

論文 90-27-6-18

## 부분적으로 가려진 물체의 인식 룰의 습득

## (Learning Rules for Partially Occluded Object Recognition)

鄭宰泳\*, 金文鉉\*\*

(Jae Young Jeong and Moon Hyun Kim)

## 要 約

물체간의 모든 겹침 현상에도 불구하고, 물체를 인식할 수 있는 전문가의 지식을 시스템에 직접 부여하기는 어려운 과제이다. 본 논문에서는 시스템에 공급되는 가려진 물체의 훈련 뷰들로부터 자동적으로 물체 고유의 특징을 추론하는 방식을 제안한다. 이 방식은 제한된 갯수의 훈련 뷰들의 집합으로부터 룰을 유추하고, 유추된 룰을 차후에 입력되는 뷰들로부터 검증하는 과정을 반복함으로써 점차적으로 룰을 습득하는 방식이다. 습득된 룰은 논리 형태로 표현되도록 하여, 전문가에 의한 이해 및 해석을 용이하도록 하였다. 제안된 방식을 겹침 현상을 모의 실험하여 인식률의 습득 및 이에 의한 인식률의 향상을 보임으로서, 실제적인 3차원 물체 인식 시스템에의 적용 가능성을 보였다.

## Abstract

Expertise of recognizing an object despite of every possible occlusions among objects is difficult to be provided directly to a system. In this paper, we propose a method for inferring inherent shape-characteristics of an object from training views provided. The method learns rules incrementally by alternating the rule induction process from limited number of training views and the rule verification process from the following training views. The learned rules are represented using logical expressions to enhance the readability. The proposed method is tested by simulating occlusions on 2-dimensional objects to examine the learning process and to show improvement of recognition rate. The result shows that it can be applied to a practical system for 3-dimensional object recognition.

## I. 서 론

물체의 자동 인식은 물체를 보는 각도에 따라 영상 평면에 투영되는 형상이 달라지고, 물체간의 겹침 현상에 따라 보이는 부분이 달라지기 때문에 다음과

같은 문제점이 있다. 즉, 회전 및 보는 시각에 무관한 물체의 특징 설정의 어려움과, 설정된 특징이 겹침 등의 현상으로 영상에 나타나지 않을때의 인식의 어려움이다. 이의 해결을 위한 한 방안으로, 물체의 특징 및 인식률을 설정하여 시스템에 부여하는 대신, 모든 가능한 형상을 입력 데이터로 주고, 이로부터 자동적으로 물체 고유의 형상적 특징을 유추해내는 연구가 패턴 인식과 인공 지능 분야에서 활발하다<sup>1-4)</sup> 패턴 인식의 통계적인 접근 방식에서는 주로 주어진 데이터를 수치화된 특징들의 벡터로서 묘사하며, 특징 공간 상에서 이 벡터들 간의 거리에 의하여 군

\*準會員, \*\*正會員, 成均館大學校 情報工學科  
(Dept. of Information Eng., Sungkyunkwan Univ.)

接受日字: 1990年 2月 27日

(※ 이 연구는 89년도 한국과학재단 연구비지원에 의한 결과임. 과제번호: 893-0801-006-1)

집을 파악하는 클러스터링 기법이 연구되어 왔다. 또한, 구문론적인 방식에서는 물체의 구조적 특징을 표현할 수 있는 문법을 추론하는 연구가 있어왔다. 그러나, 이상의 방식은 우선 유추된 룰이 한정된 표현, 즉 수식이나 문법으로 표기되어 습득될 수 있다는 제약이 따르고, 인간에게 쉽게 소속 클래스의 특징을 표현할 수 없으며, 인식 물체 도매인에 관련된 일반적인 지식을 물체의 클래스에 사용하기가 용이하지 않다는 문제점이 있다.

인공 지능의 접근 방식에서는 주로 인간의 개념 습득<sup>15-17</sup>과정을 모사하여, 우선 개념의 구조적인 계층 관계를 정의하고, 전문가의 지식을 논리적인 표현으로 시스템에 부여함으로써, 지식의 전달 및 습득된 룰의 이해를 용이하도록 하였다.

그러나, 인공 지능에서의 접근 방식을 물체 인식에 적용하기 위해서는

- i) 각 특징들의 값이 정수 값이거나, 실수의 경우 유한개의 범위(range)로 미리 구획화되어야 하며,
- ii) 이들이 유추해내는 개념은 논리적으로 일치(consistent), 즉 하나의 샘플 영상은 반드시 하나의 물체로만 인식되어야 한다는 제약이 따른다.

즉, 컴퓨터 시각<sup>18-21</sup>과 같이 특징들(예를들면, 물체 경계선의 길이)이 연속적인 실수 값을 가질때 어떤 방식으로 유한개의 범위로 분할할 것인가, 물체간의 겹침이나 보는 각도에 의해 물체 고유의 특징이 나타나지 않았을때 화물적으로 어떤 물체로 인식할 것인가의 문제가 해결되지 않고 있다.

