

내부 객체 정보를 이용한 온톨로지 기반의 객체 영상 인식

Ontology-based Object-Image Recognition by Using Information on Inner-Objects

이인근* · 서석태* · 석지권** · 권순학**

In K. Lee*, Suk T. Seo*, Jikwon Seok** and Soon H. Kwon**

*영남대학교 전기공학과

**안동과학대학 자동차과

요 약

객체 영상에서 색, 모양과 같은 특징은 객체의 특성을 명확하게 표현하지 못한다. 따라서 제한된 특징 정보는 객체 영상 인식의 애매성을 야기한다. 최근에는 객체 인식에서의 애매성을 줄이기 위해 지식베이스에 기반한 영상의 인식에 관한 연구가 진행되고 있다. 그러나 영상은 수치적 정보로 표현되고 지식베이스는 개념적 정보로 표현되어 영상과 지식 베이스의 결합이 쉽지 않다. 본 논문에서는 영상과 지식베이스의 정보 표현의 차이를 줄이기 위해 온톨로지를 이용하여 지식베이스를 구성한다. 그리고 내부 객체 정보를 이용하여 객체 영상 인식 과정에서의 애매성을 줄이는 객체 영상 인식 방법을 제안한다. 또한, 과일 영역에서의 객체 영상 인식 실험을 통해 제안한 방법의 효용성을 확인한다.

키워드 : 온톨로지, 영상 이해, 객체 영상 인식, 내부 객체

Abstract

Since the features in object-images such as color and shape cannot clearly express the characteristic of objects, those features lead to vagueness of object-image recognition. Recently there have been studied on object-image recognition based on knowledge base in order to reduce the vagueness. However, because images are represented by numerical information but knowledge bases are represented by conceptual information, combining two kinds of information is difficult. In this paper, we compose knowledge base by using ontology to reduce the gap between the two kinds of information, and propose a method for object-image recognition to reduce the vagueness by using information on inner-object. Moreover, we confirm the usefulness of the proposed method through the experiments on object-image recognition in fruit domain.

Key Words : ontology, image understanding, object-image recognition, inner-object

1. 서 론

영상의 이진화, 노이즈 제거, 에지 추출과 같은 영상 처리 기법을 확장하여 최근에는 지식베이스를 이용한 영상 인식과 이해[1-4]에 관한 연구가 진행되고 있다. 그러나 지식베이스를 이용하여 영상 객체를 인식하고 이해하기 위해서는 ‘픽셀(pixel) 단위의 수치적 정보로 표현된 영상’과 ‘기호(symbol) 단위의 개념적 정보로 표현된 지식베이스’의 정보 차이를 극복해야만 한다[1,4]. 이 문제의 해결을 위해 영상 인식과 이해를 위한 지식베이스 구성 방법이 제안되었다[1].

영상 인식과 이해를 위해 설계된 지식베이스[1-4]는 3가지 영역으로 구분된다. (i) ‘Conceptual knowledge base’는 특정 분야의 개념을 표현한 의미 계층을 나타낸 지식베이스로써 영상 인식 분야만이 아닌 다양한 응용 분야에서도 활용 가능하다[1,3,4]. (ii) ‘Knowledge base for object features’

는 개념적으로 표현된 지식 계층과 픽셀 단위의 수치적 영상 처리의 개념적 차이를 줄이기 위해, 객체 영상에서의 특징 정보를 개념화하고 기호화 하여 표현한 것이다[1,3]. 그리고 (iii) ‘Knowledge base for spatial relation’은 영상에 존재하는 객체들 간의 공간적 위치 관계를 표현한 것으로써 객체 인식이나 객체의 상황 설명을 위한 자료로써 활용된다[2-4]. 그러나 영상 인식과 이해를 위한 기존의 지식베이스는 특정 시스템에 특화되어 있어 이들의 재사용 및 확장이 어렵다[1].

따라서 본 논문에서는 온톨로지[5]를 이용하여 영상의 수치적 정보와 지식베이스의 의미적 정보와의 차이를 줄이기 위한 지식베이스 구성 방법을 제안하고, 객체 인식 과정의 정확률을 높이기 위해 내부 객체(inner-object)[1,3,6]의 인식을 통한 객체 인식 방법을 제안한다. 그리고 과일 분야에서의 영상 객체 인식 실험을 통해 구축한 지식베이스와 내부 객체를 이용한 객체 인식 방법의 효용성을 보인다.

