

論文98-35S-6-12

물체 정합을 위한 특징점 추출 및 물체 표현에 관한 연구

(A study on the salient points detection and object representation for object matching)

朴廷珉*, 孫光薰**, 許榮***

(Jeong Min Park, Kwang Hoon Sohn, and Young Huh)

요 약

물체를 인식하기 위한 효율적인 방법 중의 하나는 물체의 경계선에서 가장 적절한 특징들을 추출해 내어 인식에 사용하는 것이다. 본 논문에서는 경계선 위의 각 화소에서 주변 화소들과의 관계를 이용해 코너점, 접점, 변곡점을 추출하여 물체의 특징점으로 사용하였다. 기존에 주로 사용되던 중요한 특징점의 하나인 코너점은 곡률 함수상에서 찾고, 또한 물체가 직선과 곡선으로 이루어져 있을 경우 코너점만으로 물체를 표현하기에 부족하므로 곡률 함수를 미디안 필터링하여 양자화 잡음을 제거함으로써 접점과 변곡점을 찾는 새로운 방법을 제안하였다. 그리고 이 세 가지 특징점을 물체 정합의 요소로 사용하여 물체를 정합하였다. 정합 방법으로는 Discrete Hopfield Neural Network을 사용하였으며, 성능 분석 결과 곡선이 섞인 물체에서 코너점만으로 물체를 정합한 경우보다 특징점으로 물체를 정합한 경우 우수한 정합 성능을 나타내었다.

Abstract

An efficient approach to recognize occluded objects is to detect a number of essential features on the boundary of the unknown shape. The salient points including corner points, tangential points and inflection points are detected by the relation of neighboring pixels of each pixel on the boundaries. Corner points are usually detected in the curvature function and tangential points and inflection points are detected by median filtering the curvature function to avoid the effect of quantization noise as corner points is not sufficient to represent an object with lines and arcs. Then, these salient points are used as features for object matching. Discrete Hopfield Neural Network is used for object matching. Experimental results show that the matching result using salient points is better than those of using corner points only when an object consists of lines and arcs.

I. 서 론

부분적으로 가려진 물체를 인식하는 것은 산업 자동화와 군사 응용 등에서 매우 중요한 문제이다. 이런 상황에서 물체를 인식하기 위해서는 물체의 전체적인

특징들을 인식 요소로 사용할 수 없고 물체의 부분적인 특징점들을 물체 인식의 요소로 사용하여야 한다.

따라서 한 영상에서 물체의 특징점들을 추출해 내는 것은 컴퓨터 비전, 패턴 인식 분야에서 매우 중요한 일이다.^[1-3] 중요한 특징점의 하나인 코너점은 물

* 正會員, LG電子 멀티미디어 研究所
(Multimedia Research Lab., LG Electronics)

** 正會員, 延世大學校 電波工學科
(Dept. of Radio Science & Eng., Yonsei Univ.)

*** 正會員, 韓國電氣研究所 情報通信研究팀
(Power Telecommunication Lab., Korea Electrotechnology Research Institute)

接受日字: 1998年1月23日, 수정완료일: 1998年5月4日

체모양에 대한 정보를 가장 많이 가지고 있으므로 물체 표현, 해석, 인식에 가장 중요한 특징점으로 사용되고 있다.

본 논문에서는 물체의 경계선을 추출하여 한 경계선 화소에 대하여 이웃하는 화소들에 서로 다른 가중치를 부여하여 양자화 오류에 강인하고 정확한 코너점의 위치와 각도를 찾는 알고리즘을 제시한다. 또한, 실제로 물체가 직선 뿐만 아니라 곡선으로도 이루어져 있을 경우 코너점만으로는 물체를 표현하고 정합하기에 부족하므로 접점과 변곡점을 찾아 코너점과 함께 특징점으로 사용한다. 구해진 곡률 함수는 경계선 화소들이 양자화 오류로 인하여 매우 잡음이 심하므로 미디안 필터링을 한후 직선과 곡선의 특징을 이용하여 접점과 변곡점을 추출한다. 그리고 이러한 특징점들을 잇는 선을 직선과 곡선으로 근사화하여 물체를 표현한다.