이러한 관점에서, 초기에 주어진 특징값 범위를 설정된 인식룰에 이를때까지 점차 세분화하거나, 실수값을 갖는 특징 벡터들로부터 유한개의 범위를 자동으로 추론해내는 연구가 진행되어 왔다. 특히 A. Jain은 한 영상이 임의의 물체에 속할 확률 개념을 도입함으로써 위의 문제들을 부분적으로 해결<sup>10-11</sup>하였다. 그러나, 그의 방식은 각 물체의 모든 뷰(view)에 관한 샘플 데이터가 공급되었을 때, 이로부터 고유의 인식룰을 추론하고 있다. 따라서 룰 베이스가 형성된 후 새로운 샘플들이 공급되면, 기존의 룰 베이스는 사용되지 않고, 처음부터 추론 과정을 재반복해야 한다는 문제가 있다.

본 논문에서는 이러한 관찰에서, 제한된 수의 샘플 데이터로부터 인식 룰을 추론하는 과정을 되풀이함으로써, 최종 인식 룰을 습득하는 점차적 습득과정<sup>12-13</sup>을 연구하였다.

따라서 본 방식은,

- i) 습득 과정에서도 기존에 습득된 룰 베이스를 인식에 활용할 수 있으며,

- ii) 방대한 샘플 데이터로부터 인식 룰을 추론하는 계산 부하를 분산시킬 수 있으며,

- iii) 수치적인 특징의 경우, 유한개의 범위로 나누어 기호화하고 nominal 특징을 포함시킴으로써, 습득된 룰이 논리적으로 표기되어 이해하기 쉽도록 하였다.

II 장에서는 제안된 습득 구조를 설명하였고, III 장에서는 이를 이차원 물체에 가려짐 현상을 모사하여 인식 실험을 행하여 보였다.

## II. 자동 룰 베이스 습득

제안된 습득 시스템은 입력 신호 S를 영상신호로 두고, 이로부터 영상의 특징을 추출하여 특징 벡터 F로 표현하는 특징 추출 부분, 특징 벡터 F를 룰 베이스와 비교함으로써 소속 클래스를 결정하는 인식 부분, 공급된 훈련 샘플들로부터 새로운 룰을 생성하는 습득 부분으로 구성된다. 본 장에서는 제안된 룰 베이스에 의한 인식 및 습득 과정을 주로 설명하기로 한다.

### 1. 물체의 인식구조

i번째 영상 신호  $S_i$ 는 식(1)과 같이, 각 특징의 값이 양자화된 특징 벡터  $F_i$ 로 표기된다.

$$F_i = \bigwedge_{j=1}^{n_f} (f_j, v_j^{n_j}) \quad (1)$$

단,  $n_f$ 는 특징의 갯수,  $v_j$ 는 j번째 특징  $f_j$ 의 도메인, 그리고  $v_j^{n_j} \in v_j$ 이다. 이때 특징  $f_j$ 는 nil 값을 가질 수 있으며, 이는 특징이 계층적인 구조를 갖는 경우에 발생한다.

예를 들어, 물체의 볼록한 부위의 폭 및 높이의 특징들은 입력된 영상이 볼록한 형상의 특징을 가질때에만 실제적인 값을 갖고, 아니면 nil이 된다. n개의 서로 다른 물체를 인식하는 시스템의 경우, 각 물체는 하나의 클래스가 되며, 룰 베이스는  $\{R_1, R_2, \dots, R_n\}$ 으로 구성되어, 물체  $C_i$ 에 대한 인식 룰은 집합  $R_i$ 로 표기된다. 각 물체의 인식 룰은 특징의 집합  $\{f_1, f_2, \dots, f_{n_f}\}$ 으로 구성되는  $n_f$ 차 특징 공간을 물체 고유의 grid 형태로 분할하는 것으로 다음과 같이 구축된다.

하나의 K차 원소 공간  $P_e$ 는  $\bigwedge_{j \in R} (f_j, v_j^{n_j})$ 로써 정의되며, R은 인덱스 j,  $1 \leq j \leq n_f$ 의 집합으로 R의 cardinality는 K가 된다. 즉  $P_e$ 는  $j \in R$ 인 모든 j에 대하여  $f_j$ 의 값이  $v_j^{n_j}$ 인 특징 벡터의 합집합으로 특징 공간의 부분공간이다.

한 물체  $C_k$ 의 인식룰  $R_k$ 는  $\mu(P_e(i), cf_e(i))$ 로 정

의되며,  $cf_e(i)$ 는 특징 벡터  $F_i$ 가  $P_e(i)$ 의 원소일 때,  $C_k$ 클래스로 인식되는 신뢰도를 나타낸다.  $cf_e(i)$ 는 습득 과정에서  $P_e(i)$ 가 포함하는 훈련 샘플의 분포로 산출되며, 자세한 계산 과정은 다음 절에서 설명한다.

