

# Binocular stereo 방법에 의한 3차원 평면 물체의 특징값의 불확실성을 고려한 적응분류기

## (An Adaptive Classifier for 3-D Planar Object Recognition Based on Uncertainty of Features by Binocular Stereo Method)

權重長\*, 金聖大\*

(Jung Jang Kwon and Seong Dae Kim)

### 要約

본 논문에서는 3차원 평면 물체 인식을 위한 특징값의 불확실성을 고려한 적응 분류기를 제안한다. 먼저 수치해석방법을 이용하여 거리정보의 불확실성과 평면 물체의 특징값의 불확실성을 고찰한 다음 특징값의 통계적 특성이 물체의 3차원 공간에서의 위치와 방향에 따라 변화하는 것을 관측하였다. 그 후 특징값의 변화를 근사화한 후에, 제안한 적응 분류기를 이용하여 물체인식을 수행하였다. 실험을 통해서 3차원 평면 물체인식시 제안하는 방법의 유용성을 확인할 수 있었다.

### Abstract

In this paper, we propose an adaptive classifier based on uncertainty of features for 3D planar object recognition. First, we investigate the uncertainty of depth information and the feature values of 3D planar object by numerical method. And, we observed that the statistical behavior of feature is dependent on the position and orientation of objects. After that, the approximation of the statistical behavior is executed. Subsequently, the recognition procedure is executed by the adaptive classifier. By computer simulation, we confirmed that the proposed classifier is useful for 3D planar object recognition.

### [서론

3차원 물체인식 문제는 3차원 컴퓨터 시각 분야에서 매우 중요한 연구과제이며, 3차원 물체인식을 위해서는 거리 정보의 추출이 필수적이다. 그런데 거리 정보는 사용하는 방법에 따라 차이는 있지만 거리정보의 오차는 항상 존재하게된다.<sup>[1]</sup> 그러므로 오차가

있는 거리 정보로부터 얻어지는 3차원 특징값들은 당연히 부정확한 값을 가지게 된다. 그런데 기존의 3차원 물체인식 방법들은 이러한 현상을 고려하지 않고, 물체인식시 사용되어지는 특징값들이 정확하다는 가정하에 물체인식을 하였다.<sup>[6,10]</sup> 그 이유는 지금까지 물체인식에 사용되는 특징값의 불확실성에 관한 분석이 되어있지 않아서 특징값의 불확실성을 고려한 물체인식이 이루어져야 함에도 불구하고 물체인식에 적용하기가 어려웠기 때문이다. 본 논문에서는 3차원 물체인식시 사용되는 특징값들의 불확실성에 관한 분석을 하여 3차원 물체인식시에 특징값의 불확실성을

\* 正會員, 한국과학기술원 전기 및 전자공학과  
(Dept. of Electronical Eng., KAIST)  
接受日字: 1992年 3月 6日

고려한 물체인식 방법에 대한 근거를 제공하며, 실제로 물체인식을 적용할 수 있는 적응 분류기를 제안한다.

거리 정보를 추출하는 방법에는 여러 가지 방법이 있지만 스테레오 방법이 일반적으로 널리 사용되고 있다.<sup>[9]</sup> 이러한 스테레오 방법에 의한 거리정보의 부정확성에 관한 기존 연구에서는<sup>[4,5,12]</sup> 부정확성의 원인으로 영상 좌표의 양자화 오차만을 고려하여, 3차원 공간상에서 거리 정보 추출 시스템의 거리정보의 오차가 허용범위 이내에 들도록 카메라의 여러 가지 변수값들을 결정하는 것을 주목적으로 하여 진행되었다. 이러한 연구들로부터 3차원 공간에 있는 한 점에 대한 거리정보 오차가 그 점의 위치에 따라 달라진다는 것을 알 수 있으나 3차원 물체인식시에 직접 적용하기는 곤란하다.

일반적으로 3차원 물체인식과정은<sup>[10]</sup> 3차원 물체에 대한 2차원 영상을 얻고, 영상분할과정을 거친 후, 두 개의 영상으로부터 대응하는 점을 찾는 정합과정을 거친다. 이렇게 대응하는 점이 정해지면 삼각법에 의해서 3차원 거리정보가 구해지고 3차원 공간상의 면분할(surface segmentation)을 행한 후 면들의 특징값을 추정하고, 판별함수(decision function)를 이용하여 data base에 저장되어 있는 모델중에서 인식하고자 하는 입력물체에 가장 유사한 모델을 찾아 인식하게 된다. 그런데 3차원 물체인식의 여러 과정에서 양자화 오차, 센서에 의한 오차, 빛의 밝기 변화, 영상 및 특징추출을 위한 영상 분할오차, 부정합등의 다양한 요인들로 말미암아 3차원 거리정보와 물체의 특징값의 불확실성은 존재하게 된다.

