

# 불확실한 장면의 효과적인 인식을 위한 베이지안 네트워크의 온톨로지 기반 제한 학습방법

(A Constrained Learning Method based on Ontology of Bayesian Networks for Effective Recognition of Uncertain Scenes)

황 금 성 <sup>†</sup>      조 성 배 <sup>‡‡</sup>

(Keum-Sung Hwang)    (Sung-Bae Cho)

**요약** 영상을 분석하여 얻은 증거를 바탕으로 장면의 의미를 추론하고 해석하는 것을 시각 기반 장면 이해라고 하며, 최근 인과적인 판단 및 추론 과정을 모델링하기에 유리한 베이지안 네트워크(BN)를 이용한 확률적인 접근 방법이 활발히 연구되고 있다. 하지만 실제 환경은 변화가 많고 불확실하기 때문에 의미 있는 증거를 충분히 확보하기 어려울 뿐만 아니라 전문가에 의한 설계로 유지하기 어렵다. 본 논문에서는 증거 및 학습 데이터가 부족한 장면인식 문제에서 효율적인 BN 구조로 계산 복잡도가 줄어들고 정확도는 향상될 수 있는 BN 학습방법을 제안한다. 이 방법은 추론 대상 환경의 도메인 지식을 온톨로지로 표현하고 이를 제한적으로 사용하여 효율적인 계층구조의 BN을 구성한다. 제안하는 방법의 평가를 위하여 9종류의 환경에서 90장의 영상을 수집하고 레이블링하여 실험하였다. 실험 결과, 제안하는 방법은 증거의 수가 적은 불확실한 환경에서도 좋은 성능을 내고 학습의 복잡도가 줄어듦을 확인할 수 있었다.

**키워드 :** 베이지안 네트워크 구조, 제한 학습, 장면 이해, 불확실한 환경

**Abstract** Vision-based scene understanding is to infer and interpret the context of a scene based on the evidences by analyzing the images. A probabilistic approach using Bayesian networks is actively researched, which is favorable for modeling and inferring cause-and-effects. However, it is difficult to gather meaningful evidences sufficiently and design the model by human because the real situations are dynamic and uncertain. In this paper, we propose a learning method of Bayesian network that reduces the computational complexity and enhances the accuracy by searching an efficient BN structure in spite of insufficient evidences and training data. This method represents the domain knowledge as ontology and builds an efficient hierarchical BN structure under constraint rules that come from the ontology. To evaluate the proposed method, we have collected 90 images in nine types of circumstances. The result of experiments indicates that the proposed method shows good performance in the uncertain environment in spite of few evidences and it takes less time to learn.

**Key words :** Bayesian network structure, constrained learning, scene understanding, uncertain environment

## 1. 서 론

베이지안 접근 방법은 확률적인 모델을 효과적으로 구성하고 효율적인 추론 및 학습이 가능한 방법으로서 인간의 인과적인 판단 및 추론 과정을 모델링하기에 유

리한 도구이다. 복잡한 세계에 존재하는 모든 정보의 확률적 인과 관계를 모델로 표현하는 것은 거의 불가능할 뿐만 아니라 효율적이지 않다. 따라서 인과성이 높은 관계만을 네트워크 구조로 표현하고, 표현되지 않은 관계에 대해서는 상호 독립성을 가정하며, 직접적인 인과 관계에서의 조건부 확률만을 정의하여 확률 분포를 표현하는 베이지안 네트워크 구조를 이용하는 것이 효율적이다[1]. 베이지안 네트워크는 직관적인 그래픽 모델, 효율적인 추론 알고리즘 및 학습 알고리즘을 가지고 있어서 여러 문제에서 널리 사용되고 있다.

장면에 어떤 물체가 존재하는지, 어떤 장소에 있는지,

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

‡ 정회원 : 연세대학교 컴퓨터과학과  
yellowg@sclab.yonsei.ac.kr

‡‡ 종신회원 : 연세대학교 컴퓨터과학과 교수  
sbcho@sclab.yonsei.ac.kr

논문접수 : 2005년 9월 22일  
심사완료 : 2007년 4월 13일

그리고 어떤 상황인지를 알기 위해, 시각 정보로부터 물체 및 물체 특징을 인식하고 장면에 대해 설명하는 컨텍스트를 추출하는 것을 시각 기반 장면 이해라고 한다. 그리고 장면 인식은 일상사건을 인식하는 것을 의미하며 이를 이해하고 해석하면 장면 설명을 할 수 있다. 장면에서 인식의 대상은 장소, 부분, 활동, 의도 및 공간적 시간적 관계가 있다[2]. 장면을 이해하면 사용자의 의도를 인지하거나 작업 중심의 서비스 제공, 과거의 경험 발견 및 신뢰성 있는 작업이 가능하기 때문에 중요한 연구 주제로 여겨지고 있으며, 시각 정보는 사용자 및 환경과 상호작용이 요구되는 실세계 문제에서 중요한 판단의 근거가 되기 때문에 많은 관심을 받고 있다.

장면 이해를 잘 하기 위해서는 장면 관련 정보를 컨텍스트로 정의하는 과정과 컨텍스트의 관계를 정확하게 모델링하는 과정, 그리고 신뢰성 있는 추론 과정이 요구되는데, 특히 잘 구성된 모델링을 통한 정확한 컨텍스트의 추론은 어렵지만 중요한 이슈다. 장면 인식은 물체에 대한 정보를 바탕으로 여러 단계의 컨텍스트 추출이 수행되고 시간과 공간에 대한 인과 관계를 가지고 있기 때문에 확률적 접근 방법이 좋다[2]. 이는 장면 이해 과정에서 시각적인 행동 정보는 시공간적 컨텍스트의 확률적 추론에 의해 예측이 가능하고[3], 센서의 종류, 알려지지 않은 물체, 모델이 가진 고유의 불확실성 등 다양한 소스로부터 생기는 실세계에서의 불확실성에 대해 잘 다룰 수 있기 때문이다[4].

본 논문에서는 환경의 불확실성에 의한 성능 저하를 최소화하고 효율적인 계산을 수행하기 위해 계층적이면서도 간결한 베이지안 네트워크를 자동으로 학습하는 방법을 제안한다. 자주 바뀌는 실세계 환경을 대상으로 하고 가려짐에 의한 정보 부족이나 센서 노이즈의 간섭이 빈번한 불확실한 환경을 극복하기 위해서는 환경에서 직접 수집한 데이터를 이용하여 효과적인 모델링을 수행해야 한다. 이를 위해 도메인 지식을 활용한 제한된 구조 학습 방법을 제안한다. 즉, 추론 대상 컨텍스트의

관계를 온톨로지로 구성하고 모델의 레벨 및 클래스 정보를 베이지안 네트워크 학습 파라미터로 정의하여 자동 학습하는 방법이다. 이런 방법으로 학습하면 베이지안 네트워크 구조가 계층화 되고 추론의 방향이 계층에서 다른 계층으로 흐르도록 제한되기 때문에 증거가 부족하더라도 추론 결과 오류가 제한되어 신뢰성 있는 결과를 낼 수 있다. 본 논문에서는 평가를 위해 실제 영상 데이터를 수집하여 직접 레이블링한 뒤 실험하였다.

## 2. 관련 연구

장면 인식에 대한 연구는 1955년 지각 인식 컨텍스트 연구에서부터 시작되어 최근까지 계속 발전하였다. 특히 영상 처리 기술이 발전하고 영상 기반 정보 인식이 요구되는 에이전트 연구가 진행되면서 그 필요성이 증대하였다. 최근에는 확률 모델 기반 장면 인식 방법이 주로 연구되고 있다(표 1). 장면 이해를 위해 이용되는 확률 모델의 하나인 베이지안 네트워크를 설계하는 방법은 크게 두 가지가 있다. 전문가의 도움을 얻는 방법과 학습을 이용한 방법이다. 직관적이고 인과적인 설명이 가능한 베이지안 네트워크 특성상 전문가에 의한 설계 방법이 많이 이용되고 있다. 하지만 복잡하고 변화가 많은 환경에서 전문가에 의한 모델링을 유지하기 위해서는 많은 비용이 요구되기 때문에 자동 학습 방법이 많이 연구되고 있다.

