

# 상황 이해를 위한 로봇 지식 체계

한양대학교 임기현 · 서일홍\* · 이상훈\*\*

한국과학기술원 황원일 · 서효원\*

## 1. 서 론<sup>1)</sup>

가정용 서비스 로봇은 사용자의 요구를 이해하고 그들이 사는 환경을 인지해야 하며, 로봇의 Primitive Behavior를 이용하여 임무를 수행해야 한다. 로봇은 환경을 인지하기 위해 Low-level Sensor Data뿐 아니라 High Level Symbolic Data와 같은 다수의 Data가 필요하다. 예를 들면, 상황 인지나 SLAM, 혹은 물체 인식과 같은 작업은 지능 로봇에게 필수적인 High level Perceptual 작업이다. 또한 식사 접대 등의 복잡한 임무를 수행하기 위하여 Navigation, obstacle-avoidance, 집어 옮기기 등의 로봇이 할 수 있는 Primitive behavior의 다양한 조합을 하게 된다. 기존의 로봇 시스템에서는 위와 같은 작업들이 독립적으로 구축되고 로봇들은 자신만의 알고리즘이나 Data 구조를 가졌기 때문에 그것들을 재사용하거나 공유하기가 매우 힘들었다. 따라서 공유와 확장이 가능한 로봇 Knowledge 체계가 요구된다.

Web Ontology Language(OWL)는 인간과 컴퓨터 사이의 공유와 확장을 위한 Concept을 정의한다. 인터넷에서 OWL을 기반으로 하는 Upper Ontology와 Inference Tool에 대한 연구가 많이 이루어지고 있다[6,7,12]. 이러한 온톨로지는 인간의 지식을 표현한다. 그러나 로봇은 인간의 논리에 의해 만들어진 인간 중심의 Ontology로는 Knowledge를 공유하기가 힘들다. 인간은 오감으로 자연스럽게 물체나 Context를 인식할 수 있으나 로봇은 로봇 자신 만의 센서인 카메라나 Encoder, Sonar Sensor를 이용하여 물체나 Context를 파악하여야 하는데 이러한 임무 수행은 인간과 많이 다르다. 게다가 서비스 로봇은 인간의 요구사항을 이해함으로써 인간과 상호 작용을 할 수 있어야 하므로 인간의 지식 또한 다룰 수 있어야 한다.

따라서 본 글에서는 로봇의 Knowledge Framework

를 제안하는데 이 Knowledge Framework는 로봇 중심의 Ontology와 인간 중심의 Ontology를 결합한 것이다. 본 글에서 소개하는 Ontology는 Ontology의 기본 특성인 공유와 증식을 기본으로 하였다. 로봇을 위한 Ontology를 구축함으로써 로봇의 환경에 대한 Knowledge는 포괄적이고 종합적으로 관리될 수 있고 게다가 Inference tools은 잡음이 섞인 센서 때문에 소실되거나 부분적인 Data에 대한 것도 찾을 수 있게 해준다.

## 2. 온톨로지와 온톨로지 표현

### 2.1 Web Ontology Language(OWL)

Ontology는 인간과 컴퓨터가 공유하는 Concept의 집합이다. Web Ontology Language는 Fact, Knowledge, Functions를 아우르는 표준 Concept를 나타내며 이들은 Entity, Relation, Function, Axiom, Instance의 조합으로 구성되어 있다. Ontology를 사용하는 몇 가지 이유로는 Knowledge의 공유, Knowledge의 재사용, 그리고 Logic Inference 등이 있다[12]. 인터넷 상의 지식을 통합하기 위한 현재도 연구 및 확장이 되고 있는 Upper ontology[6]와 특정한 영역의 지식을 표현하는 Domain Ontology를 사용함으로써 컴퓨터가 다른 매체와 상호작용을 하는 동안 같은 Semantics에 대한 Concept의 표준 집합을 가질 수 있도록 한다[9]. 더욱이, Ontology를 이용하였을 경우 Computing Entities는 High-level, Conceptual Information을 Low-level, Raw Data로부터 추론하며 부분적으로 잃어버리거나 잡음 때문에 Inconsistent한 Data[11]를 검사하는 등의 다양한 Logic Inference Mechanism을 이용할 수 있다. 특히 OWL은 DL과 FL이라는 Inference Engine을 기반으로 한다[7].

### 2.2 First Order Logic(FOL)

Ontology의 Concept와 Relation은 다양하고 복잡한 형태로 Modeling되어야 하는데 OWL은 표현이 제

\* 종신회원

\*\* 학생회원

한적이다. 로봇 Domain에서 로봇이 복잡한 Rule을 사용할 수 있도록 Representation Mechanism이 필요하며 따라서 Hidden Knowledge를 찾기 위한 충분한 Inference Tool이 필요하다. Corcho와 Perez [1]는 전통적인 Ontology Language 분야에서 Expressiveness와 Inference Language Engine과 Web기반 Ontology Language 사이의 Tradeoff를 분석하였으며, 그들은 표현력이 풍부할수록 추론력이 약해지는 Tradeoff가 있다고 하였다. 즉 다양한 표현력을 가진 추론엔진은 많은 양의 지식으로 하는 추론에 어려움이 있다.

FOL기반 Language로는 KIF[2]나 Ontolingua [3], Prolog [4] 등이 있다. FOL기반 Language들은 Expressiveness와 Syntax의 구조적인 제한이 적으며, FOL은 Concept나 Relation, Axioms를 충분히 표현 할 수 있다. 본 연구에서는 Numerical Expression이나 Dynamic Variable등의 표현을 하기 위한 Robot Ontology로 FOL을 사용한다. FOL은 로봇이 Backward Chaining이나 Forward Chaining 방법을 이용할 때 Hidden Knowledge를 찾는 Inference Mechanism을 사용 할 수 있도록 한다. 그러나 Classification의 Inference Algorithm이나 Probabilistic Reasoning에서 몇 가지 어려움이 있다. 따라서 로봇 Ontology에는 FOL뿐 아니라 추가적인 Inference 방법이 필요하다. 본 연구에서는 이 부분을 Data mining 분야의 Association 방법을 적용하였다.

