

論 文

확장된 지역특징을 이용한 중첩된 물체인식

正會員 白 重 煥*

Overlapped Object Recognition Using
Extended Local FeaturesJoong Hwan Baek *Regular Member*

要 約

본 논문은 확장된 지역특징을 이용하여 서로 중첩된 물체를 인식하는 새로운 방법에 대해 기술한다. 먼저 모델물체의 화상으로부터 코너, 아크, 평행선 및 코너-아크로 구성된 지역특징을 추출하고 지식베이스를 구축한다. 물체의 정합을 위해, 입력화상으로부터 지역특징을 추출한 다음, 지식베이스의 특징과의 유사성을 조사하여 유사한 특징 set으로부터 기하변환을 구한다. 기하변환이 클러스터를 형성하면, 그 클러스터의 중심으로 가설을 설정하고 역기하변환으로 정합을 검증한다. 실험을 통해, 제안된 물체인식 방법이 기존의 방법에 비해 인식율과 정확도를 높인다는 것을 확인하였다.

ABSTRACT

This paper describes a new overlapped object recognition method using extended local features. At first, we extract the extended local features consisting of corners, arcs, parallel-lines, and corner-arcs from the images consisting of model objects. Based on the extended local features we construct a knowledge-base. In order to match objects, we also extract the extended local features from the input image, and then check the compatibility between the extracted features and the features in the knowldege-base. From the set of compatible features, we compute geometric transforms. If any geometric transforms are clustered, we generate the hypothesis of the objects as the centers of the clusters, and then verify the hypothesis by a reverse geometric transform. An experiment shows that the proposed method increases the recognition rate and the accuracy as compared with existing methods.

I. 서 론

*韓國航空大學 通信情報工學科
Dept. of Telecomm & Inform. Eng., Hankuk
Aviation Univ.
論文番號 : 92-144 (接受 1992. 8. 10)

물체인식을 위한 가장 간단한 방법은 입력화상의 물체에 모든 가능한 조합의 물체, 위치 및 각도로 정

합(match) 해보는 방법이다. 그러나, Besl과 Jain⁽¹⁾은 이러한 방법이 3차원 물체인식에서는 거의 불가능한 것임을 입증하였다. 따라서, 이러한 방법대신에 물체의 특징(feature)을 이용한 방법이 주로 사용되고 있다. 특징을 이용한 물체인식 방법은 처리 해야 할 데이타량을 현저히 줄일 수 있고 인식속도를 증대시킬 수 있다는 장점을 갖는다.

물체인식에 사용되는 특징은 두 가지 형태로 구분할 수 있다: 광역특징(global feature)과 지역특징(local feature). 물체인식을 위한 고전적 방법중의 하나는 광역특징 벡터를 이용한 패턴인식이다. 광역특징의 예로서는 물체의 둘레, 무게중심, 면적 등을 들 수 있다. 이러한 광역특징들은 화상으로부터 쉽게 추출되지만 그 특징값들이 물체의 전체부분에 의존하므로 물체가 서로 중첩되어 있는 경우, 사용이 불가능하다. 반면, 지역특징은 물체의 일부분에 의존하고 그들이 모여 전체를 나타낸다. 따라서, 지역특징은 중첩된 물체의 인식에 사용될 수 있다⁽²⁾. 지역특징은 주로 물체의 외각선을 선이나 커브로 변환하여 물체를 보다 더 복잡한 부분까지 기술할 수 있다. 전형적으로, 지역특징은 매우 구조적이고 함축적 표현으로 구성된다.

부분적으로 중첩된 물체의 인식을 위해 몇몇 연구자들이 지역특징을 사용했다. Ayache⁽³⁾와 Rummel⁽⁴⁾은 입력화상으로부터 물체의 윤곽선을 추출하고 그 윤곽선을 직선들로 근사화 시킨다음 그 직선들을 지역특징으로 이용하여 물체를 인식했다. Perkins⁽⁵⁾는 굴곡(curve)이 있는 물체의 인식을 위해 line drawing 기법을 이용하여 물체의 boundary를 아크로 표현했다(describe). 한편, koch^{(2),(6)}와 Li⁽⁷⁾는 입력물체의 윤곽선으로부터 코너를 추출한 다음 모델물체로부터 추출된 코너와의 정합을 통해 물체를 인식했다.

그러나, 기존의 방법들에서는 주로 단일 지역특징을 사용했기 때문에 시스템의 인식율이나 정확도는 물체의 중첩된 정도가 증가됨에 따라 현저히 저하된다. 본 연구에서는, 다른 물체인식 시스템과는 달리, 인식율과 정확도를 높이기 위해 코너, 아크, 평행선 및 코너-아크로 구성되는 확장된 지역특징을 사용한 중첩된 물체인식 알고리즘을 제안한다.