학습 데이터로부터 베이지안 네트워크를 자동 학습하는 방법은 크게 두 가지가 있다. 먼저 변수들의 연관성 기반 학습 방법이 있다. 이 방법은 주어진 데이터에서 변수들의 조건부 독립성을 테스트하면서 네트워크 구조를 형성해 나가는 방법이나 변수들의 관계를 테스트하는 것이 쉽지 않기 때문에 널리 쓰이지는 않는다[5]. 다른 방법으로 네트워크 구조 학습 문제를 최적화 문제로 두고 해결하고자 하는 접근 방법이 있다[6]. 이 방법은 네트워크의 구조가 학습 데이터에 얼마나 일치하는지를 점수로 환산하고, 가장 높은 점수를 가진 구조를

표 1 확률적 모델 기반 장면 인식 관련 연구

의미	저자	내용
장면 인식을 위한 추론 모델 구성 방법 연구	독일 Hamburg 대학 프로젝트 Neumann03 [2]	개체의 존재, 특성, 그룹 및 클래스 정보를 계층적으로 구성하고 확률적으로 정의, Bayes' Rule을 기초로 확률 연산, 시간적인 연관성과 공간적인 연관성을 상향식(Bottom-Up)으로 설계
영상 필터를 이용한 실세계 데이터 학습	MIT 연구실 Torralba03 [10]	PCA 영상 특징 추출 필터를 이용해서 장소 및 물체 인식 모델 구성, Bayes' Rule과 Markov 가정 이용, 장소 이동 관련성은 전문가가 설계, 물체의 장소별 존재 확률 추정
계층적 BN을 이용한 단계적인 컨텍스트 추론 모델 설계	미국 Massachusetts 대학 THE ASCENDER II SYSTEM 개발 프로젝트 Marengoni03 [11]	BN을 이용한 컨텍스트 모델링, 항공 영상에서 정보를 추출하여 건물 특징 및 건물 종류를 추론, 상위 수준 추론 결과가 하위 수준 추론 수행 여부를 결정하는 계층적 BN을 제안하여 연산 효율성 높임, BN 구조는 전문가 설계, 파라미터는 학습, 결정 네트워크와 유밀리티 활용

탐색하는 방법이다. 탐색 공간이 네트워크를 구성하는 변수에 대해 지수적인 복잡도를 가지고 있고 최적의 구조를 찾는 문제가 NP-hard 문제라고 알려져 있기 때문에 [7], 탐색 휴리스틱 방법이 주로 사용되고 있다[8]. 하지만 이러한 방법들은 지역 최적해에 빠지는 문제를 가지고 있어, 최근에는 진화 연산을 이용해 이를 해결하려는 노력이 이뤄졌다[9]. 확률 파라미터 학습 과정에서도 설계된 네트워크의 구조에 따라 많은 수의 데이터가 요구된다.

장면 이해 문제는 불확실한 실세계를 도메인으로 하고 있는데, 불확실한 환경에서 부딪히는 문제 상황은 예상치 못한 데이터가 입력된 경우, 환경이 바뀐 경우, 입력된 데이터에 잡음이 포함된 경우와 입력 데이터의 양이 부족한 경우가 있다. 이 중에서 앞의 두 경우는 실시간 업데이트 및 지속적인 추론 모델의 적응을 통해 극복 가능하며, 뒤의 두 경우는 오류에 강인한 확률 추론 모델 설계를 통해 극복이 가능하다. 본 논문에서 접근하는 방법은 입력 데이터의 양이 부족하거나 잡음이 포함된 경우를 극복하기 위한 방법이다.

불확실한 환경에서 좋은 성능을 얻기 위한 베이지안 네트워크 학습 방법은 해당 환경에서 직접 수집한 불확실성이 고려된 데이터에 가장 일치하는 정확한 모델을 찾는 것이었다. 이미 오래 전부터 베이지안 통계 및 정보 이론, MDL(Minimal description length) 원리[12]를 이용한 BN 탐색 방법이 고안되었고, 이러한 방법들을 발전시키고 분석하는 노력이 있었다[13]. 하지만 이러한 방법들은 학습 데이터가 부족한 환경에서는 좋은 성능을 보장할 수 없으며, 이를 해결하기 위한 연구로 표 2와 같은 방법들이 연구되었다. 하지만 학습을 통해서 네트워크 구조를 설계할 경우 불필요한 연결 관계가 생기거나 잘못 구성될 가능성이 높기 때문에 전문가의 개입에 의한 네트워크 구조 수정 및 설계 방법이 여전히 많이 사용되고 있다.

### 3. 장면 인식을 위한 베이지안 네트워크

장면 이해란, 영상에서 여러 컨텍스트 정보를 추출하는

고 이를 바탕으로 장면 인식 컨텍스트를 추론한 다음 이를 바탕으로 장면을 이해하는 과정이다. 이 과정에서 얼마나 많은 증거를 얼마나 정확하게 수집하느냐, 수집된 증거를 이용하여 얼마나 정확하게 추론하느냐가 장면 이해 성능을 좌우하게 된다. 본 논문에서 사용된 장면 인식 컨텍스트 추론 과정은 그림 1과 같다. 환경에서 수집된 센서 정보 및 기호적으로 해석된 컨텍스트 정보와 온톨로지 등으로 주어진 도메인 지식을 함께 고려하여 상대적으로 레벨이 높은 상황이나 상태 컨텍스트를 추론하는 과정을 거친다. 이때, 온톨로지란 ‘어떤 개념들이 도메인 내에서 어떻게 존재하고, 서로 관련되는가에 대한 지식을 나타내는 것’을 말하며, 환경의 지식을 포함하고 있다[19].

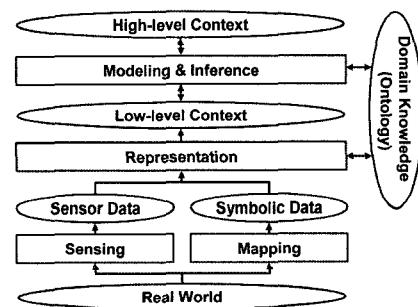


그림 1 영상 정보에서 여러 레벨의 컨텍스트를 추출하는 과정

여러 레벨의 컨텍스트를 얻기 위한 추론 과정에는 확률적인 접근 방법이 많이 사용된다. 하지만 복잡한 실세계의 모든 확률 관계를 표현하거나 설계하는 것은 매우 어렵기 때문에, 확률적 인과성이 강한 정보의 확률만 정의하는 베이지안 네트워크 모델을 이용하기도 한다. 또한 베이지안 네트워크를 이용하면 분석적 추론(Diagnostic Reasoning)을 이용해 결과에서 원인을 분석할 수 있을 뿐만 아니라, 구성하고 있는 변수의 종류에 상관없이 유연하게 입출력이 가능하기 때문에 실세계처럼 복잡한 환경에서 하나의 증거라도 더 활용할 수

표 2 부족한 BN 학습 데이터를 극복하기 위한 연구

방법	내용
Noisy-OR 기법: Buchanan84 [14], Pearl88 [15]	적은 수의 학습 데이터를 극복하기 위해 부모 조건의 독립성을 가정하고 파라미터를 학습
Learning with Boosting: Choudhury02 [16]	학습 데이터의 오류를 집중적으로 극복하기 위해 학습 단계에서 Boosting 기법을 사용하여 오류를 최소화하는 방법
Restricted BN: Schneiderman04 [17]	지역별로 오류를 최소화 하는 변수의 부분 집합을 선택한 후 BN을 탐색하는 전역 오류 최소화 과정을 이용
Restricted BN: Lucas02 [18]	도메인의 특성에 따라 Naive Bayesian network와 TAN (Tree augmented Bayesian network)의 모델 지향 특성을 조절하여 좋은 성능을 가지는 BN을 탐색

있다. 또한 불확실성을 확률적으로 다룰 수 있는데, 정 보나 증거에 대한 신뢰도를 확률적으로 정의하면 더 정 확한 추론 결과를 얻을 수 있다.

장면 이해 대상인 장소의 종류와 특성을 인식하기 위한 베이지안 네트워크를 가장 단순한 베이지안 분류기 형태인 Naive BN으로 설계하면 그림 2와 같다. 그림 2는 계산 복잡도를 줄이기 위해 인파성의 역방향으로 설계(장소→물체)하고, 장소 및 장소 특성 변수 10개와 물체 변수 33개를 대상으로 설계한 BN이다. 장소 변수는 장면 정보(장소의 종류)를 나타내는 결과 노드이고, 물체 노드는 장면 인식을 위한 증거가 입력되는 노드이다.