이상의 인식 물에 대한 정의의 이해를 돕기 위해서, 특징 공간을 3차원으로 가정하고, 물체  $C_i$ 인 인식 물과 특징 공간의 분할 관계를 예를 들어 도시하면 그림 1과 같다. 즉 특징  $f_1, f_2, f_3$ 는 각각 도메인  $\{v_1^1, v_1^2, v_1^3\}, \{v_2^1, v_2^2, v_2^3\}, \{v_3^1, v_3^2, v_3^3\}$ 를 갖고,  $P_e(1)$ 은  $f_1$ 이  $v_1^1, f_2$ 가  $v_2^2$ 를 갖는 특징 벡터의 집합으로 2차 원소 공간이 된다.  $P_e(2)$ 의 경우,  $f_3$ 가  $v_3^3$ 를 갖는 특징 벡터의 집합으로 1차 원소 공간이 된다. 각 원소 공간의 논리적 표현은 그림 1과 같다.




그림 1. 인식물과 특징 공간의 분할 관계  
Fig. 1. Relation between rules and feature space partitioning.

샘플의 인식은 우선, 각 클래스별로 인식 물의 원소 공간 중 샘플 뷰  $F_i$ 가 소속된 원소 공간을 수집하여, working set  $W, W = \{W_1^1, W_2^1, \dots, W_n^1\}$ , 를 형성함으로써 시작된다. 여기서  $W_k^1$ 는 클래스  $C_k$ 의 인식 물  $R_k$ 중  $F_i$ 가 소속되는 원소 공간  $P_e$ 를 fired rule  $P_r$ 로 두면,  $P_r$ 의 집합이 된다. 즉  $W_k^1 = \bigcup_{i=1}^{n_{ek}} P_r(i)$ 이며, 이때  $n_{ek}$ 는 fired rule의 개수이다. 다음에는 모든  $K$ 에 대하여 샘플이 그 클래스  $K$ 에 소속되는 신뢰도,  $a_k$ 를 아래와 같이 계산하여 이들의 집합  $A, A = \{a_1, a_2, \dots, a_n\}$ , 를 구한다.

```

cf(0)=0
Q(0)=ϕ
for i=1 to nek
begin
  Q(i)=Wk1-Q(i-1)
  Ne(i)=Pr(j) (단, cfe(j)=maxm{cfe(m), s. t. Pr(m)
  ∈Q(i)} )
  ncf(i)=cfe(j)
  cf(i)=cf(i-1)+ncf(i)/(1-cf(i-1))
  Q(i)=Q(i-1)-Ne(i)
end
ak=cf(nek)

```

이상에서, 샘플은 집합A 중, 가장 높은 신뢰도를 갖는 클래스에 소속되게 된다.

2. 물의 자동습득

$n$ 개의 물체 인식에서 각 물체  $C$ 마다 그 물체의  $n_c$ 개의 샘플 뷰(훈련샘플)가 제공된다. 즉  $n$ 개의 물체 인식의 경우, 샘플 뷰의 총 갯수는  $\sum_{c=1}^n n_c$ 가 되며, 이들로부터 물 베이스가 생성되어야 한다.

물체  $C$ 의 인식 물은 그 물체에만 속하는 고유의 특징을 추출하여야 한다. 즉 물체  $C$ 의 훈련 샘플의 부분 집합들에 공통적으로 존재하는 성질, 공통성이 있어야 하며, 다른 물체들의 훈련 샘플에서는 존재하지 않는 유일성이 있어야 한다. 점차적인 습득 방식에서는 샘플 뷰들이 한 번에 주어지지 않고, 소수의 단위로 나뉘어 주어지며, 이들로부터 물을 생성하는 단계와, 생성된 물을 검증하는 단계로 나뉘어 진다, 즉 물의 생성시 소수의 샘플 뷰에 근거하였기 때문에 생성된 물의 신뢰도가 낮으므로, 이를 추후 입력되는 샘플들에 적용하여 봄으로써 신뢰도의 수정을 이룬다.

이들 과정의 처리 순서를 살펴보면, 그림 2에서와 같이 물체  $C$ 의  $i$ 번째 물의 생성과정 후의 물 베이스를  $R_c^i$ 로 두면, 다음  $i+1$ 번째 물의 생성시까지  $R_c^i$ 는 제공되는 훈련 샘플들에 의하여 수정이 일어나며,




그림 2. 물의 생성과 검증 과정  
Fig. 2. Rule generation and verification process.

$i+1$ 번째 생성시에 만들어지는 물이  $r_i^c$ 이라 하면, 물 베이스는  $R_i^c \cup r_i^{c+1}$ 로서 확장된다. 이때,  $R_i^c$ 는  $i+1$ 번째 물 생성 순간의  $R_i^c$ 의 수정된 물 베이스를 나타낸다.