본 논문의 구성은, I 장의 서론에 이어서, II 장에서는 화상으로부터 확장된 지역특징을 추출하는 방법에 대해 기술하고, III 장에서는 추출된 지역특징으로부터 기하변환(geometric transform)을 통해 물

체를 정합(matching)하고 검증(verification)하는 방법에 대해 설명한다. IV 장에서는 실험을 통해 제안된 알고리즘의 성능을 분석하고, V 장에서 결론을 맺는다

II. 확장된 지역특징 추출

화상으로부터 특징을 추출하기에 앞서, 윤곽선 검출(edge detection) 및 직선 추출(straight line extraction) 과정을 거친다. 본 연구에서는 윤곽선 검출을 위해 9×9 Laplacian of Gaussian 연산자(operator)를 사용한다⁽⁸⁾. 이 연산자의 특징은 물체의 에지(edge) 부분에서 서로 연결된 영교차점(zero-crossing point)을 생성하기 때문에 세선화(thinning) 과정 없이 선으로 된 윤곽선을 검출할 수 있다.

검출된 윤곽선 segment로부터 직선을 추출하기 위해 Lowe⁽⁹⁾가 제안한 다각형 근사화법(polygonal approximation method)을 사용한다: 윤곽선 segment의 시점(starting point)과 종점(ending point)을 잇는 선으로부터 최대편향점(maximum deviation point)을 수색하여 그 점을 중심으로 두 segment로 분할(split)한 다음, 다시 각각의 segment는 같은 과정으로 반복 분할된다. 여기서 분할조건은 segment의 길이 대 최대편향거리가 임계값 이상이면 분할하고, 그렇지 않으면 그 segment는 시점과 종점을 잇는 하나의 직선으로 변환된다. 다각형 근사화된 직선의 데이터 구조는 시점의 좌표(x_1, y_1), 종점의 좌표(x_2, y_2), 직선의 길이(len), 기울기(dev)로 구성된다. 이제, 다각형 근사화된 직선들로부터 코너, 아크, 평행선 및 코너-아크로 이루어진 확장된 지역특징을 추출한다

2-1. 코너 검출

코너는 두 직선이 모이는(converge) 점으로 정의할 수 있다. 따라서, 코너는 직선추출과정에서 추출된 모든 두 직선의 시점이나 종점 사이의 근접거리(proximity)를 계산함으로써 검출할 수 있다. 만일 어떤 두 직선의 근접거리가 임계값 이하이면, 두 직선은 하나의 코너를 형성한다고 본다.

코너의 데이터 구조는 직선 1(st1), 직선 2(st2), 코너각(ang)으로 구성된다(그림 1참조). 여기서 직선 1은 두 직선중 길이가 긴것을, 직선 2는 길이가 짧은 것으로 assign 한다. 또한 st1.dev와 st2.dev를 각각 직선 1의 기울기와 직선 2의 기울기라면, 코너각

`ang`는 다음의 방법으로 구한다 :

```
diff = st2.dev - st1.dev
IF(diff>π)THEN
    ang = diff - 2π
ELSE IF (diff<-π) THEN
    ang = diff + 2π
ELSE
    ang = diff
ENDIF
```

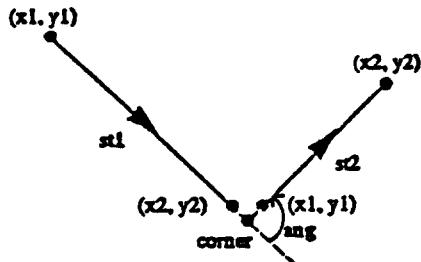


그림 1. 코너와 그의 파라메타

Fig 1. A corner and its parameters

2-2. 아크 검출

아크는 또 하나의 중요한 지역특징이다. 그러나, 아크 함수는 비선형이고 많은 파라메타를 요하므로 코너검출보다 훨씬 더 어렵다. 하나의 아크는 8개의 파라메타로 나타낼 수 있다: 반지름 R , 중심점 (X_c, Y_c) , 시점 (X_s, Y_s) , 종점 (X_e, Y_e) , 길이 L (그림 2 참조).

Perkins⁵⁾는 최소제곱오차법(least squares error criterion)을 기초로 한 아크 fitting 알고리즘을 개발

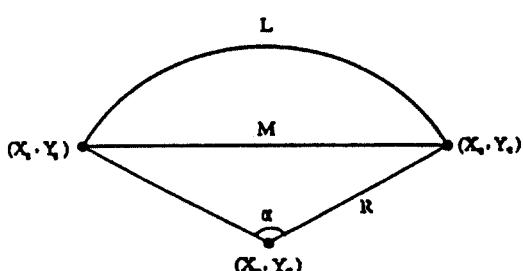


그림 2. 아크의 파라메타

Fig 2. Parameters of an arc

하였다. 하나의 아크를 다각형 근사화된 직선들에 fit시키기 위해, 아크와 직선들의 정점(vertex) 사이에 오차를 최소화해야 한다. 반지름이 R 이고 중심점이 (X_c, Y_c) 인 아크에 대한 식은 다음과 같이 나타낼 수 있다 :

$$(X - X_c)^2 + (Y - Y_c)^2 = R^2 \quad (1)$$

다각형 근사화된 직선들의 정점에 대한 좌표는 이미 알고 있으므로, 최소화 되어야 할 오차 함수는 다음과 같다 :

$$J = \sum_{i=1}^n [(X_i - X_c)^2 + (Y_i - Y_c)^2 - R^2]^2 \quad (2)$$

여기서 n 은 정점의 수이다. 식 (2)로부터, 다음 식들을 구할 수 있다.