그림 2의 BN은 모든 장소와 물체 노드가 연결되기 때문에 상당히 많은 연결 관계가 관찰된다. 따라서 많은 확률 파라미터의 정의가 요구되고, 확률 추론의 계산 복잡도가 크며, 학습을 할 경우 많은 확률 파라미터에 대응하여 많은 데이터가 요구된다. 베이지안 네트워크 구조에 따라 요구되는 확률 파라미터의 개수는 수식 (1)과

같다. 이때,  $N$ 은 변수의 수,  $r_i$ 는 변수  $X_i$ 의 상태의 수,  $U_i$ 는 변수  $X_i$ 의 부모집합을 의미한다.

$$\sum_{i=1}^N \left( r_i \times \prod_{X_j \in U_i} r_j \right) \quad (1)$$

그림 3은 도메인 지식을 이용하여 추론의 단계를 ‘발견된 물체 종류 → 장소종류 추론 → 장소특성 추론’으로 나누고 계층적 BN 구조를 설계한 경우이다. 계층이 증가하면서 구조가 단순해지고 복잡도가 줄어들었다. 본 논문에서는 이렇게 계층성이 부여된 BN 구조의 설계를 기반으로 학습 데이터에서 연관성이 강한 변수 관계를 탐색하여 자동으로 구성하는 학습 방법을 제안한다.

#### 4. 베이지안 네트워크의 제한된 학습 방법

##### 4.1 베이지안 네트워크의 학습

베이지안 네트워크는 노드의 연결 관계를 표현하는 방향성 비순환 그래프(DAG: directed acyclic graph) 형태를 가지고 있으며, 이 구조에 따라 정의된 조건부

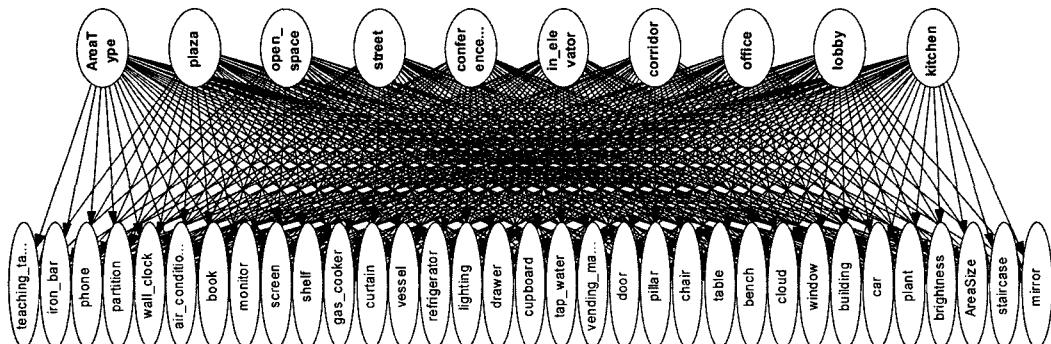


그림 2 물체 정보에서 장소를 인식하는 Naïve BN : 43개의 변수와, 330개의 연결 관계, 67,604개의 확률 파라미터를 가진다.

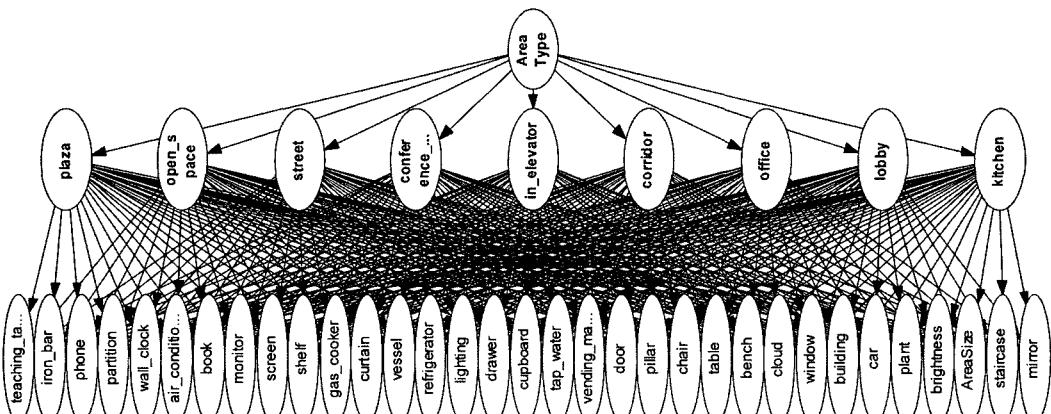


그림 3 장소 인식을 위한 계층적 Naïve BN : 추론 과정이 ‘물체→장소종류→장소 클래스’이다. 43개의 변수와, 306개의 연결 관계, 33,830개의 확률 파라미터를 가진다.

확률 테이블(CPT: conditional probability table)에 의해 적은 비용으로 많은 확률 관계를 효율적으로 표현한다. 베이지안 네트워크 모델은 네트워크 구조를 나타내는  $B_s$ 와 파라미터 집합을 나타내는  $\theta$ 를 이용해  $(B_s, \theta)$  쌍으로 정의할 수 있다. 여기서  $\theta = \{B_\phi, B_p\}$ 는 조건부 확률 테이블  $B_\phi$ 와 초기 확률 분포  $B_p$ 로 구성된다. 본 논문에서는  $B_s$ 를 제안하는 구조 학습을 통해 구성하고, 파라미터  $\theta$ 는 학습 데이터 집합  $D$ 로부터 수식 (2)와 같은 방법으로 계산한다.

$$\theta^* = \arg \max_{\theta} P(D | \theta)P(\theta) \quad (2)$$

여기서  $P(\theta)$ 는 초기 확률을 의미한다. 기본적인 학습 과정은 다음과 같다. 만약  $Z_T = \{z_1, z_2, \dots, z_T\}$ 가  $T$ 개의 상태 변수를 나타내고,  $Y_T$ 가 실제로 측정된  $T$ 개의 변수라면 수식 (3)과 같은 관계를 가지게 된다.

$$P(Z_T, Y_T, \theta) = P(Y_T | Z_T, B_\phi)P(Z_T | B_p) \quad (3)$$

여기서 조건부 확률 테이블  $B_\phi$ 는 측정값과 상태변수의 조합이 얼마나 있었는지의 빈도를 조사하여 정의 가능하다. 즉, 학습 데이터의 분포에 대한 히스토그램을 분석하여 빈도를 확률로 계산하고 베이지안 네트워크의 파라미터를 학습한다.

학습으로 구성된 베이지안 네트워크에서 주어진 증거 집합  $E$ 의 추론 결과  $h$ 에 대한 확률  $Bel(h)$ 는 Bayes' rule에 의해 수식 (4)와 같이 계산된다[1].

$$Bel(h) = P(h | E) = \frac{P(E | h)P(h)}{P(E)} = \frac{P(h \wedge E)}{P(E)} \quad (4)$$

이때 조건부 확률은 Chain Rule에 의해 수식 (5)와 같이 계산된다.

$$\begin{aligned} P(x_1, x_2, \dots, x_n) &= P(x_1, x_2, \dots, x_{n-1})P(x_n | x_{n-1}, x_{n-2}, \dots, x_1) \\ &= P(x_1)P(x_2 | x_1)P(x_3 | x_2, x_1) \dots P(x_n | x_{n-1}, x_{n-2}, \dots, x_1) \\ &= P(x_1)P(x_2 | \pi_2)P(x_3 | \pi_3) \dots P(x_n | \pi_n) \end{aligned} \quad (5)$$

여기에서  $x_i$ 는  $i$ 번째 노드를  $\pi_i$ 는  $x_i$ 의 부모를 의미한다.

## 4.2 베이지안 네트워크 구조의 제한 학습

기존 연구에서 전문가에 의해 설계된 장면 인식을 위한 베이지안 네트워크 구조들을 살펴보면 계층성이 많이 나타난다[2,10,11]. 본 논문은 이러한 계층적인 베이지안 네트워크를 자동으로 설계하기 위한 한 가지 방법을 제안한다. 제안하는 방법은 그림 4와 같으며 도메인 지식과 학습 데이터를 이용하여 계층적인 BN을 생성하는 과정이다.

그림 4에서 사용되는 도메인 지식은 베이지안 네트워크 소속 변수의 인과성과 레벨에 관련된 정보이고 그림 5와 같은 온톨로지로 정의하였다.