### 2.3 Human-centered ontology

기존의 Ontology는 IEEE Standard Upper Ontology Working Group(SUO WG)[6]에 정의된 “Ontology는 사전과 비슷하다. 그러나 더 방대한 세부 사항과 구조는 컴퓨터가 자신의 Contents를 처리하는 것을 가능하게 한다.”라는 내용과 유사하다. Ontology는 인간과 컴퓨터가 인간의 오감을 통해 인식하고 Symbol화 된 Object에 대한 Concept를 공유 할 수 있도록 한다.

관념상의 Symbol과 실제 사물을 연결하는 Symbol Grounding Process는 인간에게 있어서 자연스러운 동작의 하나이다. 예를 들면, 인간은 여러 종류의 과일이 섞여 있는 바구니 안에서 오감을 이용하여 사과를 쉽게 찾을 수 있다. 그러나 로봇이 그와 같은 인식 작업을 수행[16]하기 위해서는 많은 도전이 필요하다. 로봇이 Object Matching을 하기 위해서 다수의 Local Feature를 사용하거나[14], Artificial Neural Net-

work로 구축한 알고리즘에 Shape이나 Color, 혹은 Texture 등의 몇몇 Data를 혼합하는 방법을 이용한다. 그리고 로봇은 Primitive Behavior를 이용하여 주어진 임무를 수행한다. 예를 들어 인간은 자신의 손과 별을 이용하여 냉장고의 음료를 쉽게 꺼내고, 병을 집고, 냉장고 문을 닫고 소파로 돌아오는 반면에 로봇은 냉장고의 문을 인식하거나, 병을 집거나, 문을 닫고 돌아오는 등의 작업도 어려운 일이다.

### 2.4 Robot-centered ontology

Ontology는 로봇의 Knowledge를 공유하거나 재사용함에 있어서 필수이다. 로봇이 주변 환경을 인지하는 것은 인간의 그것과 다르기 때문인데, 본 연구에서는 로봇의 센서나 Behavior를 중심으로 한 Ontology를 제안한다.

로봇은 자신의 센서를 이용하여 물체를 인식하고, 환경을 Modeling하며 주어진 작업의 일련의 순서에 대한 계획을 세우고, Actuator와 Motor를 이용하여 작업을 수행하고 주변 환경을 재인식하거나, 계획을 세우지 않고 미리 프로그래밍된 행동들을 지니고 센서를 이용하여 작업을 수행하는 구조이다[15]. 특히 이러한 센서 정보는 불확실하고 부분적인 정보이다[11]. 서비스 로봇은 주변 상황의 변화에 적응하기 위하여 Context-awareness가 필요하다[9,12,13]. Context는 로봇에게 알맞은 행동 선택 Mechanism을 제공하기 위한 일련의 단서를 제공한다. Context의 유용성을 이용하기 위해 Context 표현이나 공유를 쉽게 하기 위한 정형화 된 Context Model이 필요하다.

본 연구에서는 로봇의 기준으로 상황 인지를 위한 센서 자료 및 자료 처리 방법과 임무 수행을 위한 Primitive behavior를 기반으로 로봇의 행동을 선택하거나 수행하는 것을 돋는 로봇 중심의 Ontology를 정의한다. 그리고 로봇은 인간과 상호작용을 하거나 인간을 만족시키는 것을 가능하게 하는 인간 중심의 Ontology도 요구한다. 따라서 로봇 중심의 Ontology는 인간 중심의 Ontology와 긴밀하게 연결되어 있어야 한다.

## 3. Robot Knowledge

Robot knowledge로는 context and mission 등의 고차원적인 정보에서 센서를 통하여 끊임없이 입력되는 raw data 뿐만 아니라 다른 processing 모듈간의 통신을 위한 자료 구조와 자료 처리를 위한 임시 저장소를 포함한다. 자료 각각은 각자의 생성 주기와 자료 크기를 가지며, 이를 자료들을 생성하기 위해서

data processing algorithm에 따라 다양한 조합의 자료들을 사용하게 된다. 특히 센서 자료를 부분적이거나 불완전한 자료들이 많다. 그래서, 자료의 신뢰성을 확률적인 방법을 주로 사용한다. 그런데 고차원 정보는 symbolic 하고 logic으로 표현되고 추론 된다. 추론 툴은 각각의 facts에서 hidden knowledge를 찾게 되고, 이를 통하여 보다 확실한 확률을 구할 수 있게 된다. 결과에 따라 다시 sensing 과정에 도움을 주게 된다.

Table 1은 로봇에서 생성되는 지식의 종류와 각각의 생성 주기와 생성 정보의 크기 및 생성에 필요한 자원을 나타낸다. 특히 high level information인 spatial context와 temporal context는 센서를 통하여 생성된 모든 자료를 사용하게 된다.

표 1 Example of Robot Knowledge

	생성 주기 (ms)	정보 크기 (byte)	필요 자원
스테레오 카메라	66	$640*480*2 = 614,400$	스테레오 카메라
초음파 센서	50	$12*34=408$	Sonar
Odometer	10	43	Encoder
SIFT	250	약 $300*128 =$ 약 $38,400$	흑백 이미지
Harris corner	100	약 $200*292 =$ 약 $58,400$	흑백 이미지
Object recognition	1000	수십 byte	SIFT
Spatial Context	1000	수십 byte	상위 모두
Temporal Context	요청시	수십 byte	상위 모두

### 3.1 Synchronized and event-driven Short Term Memory(STM)

각각의 정보 중에서 고차원적으로 학습되고 추론된 정보는 영구적으로 사용되는 Long Term Memory(LTM)에 저장되며 되고, Short Term Memory(STM)은 센서 정보와 로봇 task 중심으로 표현된 심볼과 연결하는 일, 서로 다른 모듈간의 데이터 전송을 위한 Data cache 및 로봇 동작시 사용되는 로봇의 위치나, 센서 정보 등이 임시 저장되는 공간으로 사용된다. 끊임없이 많이 발생하는 STM data들은 온톨로지로 표현되는 symbolic data로 추상화되어 LTM에 저장되고, STM은 망각 과정을 통하여 제거됨으로써 제한된 메모리 내에서 새로운 sensor 정보를 받아들이고, 자료 처리 알고리즘을 구동할 수 있게 한다. STM은 블랙 보드 구조로 설계되어 누구나 자료에 접근하여 새로운 정보 생성이 용이하다.