1) 물의 생성

물체 C의 샘플뷰를 C의 인식물 생성을 위한 양의 샘플, 다른 물체의 샘플뷰를 음의 샘플로 규정할 때, 이들이 각각 제한된 수  $n_p, n_n$ 만큼 공급되면, 생성과정이 시작된다. 우선 각 샘플뷰를 특징 벡터화 함으로써 특징 공간상에 위치시키고, 이들로부터 공통성과 유별성을 만족시키는 물, 즉 원소 공간을 찾는다. 이 때, 원소 공간  $P_e$ 가 공통성과 유별성을 갖는지는 식(2)의 조건을 만족하는지의 여부로 판단된다.

$$cf(P_e) = \alpha * D_p(P_e) + (1 - \alpha) * \frac{N_p(P_e)}{N_t(P_e)} > \text{임계치}$$

$$(0 \leq cf(P_e) \leq 1) \quad (2)$$

단,  $N_p$ 와  $N_t$ 는 각각  $P_e$ 내의 양과 음의 샘플의 개수를 나타낸다. 또한  $D_p$ 는  $P_e$ 내의 양의 샘플의 분포 밀도로서 식(3)과 같이 추정된다.

$$D_p(P_e) = \frac{N_p(P_e)}{\{P_e\text{내의 가능한 모든 특징벡터의 개수}\}} \quad (3)$$

그러나,  $P_e$ 를 구성하는 경우의 수가 방대하므로 ( $\sum_{i=1}^{n_i} n_i C$ , 단,  $n_i$ 는  $v_i$ 의 cardinality), 다음과 같은 경험적 탐색 방법을 사용한다. 먼저, 원소 공간의 구축시, 한 특징축 방향으로의 폭을 그 특징의 하나의 값으로 제한한다.

아래에 트리 탐색 방식에 의한 구체적인 알고리즘을 설명한다. 트리에서  $i$ 번째 레벨의 노드는  $i$ 차 원소 공간을 나타내며, 각 노드는 그 원소공간이 포함하고 있는 양의 훈련 뷰들과 음의 훈련 뷰들의 집합을 속성으로 갖고 있고, 노드를 연결한 임의의 arc  $a_i$ 는 특징과 특징값의 순서쌍,  $(f_i, v_i^{n_i})$ , 의 속성을 갖고 있다. Arc  $a_i$ 로 연결된  $i$ 번째 레벨의 노드  $x$ 와  $i+1$ 번째 레벨의 노드  $y$ 사이에는,  $y$ 의 원소 공간이 특징  $f_i$ 의 값이  $v_i^{n_i}$ 인  $x$ 의 원소 공간의 부분 집합인 관계가 있다.

물 생성 알고리즘

[초기화] • 트리의 근 노드에 수집된 양의 훈련 뷰와 음의 훈련 뷰들의 집합을 기록한다.

• 후보 목록  $L_c$ 에 근 노드를 기록한다.

[1단계]  $L_c$ 가 공집합이 될 때까지 다음을 반복한다

1.  $L_c$ 에서 식(2)에 의하여 최고의 신뢰도를 갖는 후보 노드,  $n_c$ 를 선정하여  $L_c$ 에서 삭제한다.

2.  $n_c$ 의 값이 임계치,  $T_r$ 보다 크면, 터미널 노드로 선언하고 1로 되돌아간다.

3.  $n_c$ 의 레벨이 주어진 임계치,  $T_a$  보다 크면, 1로 되돌아간다.

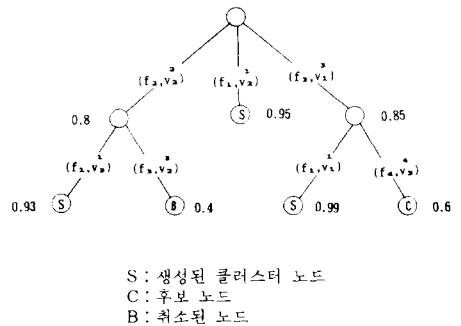
4.  $n_c$ 의 원소 공간을 하나의 특징과 특징값의 쌍을 명시함으로써, 한 차원 낮은 부 공간으로 나누고, 이들 중 신뢰도 값이 임계치  $T_c$ 보다 큰 공간을 후보 공간이라 한다. 각 후보 공간은 노드를 생성하고  $n_c$ 와 arc로 연결함으로써 트리에 기록된다. 각 후보 공간들을  $L_c$ 에 등록한다.

[2단계] 각 터미널 노드는 물이 되며, 근 노드로부터 그 노드까지의 경로상에 있는 arc의 속성을 논리적 AND로 취하여 원소 공간을 묘사하고, 이 공간이 포함하고 있는 양의 샘플의 개수  $n_p$ , 음의 샘플의 개수  $n_n$ , 신뢰도  $cf$ 를 그 물의 속성으로 명시하여 표현한다.