2. 영상 객체 인식을 위한 온톨로지 설계

영상에서 객체는 그림 1과 같이 독립된 객체인 주 객체(main object)와 그의 일부로써 존재하는 내부 객체로 정의

접수일자 : 2009년 9월 28일

완료일자 : 2009년 12월 7일

+Corresponding author

한다. 특히, 그림 1(c)와 같은 객체의 위치 관계를 RCC-8[1] 모델에서는 NTPP(X,Y)로 표현하기도 한다. 따라서 그림 2와 같은 ‘개념 온톨로지’를 구성하기 위해 참고 문헌 [3]과 같이 WordNet[7]을 참조하여 개념의 계층을 구성하고, 그림 1의 “내부 객체인 AvocadoSeed가 주 객체인 Avocado의 부분으로 존재한다.”는 것을 ‘isPartOf(Avocado Seed, Avocado)’와 같이 표현한다¹⁾. 본 논문에서는 온톨로지를 그래프로 표현하기 위해 그림 2의 우측 상단의 기호들을 이용한다.



(a) 주 객체 (b) 내부 객체 (c) 위치 관계
그림 1. 주 객체와 내부 객체의 위치 관계

Fig. 1. Positional relation between main object and its inner-object




그림 2. 개념 온톨로지 스키마
Fig. 2. Conceptual ontology schema

영상 이해를 위한 지식베이스의 구축에 관한 기존 연구 [1,4]에서는 객체 영상에서 추출할 수 있는 특징들을 유한개의 개념으로 표현하고, 개념화된 특징을 이용하여 객체를 정의하였다. 예를 들면, “사과의 색은 빨강이다”라는 일반적 지식을 ‘색(사과, 빨강)’으로 표현하고, 개념화된 특징인 ‘빨강’을 정의하기 위해 RGB 색 범위를 $R \in [0.8, 1]$, $G \in [0, 0.2]$, $B \in [0, 0.2]$ 와 같이 수치적 정보를 이용하여 표현하였다. 즉, 영상에서 ‘빨강’이 차지하는 비율이 다른 색보다 크기 때문에 ‘사과’의 색을 ‘빨강’으로 일반화하여 표현하였다. 그러나 이 방법은 영상의 색을 구성하는 다른 색 정보를 객체 인식에 활용할 수 없는 문제가 있다. 따라서 객체의 색과 형태와 같은 영상의 특징 정보를 표현하기 위해, 그림 3, 4와 같은 객체 인식을 위한 ‘특징 온톨로지’를 구성한다. 그림 3의 ‘ImageObject’의 하위 개념들은 영상에서 인식하고자 하는 객체의 개념을 정의한 것이고, ‘ImageFeature’의 하위 개념들은 객체에서 추출할 수 있는 특징을 개념으로 정의한 것으로서, 그림 4와 같이 객체의 특징은 ‘xsd:double²⁾’ 형태의 실수 값으로 표현 가능하다는 것을 의미한다.




그림 3. 특징 온톨로지 스키마
Fig. 3. Feature ontology schema

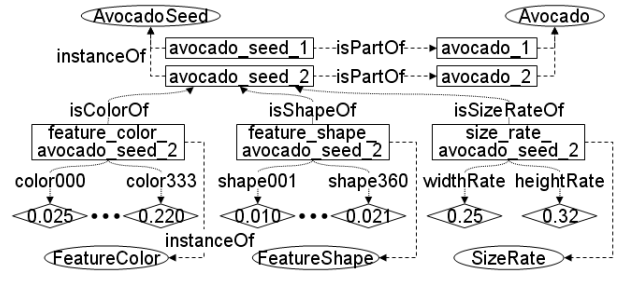


그림 4. 객체 영상의 특징 정보 표현
Fig. 4. Feature representation of object-images

예를 들어, 그림 4에서 ‘AvocadoSeed’를 나타내는 실제 영상을 ‘avocado_seed_2’라는 개체(instance)로 표현하고, 이 영상 개체로부터 추출한 색을 ‘isColorOf(avocado_seed_2, feature_color_avocado_seed_2)’와 같이 나타낸다. 여기서 ‘feature_color_avocado_seed_2’는 그림 3의 ‘FeatureColor’의 개념에 포함되는 개체이다. ‘avocado_seed_2’로부터 추출한 수치적 색 정보는 다수 존재하므로, 이들의 정보는 ‘color000(feature_color_avocado_seed_2, 0.025)’와 같이 나타낸다. 즉, 영상 개체의 여러 가지 속성은 개념적으로 표현하고, 개체의 특징에 따라 다양한 수치 값을 특징별로 표현하여 다양한 특징 정보를 온톨로지로 나타낼 수 있다. 그리고 그림 3에서 ‘SizeRate’는 영상에서 주 객체에 대한 내부 객체의 상대적 크기의 비율을 나타낸 것으로서, 이 정보는 주 객체로부터 내부 객체를 추출하는 과정에서 활용된다. 예를 들어, 그림 1에서 주 객체와 내부 객체의 크기 비율은 ‘0.34’이다. 각 특징 값을 결정하는 방법은 3.3절에서 자세히 설명한다.