각각의 센서에서 정보 생성 주기에 따라 관리 모듈은 최적화된 시간 동기에 따라 각 정보를 생성하고, 이를 사용하는 상위 모듈도 같은 시간 동기로 설정함으로써 각 정보간 시간 동기화된 정보로 사용할 수 있도록 구현하였다.

시간으로 동기화된 정보 생성뿐만 아니라 관심 있는 특정 event를 등록해 둠으로써, 특정 event 상황이 발생하는 경우에 따라 새로운 정보 생성을 위한 data processing module 을 동작 시킨다. 특히 event driven 방식에서 불완전한 인식 능력으로 숨어 있거나, 잃어버린 정보들을 추론함으로써 consistent data 관리가 가능하여 robot의 sensor data 와 state data를 생성 관리한다. 실제 사용 예로 로봇의 위치 정보, 제어 명령, camera의 위치, 획득된 영상 이미지, 각 영상 이미지에 대한 SIFT descriptor 와 Harris corners 정보를 저장하고 있으면 time index에 따라 동기화 된다.

### 3.2 Context

고차원 정보로 대표적인 것으로 contextual information 이다. 상황정보는 단순히 object recognition이 아니다. 상황정보는 로봇 sensor를 통하여 raw data 입력으로 로봇과 환경, 인간 사이의 상호작용과 관련 있다고 고려되는 사람, 장소 객체인 entity를 인식하고, 인식된 entity들간의 spatial-temporal relation을 통하여 high level context를 유추할 수 있다. 상황정보는 로봇이 인간을 위한 적절한 임무를 수행하고, 다시 raw data를 sensing 하는데 상당한 영향을 끼치게 된다. 예를 들어 수업을 하는 상황이면 교사가 학생들 앞에서 많은 이야기하는 것을 알 수 있고, 수업과 관련 있는 사물들은 추론하여 관련 사물을 주로 인식하고자 하여 아무 정보도 없는 경우에 비하여 보다 빠르고 정확하게 인식 할 수 있게 된다. 이렇게 저 수준의 자료와 고 수준의 자료가 연결되어 단독으로는 찾기 어려운 보다 많은 정보를 얻을 수 있다. Context 정보 또한 time index를 통하여 동기화 된다. 그리고, temporal context 및 high level context의 경우는 on demand 나 특정 event시에 생성된다.

## 4. Ontology-based Multi-layered Robot Knowledge Framework(OMRKF)

증식 및 성장이 가능한 로봇의 지식 체계를 위하여 본 연구팀에서는 온톨로지 기반의 멀티 레이어 로봇 지식 프레임워크 (Ontology-based Multi-layered

Robot Knowledge Framework: OMRKF)를 개발하고자 한다.

OMRKF는 Robot Knowledge Framework로써 지능 로봇이 환경을 인지하는 것을 돋고, 주변 환경을 모델링하거나 작업의 순서를 계획하고 Activity의 선택과 Context Situation의 인지를 수행하도록 한다. Ontology는 Knowledge를 공유하거나 확장하도록 하고 숨겨진 Knowledge를 추론하며 Knowledge의 Hierarchy는 Knowledge를 쉽게 관리 할 수 있도록 한다.

Framework는 4 Level의 Knowledge를 갖는데 다음과 같다. Perception Level, Modeling Level, Context Level, 마지막으로 Activity Level이다. 그리고 각 Level은 3개의 Knowledge Layer로 구성된