물체 정합 방법으로는 신경망의 한 종류인 Discrete Hopfield Network(DHN)을 사용하였다. 신경망은 병렬 처리를 함으로써 빠른 처리 속도를 가지며 많은 노드를 사용함으로써 오류에 강인한 특성을 가지므로 여러 분야에서 응용되고 있다.^[4-5] 특히, Hopfield 신경망은 최적화 문제를 풀 수 있는 특성을 가지므로 물체 정합에 자주 사용된다.^[6-8] 제안된 방법으로 추출한 특징점들의 각도와 각 특징점들 사이의 거리가 DHN의 뉴런들 사이의 연결 강도를 결정하는데 사용되며 물체 정합 과정을 수행하게 된다.

물체에 곡선이 포함되어 접점과 변곡점이 존재할 경우에는 특징점으로 정합한 경우가 코너점만으로 정합한 경우보다 우수한 성능을 나타낸다. 특히 물체의 코너점들이 많이 가려져 있을 경우나 물체에 코너점이 적게 존재할 때는 코너점으로는 정합하기가 불가능하므로 특징점으로 정합할 경우 월등히 좋은 성능을 나타낸다.

본 논문의 전체적인 구성은, II장에서 물체의 특징점을 추출 및 물체 표현 방식을 제안하고, 제 III 장에서 DHN으로 특징점들을 이용하여 물체를 정합하는 과정을 설명한다. IV장에서는 시뮬레이션을 통해 정합 성능을 보여주고, 마지막으로 V장에서는 결론을 맺는다.

II. 특징점 추출 및 물체 표현

1. 코너점 추출

한 영상에서 물체를 추출한 후 그 물체의 경계선

위에 존재하는 n 개의 화소들의 집합을 P 라 하면,

$$P = \{p_i = (x_i, y_i), i = 1, 2, \dots, n\} \quad (1)$$

여기서, p_{i-1} 과 p_{i+1} 은 p_i (modulo n)와 인접한 주변 화소를 나타낸다. 각 화소들을 기준으로 순방향 주변 화소(F_i)와 역방향 주변화소(B_i)를 고려하여 각 화소에서의 곡률값을 구하게 된다. 그림 1은 한 화소(p_i)에 대한 순방향, 역방향 주변 화소를 보인 것이다. 여기서 순방향이란 반시계방향이고, i 번째 화소에서의 F_i 와 B_i 는 다음과 같다.

$$F_i = \{p_{i+1}, p_{i+2}, \dots, p_{i+u}\}, B_i = \{p_{i-1}, p_{i-2}, \dots, p_{i-u}\} \quad (2)$$

여기서, u 는 각도를 고려하는 주변 화소의 길이이고 본 논문에서는 실험적으로 u 가 8일 때 가장 좋은 성능을 나타내어 u 는 8로 사용하였다.





그림 1. 물체 경계선에서 한 화소(p_i)에 대한 주변 화소들

Fig. 1. Neighbor pixels for a pixel (p_i) on the boundary.


각 화소에서의 각도를 구하기 위해서는 먼저 x 축을 기준으로 순방향 각도와 역방향 각도를 구한다. 양 방향의 각도를 구하기 위해 주변 화소들의 좌표는 다음 식과 같이 변환된다.

$$\begin{bmatrix} x'_j \\ y'_j \end{bmatrix} = \begin{bmatrix} x_j \\ y_j \end{bmatrix} - \begin{bmatrix} x_i \\ y_i \end{bmatrix} \quad (3)$$

그림 2는 식(3)에 순방향 화소들의 변환과 역방향 화소들의 변환을 나타낸다.



(a) 순방향 주변 화소들의 변환



(b) 역방향 주변 화소들의 변환

그림 2. 한 화소(p_i)에 대한 주변 화소들의 변환
Fig. 2. Transformation of neighbor pixels for a pixel p_i .

