

論文98-35C-1-7

3차원 물체 인식을 위한 전략적 매칭 알고리즘

(Strategical Matching Algorithm for 3-D Object Recognition)

李商根*, 李瑄鎬*, 宋浩根*, 崔宗秀*

(Lee Sang Keun, Lee Sun Ho, Song Ho Keun, and Choi Jong Soo)

요 약

본 논문에서는 위치나 방향에 관계없이 3차원(3-D) 물체 인식을 위한 전략적 매칭 알고리즘을 제안한다. 그리고 서로간 특징 비교 방법은 Hopfield 신경망(Neural Network)을 이용한다. 제안하는 방법에서는 입력 되는 모든 물체와 모델 물체를 단일 좌표계에서 면 조각들의 집합으로 표현하고, 각 면 조각들은 다시 면 특징들의 집합으로 기술한다. 또한 각 특징들은 비교시 전략적 상수로 갱신되어 3차원 이동, 회전, 스케일 변화에도 강건하게 한다. 컴퓨터 모의실험을 통하여, 합성 거리 영상과 실제 거리 영상에 대해 3차원 이동, 회전 및 스케일 변화에 따른 입력 분류 실험과 매칭 실험을 하고, 결과에 따른 유사도를 통하여 제안하는 방법의 우수함을 확인하게 된다.

Abstract

This paper presents a new matching algorithm by Hopfield Neural Network for 3-D object recognition. In the proposed method, a model object is represented by a set of polygons in a single coordinate. And each polygon is described by a set of features; feature attributes. In case of 3-D object recognition, the scale and poses of the object are important factors. So we propose a strategy for 3-D object recognition independently to its scale and poses. In this strategy, the respective features of the input or the model objects are changed to the strategical constants when they are compared with one another. Finally, we show that the proposed method has a robustness through the results of experiments which included the classification of the input objects and the matching sequence to its 3-D rotation and scale.

I. 서 론

3차원 물체의 인식이 2차원 물체의 인식과는 달리, 보는 시각에 따라 물체의 형상이 다양하게 변화하게 되므로 그만큼 어려움을 내포하고 있다. 따라서 3차원 (3-D) 물체 인식을 위해서는 물체의 3차원 형상에 대한 충분한 지식 표현과 그에 따른 알맞은 인식 기법이

필요하다.^[1] 근래에는 기하학적인 변형에 따른 강건한 인식을 위하여 신경회로망을 적용하는 연구가 활발하다. 효과적인 인식을 위해서는 입력 영상과 모델 특징간의 비교 매칭을 가능한 한 빠른 시간에 효율적으로 해결할 수 있는 기법이 요구된다.^[2] Hopfield 신경회로망은 여타 신경회로망에 비하여 수렴 속도가 빠르며 하드웨어 수행이 매우 빠른 장점이 있다. 또한 영상처리나 패턴 인식 분야에서는 입력 영상과 특징 기술 형태에 따라 입력 및 출력 노드의 구성이 다양하게 변화하기 때문에, 신경회로망의 뉴런(neuron) 개수 변화에 대해 비교적 쉽게 적응할 수 있는 특징이

* 正會員, 中央大學校 電子工學科

(Department of Electronic Engineering, Chung Ang University)

接受日字:1997年9月19日, 수정완료일:1997年12月31日

있다.^[3] 기존의 유사 연구를 살펴보면, Nasrabadi et al^[4] 와 Young et al.^[5]은 2-D 물체를 인식하기 위해서 Hopfield 신경회로망을 이용하였다. 그러나, 2-D 물체 인식에 한정하였기 때문에 시점 변화에 따른 입력 형상 변화에는 적용할 수 없다. 3-D 물체 인식으로는 Lin et al.^[6]이 한 물체에 대해 다중 관찰 방향(multi-view)에서 얻어진 여러 개의 2-D 영상을 모델화하고 Hopfield 신경회로망을 이용한 인식방법을 제안하였지만 인식 과정에서 여러 개의 모델과 비교해야 하는 번거로움을 감수해야만 했다. 또한 정우상^[7] 등은 상기 신경회로망을 이용하여 다각형의 3차원 물체 인식을 행하였는데, 대상 물체의 불변 특징을 형상 특징과 관계 특징으로 구분하고, 특징 비교 시 영상에서 보여지는 가장 큰 특징량을 기준으로 정규화시켜 크기 변화에 불변토록 하였다. 그러나, 회전으로 인한 시점이동시, 정규화의 기준면이 손실을 입으면, 매칭에 어려움을 겪게 되는 치명적인 단점이 있다. 따라서 시점이 이동하더라도 기준이 되는 특징량이 손실을 입지 않는 전략이 필요하다.^[8] 이에 이상근^[8] 등은 다면체를 대상으로 모델 물체를 모든 면에 대해 특징을 추출하고, 입력 영상과 비교 시, 각 면의 추출 특징에 대해 서로간의 상대적 비율을 적용하는 전략으로 단점을 극복하였다. 한편, 물체를 구성하는 면이 증가할수록 기하급수적으로 증가하는 처리 데이터로 인한 인식속도 저하에 대한 문제점을 안고 있다. 따라서, - 본 논문에서는 모델물체를 단일 좌표계에서 전체 면 조각들의 집합으로 표현하고, 각 면들은 다시 3-D 불변 특징들로 기술한다. 이때 각 특징들은 3-D 회전에 강건한 특징만을 선별한다. 그리고, 매칭과정에서는 2-D 배열 구조의 Hopfield 신경회로망을 이용한 전략적 알고리즘을 통하여 전략적 상수로 변환하여 비교, 평가함으로써 3차원 이동 및 크기 변화에 대해 기존의 방식보다 시점 변화에 따른 물체의 기하학적 변형에 강건하고 수렴 속도 면에서 향상된 3차원 물체 인식을 위한 전략적 알고리즘을 제안한다.

