을 찾아내고, 이 불연속점들을 대상으로 하나의 불연속점을 구성하고 있는 두 선분사이의 각도들과, 주변 불연속점들 사이의 거리들을 계산하여 매칭을 위한 특징으로 사용하였다. 위 논문의 매칭 방법은 입력 영상에서 계산된 특징값들을 Hopfield 신경회로망으로 모델의 특징값들과 비교하여 각각 대응되는 불연속점들을 찾는 방법을 사용하였다. 실험 결과에서는 공구의 유팍선에서 찾아진 입력 특징들과 모델특징들이 비교적 정확하게 매칭되는 것을 보이고 있으나, 물체의 유팍선이 유사할 경우 불연속점들이 유팡선의 비슷한 위치에 분포하게 되고, 따라서 유사한 물체끼리는 낮은 인식율을 보이는 문제점이 있었다. 한편 Young et al.^[7]은 Hopfield 신경회로망을 두 층으로 구성하고 입력 명암 영상과 모델도 두개의 해상도로 구성하여 유사한 2차원 물체를 인식할 수 있는 방법을 제안하였다. 두 층으로 구성된 신경회로망의 뉴우런은 서로 다른 층의 뉴우런과 연관 관계를 가지도록 구성이 되어 있다. 그리고 입력 명암 영상은 QMF 필터에 의해 모델 영상과 마찬가지로 영상의 크기가 1/2인 해상도의 영상이 생성된다. 해상도가 서로 다른 두 장의 입력 영상은 각각 불연속점들과 특징값들이 구해지고 두 층의 신경회로망을 사용하여 각각 모델의 특징값들과 비교한다. 실험 결과에서는 하나의 Hopfield 신경회로망을 이용했을 때보다 두 층으로 구성된 Hopfield 신경회로망을 이용했을 때 더 높은 매칭율로써 유팡선이 유사한 열쇠를 분류한 것을 보이고 있다. 하지만 위와 같은 2차원적 물체 인식 방법들은 2차원 명암 영상으로부터 추출된 2차원 특징들을 사용하는 관찰자 중심의 인식 방법들이기 때문에 3차원적 시점 변화에 따른 기하학적 변화에 적응되기 힘든 난점이 있다. 따라서 시점에 무관하게 물체를 인식하기 위해서는 물체 중심의 인식 방법으로서 3차원적 물체 인식 방법이 필요하다.

2. 기존의 신경회로망을 이용한 3차원 물체 인식 방법들

3차원 물체 인식에 있어서는 Lin et al.^[8]이 한 물체에 대하여 다중 관찰 방향(multiple-view)에서 얻어진 여러 개의 2차원 영상들을 모델화하여 Hopfield 신경회로망을 이용한 3차원 물체 인식 방법을 제안하였다. 그들은 2단계 인식 과정(coarse-to-fine)을 제

안했는데, 1단계는 Hopfield 신경회로망을 이용하여 입력 영상과 모델간의 면 매칭으로 인식 대상 모델의 범위를 좁히고 2단계에서는 1단계에서 선택된 모델들과 입력 영상과의 정점(vertex) 정합을 Hopfield 신경회로망을 이용하여 결정하였다. 하지만 위 논문은 하나의 3차원 물체를 인식하기 위해 다중 관찰 방향에서 얻어진 여러개의 모델들과 비교해야 하는 번거로움이 있고, 다중 관찰 방향에서 얻어진 모델 영상과 입력 영상의 시점이 일치하지 않을 경우 정확한 면 매칭을 보장할 수 없었다. 한편 Hongbin et al.^[9]은 신경회로망을 이용하여 3차원 곡면체를 인식하는 방법을 제안하였다. 위 논문에서는 평면, 원뿔면, 원통면, 구면과 같은 기본적인 면의 유형과 각 면 사이의 연관 관계를 특징으로 사용하였다. 여기서 사용한 면의 유형은 3차원 불변 특징으로 3차원 물체내의 면 매칭에 유용하게 사용될 수 있다. 그러나 면 유형만을 사용했기 때문에 인식하고자 하는 두 물체의 외형이 서로 다르더라도 면의 유형이 모두 같은 경우에는 전혀 인식할 수 없는 문제가 있다.

결국 위 고찰들을 통하여 시점변화에 따른 기하학적 변형을 포함하는 3차원 물체들을 효과적으로 인식하기 위해서는 3차원 불변 특징을 사용함이 바람직하며, 특히 기하학적 변형과 유사한 물체에 대한 인식율을 높이기 위해서는 물체를 표현하는 특징들을 복합적으로 사용하여야 함을 알 수 있다.

III. 제안하는 신경회로망을 이용한 3차원 물체 인식 방법

본 장에서는 제안하는 Hopfield 신경회로망을 이용한 3차원 물체 인식방법에 대하여 고찰한다.

1. 물체 특징의 기술(description)

물체의 기술(description)을 위해 어떠한 특징들을 사용하는가는 인식 과정 전체에 큰 영향을 미친다. 따라서 물체의 변형에 영향을 적게 받는 특징들을 찾아 모델 기술에 사용한다면, 그 만큼 인식 시스템의 효율 및 신뢰도를 높일 수 있다. 그러므로 이용되는 특징들에 대한 심도 있는 고찰이 필요하다^[10,11]. 따라서 인식에 사용될 물체 특징들을 그 특성에 따라 분류해 놓는 것은 인식의 매칭 과정에서 입력 영상의 여러 가지 가능한 상황에 융통성 있게 대처할 수 있게 해준다는

점에서 매우 중요한 일이다. 여러 가지 물체의 특징들 중 먼저 그것이 무엇을 표현해 주기 위한 특징인가에 따라 다음과 같이 분류한다.^[12] 첫째, 위치, 방향(position, orientation)특징이다. 이는 면, 선, 점등의 위치와 방향에 관한 정보를 표현하는 특징이다. 그 전형적인 예로, 면의 방향, 면과 선의 3차원 좌표 등이 있다. 3차원 공간상의 위치, 방향 정보는 입력 장치와 물체의 놓여져 있는 위치에 따라 달라지므로, 객관적인 인식의 평가 기준이 될 수 없다. 둘째, 형상(shape)특징이다. 이는 물체 내에 존재하는 면과 선의 기하학적 형상을 표현하는 특징이다. 예로서는 면의 넓이, 표면 유형, 이심율, 선의 길이, 선의 유형 등이 있다. 일반적으로 형상 특징들은 관찰 방향 혹은 가려짐(occluding) 등의 영향을 많이 받게 되고, 따라서 인식 과정에 사용하기에는 많은 난점을 가진다. 그러나 각 특징들의 형상을 무시하고 인식을 행한다는 것은 불가능한 일이므로, 인식을 위해 이들 형상 특징들의 갖가지 외부 요인들에 대한 민감성의 고려가 뒤따라야 한다.셋째, 관계(relation)특징으로 이는 면과 면, 혹은 선과 선간의 기하학적 연관 관계를 표현하는 특징이다. 그 대표적인 예로 면간 접합 각도, 접합 유형, 접합선 길이 그리고 선간 접합 각도와 유형 등이 있다. 일반적으로 관계 특징들은 관찰 방향의 변화나 중첩에 의한 영향을 받지 않으므로 인식에 있어 매우 유용하게 사용된다. 또 다른 분류의 기준으로 자신이 표현하는 정보의 차원에 따라 3차원 특징과 2차원 특징으로 분류된다. 첫째, 3차원 특징이란 물체의 3차원적 정보, 예를 들면 면의 3차원 방향 정보, 표면의 유형 정보, 그리고 면과 면사이의 접합 유형이나 접합 각도에 관한 관계 정보 등을 표현하는 특징을 말한다. 3차원 특징들은 관찰 방향이나 중첩에 강건하기 때문에 인식에 매우 유용하게 사용된다. 둘째, 2차원 특징들은 물체의 2차원적 정보를 표현한다. 2차원적 특징에는 면과 선 등의 2차원적 형상 정보와 관계 정보를 가지며, 인식 과정에서 각 특징들의 비교에 사용된다. 그러나 3차원 물체 인식에 있어서 2차원 특징들은 기하학적 변형에 민감하기 때문에 사용하는데 한계가 있다. 위에서 설명한 물체의 특징들을 종합적으로 분류하면 표 1과 같다.