각도를 계산할 때는 경계선의 양자화 오류의 영향을 받지 않기 위해 한 화소(p_i)로부터 멀리 있는 주변 화소들에 가중치를 더 주어 평균을 구한다. 식(4)는 위의 방법으로 순방향과 역방향의 좌표값들의 가중치 평균을 구한 것이다.

$$\begin{aligned} Sx_{Fi} &= \frac{1}{u} \sum_{k=1}^u k \times x_{i+k} & Sx_{Bi} &= \frac{1}{u} \sum_{k=1}^u k \times x_{i-k} \\ Sy_{Fi} &= \frac{1}{u} \sum_{k=1}^u k \times y_{i+k} & Sy_{Bi} &= \frac{1}{u} \sum_{k=1}^u k \times y_{i-k} \end{aligned} \quad (4)$$

위의 식을 이용하여 순방향 각도(θ_{Fi})와 역방향 각도(θ_{Bi})를 계산하면

$$\theta_{Fi} = \tan^{-1}\left(\frac{Sy_{Fi}}{Sx_{Fi}}\right), \quad \theta_{Bi} = \tan^{-1}\left(\frac{Sy_{Bi}}{Sx_{Bi}}\right) \quad (5)$$

이며, 각도의 범위는 $0^\circ \leq \theta_{Fi}, \theta_{Bi} \leq 360^\circ$ 이다.

화소 p_i 에서의 각도(Ψ_i)는 아래 식과 같이 정의하여 예약에서는 0° 에서 180° 사이의 각을 갖고 둔가에서는 -0° 에서 -180° 사이의 각을 갖도록 한다.


$$\Psi_i = \begin{cases} \theta_{Bi} - \theta_{Fi}, & \text{if } -180^\circ \leq \theta_{Bi} - \theta_{Fi} \leq 180^\circ \\ 360^\circ - (\theta_{Bi} - \theta_{Fi}), & \text{if } \theta_{Bi} - \theta_{Fi} > 180^\circ \\ 360^\circ + (\theta_{Bi} - \theta_{Fi}), & \text{if } \theta_{Bi} - \theta_{Fi} < -180^\circ \end{cases} \quad (6)$$

화소 p_i 에서 각도가 작을수록 p_i 는 코너의 성질을 크게 갖는다. 따라서 코너의 성질이 클수록 큰 값을 갖는 곡률 함수를 정의한다. 화소 p_i 에서의 곡률 함수(x_i)는 다음과 같다.


$$x_i = \begin{cases} 180 - \Psi_i, & \text{if } 0^\circ \leq \Psi_i \leq 180^\circ \\ -180 + \Psi_i, & \text{if } -180^\circ \leq \Psi_i \leq 0^\circ \end{cases} \quad (7)$$

코너점은 곡률 함수에서 $|x_i|$ 가 30 이상인 극점으로 정의한다. 그림 3은 니퍼의 경계선을 추출한 후 각 경계선 화소에 대한 곡률 함수를 구한 후 그 것을 이

용하여 니퍼의 코너점을 찾아 경계선에 표시한 것이다.



(a) 니퍼의 곡률 함수



(b) 니퍼의 코너점


그림 3. 니퍼의 곡률 함수와 코너점
Fig. 3. Curvature and corner points of a nipper.