그림 5는 온톨로지에서의 개념간의 관계 설정을 위한 속성들의 계층 관계를 나타낸 것이다. ‘objectProperty’는 개념간의 관계를 설정할 때 사용되고, ‘datatypeProperty’는 개념과 자료(숫자나 문자)와의 관계를 설정할 때 사용된다.




그림 5. 속성 계층
Fig. 5. Hierarchy of properties

특정 객체 영상으로부터 추출한 특징 정보를 이용하여 [정의 1]과 같이 개념의 특징을 표현할 수 있으나, 동일한 개념일지라도 특징이 다른 객체가 존재할 수 있다. 이 문제를 해결하기 위해 참고문헌 [3]에서는 다수의 학습 영상 객체로부터 개념의 특징 범위를 지정하는 ‘영상 학습’ 방법을 제안하였다. 즉, 학습 객체에서 추출한 특징을 이용하여 유사도 판단의 기준을 정하고, 테스트 객체를 인식하기 위해 그 기준과의 유사도를 이용하여 객체 인식을 수행한다³⁾. 따라서 다수의 학습 객체의 특징 정보를 이용하여 [정의 2]와 같이 개념의 특징을 정의한다.

1) Predicate logic을 이용한 온톨로지의 개념간 관계 표현
2) xsd:double은 XML Schema Definition[8]으로 W3C에서 정의한 실수 값의 데이터를 의미한다.

3) ‘학습 객체’는 지식베이스를 구성하는 개념의 특징을 정의하기 위한 객체 영상을 의미하며, ‘테스트 객체’는 객체 인식 과정을 통해 특정 개념으로 분류될 객체 영상을 의미한다.

[정의 1]

Papaya $\equiv \exists x. (\text{ImageObject}(x) \wedge (\text{isColorOf}(\text{featureC1},x) \wedge \text{isShapeOf}(\text{featureS1},x)))$

[정의 2]

Apple $\equiv \exists x. (\text{ImageObject}(x) \wedge ((\text{isColorOf}(\text{featureC2},x) \wedge \text{isShapeOf}(\text{featureS2},x)) \vee (\text{isColorOf}(\text{featureC3},x) \wedge \text{isShapeOf}(\text{featureS3},x))))$

[정의 3]

Citrus $\equiv \exists x. (\text{ImageObject}(x) \wedge ((\text{isColorOf}(\text{featureC1},x) \wedge \text{isShapeOf}(\text{featureS2},x)))$

사람은 특정 사물에 대한 오랜 시간의 경험에 의해 그 사물의 특징들을 기억한다. 그리고 그와 유사한 사물을 보았을 때 기억 속에서 특징이 가장 유사한 객체 후보들을 분류해 내고, 주변 상황에 따른 종합적인 판단으로 그 객체의 정체성을 인지한다. 그러나 특정 사물에 대해서는 한 번도 보지 못하였더라도, 기억 속의 다른 사물의 특징을 이용하여 특정 사물의 특징을 설명할 수 있다. 예를 들어, ‘귤’에 대한 학습 객체가 없더라도, “귤의 모양은 사과와 유사하고, 색은 파파야와 유사하다.”고 정의할 수 있다. 따라서 [정의 3]과 같이 다른 개념들의 특징 정보를 이용하여 학습 객체 영상이 존재하지 않는 추상적 객체의 개념을 정의한다.

3. 내부 객체를 이용한 객체 영상 인식

영상에서 추출할 수 있는 특징 정보는 제한적이다. 특히 객체의 색과 모양의 특징만을 이용하여 객체를 정의할 경우에는 객체 인식이 어려울 수 있다. 따라서 본 논문에서는 [내부 객체를 이용한 객체 영상 인식 프로세스]를 통해 부족한 특징 정보로 인한 객체 인식의 애매성을 줄인다. 그림 6은 내부 객체 인식을 통한 객체 영상 인식 과정을 보인다.

[내부 객체를 이용한 객체 영상 인식 프로세스]

- step 1.** 다수의 객체가 섞여 있는 복합 영상으로부터 주 객체 추출.
- step 2.** 객체로부터 특징을 추출.
- step 3.** 학습 객체 특징과의 유사도를 측정하여 객체 인식
- step 4.** 객체 인식 판단 과정을 통해 종료 여부를 판단. 객체 인식의 애매성 존재할 경우 **step 5**로 이동. 객체 인식 완료시 **step 6**으로 이동.
- step 5.** 내부 객체 추출하고 **step 2**로 이동.
- step 6.** 프로세스 종료.




