

지능형 홈 에이전트의 의사결정을 위한 베이지안 확률기반 온톨로지 추론 방법

임성수⁰ 조성배

연세대학교 컴퓨터과학과

lss@sclab.yonsei.ac.kr⁰, sbcho@cs.yonsei.ac.kr

A Method of Ontology Inference based on Bayesian Probability for Decision Making of Intelligent Home Agents

Sungsoo Lim⁰ Sung-Bae Cho

Dept. of Computer Science, Yonsei University

요 약

지능형 에이전트가 홈네트워크 환경 속에서 사용자에게 적절한 서비스를 제공하기 위해서는 에이전트가 속한 환경에 대한 모델이 필요하다. 온톨로지는 이러한 환경 모델을 표현하기 위한 유용한 도구로 복잡한 도메인의 조직적 구조 표현에 있어서 뛰어난 성능을 보여준다. 하지만 전통적 온톨로지는 크리스프 로직에 기반하기 때문에 현실세계의 불확실성을 표현하기에는 적합하지 않다. 본 논문에서는 온톨로지의 이러한 한계점을 보완하고, 불확실한 환경 속에서 지능형 홈 에이전트가 적절한 의사결정을 내릴 수 있도록 하는 베이지안 네트워크기반 온톨로지 추론 방법을 제안한다. 제안하는 방법에서는 온톨로지의 클래스 객체를 베이지안 네트워크의 노드로 나타내고, 객체 속성(object property)을 아크로 표현함으로써, 확률적 추론이 가능한 온톨로지를 제공한다. 몇 가지 시나리오와 설계 복잡도 분석을 통해서 제안하는 방법의 유용성을 평가한다.

1. 서 론

에이전트는 지식과 추론 능력, 학습능력 등을 가지고 사용자를 대신하여 사용자가 원하는 작업을 자동적으로 해결하여 주는 시스템이다[1]. 에이전트가 이러한 일들을 수행하기 위해서는 에이전트의 행동이 환경에 어떠한 영향을 미치는지, 그리고 그 영향이 어떻게 에이전트의 목적 달성에 도움을 주는지 등을 표현하는 환경 모델이 필요하다.

온톨로지는 위와 같은 환경 모델을 표현하기 위한 유용한 도구로, 특정 도메인을 설명하기 위한 개념과 개념 간의 관계를 정의하기 위한 지식 모델이다[2]. 온톨로지는 거대하고 복잡한 도메인의 조직적 구조 표현에 있어서 뛰어난 성능을 보여주지만, 크리스프(crisp) 로직에 기반한 전통적 온톨로지로는 현실 세계의 불확실성을 다루기에는 한계가 있다[3]. 이러한 한계는 동적이고 열려있는 환경에서 서비스를 제공해야 하는 에이전트가 극복해야 할 어려움 중 하나이다[4].

온톨로지의 이러한 한계를 극복하고자 온톨로지에 베이지안 확률 추론(BN)을 결합하려는 시도가 있어왔다. 베이지안 확률 추론은 지능형 에이전트나 시스템이 불충분한 지식을 가지고 표상하거나 추론하는 대표적인 방법으로[5,6], OntoBayes는 온톨로지 모델에서 부분적으로 BN 모델을 포함하여 확률 추론이 가능하게 하였고[7], BayesOWL은 온톨로지 전체를 BN으로 변화시킴으로써, 온톨로지에서도 확률적 추론이 가능하도록 하였다[8,9].

그러나 OntoBayes는 온톨로지와 이와 관련된 BN 추론 모델을 함께 활용하는 것과 큰 차이가 없으며, BayesOWL은 온톨로지 전체를 하나의 BN으로 만들므로 BN 추론 및 학습에 많은 연산량이 필요하다.

본 논문에서는 온톨로지를 다수의 Naive BN으로 구성시킴으로써 BN 파라미터 설계 비용 및 학습에 필요한 비용을 줄이며 전체 온톨로지에서도 확률 추론이 가능한 베이지안 확률기반 온톨로지 추론 방법을 제안하고, 제안하는 방법을 지능형 홈 에이전트 환경에 적용한다.