2. 접점 및 변곡점 추출

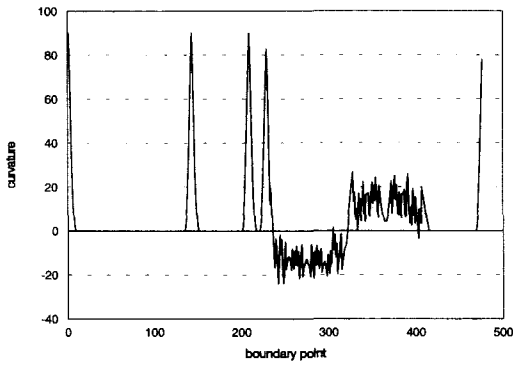
물체가 직선뿐만 아니라 곡선으로도 이루어져 있을 경우 코너점만으로는 물체를 표현하기에 부족하다. 따라서 본 논문에서는 코너점 이외에도 곡선과 직선이 섞인 물체에서 자주 나타나는 접점과 변곡점을 물체의 특징점으로 사용한다. 접점은 직선과 곡선이 만나는 점이고 변곡점은 convex와 concave 곡선이 만나는 점이다. 이 두 점을 찾기 위해서는 먼저 이산적인 곡률 함수를 미디안 필터링을 하여 충격 잡음들을 제거한다. 필터링 되어진 곡률 함수에서 접점과 변곡점에서 나타나는 특성을 고려하여 식(8)과 식(9)와 같은 조건을 정하였다. 접점이 나타나는 경우는 식(9)과 같은 네 가지 경우이다. 역방향으로 직선이고 순방향으로 convex나 concave인 경우와 역방향으로 convex나 concave이고 순방향으로 직선인 경우이다. 변곡점이 나타나는 경우는 역방향과 순방향이 각각 convex, concave이거나 concave, convex인 경우이다. 고려하는 이웃 화소들의 간격은 앞, 뒤로 각각 $2u$ 씩 고려하여 찾는다. 변곡점들의 집합을 I , 접점들의 집합을 T 라 하면, I 와 T 에 속하는 화소들은 다음과 같은 조건에 의해 결정된다.

$$I \ni p_i, \begin{cases} \text{if } \forall x_{i-n} \in [0, 30], x_{i+n} \in [-30, 0] \\ \text{if } \forall x_{i+n} \in [0, 30], x_{i-n} \in [-30, 0] \end{cases} \quad (8)$$


$$T \ni p_i, \begin{cases} \text{if } \forall x_{i-n} = 0, x_{i+n} \in [0, 30] \\ \text{if } \forall x_{i-n} = 0, x_{i+n} \in [-30, 0] \\ \text{if } \forall x_{i+n} = 0, x_{i-n} \in [0, 30] \\ \text{if } \forall x_{i+n} = 0, x_{i-n} \in [-30, 0] \\ n = 1, 2, \dots, 2u \end{cases} \quad (9)$$



(a) 물체의 특징점들
(X:코너점, □:접점 및 변곡점)



(b) 물체의 곡률 함수



(c) 물체의 필터링된 곡률 함수

그림 4. 물체의 특징점 추출

Fig. 4. Salient points detection of an object.

그림 4 (a)는 제안방식으로 찾은 물체에 대한 특징점들을 보여주며, (b)는 곡률 함수를 보여준다. 곡률 함수는 매우 잡음이 심하므로 접점과 변곡점을 추출할


수 없다. 따라서, (c)는 이러한 잡음을 제거하기 위해 곡률 함수를 미디안 필터링 한 것이다.

3. 물체 표현

위에서 찾은 특징점들을 가지고 물체를 표현하기 위해서는 먼저 각 점들을 잇는 선들이 직선인지 곡선인지를 결정해야 한다. 이를 결정하기 위해 인접한 두 특징점을 직선으로 연결하고 두 특징점 사이의 경계선 위에 m 개의 화소들이 존재한다고 가정한다. 한 특징점으로부터 i 번째 화소에서 직선까지의 거리는 $d(i)$ 이고 양수와 음수 값을 가진다. $d(i)$ 는 직선을 기준으로 위에 존재하면 양수, 아래에 존재하면 음수 값을 가진다. 거리의 합(D)은 다음식과 같다.

$$D = \sum_{i=0}^m d(i) \quad (10)$$

그리고 두 특징점 사이의 거리를 N 라 하여 D/N 의 절대값이 임계값 이하이면 직선으로 근사화하고 임계값 이상이면 spline 방법을 이용하여 곡선으로 근사화하여 나타낸다. 본 논문에서는 실험적으로 임계값을 2로 정하였다. 그림 5는 이와 같은 방법으로 물체를 직선과 곡선으로 근사화한 물체의 경계선이고, 점선은 원 물체의 경계선을 나타낸 것이다.



(a) 니퍼의 근사화

(b) 겹쳐진 물체의 근사화

그림 5. 직선과 곡선으로 근사화한 물체

Fig. 5. Object representation using lines and arcs.