위에서 언급한대로 3차원 거리정보의 오차는 여러 가지 요인으로 부터 발생하지만 본 논문에서는 2차원 영상에서 두 개의 대응하는 점의 부정확성에 기인한다고 가정하고, 2차원 영상의 대응하는 좌표의 오차가 정확하게 어떠한 분포를 가진다고 단정할 수는 없지만 앞에서 말한 3차원 물체인식 과정의 여러 가지 다양한 요인으로 불확실성이 발생하므로 일반적으로 많이 사용하는 정규분포라고 가정한다.

기존의 많은 연구에서 대부분 다면체(polyhedral object)를 인식 대상 물체로 한다.<sup>[2,3,6,7,8]</sup> 그런데 다면체는 평면의 조합으로 이루어지는 것이므로, 본 논문에서는 먼저 평면물체를 대상으로 하여 3차원 공간상의 특징값의 불확실성과 적응 인식 알고리즘의 유용성을 알아보기로 한다.

본 논문의 구성은 다음과 같다. 제I장 서론에 이어, 제II장에서는 3차원 특징값의 불확실성에 대하여

분석을 하고, 제III장에서는 새로운 적응 분류기(adaptive classifier)를 제안한다. 제IV장에서는 실험결과를 보이고, 제V장에서 본 논문의 결론을 내리 고자 한다.

## II. 3차원 물체의 특징값의 불확실성에 관한 고찰

본 논문에서는 거리정보의 추출을 위해 사용한 카메라는 그림1과 같이 바늘구멍사진기 모델(pin-hole camera model)을 사용하였고, 두 개의 카메라의 중심축(optical axis)이 평행하고, 초점거리도 동일하며, 수평축과 수직축의 pixel resolution이 같다고 가정한다. 그림1에서 P는 3차원 공간상에서의 한 점을 가르키고, f는 초점거리, Δ는 base width, k는 scale factor, (I<sub>L</sub>, J<sub>L</sub>)은 왼쪽 영상의 x축, y축 좌표를 나타내고 (I<sub>R</sub>, J<sub>R</sub>)은 오른쪽 영상의 x축, y축 좌표를 나타낸다. 실험에서는 f를 5cm, Δ를 50cm, k는 0.023cm/pixel으로 하였다.

### 1. 3차원 공간상의 한 점에 대한 거리정보의 불확실성

그림 1의 좌표계에서는 3차원 공간상의 한 점(x, y, z)이 2차원 영상에 투영되는 점의 좌표(I<sub>L</sub>, J<sub>L</sub>)와 (I<sub>R</sub>, J<sub>R</sub>)은 오차가 없는 경우에 식(1)과 같다.<sup>[11]</sup>

$$I_L = \frac{fx}{(f-z)k}$$

$$J_L = \frac{f\left(y + \frac{\Delta}{2}\right)}{(f-z)k}$$

$$I_R = \frac{fx}{(f-z)k}$$

$$J_R = \frac{f\left(y - \frac{\Delta}{2}\right)}{(f-z)k}$$
(1)

여기서 (x, y, z)는 3차원 공간 상에서의 실제 좌표 값이고 (I<sub>L</sub>, J<sub>L</sub>)은 왼쪽 2차원 영상의 x, y축 좌표를 나타내며 (I<sub>R</sub>, J<sub>R</sub>)은 오른쪽 2차원 영상의 x, y축 좌표를 나타낸다.

또한 역으로 2차원 영상에서 대응하는 두 개의 점의 좌표를 알 때 대응하는 좌표값에 오차가 없는 경우의 3차원 공간상의 한점의 좌표는 식(2)와 같이 구해진다.




그림 1. 3차원 공간 좌표계와 영상 좌표계  
 Fig. 1. 3-D coordinates system and image coordinates systems.

$$\begin{aligned}
 x &= -\frac{\Delta f_L}{(J_R - J_L)} \\
 y &= -\Delta \left( \frac{1}{2} + \frac{J_L}{(J_R - J_L)} \right) \\
 z &= \frac{\Delta f}{(J_R - J_L)k} + f
 \end{aligned} \tag{2}$$

2차원 영상의 좌표에 오차가 있는 경우는 식(3)과 같이 된다.

$$\begin{aligned}
 x &= -\frac{\Delta(I_L + dI_L)}{(J_R - J_L)(dJ_R - dJ_L)} \\
 y &= -\Delta \left( \frac{1}{2} + \frac{J_L + dJ_L}{(J_R - J_L + dJ_R - dJ_L)} \right) \\
 z &= \frac{\Delta f}{(J_R - J_L + dJ_R - dJ_L)k} + f
 \end{aligned} \tag{3}$$

여기서  $dI_R, dI_L, dJ_R, dJ_L$ 은 각각  $I_R, I_L, J_R, J_L$ 의 오차를 나타낸다.


본 논문에서는 2차원 영상에 gaussian 오차가 있는 경우에 컴퓨터 모의 실험을 통하여 얻어진 3차원

좌표의 각축별 확률밀도 함수는 그림2와 같다. 여기서 알 수 있는 것은 x축, y축, z축의 좌표가 원점에서 멀어질수록 3차원 공간상의 한 점의 좌표의 거리 정보의 불확실성이 증가함을 알 수 있다.


