

# 효율적인 컨텍스트 분류를 위한 베이지안 네트워크 구조의 제한 학습

황금성<sup>o</sup> 조성배  
연세대학교 컴퓨터학과  
(yellow<sup>o</sup>, sbcho)@cs.yonsei.ac.kr

## Constrained Learning Method of Bayesian Network Structure for Efficient Context Classification

Keum-Sung Hwang<sup>o</sup>, Sung-Bae Cho  
Dept. of Computer Science, Yonsei University

### 요 약

지능형 로봇 에이전트 기술이 발전하면서 서비스 질을 높이기 위한 방법으로 컨텍스트의 활용성이 부각되고 있다. 하지만 컨텍스트 분류 기술들은 아직까지 초기 개발 단계이며 다양한 방법들이 시도되고 있다. 본 논문에서는 전문가의 지식과 학습된 지식을 함께 적용할 수 있고 사람이 그 내용을 이해하기 유리한 베이지안 네트워크(BN)를 이용한 컨텍스트 분류 방법을 제안한다. 일반적인 BN 구조 학습에 사전 지식 및 방향성, 연결 관계 범위를 부여할 수 있는 제한(Constraint)을 적용한 효율적인 컨텍스트 분류 방법을 소개하고, 몇 가지 비교 실험을 통해 기존 방법에 비해 전문가의 개입이 줄어들고 좀 더 신뢰성 있는 컨텍스트 분류기를 얻을 수 있음을 보인다.

### 1. 서론

최근 들어 기술의 발전과 사용자의 요구에 힘입어 로봇의 개발 방향에 큰 변화가 생겼다. 즉, 물리적인 행동 위주의 로봇 개발에서 인간과 같은 지능적인 서비스를 제공하는 로봇에 대한 개발이 활발해진 것이다. 지능형 로봇이란 시각, 청각 등의 센서 데이터를 통하여 외부 정보를 입력받은 뒤 로봇이 스스로 판단하여 마치 인간처럼 적절한 대응을 하는 로봇을 말한다. 이러한 지능형 로봇의 중심에는 상황을 파악하고 추론하여 얻는 컨텍스트(Context)가 있다.

컨텍스트는 사전적 의미로는 문맥이나 환경, 정황 등을 의미한다. 하지만 지능형 로봇 및 에이전트에서 가지는 의미는 '누가 무엇을 어떤 의도를 가지고 어떤 행위를 하였는지'에 대한 정보를 통칭한다. 현재 많은 분야에서 컨텍스트를 추출하기 위한 여러 가지 방법들이 시도되고 있으며 중요한 역할을 하고 있다. Korpipää는 센서 기반 컨텍스트 정보 추출 연구들에 대해 잘 정리하고 있는데[1], 그 내용을 살펴보면, Clarkson 등이 Hidden Markov Model을 이용해 음성 노이즈를 분류했으며, Laerhoeven 등은 Kohonen map, K nearest neighbor classification을 이용하였고, Mäntyjärvi 등은 k-means clustering, PCA, ICA를 이용한 뒤, 베이지안 기법을 제안하여 성능을 개선하였다. 지능형 로봇의 성능과 밀접한 연관성을 가지고 영상인식 시스템 연구에서도 컨텍스트는 분류의 성능을 올리기 위한 중요한 정보로 사용되고 있으며 베이지안 기법을 사용하여 성능 향상을 꾀하고 있다[2,3,4].

하지만 기존 연구에서는 베이지안 네트워크를 전문가가 설계하거나 매우 단순한 경우가 많다. 변화하는 환경에 적응해야 하는 컨텍스트 분류에 있어서 전문가 개입에 의존하는 것은 상당히 번거로운 일이다. 본 논문에서는 이러한 경우 효율적으로 컨텍스트 분류를 할 수 있는 방법을 제안한다. 즉, 적절한 전문가 지식이 반영된 제약(Constraint)을 가하여 자동 학습 단계에서 컨텍스트 분류에 효과적인 베이지안 네트워크 분류기를 획득할 수 있도록 제안하는 것이다.

### 2. 배경

#### 2.1. 베이지안 네트워크

베이지안 네트워크는 변수들 간의 원인과 결과 관계를 확률적으

로 모델링하기 위한 도구로서 불확실한 환경에서 좀 더 신뢰성 있는 결과를 추론하기 위해 쓰이는 대표적인 방법이다. 변수의 확률적 인과관계를 네트워크로 구성한 다음 특정 조건이나 증거가 주어진 경우의 확률, 즉 조건부 확률을 복합적으로 계산하여 결과를 판단하고 분류에 이용한다[5].