$$\sum_{i=1}^n (X_i - X_c)^3 + \sum_{i=1}^n (Y_i - Y_c)^2 (X_i - X_c) - R^2 \sum_{i=1}^n (X_i - X_c) = 0 \quad (3)$$

$$\sum_{i=1}^n (X_i - X_c)^2 (Y_i - Y_c) + \sum_{i=1}^n (Y_i - Y_c)^3 - R^2 \sum_{i=1}^n (Y_i - Y_c) = 0 \quad (4)$$

$$\sum_{i=1}^n (X_i - X_c)^2 + \sum_{i=1}^n (Y_i - Y_c)^2 - nR^2 = 0 \quad (5)$$

위 세식들은 미지의 변수 X_c, Y_c, R 에 대해 Newton의 방법으로 풀 수 있다.

아크의 길이 L 을 구하기 위해 α 를 아크의 중심각, M 을 아크의 시점과 종점을 잇는 선의 길이라 하자. cosine법칙으로부터,

$$M^2 = 2R^2 - 2R^2 \cos \alpha$$

또는,

$$\alpha = \cos^{-1} \left[\frac{2R^2 - M^2}{2R^2} \right] \quad (6)$$

여기서,

$$M = \sqrt{(X_e - X_s)^2 + (Y_e - Y_s)^2}$$

이제, 아크의 길이 L 은 다음 식으로 주어진다.

$$L = \alpha \cdot R \quad (7)$$

2-3. 평행선 검출

인식 대상 물체의 외형에는 주로 평행선이 포함된 경우가 많다. 따라서, 평행선은 그들 물체의 중요한 특징 중의 하나가 될 수 있다. 본 연구에서는, 물체로부터 평행선을 검출하기 위해 두 직선의 병렬도(significance of parallelism), S_{par} 를 다음 식으로 정의 한다. :

$$S_{par} = C \cdot \left[\frac{1}{\theta \cdot d} \right] \left[\frac{l_2}{l_1} \right] \quad (8)$$

여기서, C 는 상수, θ 는 두 직선사이의 각차(angular difference), d 는 긴 직선으로부터 짧은 직선의 중점에 이르는 수직 거리, l_1 은 긴 직선의 길이, l_2 는 짧은 직선의 길이다. 이들 파라메타는 그림 3에 보인다. 식 (8)로부터, S_{par} 가 클수록 두 직선의 병렬도가 큼을 알 수 있다.

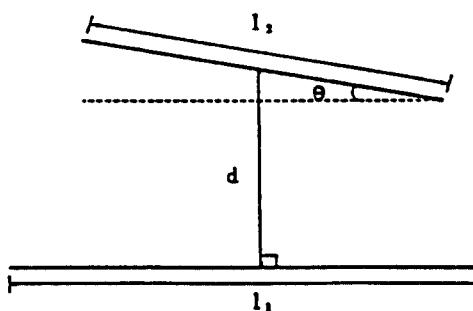


그림 3. 두 직선사이의 병렬도를 위한 파라메타
Fig 3. Parameters for the significance of parallelism between two lines

다각형 근사화된 직선들로부터 평행선을 검출하기 위해, 식 (8)을 이용하여 모든 두 직선 사이의 병렬도 S_{par} 를 계산한다. 만일 어떤 두 직선의 S_{par} 가 미리 정해진 임계값 이상이면 그 두 직선은 평행선이라 정의 한다. 평행선의 데이터 구조는 직선 1(st1), 직선 2(st2), 두 직선사이의 수직거리(d)로 구성된다. 여기서 직선 1은 두 직선중 길이가 긴 것을, 직선 2는 길이가 짧은 것으로 assign 한다. 또한 직선 1의 시점 및 종점의 좌표를 (x_{11}, y_{11}) 와 (x_{12}, y_{12}) 라 하고 직선 2의 시점 및 종점의 좌표를 (x_{21}, y_{21}) 와 (x_{22}, y_{22}) 라 하면, 두 직선 사이의 수직거리 d 는 다음 식으로 구할 수 있다.

$$d = \frac{|ax+by+c|}{\sqrt{a^2+b^2}} \quad (9)$$

여기서,

$$a = y_{11} - y_{12}, \quad b = x_{12} - x_{11}, \quad c = -ax_{11} - by_{11}, \\ x = (x_{21} + x_{22}) / 2, \quad y = (y_{21} + y_{22}) / 2 \text{이다.}$$

2-4. 코너-아크 검출

만일 아크와 코너가 한 물체안에 존재한다면, 그 정보들은 서로 결합되어 또 하나의 중요한 특징이 될 수 있다. 예를 들면, 코너의 각, 아크의 반지름, 코너 점으로부터 아크의 중심점까지의 거리 등은 하나의 특징 정보로서 결합될 수 있다. 이와 같은 특징정보들은 물체가 이동되거나 회전되어도 불변이다. 본 연구에서는, 이러한 새로운 특징을 “코너-아크”라 부른다.