이와 같은 온톨로지 정의를 통해 개체 및 속성의 연관 관계와 클래스 계층 구조를 고려하여 베이지안 네트워크 학습을 위한 파라미터를 정의할 수 있다. 이때 온톨로지를 정의하기 위해 수집하고 분석한 정보는 다음과 같다. 여기서 Category와 Association은 더 많은 데이터가 수집될 수도 있으나 문제의 복잡도를 줄이기 위해 제안하는 정도로만 한정시켰다.

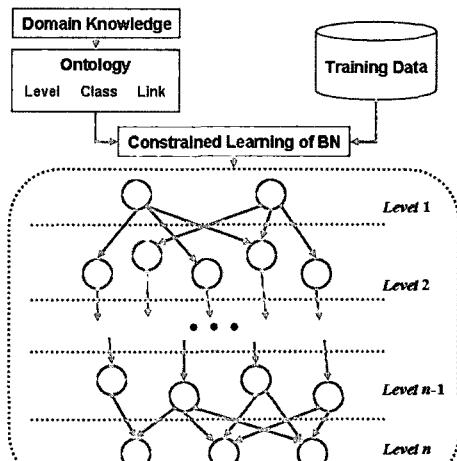


그림 4 제안하는 BN 제한 학습 방법의 개요

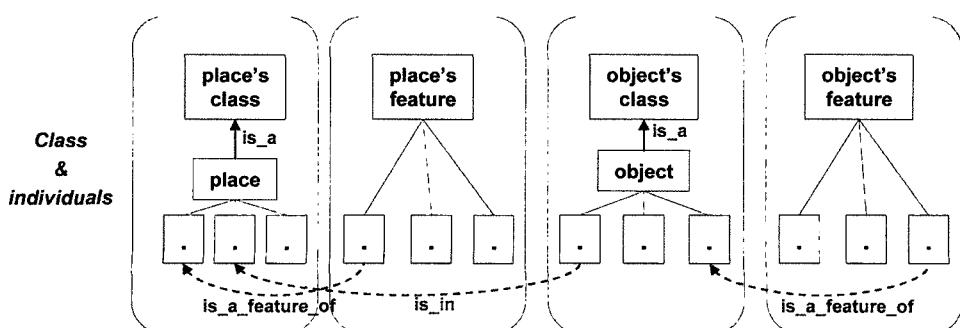


그림 5 물체 및 장소의 계층성과 관계를 나타낸 온톨로지 구조

- Domain: 사무실 및 주변 환경에서 물체를 식별하여 장소의 종류를 인식하는 문제
- Entity: 사용되는 데이터의 종류를 구분 지음
  - 예: {물체의 특징, 물체, 장소의 특징, 장소}
- Class: 그룹을 형성하거나 포함하는 개념
  - 예: 물체((책상, 의자)) ⊂ 물체 클래스(사무용 가구)
- Individual: 발견되거나 인식된 각각의 정보 변수
  - 예: {책상, 의자} ⊂ 물체
- Association: Class 및 individual 사이의 연관성을 표시
  - 예: is\_a, is\_in, is\_a\_feature\_of

온톨로지로 표현된 도메인 지식을 바탕으로 수행되는 제한된 베이지안 네트워크 학습 방법은 그림 6과 같다. 온톨로지를 통해 얻은 도메인 정보를 바탕으로 level, predefined link와 같은 파라미터를 정의하고, BN 학습에 필요한 추가 파라미터(예: topological order)를 생성하거나 초기 BN을 구성하고 제한된 BN 구조 학습 및 수정하는 과정을 거쳐서 목표 BN을 탐색한다. 이 같은 과정은 학습데이터와 BN 구조의 일치성을 평가하는 함수를 정의하고 가장 만족스러운 네트워크 구조를 탐색하는 BN 구조 탐색 알고리즘에 도메인 정보로 제한을 가한 것이다.

본 논문에서는 level 수준을 정의하기 위해서 그림 5의 좌측을 고레벨로, 우측을 저레벨로 정의하였다. 제안하는 학습 알고리즘이 인접 레벨 사이의 연결만 허용하기 때문에 가능한 한 많은 인접 연결(association)을 허용할 수 있도록 {'place's class' → 'place' → 'place's feature' → 'object's class' → 'object' → 'object's feature'} 순서로

배열한 다음에 level을 정의한 것이다. 이때 연결에 의해 구분되는 계층의 경계가 불확실한 경우 같은 level을 정의하는 것도 가능하다. 실제로 본 논문의 실험에서는 'object'와 'object's feature'를 같은 level로 정의하였다. predefined link는 온톨로지에서 정의된 'is\_a', 'is\_in', 'is\_a\_feature\_of' 연결을 그대로 채택하였다. 온톨로지에서 정의된 클래스에 속하는 서브 클래스나 인스턴스 사이에 알려져 있는 연결 관계는 이미 인과 관계를 가지고 있다고 가정하는 것이다. 이러한 연결 관계는 설계자가 인과 관계가 있다고 확신하는 경우에만 해당된다. 제안하는 알고리즘에서 베이지안 네트워크는 predefined link가 연결된 상태에서 학습을 시작한다. topological order는 4.3절에서 다루는 베이지안 네트워크 학습 방법에 적용되는 파라미터로서 부모가 될 가능성이 높은 노드에 대한 순서를 정의한다. 본 논문에서는 topological order를 정의하기 위해 같은 level의 노드 사이에서는 순서를 임의로 생성하고 level 사이에는 높은 레벨이 우선순위가 높도록 하였다. topological order를 어떻게 정의하느냐에 따라 알고리즘의 성능이 차이가 날 수 있으나 본 논문에서는 topological order의 최적화 방법에 대해서는 다루지 않고 반복 실험에 의한 성능 검증까지만 수행하였다.

일반적으로 베이지안 네트워크 구조를 학습하기 위해 사용되는 방법은 각 노드별로 부모를 정의했을 때 주어진 데이터의 존재 확률값을 최대로 하는 부모 집단을 찾는 방법으로 수식 (6)과 같다. 여기서  $\pi_i$ 는  $X_i$ 의 부모 집단을 의미하고,  $\theta_i$ 는  $X_i$ 에 대한 조건부 확률 테이블을 의미한다.

$$\pi_i^* = \arg \max_{\pi_i} P(D | \theta_i) P(\theta_i | \pi_i) P(\pi_i) \quad (6)$$

본 논문에서는 레벨 파라미터( $L$ )를 이용하기 때문에  $X_i$ 의 부모 탐색 복잡도가 줄어드는 효과를 가진다. 기존에는 탐색 후보 집합이  $X_i$ 를 제외한 모든 변수였지만, 제안하는 방법에서는 레벨 파라미터( $L$ ) 값이 높은 변수 중에서  $X_i$ 를 제외한 변수가 후보 집합이다. 계층적인 BN 구조를 학습하기 위해서 제한되는 사항은 다음과 같다. 이때 order는 숫자가 작을수록 우선순위가 높음을 나타내고, level은 숫자가 클수록 상위 수준을 의미하며, level이 높을수록 order는 작다.

#### • 기호 정의

$X_i = i^{\text{th}}$  variable that is included in the set  $\mathbf{X}$

$\text{level}(X_i) = \text{an integer which is the level of variable } X_i$

$\text{order}(X_i) = \text{an integer which is the topological order of variable } X_i$

$\text{parents}(X_i) = \{X_j \mid X_j = \text{the parent of variable } X_i\}$

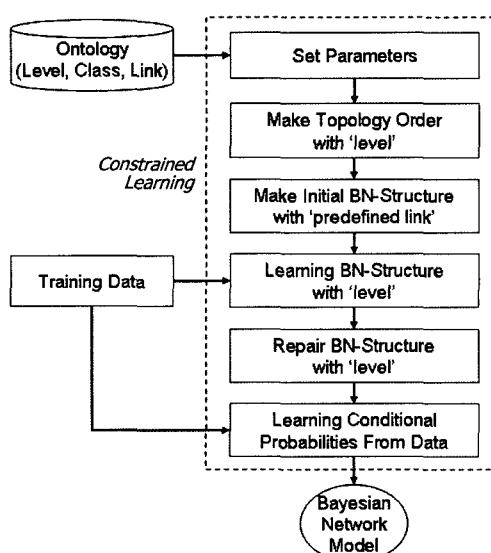


그림 6 베이지안 네트워크의 제한 학습 과정

`parents_level_area( $X_i$ ) = { $k \mid k = \text{available level as parent of variable } X_i\}$`