II. 전략적 상수에 의한 3차원 물체 인식

1. 물체 특징 추출(Object Feature Extraction)

본 논문에서는 논문 [9] 에서 처럼 모든 모델 물체와 입력 물체가 이상적으로 분할되었다고 가정한다. 특히, 실제 거리 영상은 분할 영상의 결과에 따라 인

식의 성패가 좌우되므로 이상적인 분할에 가깝다고 판단될 때까지 분할 과정을 되풀이하였다. 또한, 모델물체 M 을 $M=(P_{m1}, P_{m2}, \dots, P_{mM})$ 과 같이 물체를 구성하는 전체 면 조각들의 집합으로 표현하고, 입력물체 I 는 가시면 조각들(Visible Patches)에 대하여 $I=(P_{i1}, P_{i2}, \dots, P_{iN})$ 과 같이 표현하였다. 각 면 조각들은 다시 면 특징들(Patch Attributes)의 집합으로 기술하였다. 그리고 본 논문에서는 각 면 조각들은 관찰시점에 따른 형상변화를 포함한다는 가정을 설정하고 다음과 같은 면 특징들을 사용하였다. 첫째, 3-D 형상 특징으로서 분할된 각 면의 3-D 면적이다. 각 면의 한 화소를 하나의 조각으로 가정하여 각 조각의 3-D 면적을 구한 후, 각 면에 속하는 조각들의 면적의 합을 면의 면적으로 사용하였다. 둘째 3-D 형상의 구체적 특징으로 각 면의 정점 개수를 사용한다. 셋째, 3-D 관계 특징인 각 면 중심점간의 거리를 구하여 사용한다. 넷째, 3-D 관계 특징인 각 면간의 접합 각도를 계산하여 사용한다. 위 네 가지 특징들은 모두 3-D 관찰 시점 변화에 강건한 특성을 지니므로 물체를 구성하는 각 면의 형상과 각 면간의 관계를 구별할 수 있다. 가려짐 현상에 다소 약점을 보이는 꼭지점의 개수를 특징 추출에 사용한 이유는 형상특징을 가지는 면적이 다음에 설명될 전략적 상수화에 의해 형상특징이라는 특성이 미약해 지는 것을 어느 정도 보완하기 위해서이며, 매칭 비교시 가중치를 작게 하였다.

2. 전략적 상수(Stratigical Constant)

1에서 도입한 특징들은 시점 변화에 따른 스케일 변화에는 적용하지 못한다. 따라서 본 논문에서는 각 특징들의 비교 시, 전략적 상수를 사용하여 물체의 회전 및 스케일 변화에도 불변토록 한다. 또한 제안하는 새로운 전략을 위해 각 면을 구성하는 3-D 형상 특징 중 정점간의 최장 3-D 길이를 계산하여 제안하는 전략을 위해 사용한다. 알고리즘에서 쓰이는 특징기술과 전략을 살펴보면 첫째, 면 면적을 구한다. 앞에서 언급한 것과 같이 한 화소의 크기는

$$area_i = \frac{\sqrt{(x_{i+1}-x_i)^2 + (y_{i+1}-y_i)^2 + (z_{i+1}-z_i)^2}}{\sqrt{(x_{i+2}-x_i)^2 + (y_{i+2}-y_i)^2 + (z_{i+2}-z_i)^2}} \times \sin 6 \tag{1}$$

에 의해 구하고, 면의 면적은 면을 이루는 화소의 합

$$Area_i = \sum_{j=0}^{n-1} area_j \tag{2}$$

이다. 여기서 N 은 한 면을 이루는 화소의 개수이다. 또한, 시점에 무관한 전략적 상수는 그림 1.에서와 같이 (2)식을 한 면의 가장 긴 선분을 한 변으로 하는 정사각형 면적(S_i)으로 나누어

$$AreaConst_i = \frac{Area_i}{S_i}, \quad S_i = L_i^2 \quad (3)$$

을 얻게 된다. 여기서 L_i 는 한 면의 가장 긴 선분의 길이이다.