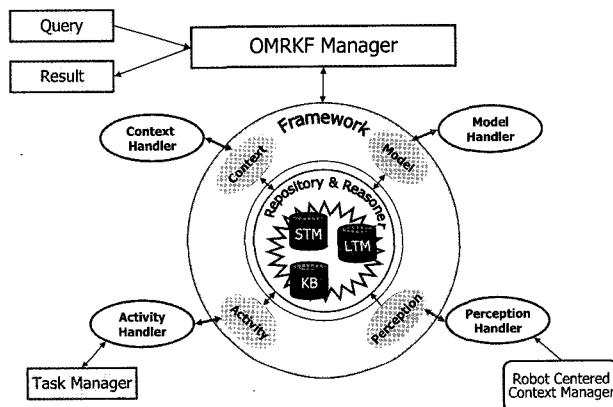


그림 1 The architecture of OMRKF

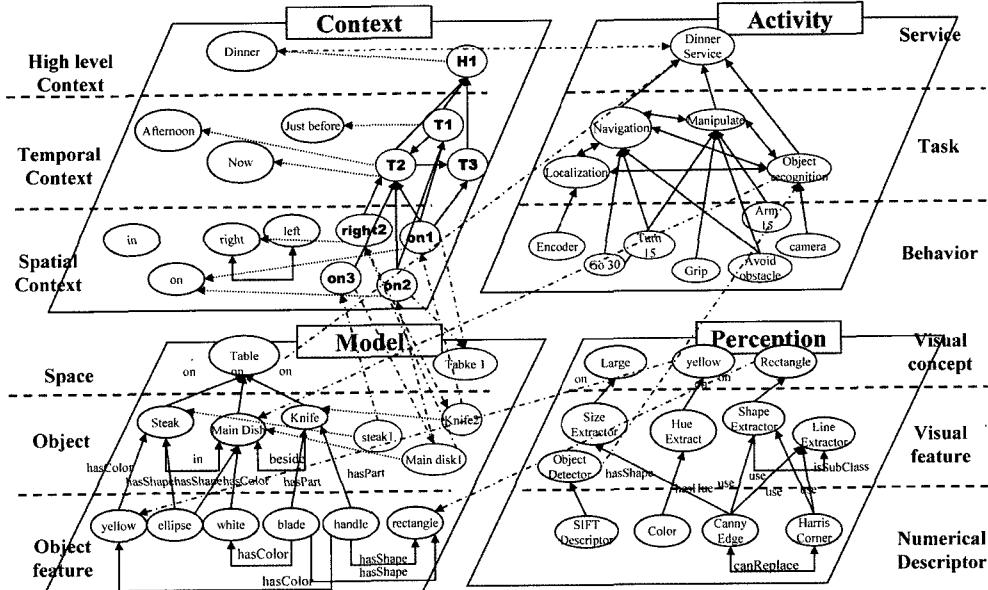


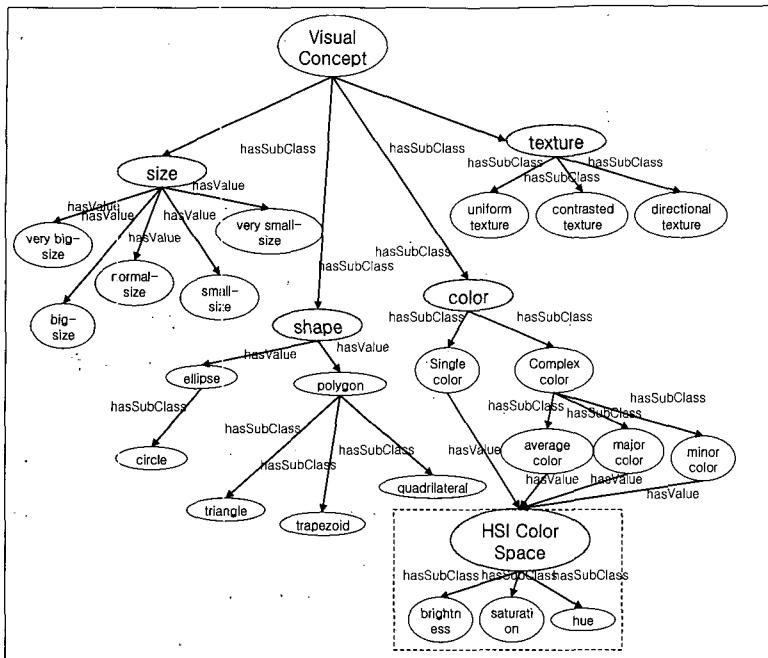
그림 2 Robot-centered ontology and rule Robot-centered ontology has 4 level of knowledge; Perception, Model, Context and Activity. Each level of knowledge have 3 knowledge layer; high level layer, middle level layer and low level layer. And each knowledge layer have 3 ontology layer; meta ontology layer, ontology layer and ontology instance layer. And there are axioms and rules.

다. Layer는 다음과 같다. Low-knowledge Layer, Middle-knowledge Layer 그리고 High-knowledge Layer이다. 각 Knowledge Layer는 Meta Ontology Layer, Ontology Layer, Ontology Instance Layer의 3가지 Ontology Layer를 갖는다. 그리고 Framework는 Axiom과 Rule을 갖는데, Axiom은 같은 Knowledge Layer에서의 Concept의 Relation을 나타내고, Rule은 각 knowledge의 Association이나 Knowledge 사이의 Linkage를 나타낸다. 그림 1은 OMRKF의 구조이다.

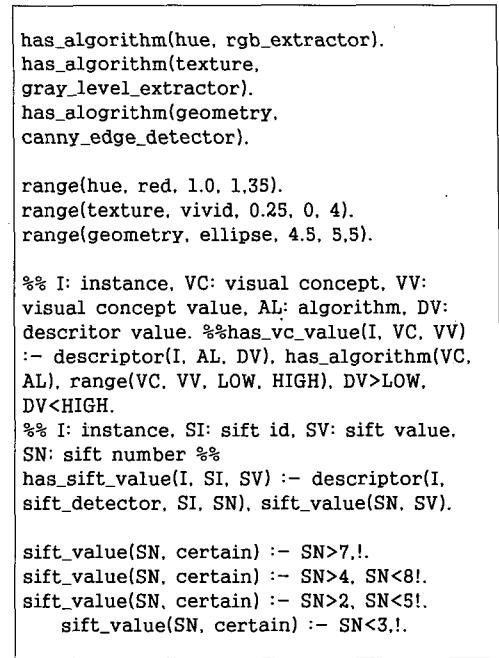
#### 4.1 4 Levels of Knowledge

로봇의 구조로는 로봇이 자신의 센서로 주변 환경을 인식하며, 인식 결과를 바탕으로 환경에 대한 모델을 구축하고, 계획된 작업을 수행하고, 다시 새로이 주변 환경을 인식하거나, 로봇이 Deliberative한 Consideration이 없이 반사적으로 행동을 선택하여 수행한다. 이런 구조는 모두 몇 가지의 기본적인 Module로 구성되는데 각각 Perception, Modeling, Planning, 그리고 Action이다. 그리고 로봇이 올바르게 환경을 인식하거나, 환경을 모델링하거나 작업을 완료하기 위한 그들의 행동을 계획하거나 혹은 주변 환경에 적응하면서 로봇의 행동을 수행하는 등의 로봇 지능을 만들기 위해서는 상황 인지는 필수적이다.

OMRKF는 4 Level의 Knowledge를 가지는데, Perception level, Modeling Level, Activity Level 그



(a) visual concept ontology



(b) visual concept fact and rule

그림 3 Perception level ontology

리고 Context Level로 구성된다. 그리고 Concept들의 Relation과 Knowledge의 Association에 대한 Rules과 Axiom이 존재한다.

그림 2 로봇 중심의 Ontology와 Rule: 로봇 중심의 Ontology는 4 Level의 Knowledge를 가진다. Perception, Model, Context, Activity이다. 각 Level의 Knowledge는 High-level, Middle-level, Low-level의 3개의 Layer를 가진다. 그리고 각 Knowledge Layer는 Meta ontology, Ontology, Ontology Instance의 3가지의 Ontology Layer를 가진다. 마지막으로 Axiom과 Rule이 존재한다. Axiom은 각 layer내에서 정의되고, 다른 Layer간이나 다른 Level간에 규칙은 Rules로 정의 한다.