III. DHN을 이용한 물체 정합

DHN은 Hopfield 신경망의 원래 모델이고 빠른 처리 속도를 가지고 적용하기 쉬운 장점이 있다. 물체 정합을 위해 2-D DHN을 사용하였으며, 행렬에서 열은 모델 물체의 노드이고 행은 입력 물체의 노드이다. 다음과 같은 에너지 함수를 최소화 함으로써 정합 과

정을 수행하게 된다.

$$E = -\frac{A}{2} \sum_i \sum_j \sum_k \sum_l C_{ijkl} V_{ik} V_{jl} \quad (11)$$

$$+ \frac{B_1}{2} \sum_i \sum_k \sum_{l \neq k} V_{ik} V_{il} + \frac{B_2}{2} \sum_k \sum_i \sum_{j \neq i} V_{ik} V_{jl}$$

여기서, V_{ik} 는 이진 값을 갖고, 입력 물체의 i 번째 노드와 모델 물체의 k 번째 노드가 정합될 때 1이 되고 아니면 0이다. 식(11)에서 첫 번째 항은 노드 간의 관계를 제약하고 두 번째와 세 번째 항은 각 행과 각 열의 합이 각각 1 이하가 되어야 한다는 제약이다. 에너지 함수에서 물체가 가려져 있을 때 반드시 행과 열이 일대일로 정합되는 것이 아니므로 에너지 함수에서 $\sum_i \sum_k (1 - V_{ik})^2$ 항의 제약은 제외시켰다.^[9-11] 적절한 균을 얻는데 A_1 이 B_1 과 B_2 보다 큰 영향을 미치므로 A_1 을 B_1 과 B_2 보다 크게 놓는다. 식(11)의 C_{ijkl} 은 다음과 같이 정의된다.

$$C_{ijkl} = W_1 \times F(f_i, f_k) + W_2 \times F(f_j, f_l) + W_3 \times F(r_{ij}, r_{kl}) \quad (12)$$

여기서, $F(x, y)$ 는 퍼지 함수이고 x 와 y 의 차이가 임계값 이상이면 1 이하이면 -1을 출력하게 된다. f_i 는 i 번째 노드의 각도이고 r_{ij} 는 i 번째 노드와 j 번째 노드 사이의 거리이다. 첫 번째 항과 두 번째 항은 각 특징점들의 각도를 비교하는 항이고 세 번째 항은 각 특징점들 사이의 거리를 비교하는 항이다. W_1 는 각 특징들의 가중치를 주는 것이다. W_1 의 합은 1이고 세 번째 항은 특징점들 사이의 상관적인 특성이므로 W_3 에 비중을 더 주어 $W_1=0.15$, $W_2=0.15$, $W_3=0.7$ 로 정하였다. 식(11)의 두 번째 항은 다음과 같이 표시될 수 있다.

$$\begin{aligned} \sum_i \sum_j \sum_k \sum_l V_{ik} V_{jl} &= \sum_i \sum_k \sum_j \sum_l V_{ik} V_{jl} - \sum_i \sum_k \sum_j \sum_l \delta_{kl} V_{ik} V_{jl} \\ &= \sum_i \sum_j \sum_k \sum_l \delta_{kl} V_{ik} V_{jl} - \sum_i \sum_j \sum_k \sum_l \delta_{ij} \delta_{kl} V_{ik} V_{jl} \\ &= \sum_i \sum_j \sum_k \sum_l (\delta_{kl} - \delta_{ij} \delta_{kl}) V_{ik} V_{jl} \end{aligned} \quad (13)$$

위의 식을 이용하여 식(11)의 에너지 함수를 표현하면 다음과 같다.

$$E = -\frac{1}{2} \sum_i \sum_j \sum_k \sum_l T_{ijkl} V_{ik} V_{jl} - \sum_i \sum_j I_{ik} V_{ik} \quad (14)$$

$$T_{ijkl} = AC_{ijkl} - B_1 \delta_{ij} - B_2 \delta_{kl} + (B_1 + B_2) \delta_{ij} \delta_{kl}$$

Hopfield는 에너지 함수가 Liapnov 함수임을 증명하였다. 따라서 뉴런들은 안정 상태로 수렴하게 되고 에


너지 함수는 지역적인 최소값으로 수렴하게 된다.^[12]

IV. 정합 성능 비교 및 분석

본 장에서는 코너점, 접점, 변곡점들을 포함하고 있는 10가지 모델 물체를 가지고 서로 겹쳐진 상황을 만들어 정합 성능을 비교하였다.