표 1의 분류를 바탕으로 3차원 관찰 방향에 따른 물체 형상의 변화에 강건한 3차원 물체 인식을 위해서는 3차원 형상 특징과 3차원 관계 특징이 유용함을 알 수 있다. 물론 보다 많은 특징을 사용할수록 보다 강건한

인식이 가능하지만 현실적으로는 주어진 상황에 적합한 최소개의 특징들이 요구되고 있다. 한편 일반적으로 3차원 물체는 면조각들(patches)의 집합으로 충분히 표현이 가능하며, 각 면조각들은 다시 면 특징들(patch attributes)로 기술된다^[13]. 따라서, 본 논문에서는 모델물체 M을 $M = \{P_{m1}, P_{m2}, \dots, P_{mM}\}$ 과 같이 면조각들의 집합으로 표현하고, 입력물체 I 역시 가시면조각들(visible patches)에 대하여 $I = \{P_{i1}, P_{i2}, \dots, P_{iN}\}$ 과 같이 표현하였다. 그리고 각 면조각들은 관찰시점에 따른 형상변화를 포함한다는 가정을 설정하고 다음과 같은 면특징들을 사용하였다.

표 1. 특징들의 분류
Table 1. Classification of features.

특징	특성	중첩	관찰 방향	차원
법선 방향	위치/방향	○	×	3D
2D 넓이	형상	△	×	2D
3D 넓이	형상	△	○	3D
표면 유형	형상	○	○	3D
이심율	형상	×	×	2D
원형도	형상	×	×	2D
구멍 개수	형상	△	○	2D
선분 개수	형상	△	○	2D
인접면 개수	관계	△	×	2D
접합 유형	관계	○	○	3D
접합 각도	관계	○	○	3D
접합선 길이	관계	△	×	2D
선 유형	형상	○	×	2D
선 길이	형상	△	×	2D
선간 접합각도	관계	○	×	2D

첫째, 3차원 형상 특징 중의 하나인 분할된 각 면의 3차원 면적이다. 3차원 공간에서 각 면의 모양이 보는 각도에 따라 다르기 때문에 2차원 공간에서 면적을 구하면 면적의 크기가 보는 각도에 따라 달라진다. 이와 같은 문제점을 해결하기 위해 본 연구에서는 각 면의 한 화소를 하나의 조각으로 가정하여 각 조각의 3차원 면적을 구한 후, 각 면에 속하는 조각들의 면적의 합을 면의 면적으로 사용하였다. 그림 1와 같은 조각의 면적은

$$\text{Area} = \sqrt{(x_1 - x_0)^2 + (y_1 - y_0)^2 + (z_1 - z_0)^2} \quad (1)$$

$$\times \sqrt{(x_2 - x_0)^2 + (y_2 - y_0)^2 + (z_2 - z_0)^2} \times \sin \theta$$

와 같은 식을 이용하여 구한다^[14].

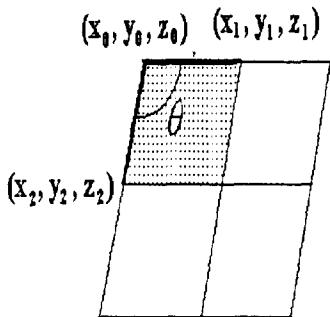


그림 1. 3차원 면적을 구하기 위한 조각

Fig. 1. Patch for 3-dimensional area.

둘째, 3차원 형상 특징으로 각 면을 구성하고 있는 정점의 3차원 좌표값으로부터 한 면을 구성하는 정점들간의 길이를 각각 계산하여 가장 긴 길이와 가장 짧은 길이를 각 면의 특징으로 사용한다. 위와 같은 두가지 3차원 형상 특징을 사용하면 형상은 다르지만 우연히 면적이 비슷할 경우에도 서로 다른 면으로 인식할 수 있게끔 하여 물체 인식의 정확성을 기할 수 있다.

셋째, 각 면의 중심점을 구하고 3차원 관계 특징인 각 면 중심점간의 거리를

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad (2)$$

와 같이 구하여 각 면의 관계를 함축적으로 표현하는 중요한 특징으로 이용한다. 그림 2은 물체의 2번 면의 중심점과 주변 면들의 중심점간의 거리 특징인 $d_{21}, d_{23}, d_{24}, d_{25}, d_{26}$ 을 보여준다.

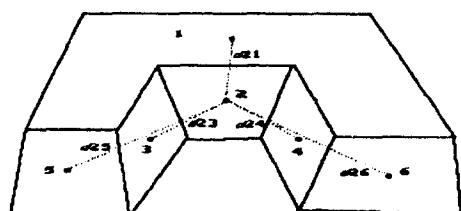


그림 2. 중심점간의 거리 특징

Fig. 2. Distance feature set.

넷째, 3차원 관계 특징인 각 면 간의 접합 각도를 계산하여 사용한다. 앞서 논한 3차원 형상 특징들과 마찬가지로 사용되는 3차원 관계 특징들도 중심점간의 거리와 접합 각도가 서로 보완적인 기능을 수행한다. 예

를 들어, 중심점간 거리가 같은 경우라도 접합 각도가 다른 관계를 구별할 수 있다.

위 네가지 특징들을 사용하면 물체를 구성하는 각 면의 형상과 각 면간의 관계를 구별할 수 있다. 위 특징들은 모두 3차원 관찰 시점 변화에 강건한 특성을 지닌다. 하지만 물체와 시점간의 거리 변화에 따른 입력 물체의 크기 변화에는 적응하지 못한다. 물론 크기가 다른 입력 물체의 경우 상이한 물체로 해석하는 견해도 있지만 본 논문에서는 모델 물체가 다양한 시점 변화에 의존하여 입력되는 상황을 가정하고 본 논문에서 사용하는 특징들, 즉 각 면의 3차원 면적과 정점간 최대, 최소 거리 그리고 각 면의 중심점간의 거리는 모델 또는 입력 물체내에서 가장 큰 값으로 각각 정규화하여, 물체의 스케일 변화에 불변도록 개선 사용한다. 따라서 본 논문에서 사용하고 있는 특징값들은 모델 물체에 대하여 입력 물체가 3차원적 회전 변화 및 스케일 변화가 되더라도 매칭 과정에 유용하게 사용될 수 있다.