코너-아크를 검출하기에 앞서, 코너 검출과 아크 검출이 선행되어야 한다. 만약, 아크가 검출되었다면 작은 코너각을 갖는 코너를 수색하여 아크와 코너를 상호 결합하여 필요한 파라메타를 구한다. 코너-아크 특징을 검출하기 위해, 작은 코너각을 갖는 코너만을 사용하는 이유는 모든 코너와 아크를 결합할 경우 코너-아크의 수가 방대해져 정합과정에서 처리시간의 증가를 초래하기 때문이다. 또한, 작은 코너각을 갖는 코너, 즉 물체의 뾰족한 부분은 그 물체를 표현하는 중요한 특징이 될 것이다. 코너-아크의 데이터 구조는 코너점(x, y), 아크의 중심점(x_c, y_c), 코너각(ang), 코너점으로부터 아크중심점 까지의 거리(r)로 구성된다 (그림 4 참조)

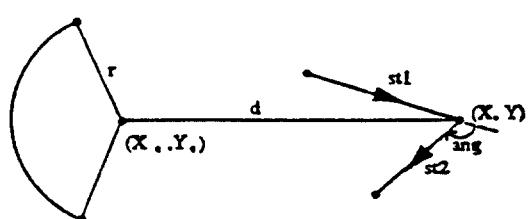


그림 4. 코너-아크의 파라메타
Fig 4. Parameters of a corner-arc

III. 정합 및 검증

대부분의 산업용 비전 시스템은 지식베이스(knowledge-base) 시스템이고 정합단계에서 가설·검정(hypothesis-test) 전략을 주로 사용한다. 가설 설정(hypothesis generation) 단계에서는, 몇개의 물체들에 대한 종류 및 위치들이 가정되고, 반면 가설 검정 단계에서는, 가정된 물체들이 입력화상에 존재하는 물체들과 정합되는지를 확인함으로써 그 가설이 검정된다.

입력화상에 존재하는 물체들에 대한 종류 및 위치를 가설하는 방법에는 두 가지가 있다: 모델 구동법(model-driven)과 데이터 구동법(data-driven)⁽¹⁰⁾. 모델 구동법에서는, 가설을 설정하기 위하여 각 모델의 모든 특징들이 입력화상으로부터 추출된 특징들에 차례로 비교된다. 이 방법은 '과도한 검색과정'이 요하므로 실행시간 측면으로 볼 때 단점을 갖고 있다. 따라서, 모델 구동법은 모델물체의 수가 많을 때는 부적합하다. 한편, 데이터 구동법에서는, 어느 물체들이 입력화상에 존재하는지를 가설하기 위해 입력화상으로부터 추출된 특징들과 유사한 특징들을 지식베이스로부터 수색한다. 따라서, 데이터 구동법이 모델 구동법에 비해 효율적이다. 본 연구에서는 데이터 구동법을 사용한다.

3-1. 가설 설정 및 정합

일단, 모델물체의 화상으로부터 확장된 지역특징이 추출되면, 그 모델물체는 추출된 특징들로 모델링된다. 모델물체에 대한 지식베이스는 물체의 이름, 각 종류별 특징의 수, 특징 데이터 등을 포함한다. 지식베이스의 구조도 그림 5에 보인다. 또한, 입력화

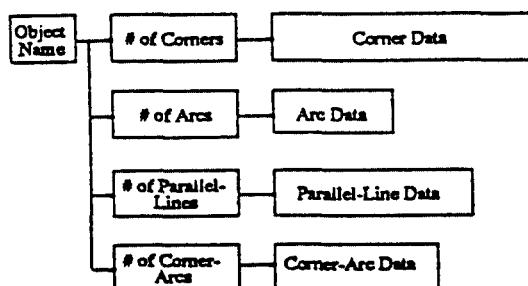


그림 5. 지식베이스의 구조도

Fig 5. Structure of the knowledge-base

상에 있는 물체를 인식하기 위해, 입력화상으로부터 특징추출과정이 수행되고, 지식베이스 수색을 통해 하나 또는 그 이상의 물체가 가설된다.