그림 1. 면의 면적을 구하기 위한 조각(화소)과 제안하는 전략

Fig. 1. One pixel for the area of ith polygon and Sum up to area.

둘째, 각 면의 중심점간 3차원 거리는

$$d_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2 + (z_i - z_j)^2} \quad (4)$$

이며, 그림 2로 표현된다. 제안하는 전략을 위하여, 면간 거리에 대한 전략적 상수 D_i, D_j 를 다음과 같이 정의한다. 즉, D_i 는 첫 번째 첨자가 속하는 i 면의 선분 중 가장 긴 길이로 나눈 값

$$D_i = \frac{d_{ij}}{L_i} \quad (5)$$

이다. 또한, j 면에 대해 D_j 는

$$D_j = \frac{d_{ji}}{L_j}, \quad d_{ij} = d_{ji} \quad (6)$$

이다. 여기서 d_{ij}, d_{ji} 는 면의 중심점간 거리를 나타낸다.

셋째로, 각 면을 이루는 꼭지점의 개수는 시점의 변화와 무관하므로 전략 없이 사용되며, 넷째로, 면간 접합각도 역시 시점 변화에 영향을 받지 않기 때문에 전략없이 사용한다. 면간 접합각도는 다음 그림 3과 같은 경우




그림 2. 중점간의 거리

Fig. 2. Distance between the center of ith polygon and that of jth polygon.




그림 3. 면간 접합 각도

Fig. 3. Angle between the center of ith polygon and that of jth polygon.

$$\cos(180^\circ - \theta) = n_i \cdot n_j \quad (7)$$

이므로

$$\theta = \sin^{-1}(n_i \cdot n_j) \quad (8)$$

이며, 식(7), (8)로써 각 면간 법선 벡터를 이용하여 구한다. 여기서 n_i, n_j 는 단위 법선 벡터를 나타낸다. 결국, 본 논문에서 사용하고 있는 특징 값들은 모델 물체에 대하여 입력 물체가 3-D 이동, 회전 및 스케일 변화되더라도 매칭 과정에 유용하게 사용될 수 있다.

이러한 절차에 의한 전략적 상수는 본 논문과 비슷한 결과를 갖는 다중 관찰 방향에서 얻어진 영상 및 각 면에 속하는 특징들간의 상대적 비율에 의한 방법으로부터 구축된 데이터 베이스량과 비교할 때, 모든 면에 대해 구성된 데이터 베이스(database)량뿐만 아니라 수렴 속도면에 있어서도 향상된다. 3차원 면적을 예로 들어보면, 기존의 논문에서는 서로간의 상대적 비율로써 비교하기 때문에 N 개의 다각형으로 이루어진 물체의 경우의 데이터량은 그림 4(a)와 식(9)에 의해

$$f(N) = N(N - 1) \quad (9)$$

로 구해진다. 그러나, 제안하는 방법에서는 각 면에 대

해 하나의 전략적 상수만을 가지므로


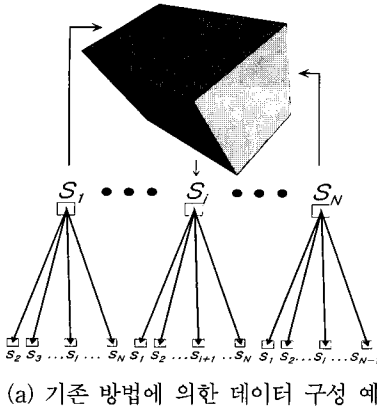


그림 4. 기존 방법에 의한 데이터 구성 예와 개수 비교 (a) 기존 방법에 의한 데이터 구성 예 (b) 데이터 개수 비교를 위한 그래프

Fig. 4. An example for the database of conventional method and Graphs for the comparison. (a) An example for the database of conventional method (b) Graphs for the comparison

$$f^*(N) = N \tag{10}$$

로 표현된다. 하나의 입체가 적어도 세 평면에 의해 이루어진다고 생각하면 N 이 커지면 커질수록 식(9)와 식(10)은 상당한 차이를 보임을 알 수 있다. 본 논문에서 사용하고 있는 특징값들을 대상으로 전체 데이터량을 계산해 보면, 기존의 방법과 제안하는 방법은

$$f(N) = N(N-1) + N + \frac{N(N-1)}{2} \left\{ \frac{N(N-1)}{2} - 1 \right\} + \frac{N(N-1)}{2} \tag{11}$$