그림 6. 객체 영상 인식 프로세스
Fig. 6. Object-image recognition process

3.1 객체 영역 추출

영상에서 관심 객체의 분리와 인식에 관한 기존의 연구 [9,10]에서는 관심 객체와 배경과의 특징 차이를 통해 경계 영역을 추출하고, 경계 영역 내의 영상을 데이터베이스에

저장된 객체 영상과 비교하여 신뢰도를 기준으로 영역을 선정한다. 즉, 추출하고자 하는 객체 영상 정보를 이용하여 복합 영상에서 객체 영역을 추출하는 것은 가능하지만, 추출하고자 하는 객체에 대한 정보가 없이 객체를 추출하는 것은 어려운 일이다. 또한 이것은 본 연구의 초점에서 벗어난다. 따라서 본 논문에서는 단순한 특징 정보만으로도 객체 영역 추출이 가능한 객체 영상을 대상으로 한다.

3.2 객체 특징 추출

영상 검색 및 인식에 주로 이용되는 특징은 객체의 색 분포이며, 그 외에도 질감, 모양, 공간과 같은 특징 정보가 이용된다[1]. 영상으로부터 특징 정보를 추출하기 위한 방법으로 RGB와 같은 시각으로 인식할 수 있는 색 정보를 그대로 이용하거나, Wavelet이나 Fourier Transform과 같은 특징의 변환 과정을 통해 정보를 획득하는 방법이 있다. 본 논문에서는 참고문헌 [3]에서의 특징 추출 방법을 이용하여 객체의 색이나 형태와 같은 특징들을 추출한다. 참고문헌 [3]에서의 특징 추출 방법은 다음과 같이 요약할 수 있다.

① 색 특징 추출

식 (1)과 같이 색의 범위를 RGB 각 채널별로 3개로 지정하고 총 27가지의 색 그룹(Color Group)을 생성한다. 객체를 구성하는 모든 픽셀의 색의 값을 식 (2)를 통해 정규화 한다. 그리고 식 (3)의 조건에 따라 각 픽셀의 그룹을 결정하고, $G_{rgb} = \{G_{111}, \dots, G_{333}\}$ 으로 표현되는 27개의 색 그룹을 기준으로 객체의 색 히스토그램을 구한다. 식 (2)에서 L_R, L_G, L_B 는 RGB 각 색 채널에서의 최대 범위로서, R-채널의 색 범위가 [0~255]인 경우에는 L_R 은 255가 된다.

$$Color\ Group = \{G_{rgb} | 1 \leq r, g, b \leq 3, r, g, b: \text{자연수}\} \quad (1)$$

$$N_R = \frac{R}{L_R}, \quad N_G = \frac{G}{L_G}, \quad N_B = \frac{B}{L_B} \quad (2)$$

$$\begin{cases} \text{if } 0 \leq N_R \leq 0.33 & \text{then } r = 1 \\ \text{if } 0.33 < N_R \leq 0.66 & \text{then } r = 2 \\ \text{if } 0.66 < N_R \leq 1 & \text{then } r = 3 \end{cases} \quad (3)$$

(N_G, N_B 에 대해서 식 (3)과 같은 방법으로 g, b 를 구한다)

색 히스토그램을 식 (4)로 정규화하여 객체에서의 색 분포를 구한다. 즉, 특정 색 그룹(G_{rgb})에서의 픽셀 수(NG_{rgb})가 객체를 구성하는 전체 픽셀에서 차지하는 비율로써 정규화한 색 히스토그램을 구한다.

$$C_{rgb} = NG_{rgb} / \text{total pixel number} \quad (4)$$

② 형태 특징 추출

객체의 형태 특징은 객체의 무게중심점(x_c, y_c)에서 외곽(x_s, y_s)까지의 거리를 식 (5)와 같이 일정 각도씩 회전하면서 측정한다. 그리고 식 (6)과 같이 특정 각도(d')에서의 정규화한 형태 특징 값($S_{d'}$)을 구한다.

$$s_{d'} = \sqrt{(x_c - x_s)^2 + (y_c - y_s)^2} \quad (5)$$

$$S_{d'} = \frac{s_{d'}}{\arg \max_{0 < d' \leq 360} (s_{d'})} \quad (6)$$

3.3 객체 특징 유사도 측정

학습 객체와 테스트 객체 간의 특징간 유사도 측정을 위해 참고문헌 [3]에서의 유사도 측도(similarity measure)를 이용한다. 색 간의 유사도는 (7)과 같이 구한다.

$$ColS = \left(\sum_{r=1}^3 \sum_{g=1}^3 \sum_{b=1}^3 |C_{rgb}^i - C_{rgb}^t| + 1 \right)^{-1} \quad (7)$$