2 확률기반 온톨로지

확률기반 온톨로지에 관련한 연구로 Yang과 Calmet의 OntoBayes와 Ding 등의 BayesOWL이 있다[7,8,9]. OntoBayes는 온톨로지 웹 언어인 OWL을 확장하여 FullProbDist, hasPrior, PriorProb, hasCond, CondProb, dependOn의 태그를 정의하고, 이를 통해 객체 속성이나 데이터 속성(data property) 간의 의존관계와 조건부 확률 테이블 값을 정의한다. OntoBayes를 이용하면, 에이전트는 자신의 행동이 환경에 미치는 영향을 확률적으로 추론할 수 있다는 장점이 있다. 그러나 OntoBayes는 OWL을 통해서 Bayesian network의 성질을 표현하였을 뿐, 온톨로지 추론과정에 Bayesian network가 적용되는 것이 아니기 때문에, Ontology와 Bayesian network 모델을 각각 가지고 있는 것과 큰 차이가 없다.

BayesOWL은 OntoBayes와 달리 온톨로지 전체를 베이지안 네트워크로 변화시켜 온톨로지에서도 확률 추론이 가능하다. BayesOWL은 객체나 속성간의 의존관계를 온톨로지의 구조를 그대로 따라서 정의하며, OntoBayes와 같이 조건부 확률값을 위한 몇 가지 태그를 정의하고 있다. 그러나 BayesOWL은 온톨로지 전체를 베이지안 네트워크로 구성하므로, 거대하고 복잡한 도메인에 대해서 각 객체간의 관계를 조건부 확률로 나타

내기 위해서는 많은 양의 조건부 확률 값을 설정해 주어야하므로, 초기 설계에 많은 시간이 필요하다. 그리고 학습을 위해서는 온톨로지 전체에 대한 데이터 수집이 필요하므로 많은 시간과 노력이 필요하며, 따라서 온톨로지 데이터의 확장에 있어서 많은 비용이 필요하다.

3. 베이지안 확률기반 온톨로지 추론

본 논문에서는 2장에서 알아본 기존의 확률기반 온톨로지 추론 방법의 한계를 극복할 방법을 제안한다. 제안하는 방법은 온톨로지를 객체 속성(Object property) 관계에 따라서 여러 개의 Naive BN으로 분할하여 확률 추론을 위한 온톨로지를 구성하고, 증거 변수를 기준으로 단계적 추론을 통해 온톨로지에서의 확률적 추론 결과를 종합한다. 이렇게 하나의 온톨로지를 객체 속성 관계에 따라 여러 개의 Naive BN으로 분할함으로써 설계의 어려움을 완화시켜주며, 온톨로지의 부분적 학습도 가능하여 온톨로지의 확장성을 높여준다.