그림 6은 하나의 예로 모델 물체와 겹쳐진 물체의 경계선을 보인 것이다. 각 물체들의 경계선을 추출한 후 제안된 방법으로 특징점을 찾아 물체들 경계선 위에 특징점들을 표시하였다. 특징점의 순서는 그림 6에 표시한 1번을 기준으로 반시계 방향이다.

그림 7의 행렬은 DHN으로 그림 6 (b)의 입력 물체에 대하여 그림 6 (a)의 모델 물체로 정합한 후의 뉴런의 상태이다. 행렬에서 행은 입력 물체의 노드 번호를 나타내고 열은 모델 물체의 노드 번호를 나타낸다. 모델 물체의 특징점 중에 입력 물체에서 보이는 부분은 모델 물체의 3, 4, 5번과 7, 8번이고 이에 대응하는 입력 물체의 노드는 각각 13, 14, 1번과 4, 5번이다. 그림 7을 보면 알 수 있듯이 4개의 노드가 정확히 정합되고 1개의 노드는 정합되지 않았다.



(a) 모델 물체 (b) 입력 물체

그림 6. 모델 물체와 겹쳐진 물체의 특징점들
Fig. 6. Salient points of a modal object and an input object.

표 1과 표 2는 겹쳐진 물체 10가지에 대하여 각각 코너점으로 정합한 결과와 특징점으로 정합한 결과를 보여 준다. 평균적으로 보았을 때 코너점으로는 물체 노드의 41%가 가려져 있고 특징점으로는 34%가 가려진 상황이다. 이것은 같은 물체에서도 코너점이 많이 가려진 경우가 생기므로 겹쳐진 비율이 다르다. 물체 정합 성능은 MS(Matching Score)와 MIS (Mismatching Score)를 척도로 비교하였다. MS와

MIS는 다음과 같이 정의된다.

$$MS = \frac{\text{정확히 정합된 노드의 수}}{\text{입력 물체에 나타난 모델 노드의 수}} \quad (15)$$

$$MIS = \frac{\text{잘못 정합된 노드의 수}}{\text{입력 물체에 나타난 모델 노드의 수}} \quad (16)$$

위의 식의 MS는 클수록 MIS는 작을수록 물체 정합 성능은 우수한 것이다. 10가지 겹쳐진 물체에 대한 정합 결과의 평균을 계산한 결과 MS는 코너점으로 정합한 경우와 특징점으로 정합한 경우 모두 1로 나타났지만 MIS는 각각 0.46와 0.34로 특징점으로 정합하였을 때 우수하게 나타났다.

		모 델 노 드											
		1	2	3	4	5	6	7	8	9	10	11	12
입 력 노 드	1	0	0	0	0	0	0	0	0	0	0	0	0
	2	0	0	0	0	0	0	0	0	0	0	0	0
	3	0	0	0	0	0	0	0	0	0	0	0	0
	4	0	0	0	0	0	0	1	0	0	0	0	0
	5	0	0	0	0	0	0	0	1	0	0	0	0
	6	0	0	0	0	0	0	0	0	0	0	0	0
	7	0	0	0	0	0	0	0	0	0	0	0	0
	8	0	0	0	0	0	0	0	0	0	0	0	0
	9	0	0	0	0	0	0	0	0	0	0	0	0
	10	0	0	0	0	0	0	0	0	0	0	0	0
	11	0	0	0	0	0	0	0	0	0	0	0	0
	12	0	0	0	0	0	0	0	0	0	0	0	0
	13	0	0	1	0	0	0	0	0	0	0	0	0
	14	0	0	0	1	0	0	0	0	0	0	0	0

그림 7. DHN으로 정합한 후의 뉴런 상태
Fig. 7. Neuron states after convergence of DHN.

표 1. 코너점으로 정합한 결과
Table 1. Matching with coner points.