본 연구에서 사용되는 물체들이 견고하여 외형이 변형되지 않는다면, 특징들의 파라메타 값중 몇몇은 회전(rotation) 및 이동(translation)에 불변하다. 예를 들면, 코너의 경우, 두 직선 사이의 각이나 두 직선의 길이는 물체가 회전되거나 이동되어도 변하지 않는다. 따라서, 물체를 정합하기 위해 특징 유형 별로 모델특징과 입력화상특징 사이에 유사성을 조사한다. 유사성 조사를 위해, 본 연구에서는 거리 함수(distance function)을 이용한다.

CC, AA, PP, EE를 각각 코너, 아크 평행선, 코너-아크들 사이의 유사성이라 정의하면, 각 유사성은 다음 식으로 주어진다:

1) 코너 대 코너 :

$$\begin{aligned} CC = & [C_1(\alpha_i - \alpha_m)^2 + C_2(1_{ii} - 1_{im})^2 \\ & + C_3(1_{2i} - 1_{2m})^2]^{1/2} \end{aligned} \quad (10)$$

2) 아크 대 아크 :

$$AA = [A_1(L_i - L_m)^2 + A_2(R_i - R_m)^2]^{1/2} \quad (11)$$

3) 평행선 대 평행선 :

$$\begin{aligned} PP = & [P_1(d_i - d_m)^2 + P_2(1_{ii} - 1_{im})^2 \\ & + P_3(1_{2i} - 1_{2m})^2]^{1/2} \end{aligned} \quad (12)$$

4) 코너-아크 대 코너-아크 :

$$\begin{aligned} EE = & [E_1(\alpha_i - \alpha_m)^2 + E_2(r_i - r_m)^2 \\ & + E_3(d_i - d_m)^2]^{1/2} \end{aligned} \quad (13)$$

여기서, $C_1, C_2, C_3, A_1, A_2, P_1, P_2, E_1, E_2, E_3$ 는 상수이다. 만약 유사성 함수값이 임계값 이하이면, 그 모델특징과 그에 대응되는 입력화상특징은 서로 유사하다고 정의하고, 그 유사한 특징 set으로부터 기하변환(geometric transform)을 유도한다.

3-2. 기하변환

기하변환은 모델특징의 좌표를 입력화상특징의 좌표로 사상(mapping)한다. θ 와 (t_x, t_y) 를 회전각 및 x, y 축으로의 이동 좌표라 하고, (M_{xi}, M_{yi}) 와 (I_{xi}, I_{yi}) 를 모델특징과 입력화상특징의 한 점의 좌표라 하면, 기하변환 (θ, t_x, t_y) 는 모델의 한 점 (M_{xi}, M_{yi}) 를 각 θ 만큼 회전시키고, x, y 축 방향으로 (t_x, t_y) 만큼 이

동시켜, 변환된 모델점을 화상점에 정합시킨다. 이과정은 다음과 같은 매트릭스 형태의 식으로 나타낼 수 있다.

$$[I_{xi} \ I_{yi}] = [M_{xi} \ M_{yi}] \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} + [t_x \ t_y] \quad (14)$$

위 식을 I_{xi} 와 I_{yi} 에 대해, 풀면, 다음의 두 식이 얻어진다.

$$I_{xi} = M_{xi} \cos\theta - M_{yi} \sin\theta + t_x \quad (15)$$

$$I_{yi} = M_{xi} \sin\theta + M_{yi} \cos\theta + t_y \quad (16)$$

여기서, Q_1 과 Q_2 를 다음과 같이 정의하자.

$$Q_1 = \sum_{i=1}^n (I_{xi} - M_{xi} \cos\theta + M_{yi} \sin\theta - t_x)^2 \quad (17)$$

$$Q_2 = \sum_{i=1}^n (I_{yi} - M_{xi} \sin\theta + M_{yi} \cos\theta - t_y)^2 \quad (18)$$

여기서 n 은 특징소(feature segment)를 따라 취한 점의 갯수이다. Q 를 Q_1 과 Q_2 의 합이라 정의하면, 즉,

$$Q = Q_1 + Q_2 \quad (19)$$

Q 는 화상점과 변환된 모델점들 사이의 제곱오차(squared error)들의 합이므로 최소가 되어야 한다. 다시 말하면,

$$\frac{\partial Q}{\partial t_x} = 0, \quad \frac{\partial Q}{\partial t_y} = 0, \quad \frac{\partial Q}{\partial \theta} = 0 \quad (20)$$

위의 조건으로부터, t_x , t_y , θ 에 대한 식들을 유도할 수 있다.