C_{rgb}^t : 테스트 영상 색 그룹의 히스토그램 값

C_{rgb}^i : 학습한 영상객체의 색 그룹의 히스토그램 값

형태 유사도는 테스트 영상 개체를 회전하면서 학습 영상과의 유사도를 측정하여 최대 유사도 값을 선택한다.

$$ShaS = \arg \max_{1 \leq r \leq n} \left[\left(\sum_{d=1}^m (S_d^i - S_{d,r}^t)^2 + 1 \right)^{-1} \right] \quad (8)$$

$$n = \frac{360}{r'}, \quad m = \frac{360}{d'}, \quad (n, r', m, d': \text{자연수}, 0 < d', r' \leq 360)$$

n : 테스트 영상 객체를 r' 간격으로 회전 가능한 횟수

m : 영상 객체의 d' 각도에 대한 특징 값의 개수

$S_{d,r}^t$: r 번째 영상 개체 회전에 대한 테스트 영상의 d 각도에서의 형태 특징 값

S_d^i : 학습 영상 개체의 d 각도의 형태 특징 값

영상에서 두 가지 특징인 색과 형태는 상호 독립적으로 식 (9)와 같은 벡터의 크기를 이용하여 개념 c_i 에 대한 학습 객체와 테스트 객체와의 유사도를 생성한다.

$$TS_i = \sqrt{(ColS_i)^2 + (ShaS_i)^2} \quad (9)$$

3.4 객체 인식 종료 판단

유사도 기반의 객체 인식에서는 학습 객체와의 유사도가 가장 큰 개념으로 테스트 객체를 분류한다. 그러나 색이나 모양과 같은 특징은 상황에 따라 그 값이 변할 수 있다. 따라서 유사도가 비슷하여 테스트 객체를 특정 개념으로 분류하기 애매한 경우, 테스트 객체의 내부 객체를 인식함으로써 인식의 애매성을 줄인다. 그러나 “유사도가 비슷하다.”는 기준이 명확하지 않다. 따라서 본 논문에서는 테스트 객체와 학습 객체와의 유사도를 크기순으로 나열한 후, 식 (10)을 통해 이웃한 객체 후보 간의 유사도 차이($SG_{i,j}$)가 가장 큰 지점을 기준으로 내부 객체의 인식을 수행할 후보 그룹을 형성한다.

$$SG_{i,j} = |TS_i - TS_j| \quad (10)$$

그림 7은 두 개의 객체에 대한 유사도 계산 결과를 크기순으로 나열하고, 이웃한 객체 후보 간의 유사도 차이를 나타낸 것이다. 여기서 $g_{i,j}$ 는 개념 c_i 와 개념 c_j 사이의 유사도 차이를 나타내는 기호이다. 예를 들어, 그림 7(a)는 객체 인식 후보로써 1개의 객체가 선택된 경우이고, 그림 7(b)는 객체 인식 후보로써 6개의 객체가 선택된 경우이다. 그림 7(a)와 같이 단 하나의 개념만이 후보로 선택된 경우에는 테스트 객체를 유사도가 가장 큰 개념 ' c_1 '으로 분류한다. 그러나 그림 7(b)의 경우에는 ' $c_1 \sim c_6$ '을 내부 객체 인식 후보로 선택한다.




그림 7. 객체 인식 프로세스의 종료 판단
Fig. 7. Detection of completion of the process

3.5 내부 객체 영역 추출 및 인식

지식베이스로부터 내부 객체 인식 후보로 선택된 개념들의 내부 객체에 대한 정보를 참조하여 객체 영상에서 내부 객체를 추출한다. 내부 객체의 추출은 3.1절의 주 객체 추출과 달리 지식베이스가 내부 객체에 대한 사전 정보를 포함하고 있어 내부 객체의 추출이 용이하다. 예를 들면, 그림 1에서 주 객체에 대한 내부 객체의 상대적 크기 정보를 이용하여 내부 객체로써의 가능성이 높은 영역을 추출하고, 3.2~3.4절의 방법을 통해 내부 객체를 인식할 수 있다. 이 과정에서 주 객체 영상에서 다수의 내부 객체의 영역이 선택된다 하더라도, 이들 중 지식베이스에 등록된 내부 객체만이 인식 결과로 선택되기 때문에, 지식베이스에 등록되지 않은 다른 내부 객체는 인식 과정에서 제외된다.

3.6 객체 인식 종합 판단

주 객체와 내부 객체의 관계를 통해 테스트 객체를 특정 개념으로 분류한다. 즉, 식 (11)을 이용하여 개념 c_i 에 대한 주 객체의 전체 유사도(RS_i)를 구하고, 3.4절의 방법을 통해 객체 인식 판단을 수행한다.

$$RS_i = \sqrt{\sum_{k=0}^K (TS_i^k)^2} \quad (11)$$

여기서 k 와 K 는 각각 내부 객체의 깊이와 지식베이스에 표현된 개념 c_i 의 내부 객체의 최대 깊이를 나타낸다. 예를 들어, $k=0$ 은 주 객체, $k=1$ 은 내부 객체, 그리고 $k=2$ 는 내부 객체에 존재하는 또 다른 내부 객체를 의미한다.