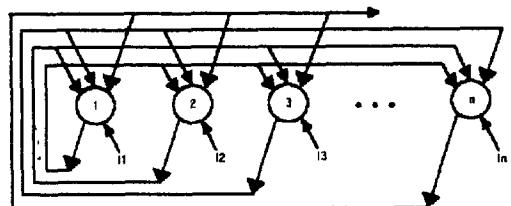


그림 3. Hopfield 신경회로망의 기본 구조

Fig. 3. Basic structure of the Hopfield neural network.

2. 매칭을 위한 Hopfield 신경회로망

Hopfield 신경회로망은 상호결합형 신경망 모델로서 각 뉴런들은 그림 3처럼 서로 완전 연결되어 있는 단층으로 구성되었으며 패턴 인식이나 최적화 문제를 병렬적으로 푸는데 많이 사용된다.^[5] 그리고 신경회로망의 뉴런의 개수 변화에 비교적 쉽게 적응되고 수령 속도가 빠르며 하드웨어 구성을 수행 속도에서의 장점들이 있다. 따라서 본 논문에서는 Hopfiled 신경회로망을 매칭과정의 최적화 문제에 적용하여 모델 특징값과 입력 특징값사이의 매칭 도구로써 사용하였다. 한편 물체 인식에 사용되는 Hopfield 신경회로망의 뉴런은 그림 4와 같은 $M \times N$ 2차원 배열로 구성된다.^[6,8] 이 때 각 행에는 입력 영상의 각 면특징들이, 각 열에는 모델 영상의 각 특징들이 할당된다. 따라서 각 뉴런

의 상태값은 각 노드의 매칭 정도를 표시하고, 신경회로망의 전체 에너지가 최소값으로 수렴될 때 입력 물체와 모델 물체가 서로 매칭되었다고 본다.

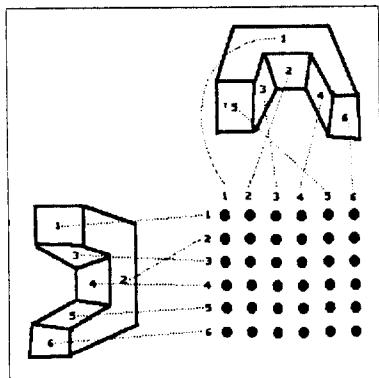


그림 4. 신경회로망의 2차원 배열 구조

Fig. 4. Two-dimensional structure of neural network.

본 논문에서와 같은 3차원 매칭 과정은

$$E = - \sum_{i=1}^N \sum_{k=1}^M \sum_{j=1}^N \sum_{l=1}^M C_{ikjl} V_{ik} V_{jl} + \sum_{i=1}^N \left(1 - \sum_{k=1}^M V_{ik} \right)^2 + \sum_{k=1}^M \left(1 - \sum_{i=1}^N V_{ik} \right)^2 \quad (3)$$

와 같이 전체에너지 E 를 최소화하는데에 기여하도록 뉴런의 출력을 정하게 되는 과정으로 정의할 수 있다.^[15,16] 여기서 V_{ik} 는 뉴우런의 출력으로 입력 영상의 i 번째 면과 모델 영상의 k 번째 면이 매칭되면 1로, 그렇지 않으면 0으로 근사화된다. C_{ikjl} 은 행 i , 열 k 의 뉴우런과 행 j , 열 l 의 뉴우런사이의 연결강도이다. 연결강도는

$$C_{ikjl} = \sum_n W_n \times F(x_n, y_n) \quad (4)$$

로부터 구해진다. 여기서 W_n 은 입력 영상과 모델에서 추출한 n 번째 특징값을 비교하는 불연속 함수(non-linear function)인 $F(x_n, y_n)$ 의 결과에 대한 가중치 (weight)이며, x_n 은 입력 영상의 n 번째 특징값, y_n 은 모델의 n 번째 특징값이다. 이때 가중치의 합은

$$\sum_n W_n = 1 \quad (5)$$

와 같이 1이여야 하며, 불연속함수 $F(x, y)$ 의 특성은

$$F(x, y) = \begin{cases} 1, & \text{if } |x-y| < \theta_1 \\ -1, & \text{otherwise} \end{cases} \quad (6)$$

와 같다.(그림 5 참조)

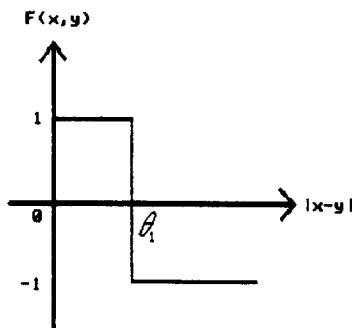


그림 5. 불연속함수 $F(x,y)$

Fig. 5. Nonlinear function $F(x,y)$.

한편, 식 (3)은 Hopfield 신경망의 에너지 함수의 형태로

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{k=1}^M \sum_{j=1}^N \sum_{l=1}^M T_{ikjl} V_{ik} V_{jl} - \sum_{i=1}^N \sum_{k=1}^M I_{ik} V_{ik} \quad (7)$$

와 같이 간단히 나타낼 수 있다. 여기서 I_{ik} 는 뉴런 N_{ik} 에서 자기 연결(self-connection)을 위한 가중치 계수이고, T_{ikjl} 은 뉴런 N_{ik} 와 N_{jl} 사이의 상호연결(interconnection)을 위한 가중치 계수로,

$$I_{ik} = 2 ; \quad T_{ikjl} = C_{ikjl} - \delta_{ij} - \delta_{lk} \quad (8)$$

와 같다. 여기서 δ_{xy} 는 $x=y$ 일 때만 1의 값을 가지고, 그 밖의 경우에는 0의 값을 가진다.

위와 같은 구조에서 뉴런 N_{ik} 의 상태 u_{ik} 에 대한 상태 방정식은

$$\frac{du_{ik}}{dt} = \sum_{j=1}^N \sum_{l=1}^M C_{ikjl} V_{jl} - \sum_{l=1}^M V_{jl} - \sum_{j=1}^N V_{jk} - \frac{u_{ik}}{\tau} + I_{ik} \quad (9)$$

와 같이 신경회로망이 반복될 때마다 그 차이값을 계산하므로써 구한다. 여기서 τ 는 식(7)로부터 유도된 상수이고, 각 뉴우런의 출력값은

$$V_{ik} = g(u_{ik}) = \left[1 + \exp\left(\frac{-2u_{ik}}{u_0}\right) \right]^{-1} \quad (10)$$

의 결과값이다. 여기서 u_0 는 시그모이드(sigmoid)함수의 기울기를 결정하는 계수이다.