$$t_x = \frac{1}{n} \left[\sum_{i=1}^n I_{xi} - \cos\theta \sum_{i=1}^n M_{xi} + \sin\theta \sum_{i=1}^n M_{yi} \right] \quad (21)$$

$$t_y = \frac{1}{n} \left[\sum_{i=1}^n I_{yi} - \sin\theta \sum_{i=1}^n M_{xi} + \cos\theta \sum_{i=1}^n M_{yi} \right] \quad (22)$$

$$\theta = \tan^{-1} \quad (23)$$

$$\left[\frac{-n \sum_{i=1}^n I_{xi} M_{yi} + \sum_{i=1}^n I_{xi} \sum_{i=1}^n M_{yi} + n \sum_{i=1}^n I_{yi} \sum_{i=1}^n M_{xi} - \sum_{i=1}^n I_{yi} \sum_{i=1}^n M_{xi}}{n \sum_{i=1}^n I_{xi} M_{xi} - \sum_{i=1}^n I_{xi} \sum_{i=1}^n M_{xi} + n \sum_{i=1}^n I_{yi} \sum_{i=1}^n M_{yi} - \sum_{i=1}^n I_{yi} \sum_{i=1}^n M_{xi}} \right]$$

만일, 입력화상에 있는 물체와 모델물체가 정합되

었다면, 기하변환은 같거나 유사한 기하변환 계수를 갖는 하나의 그룹 또는 클러스터(cluster)를 생성할 것이다. 이러한 클러스터된 기하변환을 수색하여 클러스터의 중심을 그 물체의 정합을 위한 최종 기하변환으로 설정한다. 본 연구에서는, 클러스터를 수색하기 위해 maximin-distance algorithm을 이용한다.

3-3. 가설 검증

기하변환과 클러스터 수색과정을 통해 회전각 θ 와 이동 좌표 (t_x , t_y)를 구한 다음, 가설 검증을 위해 모델물체의 각 점들을 θ 만큼 회전시키고 (t_x , t_y)만큼 이동시킨다. (M_{xi}^T , M_{yi}^T)를 기하변환된 모델물체의 한 점이라면, 이 과정은 다음 식으로 나타낼 수 있다.

$$[M_{xi}^T \ M_{yi}^T] = [M_{xi} \ M_{yi}] \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} + [t_x \ t_y] \quad (24)$$

또는,

$$M_{xi}^T = M_{xi} \cos\theta - M_{yi} \sin\theta + t_x \quad (25)$$

$$M_{yi}^T = M_{xi} \sin\theta + M_{yi} \cos\theta + t_y \quad (26)$$

정합을 확인하기 위해, 기하변환된 모델점 M^T 는 입력 화상 위에 포개지고 각각의 기하변환된 모델점들에 위치한 입력화상 화소(pixel)들이 물체의 영역에 속한 화소인지를 확인한다. 만일 물체의 영역에 속한 화소라면, “정합”되었다고 정의한다. 정합율(matching ratio) R_m 은 다음 식으로 정의한다:

$$R_m = \frac{\text{정합된 점의 수}}{\text{모델 점의 수}} \times 100(%) \quad (27)$$

만일 정합율이 일정값 이상이면 그 가설은 받아들여지고, 그렇지 않으면 거부된다.

IV. 실험 및 고찰

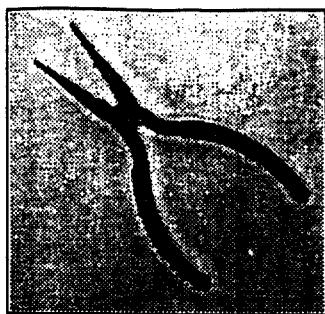
확장된 지역특성을 이용한 중첩된 물체인식 알고리즘이 hypercube구조를 갖는 다중처리 컴퓨터에서 프로그래밍 언어 C로 구현되고 실험되었다. 실험은 두 단계로 나누어서 실행되었다. 첫번째 실험에서는 3개의 공구를 사용했다: adjustable wrench, long

nose plier, Allen Wrench. 각 모델 물체의 화상은 그림 6에, 중첩된 물체들의 화상은 그림 7에 각각 보인다. 각 화상의 크기는 512×512 이다. 그림 7에서, 세 물체들은 임의로 회전되고 이동되어 중첩되었다.

먼저, 모델물체의 화상에 9×9 Laplacian of Gaussian 연산자를 콘벌루션하고 영교차점을 찾아 각 모델물체의 윤곽선을 검출한 다음, 다각형 근사화 법을 이용하여 윤곽선으로부터 직선들을 추출하였다. 그 다음, 추출된 직선들로부터 확장된 지역특징을 추출하여 지식베이스를 구축하였다. 각 화상들로부터 추출된 특징들의 수가 표 1에 주어진다.