2. 3차원 평면 물체의 특징값의 불확실성

3차원 공간상의 평면 물체는 꼭지점들과 경계(edge)들로 구성되어진다. 그러므로 평면 물체의 꼭지점들의 위치에 따라 정해지는 여러가지 특징값들도 오차를 가지고 있는 것은 당연하며, 특징의 통계적 특성 또한 평면 물체의 3차원 공간상에서 존재하는 상태에 따라서 달라진다. 3차원 공간상에서 평면 물체의 특징값의 변화에 대해서 고찰하려면 각 꼭지점들의 위치 및 꼭지점들 사이의 상대적인 분포에 대해서도 모두 해석을 하는 것이 정확하지만 그것은 매우 어려운 일이다. 그러므로 본 논문에서는 3차원 평면 물체의 3차원 공간상의 존재하는 상태를 평면 물체의 중심점의 위치(x, y, z)와 자세(x축으로 기울어진 각도  $\theta$ , y축으로 기울어진 각도  $\phi$ , z축을 중심으로 회전한 각도  $\psi$ 로써 나타내고, 그것에 따라 인식시 사용되는 특징들은 많은 종류가 있지만, 본 논문에서는 평면 물체를 연구 대상으로 하므로 면적, 둘레, compactness 등의 수치적 특징(numerical feature)에 관하여 고찰한다. 실험에 사용한 평면 물체들은 그림 4와 같은 여러 모양의 다각형을 사용하였다.


평면물체의 특징값들의 변화를 수식적으로 해석하는 것이 어려우므로 컴퓨터로 모의 실험을 하여 특징값들의 불확실성에 관하여 고찰한다. 그 실험 방법은 다음과 같다.



(a)



(b)



(c)

그림 2. 3차원 공간 좌표에 따른 확률 밀도 함수의 변화

- (a) x축에 따른 확률 밀도 함수의 변화
- (b) y축에 따른 확률 밀도 함수의 변화
- (c) z축에 따른 확률 밀도 함수의 변화

Fig. 2. Variation of probability density function of estimated coordinates.

- (a) the pdf variation according to x-coordinates.
- (b) the pdf variation according to y-coordinates.
- (c) the pdf variation according to z-coordinates.

- 1) 임의의 한 평면물체를 역투시 변환 행렬을 이용하여 주어진 위치와 자세로 3차원 공간상에 변환한다.
  - 2) 3차원 평면물체를 투시변환 행렬을 이용하여 2차원 영상에 변환한다.
  - 3) 2차원 영상의 평면에 각 꼭지점의 위치에 오차를 첨가한다.
  - 4) 2차원 영상의 평면들을 다시 3차원 공간상으로 변환한다.
  - 5) 3차원 평면물체의 특징값들을 추출한다.
- 3)4)5)를 충분히 반복한다. (실험에서는 5000번 반복하였음)

앞의 과정을 위치와 자세를 변화시키면서 특징값들의 분포를 살펴보면 gaussian분포와 비슷하며 평균과 분산이 위치와 자세에 따라 변화함을 알 수 있다. 그림 5에서 그림7까지의 실험결과는 한 변의 길이가 20cm인 정삼각형을 대상 물체로 하여 실험한 결과이다. 이때 모델의 면적은 173.2cm<sup>2</sup>로, 둘레는 60cm, compactness는 0.603이며, 오차는  $\sigma$ 가 2차원 영상에서 2pixel이 되도록 하였다. 이것은 다음과 같은 의미를 지닌다.  $x_c=0cm, y_c=0cm, z_c=150cm, \theta = \phi = 0$ 일 때 한변의 길이가 20cm인 정삼각형은 2차원 영상에서 한 변의 길이가 약 30pixel 정도로 나타난다.  $z_c=100cm$ 일 때 약 45pixel로 나타난다.

그림 5, 그림 6은 2차원 영상의 대응하는 좌표값의 오차가 uniform분포를 가질 때와 gaussian분포를 가질 때의 3차원 공간에서의 특징 값의 분포를 나타낸다. 오차가 uniform분포이든 gaussian분포이든 3차원 공간상에서 특징값은 모두 gaussian 분포와 비슷한 형태를 가진다는 것을 알 수 있었고 평면 물체의 3차원 공간상에서의 위치와 자세에 따라 특징값의 통계적 특성이 변화함을 알 수 있었다. 그림 7은 물체의 위치와 자세에 따른 면적의 평균과 분산의 변화를 나타낸다. 여기서 살펴보면  $x_c, y_c$ 의 변화보다는  $z_c$ 의 변화에 따른 영향이 상대적으로 크게 나타나고  $\zeta$ 의 영향보다는  $\theta$ 와  $\phi$ 의 변화에 의한 영향이 크게 나타남을 알 수 있다.

그림 8은 두개의 정삼각형을 대상으로 하여  $Z_c$ 와  $\theta$ 에 따른 각각의 면적의 통계적 분포를 나타낸 것이다. 여기서 두 개의 삼각형을 A와 B라고 하고, 입력되는 물체를 A와 B로 분류하는 문제를 생각해보면, 그때의 결정치(decision value)는  $z_c$ 와  $\theta$ 에 따라 다른 결정치를 사용하여야 효과적임을 알 수 있다.