신경회로망을 동작시키기 위해서 임의의 초기값을 결정해야 하며, 초기화된 모든 뉴우런의 V_{ik} 의 합은 이상적인 최종 출력값과 같아야 한다는 조건을 만족해야

한다. 그리고 2차원 배열 구조의 Hopfield 신경망은 입력 특징 개수나 모델 특징 개수 중 작은 수에 의존하여 활성 뉴런의 개수가 결정되므로 이상적인 최종 출력값의 합은

$$\sum_{i=1}^N \sum_{k=1}^M V_{ik} = N \quad (11)$$

과 같이 행과 열의 개수 중 작은 수 N 과 일치한다. 따라서 식(10)와 식(11)에서 u_{ik} 의 초기 조건은

$$u_{init} = -\frac{u_0}{2} \ln(N-1) \quad (12)$$

와 같이 유도된다. 그리고 각 뉴우런의 값이 불안정한 상태에 빠지는 것을 방지하기 위해서

$$u_{ik}^0 = u_{init} + \delta \quad (13)$$

와 같이 초기값에 일정한 범위내의 난수를 더한다. 여기서 난수 δ 는 $-0.1u_{init} \leq \delta \leq 0.1u_{init}$ 범위내의 값을 가진다. 초기값 $V_{ik}^0 = g(u_{ik}^0)$ 가 결정되면, 식(9)의 해를 구하여 새로운 u_{ik} 를 생성(update)하고 V_{ik} 를 결정한다. 미분방정식인 식(9)의 해를 구하는데에는

$$u_{ik}^{t+1} = u_{ik}^t + \left(\frac{25}{216} k_1 + \frac{1408}{2565} k_3 + \frac{2197}{4104} k_4 - \frac{1}{5} k_5 \right) \quad (14)$$

와 같은 6차 Runge-Kutta 방법^[17]을 사용하였다. 여기서

$$k_1 = h \cdot f(u_{ik}^t)$$

$$k_2 = h \cdot f(u_{ik}^t + \frac{1}{4} k_1)$$

$$k_3 = h \cdot f(u_{ik}^t + \frac{3}{32} k_1 + \frac{9}{32} k_2)$$

$$k_4 = h \cdot f(u_{ik}^t + \frac{1932}{2197} k_1 - \frac{7200}{2197} k_2 + \frac{7296}{2197} k_3)$$

$$k_5 = h \cdot f(u_{ik}^t + \frac{439}{216} k_1 - 8k_2 + \frac{3680}{513} k_3 - \frac{845}{4104} k_4)$$

$$k_6 = h \cdot f(u_{ik}^t - \frac{8}{27} k_1 + 2k_2 - \frac{3544}{2565} k_3 + \frac{1859}{4104} k_4 - \frac{11}{40} k_5)$$

이며, $f(\cdot)$ 는 식(10)의 우항 계산값이고, h 는 상수이다. 위와같은 신경회로망은 반복 횟수만큼 u_{ik} 가 생성되면 서 뉴우런의 출력값 V_{ik} 가 계산된다. 최종 출력값 V_{ik} 는 입력 영상의 i 번째 면과 모델의 k 번째 면이 매칭되었을 때 1에 근사한 값, 그렇지 않을 경우 0에 근사한 값을 출력한다. 근사값으로 표현된 최종 출력값은

$$V_{ik} = \begin{cases} 1, & \text{if } (V_{ik}) > \theta_2 \\ 0, & \text{otherwise} \end{cases} \quad (15)$$

와 같이 문턱치 처리를 한다. 여기서 θ_2 는 최종 출력값을 위한 문턱치이다. 뉴우런의 출력값이 문턱치 이상이면 입력 영상의 면과 모델의 면이 매칭이 된 것으로 간주하고, 문턱치 이하이면 매칭이 안된 것으로 간주한다. 이렇게 문턱치 처리를 하므로써 뉴우런의 최종 출력값이 매칭된 면은 1, 그렇지 않은 경우는 0으로 표현된다.

3. Hopfield 신경회로망을 이용한 매칭

앞서 언급되었듯이 본 논문에서 사용되는 Hopfield 신경회로망의 뉴우런은 2차원 배열로 구성된다. 한편 2차원 구조의 Hopfield 신경회로망을 이용한 매칭 과정은 제약 조건의 만족 과정(constraint satisfaction process)으로 생각할 수 있다. 따라서 모델 특징들은 입력 특징들에 대한 제약 조건으로서 이해될 수 있고, 두 특징값들의 조건에 따라 각 뉴런들의 상태값 변화가 양(+)으로 혹은 음(-)으로 영향을 받는다. 결국 2차원 신경회로망 구조에서 각 행과 열에 해당하는 면특징들이 할당되면 모든 뉴우런간의 연결 강도를 구해야 되며, 연결 강도는

$$C_{ijkl} = W_1 \times F(IA_i, MA_k) + W_2 \times F(IL_i, MA_l) + W_3 \times F(IL_i, ML_k) + W_4 \times F(IL_j, ML_l) + W_5 \times F(IS_i, MS_k) + W_6 \times F(IS_i, MS_l) + W_7 \times F(d_{ijl}, d_{MKMl}) + W_8 \times F(a_{iil}, a_{MKMl}) \quad (16)$$

와 같이 추출된 물체의 특징을 기반으로 계산된다. 여기서

$$IA_x = \text{입력 영상 } x\text{번째 면의 면적}$$

$$MA_x = \text{모델 } x\text{번째 면의 면적}$$

$$IL_x = \text{입력 영상 } x\text{번째 면의 정점 사이의 최대 길이}$$

$$ML_x = \text{모델 } x\text{번째 면의 정점 사이의 최대 길이}$$

$$IS_x = \text{입력 영상 } x\text{번째 면의 정점 사이의 최소 길이}$$

$$MS_x = \text{모델 } x\text{번째 면의 정점 사이의 최소 길이}$$

$$d_{ijl} = \text{입력 영상 } i\text{번째 면과 } j\text{번째 면의 중심점 거리}$$

$$d_{MKMl} = \text{모델 } k\text{번째 면과 } l\text{번째 면의 중심점 거리}$$

$$a_{iil} = \text{입력 영상 } i\text{번째 면과 } j\text{번째 면의 각도}$$

$$a_{MKMl} = \text{모델 } k\text{번째 면과 } l\text{번째 면의 각도}$$

이다. 식 (16)에서 구해진 연결 강도를 상태 방정식(식 (9))에 적용시켜 새로운 u_{ik} 를 개신하고, 뉴런의 출력식(식 (10))에 의해 새로운 출력값 V_{ik} 를 계산한다. 이와 같은 동작을 반복 학습하므로써 신경회로망은 최적해를 구한다. 만약 입력 영상의 i 번째 면과 모델의 j 번째 면이 이상적으로 매칭이 일어날 경우 행 i 번째, 열 j 번째 뉴우런이 활성 뉴우런(active neuron)이 되고, 반복 학습에 의한 최종 출력은 식 (15)과 같이 문턱치 처리를 하면 결국 1이 된다. 그리고 이를 제외한 행 i 와 열 j 의 모든 뉴우런은 0이 된다.(그림 6 참조)

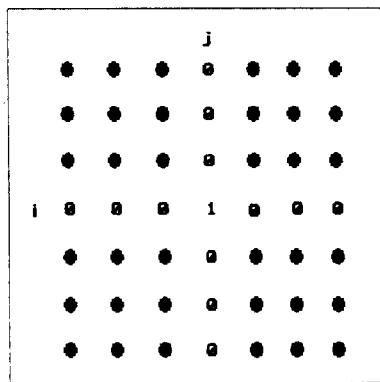


그림 6. 매칭이 일어난 최종 결과의 예

Fig. 6. Example of final matching result.