이상의 단계를 각 클래스에 대해 반복함으로써 물을 생성하게 되며, 예시하면 그림 3과 같다.

2) 물의 검증

위의 단계에서 생성된 물이 합하여진 새로운 물 베이스는, 이 후 들어오는 훈련뷰에 의하여 검증이 일어난다. 물체 C의 하나의 훈련 뷰  $V_c^i$ 가 입력되면, C의 인식 물 중,  $V_c^i$ 를 포함하는 원소 공간의 물을 일치(consistent)물이라 하고, C 이외의 물체의 인식 물 중,  $V_c^i$ 를 포함하는 원소 공간의 물을 불일치(inconsistent)물이라 한다. 이때 검증 과정은 모든  $c$ 와  $i$ 에



생성된 물 :  $\{(f_2, v_2^2) \wedge (f_1, v_1^1)\}$   
 $\{(f_1, v_1^1)\}$   
 $\{(f_1, v_1^1) \wedge (f_1, v_1^1)\}$

그림 3. 샘플 클러스터링에 의한 물의 생성  
 Fig. 3. Rule generation by sample clustering.

대하여  $V_k^i$ 의 일치률의 양의 샘플의 갯수를 1 증가시키고, 불일치률에 대하여서는 음의 샘플의 갯수를 1 증가시킴으로써, 식(2)에 의해 일치률과 불일치률의 신뢰도를 각기 증가시키거나 감소시킨다.

III. 모의실험

이차원 물체에 직사각형의 window를 설치함으로써, 겹침 현상을 모의 실험하였다. 대상 물체로는 그림4의 두 나라를 선택하였으며, window의 배치방법은 그림5와 같이 반드시 연속적인 경계선이 보이도록 하거나, 경계선이 불연속적이 되게끔 하는 두 가지 방식을 사용하였다. 두 가지 방식으로 사용한 이유는, 첫째 방식의 경우 경계선의 특징만을 추출할 수 있도록 하고, 둘째 방식의 경우 window내의 영역적인 특징도 추출할 수 있도록 하여, 인식 물을 비교하기 위함이다. 실험에서는 물의 습득 이전, 즉 초기 상태에서 몇 개의 인식 물을 제공함으로써, 습득에 소요되는 시간을 줄이도록 하였다.

영상으로 부터의 특징 추출부는 C로써, 물 베이스 습득 구조는 Lisp로써 IBM PC 상에서 구현하였다. 전체의 습득 과정은 첫번째 방식의 경우 6번, 두번째 방식의 경우 10번의 추론 과정을 거치며, 한 번의 추론 과정은 훈련 뷰가 클래스별로 각각 10개씩 공급되었을 때 동작되도록 하였다. 이때,  $i$ 번째와  $i+1$ 번째의 추론과정 사이(이를  $i$ 번째 훈련 기간(training period)이라 부른다)에 수집된 클래스 K의

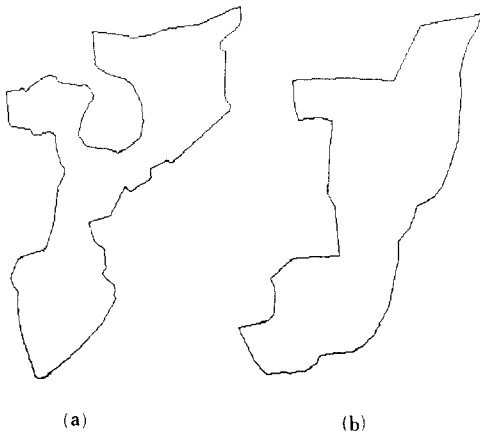


그림 4. 선정된 대상 물체(두 나라)  
 (a) 콩고 (b) 모잠비크  
 Fig. 4. Objects selected(two countries).  
 (a) Kongo (b) Mosambik




그림 5. 연속적인 경계선의 window 배치 방법  
 Fig. 5. Window located on the continuous boundary.

훈련 뷰의 집합을  $V_k^i$ 라 둔다.  $i$ 번째 훈련 기간에서 바르게 샘플을 인식한 인식을  $R_i$ 는,  $V_k^i$ 중 클래스 K로 인식된 샘플의 집합을  $D_k^i$ 라 할 때, 식(4)와 같이 정의된다.

$$R_i = \frac{\sum_{k=1}^2 |D_k^i|}{\sum_{k=1}^2 |V_k^i|} \quad (4)$$

또한 습득 효과를 보이기 위해서,  $i$ 번째 훈련기간 동안에 습득된 물이 인식에 미치는 기여도  $E_i$ 를 식(5)와 같이 정의하였다.

$$E_i = \frac{\sum_{k=1}^2 m_k^i}{\sum_{k=1}^2 \{m_k^i + n_k^i\}} \quad (5)$$

단,  $m_k^i$ ,  $n_k^i$ 는 각각  $i$ 번째 훈련 기간 동안에 훈련 샘플을 만족시키는 K 클래스의 습득된 물 및 초기에 공급된 물의 갯수를 나타낸다.