(a)



(b)



(c)

그림 6. 모델 물체들의 화상

Fig 6. Images of model objects

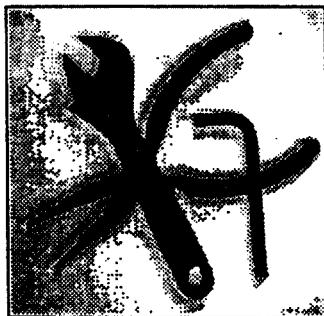


그림 7. 중첩된 물체들의 화상
Fig 7. Image of overlapped objects

표 1. 각 화상들로부터 추출된 특징들의 수

Table 1. Number of features extracted from each image

화상	코너	아크	평행선	코너-아크
Adjustable wrench	27	1	3	2
Long nose plier	38	8	7	14
Allen wrench	9	0	2	0
Overlapped objects	67	6	11	36

정합을 위해, 모델물체로부터 추출된 특징들과 입력화상으로부터 추출된 특징들 사이에 유사성을 비교하여, 유사성을 갖는 특징 set으로부터 식 (21), (22), (23)을 이용하여 기하변환 (θ, t_x, t_y)를 계산하였다. maximin-distance algorithm을 이용하여 기하변환들의 클러스터를 수색한 다음 가장 많은 원소를 갖는 클러스터의 중심을 그 정합을 위한 최종 기하변환으로 하였다. adjustable wrench, long nose plier, Allen wrench에 대한 최종 기하변환은 $(0.46, 63.8, -92.1), (-1.35, -9.2, 433.6), (0.61, 268.3, -80.7)$ 이었다. 정합을 검증하기 위해, 모델물체의 윤곽선을 θ 만큼 회전시키고 (t_x, t_y) 만큼 이동시킨 다음, 입력화상으로부터 추출된 윤곽선 위에 중첩시켰다(그림 8 참조). 그림 9로부터, 세물체가 모두 정합되었음을 알 수 있다.

확장된 지역특징을 이용한 물체인식 방법의 성능을 기존방법과 비교하기 위해, 단일 특징만을 사용할 때의 정합율과 확장된 지역특징을 사용할 때의 정합율을 비교하였다(표 2 참조). 단일 특징만을 사용한 경우, 특징수의 부족으로 정합율이 떨어지거나 전혀

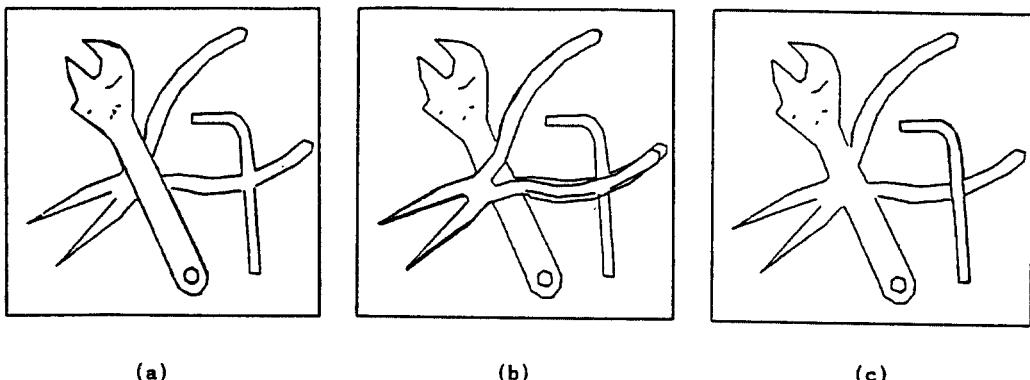


그림 8. 정합에 대한 검증
Fig 8. Verification of the matching

표 2. 정합율의 비교

Table 2. Comparisons of matching ratios

물체	코너만 사용	아크만 사용	평행선만 사용	확장된 지역 특징 사용
Adjustable wrench	95.7%	No match	89.5%	97.5%
Long nose plier	86.2%	86.5%	87.1%	87.6%
Allen wrench	No match	No match	No match	90.3%

정합되지 않는 경우가 발생 하였다. 이 결과로부터 확장된 지역특징이 정합율을 높이고 전체적인 인식율을 높임을 알 수 있다.

두번째 실험에서는, 10개의 서로 다른 공구들을 이용하여 20개의 입력화상을 만들어 실험하였다. 각 화상은 3개에서 5개 까지의 서로 다른 공구들이 무작위로 선택되어 회전, 이동된 후 서로 중첩되었다. 20개의 화상에 총 74개의 물체가 포함되었다(3.7개 / 화상). 평균 중첩율은 35.8% 이었다. 단일 특징만을 사용한 경우와 확장된 지역특징을 사용한 경우의 정가설율(ratios of correct hypothesis)과 정인식율(ratios of correct recognition)을 표 3에 나타내었다. 그림 9는 입력화상의 한 예와 정합결과를 보인다.