그림 3. 3차원 공간에서 평면 물체의 위치 (position)와 자세(orientation)  
 Fig. 3. Position and orientation of a polygonal objects






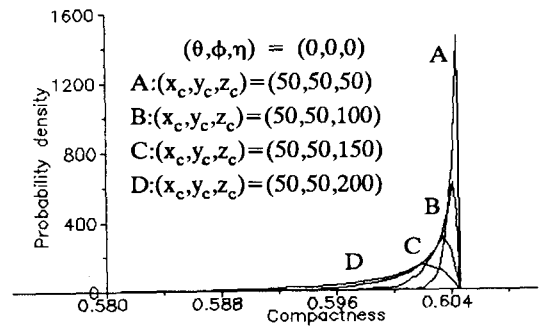
그림 4. 특징값의 변화를 고찰하기 위한 실험에 사용한 평면 물체들  
 Fig. 4. Polygonal objects used in experiments.



(a) 면적  
 (a) Area




(b) 둘레  
 (b) Perimeter




(c) Compactness  
 (C) Compactness


그림 5. 2차원 좌표의 오차의 분포가 uniform분포 일 때의 특징값의 변화  
 Fig. 5. Probability distribution of features for uniform error modeling.




(a) 면적  
(a) Area




(a) 평균(Xc, Yc)  
(a) mean(Xc, Yc)




(b) 둘레  
(b) Perimeter



(b) 분산(Xc, Yc)  
(b) variance(Xc, Yc)




(c) Compactness  
(c) Compactness




(c) 평균(Xc, Zc)  
(c) mean(Xc, Zc)

그림 6. 2차원 좌표의 오차의 분포가 gaussian 분포 일 때의 특징값의 변화


Fig. 6. Probability distribution of features for gaussian error modeling.




(d) 분산( $x_c, z_c$ )  
(d) variance( $x_c, z_c$ )




(g) 평균( $\theta, \eta$ ) (g) mean( $\theta, \eta$ )



(e) 평균( $\theta, \phi$ )  
(e) mean( $\theta, \phi$ )



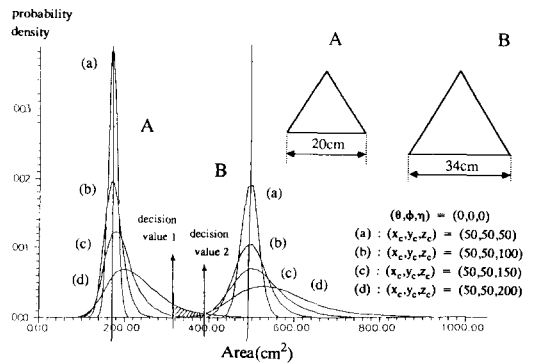
(h) 분산( $\theta, \eta$ ) (h) variance( $\theta, \eta$ )



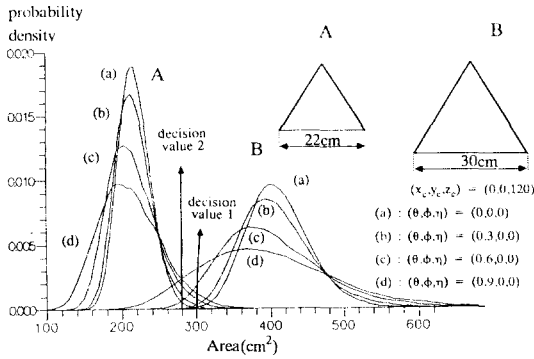
(f) 분산( $\theta, \phi$ )  
(f) variance( $\theta, \phi$ )

그림 7.  $x_c, y_c, z_c, \theta, \phi, \eta$ 의 변동에 따른 면적의 통계적 특성의 변화

Fig. 7. Variation of statistical properties of area in terms of ( $x_c, y_c, z_c$ ) and ( $\theta, \phi, \eta$ )



(a)  $z_c$ 에 따른 결정치의 변화  
(a) variation of decision value according to  $z_c$



(b)  $\theta$ 에 따른 결정치의 변화  
 (b) variation of decision value according to  $\theta$

그림 8. 두개의 class 분류시  $z_c$ 와  $\theta$ 에 따른 최적 결정치의 변화

Fig. 8. Variation of optimum decision boundary according to  $z_c$  and  $\theta$  for a two-class classification

### III 적응 분류기(Adaptive classifier)

앞에서 물체의 위치와 자세에 따라 특징값의 통계적 특성이 변화함을 알 수 있었고 본 장에서는 이러한 현상을 고려하여 평면물체의 적응 분류기를 제안한다.

적응 분류기에 관하여 객관적인 설명을 하던 다음과 같다. 먼저 인식대상 물체의 특징값의 통계적 특성을 학습(Learning)과정을 통하여 위치와 자세에 따라 어떻게 변화하는가를 조사하여, 그 변화를 다항 근사법(polynomial approximation method)을 이용하여 modeling 한 후 다항식의 계수들을 database에 저장한다. 그 다음 입력물체(input object)의 특징값과 위치(position)와 자세(orientation)를 이용하여 분류(classification)한다.