$$= \frac{N^4 - 2N^3 + 5N^2}{4}$$

$$f^*(N) = N + N + N(N-1) + \frac{N(N-1)}{2} \tag{12}$$

$$= \frac{3N^2 + N}{2}$$

로 각각 표현된다. 여기서, 첫 번째 항은 면적, 두 번째 항은 꼭지점, 세 번째 항은 면 중심간 거리, 그리고 마지막 항은 면간 접합각도에 대한 알고리즘에 따른 데이터수를 나타낸다. 예컨대, 마지막 항은 N 개의 면 중 서로 다른 두 면을 선택하는 조합($N C_2$)의 결과이다. N 이 3이상의 자연수이므로 (11)식에서 (12)식의 차는 그림 4.(b)에서와 같이 기하급수적으로 증가한다.

III. 매칭을 위한 Hopfield 신경회로망

Hopfield 신경회로망은 상호결합형 신경망 모델로써 각 뉴우런들은 상호 완전 연결되어 있는 단층으로 구성되었으며, 패턴 인식이나 최적화 문제를 병렬적으로 푸는데 많이 사용된다. 한편 물체 인식에 사용되는 Hopfield 신경회로망의 뉴우런들은 2-D 배열로 구성된다. $M \times N$ 2-D 배열 구조를 갖는 Hopfield 신경회로망을 그림 5에 보인다.




그림 5. 상호 연결된 $M \times N$ Hopfield 신경회로망
Fig.5. Interconnected $M \times N$ Hopfield Neural Network.

이때, 각 행에는 입력 영상의 각 면 전략적 상수가, 각 열에는 모델 영상의 각 면 전략적 상수가 할당된다. 전체적인 매칭 과정은 신경회로망의 전체 에너지가 최소값으로 수렴될 때 입력 물체와 모델 물체가 서로 매칭되었다고 본다. 따라서 본 논문에서와 같은 3-D 매칭 과정은

$$E = - \sum_{i=1}^M \sum_{j=1}^N \sum_{k=1}^M \sum_{l=1}^N C_{ijkl} V_{ik} V_{jl} + \sum_{i=1}^M (1 - \sum_{k=1}^M V_{ik})^2 + \sum_{j=1}^N (1 - \sum_{l=1}^N V_{jl})^2 \tag{13}$$

과 같은 전체에너지 E를 최소화하는 데에 기여하도록 뉴우런의 출력을 정하게 되는 과정으로 정의할 수 있

다. 여기서 V_{ik} 는 하나의 뉴우런의 2진 상태값을 나타내며 입력 영상 i 번째 값과 모델 영상 k 번째 값이 매칭되면 1을 취하게 된다. 입력 영상의 C_{ikjl} 은

$$C_{ikjl} = \sum_n W_n \times F(x_n, y_n) \quad (14)$$

와 같이 구해지며, C_{ikjl} 은 행 i , 열 k 의 뉴우런과 행 j , 열 l 의 뉴우런사이의 연결강도이고 W_n 은 입력 영상과 모델에서 추출한 n 번째 특징값에 대한 비교 함수 $F(x_n, y_n)$ 의 결과에 대한 가중치(weight)이다. 각 특징값 전체에 대한 가중치의 합은

$$\sum_n W_n = 1 \quad (15)$$

와 같이 1이어야 한다. 특징값을 비교하는 불연속 함수인 $F(x_n, y_n)$ 의 특성은 식(16)과 같은 특성을 갖는다.

$$F(x_n, y_n) = \begin{cases} 1, & \text{if } |x_n - y_n| < \theta_1 \\ -1, & \text{otherwise} \end{cases} \quad (16)$$

여기서 x_n 은 입력 영상의 n 번째 값, y_n 은 모델의 n 번째 값, θ_1 은 특징 비교를 위한 문턱치이다. 위와 같은 구조에서 뉴우런 N_{ik} 의 상태 u_{ik} 에 대한 상태 방정식은

$$\frac{du_{ik}}{dt} = \sum_j \sum_l C_{ikjl} V_{jl} - \sum_j V_{ij} - \sum_j V_{jk} - \frac{u_{ik}}{\tau} + I_{ik} \quad (17)$$

로서 신경회로망이 반복될 때마다 그 차이 값을 계산하므로써 구한다. 여기서 τ 와 I_{ik} 은 식(9)에 대한 Hopfield 에너지 함수로부터 유도되어진 상수들이다. 뉴우런 상태값 결정을 위한 각 뉴우런의 출력값 V_{ik} 는

$$V_{ik} = g(u_{ik}) = \left[1 + \exp\left(\frac{-2u_{ik}}{u_0}\right) \right]^{-1} \quad (18)$$