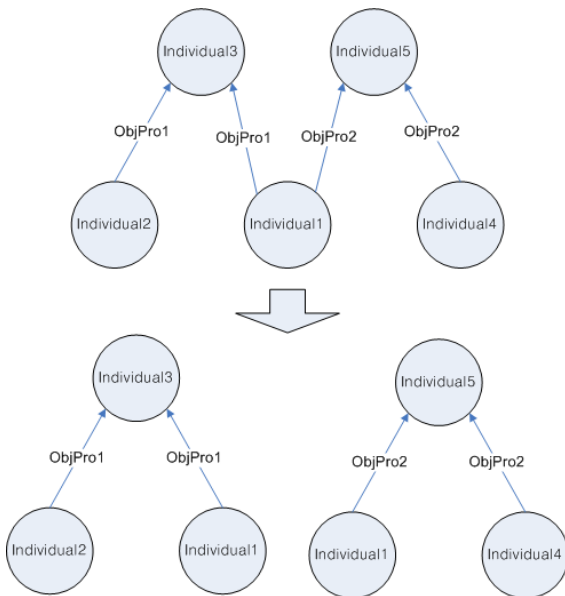


그림 1. 객체 속성에 따른 온톨로지 분할

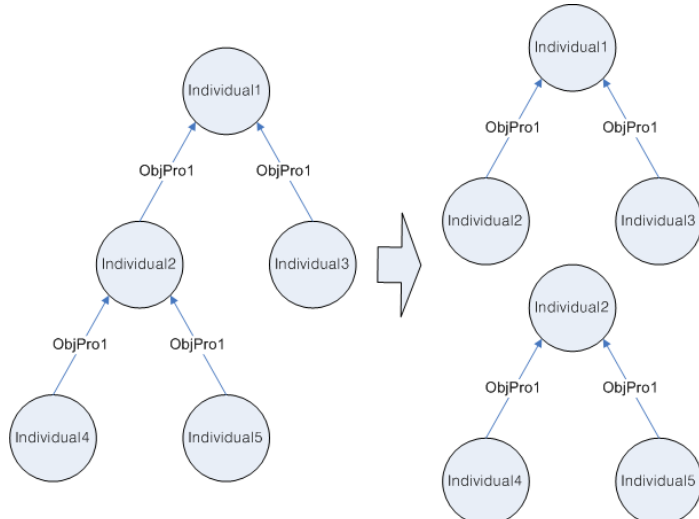


그림 2. 개체간 거리에 따른 온톨로지 분할

3.1 온톨로지의 베이지안 네트워크 구성 방법

본 논문에서는 온톨로지서 BN을 구성하기 위해 온톨로지 구조로부터 다수의 Naive BN을 구성한다. 온톨로지의 개체를 BN의 랜덤 변수로 표현하고, 객체 속성을 BN의 아크로 표현한다. 이때, 객체 속성의 종류에 따라서 온톨로지를 분할하며 (그림 1), 동일한 객체 속성으로 연결되어 있더라도 개체간의 거리가 2 이상이 되면 두 개체가 다른 BN에 속하도록 분할한다 (그림 2).

온톨로지를 다수의 Naive BN으로 분리한 후의 각 BN 노드는 상황에 따라, marginal 확률 값이나 조건부 확률 값을 갖는다. 본 논문에서는 OWL의 rdfs:comment 태그 안에 각 노드의 확률 값 기술을 위한 기술언어를 삽입한다. 그림 3과 4는 marginal 확률 및 조건부 확률 값을 위한 BNF 형식과 그 사용 예를 보여주고 있다.

```
[marginal] := "<marginal ObjPro = " [object_property]
">" [prob]* "</marginal>"
[prob] := "<prob>" [state] [value] "</prob>"
[state] := "<state>" @string "</state>"
[value] := "<value>" @float[0-1] "</value>"

<Home rdf:ID="LivingRoom">
...
<rdfs:comment rdf:datatype =
"http://www.w3.org/2001/XMLSchema#string">
<marginal ObjPro = hasDevice>
<prob>
<state> true </state>
<value> 1 </value>
</prob>
<prob>
<state> false </state>
<value> 0 </value>
</prob>
</marginal>
</rdfs:comment>
...
</Home>
```

그림 3. Marginal 확률값 정보

3.2 베이지안 확률기반 온톨로지 추론 알고리즘

그림 5의 의사코드는 제안하는 베이지안 확률기반 온톨로지 추론 과정을 설명하고 있다. 우선 추론에 필요한 증거변수들을 추론 큐에 입력하고, BN에 증거변수를 등록한 후, 큐가 empty가 될 때까지 다음을 반복한다. 1) 큐에서 노드를 하나 꺼내고, 2) 해당 노드를 갖는 모든 BN에 대해 BN 확률 추론을 수행하고, 3) 추론결과 threshold 값과 마킹된 값 이상인 노드를 다시 큐에 입력하고 마킹된 값을 바꿔준다. 이러한 추론 과정을 통해서 분리된 BN 간의 연결이 가능하다.

```
[conditional] := "<conditional ObjPro = " [object_property]
">" [prob]* "</conditional>"
[prob] := "<prob>" [state] [condition]* [value] "</prob>"
[state] := "<state>" @string "</state>"
[condition] := "<condition>" [var] [state] "</condition>"
[var] := @string
[state] := @string
[value] := "<value>" @float[0-1] "</value>"
```

```
<Home rdf:ID="LivingRoomAcOn">
...
<rdfs:comment rdf:datatype =
"http://www.w3.org/2001/XMLSchema#string">
<conditional ObjPro=hasProperAction>
  <prob>
    <state> true </state>
    <condition> LR_Temp hot </condition>
    <condition> OD_Temp hot </condition>
    <value> 1 </value>
  </prob>
  <prob>
    <state> false </state>
    <condition> LR_Temp hot </condition>
    <condition> OD_Temp hot </condition>
    <value> 0 </value>
  </prob>
  <prob>
    <state> true </state>
    <condition> LR_Temp hot </condition>
    <condition> OD_Temp normal </condition>
    <value> 0.3 </value>
  </prob>
  <prob>
    <state> false </state>
    <condition> LR_Temp hot </condition>
    <condition> OD_Temp normal </condition>
    <value> 0.7 </value>
  </prob>
  ...
</conditional>
</rdfs:comment>
...
</Home>
```

그림 4. 조건부 확률값 정보

```
Push evidence nodes with its probability in a queue Q;
Mark evidence nodes with its probability;
Set evidence nodes;
```

```
while ( Q is not empty ) {
  active_node = Q.pop();
  for all BN bn which has the active_node {
    Bayesian inference;
    for all nodes n in bn {
      if ( probability of n < threshold ) continue;
      if ( probability of n < Marked value of n )
        continue;
      find and pop the node n in Q;
      Q.push(n);
      Mark n with it probability;
    }
  }
}
```