따라서, 이상적인 매칭 결과는 입력 영상의 분할된 면의 개수와 모델의 분할된 면의 개수 중 작은 수만큼만 활성 뉴우런이여야 하며, 각 행과 열의 활성 뉴우런은 단 하나여야 한다. 최종 결과를 얻게 되면 입력 영상과 모델간의 매칭 정도를 수치로 나타내는 유사도(similarity)를 구한다. 유사도를 구하는 방법은 여러 가지가 있을 수 있으나 본 논문에서는 먼저 임의의 변수를 0으로 초기화하고, 첫번째 행에서 최종 출력값이 1인 뉴우런의 수를 계수한다. 1인 뉴우런이 하나이면 변수에 1을 더하고, 하나이상 n 개이면 $1/n$ 을 더한다. 만약 1인 뉴우런이 없으면 무시하고 다음 행으로 넘어간다. 모든 행에 대해서 위와 같은 동작을 반복하여 누적된 변수값을 보관한다. 열에 대해서도 행과 같은 방법을 수행하여, 행과 열의 각각의 변수값을 비교하여 작은 값을 선택한다. 마지막으로 선택된 변수를 행과 열의 개수중 적은 수인 N 으로 나누고 여기서 얻어진 값이 유사도가 된다. 이상적인 매칭이 일어났을 경우 입력 영상의 한 면은 해당되는 모델의 한 면에만 매칭

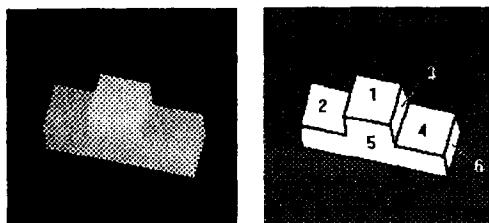
이 일어나야 한다. 이와 같이 입력 영상의 모든 면이 이상적으로 매칭되었을 경우 유사도는 1이 된다. 그리고 입력 영상의 면들 중 모델의 면과 매칭에 실패한 수가 많을 수록 유사도는 1보다 적어지게 된다. 그러므로 유사도가 1에 가까울수록 두 물체는 매칭율이 높은 것을 의미한다.

IV. 실험 및 검토

본 실험은 IBM PC 486-DX system을 사용하였으며, 실험 대상 영상은 기하학적 변형 즉, 3차원적 회전과 크기 변화가 일어난 합성 거리 영상을 사용하였다. 합성 거리 영상은 컴퓨터 그래픽스에서 사용되는 ray tracing^[18]을 이용하여 제작하였으며, 영상 크기는 256×256 , 화소값은 실수값을 사용하였다. 그리고 신경회로망의 실제 구축을 위하여 시그모이드 함수의 기울기를 결정하는 w_0 를 0.002로, 상태방정식에서의 상수 τ 는 1로, 그리고 Runge-Kutta 근사화를 위한 상수 h 는 0.0001로 하였다. 마지막으로 뉴런간의 연결 강도를 위한 내부 가중치는 각각 $W_1=W_2=0.1$, $W_3=W_4=0.1$, $W_5=W_6=0.1$, $W_7=0.2$, $W_8=0.2$ 를 주었다. 위와 같은 가중치값은 III-1절에서 고찰하였듯이 3차원 관계 특징이 관찰 방향의 변화와 중첩에 의한 영향을 받지 않는 가장 강건한 특징이기 때문에 상대적으로 가중치를 형상 특징들에 비하여 2배로 한 결과이다. 또한 특징값 비교함수 $F(x,y)$ 의 문턱치 θ_1 은 0.1을, 최종 출력값에 주어진 문턱치 θ_2 는 0.9로 설정하였다.

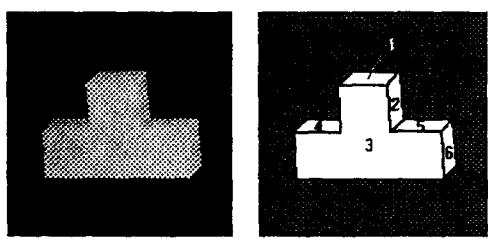
그림 7-(a),(c)는 모델 물체에 대하여 3차원 회전된 물체가 입력될 때 제안된 방식의 매칭 과정 및 결과를 보이기 위하여 제작된 입력 거리 영상과 모델 거리 영상을 보인다. 그림 7-(b),(d)는 각각 입력 거리 영상과 모델 거리 영상의 면분할된 영상이다. 그림 8-(a)는 2차원적으로 배열된 각 뉴우런들의 반복학습된 최종 결과값이다. 여기서 행은 입력 영상의 각 면을, 열은 모델의 각 면이 할당되었다. 입력 물체의 면과 모델의 면이 매칭되면 높은 활성값을 가지고 문턱치 처리에 의해 1의 값을 나타내고, 그렇지 않은 경우 0으로 출력된 것을 볼 수 있다. 그림 8-(b)는 입력 물체와 모델 물체의 각 면에 대한 최종 매칭 결과를 보인다. 위 매칭 결과에서 모델 물체와 입력 물체의 각 면이 정확히 매칭된 것을 알 수 있다. 그리고 입력 물체의 모든 면과 모델 물체의 모든 면이 매칭에 성공되어 유사도는 1이

되었다.



(a)

(b)



(c)

(d)

그림 7. (a) 입력 거리 영상 (b) 분할된 입력 영상
 (c) 모델 거리 영상 (d) 분할된 모델 영상

Fig. 7. (a) Input range image (b) Segmented input image.