로부터 구하며, 여기서 u_0 는 시그모이드(sigmoid) 함수의 기울기를 결정하는 계수이다. 한편 신경회로망의 동작을 위해서 임의의 초기값을 결정해야 하며, 초기화된 모든 뉴우런의 V_{ik} 의 합은 이상적인 최종 출력값으로서

$$\sum_j \sum_k V_{jk} = N \quad (19)$$

과 같이 2-D 뉴우런의 행과 열의 개수 중 작은 수 N 과 일치한다. 따라서 식(17)와 식(18)에서 u_{ik} 의 초기값은

$$u_{ik}^0 = u_{init} + \delta = -\frac{u_0}{2} \ln(N-1) + \delta \quad (20)$$

과 같이 유도된다. 여기서 δ 는 각 뉴우런의 값이 불안정한 상태에 빠지는 것을 방지하기 위한 난수값으로 $-0.1u_{init} \leq \delta \leq 0.1u_{init}$ 범위 내의 값을 가진다. 초기값 $V_{0ik} = g(u_{0ik})$ 가 결정되면, 식(17)의 해를 구하여 새로운 u_{ik} 를 갱신(update)하여 V_{ik} 를 결정한다. 미분방정식인 식(17)의 해를 구하는 데에는 6차 Runge-Kutta 방법을 사용한다. 신경회로망의 반복 횟수만큼 u_{ik} 가 갱신되면서 뉴우런의 출력값 V_{ik} 가 계산된다. 최종 출력값 V_{ik} 는 입력 영상의 i 번째 면과 모델의 k 번째 면이 매칭 되었을 때 1에 근사한 값, 그렇지 않을 경우 0에 근사한 값을 출력한다. 근사값으로 표현된 최종 출력값은

$$V_{ik} = \begin{cases} 1, & \text{if } (V_{ik} > \theta_2) \\ 0, & \text{otherwise} \end{cases} \quad (21)$$

과 같이 문턱치 처리를 한다. 여기서 θ_2 는 최종 출력값을 위한 문턱치이다. 따라서 문턱치 처리에 의해 뉴우런의 최종 출력값은 매칭된 면에서 1, 매칭되지 않은 면에서는 0으로 표현된다.

따라서, 이상적인 매칭 결과는 입력 영상의 분할된 면의 개수와 모델을 구성하는 전체면의 개수 중 작은 수만큼만 활성 뉴우런이어야 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, 첫 번째 행에서 최종 출력값이 1인 뉴우런의 수를 계수한다. 1인 뉴우런이 하나이면 변수에 1을 더하고, 하나이상인 n 개이면 $1/n$ 을 더한다. 만약 1인 뉴우런이 없으면 무시하고 다음 행으로 넘어간다. 모든 행에 대해서 위와같은 동작을 반복하여 누적된 변수값을 보관한다. 열에 대해서도 행과 같은 방법을 수행하여, 행과 열의 개수중 적은 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 해당하는 모델의 한 면에만 매칭이 일어나야 한다. 이와 같이 입력 영상의 모든 면이 이상적으로 매칭되었을 경우 유사도는 1이 된다. 그리고 입력 영상들의 면들 중 모델의 면과 매칭에 실패한 수가 많을수록 유사도는 1보다 작아지게 된다. 그러므로 유사도가 1에 가까울수록 두 물체는 매칭율이 높은 것



을 의미한다. Hopfield 전체 에너지의 수렴 증명^[10]은 구성된 회로망이 언제나 안정된 상태로 도달할 수 있음을 보여준다. Hopfield에 의해 지적되었지만 최적(전체적인)의 해가 언제나 국부적인 안정상태의 해처럼 구해지는 것은 아니다. 그러나 이러한 국부 상태는 물체인식에 충분한 매칭 특징들을 표현하는 것으로 알려져 있다^{[11] [12]}.

IV. 실험 및 검토

본 실험은 IBM PC 586 system을 사용하였으며, 실험 영상은 3-D 회전과 스케일 변화를 대상으로 제작된 256 × 256 합성 거리 영상과 캐나다 Servo-robot사의 레인지 파인더로 취득된 실제 거리 영상을 사용하였다. 신경회로망의 실제 구축을 위하여 시그모이드 함수의 기울기를 결정하는 u_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 $W_1=W_2=0.1$, $W_3=W_4=0.1$, $W_5=0.3$, $W_6=0.3$ 을 주었다. 실험적으로 $F(x, y)$ 함수의 문턱치 θ_1 은 0.078을, 최종 출력값에 주어질 문턱치 θ_2 는 0.9로 설정하였다.