#### 1. 분류 규칙

지금까지 일반적으로 물체인식시 사용되어지는 분류기는 그림9와 같이 물체의 특징값들을 입력으로 하여 각 모델별로 판별 함수를 계산하여 그 중 가장 큰 값을 가지는 모델로 판정한다. 이때 사용되어지는 판별함수는 대부분 식(4)와 같은 MDC(Minimum Distance Classifier)이다.<sup>[6],[11]</sup> 또는 각 특징 별로 가중치를 경험에 의해서 인위적으로 다르게 주기도

한다.<sup>[6]</sup> 이 때 수식은 식(5)와 같이 표현된다.

$$d_i(\mathbf{x}) = -\|\mathbf{x} - \mathbf{m}_i\|^2 = -(\mathbf{x} - \mathbf{m}_i)'(\mathbf{x} - \mathbf{m}_i) \quad (4)$$

$$d_i(\mathbf{x}) = -\|\mathbf{W}(\mathbf{x} - \mathbf{m}_i)\|^2 \quad (5)$$

여기서  $i=1, \dots, c$ .  $c$ 는 class수를 의미하고,  $\mathbf{m}$ 은 평균 벡터를 나타내며,  $\mathbf{x}$ 는 특징 벡터,  $\mathbf{W}$ 는 가중치 행렬(weight matrix)을 의미한다.

이러한 판별함수를 보다 일반적인 형태로 나타내면 식(6)처럼 된다<sup>[11]</sup>

$$d_i(\mathbf{x}) = \mathbf{x}'\mathbf{W}_i\mathbf{x} + \mathbf{w}_i'\mathbf{x} + \mathbf{w}_{i0} \quad (6)$$

이때  $\mathbf{x}$ 가 gaussian random vector라고 가정하면  $\mathbf{W}_i, \mathbf{w}_i, \mathbf{w}_{i0}$ 는 식(7)과

$$\begin{aligned} \mathbf{W}_i &= -\frac{1}{2}\mathbf{C}_i^{-1} \\ \mathbf{w}_i &= \mathbf{C}_i^{-1}\mathbf{m}_i \\ \mathbf{w}_{i0} &= -\frac{1}{2}\mathbf{m}_i'\mathbf{C}_i^{-1}\mathbf{m}_i - \frac{1}{2}\log|\mathbf{C}_i| + \log P(\mathbf{w}_i) \end{aligned} \quad (7)$$

같이 나타낼 수 있다. 여기서  $\mathbf{m}_i$ 는 평균 벡터를 나타내고  $\mathbf{C}_i$ 는 공분산(covariance matrix)을 나타낸다. 그런데 이전의 (4)(5)(6)(7)은 모두 특징 벡터의 통계적 특성이 위치와 자세에 따라 변화하는 것이 고려되어 있지 못하다.

그림5, 그림6에서 살펴본 대로 2차원 영상에서의 오차의 분포가 uniform 형태이든 gaussian 형태이든 모두 3차원 물체의 특징값의 분포는 gaussian 분포와 비슷한 형태를 가지므로 특징값의 분포가 gaussian 분포라고 가정하면 그 때의 적응 분류기(adaptive classifier)의 block diagram은 그림 10과 같이 나타내어지고 판별함수는 식(8)과 같다.

$$d_i(\mathbf{x}, \mathbf{p}) = \mathbf{x}'\mathbf{W}_i(\mathbf{p})\mathbf{x} + \mathbf{w}_i'(\mathbf{p})\mathbf{x} + \mathbf{w}_{i0}(\mathbf{p}) \quad (8)$$

여기서  $\mathbf{p}=(x_c, y_c, z_c, \theta, \phi, \eta)$ 이고  $x_c, y_c, z_c$ 는 평면물체의 중심좌표,  $\theta, \phi, \eta$ 는 기울어진 각도를 나타낸다.

각 class의 a priori probability가 동일하다고 가정하면  $\mathbf{W}_i, \mathbf{w}_i, \mathbf{w}_{i0}$ 는 식(9)로 표현된다.

$$\begin{aligned} \mathbf{W}_i(\mathbf{p}) &= -\frac{1}{2}\mathbf{C}_i^{-1}(\mathbf{p}) \\ \mathbf{w}_i(\mathbf{p}) &= \mathbf{C}_i^{-1}(\mathbf{p})\mathbf{m}_i(\mathbf{p}) \\ \mathbf{w}_{i0} &= -\frac{1}{2}\mathbf{m}_i'(\mathbf{p})\mathbf{C}_i^{-1}(\mathbf{p})\mathbf{m}_i(\mathbf{p}) - \frac{1}{2}\log|\mathbf{C}_i(\mathbf{p})| \end{aligned} \quad (9)$$



여기서  $m_i$ 는 mean vector를 나타내고  $C_i$ 는 covariance matrix를 나타낸다.