#### 4.1.1 KBoards - Perception

Perception level의 Knowledge는 3개의 Perception Level: P<sub>1</sub>, P<sub>2</sub>, P<sub>3</sub>을 가진다. P<sub>1</sub>은 로봇의 센서에서 만들어진 센서 데이터를 포함하는 Numerical Descriptor Layer이다. P<sub>2</sub>는 센서 데이터를 처리한 Data Feature Layer이다. P<sub>3</sub>는 로봇의 주변 환경을 인식하기 위한 Data Processing과 Symbol을 Anchoring한 집합인 Visual Concept Layer이다. 로봇은 Vision, Encoder, Sonar와 같은 센서들을 탑재하고 있다. 각 센서들은 SIFT(14)나 DFT혹은 Hue값과 같은 Data Processing Algorithm을 통해 처리한 Numerical Value나 Raw Sensor와 같은 고유의 Numerical Descriptor를 가진다.

그림 3.(a)는 Size, Texture, Shape, Color등을 가지는 Visual Concept Layer의 Ontology Layer의 예시를 나타낸다. 그림 3.(b)는 Prolog에 의한 Visual Concept Rule, Fact 혹은 Instance를 표현한다.

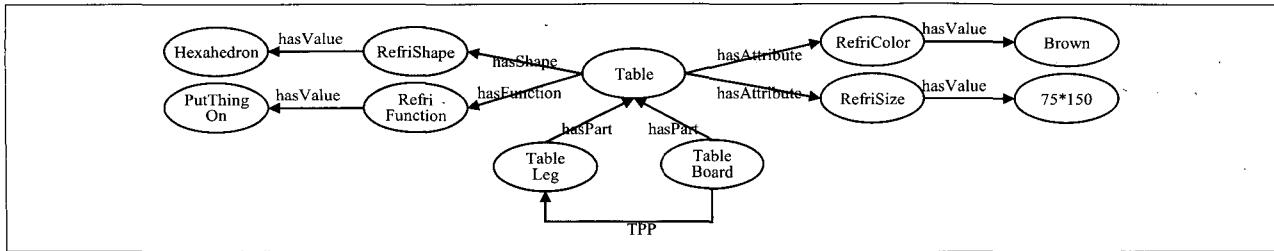
#### 4.1.2 KBoards - Model

Knowledge의 Model Level은 M<sub>1</sub>, M<sub>2</sub>, M<sub>3</sub>의 3가지로 구성된다. M<sub>1</sub>은 Object의 Part나 Object의 Visual Feature인 Color, Shape, 등을 포함하는 Object Feature Layer를 나타내는데, Perception Level의 Visual Concept Layer와 Anchoring하고 있다. M<sub>2</sub>는 Object의 이름과 기능을 담고 있는 Object Layer이다. 마지막으로 M<sub>3</sub>는 Space Layer로써 이것은 Grid Map이나 Feature-based Map, Topological Map, Semantic Map 등과 같은 다양한 표현이 가능한 World Model의 일부를 나타낸다. 로봇은 Object Perception을 기반으로 Model을 구축한다.

그림 4(a)는 Table의 Color와 Shape 특징과 Table leg, Table Board를 포함하는 Object Layer의 Ontology Layer의 예시이다. Object Feature의 Instance가 존재함을 알 수 있다. 그림 4(b)는 Table의 Object Concept에 대한 Axiom을 나타낸다. 마지막으로 그림 4(c)는 Object와 Object Match를 위해 후보를 만드는 Object Layer의 Rule이다.

#### 4.1.3 KBoards - Context

Knowledge의 Context Level은 3개로 나누어지는



(a) object ontology

```

has_geometry(table, hexahedron).
has_width(table, W_ref) :- W_ref>500, W_ref<2500.
has_height(table, H_ref) :- H_ref>500, H_ref<1000.
has_function(table, put_thing_on).
has_part(table, leg).
has_part(table, board).
hasRelation(table, chair)

```

(b) object ontology axioms

```

match_height(I,T) :- has_height(I,IH), has_height(T,IH).
match_width(I,T) :- has_width(I,IH), has_width(T,IH).
match_geometry(I,T) :- has_geometry(I,IH), has_geometry(T,IH), I W=T.
match_color(I,T) :- has_color(I,IH), has_color(T,IH), I W=T.
match_peripheral(I,T) :- has_peripheral(I,IH), has_peripheral(T,IH), I W=T.

candidate_1(I, T) :- match_height(I,T), match_width(I,T), %first.
match_geometry(I,T), match_color(I,T), match_peripheral(I,T), I W=T.
candidate_2(I, T) :- match_height(I,T), match_width(I,T), (%second.
match_geometry(I,T) : match_color(I,T) ), match_peripheral(I,T), I W=T.
candidate_3(I, T) :- match_height(I,T), match_width(I,T),
match_peripheral(I,T), I W=T. %third.
candidate_4(I, T) :- match_height(I,T), match_width(I,T), (%third.
match_geometry(I,T) : match_color(I,T) ), I W=T.
candidate_5(I, T) :- match_height(I,T), match_width(I,T), I W=T. %last.

```

(c) object rules

그림 4 Model level ontology

데 각각  $C_1$ ,  $C_2$ ,  $C_3$ 이다.  $C_1$ 은 Over, Under, Left, Right등과 같은 Spatial Concept를 담은 Spatial Context Layer이다.  $C_2$ 는 Now, Just Before, After, Morning, Yesterday와 같은 Temporal Concept를 가진 Temporal Context Layer이다. 그리고  $C_3$ 는 High-level Context Layer로써 단순히 물체 인식이 아닌 이해에 관련되거나 이해하는 것을 돋는 General Situation의 Context를 담고 있다.

Meta-ontology, Ontology, Ontology Instance Layer이다.