그림 1. 간단한 베이지안 네트워크 구조의 예

그림 1은 간단한 베이지안 네트워크의 예를 표현하고 있다. 노드는 변수를, 연결선은 각 변수들 간의 연관성을 나타내고, 연결선은 방향성을 가지고 있어 부모에서 자식으로의 인과관계를 표현한다. 노드의 부모와 확률값이 정해지면 조건부확률 테이블(CPT: conditional probability table)을 가지고 베이지안 규칙(Bayes' Rule)을 이용해 계산을 하게 되는데, 기존 확률 이론에 비해 훨씬 적은양의 계산만으로 확률 추론이 가능하다. 그림1에서 결합 확률값인  $P(x_1, x_2, x_3, x_4, x_5)$ 의 변수 독립성 가정과 체인 규칙을 이용하여 수식 (1)과 같이 계산된다[6].

$$P(x_1, x_2, x_3, x_4, x_5) = P(x_1)P(x_2)P(x_3|x_1, x_2)P(x_4|x_2)P(x_5|x_3, x_4) \quad (1)$$

#### 2.2. 베이지안 네트워크 학습

본 논문에서는 베이지안 네트워크 구조 학습을 위해 Cooper가 제안하였고 현재 가장 널리 사용되고 있는 K2 베이지안 네트워크 구조 학습 기법을 사용하였다[7]. 이 방법은 그림 2에서 회색박스를 제외한 부분과 같은 순서로 진행되면서 높은 K2 metric 값(그림 2의  $g(\cdot)$ )을 만족하는 구조를 탐욕적으로 찾는다. 이때 노드의 순서는 네트워크의 구조를 결정짓는 중요한 파라미터로 간주된다.

```

BEGIN ConstrainedK2
  sort nodes 1-n by level
  FOR i:=1 TO n DO
  BEGIN
     $\Pi_i := 0$ ;
     $\Pi_i := \text{predefined parents}$ 
     $P_{old} := g(i, \Pi_i)$ ;
    OKToProceed := TRUE
    WHILE OKToProceed AND  $|\Pi_i| < \mu$  DO
    BEGIN
      Let Z be the node in  $\text{Pred}(X_i) - \Pi_i$  that
      maximizes  $g(i, \Pi_i \cup \{Z\})$ 
      and  $0 \leq \text{level}(Z) - \text{level}(i) < 2$ ;
       $P_{new} := g(i, \Pi_i \cup \{Z\})$ ;
      IF  $P_{new} > P_{old}$  THEN
      BEGIN
         $P_{old} := P_{new}$ ;
         $\Pi_i := \Pi_i \cup \{Z\}$ 
      END
      ELSE OKToProceed := FALSE;
    END;
    WRITE( 'Node:',  $X_i$ , 'Parents of this node:',  $\Pi_i$  )
  END;
  FOR i:= each of all the nodes that
  have parent with same level
  BEGIN
    z = current parent with same level
    z' = shortest indirect parent;
     $\Pi_i := \Pi_i \cup z' - z$ 
  END;
END ConstrainedK2.
  
```

그림 2. K2 베이저안 구조 학습 방법 및 제한한 알고리즘 여기서 사용된 함수들의 수식은 그림 3에 나타나 있다[7].

- $N_{ijk}$ : number of cases in D in which variable  $X_i$  has the value  $v_{jk}$  and  $\Pi_i$  is instantiated as  $w_{ij}$
- $w_{ij}$ :  $j$ th unique instantiation of  $\Pi_i$  relative to D
- $(v_{j1}, \dots, v_{jm})$ : Possible value assignments

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

그림 3. K2 베이저안 구조 학습에서 사용되는 수식

2.3. 베이저안 네트워크를 이용한 컨텍스트 분류

베이저안 네트워크를 이용하여 정보를 분류하고 컨텍스트를 추출하는 과정은 그림4와 같다. 먼저 환경에 대한 학습 데이터를 수집하고, 이를 이용하여 베이저안 네트워크 구조를 학습한 다음 파라미터를 학습하고, 마지막으로 컨텍스트 인과 관계를 수정하는 과정을 거친다.