호	노드의 개수						정합 결과				분석			
	ML	IN	ML/IN	EM	MM	UM	OR	SR	MIS	MS	OR	SR	MIS	MS
1	4	6	3	3	2	-	0.75	0.5	0.66	1				
2	3	4	2	2	1	-	0.67	0.5	0.5	1				
3	7	8	3	3	1	-	0.43	0.38	0.33	1				
4	7	12	2	2	1	-	0.23	0.17	0.5	1				
5	7	9	4	4	0	-	0.57	0.44	0.0	1				
6	9	13	8	8	1	-	0.89	0.62	0.13	1				
7	3	12	2	2	1	-	0.67	0.17	0.5	1				
8	9	12	7	7	3	-	0.78	0.58	0.43	1				
9	3	6	2	2	0	-	0.67	0.33	0.0	1				
10	9	6	2	2	3	-	0.22	0.33	1.5	1				
평균							0.59	0.40	0.46	1				

- ML : 모델 물체의 노드의 개수
- IN : 입력 물체의 개수
- ML/IN : 입력 물체에 나타난 모델 물체의 개수
- EM : 정확히 정합된 노드의 개수
- MM : 잘못 정합된 노드의 개수
- UM : 정합되지 않은 노드의 개수

- OR : (ML/IN)/ML
- SR : (ML/IN)/IN
- MIS : MM/(ML/IN)
- MS : EM/(ML/IN)

표 2. 특징점으로 정합한 결과
Table 2. Matching with Salient points.

호	노드의 개수						정합 결과			분석				
	ML	IN	ML/IN	EM	MM	UM	OR	SR	MIS	MS	OR	SR	MIS	MS
1	8	11	7	7	0	-	0.88	0.64	0	1				
2	7	13	6	6	2	-	0.86	0.46	0.33	1				
3	8	11	4	4	3	-	0.5	0.36	0.75	1				
4	8	17	3	3	2	-	0.38	0.18	0.66	1				
5	11	14	6	6	1	-	0.55	0.43	0.17	1				
6	12	17	10	10	2	-	0.83	0.59	0.2	1				
7	7	18	4	4	2	-	0.57	0.22	0.5	1				
8	15	18	11	11	1	-	0.73	0.61	0.01	1				
9	7	13	6	6	2	-	0.86	0.46	0.33	1				
10	12	13	5	5	2	-	0.42	0.38	0.4	1				
평균							0.66	0.43	0.34	1				

즉, 물체가 직선과 곡선으로 이루어져 있는 경우 특징점으로 정합하면 정합 성능을 향상시킬 수 있다. 물체의 코너점이 모두 가려져 정합할 수 없는 상황에서도 물체의 접점이나 변곡점이 보인다면 이것만으로도 물체 정합이 가능하다.

V. 결 론

본 논문에서는 코너점 이외에 접점과 변곡점을 추출하여 특징점으로 사용하여 물체를 정합하였다. 먼저 제안된 방법으로 구한 곡률 함수를 미디안 필터링을 함으로써 양자화 잡음을 제거하여 접점 및 변곡점을 추출하였다. 그리고 각 특징점들을 잇는 선을 직선과 곡선으로 근사화하여 물체를 표현하였다. 기존의 Hopfield 신경망을 사용하여 특징점들을 추출하고 물체를 정합하며, 기존의 코너점만을 이용한 방법과 정합 성능을 비교하였다.

정합 성능을 분석하기 위하여 Hopfield 신경망의 최적화 성질을 이용하여 정합되는 노드의 수를 비교하였다. 코너점만으로 정합한 경우와 특징점으로 정합한 경우 MS의 경우는 같게 나타났지만 MIS의 경우 특징점을 사용하였을 때 정합 성능을 향상시킬 수 있었다. 직선과 곡선으로 이루어진 물체에서 코너점의 개수가 적다든지 특징점 중에 코너점이 많이 가려진 경

우에는 특징점을 이용하여야 물체를 정합할 수 있었다. 따라서 특징점을 추출하여 물체를 정합하는 것이 물체 정합 성능을 상당히 향상시킬 수 있다.