그림 5. 베이지안 확률기반 온톨로지 추론 알고리즘

4. 실험 및 결과

4.1 전통적 온톨로지 추론과 확률기반 온톨로지 추론 비교

본 논문에서는 확률기반 온톨로지 추론 방법의 유용성을 보여주기 위해 홈 네트워크 환경에서 에이전트의 의사결정을 위한 온톨로지를 구현하고, 하나의 시나리오를 통해 전통적 온톨로지 추론 방법과 제안하는 방법을 비교 분석한다. 설계된 온톨로지는 원룸형 오피스텔을 모델링한 것으로, 방으로는 거실, 화장실, 침실이 있고, 거실과 침실에는 각각 TV, 창문, 에어컨, 보일러, 전등이 설치되어 있으며, 화장실에는 전등과 환풍기가 설치되어 있다. 설계된 온톨로지는 총 26개의 클래스와 8개의 객체 속성, 114개의 individual로 구성된다. 그림 6은 설계된 온톨로지의 추상화된 모델을 보여준다.

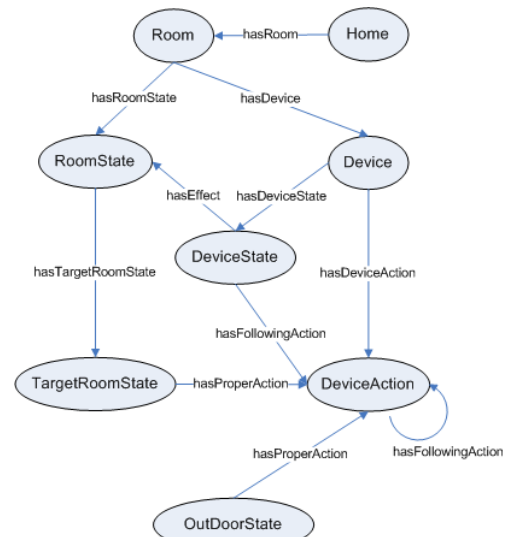


그림 6. 홈 에이전트 의사결정을 위한 온톨로지

확률기반 온톨로지 추론 방법의 유용성을 보이기 위한 간단한 예로, 실내온도와 실외온도가 모두 더운 상태에서 전통적 온톨로지와 제안하는 온톨로지가 어떻게 에이전트의 의사결정에 영향을 미치는지 비교해본다.

그림 7은 위의 상황과 연관되어 설계된 온톨로지의 부분을 보여주고 있다. 일반적인 온톨로지의 경우는 추론 증거 값으로 (현재상태 방:더움, 참), (현재상태 실외:더움, 참)이 입력되어, 각각 hasTargetState와 hasProperAction의 객체 속성을 따라, (기기행동 창문 열기, 참)와 (기기행동 AC ON, 참)이라는 결과가 추론되고, hasFollowingAction을 통해서 (기기행동 창문 닫기, 참)라는 결과가 추론된다.

즉, 창문 열기와 창문 닫기의 서로 상반된 행동이 참값을 가지므로, 에이전트는 이 상황에 적합한 행동을 취하기 위해서는 각 객체 속성 간의 의미를 분석하여 행동을 결정해야 한다.

반면, 확률기반 온톨로지 추론 방법에서는 우선 입력 값으로 참/거짓 값이 아닌 확률 값이 입력되므로, 좀 더 유연한 추론 결과를 얻을 수 있다. 예를 들어, 일반적인 온톨로지에서는 방의 온도와 실외온도의 차이와는 상관없이 동일한 추론 결과를 얻게 되지만, 제안하는 방법에서는 방의 온도가 더 더운 경우에는 창문을 열고, 실외 온도가 더 더운 경우에는 에어컨을 켜는 등의 행동일 설계 할 수 있다. 또한 추론 과정이 단계적으로 일어나므로, 어떠한 개체가 어떠한 이유에서 활성화 되었는지를 쉽게 알 수 있어, 추론 결과 해석에 용이하다.