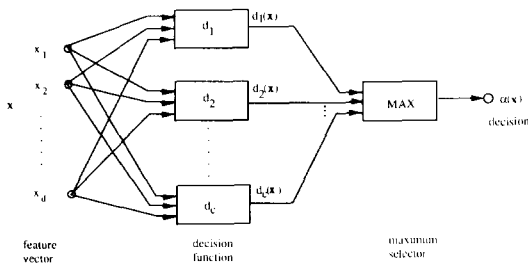


그림 9 일반적인 classifier  
Fig. 9. Conventional classifier.

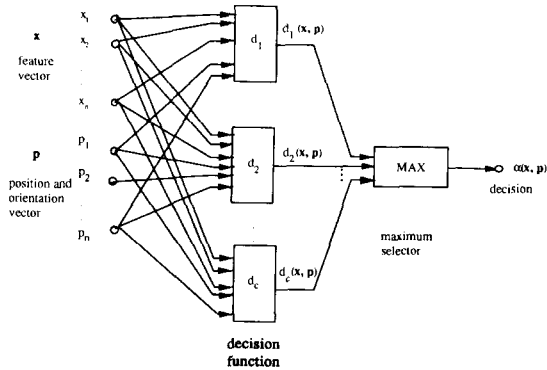


그림 10. 제안한 classifier  
Fig. 10. Proposed classifier.

2. 통계적 특성값의 근사화

그림7에서 살펴본 바와 같이 평면물체의 통계적 특성이 위치와 자세에 따라 변화함을 살펴 보았고, 여기서는 그 변화를 다항 근사법 (polynomial approximation method)을 이용하여 학습과정을 통해 모델의 data base에 저장한다.

3차원 공간상에서 평면물체의 통계적 특성의 변화에 변수는  $x_c, y_c, z_c, \theta, \phi, \eta$ 의 6개 이었지만  $z_c, \theta, \phi$ 의 영향이 지배적임을 알 수 있었고 또한 실제로 물체인식을 하는 대부분의 경우에 물체인식 시스템이 주어지면 물체가 놓여지는 위치는 거의 일정하고 물체가 놓여지는 자세만 달라진다. 그러므로 본 논문의 경우에는  $x_c, y_c, z_c, \eta$ 의 변화는 무시하고  $\theta, \phi$ 만을 고려하기로 한다.

변수가 == 2개인 경우의 다항 근사화 방법을 [13] 설명하면 다음과 같다. 먼저 실험에 의해서 4차로 다항 근사화하면 적당함을 알 수 있었고 그 때의 다항식  $g(\theta, \phi)$ 는 식(10)으로 표시된다.

$$g(\theta, \phi) = b_1 + b_2\theta + b_3\phi + b_4\theta^2 + b_5\phi^2 + b_6\theta\phi + b_7\theta^3 + b_8\phi^3 + b_9\theta^2\phi + b_{10}\theta\phi^2 + b_{11}\theta^4 + b_{12}\phi^4 + b_{13}\theta^3\phi + b_{14}\theta^2\phi^2 + b_{15}\theta\phi^3 \quad (10)$$

$$g = [b_1 b_2 \dots b_{15}] [1 \theta \phi \theta^2 \phi^2 \theta\phi \theta^3 \phi^3 \theta^3\phi \theta^2\phi^2 \theta\phi^3] = \mathbf{b}^T \mathbf{X} \quad (11)$$

이것을 LMSE(Least Mean Square Error)추정 (estimation) 기술을 이용하여 계수(coefficient)를 구하는 문제로 생각할 수 있으며 식(12)처럼 표현된다.

$$\mathbf{Xb} = \mathbf{g} \quad (12)$$

여기서

$$\mathbf{b} = [b_1 b_2 \dots b_{15}]^T$$

$$\mathbf{g} = [g_1 g_2 \dots g_n]$$

그리고

$$\mathbf{X} = \begin{bmatrix} 1 & \theta_1 & \phi_1 & \theta_1^2 & \phi_1^2 & \theta_1\phi_1 & \theta_1^3 & \phi_1^3 & \theta_1^3\phi_1 & \theta_1^2\phi_1^2 & \theta_1\phi_1^3 & \theta_1^4 & \phi_1^4 & \theta_1^3\phi_1^2 & \theta_1^2\phi_1^3 \\ 1 & \theta_2 & \phi_2 & \theta_2^2 & \phi_2^2 & \theta_2\phi_2 & \theta_2^3 & \phi_2^3 & \theta_2^3\phi_2 & \theta_2^2\phi_2^2 & \theta_2\phi_2^3 & \theta_2^4 & \phi_2^4 & \theta_2^3\phi_2^2 & \theta_2^2\phi_2^3 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & \theta_n & \phi_n & \theta_n^2 & \phi_n^2 & \theta_n\phi_n & \theta_n^3 & \phi_n^3 & \theta_n^3\phi_n & \theta_n^2\phi_n^2 & \theta_n\phi_n^3 & \theta_n^4 & \phi_n^4 & \theta_n^3\phi_n^2 & \theta_n^2\phi_n^3 \end{bmatrix}$$

여기서 n은 학습표본(training sample)들의 개수를 나타낸다.

b는 식(11)로부터 아래와 같이 구해진다

$$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{g} \quad (13)$$

변수가 6개인 경우도 다항식만 달라지고 동일한 방법으로 구할 수 있다.