• 연속적인 경계선의 window 방식

영상에 총 경계선 길이의 30%가 되는 경계선이 보이도록 window의 크기를 설정하였으며, window의 위치는 균일한 확률 분포를 갖는 랜덤 변수를 취하여 다수개의 샘플 집합  $S_j$ 를 만들었다. 보이는 경계선을  $\psi$ -S 곡선으로 변환한 후,  $\psi$ -S 곡선 상에서 표 1과 같은 특징들을 추출하였으며, window 내에 존재하지 않는 특징은 nil값을 갖는다.

습득 과정에 따라 인식률과 기여도의 변화를 그림

표 1. 연속적인 경계선의 window 방식에서 추출된 특징들

Table 1. Extracted features in the method of window on the continuous boundary.

볼록한 곡선 부분의 특징(폭, 높이)
오목한 곡선 부분의 특징(폭, 깊이)
직선 부분의 기울기
직선 부분의 선형도
직선 부분의 대칭성




그림 6. 연속적인 window 방식에 의한 인식률의 변화

Fig. 6. The change of recognition rate by the method of window on the continuous boundary.




그림 7. 연속적인 window 방식에 의한 기여도의 변화

Fig. 7. The change of contribution rate by the method of window on the continuous boundary.

으로 표현하면, 각각 그림6,7과 같다. 인식률은 물의 습득에 따라 점차 향상되어, 초기의 인식률 0.5에 비해 최종 인식률은 0.95로 향상되었고, 습득된 물이 인식 과정에 참여하는 룰도 점차 높아져서, 최종적으로는 약 80%에 도달하고 있다. 최종적으로 습득된 룰의 예를 보이면 표2와 같고, 이해를 돕기 위해 이를 해석한 결과가 표 3에 있다.

• 불연속적인 경계선의 window 방식

이차원 영상으로부터 그림8과 같이 직사각형의 window를 씌워서 하나의 입력 샘플을 구하였으며, 영상은 45°, 90°의 회전이 가능하도록 하였다. Window의 크기는 수평 방향으로서는 영상의 경계선이 모두 포함될 수 있도록 하였고, 수직 방향으로서는 물체의 최대 거리의 1/6이 되도록 하였다. 이 때 영상의 경계선으로부터 추출되는 특징은 표4와 같으며, 여기에

표 2. 연속적인 경계선의 window 방식에서 습득된 룰의 예

Table 2. Examples of rules learned in the method of window on the continuous boundary.

클래스 1	• 룰 1 :if (negative-dull-small 1) then(class-1) attr. (13 1 0.928);(양의샘플수,음의샘플수,신뢰도)
	• 룰 2 :if { (positive-dull-small 1) (flat 2)} then (class-1) attr. (7 0 0.995)
	• 룰 3 :if { (negative-sharp-middle 1) (positive-dull-small 1)} then (class-1) attr. (7 0 0.995)
	• 룰 4 :if (flat 4) then (class-1) attr. (3 0 0.989)
클래스 2	• 룰 1 :if (right-biased-decreasing-middle 1) then (class-2) attr. (29 0 0.999)
	• 룰 2 :if { (negative-sharp-small 1) (positive-sharp-long 1)} then (class-2) attr. (6 0 0.994)
	• 룰 3 :if { (negative-sharp-small 1) (left-biased-increasing-long 1)} then (class-2) attr. (3 0 0.989)
	• 룰 4 :if (right-biased-decreasing-small 1) then (class-2) attr. (14 0 0.998)

표 3. <표2>의 습득 룰의 해석

Table 3. Analysis of rules learned in the <Table 2>.

클래스 1	• 룰 1:완전히 감소하는 짧은 직선이 존재한다.
	• 룰 2:보통 크기의 편평한 부분이 있고, 근접한 곳에 완만히 증가하는 작은 직선이 존재한다.
	• 룰 3:급격히 감소하는 보통 크기의 직선이 있고, 근접한 곳에 완만히 증가하는 작은 직선이 존재한다.
	• 룰 4:매우 편평한 부분이 존재한다.
클래스 2	• 룰 1:오른편에서 최대 곡률을 가지고, 직선 $y=ax$ (a:양수)에 관하여 대칭성이 있는 보통 크기의 primitive 파형(한극점과 다음 극점사이)이 존재한다.
	• 룰 2:급히 감소하는 짧은 직선이 존재하며, 근접한 곳에 기울기가 양인 긴 직선이 존재한다.
	• 룰 3:급히 감소하는 짧은 직선이 존재하며, 왼편에서 최대 곡률을 가지고, 직선 $y=-ax$ 에 관하여 대칭성이 있는 큰 primitive 파형이 존재한다.
	• 룰 4:오른편에서 최대 곡률을 가지고, 직선 $y=ax$ (a:양수)에 관하여 대칭성이 있는 작은 크기의 primitive 파형이 존재한다.