(c) Model range image (d) Segmented model image

Final Means	Value					
0.000000	0.300000	0.000000	0.000000	0.300000	0.000000	0.000000
0.000000	0.300000	0.000000	0.000000	0.300000	0.000000	0.000000
0.000000	1.000000	0.000000	0.000000	0.000000	0.000000	0.000000
0.000000	0.300000	0.300000	0.000000	0.300000	0.000000	0.000000
0.000000	0.300000	0.000000	0.000000	0.300000	0.000000	0.000000
0.000000	0.300000	0.000000	0.000000	0.300000	0.000000	0.000000

Input-Model		
1	-	1
2	-	4
3	-	2
4	-	5
5	-	3
6	-	6

그림 8. (a)뉴우런의 결과값 (b)매칭 결과 ($S=1$)
 Fig. 8. (a) Final neuron matrix (b) Matching result ($S=1$)

그림 9은 제안된 알고리듬의 물체 분류 및 인식 성능을 검증하기 위한 모델 거리 영상들이다. 모델들은 평면들로 구성되어 있으며, 여러가지 모양을 지닌다. 그림 10은 면분할된 모델 영상을 보인다. 그림 11은 모델 물체에 대해 3차원 회전이 되어진 입력 거리 영상들이다. 그림 12은 입력 거리 영상의 면분할 영상이다. 표 2는 입력 물체와 모델 물체의 매칭 결과에 대한 유사도를 나타낸다. 위 유사도 결과를 보면, 모델 물체에 대하여 3차원 회전된 입력 물체라도 높은 유사도로

서 매칭되고 있음을 확인할 수 있다. 다만 그림 11-(d)의 입력 물체의 경우 0.25의 낮은 유사도로 그림 9-(d)의 모델 물체와 매칭되고 있는데 그 이유는 모델 영상에서는 보이지 않던 뒷면이 3차원 회전 변화에 의해 입력 영상에 포함되어 결과적으로 매칭되어야 할 면이 3개로 감소했기 때문이다.

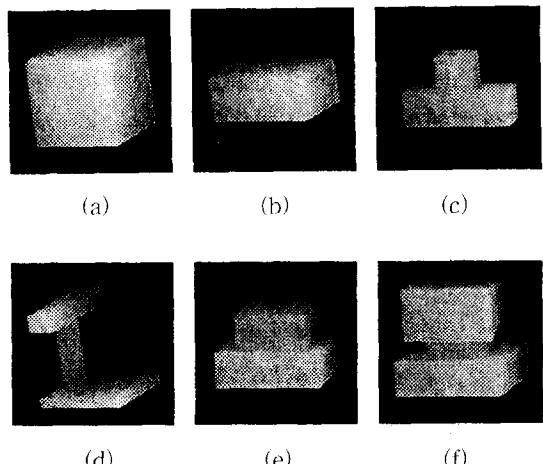


그림 9 모델 거리 연산

Eig. 9 Model range images

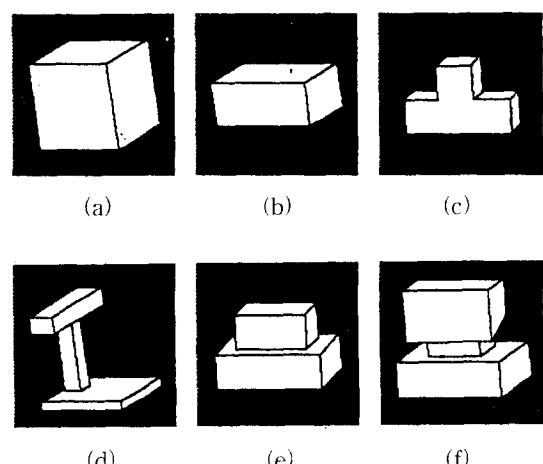


그림 10 분할된 모델 영상

Fig. 10 Segmented model images.

이 경우 이상적인 매칭이 일어나더라도 유사도는 0.375로 제한된다. 따라서 그림 11-(d)의 입력 물체에 대한 매칭은 비록 다른 모델들과의 유사도 중 가장 높은 값으로 그림 9-(d)의 모델 물체가 선택되지만 낮은 유사도이기 때문에 인식에는 실패하게 된다. 그리고 그림 11-(f)의 입력 물체의 경우, 그림 9-(f)의 모델 물

체와 유사도가 0.875로써 하나의 면을 매칭시키지 못하고 있는데 이는 물체의 회전에 의해 한 면이 대부분 가려졌기 때문에 추출된 특징들만으로는 가리워진 면을 매칭시킬 수 없었기 때문이다.

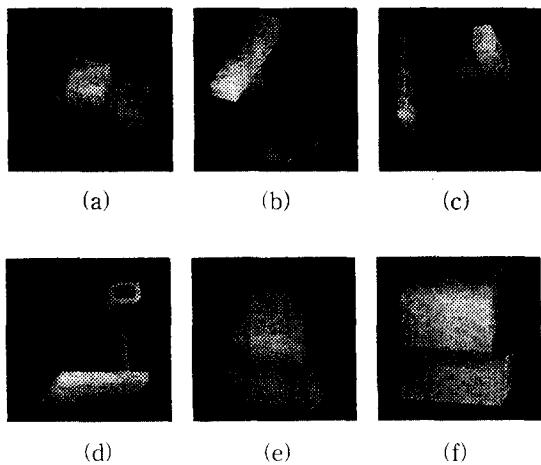


그림 11. 입력 거리 영상
Fig. 11. Input range images.

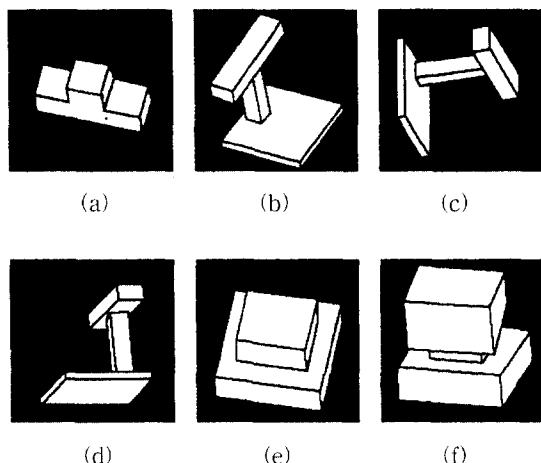


그림 12. 분할된 입력 영상
Fig. 12. Segmented input images.

다음은 기하학적인 변형 중 크기 변화와 회전 변화가 동시에 발생한 경우에 대한 인식 실험을 위한 입력 영상과 매칭 결과이다. 그림 13은 모델 영상의 분할 결과이다. 그림 14는 그림 13의 모델 물체에 대하여 크기가 반으로 줄어들고 동시에 3차원 회전이 있는 입력 물체에 대한 분할 결과이다. 표 3의 실험 결과에서 크기 변화와 회전이 있는 입력 영상에 대해서도 정확하게 인식하고 있는 것을 볼 수 있다.

표 2. 매칭 결과에 대한 유사도 (S)
Table 2. Similarities(S) on matching result.

model input \	1	2	3	4	5	6
1	0	0	1	0	0	0.167
2	0	0	0	1	0	0
3	0	0	0	1	0	0
4	0	0	0.125	0.25	0	0
5	0	0	0	0	1	0
6	0	0	0.25	0	0	0.875

위 결과는 추출된 특징값들을 정규화하여 스케일 변화에도 무관토록 생신 사용하였기 때문이다.

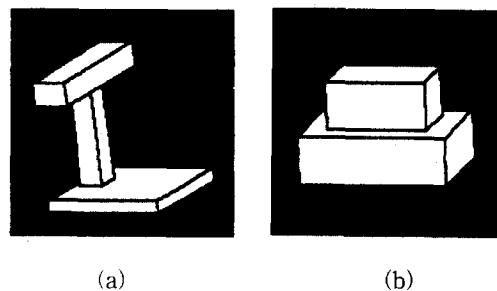


그림 13. 분할된 모델 영상
Fig. 13. Segmented model images.