그림 4. 베이저안 네트워크 컨텍스트 분류기를 얻는 과정

이와 같은 일반적인 베이저안 네트워크 학습 기법에서는 컨텍스트 분류와 관련된 특성 고려는 하지 않기 때문에 원인 노드와 결과 노드가 바뀌거나, 이미 알고 있는 연결이 빠질 수 있다. 또한 학습 데이터에 과적응(overfitting)되어 필요 없는 연결 관계에 의해 올바른 추론을 방해할 수 있다. 이때 전문가에 의해 수정될 수 있는 네

용은 다음 3가지가 있다. 첫 번째, 원인 노드와 결과 노드 사이의 방향을 알고 있는 정보대로 수정한다. 두 번째, 원인 노드에서 원인노드2를 거쳐서 결과노드로 연결된 경우 직접 원인노드에서 결과노드로 연결되도록 수정한다. 세 번째, 이미 알고 있는 연결이 빠진 경우 연결선을 추가한다. 이와 같은 수정 과정을 거치지 않기 위해 일반적으로는 사람이 직접 설계한 베이저안 네트워크를 사용한다.

3. 베이저안 네트워크의 제한된 구조 학습 방법 제안

전문가의 복잡한 개입이나 설계 없이 베이저안 네트워크의 자동 학습을 통해 컨텍스트 분류기를 얻기 위해 2가지의 사전 지식을 정의하여 그림 5와 같은 순서대로 진행하였다. 첫 번째는 변수의 레벨이다. 컨텍스트 정보는 그 개념과 용도에 따라 수준의 차이를 가지고 있는데, 예를 들어, 센서 정보는 하위 수준, 센서의 해석은 상위 수준의 변수를 나타낸다. 따라서 수준의 정의를 통해 추론의 흐름이 일정한 방향으로 유지되도록 제한하는 것이 가능하다. 두 번째는 사전 정의된 연결의 적용이다. K2 학습은 초기에 연결이 없는 상태에서 시작하는 것이 일반적이지만 이미 일부가 연결된 구조에서도 알고리즘 수행이 가능하다.




그림 5. 제한된 베이저안 네트워크 구조 학습 과정

그림 5에서 사용되는 제한된 K2 학습은 표1과 같은 과정을 통해 수행된다. 즉, 레벨에 의한 부모 제한을 적용하기 위해 K2 알고리즘에 들어가는 변수의 순서를 바꾸고, 레벨 차이가 큰 관계는 허락하지 않으며, 레벨 차이가 작은 경우 간접 부모를 직접 찾아 연결해 줌으로써 컨텍스트 특징이 반영된 BN 구조를 유도하는 것이다.

- 표 1. 제한된 K2 학습 방법
1. 레벨을 기준으로 변수의 순서 정렬 (크기 내림차순, 같은 레벨은 초기 순서대로 유지)
  2. K2 구조 학습 (레벨차이가 2보다 작은 연결만 허용)
  3. 레벨 차이가 0인 연결은 레벨 차이가 1인 간접 부모를 찾아 그 변수와의 연결로 수정

그림 5와 6에서 추가된 학습 과정은 그림 2에 박스 안에 기술되어 있다.

4. 실험 및 결과

4.1. 실험 환경

실험에 사용된 구조 학습 방법은 앞서 소개한 K2 학습 방법이며, 부모의 수 제한 옵션은 10으로 두었다. 실험에 사용한 데이터는 각기 9종류 90개의 다른 장소의 영상 정보(그림 6)에서 구한 33개의 개체의 많고 적은 정보를 사용하였다. 그림 6은 수집된 데이터를 그 정도에 따라 회색으로 표현한 결과이다. 그림 7에서 아래쪽 10개의 데이터는 분류 항목이다. 9개의 장소와 실내/실외의 구분을 나타낸다. 여기서 변수 AreaType은 레벨 2이고, 변수 plaza, lobby, kitchen, corridor, in\_elevator, curtain, office, conference\_room, open\_space, street는 레벨 1을 가지며, 나머지 변수는 모두 레벨 0이다.



그림 6. 데이터 수집에 사용된 영상 정보의 예




그림 7. 90개의 장소에서 수집한 개체 정보 데이터

실험에서는 기존 K2 학습 방법을 랜덤 순서로 실행한 경우 (K2R), 제안한 학습 방법과 같은 순서를 적용한 경우(K2C)로 나누어, 제안한 방법(CoK)과 비교하였다.

4.2. 분류 성능 비교

그림8은 실험을 통해 얻은 페이지안 네트워크를 최상위 노드를 기준으로 도달 거리에 따라 트리방식으로 나타낸 것이다. 기존 K2 방법(K2R)은 레벨에 따른 변수 분포가 무작위적이지만, 제안한 방법(CoK)은 레벨에 따라 규칙성을 보여서 확률 관계를 사람이 이해하는데 도움이 된다. K2C도 어느 정도 규칙성을 보이고 있다. CoK는 CoK에서 레벨차이가 0인 연결을 허용한 경우(표1의 규칙3 미적용)인데 입력정보가 상호 연관성이 많을 때 유용하므로 함께 비교하였다.