#### 4.1.4 KBoards - Activity

Knowledge는 3개의 Activity Level로 구성되는데 각각  $A_1$ ,  $A_2$ ,  $A_3$ 이다.  $A_1$ 은 로봇의 기본 함수에 관련된 Behavior Layer이다. 로봇의 Basis Function은 예를 들면, 앞으로 10가시오, 뒤로 10가시오, 5만큼 좌회전 하시오, 사진을 찍으시오, 팔을 움직이시오, 잡으시오 등과 같은 것들을 말한다.  $A_2$ 는 Behavior의 몇몇 조합에 따른 task Layer이다.  $A_3$ 는 Navigation,

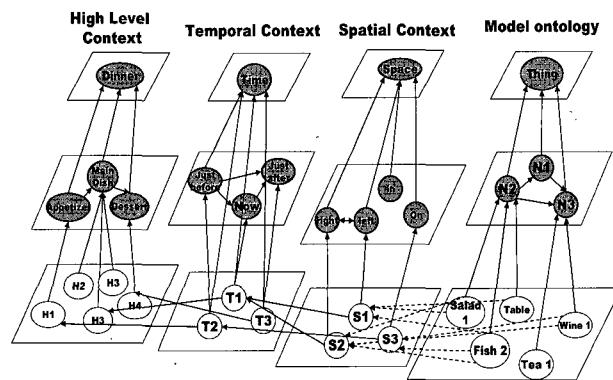


그림 5 Context level ontology

그림 5는 각각 3개의 Knowledge Layer를 가진 Context Level Ontology와 Model level의 Relevant Object Ontology의 예제이다. 그리고 3개의 Knowledge Layer는 High-level Context, Temporal Context, Spatial Context로 구성되어 있다. 그리고 각각에 해당하는 3개의 Ontology Layer는

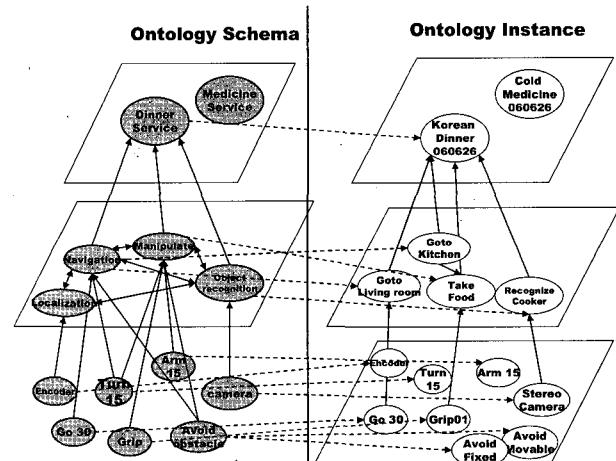


그림 6 Activity level ontology

Localization, Object Recognition, Manipulation 등과 같은 Short Term Sequence로 이루어져 있다.

$A_3$ 는 저녁 식사 서비스나, 의료 서비스 등과 같은 Long Term Goal들에 대한 Service Layer를 나타낸다.

그림 6은 3개의 Knowledge Layer를 가진 Ontology와 Ontology Instance의 Activity Level에 대한 예시이다. Knowledge Layer는 Behavior, Task, Service의 3가지이다. 그리고 각각의 Ontology Layer 3개는 Meta-ontology, Ontology, Ontology Instance Layer를 포함한다.

## 5. 지식 추론 및 상황 인지 예제

Inference Method는 Backward Chaining과 Forward Chaining의 두 가지가 있다. 첫 번째, Forward Chaining은 숨겨진 Knowledge를 찾아 내기 위하여 사용 가능한 Data와 Inference Rule을 가지고 시작하는 방법이다. 두 번째 Backward Chaining은 Query를 기반으로 한 것으로 예를 들어 “저녁 식사 서비스는?”과 같은 목표를 가지고 Backward방식으로 관련 Data나 Sub-goal의 도움을 받아서 추론을 하는 방법이다.

OMRKF는 Knowledge의 같은 Level사이에서 추론을 하기 위해 Forward Chaining을 사용한다. 표 2의 가로방향은 Forward Chaining을 나타낸다. 표 2의 시간 200608091730의 모델의 예에서 Vision Sensor나 Object Matching Algorithm으로 식탁 1을 인식하지 못했는데 이유는 부분적인 소실이 일어났거나 잡음 때문이다. 그러나 식탁은 움직이지 않으며, 로봇은 이전 시간에 움직임이 없었고, 로봇이 식탁1을 인식했다는 몇 가지 Rule을 이용하여 Forward Chaining방법으로 식탁1을 찾아 낸 것을 알 수 있으며 이런 방식으로 Forward Chaining Rule은 Hidden Knowledge을 찾아 낼 수 있다.

그리고, OMRKF는 다른 Level의 Knowledge사이에서 Inference를 하기 위해 Backward Chaining방법을 사용한다. 표 2에서 세로 방향으로의 추론은 Backward Chaining을 수행하는 것이다. 표 2의 시간 200608091710은 Beef1과 Wine1이 식탁1위에 있고, 이전의 행동은 Dinner Service1이며, 그 상황의 Context는 Main Dish2가 제공될 시간이라는 Evidence이다. Context와 같은 Symbolic Information이 제공된다면, Inference Engine은 Model안에 있는 작업과 관련된 물체의 목록을 추천하고 Perception Module은 추천된 물체의 목록을 이용하여 굳이 모든 물체를 고려하지 않고 Matching을 수행 할 수 있다.

OMRKF는 4 Level의 Knowledge를 가지며 Know-

ledge의 각 Level은 Low-knowledge Layer에서 High-knowledge Layer로부터 추론하기 위한 자신만의 Rule을 가진다. 그리고 OMRKF는 Knowledge의 각 Level들 간의 Association Rule을 가진다[5].

Data Mining분야에서, Association Rule Mining은 Data Item들 사이에서 Interesting Association이나 Correlation Relationship을 찾아낸다. Rule Support와 Confidence는 Rule Interestingness에 대해 두 가지 Measure이다.