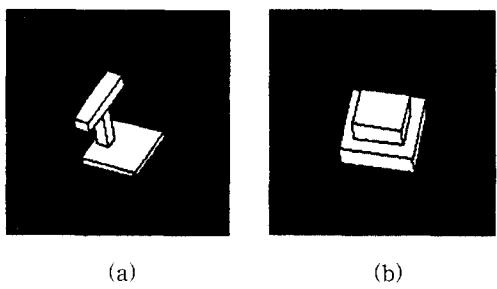


그림 14. 분할된 입력 영상
Fig. 14. Segmented input images.

표 3. 매칭 결과에 대한 유사도 (S)
Table 3. Similarities(S) on matching result.

model input \	1	2
1	1.0	0
2	0	1.0

다음은 유사한 물체들에 대한 인식 실험을 위한 영

상들과 매칭 결과이다. 실험에 사용된 물체들은 전기 스탠드 모양으로 전등갓 부분의 길이만 다르고 기둥과 받침대 부분은 모두 동일한 경우이다. 그림 15-(a)의 모델 물체에서 전등갓 부분의 길이에 비하여 그림 15-(b)의 모델 물체에서 전등갓 부분의 길이는 1.5배, 그림 15-(c)의 모델 물체에서 전등갓 부분의 길이는 0.5배이다. 그리고 입력 물체들은 모두 모델 물체에 대해서 회전 변화된 모습이다. 표 4의 매칭 결과를 보면, 모든 물체의 기둥과 받침대 부분이 같기 때문에 입력 물체와 모델 물체와의 유사도가 모두 0.5이상인 것을 볼 수 있다. 하지만 전등갓 부분이 같은 동일 물체에 대하여는 완전한 매칭이 이루어졌다. 여기서 서로 다른 스탠드간의 매칭에서는 전등갓에 가리워진 기둥면의 일부가 결국 매칭에 실패하지만 같은 모양의 스탠드에서는 전등갓 부분에서 매칭에 성공되어 상호 작용하는 뉴런의 역할에 의해 기둥면에서도 높은 활성값을 가지게되고 결국 상호 매칭되는 것을 알 수 있다.

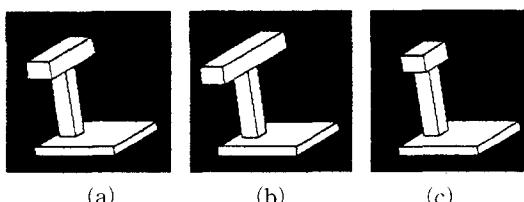


그림 15. 분할된 모델 영상
Fig. 15. Segmented model images.

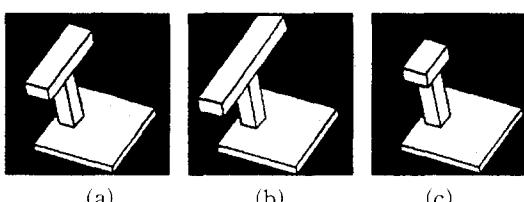


그림 16. 분할된 입력 영상
Fig. 16. Segmented input images.

표 4. 매칭 결과에 대한 유사도 (S)
Table 4. Similarities(S) on matching result.

model input \ model	1	2	3
1	1.0	0.5	0.5
2	0.625	1.0	0.5
3	0.5	0.5	1.0

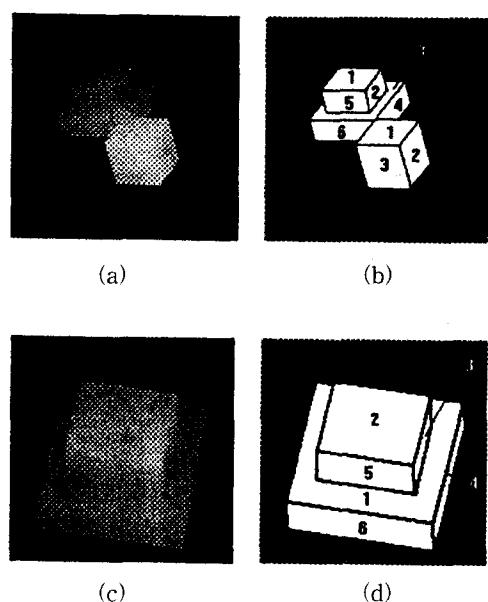


그림 17. (a) 중첩이 있는 입력 거리 영상 (b) 분할된 입력 영상

Fig. 17. (a) Occluded input range image (b) Segmented input image
(c) Model range image (d) Segmented model image

Final Neuron Value	0.102008	0.359999	0.000348	0.000593	0.000735	0.000804
0.000133	0.000125	0.959553	0.000112	0.730259	0.001258	
0.999711	0.001004	0.000745	0.000452	0.000569	0.166922	
0.999806	0.130134	0.0005128	0.999973	0.000866	0.037822	
0.003218	0.000075	0.000042	0.002633	0.999978	0.000104	
0.000071	0.035095	0.000121	0.017735	0.000333	0.999978	

(a)

Final Neuron Value	0.000000	0.000000	0.000000	0.000000	0.000000
0.000000	0.000000	1.000000	0.000000	0.000000	0.000000
1.000000	0.000000	0.000000	0.000000	0.000000	0.000000
0.000000	0.000000	0.000000	1.000000	0.000000	0.000000
0.000000	0.000000	0.000000	0.000000	1.000000	0.000000
0.000000	0.000000	0.000000	0.000000	0.000000	1.000000

(b)

그림 18. (a) 최종 뉴우런 결과값 (b) 문턱치 처리한 뉴우런 결과값

Fig. 18. (a) Final neuron matrix (b) Thresh holded neuron matrix

다음은 인식 대상 물체가 다른 물체에 의해 일부 가려짐이 발생한 경우에 대한 인식 실험이다. 그림 17-(a),(b)는 앞쪽 정육면체에 의해 인식하고자 하는 뒷쪽

물체가 일부 가려진 입력 거리 영상과 면분할된 영상이다. 일부 가려진 대상 물체는 그림 17-(c),(d)와 같은 모델 물체에 대하여 크기는 반으로 줄고 3차원 회전이 되어있다. 위와 같은 경우 가리워진 면의 형상 특징들은 손상을 입지만, 관계 특징들은 가려짐에 대하여 강건하기 때문에 그림 18-(a),(b)와 같이 모델과 정확하게 매칭을 시키고 있다. 하지만 가려짐 정도가 심하여 형상 특징들뿐 아니라 관계 특징들까지 손상을 입는 경우에는 본 논문에서 제안하는 방법으로는 정확하게 매칭시킬 수 없다.