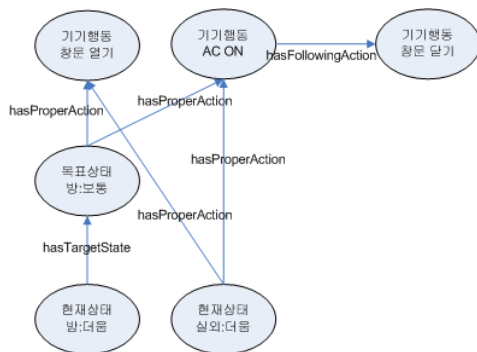


그림 7. 온도와 관련된 온톨로지 예

4.2 온톨로지의 BN 파라미터 설계 복잡도 비교

본 절에서는 하나의 온톨로지를 하나의 BN으로 만드는 경우와 제안하는 방법과 같이 분할하여 작성하는 경우, 설계되어야 할 BN 파라미터의 설계 복잡도를 비교한다. 온톨로지는 표현하는 대상 도메인에 따라서 다양한 형태의 구조를 가지며, 같은 도메인이라도 설계자의 노하우에 따라서 다른 형태의 구조를 가질 수 있다. 본 논문에서는 계산의 편의를 위해서 트리형태의 온톨로지 구조에 대해서 BN 파라미터 설계 복잡도를 보인다.

p 개의 객체 속성을 가지며, 각 객체 속성을 따라 각 노드에서 2개의 자식 노드가 존재하는 n 개의 층으로 이루어진 온톨로지를 생각해 보자.

이 온톨로지를 하나의 BN으로 표현하면, 말단 노드를 제외한 모든 노드는 $2p$ 개의 자식을 가지고 $2p$ 개의 자식 노드를 가

진 노드는 각 노드의 상태가 2가지인 경우, 총 2^{2p} 개의 확률 값이 필요하다. 이러한 노드가 $p^0 + p^1 + \dots + p^{n-1}$ 개 있으므로, 이때의 설계 복잡도는 $O(p^{n-1} \times 2^{2p})$ 이 된다.

그러나 제안하는 방법과 같이 온톨로지를 여러개의 Naive BN으로 나누는 경우, 우선 객체 속성에 따라, p 개의 높이가 n 인 바이너리 트리가 생성되고, 각 바이너리 트리는 다시 2^{n-1} 개의 높이가 2인 바이너리 트리로 나뉘어 진다. 높이가 2인 바이너리 트리에서의 BN 파라미터의 개수는 6이므로, 최종 설계 복잡도는 $O(6p \times 2^{n-1})$ 가 된다.

5. 결론 및 향후연구

본 논문에서는 베이지안 확률기반 온톨로지 추론을 위해서 온톨로지를 다수의 Naive BN으로 분할하는 방법과 분할된 Naive BN들로부터 온톨로지의 확률적 추론 방법을 제안했다. 제안하는 방법은 온톨로지의 확률 추론에 필요한 BN 파라미터의 수를 줄임으로써 설계에 드는 시간 비용을 줄일 수 있을 뿐만 아니라, 다양한 인과관계를 고려하지 않고 하나의 객체 속성과의 인과관계만을 고려하여 BN 파라미터를 설계하면 되기 때문에, 손쉽게 네트워크를 설계할 수 있다. 또한 부분적인 학습이 가능하여 온톨로지의 확장성을 높여준다.

향후 연구로는 제안하는 방법의 유용성을 평가하기 위한 정량적인 실험 수행이 필요하고, 베이지안 네트워크의 파라미터를 학습을 통해서 자동으로 구축하여 설계에 드는 시간 비용을 줄일 필요가 있다.

감사의 글

본 연구는 정보통신부 및 정보통신연구진흥원의 대학 IT연구센터 지원사업의 연구결과로 수행되었음. IITA-2006-(C1090-0603-0046)

참고문헌

- [1] W. Gerhard, *Multiagent Systems: A Modern Approach to Distributed Artificial Intelligence*, The MIT Press, 1999.
- [2] T.R. Gruber, "A translation approach to portable ontology specifications," *Knowledge Acquisition*, vol. 5, no. 2, pp. 199-220, 1993.
- [3] D. Koller and A. Pfeffer, "Probabilistic frame-based system," *Proc. AAAI National Conf. on Artificial Intelligence*, pp. 580-587, 1998.
- [4] S.J. Russell and P. Norvig, *Artificial intelligence*, Prentice Hall, 2003.
- [5] E. Charniak, "Bayesian networks without tears," *AI Magazine*, vol. 12, no. 5, pp. 50-63, 2003.
- [6] T. Stephenson, "An introduction to Bayesian network theory and usage," *IDIAP-RR 00-03*.
- [7] Y. Yang and J. Calmet, "OntoBayes: An ontology-driven uncertainty model," *Proc. of the Int. Conf. on Intelligent Agents*, vol 1, pp. 457-464, 2005.