표 2 Inference of Robot Knowledge framework

Time	Perception	Model	Activity	Context
200608 091700	Image00, SIFT01, Encoder00	Salad1, Table1	Dinner service1	(Appetizer1)
200608 091710	Image10, SIFT10, Encoder10	Beef1, Wine1, Table1	(Dinner service2)	(Main dish1)
200608 091720	Image20, Color20, Sonar20	Beef1, (Wine1), Table1	Dinner service2	Main_dish2
200608 091730	Image20, SIFT20, EKF30	Tea1, Cookie1, (Table1)	(Dinner service3)	(Dessert1)
200608 091740	Image30, SIFT30, Encoder30	Tea1, Table1	Dinner service3	(Dessert2)
200608 091750	Image40, SIFT40, Sonar40	Table1	(Clear Table1)	(End of dinner1)
200608 091760	Image50, SIFT50, Sonar50	Vitamin C1, (Glass1), Table1	Medicine service1	(Medicine1)
200608 091770	Image60, SIFT60, Encoder60	(Cold Medicine1), Glass1	Medicine service2	(Medicine2)

) are inferred by OMRKF. The inferences in the same level of knowledge are made on forward chaining method, on the other hands, the inference among the different levels of knowledge are made on backward chaining when it is queried.

$$support(A \Rightarrow B) = P(A \cup B) \quad (1)$$

$$confidence(A \Rightarrow B) = P(B|A). \quad (2)$$

Support( $A \rightarrow B$ ) Rule에서 Support는 A와 B가 모두 지니고 있는 Data Set의 비율을 말한다.  $A \rightarrow B$  Rule은 Confidence는 A뿐만 아니라 B도 갖고 있는 모든 Data set에 대한 비율이 Confidence일 경우이다. 이것은 Conditional Probability  $P(B|A)$ 와 같다. 그리고 Single-dimensional Association Rule과 Multilevel Association Rule의 Mining을 위한 두 가지 방법이 있다. Single-dimensional Association Rule은 같은 Data Field안에서의 Rule인 반면에 Multilevel Association Rule은 Data Field의 다른 Level의 Item도 포함한다.

본 연구의 연구에서, OMRKF는 하나의 Measure로 confidence와 Multilevel Association Rule 방법을 사용한다. OMRKF는 Query를 기반으로 Knowledge를 추출한다 (KQuery). KQuery는 KBoard의 부분 집합으로써, KBoard는 Knowledge의 모든 Level로 채워져 있다. 표 3은 KBoards와 KQuery의 예이다. 따라서 OMRKF는 주어진 Level과 관련된 Knowledge의 추론된 Level과 함께 Knowledge의 빈 Level을 채운다. 그리고 OMRKF는 4개의 Knowledge Level 사이에서 Multilevel Association Rule을 이용하는데, 4개의 Knowledge Level은 Perception, Model, Context 그리고 Activity 또는 Abstraction의 다른 Level의 Knowledge Level을 포함하는 Rule로 구성되어 있다.

앞서 기술한 지능 구현을 위한 로봇 지식 체계 프레임워크의 효용성을 보이기 위하여 그림 7과 같은 환경을 식사 접대 서비스를 위한 로봇 지식을 실험하였다.

그림 8은 로봇의 비전을 통하여 물건을 인식하고 (scenario 1), 찾아진 물건들의 시공간 상황 정보를 생성하여, 식사 접대라는 high level 상황 정보를 추론하고 (scenario 2), 상황에 적합한 activity를 선택

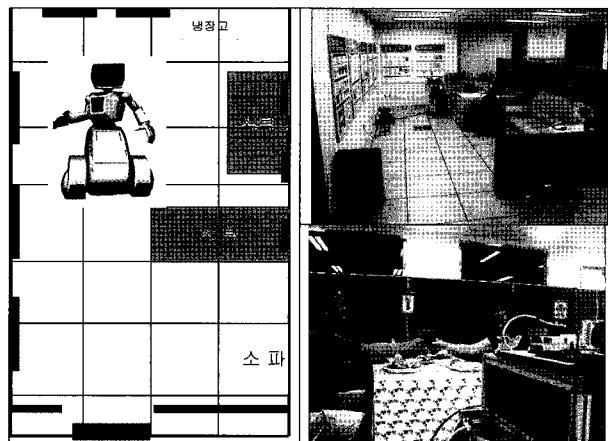


그림 7 Experimental Environments

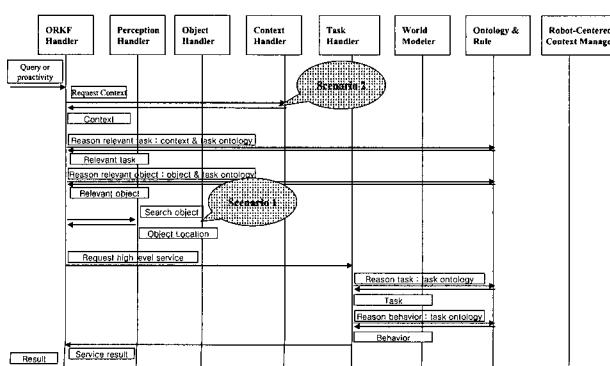


그림 8 Sequence Diagram

하는 과정을 보여주는 sequence diagram이다. 그리고, 그림 9는 식사 접대 시나리오에서의 상황 정보의 생성 예제이다.



그림 9 Example of object recognition and Context awareness

그리고, 그림 10은 식사 접대 시나리오에서 다음 activity를 추론한 결과를 보여 준다. 사물을 인식하고, 가려진 접시 등을 추론하여, 식사의 상황과 진행 상태를 인지하여, 다음에 필요한 task와 task와 관련된 오브젝트를 추천하게 된다.