• 제한 규칙 1. 위상 순위 초기화:

On the initialization process,

`set: order( $X_i$ ) $\leftarrow$ order( $X_j$ ), order( $X_j$ ) $\leftarrow$ order( $X_i$ ) if level( $X_i$ ) $<$ level( $X_j$ )  $\wedge$  order( $X_i$ ) $<$ order( $X_j$ )`

`where:  $\forall X_i \in \mathbf{X}, \forall X_j \in \mathbf{X} \wedge i \neq j$ ,`

• 제한 규칙 2. 알려진 연결 관계 반영:

On the initialization process,

`set: parents( $X_j$ )  $\leftarrow$  parents( $X_j$ ) $\cup$ { $X_i$ }`

`where:  $\forall X_i \in \mathbf{X}, \forall X_j \in \mathbf{X} \wedge X_i \text{ causes } X_j$`

• 제한 규칙 3. 부모 탐색 도메인의 제한:

On the learning process,

`set: parents-candidate-set( $X_i$ ) = { $X_k \mid \text{level}(X_k) \in \text{parents\_level\_area}(X_i), X_k \in \mathbf{X}, i \neq k\}$`

• 제한 규칙 4. 동수준 연결 관계의 수정:

After the learning process,

`set: parents( $X_i$ )  $\leftarrow$  (parents( $X_i$ ) $-$ { $X_j$ }) $\cup$ { $X_k$ } if  $\exists X_k \in \text{parents}(X_j) \wedge \text{level}(X_j) < \text{level}(X_k)$`

`where:  $\forall X_i \in \mathbf{X}, \forall X_j \in \mathbf{X} \wedge i \neq j \wedge X_j \in \text{parents}(X_i)$`

`$\wedge \text{level}(X_i) = \text{level}(X_j)$`

### 4.3 알고리즘

제안하는 베이지안 네트워크 학습 방법은 Cooper가 제안한 K2 학습 알고리즘[8]에 레벨 파라미터( $L$ )와 연결 관계 파라미터( $R$ )에 의한 제한을 적용한 방법이다 (그림 7).

<p><b>Given Parameter:</b>  <math>D = \{x_1, \dots, x_N\}, x = \{s_1, \dots, s_N\}, s_i = \text{state value of variable } X_i</math>  <math>\mu = \text{Limitation of number of parents on K2 Learning}</math>  <math>a = \text{Coverage of level parameter}</math>  <math>M = \text{number of training data}</math>  <math>N = \text{number of variables of BN}</math></p> <p><b>Environment Variables:</b>  <math>B_s = \{\pi_1, \dots, \pi_N\}, \pi_i = \text{parents list of variable } X_i</math>  <math>B_\phi = \text{total CPT}</math>  <math>X_i = \text{variable } i</math></p> <p><b>Environment Functions:</b>  <math>\text{PredefinedParents}(i) = \text{predefined parents set of variable } X_i \text{ based on predefined link}</math>  <math>\text{ParentLevelArea}(i) = \text{available level set for parents of variable } X_i</math>  <math>\text{level}(i) = \text{level of variable } i</math>  <math>\text{order}(i) = \text{topological priority value of variable } i</math>  <math>\text{Learn_Parameters_from_Data_Distribution}(B_s, D) = \text{parameter learning with structure } B_s \text{ and dataset } D</math></p> <p><b>Learning:</b></p> <pre> // initialization process For i=1, ..., N,     if <math>X_i</math> has Predefined Parents then         <math>\pi_i = \text{PredefinedParents}(i);</math> // initialize parents of node         ParentLevelArea(i) = {level(i), ..., level(i)+a}; // initialize available level set for parents     End;     For j=i+1, ..., N,         If order(i) &lt; order(j) and level(i) &lt; level(j) then             swap (order(i), order(j)); // sort topological order with level         End;     End; End;  // modified K2 learning process For i = 1, ..., N,     <math>P_{old} = g(i, \pi_i, D);</math>     While <math> \pi_i  &lt; \mu \text{ AND Proceed = true DO;}</math>         <math>X_k = \text{the node in } (\text{Pred}(X_i) - \pi_i) \text{ that maximizes } g(i, \pi_i \cup \{X_k\})</math>         where level(k) is in ParentLevelArea(k);         <math>P_{new} = g(i, \pi_i \cup \{X_k\}, D);</math>         If <math>P_{new} &gt; P_{old}</math> THEN             <math>P_{old} = P_{new};</math>             <math>\pi_i = \pi_i \cup \{X_k\};</math>             ELSE Proceed=false;         End;     End;  FOR <math>X_j = \text{each node in } \pi_i</math> // modification process     If level(i)=level(j) THEN <math>\pi_i = \pi_i \cup \pi_j - \{X_j\};</math>     End; End; End;  <math>B_\phi = \text{Learn_Parameters_from_Data_Distribution}(B_s, D);</math> </pre>
---

그림 7 제한된 베이지안 네트워크 학습 알고리즘

제안하는 알고리즘은 베이지안 네트워크의 최적 구조를 판단하기 위해 Cooper가 제안한 K2 metric인  $g(\cdot)$  함수를 사용하였으며, 최대 부모수 파라미터( $\mu$ )와 변수 순서 파라미터( $O$ )를 같이 사용하였다.  $\mu$ 는 K2 학습 알고리즘의 파라미터로서 너무 복잡한 구조의 베이지안 네트워크 구조가 되지 않도록 부모의 수를 제한하는 역할을 하며,  $a$ 는 부모로 정의가 가능한 레벨 차이의 범위를 나타낸다. 예를 들어,  $a$ 가 2이면 level 1인 노드는 level 1~3인 노드를 부모로 가질 수 있다. K2 알고리즘은 상대적으로 위상 순위가 높은 변수만 부모가 될 수 있도록 제한하고 있기 때문에 이를 제한 규칙 1에 적용하였다. 그리고 초기화 과정에서 제한 규칙 2가 적용되었으며, K2 학습 과정에서 제한 규칙 3이 적용된 부모 변수 탐색이 수행되고, 수정하는 단계에서 제한 규칙 4가 사용되었다. 이때 학습에 사용되는 K2 점수 계산 함수는 수식 (7)과 같으며, 여기서,  $(v_{ii}, \dots, v_{ir_i})$ 은 변수  $X_i$ 에 배정 가능한 값 배열을,  $r_i$ 는 그 배열의 수를,  $\pi_i$ 는 변수  $X_i$ 의 부모 집합을,  $w_{ij}$ 는 부모집합  $\pi_i$ 의  $j$ 번째 상태를,  $q_i$ 는 부모 집합  $\pi_i$ 의 상태수를,  $N_{ijk}$ 는 변수  $X_i$ 가 값  $v_{ik}$ 를 가지고 부모집합  $\pi_i$ 가  $w_{ij}$ 로 초기화 된 경우의 수를 의미한다[8].

$$g'(i) = \prod_{j=1}^{q_i} \frac{(r_i - 1)!}{(N_{ij} + r_i - 1)!} \prod_{k=1}^{r_i} N_{ijk}! \quad (7)$$

## 5. 실험 및 결과

본 장에서는 제안하는 베이지안 네트워크 학습 방법이 컨텍스트 추론 기능에서 어떤 특성을 보이는지 알아보기 위해 비교실험을 수행하였다. 특히 제안하는 방법의 경우 계층적으로 수행되는 분류 특성으로 인해 부족하거나 잘못된 증거의 오류가 줄어들 수 있기 때문에 증거가 부족한 상황을 가정하여 비교실험을 수행하였다. 실험을 위해 9종류의 장소별로 10장의 다른 영

상 데이터를 수집하고, 영상에서 관찰되는 물체, 장소, 장소의 클래스에 대한 컨텍스트를 레이블링 하였다(그림 8). 이때 레이블링 항목은 장소의 종류를 인식하는데 도움이 되는 것을 위주로 채택하였으며, 주로 물체 존재 여부가 장소의 증거로 사용되는 것으로 가정하였다.

### 5.1 실험 환경

그림 9는 영상 데이터로부터 장면을 인식하기 위해 사용될 수 있는 물체와 장소 관련 도메인 지식을 온톨로지로 표현한 것이다. 영상 데이터를 분석하여 레이블링 한 항목은 그림 9에서와 같이 장소 클래스, 장소, 물체, 물체 특성이다. 그림에서 'place'와 'place's class'의 사이에는 연결 관계가 명확하게 드러나 있지만 'object'와 'place' 사이에는 어떤 노드 사이에 연결을 가지고 있는지 알 수 없는 경우이다. 해당 연결 관계는 제안하는 베이지안 네트워크의 학습 과정에서 찾게 될 것이다.