IV. 실험결과 및 고찰

제안하는 방법의 유용성을 조사하기 위하여 실험에 사용한 인식 대상 물체의 모델은 그림 11과 같은 평면 물체들을 대상으로하여 컴퓨터를 이용한 모의 실험을 하였다. 물체인식에 사용한 특징들은 면적, 둘째 compactness로 하였고 오차가 없는 경우의 각 모델들의 특징값들은 표1과 같으며 실험에 사용한 카메라 모델은 그림1과 동일하게 가정하였다.

일반적으로 물체인식 시스템에서 인식하고자 하는 물체는 거의 비슷한 위치에 놓여지고  $\eta$ 의 변화에 의한 영향은  $\theta$ 와  $\phi$ 의 변화에 의한 영향에 비하여 매우 작다. 또한 인식 대상 물체가 다면체인 경우에도 물체의 각면의 법선 벡터가 카메라의 중심축(optical axis)와 이루는 각도에 의한 불확실성이 가장 크게 나타난다. 그러므로 본 논문에서는  $\theta$ 와  $\phi$ 의 변화에 의한 영향만을 고려한 실험을 하였다.

먼저 각 모델의 평면들을 3차원 공간상에서  $\theta$ 와  $\phi$ 를 변화시키면서 그때의 통계적 특성값의 변화를 조사하고 다항 근사법을 이용하여 근사화시킨다. 그후에 모델의 database에 다항식의 계수들을 저장한다. 그림 12는 model1의  $\theta$ 와  $\phi$ 에 따른 면적의 평균값과 분산의 변화와 그때의 근사화된 결과를 나타낸다. 인식률을 구하기 위하여 모델을 3차원 공간상에서  $\theta$ 와  $\phi$ 를 변화시키면서 2차원으로 투영된 좌표에 오차를 첨가한다. 그 후에 다시 3차원 공간상으로 역변환하여 입력 물체의 특징값과  $\theta$ 와  $\phi$ 를 구하고 이 값들을 이용하여 물체를 분류한다. 그림 13은  $\theta$ 와  $\phi$ 를 변화시키면서 본 논문에서 제안하는 방법과 식(4)와 같은 MDC(Minimum Distance Classifier), 식(5)에서 가중치(weight)를 각 특징별로 정규화한 NMDC(Normalized Minimum Distance Classifier)를 사용하였을 때의 인식률을 비교한 것이다. 실험 결과로부터 제안한 방법이 높은 인식률을 보이며  $=$ 와  $=$ 가 큰 경우 즉 평면 물체가 많이 기울어진 경우에도 상대적으로 좋은 결과를 보이는 것을 알 수 있다.

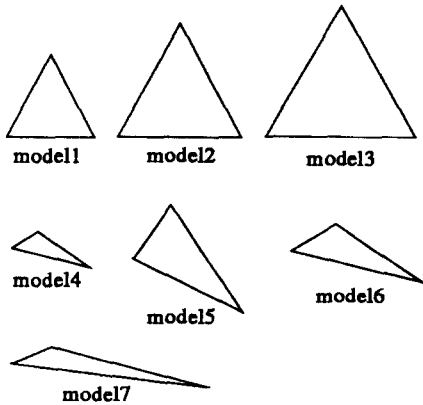




그림 11. 실험에 사용한 평면 물체 model들  
Fig. 11. models used in the experiment of recognition

표 1. model들의 실제 특징값  
Table 1. True values of features of the models.


model feature	model 1	model 2	model 3	model 4	model 5	model 6
area	173.29	292.71	500.56	27.00	108.00	100.00
perimeter	60.00	78.00	102.00	30.00	60.10	68.80
compactness	0.60	0.60	0.60	0.37	0.37	0.26




(a) 평균값의 변화  
(a) the variation of mean( $\theta$ ,  $\phi$ )



(b) 평균값의 근사화 결과  
(b) the approximation result of mean( $\theta$ ,  $\phi$ )



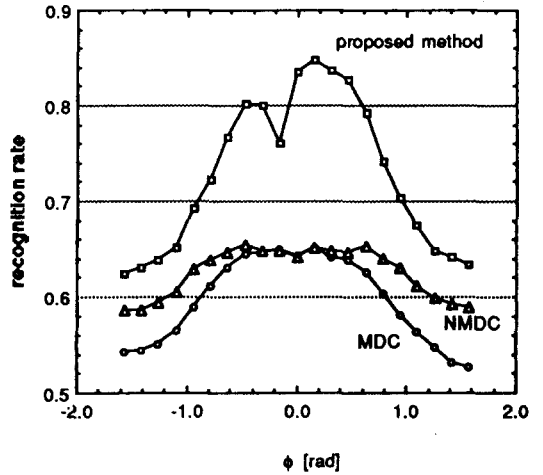
(c) 분산값의 변화  
(c) the variation of variance( $\theta$ ,  $\phi$ )



(d) 분산의 근사화 결과  
 (d) the approximation result of variance( $\theta$ ,  $\phi$ )

그림 12. 다항식에 의한 근사화 결과

Fig. 12. Results of polynomial approximation.