1. 합성 거리 영상 실험

그림 6은 모델 물체와 입력 물체와의 매칭 과정을 보이기 위한 하나의 예를 보인다. (a)는 컴퓨터 합성에 의한 합성 거리 영상을 나타내며 (b)는 (a)의 영상을 전처리를 통해 분할한 결과를 보이고 있다. 모든 면 분할된 영상은 이상적인 면 분할이 되었다는 가정에서 구성하였다. 또한 (c)와 (d)는 매칭을 위해 분할된 입력 물체와 모델 물체의 각면에 할당된 면번호를 나타내고 있다. 그리고 (e)는 배열에 할당된 면을 보여주고 있으며, (f) ~ (i)까지는 각 뉴우런의 상태값들이 임의의 초기값으로부터 반복적으로 갱신되어 매칭되었을 경우는 1로, 매칭에 실패한 경우는 0으로 최종 출력된다. 매칭 결과를 보면 입력 물체의 모든 면이 모델 물체와 성공적으로 매칭되어 유사도가 1이 된 것을 볼 수 있다.



(e)

Input	Model	Similarity
1	6	1
2	5	1
3	1	1
4	7	1
5	8	1
6	11	1
7	13	1
8	15	1

(f)

(g)

Input	Model	Similarity
1	6	1
2	5	1
3	1	1
4	7	1
5	8	1
6	11	1
7	13	1
8	15	1

Input	Model	Similarity
1	6	1
2	5	1
3	1	1
4	7	1
5	8	1
6	11	1
7	13	1
8	15	1

(h)

(i)

그림 6. 매칭 과정의 예

(a) 입력 거리 영상 (b)분할된 입력 영상 (c) 면 기술된 입력 물체 (d) 면 기술된 모델 물체 (e) 행렬에 할당된 특징값 (f) 뉴우런의 초기값 (g) 뉴우런의 최종 활성화값 (h) 문턱치 처리된 뉴우런의 상태값(0.9) (i) 매칭 결과(유사도 = 1)

Fig. 6. A example of matching processing.

(a) Input Range Image (b) Segmented Input Image (c) Labeled Input Object (d) Labeled Model Object (e) Row-Column Assigned Features (f) Initialized Neuron value (g) Final Values of neurons (h) Final active neuron values over threshold value(0.9) (i) Matching Result(Similarity = 1)

그림 7은 그림 6의 모델 물체에 대하여 기존 논문 [7]과 비교를 위하여 3-D회전에 대해 극단적인 상황을 설정한 것으로 표 1은 기존의 방법과 제안하는 방법에 의한 최종 매칭 결과를 유사도로 나타낸 것이다. 표 1에서 보면 (a)와 같이 기존의 방법에서 사용하고 있는 정규화의 기준이 되는 가장 큰 면이 입력 영상에 존재하면 정확히 모델 물체와 매칭이 되지만, 기준면이 손실되고 새로운 면이 나타나는 (b)와 같은

극단적인 경우 매칭에 실패하고 있다. 하지만, 제안하는 방법으로는 위의 경우도 충분히 극복하고 있다.



그림 7. 비교를 위한 입력 영상들

(a) 입력 영상 #1 (b) 입력 영상 #2

Fig. 7. Input Images for the comparison

(a) Input Image #1 (b) Input Image #2

표 1. 입력 영상에 대한 매칭결과(유사도) 비교

Table 1. Matching Result(Similarity) Comparison.

유사도 \ 입력	#1	#2
기존의 방법	1	0.68
제안하는 방법	1	1

그림 8은 모델 (a)에 대해 3차원 회전, 스케일 변화 및 유사 물체 실험을 위해 차를 표현한 여러 거리 영상을 보인다. 입력영상 (b)는 모델 물체에 대해 회전한 입력 영상을 나타내고, (c), (d)는 1/2로 축소하고 회전한 영상을, (e)~(f)는 1/4로 축소하고 회전한 영상을 각각 나타내고 있으며 (g), (h)는 유사물체에 대한 영상이다. 또한 표 2.는 제안하는 방법으로 각 입력 물체와 모델 물체와의 최종 매칭 결과를 유사도로 나타낸 것이다. 요컨대, 제안하는 방법에 있어서 모델 물체에 대하여 입력 물체가 3-D 회전 및 스케일 변화가 발생하더라도 정확히 인식하고 있다. 그러나, 유사 입력 물체 #6은 모델 물체와 비슷하지만 물체 후반부가 상이하고, 입력 물체 #7은 제일 앞부분과 바퀴부분을 제외한 모든 부분이 상이하므로 일부 면이 매칭에 실패하여 최종 문턱치값($\theta_2 = 0.9$)을 넘지 못하고 있다. 결과적으로 제안하는 방법은 유사물체 분류에도 사용할 수 있음을 보여준다.