표 3은 베이지안 네트워크의 학습에 사용된 데이터를 나타낸다. 물체 노드는 관찰의 빈도수에 따라 3개의 상태{none, a little, a lot}로 구분하였다. 물체 특정 노드는 장면에 대해 중요한 증거가 될 수 있다고 판단되는 '바닥의 밝기(brightness)'와 '바닥의 크기(area size)'에 대해서만 정의하였는데, 'brightness'는 {'normal', 'dark', 'bright'}로 정의하였고, 'area size'는 {'small', 'normal', 'wide', 'long'}로 정의하였다. 각 장소 노드는 {'Yes', 'No'}로 정의하였으며, 장소의 클래스 노드는 {'indoor', 'outdoor'}를 상태로 가지는 'AreaType' 노드 하나만 사용하였다. 이때 속성을 선택하기 위한 기준은 레이블링에 참여한 전문가의 의견을 그대로 반영하였다. 'door'나 'tap\_water'와 같이 빈도수가 작은 물체의 경우 2개 이상이면 'a lot'으로 정의하였고, 'chair'와 같이 원래 어느 정도 많이 존재하는 물체의 경우에는 5개 이상이면 'a lot'으로 레이블링 하였다.

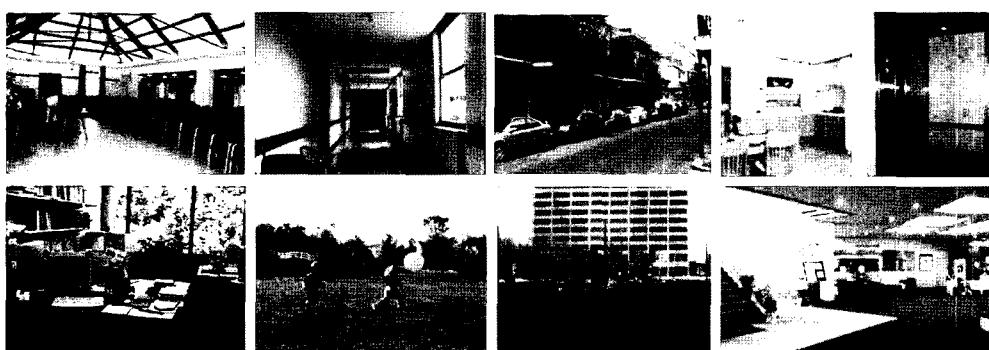


그림 8 인터넷에서 수집한 영상 데이터의 예

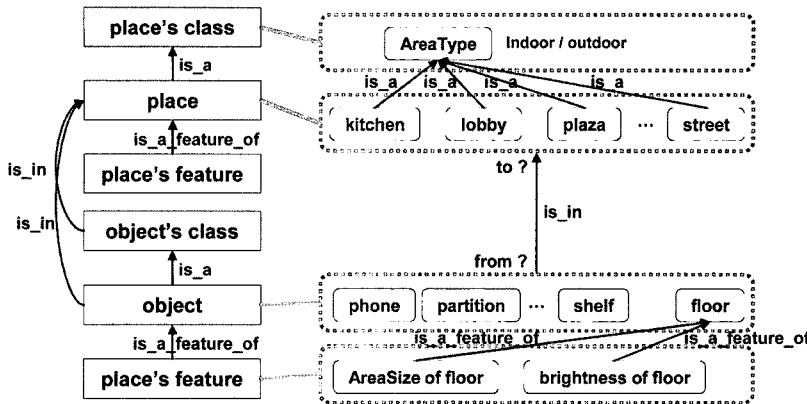


그림 9 온톨로지로 설계된 도메인 지식 모델

표 3 실험에 사용된 데이터 일부

번호	종류	이름	속성 구분	레벨	부모
1	places's class	AreaType	indoor / outdoor	2	없음
2	place	plaza	Yes / No	1	AreaType
3	place	lobby	Yes / No	1	AreaType
...	...	...	...	...	...
10	place	street	Yes / No	1	AreaType
11	object	tap_water	none / a_little / a_lot	0	없음
...	...	...	...	...	...
41	object	cupboard	none / a_little / a_lot	0	없음
42	object's feature	brightness	normal / dark / bright	0	없음
43	object's feature	areaSize	small / normal / wide / long	0	없음

컨텍스트의 level은 그림 9의 온톨로지를 바탕으로 정의하였다. 이때, 모든 장소에서 'floor'는 항상 존재하고 'floor'의 속성을 다양하게 정의하는 것보다 특징 'brightness', 'AreaSize'에 의한 직접적인 장소 증거 활용이 더 효율적이라 판단하여 'brightness'와 'AreaSize'를 물체와 같은 레벨로 정의하였다. 정의된 레벨 속성은 {level of 'object's feature'= 0, level of 'object'= 0, level of 'place'= 1, level of 'place's class'= 2}과 같다. 표 4는 베이지안 네트워크 학습 실험에 사용된 환경

변수 및 주어진 파라미터를 나타낸다.

## 5.2 자동 설계된 베이지안 네트워크 구조

제한된 BN 학습 알고리즘은 Naïve BN 구조의 많은 연결 관계에 의한 복잡도 문제를 해결하고 전문가에 의한 BN 설계 어려움을 덜기 위해 제안된 것이다. 그림 10과 11은 실험 결과 얻은 BN을 레벨이 가장 높은 'AreaType' 노드를 기준으로 최소 경로 거리에 따라 중심에서 동심원 모양으로 배열한 그림이다. 그림 10은 기존의 K2 알고리즘을 이용하여 설계된 BN을 나타낸다.

표 4 실험 환경 변수

환경 변수	내용
학습	물체 및 물체 특성 컨텍스트 장소 컨텍스트
데이터	장소 클래스 컨텍스트
관련	데이터 수 ( $M$ ) BN 노드 수 ( $N$ )
	최대 부모수 ( $\mu$ ) 초기 변수 우선순위 ( $O$ )
파라미터	레벨 ( $L$ ) 연결 관계 ( $R$ )
관련	Coverage of level ( $a$ )

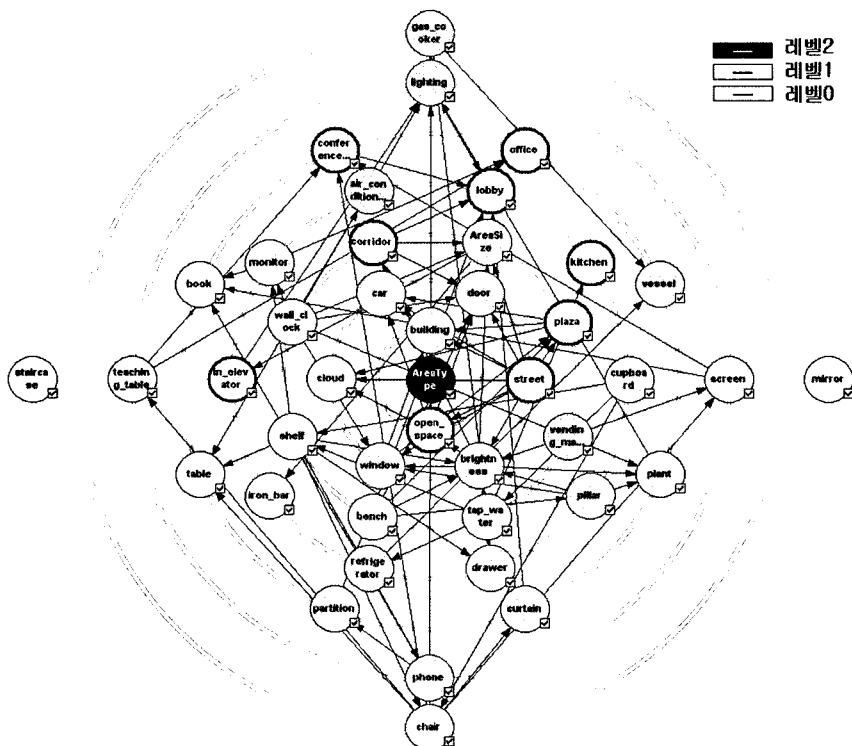


그림 10 K2 알고리즘에 의해 얻은 BN : 계층성이 약하고 노드가 흩어져 있다. ‘AreaType’ 변수를 중심으로 경로 거리에 따라 동심원으로 배열하였다.