참 고 문 헌

- [1] H. Freeman and L. S. Davis, "A corner - finding algorithm for chain-coded curves," *IEEE Trans. Comput.* vol. C-26, pp. 297-303, Mar. 1977.
- [2] H. L. Beus and S. S. H. Tiu, "An improved corner detection algorithm based on chain-coded curves," *Pattern Recognition*, vol. 20, pp.291-296, 1987.
- [3] H. C. Liu and M. D. Srinath, "Corner detection from chain code," *Pattern Recognition*, vol. 23, pp. 51-68, 1990.
- [4] R. P. Lippman, "An introduction to computing with neural networks," *IEEE ASSP*, pp. 4-22, April, 1987.
- [5] M. Takeda and J. W. Goodman, "Neural networks for computation: Number representation and programming complexity," *Applied Optics*, vol. 25, no. 18, Sept. 15, 1986.
- [6] Robert J. Mcelice et. al., "The capacity of the Hopfield associative memory," *IEEE Trans. Information Theory*, vol. IT-33, no. 4, pp. 461-482, July, 1987.
- [7] D. W. Tank and J. J. Hopfield, "Simple "Neural" Optimization Network: An A/D Converter, Single Decision Circuit, and a Linear Programming Circuit," *IEEE Trans. on Circuit and Systems*, vol. 33, no. 5, pp. 533-541, 1986.
- [8] Bang W. Lee and Bing J. Sheu, "Modified Hopfield Neural Networks for retrieving the Optimal Solution," *IEEE Trans. on Neural Networks*, vol. 2, no. 1, pp.137-142, 1991.
- [9] Jung H. Kim, Sung H. Yoon and Kwang H. Sohn, "A robust boundary-based object recognition in occlusion environment by Hybrid Hopfield Neural Networks," *Pattern Recognition*, vol. 29, no. 12, pp. 2047-2060, 1996.
- [10] W. Lin, F. Liao, C. Taso and T. Lingutle, "A hierarchical Multiple-view approach to three-dimensional object recognition," *IEEE Trans. on Neural Net.* vol. 2, pp. 84-92, 1991.
- [11] W. Li and M. Nasrabadi, "Object recognition based on graph matching implemented by a Hopfield-style neural network," *Int. J. Conf. Neural Networks*, vol II, pp. 278-290, June , 1989.
- [12] J. J. Hopfield, "Neural networks and physical systems with emergency computational abilities," *Proc. Nat. Acad. Sci. USA*, vol. 79, pp. 2554-2558, 1982.


저 자 소 개



朴廷珉(正會員)


1996년 2월 연세대학교 전파공학과 졸업(학사). 1998년 2월 연세대학교 전파공학과 대학원 졸업(석사). 현재 LG전자 멀티미디어 연구소 연구원. 주관심분야는 영상처리, 컴퓨터비전

터비전



孫光 燾(正會員)

1983년 2월 연세대학교 전자공학과 졸업(학사). 1985년 8월 미네소타대학교 전기공학과 졸업(석사). 1991년 12월 노스캐롤라이나 주립대학교 전기 및 컴퓨터 공학과 졸업(박사). 1992년 4월~1993년 12월 한국 전자통신연구원 선임연구원. 1994년 1월~1994년 12월 Georgetown 대학교 MRI 연구센터 Post-Doctoral Fellow. 1995년 3월~현재 연세대학교 전파공학과 부교수. 주관심분야는 영상처리, 영상통신, 컴퓨터비전



許 榮(正會員)

1957년 1월 15일생. 1980년 한양대학교 전자통신공학과 (학사). 1985년 동 대학원 졸업 (석사). 1995년 미국 University of Texas at Arlington 졸업 (박사). 1983년~1987년 육군사관학교 전자공학과 전임강사. 1995년 미국 University of Texas at Arlington 전기공학과 강사. 1998년~국립 창원대학교 전자공학과 겸임 부교수. 1987년~현재 한국전기연구소 정보통신연구팀 책임연구원. 주관심분야는 디지털 영상 신호처리 및 영상부호화 기술, HDTV 신호처리 및 DSP 응용기술, 의료 영상신호처리 기술 등