그림 8. 제안하는 방법을 위한 모델 물체와 여러 가지 입력 물체

(a)모델 영상 (b)입력 #1 (c)입력 #2 (d)입력 #3 (e)입력 #4 (f)입력 #5 (g)입력 #6 (h)입력 #7

Fig. 8. Model and Input Images for the proposed Method.

(a)Model Image (b)Input #1 (c)Input #2 (d)Input #3 (e)Input #4 (f)Input #5 (g)Input #6 (h)Input #7

표 2. 각 입력 영상들에 대한 매칭결과(유사도)

Table 2. Matching Result.

모형 \ 입력	#1	#2	#3	#4	#5	#6	#7
유사도	1.00	1.00	1.0	1.00	1.00	0.73	0.58

2. 실제 거리 영상 실험

그림 9는 실제 영상을 대상으로 한 유사 물체 분류 실험이다. 첫 번째 영상 (a)는 찾고자 하는 대상이 되는 모델 물체이며 (b)~(g)는 Range Finder로 취득한 실제 입력 영상이다. 각 영상 아래에 나타내어진 (x-1) 영상은 각 영상의 분할된 결과를 보여 주고 있다. 표 3은 각 입력영상에 대한 유사도를 나타내고 있다. 표 3에서 찾고자하는 대상 물체를 정확히 구별하고 있으며 다른 각 입력 영상도 모델 물체의 추출 전략적 특성과 비슷한 전략적 특성을 많이 가질수록 유사도 1에 보다 가깝게 된다. 분할 영상에서 나타내지는 바와 같이 분할 과정에서 발생하는 에러에 의해 합성 영상에서 보다 상당히 영상이 일그러져 있다. 하지만, 접합 면간의 형태 변화에 따른 전략적 상수에는 큰 영향을 주지 않아 정확히 찾고자 하는 물체를 구별하여 인식하고 있다. 그러나, 입력 영상 #7은 모델과 상반부의 모양이 비슷함에도 불구하고 유사도가 낮은 이유는 다른 영상에 비해 기계 장치로부터의 취득과정에서 발생하는 에러가 상당히 크기 때문이다. 본 실험에서는 특징 추출을 위해 분할하는 과정에서 발생하는 에러에 대응하기 위해 실험 통계상 뉴우런 학습 반복 횟수를 10%정도 늘려야 했고 문턱치도 5%정도 낮춰

야했다.




그림 9. 모델 물체와 여러 가지 실제 거리 입력 물체 (a)모델 영상 (b)입력 #1 (c)입력 #2 (d)입력 #3 (e)입력 #4 (f)입력 #5 (g)입력 #6 (h)입력 #7

Fig. 9. Real model and Real input images for the proposed Method.

(a)Model Image (b)Input #1 (c)Input #2 (d)Input #3 (e) Input #4 (f) Input #5 (g)Input #6 (h)Input #7

표 3. 각 실제 거리 입력 영상들에 대한 매칭결과(유사도)

Table 3. Matching Result. (Similarity)

모델 \ 입력	#1	#2	#3	#4	#5	#6	#7
유사도	0.00	0.00	0.00	1.00	0.75	0.83	0.33

그림 10은 그림 9 실험의 확장으로 잡음에 의해 왜곡되어진 실제 거리 영상에 대한 실험이다.

표 4. 각 왜곡 입력 영상들에 대한 매칭결과 (유사도=1)

Table 4. Matching Result. (Similarity=1)

모델 \ 입력	(a)	(b)	(c)
유사도	1.0	1.0	1.0




그림 10. 왜곡 실험을 위한 영상들

(a) 10 % 왜곡 영상 (b) 20 % 왜곡 영상 (c) 30 % 왜곡 영상

Fig. 10. Images for the experiment about Distortion. (a) 10 % distorted Image (b) 20 % distorted Image (c) 30 % distorted Image

그림 (a), (b), (c)는 각각 10%, 20%, 30%의 가우시안 잡음(Gaussian noise)을 포함하는 영상이며, 표 4.는 이에 대한 결과로써 나타내어지는 유사도를 나타내고 있다. 요컨대, 표 4.에서 보는 바와 같이 모두 10 ~ 30%까지의 왜곡에도 불구하고 정확히 유사도 1로써 정합 된다.