만일, 테스트 객체의 인식 결과가 불명확하더라도 지식베이스에서 더 이상 내부 객체가 존재하지 않는 경우에는 명확한 분류가 불가능하다고 판단한다. 그리고 테스트 객체가 최종 후보 개념들 중 하나일 가능성만을 남겨두고 인식 과정을 종료한다.

4. 모의실험 및 고찰

제한한 객체 인식 방법의 효용성 확인을 위해 과일 영상에 대한 객체 인식 실험을 수행한다. 과일 분야에서 개념의 계층 및 부분 관계를 온톨로지 구성하고, 10가지 종류의 과일에 대해 학습 및 테스트 영상을 포함하여 총 120개의 영상을 수집하였다. 그림 8은 실험을 위한 과일 분야의 객체 영상을 보인다. 객체 속성의 다양성을 부여하기 위해 'apple', 'banana', 'grape'은 동일 개념에 대해 색이 다른 객체를 선정하였고, 'avocado', 'citrus', 'kiwi', 'mangosteen', 'papaya', 'watermelon'은 각각의 단면을 나타내는 객체 영상을 'avocadoCut', 'citrusCut', 'kiwiCut', 'mangosteen'

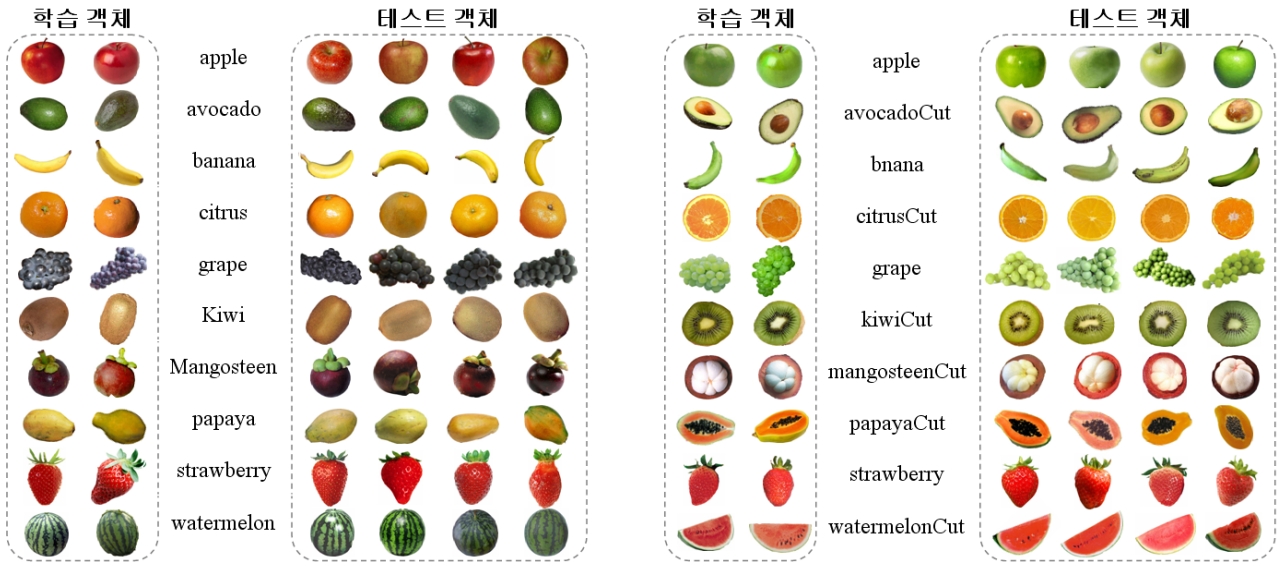


그림 8. 객체 인식 실험을 위한 객체 영상
Fig. 8. Object images for experiment of object recognition

Cut’, ‘papayaCut’, ‘watermelonCut’의 새로운 개념으로 정의하였다. 그리고 ‘apple’, ‘avocadoCut’, ‘citrus’, ‘grape’, ‘kiwiCut’, ‘mangosteen’, ‘mangosteenCut’, ‘papayaCut’, ‘strawberry’의 개념에 대해서는 온톨로지에 내부 객체에 대한 정보를 기록하였다. 따라서 총 16개의 각 객체 개념에 대해 40개의 객체 영상을 학습하고, 총 80개의 객체 영상에 대한 인식 실험을 수행한다. 실험은 객체 개념의 특징 정의에 따른 객체 인식 실험과 내부 객체 인식에 따른 객체 인식 실험이다.