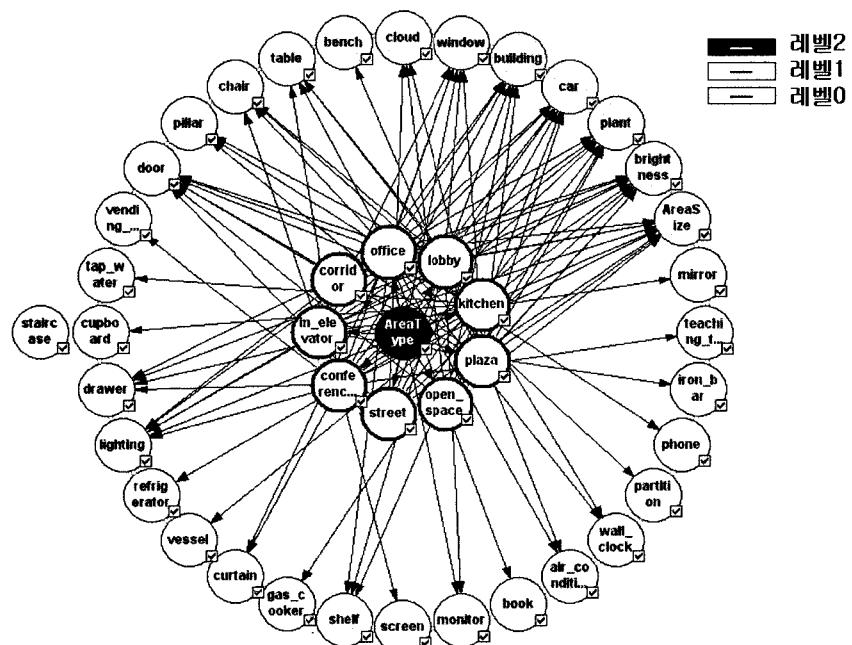


그림 11 K2R 알고리즘에 의해 얻은 BN : 'AreaType' 변수를 중심으로 경로 거리에 따라 동심원으로 배열하였으며, 노드 레벨 간 계층성이 뚜렷하다.

43개의 노드와 87개의 연결관계, 1,925개의 파라미터를 가지고 있으며, 인과성이 강한 경우에만 연결 관계가 생성되기 때문에 Naïve BN(그림 2, 그림 3)에 비해 네트워크의 복잡도가 크게 줄어들었다. 하지만 실제 노드의 레벨과 상관없이 불규칙한 8개의 충을 형성하고 있어서 이해하기 어려운 구조를 가지고 있다. 즉, 그림 10의 BN은 노드의 계층적 특성이 반영되지 않았기 때문에, 결과 노드(변수)의 판단 근거가 되는 변수가 적게 연결되어 있어서 증거가 부족한 경우 정확도가 감소할 가능성이 높다. 또한 독립성이 요구되는 증거 노드 사이에 생긴 불필요한 인과 관계로 인해 D-separation 되어 증거의 효과가 차단될 수 있다[15].

그림 11은 본 논문에서 제안한 방법을 이용해 설계된 베이지안 네트워크이다. 43개의 노드, 110개의 연결관계, 5,859개의 파라미터를 가지고 있다. 그림 10에 비해 구조가 복잡하지만 Naïve BN에 비해 복잡도가 크게 줄어들었고, 계층적으로 구성되어 있어서 증거가 1개가 들어오더라도 관련된 결과 노드에 정보를 전달할 수 있다. 또한 같은 증거 노드 사이의 연결이 배제되어 있기 때문에 추론의 단절을 방지할 수 있다.

### 5.3 컨텍스트 추론 성능 비교

제안하는 방법(K2R)과 기존의 학습 방법(K2)의 일반화 성능을 평가하기 위해 주어지는 증거의 개수를 다르게 하면서 장소에 대한 분류 성능을 평가해 보았다. 그림 13은 주어지는 증거의 수를 3개에서 33개(물체의 수)로 바꿔가면서 각각의 경우에 대해 20번씩의 분류 성능 평가를 한 다음 평균 및 표준 편차를 계산하여 표현한 결과를 나타낸다. 주어지는 증거는 33개의 물체 중에서 임의의 것을 선택하도록 하였으며 9개의 장소에 대해 가장 높은 확률을 나타낸 노드가 정답 장소와 일치하는지 여부를 평가하였다. 이 실험에서 학습 데이터와 평가 데이터는 동일한 것을 사용하였다. 실험 결과를 살펴보면 모든 경우에 대해서 K2R 방법이 더 좋은 성능을 보이고 있으며, 특히 증거의 수가 적을수록 그 성능 차이가 크게 나타나는 것을 알 수 있다. 이와 같은 결과는 계층적인 정보가 잘 반영된 베이지안 네트워크에서는 주어진 물체의 증거가 장소 존재 확률에 미치는

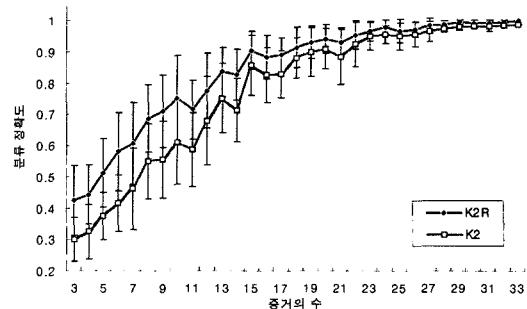


그림 12 증거의 수에 따른 베이지안 네트워크 분류 성능 및 표준 편차

영향이 잘 학습이 되어 있는데 비해, 기존의 K2 학습 방법에서는 물체와 장소 가릴 것 없이 존재 확률이 비슷한 노드에만 영향을 많이 끼치기 때문에 분석된다.

학습 데이터와 평가데이터가 다른 경우의 성능 평가를 위해 교차 검증(cross validation)을 통한 성능 평가를 하였다. 그림 13은 증거 4개('Chair', 'AreaSize', 'Brightness', 'AreaType')를 준 경우(왼쪽)와 장소 노드 9개를 제외한 34개의 증거를 준 경우(오른쪽)에 교차 검증을 통해 장소 분류 성능을 비교한 그래프를 나타낸다. 증거에 'AreaType'을 포함시켜서 '장소 특성'→'장소'의 추론 성능도 함께 평가하였다. 증거가 적은 경우에는 K2R 방법이 더 좋은 성능을 보이고 있으며, 증거가 많은 경우에는 K2R 방법과 K2 방법이 유사한 성능을 보이고 있다.

적은 수의 증거가 주어진 경우 장소 컨텍스트의 변화를 살펴보기 위해 모든 장소 컨텍스트 확률의 변화를 놓고도 다른 회색으로 표현하였다. 그림 14는 교차 검증을 하지 않고 4개의 증거('Chair', 'AreaSize', 'Brightness', 'AreaType')만을 사용하여 학습과 평가를 한 경우의 결과를 나타낸다. 실험에서 같은 종류의 장소더라도 전혀 다른 장면 형태를 가지고 있는 불연속적인 이미지를 사용하였으며, 장소의 변화를 "주방→로비→사무실→복도→엘리베이터→강의실→거리→공터→광장"으로 정의하였다. 따라서 실험 결과가 색깔이 진한 장소가 올라가는 계단형이 될수록 더 좋은 성능을 나타낸다. 그림

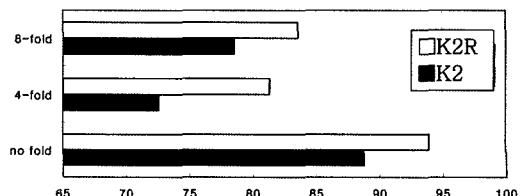
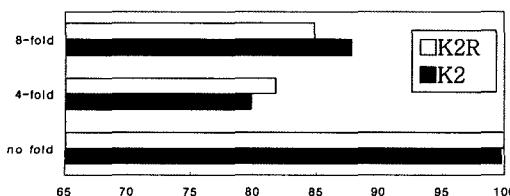


그림 13 실험에 의해 얻은 분류기의 성능 비교 그래프 : 좌측은 증거 4개('Chair', 'AreaSize', 'Brightness', 'AreaType')를 준 경우, 우측은 증거 34개(9개의 장소 노드를 제외한 나머지)를 준 경우의 결과이다.