V. 결 론

본 논문에서는 3-D 물체 인식을 위한 전략적 매칭 알고리즘을 제안하였다. 제안된 방법에서는 3-D 회전 변화에 강건한 3-D 형상 특징들과 3-D 관계 특징들을 선별 사용하고, 특히 위 특징들에 대하여 고유의 상수 값인 전략적 상수를 갖도록 함으로써 3차원 이동, 스케일 및 회전 변화에도 강건하게 하였다. 선별된 특징들은 형상 특징인 각 면의 3차원 면적과 정점의 개수를, 그리고 관계 특징인 면 중심점간의 거리와 면의 접합 각도이다. 또한 제안하는 전략을 위해 형상 특징인 면내의 정점간 최장 거리를 사용하였다. 이러한 전략의 결과로 효과적으로 비교 데이터 수를 줄였으며 상당한 인식속도 향상을 꾀할 수 있었다. 한편, 기존의 2-D 형상에 대한 3-D 특징 기술 방식 등에서 문제시되었던 시점 변화에 따른 모델 베이스의 재구성 및 그에 따르는 비효율성을 해결하기 위하여, 단일 좌표 계에서 모델 물체를 전체 면에 대해 면조각들의 집합으로 표현하는 방식으로 3-D 모델 베이스를 구축하였다. 그리고 매칭 도구로서 2-D 배열 구조의 Hopfield 신경회로망의 최적화 기능을 사용하여 기존의 순차적 유사도 결정 방식에 비하여 보다 융통성 있는 결과를 기대할 수 있고, 병렬적인 매칭 과정이 가

능하였다. 또한 잡음을 가미한 실측 물체 왜곡 실험을 통하여 제안하는 방법의 우수성을 확인하였다. 따라서 본 논문에서 제안된 신경회로망을 이용한 3-D 물체 인식 방법은 시점 변화 등에 의한 3-D 기하학적 변형이 있는 경우의 인식에 효과적으로 적용되리라 앞으로, 보다 강건한 불변 특징들의 선별, 다중 물체에 의한 가려짐 및 국부 최소값(local minima) 현상에 대한 연구가 필요하다.

참 고 문 헌

[1] Y. Shirai, *Three-dimensional computer vision*, Springer-verlag, Berlin, Heidelberg, 1987

[2] 박종훈, 최종수, "면 법선 영상 기반형 3차원 물체 인식에서의 새로운 매칭 기법," *대한 전자공학회 논문지*, 제 30권, B편, 제 7호, pp. 695-705, 1993년 7월

[3] S. J. Yeh, H. Stark and M. I. Sezan, "Hopfield-type neural networks," in *Digital Image Restoration*, A. K. Kat-saggelos, ed. Berlin, Germany : Springer-Verlag, vol. 23, chap. 3, 1991.

[4] Nasser M. Nasrabadi and Wei 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.

[5] Susan S. Young, Peter D. Scott and Nasser M. Nasrabadi, "Object recognition using multi-layer hopfield neural network," *CVPR '94*, vol. 1, pp. 417-422,

Jun. 1994.

[6] Wei-Chung Lin, Fong-Yuan Liao, Chen-Kuo Tsao, and Theresa Lingutla, "A hierarchical multiple-view approach th three-dimensional object recognition," *IEEE Trans. on Neural Networks*, vol. 2, no. 1, pp. 84-92, Jan. 1991.

[7] 정우상, 송호근, 최종수, "Hopfield 신경회로망을 이용한 모델 기반형 3차원 물체 인식," *대한 전자공학회 논문지*, 제 33권, B편, 제 5호, pp. 60-72, 1996. 5

[8] 이상근, 송호근, 최종수, "3차원 물체 인식을 위한 Hopfield 신경망 구조의 매칭 알고리즘," *한국통신학회 추계종합학술대회 논문집*, 제 14호, 제 2호, pp. 955-959, 1995. 11

[9] 송호근, 최종수, "의사 밝기 영상을 이용한 예지 기반형 거리 영상 분할," *대한전자공학회 논문지*, 제 33권, B편, 제 4호, pp. 111-123, 1996. 4

[10] J.J. Hopfield, "Neurons with graded response have collective computational properties like those of two-state neurons," *IProc.Nat.Acad. Sci. USA*, vol. 81, May 1984, pp. 3088-3092.


[11] J.J. Hopfield and D.W. Tank, "Neural computation of decisions in optimization problems," *Biol.Cybern.*, vol. 52, pp. 141-152.1985.

[12] P. J. Besl and R. C. Jain, "Three-dimensional object recognition," *ACM Computing Surveys*, vol. 17, no. 1, pp. 75-145, Mar. 1985.

저 자 소 개



李商根(正會員)
1970년 9월 10일생. 1996년 8월 중앙대학교 전자공학과졸업(공학사). 1997년 3월 ~ 현재 중앙대학교 전자공학과 석사과정 재학중. 주관심분야는 컴퓨터 비전, 패턴 인식 및 신경망



李瑄鎬(正會員)
1968년 7월 10일생. 1992년 2월 중앙대학교 전자공학과 졸업(공학사). 1994년 2월 중앙대학교 전자공학과 졸업(공학석사). 1994년 8월 ~ 현재 중앙대학교 전자공학과 대학원 박사과정 재학중. 주관심분야는 영상처리, 패턴 인식, 컴퓨터 비전 및 컴퓨터그래픽스