4.1 객체 개념의 특징 정의에 따른 객체 인식 실험

그림 8의 학습 객체 중 1개의 객체 영상을 학습하였을 때, 2개의 객체 영상을 학습하였을 때, 그리고 [정의 3]과 같이 학습 객체 영상이 존재하지 않는 추상적 개념에 대해서 다른 학습 객체의 특징을 이용하여 특징을 정의하였을 경우에 대하여 객체 인식 정확률을 측정하였다.

표 1은 학습 객체의 수에 따른 인식 정확률을 보인다. 표 1에서 보듯이 1개의 객체 영상을 학습하였을 때 80개의 테스트 객체 영상 중 63개가 객체 인식에 성공하여 ‘73.7 %’의 객체 인식 정확률을 보인다. 2개의 객체 영상을 학습하였을 때에는 앞의 실험보다 더 높은 객체 인식 정확률을 보였다. 이는 학습을 많이 할수록 객체의 특징 범위가 넓어져 좀 더 정확한 인식이 가능하게 되는 것으로 판단된다.

표 2는 [정의 3]과 같이 추상적인 객체의 특징을 정의하였을 때의 인식 정확률을 보인다. 표 2의 실험 결과가 표 1의 실험 결과와 크게 다르지 않고, 또한 개념적 특징 정의로도 ‘citrus’가 인식되는 것을 확인하였다. 여기서 1개의 객체 영상을 학습하였을 때 ‘citrus’의 객체 인식 정확률이 ‘100 %’였다. 그러나 ‘citrusCut’과 ‘citrus’의 특징이 비슷하기 때문에, 표 1의 실험 결과에서 보듯이 두 개념을 잘 구분하지 못하였다. 단, 표 2의 실험 결과에서는 ‘citrus’의 인식률이 높아진 것을 확인할 수 있다. 이것은 실험에서 ‘CitrusCut’에 대한 개념을 배제하였기 때문에 ‘citrus’의 인식률이 상대적으로 높아진 것으로 판단한다.

표 1. 객체인식 실험 결과

Table 1. Experiment results of object recognition

개념	1개 객체 영상 학습			2개 객체 영상 학습		
	실험영상개수	일치영상개수	정확률 (%)	실험영상개수	일치영상개수	정확률 (%)
apple	8	8	100	8	6	75
avocado	4	3	75	4	3	75
avocadoCut	4	4	100	4	3	75
banana	8	8	100	8	8	100
citrus	4	2	50	4	1	25
citrusCut	4	2	50	4	4	100
grape	8	6	75	8	6	75
kiwi	4	2	50	4	2	50
kiwiCut	4	2	50	4	4	100
mangosteen	4	4	100	4	4	100
mangostrenCut	4	2	50	4	2	50
papaya	4	4	100	4	4	100
papayaCut	4	1	25	4	4	100
strawberry	8	4	50	8	7	87.5
watermelon	4	3	75	4	4	100
watermelonCut	4	4	100	4	3	75
계	80	59	73.7	80	65	81.2

표 2. 추상적 개념 정의에 대한 객체인식 실험 결과

Table 2. Experiment results of object recognition by conceptual description

개념	1개 객체 영상 학습			2개 객체 영상 학습		
	실험영상개수	일치영상개수	정확률 (%)	실험영상개수	일치영상개수	정확률 (%)
apple	8	7	87.5	8	6	75
citrus	4	4	100	4	1	25
kiwiCut	4	2	50	4	3	75
mangostrenCut	4	2	50	4	3	75
papaya	4	3	75	4	4	100
papayaCut	4	3	75	4	4	100
...
계	76	59	77.6	76	60	78.9

4.2 내부 객체 인식에 따른 객체 인식 실험

명확한 객체 인식이 되지 않는 객체 영상에 대해서 내부 객체의 인식 과정을 통한 객체 인식 실험을 수행하였다. 3.6 절에서의 ‘객체 인식 종합 판단’ 결과 다수의 객체인식 후보가 존재할 경우에는 유사도가 가장 큰 객체를 기준으로 인식 정확률을 계산하였다. 표 3은 내부 객체 인식을 통한 객체 인식 실험 결과를 보인다. 표 3에서 ‘일치영상개수’ 행에서 ‘(→)’는 비교를 위해 표 1에서의 인식 결과를 표기한 것이다. 1개 객체 영상을 학습한 경우 표 1의 실험에서 인식에 실패한 12개의 객체가 표 3에서는 객체 인식에 성공하였다. 그리고 전체적으로 ‘90 %’의 객체 인식 정확률을 보인다. 또한 2개 객체 영상을 학습의 경우 내부 객체 인식 결과에서는 ‘91.2 %’의 객체 인식 정확률을 보인다. 표 3의 실험 결과에서 객체 인식 과정에서의 애매성을 줄이는 방법으로 내부 객체를 추출하여 인식하는 방법이 효과적임을 확인할 수 있다.