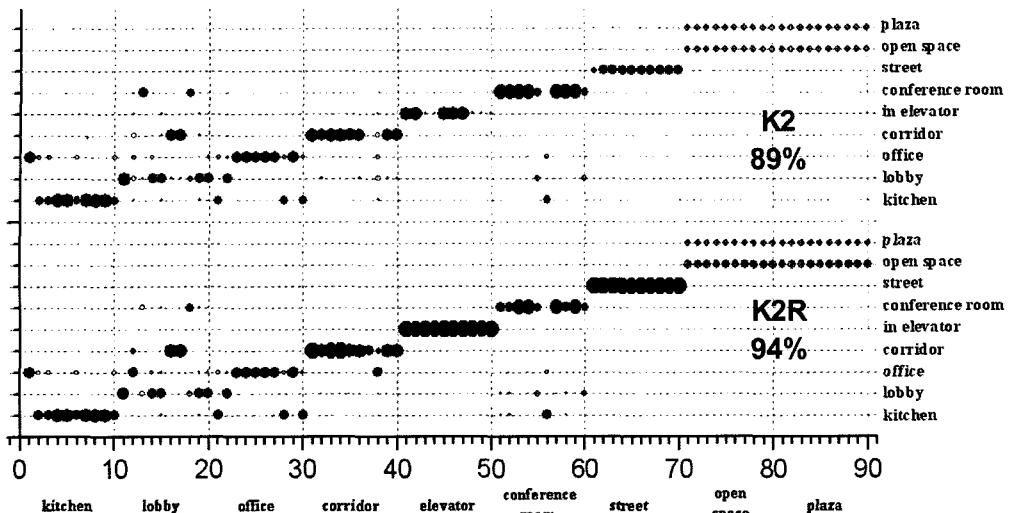


그림 14 장소 이동에 따른 컨텍스트 추론 결과 비교 그래프 : 레이블링 하면서 수집된 실제 장면 영상 분류 실험 결과를 나타낸다.

을 살펴보면 K2R 방법이 더 좋은 분류 결과를 나타내고 있다. 특히, 복도(corridor)와 회의실(conference room)의 성능향상이 두드러진다. 그리고 증거로 실내/실외 특성(AreaType)을 주었기 때문에 실내일 경우에는 광장(Plaza)과 공간(Open space), 거리(Street)의 확률값이 0%이고, 실외인 경우에는 나머지 장소의 확률이 0%인 것이 관찰된다. 이는 주어진 장소 클래스 정보에 의해 각 장소 컨텍스트가 잘 구분되고 있다는 증거를 나타낸다. 실험에서 '공터'와 '거리'는 비슷한 물체를 가지고 있는 장소이기 때문에 상대적으로 성능이 좋지 않게 나왔다.

## 6. 결론 및 토의

본 논문에서는 장면 인식을 수행하기 위한 베이지안 네트워크를 설계할 때 기존의 자동 설계 기법으로는 전문가와 같은 계층적인 설계가 어렵다는 문제를 해결하기 위해 도메인 지식을 이용한 제한된 BN 구조 학습 방법[20]을 체계적으로 제안하고 실험으로 검증하였다. 이를 위해, 도메인 지식을 클래스와 카테고리, 연결 관계로 구성된 온톨로지로 표현한 뒤, level과 predefined link 학습 파라미터로 정의하여 제한 학습을 수행하였다. 계층적으로 잘 설계된 BN의 경우 각 층별로 분류가 이뤄지기 때문에 오류의 확산이 적어서, 증거가 부족한 불확실한 환경에서 더 좋은 분류 성능을 보일 수 있으며, 제한된 부모 도메인 속에서 학습 방법을 사용하기 때문에 계산 복잡도가 줄어든다.

하지만 제안하는 방법에서는 레벨의 제한에 의해 학습 과정에서 무시되는 부모 자식 관계가 있어 성능 저하 가능성이 남아 있다. 따라서 정보 이론에 의한 분석

과 연관 관계가 강인한 변수 쌍에 대해 은닉 노드(Hidden Node)를 추가시키는 방법이 함께 사용된다면 더 좋은 BN 설계가 가능할 것이다. 또한 좀 더 복잡한 도메인 지식을 고려한 학습 기법의 연구가 필요할 것이다.

## 참 고 문 헌

- [1] K. B. Korb and A. E. Nicholson, *Bayesian Artificial Intelligence*, Chapman & Hall/CRC, 2003.
- [2] B. Neumann, *A Conceptual Framework for High-Level Vision*, Bericht, FB Informatik, FBI-HH-B245/03, 2003.
- [3] J. Fernyhough et al., "Building qualitative event models automatically from visual input," *In Proc. ICCV-98*, IEEE Computer Society, pp.350-355, 1998.
- [4] L. R. Biswas, et al., "A probabilistic approach to inference with limited information in sensor networks," *In Proc. of the 3rd Int. Symposium on Information Processing in Sensor Networks*, pp.269-276, 2004.
- [5] P. Spirtes, et al., *Causation, Prediction, and Search (2nd edition)*, MIT Press, Cambridge, 2000.
- [6] N. Friedman and M. Goldszmidt, "Learning Bayesian networks with local structure," M.I. Jordan (eds.), *Learning in Graphical Models*, MIT Press, Cambridge, pp. 421-459, 1999.
- [7] D.M. Chickering, "Learning Bayesian networks is NP-complete," D. Fisher, H.-J. Lenz (eds.), *Learning from Data: Artificial Intelligence and Statistics V*, Springer-Verlag, Berlin Heidelberg New York, pp. 121-130, 1996.
- [8] G. F. Cooper and E. Herskovits, "A Bayesian

- method for the induction of probabilistic networks from data," *Machine Learning*, vol. 9, pp. 309-347, 1992.
- [9] M. L. Wong and K. S. Leung, "An efficient data mining method for learning Bayesian networks using an evolutionary algorithm-based hybrid approach," *IEEE Transactions on Evolutionary Computation*, vol. 8, no. 6, pp. 532-545, Aug. 2004.
- [10] A. Torralba, et al., "Context-based vision system for place and object recognition," *In Proc. of Int. Conf. Computer Vision*, pp.273-280, 2003.
- [11] M. Marengoni, et al., "Decision making and uncertainty management in a 3D reconstruction system," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 25, no.7, pp.852-858, July 2003.
- [12] J. Rissanen, "Modeling by shortest data description," *Automatica*, vol. 14, pp. 465-471, 1978.
- [13] R. R. Bouckaert, "Bayesian belief networks: From inference to construction," Ph.D.Dissertation, Utrecht Univ., Utrecht, The Netherlands, 1995.
- [14] B. G. Buchanan and E. H. Shortliffe, *Rule-based Expert Systems: The MYCIN Experiments of The Stanford Heuristic Programming Project*, Addison-Wesley, Reading, MA, 1984.
- [15] J. Pearl, *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*, Morgan Kaufmann, San Mateo, CA, 1988.
- [16] T. Choudhury et al., "Boosting and structure learning in dynamic Bayesian networks for audio-visual speaker detection," *Proc. of Int. Conf. on Pattern Recognition*, vol. 3, pp. 789-794, Aug. 2002.
- [17] H. Schneiderman, "Learning a restricted Bayesian network for object detection," *In Proc. of IEEE Conf. on Computer Vision and Pattern Recognition*, pp. 639-646, June 2004.
- [18] P. Lucas, "Restricted Bayesian network structure learning," *In Proc. of 14th Belgian-Dutch Conf. on Artificial Intelligence*, pp. 211-218, 2002.
- [19] B. Smith, "Basic concepts of formal ontology," *Formal Ontology in Information Systems*, IOS Press, pp. 19-28, 1998.
- [20] 황금성, 조성배, "효율적인 컨텍스트 분류를 위한 베이지안 네트워크 구조의 제한 학습", 한국정보과학회 가을학술발표논문집, vol. 31, no. 2, pp. 112-114, 2004.

## 조 성 배

정보과학회논문지 : 소프트웨어 및 응용  
제 34 권 제 5 호 참조



황 금 성

2001년 2월 연세대학교 컴퓨터과학과 졸업(학사). 2003년 2월 연세대학교 컴퓨터과학과 졸업(석사). 2004년 3월~현재 연세대학교 컴퓨터과학과 박사과정 재학 중. 관심분야는 전화 알고리즘, 지능형 에이전트, 베이지안 네트워크