(b)  $\phi$ 에 따른 인식률의 변화  
 (b) the variation of recognition rate according to  $\phi$


그림 13. 제안한 방법의 인식률

Fig. 13. Recognition rate of the proposed algorithm.

V. 결론

본 논문에서는 거리 정보의 불확실성은 2차원 영상에서 대응하는 점의 좌표값의 오차에 기인하고, 또한 그 분포는 gaussian 분포를 가진다고 가정하여 binocular stereo 방법에 의한 거리 정보의 불확실성과 3차원 평면 물체의 특징값의 불확실성에 관하여 살펴보았고, 그 결과 이러한 현상을 고려한 물체 인식이 수행되어야 함을 알 수 있었다. 또한 특징값의 변화를 평면 물체의 중심점의 좌표, x축 y축으로 기울어진 각도, z축을 중심으로 회전한 각도의 함수로 가정하여 그 변화를 추정할 수 있었으며, 이러한 현상을 고려하여 물체의 위치와 자세에 따라 특징값이 변화하는 경우에 적용할 수 있는 적응 분류기를 제안하였고, 실험을 통하여 제안하는 방법의 유용성을 확인할 수 있었다.

그리고, 어떠한 거리정보 추출 방법을 이용하든지 오차는 항상 존재하게 됨으로 제안하는 방법을 기존 물체인식 시스템에 적용하면 시스템의 오차를 고려한 물체인식이 수행되어 보다 정확한 물체인식을 할 수 있으리라 예상된다.



(a)  $\theta$ 에 따른 인식률의 변화  
 (a) the variation of recognition rate according to  $\theta$

參 考 文 獻

[1] Katsudhi Ikeuchi, Takeo Kanade, "Applying Sensor Models to Automatic Generation of Object Recognition", Second International Conference on Computer Vision, IEEE, pp.228-237, 1988.

[2] M. Dhome and T.Kasvand, "Polyhedral Recognition by Hypothesis Accumulation", IEEE vol. PAMI-9 no.3, pp429-438, May 1987.

[3] Jan R. Engelbrechet and Fredrich M. Wahl, "Polyhedral Object Recognition using Hough-Space Features", Pattern Recognition vol.21, no.2, pp.155-167, 1988.

[4] Steven D. Blostein and Thomas S. Huang, "Error Analysis in Stereo Determination of 3D Point Positions", IEEE vol. PAMI-9 no.6, pp752-765, November 1987.

[5] Behrooz Kamgar-Parsi and Behzad Kamgar-Parsi, "Evaluation of Quantization Error in Computer Vision", IEEE PAMI vol.11 no.9, pp929-940, September 1989.

[6] Masaki Oshima and Yoshiaki Shirai, "Object recognition using Three-Dimensional information," IEEE PAMI-5 no.4, pp.353-361, July 1983.

[7] Yoshiaki Shiraz, "Recognition of Polyhedrons with A Range Finder", Pattern Recognition vol.4, pp.243-250 1972.

[8] Rodney A. Brooks, "Model-Based Three-Dimensional Interpretations of Two-Dimensional Images", IEEE PAMI-5, no.2, pp.140-150 March 1983.

[9] S. Barnard and M.A. Fisher, "Computational stereo," Comput. Survey, vol.14, no.4, pp.553-572, Dec. 1982.

[10] Paul J. Besl and Ramesh C. Jain, "Three-dimensional object recognition," Comput. Survey, vol.17, no.1, pp.75-144, Mar. 1985.

[11] R. Duda and P. Hart, Pattern Classification and Scene Analysis, New York, 1971.

[12] Jeffrey J. Rodriguez and J.K. Aggarwal, "Stochastic analysis of stereo quantization error," IEEE Trans. Pattern Anal. Machine Intell. vol.12, no.5, pp.467-470, May.1990.

[13] William H. Press and et al, Numerical Recipes in C, Cambridge University press, 1988.

著 者 紹 介



權 重 長 (正會員)

1962年 11月 22日生. 1985年 2月 부산대학교 전자공학과 학사 학위 취득. 1987年 2月 한국과학기술원 전기 및 전자 공학과 석사학위 취득. 1993年 2月 한국과학기술원 전기 및 전자 공학과 박사학위 취득. 1993年 3月 ~ 현재 경성대학교 컴퓨터공학과 전임 강사. 주관심분야는 3D computer vision, Robot vision, 한글인식, 영상인식, 영상처리, 신경회로망, fuzzy 이론 등임.



金 聖 大 (正會員)

1953年 12月 26日生. 1977年 2月 서울대학교 전자공학과 학사학위 취득. 1979年 2月 한국과학기술원 전기 및 전자공학과 석사학위 취득. 1983年 12月 ENSEEIHT 박사학위 취득. 1984年 9月 ~ 현재 한국과학기술원 전기 및 전자공학과 부교수. 주관심분야는 패턴인식, low-level image processing, 영상부호화 알고리즘의 VLSI 구현 등임.