표 3. 내부 객체 인식을 통한 객체인식 실험 결과
Table 3. Experiment results of object recognition by interpretation of inner-object

개념	1개 객체 영상 학습			2개 객체 영상 학습		
	실험영 상개수	일치영 상개수	정확률 (%)	실험영 상개수	일치영 상개수	정확률 (%)
apple	8	8	100	8	(6→) 7	87.5
avocadoCut	4	4	100	4	(3→) 4	100
citrus	4	(2→) 4	100	4	(1→) 4	100
grape	8	(6→) 7	87.5	8	(6→) 7	87.5
kiwiCut	4	(2→) 4	100	4	4	100
mangostrenCut	4	(2→) 3	75	4	(2→) 3	75
papayaCut	4	(2→) 4	100	4	4	100
strawberry	8	(4→) 8	100	8	(7→) 8	100
...
계	80	72	90.0	80	73	91.2

5. 결 론

본 논문에서는 온톨로지를 이용하여 객체 영상 인식을 위한 지식베이스를 구축하고, ‘내부 객체’의 인식을 통해 객체 영상 인식 과정에서의 애매성을 줄이는 객체 영상 인식 방법을 제안하였다. 그리고 객체 영상 인식 실험을 통해 제안한 온톨로지 구성 방법과 내부 객체 인식을 통한 객체 인식의 효용성을 확인하였다. 본 논문에서는 온톨로지 구성 방법과 객체 영상의 인식 방법에 초점을 두고, 객체 영역의 추출이 용이한 객체 영상을 대상으로 연구를 수행하였다. 그러나 영상 이해 분야의 폭넓은 연구를 위해서는 객체 영역 추출 및 영상 의미 해석 과정과의 연계를 위한 연구가 수행되어야 하며 이는 차후 연구로 남겨둔다.

참 고 문 헌

[1] N.E. Maillot and M. Thonnat, “Ontology based complex object recognition,” *Image and Vision Computing*, Vol. 26, pp. 102-113, 2008.
[2] C. Hudelot, J. Atif, and I. Bloch, “Fuzzy spatial relation ontology for image interpretation,” *Fuzzy Sets and Systems*, Vol. 159, pp. 1929-1951, 2008.

[3] 이인근, 서석태, 정혜천, 손세호, 권순학, “온톨로지 기반 영상이해 시스템,” *한국퍼지 및 지능 시스템학회 논문지*, 제17권, 3호, pp. 328-335, 2007.
[4] D. Crevier and R. Lepage, “Knowledge-Based Image Understanding Systems: A Survey,” *Computer Vision and Image Understanding*, Vol. 67, No. 2, pp. 161-185, 1997.
[5] G.Perez and F.L.Corcho, *Ontological Engineering*, Springer, 2004.
[6] 이인근, 서석태, 단나, 권순학, “내부 객체를 이용한 객체 영상 인식 과정,” *한국지능시스템학회 추계학술대회 학술발표 논문지*, 제18권, 2호, pp. 349-351, 2008.
[7] Wordnet, <http://wordnet.princeton.edu/>
[8] XML Schema, <http://www.w3.org/XML/Schema/>
[9] X. Bai, X. Yang, and L.J. Latecki, “Detection and recognition of contour parts based on shape similarity,” *Pattern Recognition*, Vol. 41, pp. 2189-2199, 2008.
[10] C. Hudelot and M. Thonnat, “A Cognitive Vision Platform for Automatic Recognition of Natural Complex Objects,” in: *International Conference on Tools with Artificial Intelligence*, USA, 2003.

저 자 소 개

이인근(In K. Lee)

제19권 1호 (2009년 2월호) 참조

E-mail : iklee@ynu.ac.kr

서석태(Suk T. Seo)

제18권 5호 (2008년 10월호) 참조

E-mail : kenneth78@ynu.ac.kr



석지권(Jikwon Seok)

1982년 : 충남대학교 기계공학교육과 (학사)

1991년 : 경북대학교 대학원 기계공학전공 (공학석사)

2002년 : 경북대학교 대학원 기계공학과 (공학박사)

현재 : 안동과학대학 자동차과 교수

관심분야: 연소 공학, 제어공학, 자동차공학

E-mail : seok3589@asc.ac.kr

권순학(Soon H. Kwon)

제19권 1호 (2009년 2월호) 참조

E-mail : shkwon@yu.ac.kr