V. 결 론

3차원 물체 인식은 컴퓨터 시각의 궁극적인 목적이다. 그러나 3차원 물체 인식은 보는 방향에 따라 물체의 형상이 다양하게 변화하는 난점을 내포하고 있다. 따라서 본 논문에서는 3차원 거리 영상으로부터 3차원 불변 특징들을 추출하고 Hopfield 신경회로망으로 모델 특징들과 비교 평가하므로써 시점 변화에 따른 물체의 기하학적 변형에 강건한 모델 기반형 3차원 물체 인식 방법을 제안하였다. 본 논문에서 사용하는 Hopfield 신경회로망은 2차원 배열 구조의 뉴우런들로 구성되며 배열의 행은 입력 영상의 면특징이, 열은 모델의 면특징이 표현된다. 제안하는 방법은 물체를 보는 방향의 변화에 의해 일어나는 기하학적인 변형, 즉 3차원 회전, 이동, 스케일 등의 변화에 강건하게 입력 영상 내의 물체를 인식한다. 이는 3차원적 회전 변화에 따르는 특징 변화량을 최소화하기 위하여 3차원 형상 특징들과 3차원 관계 특징들을 선별 사용하고, 특히 위 특징들을 정규화하여 크기 변화에도 불변도록 하였기 때문이다. 그리고 2차원 배열 구조를 가지는 Hopfield 신경회로망의 반복 학습 기능에 의하여 각 모델 특징들과 비교하므로써, 일부 변형과 가려짐이 있는 물체에 대해서도 만족할 만한 매칭 결과를 얻을 수 있었다. 모의 실험에서는 3차원 회전 변화가 발생한 여러 가지의 입력 영상들에 대한 물체 분류 실험, 3차원 회전과 크기 변화가 발생한 입력 물체에 대한 매칭 실험, 서로 유사한 입력 물체들에 대한 물체 분류 및 매칭 실험, 마지막으로 일부 가려짐이 있는 입력 물체에 대한 매칭 실험을 통하여 제안하는 인식 방법의 성능을 확인할 수 있었다. 따라서, 본 논문에서 제안된 신경회로망을 이용한 3차원 물체 인식 방법은 시점 변화등에 의

한 3차원 기하 변형이 있는 경우의 인식에 효과적으로 적용되리라 사료된다. 앞으로, 보다 강건한 불변 특징들의 선별, 다중 구조의 신경회로망 그리고 다중 물체에 의한 가려짐 현상들에 대한 연구가 필요하다.

참 고 문 헌

- [1] Y. Shirai, *Three-dimensional computer vision*, Springer-verlag, Berlin, Heidelberg, 1987.
- [2] P.J. Besl and R.C. Jain, "Three-dimensional object recognition," *ACM Computing Surveys*, vol. 17, no. 1, pp. 75-145, Mar. 1985.
- [3] 박 종훈, 최 종수, "면 법선 영상 기반형 3차원 물체 인식에서의 새로운 매칭 기법," *대한 전자 공학회 논문지*, 제 30권, B편, 제 7호, pp. 695-705, 1993년 7월
- [4] S.J. Yeh, H. Stark, and M. I. Sezan, "Hopfield-type neural networks," in *Digital Image Restoration*, A. K. Katsaggelos, ed. Berlin, Germany : Springer - Verlag, vol. 23, ch. 3, 1991.
- [5] 김 대수, "신경망 이론과 응용 (I)," *하이테크 정보사*, 1992
- [6] N.M. Nasrabadi and W. Li, "Object recognition by a Hopfield neural network," *IEEE Trans. on Systems, Man, and Cybernetics*, vol. 21, no. 6, pp. 1523-1535, Nov./Dec. 1991.
- [7] S. S. Young, P. D. Scott, and N. M. Nasrabadi, "Object recognition using multi-layer hopfield neural network," *CVPR '94*, vol. 1, pp. 417-422, Jun. 1994.
- [8] W.C. Lin, F.Y. Liao, C.K. Tsao, and T. Lingutla, "A hierarchical multiple-view approach to three-dimensional object recognition," *IEEE Trans. on Neural Networks*, vol. 2, no. 1, pp. 84-92, Jan. 1991.
- [9] H. Zha, H. Nakamura, and T. Nagata, "A Hopfield-style matching algorithm for recognizing 3-D curved objects," *ACCV '93*, Osaka, Japan, pp. 248-251, Nov. 1993.
- [10] M. Oshima and Y. Shirai, "Object recognition using three-dimensional informa-

- tion," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 5, no. 4, pp. 353-361, Jul. 1983.
- [11] T.J. Fan, G. Medion, and R. Nevatia, "Recognizing 3-D objects using surface descriptions," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 11, no. 11, pp. 1140-1157, Nov. 1989.
- [12] C.H. Chen and A.C. Kak, "A robot vision system for recognizing 3-D objects in low-order polynomial time," *IEEE Trans. System, Man, and Cybernetics*, vol. 19, no. 6, pp. 1535-1563, Nov./Dec. 1989.
- [13] T.Nagata, H.B.Zha, "Recognizing and Locating a Known Object from Multiple Images," *IEEE Trans. Robotics and Automation*, vol. 7, pp. 434-448, 1991.
- [14] 함 영국, 박 래홍, "Hidden Markov Model을 이용한 3차원 물체 인식," 제 7회 영상처리 및 이해에 관한 워크샵 발표 논문집, pp. 77-82, 1995년 2월
- [15] J. A. Freeman, *Simulation Neural Networks*, Addison Wesley, Reading, MA, 1994.
- [16] B. Kosko, *Neural Networks for Signal Processing*, Prentice-Hall Inc., Englewood Cliffs, N. J., 1992.
- [17] C. F. Gerald and P. O. Wheatley, *Applied Numerical Analysis*, Addison-Wesley, Reading, MA, 1989.
- [18] J.D. Foley, A.V. Dam, S.K. Feiner, and J. F. Hughes, *Computer graphics*, Addison-Wesley Publishing Company, Nov. 1992

저자 소개



鄭宇翔(正會員)

1969年 7月 6日生. 1993年 2月 중앙대학교 전자공학과 졸업(공학사), 1995年 8月 중앙대학교 대학원 전자공학과 졸업(공학석사). 1995年 8月 ~ 현재 현대 전자 멀티미디어 연구소 근무중. 주관심 분야는 패턴 인식, 3차원 비전, 이미지 코딩 등임.



宋浩根(正會員)

1965年 1月 13日生. 1991年 2月 중앙대학교 전자공학과 졸업(공학사). 1993年 2月 중앙대학교 대학원 전자공학과 졸업(공학석사). 1993年 3月 ~ 현재 중앙대학교 대학원 전자공학과 박사과정 재학 중. 1996年 3月 ~ 현재 한서대학교 전자계산학과 전임강사. 주관심 분야는 영상 처리, 영상 분할, 패턴 인식, 3차원 비전 등임.



金泰銀(正會員)

1964年 1月 29日生. 1989年 8月 중앙대학교 전기공학과 졸업(공학사). 1992年 2月 중앙대학교 대학원 전자공학과 졸업(공학석사). 1993年 9月 ~ 현재 중앙대학교 대학원 박사과정 재학중. 주관심 분야는 머신비전, 컴퓨터비전, 신경회로망, 계측제어신호처리, 패턴인식등임.

崔宗秀(正會員) 第 28 卷 B 編 第 5 號 參照

현재 중앙대학교 전자공학과 교수