그림 10 Example of inference Activity

## 6. 결 론

본 연구에서는 4개의 Knowledge Level과 12개의 Knowledge Layer를 가진 Ontology-based Multi-layered Robot Knowledge Framework를 제안하였다. 4개의 Knowledge Level은 Perception, Model, Context, Activity로 이루어져 있고 각 Knowledge Level은 High-level, Middle-level, Low-level의 3 가지 Layer로 이루어져 있다. 특별히, Low-level Knowledge는 로봇 센서나 Actuator, Motor 등과 연결되어 있으며, 각 Knowledge Layer는 Meta-ontology Layer, Ontology Layer, Ontology Instance Layer 3가지로 구성되어 있다. 따라서 OMRKF는 총 36개의 KBoards를 가지고 Forward Chaining과 Backward Chaining을 위해 Axiom이 존재하고, 다른 Level의 Knowledge 사이의 Association을 위하여

Rule이 존재한다. 본 연구에서는 저녁 식사 상황에서 접대 서비스를 통해 OMRKF를 검증해 보았다. 추후에는 다른 분야의 상이한 로봇들에게 OMRKF를 재사용하고 공유하는 방법을 연구할 것이다.

### 참고문헌

- [1] O. Corcho, and A.G. Pérez, "A Roadmap to Ontology Specification Languages" *Lecture Notes in Computer Science*, 2000, pp. 80-96.
- [2] M. R. Genesereth, Knowledge interchange format,  
<http://logic.stanford.edu/kif/dpans.html>.
- [3] A. Farquhar, R. Fikes and J. Rice, "The Ontolingua Server: a tool for collaborative ontology construction", *International journal of human-computer studies*, 46(6), 1997, pp. 707-727.
- [4] I. Bratko, "Prolog programming for artificial intelligence," 3rd ed. Pearson education, 2001, pp. 57.
- [5] J. Han and M. Kamber, "Data Mining: Concepts and Techniques," Morgan Kaufmann, 2001, ch. 6.
- [6] J. Schoening, IEEE P1600.1 Standard Upper Ontology Working Group,  
<http://suo.ieee.org>.
- [7] Baader, F., Calvanese D., Mcguinness D.L., Nardi D. and Patel-schneider P.F., "The description logic handbook," Cambridge university press, 2003, ch. 2.
- [8] Bozsak, E., Ehrig M., Handschuh S., Hotho A., Maedce A., Motik B., Oberle D., Schmitz C., Staab S. and Stojanovic L., "KAON - Towards a Large Scale Semantic Web," *Lecture notes in computer science*, No. 2455, 2002, pp. 304-313.
- [9] W. Hwang, J. Park, H. Suh, H. Kim and I.H. Suh, "Ontology-based Framework of Robot Context Modeling and Reasoning for Object Recognition" *Lecture Notes in Computer Science*, 2006.
- [10] E. Wang, Y. S. Kim, H. S. Kim, J.H. Son, S. Lee, and I. H. Suh, "Ontology Modeling and Storage System for Robot Context Understanding," *Lecture notes in computer science*, 2005, no. 3683, pp. 922-929.
- [11] S. Thrun, W. Burgard and D. Fox, "Probabilistic Robotics." MIT Press 2005, ch. 1.
- [12] X.H. Wang, D.Q Zhang, T. Gu and H.K. Pung, "Ontology Based Context Modeling and Reasoning using OWL," *Proc. of the Second IEEE Annual Conference on Pervasive Computing and Communication Workshops (PERCOMW'04)*, 2004.
- [13] K. Henricksen, J. Indulska, and A. Rakoto-nirainy, "Modeling Context Information in Pervasive Computing Systems," *Lecture notes in computer science*, 2002, no. 241, pp. 167-180.
- [14] D. Lowe, "Distinctive image features from scale-invariant keypoints," *International Journal of Computer Vision*, Vol.60, pp.91-110, 2004.
- [15] R.C Arkin, "Behavior-based Robotics," MIT Press, 1998.
- [16] N. Maillot, M. Thonnat, and A. Boucher, "Towards ontology-based cognitive vision," *Machine Vision and Applications*, pp.33-40, 2004.

### 임기현



2005~현재 한양대학교 정보통신학과  
석사과정 재학 중  
2004~1999 알티 솔루션 RTOS 팀장  
1997~1998 동부전자 FA team 근무  
1997 한양대학교 금속공학과 공학사  
관심분야 : 온톨로지, 상황 인지, 기계 학습,  
계획 수립, 지식 모델링, 인지  
과학  
E-mail : hmetal@incorl.hanyang.ac.kr

### 서일홍



2006~현재 한양대학교 네트워크기반  
지능로봇 교육센터장  
1985~현재 한양대학교 정보통신학과  
교수  
2004~2006 한양대학교 정보통신대학  
학장  
2004~2006 한양대학교 정보통신대학원  
원장  
1982 한국과학기술원 전기공학과 박사  
관심분야 : 로봇 지능, 로봇 행동 선택  
메커니즘, 상황인지, 온톨로지  
E-mail : ihsuh@hanyang.ac.kr

---

### 이상훈



2006~현재 한양대학교 네트워크기반  
지능로봇 교육센터 연구교수  
2006 한양대학교 전자전기제어계측과  
박사  
1997 한양대학교 산업대학원  
전자계산학과 석사  
1994 한양대학교 수학과 학사  
관심분야: 로봇 지능, 로봇 행동 선택  
메커니즘, 로봇 소프트웨어  
아키텍처  
E-mail : shlee@incrl.hanyang.ac.kr

### 황원일



2005~현재 한국과학기술원 산업공학과  
석사과정 재학 중  
2005 한국과학기술원 산업공학과 학사  
관심분야: 온톨로지, 비즈니스 프로세스  
모델링  
E-mail : onil@kaist.ac.kr

### 서효원



1996~현재 한국과학기술원 산업공학과  
교수  
1992~1995 한국생산기술연구원  
생산시스템센터 수석연구원  
1991 West Virginia University  
산업공학과 박사  
1983~1987 대우중공업(주) 중앙연구소  
주임연구원  
관심분야: 동시공학, 비즈니스 프로세스  
모델링, PDM, 온톨로지  
E-mail : hwsuh@kaist.ac.kr

---