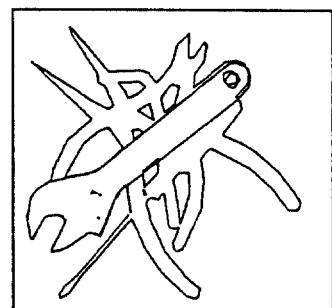
표 3. 정가설율과 정인식율의 비교

Table 3. Comparisons of ratios of correct hypothesis and ratios of correct recognition

	코너만 사용	아크만 사용	평행선만 사용	확장된 지역 특징 사용
정가설율	80.9%	64.6%	73.2%	82.5%
정인식율	75.1%	53.7%	64.4%	77.0%



(a)



(b)

그림 9. 입력화상의 한 예와 정합결과

Fig 9. An example of input image and matching result

V. 결 론

본 연구에서는 확장된 지역특징을 이용한 새로운 물체인식 방법을 제안하였다. 먼저 Laplacian of Gaussian 연산자를 화상에 콘벌류션하고 영교차점을 검출하여 물체의 윤곽선을 추출한다음, 다각형 근사화법을 이용하여 윤곽선을 직선들로 변환하고, 변환된 직선들로부터 코너, 아크, 평행선 및 코너-아크로 구성된 지역특징을 추출하였다. 지식베이스를 구축하기 위해, 모든 모델물체의 영상들로부터 확장된 지역특징을 추출하였다.

물체의 정합을 위해, 입력 화상으로부터 추출된 특징들과 지식베이스의 특징들 사이에 유사성을 비교하여, 유사성을 갖는 특징 set으로부터 기하변환 파라메타(θ , t_x , t_y)를 계산하고 maximin-distance algorithm을 이용하여 기하변환 파라메타들의 클러스터를 수색한 다음, 클러스터의 중심을 최종 기하변환으로 하였다. 정합을 검증하기 위해, 모델 물체의 윤곽선을 θ 만큼 회전시키고 (t_x , t_y)만큼 이동시킨 다음, 입력 화상으로부터 추출된 윤곽선 위에 포개어 정합율을 측정하였다.

산업용 공구를 이용한 실험에서, 제안된 물체인식 방법을 통해 서로 중첩된 물체를 성공적으로 인식할 수 있었고, 또한 제안된 물체인식 방법이 기존의 방법에 비해 인식율과 정확도를 높인다는 것을 확인하였다. 그러나, 제안된 방법의 문제점으로는, 화상으로부터 추출할 특징수의 증가로, 지식베이스를 수색하는 시간이 길어진다는 단점이 지적된다. 따라서, 확장된 지역특징 추출에 대한 처리속도 증대와 보다 효율적인 지식베이스 수색 알고리즘 개발에 대한 연구가 필요하다.

참 고 문 헌

1. Paul J. Besl and Ramesh C. Jain, "Three-Dimensional Object Recognition," Computing Surveys, Vol. 17, No. 1, pp.75-145, March 1985.
2. Mark W. Koch and R. L. Kashyap, "A Vision System to Identify Occluded Industrial Parts," IEEE International Conference on Robotics and Automation, pp.55-60, 1985.
3. Nicholas Ayache and Olivier D. Faugeras, "HYPER: A New Approach for the Recognition and Positioning of Two-Dimensional Objects," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-8, No. 1, pp.44-54, January 1986.
4. P. Rummel and W. Beutel, "Workpiece Recognition and Inspection by a Model-Based Scene Analysis System," Pattern Recognition, Vol. 17, No. 1, pp.141-148, 1984.
5. W. A. Perkins, "A Model-Based Vision System for Industrial Parts," IEEE Transaction on Computers, Vol. C-27, No. 2, pp.126-143, February 1978.
6. Mark W. Koch and Rangasami L. Kashyap, "Using Polygons to Recognize and Locate Partially Occluded Objects," IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. PAMI-9, No. 4, pp.483-494, July 1987.
7. Wei Li and Nasser M. Nasrabadi, "Object Recognition Based on Graph Matching Implemented by a Hopfield-Style Neural Network," Proceedings of International Joint Conference on Neural Network, Vol. II, pp.287-290, 1989.
8. D. Marr and E. Hildreth, "Theory of Edge Detection," Proceedings of Royal Society of London, B, Vol. 207, pp.187-217, 1980.
9. David G. Lowe, "Three-Dimensional Object Recognition from Single Two-Dimensional Images," Artificial Intelligence, Vol. 31, 1987, pp.355-395.
10. Rajiv Mehrotra, Fu K. Kung, and William I. Grosky, "Industrial Part Recognition Using a Component-Index," Image and Vision Computing, Vol. 8, No. 3, pp.225-232, August 1990.



白 重煥(Joong Hwan Baek) 正會員

1959년 6월 28일생

1981년 2월 : 한국항공대학 통신공
학과 졸업(공학사)

1987년 7월 : 미국 Oklahoma State
University 전기공학
과(공학석사)

1991년 7월 : 미국 Oklahoma State
University 전기공학
과(공학박사)

1991년 9월 ~ 1992년 2월 : 한국전자통신연구소 ISDN용용
연구실 선임연구원

1992년 3월 ~ 현재 : 한국항공대학 통신정보공학과 전임강
사

※주요관심분야 : 영상처리, 패턴인식, 로보트 시각, 신경
회로망 등