그림 8. 불연속적인 경계선의 window 배치 방법  
Fig. 8. Window located on the discontinuous boundary.

서 폭은 window내의 좌측 경계선으로부터 같은 높이의 우측 경계선까지의 길이를 나타낸다. 인식률 및 기여도의 변화를 보면 그림9, 10과 같다. 연속적인 경계선의 인식 방법에 비해, 최종 인식률이 높지 않고, 습득된 룰의 기여도가 낮은 이유는 window의 크기가 충분히 크지 않고(약 20%), 설정된 특징들이

표 4. 불연속적인 경계선의 window 방식에서 추출된 특징들

Table 4. Extracted features in the method of window on the discontinuous boundary.

경계선의 길이의 합
폭의 평균 변화율
평균 폭
편평한 부분의 길이
굴곡의 정도




그림 9. 불연속적인 window 방식에 의한 인식률의 변화

Fig. 9. The change of recognition rate by the method of window on the discontinuous boundary.




그림 10. 불연속적인 window 방식에 의한 기여도의 변화

Fig. 10. The change of contribution rate by the method of window on the discontinuous boundary.

표 5. 불연속적인 경계선의 window 방식에서 습득된 룰의 예

Table 5. Examples of rules learned in the method of window on the discontinuous boundary.

클래스 1	<ul style="list-style-type: none"> <li>• 룰 1 : if { (width-type1 1) (length-type 1st) (Dwidth steep) } then (class-1) attr. (3 1 0.911)</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 2 : if { (Dwidth slow) (flat-small 1) } then (class-1) attr. (3 1 0.911)</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 3 : if { (width-type3 1) (width-type2 4) (length-type 2nd) } then (class-1) attr. (3 0 0.916)</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 4 : if { (Dwidth slow) (length-type 2nd) } then (class-1) attr. (5 2 0.910)</li> </ul>
클래스 2	<ul style="list-style-type: none"> <li>• 룰 1 : if { (Dwidth slow) (width-type2 3) (length-type 2nd) } then (class-2) attr. (2 1 0.904)</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 2 : if (intersect 4) then (class-2) attr. (14 19 0.791)</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 3 : if { (length-type 3rd) (intersect 3) (flat middle 1) } then (class-2) attr. (2 1 0.904)</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 4 : if { (length-type 2nd) (width-type3 4) (width-type2 1) } then (class-2) attr. (2 1 0.904)</li> </ul>

회전에 무관하지 않음으로써 효율적인 룰이 습득되지 않고 있음을 알 수 있다. 최종적으로 습득된 룰의 형태를 보이면 표5와 같고, 이를 해석한 결과가 표6에 있다. 클래스 2의 룰 2의 경우, 습득 과정을 반복함에 따라 룰의 신뢰도가 매우 떨어졌는데, 이는 영상의 회전에 민감한 특징이 존재하기 때문이다.

IV. 결 론

본 논문에서는 가려진 물체의 인식을 위하여, 공급

표 6. <표 5>의 습득 룰의 해석

Table 6. Analysis of learned rules in the <Table 5>.

클래스 1	<ul style="list-style-type: none"> <li>• 룰 1: 경계 길이가 11-20이고, 폭이 급격히 변화하는 영역이 존재하며, 내부에는 폭이 1-5인 행이 단 하나 존재한다.</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 2: 폭이 완만히 변화하는 영역이 존재하며, 내부에 평평한 부분이 존재한다.</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 3: 경계 길이가 11-20인 영역이 존재하고, 내부에 폭이 6-10인 행이 넷, 11-15인 행이 하나 존재한다.</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 4: 경계 길이가 11-20이고, 폭이 완만히 변화하는 영역이 존재한다.</li> </ul>
클래스 2	<ul style="list-style-type: none"> <li>• 룰 1: 경계 길이가 11-20이고, 폭이 완만히 변화하는 영역이 존재하며, 내부에는 폭이 6-10인 행이 셋 존재한다.</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 2: 굴곡이 매우 큰 영역이 존재한다.</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 3: 경계 길이가 21-30이고, 굴곡이 큰 영역이 존재하며, 내부에는 상당히 평평한 부분이 존재한다.</li> </ul>
	<ul style="list-style-type: none"> <li>• 룰 4: 경계 길이가 11-20인 영역이 존재하며, 내부에는 폭이 6-10인 행이 하나 존재하고, 11-15인 행이 넷 존재한다.</li> </ul>

된 훈련 샘플들로부터 영상의 경계선의 특징을 룰 베이스로 추론해 내는 방식을 보였다. 이 방식은 특히 기존의 룰 습득 방식과는 달리, 작은 수의 훈련 샘플들로부터 인식 룰을 반복적으로 습득함으로써, 추론과정의 부하를 줄이고, 기존에 습득된 룰 베이스를 인식에 활용하면서, 자동적으로 수정·경신해 나가는 점차적인 룰 습득 방식이다.

룰 습득 구조를 가려진 물체의 경계선만의 정보에 의하여 인식하는 과정을 모의 실험함으로써, 제안된 방식의 타당성 및 그 효과를 보였으나, 실용적인 물체 인식의 경우에는 영상으로부터 면의 가우스 곡률, 평균 곡률 등과 같은 다양한 3차원의 정보를 추출하여, 실제적인 물체 인식 실험이 필요하겠다. 즉 실험 결과에서 알 수 있듯이, 가려진 물체의 경우 경계선만의 정보로는 완전한 인식을 행하기 힘들며, 이를 위해서는 영상으로부터 풍부한 3차원 특징의 추출과, 이들 특징값을 좀 더 세분화하는 기술이 요구된다.

參 考 文 獻

[1] R.S. Michalski, "A theory and methodology of inductive learning," *Artificial Intelligence*, vol. 22, pp. 111-161, 1983.  
 [2] Y. Cheng and K.S. Fu, "Conceptual clustering in knowledge organization," *IEEE Trans. on Pattern Anal. Machine Intell.*, vol. PAMI-7, no. 5, Sep. 1985.



- [3] Y. Kodratoff and G. Tecuci, "Learning based on conceptual distance," *IEEE Trans. on Pattern Anal. Machine Intell.*, vol. 10, no. 6, Nov. 1988.
- [4] C.T. Zahn, "Graph-theoretical methods for detecting and describing gestalt clusters," *IEEE Trans. on Computers*, vol. C-20, no. 1, Jan. 1971.
- [5] R.S. Michalski, J.G. Carbonell and T.M. Mitchell, *Machine Learning*, Tioga, 1983.
- [6] R.S. Michalski and R.E. Stepp, "Automated construction of classifications: conceptual clustering versus numerical taxonomy," *IEEE Trans. on Pattern Anal. and Machine Intell.*, vol. PAMI-5, no. 4, Jul. 1983.
- [7] E. Giakoumakis, G. Papaconstantinou and E. Skodidakis, "Rule-based systems and pattern recognition," *Pattern Recognition Letters* 5, Apr. 1987.
- [8] W.A. Perkins "A model-based vision system for industrial parts," *IEEE Trans. on Computers*, vol. C-27, no. 2, Feb. 1978.
- [9] T.F. Knoll and R.C. Jain, "Recognizing partially visible objects using feature indexed hypotheses," *IEEE Journal of Robotics Automation*, vol. RA-2, no. 1, Mar. 1986.
- [10] R. Hoffman, A.K. Jain, "Learning rules for 3-D object recognition," *Computer Vision & Pattern Recognition*, 1988.
- [11] A.M. Darwish and A.K. Jain, "A rule based approach for visual pattern inspection," *IEEE Trans. on Pattern Anal. Machine Intell.*, vol. 10, no. 1, 1988.
- [12] S.H. Lee and M.H. Kim, "Expert assisted robot fine motion skill acquisition," *IMACS Inter. Symp. on A.I. Expert Systems and Languages in Modelling and Simulation*, 1987.
- [13] S.H. Lee and M.H. Kim, "Expert assisted robot skill acquisition, part II: skill discovery and experiment," *Technical Report, CRI-86-31. USC*, nov. 17, 1986.
- [14] 정재영, 유병민, 김경미, 김문현, "신호 파형 인식을 위한 물의 습득," 제2회 신호처리 합동 학술대회, 한국통신학회, 1989

---

 著 者 紹 介
 

---



金文鉉(正會員)

1956年 1月 31日生. 1978年 2月 서울대학교 전자공학과 졸업. 1980年 2月 한국과학기술원 전기 및 전자공학과 석사. 1988年 3月 Univ. of Southern California 박사. 1980年 3月~1983年 5月 대우중공업 연구원. 1984年 9月~1988年 3月 Univ. of Southern California 연구조교. 1988年 3月~현재 성균관대학교 정보공학과 조교수. 주관심분야는 컴퓨터 비전, 패턴인식, 전문가 시스템 등임.



鄭宰泳(準會員)

1966年 11月 17日生. 1988年 2月 성균관대학교 정보공학과 졸업. 1990年 3月~현재 성균관대학교 정보공학과 석사과정. 1990年 3月~현재 성균관대학교 정보공학과 조교. 주관심분야는 컴퓨터 비전, 전문가 시스템 등임.