그림 8. 실험에 의해 얻은 페이지안 네트워크 구조

그림 9는 cross-validation으로 얻은 컨텍스트 분류기의 분류 성능을 비교하여 표현한 것이다.




그림 9. 실험에 의해 얻은 분류기의 성능 비교 그래프

1-fold-cross-validation은 실험세트와 평가세트를 동일한 것을 사용한 결과이다. 결과는 아무런 제약을 가하지 않은 K2R이 전체적으

로는 좋은 성능을 보였다. 하지만 4-fold의 경우에는 제안한 방법이 더 좋은 성능을 보여서 레벨과 사전지식이 반영된 BN이 좀 더 일반화된 성능을 보일 수도 있음을 알 수 있다. 2-fold의 경우 CoK가 안 좋은 성능을 보였는데 레벨0의 데이터의 상호 연관성을 무시한 결과로 보인다.

4.3. 새로운 환경에서의 분류 성능 비교

그림 10을 보면 기존 학습 방법이 좋아 보이지만 이것은 적은 수 (90개)의 학습 데이터에 잘 맞도록 과적응되었기 때문이다. 좀 더 일반적인 분류 성능을 비교하기 위해 2개의 증거만 주고 확률 분포를 살펴보았다. 그림 10은 AreaType='Opened'와 Bench='a\_little' 증거만 넣은 경우 분류 결과를 50%를 기준으로 비교한 도표이다. K2R을 제외하고는 가장 가까운 장소인 plaza에 대한 확률이 가장 높다. 이는 K2R을 제외하고는 레벨에 의한 계층화로 인해 분류기가 잘 일반화되었기 때문이다.




그림 10. 증거 AreaType='Opened', Bench='a\_little'를 주었을 때 장소 변수의 확률 분포

5. 결론 및 토의

본 논문에서는 페이지안 네트워크를 이용한 컨텍스트 추출을 위한 방법으로 Constrained k2 학습 방법을 제안하였다. 이 방법은 기존의 불규칙한 구조 생성 규칙에 몇 가지 제한(Constraint)을 주어 방향과 레벨 등의 사전지식을 고려하도록 한 방법으로써, 전문가의 개입을 최소화하면서도 컨텍스트 분류에 적합한 구조의 페이지안 네트워크를 자동 학습으로 얻을 수 있고 상황 변화에 좀 더 유연한 성능을 보였다. 또한 사람이 이해하기에 유리한 구조를 보여서 분류기의 수정 및 분석에 유용하였다.

향후에는 좀 더 데이터가 풍부하고 복잡한 페이지안 네트워크에서의 제한 학습을 실험하고, 동레벨 변수 간 순서 및 연결에 대한 연구를 할 생각이다. 또한 다양한 페이지안 학습 기법과의 조합에 대한 연구도 필요할 것으로 보인다.

6. 참고문헌

- [1] Panu Korpipää, Miika Koskinen, Johannes Peltola, Satu-Marja Ma kela, Tapio Seppänen, "Bayesian approach to sensor-based context awareness," *Personal and Ubiquitous Computing archive*, vol. 7, pp.113-124, July 2003.
- [2] T. Stamer, et al., "Visual contextual awareness in wearable computing," *Proc. of the International Symposium on Wearable Computing (ISWC'98)*, Pittsburgh, pp. 50-57, October 1998.
- [3] T. M. Strat and M. A. Fischler, "Context-based vision: Recognizing objects using information from both 2-D and 3-D imagery," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 13, no. 10, pp. 1050-1065, 1991.
- [4] Antonio Torralba, et al., "Context-based vision system for place and object recognition," *int. conf. computer vision*, 2003.
- [5] F. Cantu, "Learning and using Bayesian networks for diagnosis and user profiling," *Technical Report CIA-RI-043, Center for Artificial Intelligence, ITESM*. Invited talk at the Computing International Conference, CIC-IPN, November, 2000.
- [6] T. Stephenson, "An introduction to Bayesian network theory and usage," *IDIA-RR 00-03*, 2000.
- [7] Gregory F. Cooper and Edward Herskovits, "A Bayesian method for the induction of probabilistic networks from data," *Machine Learning*, vol. 9, pp. 309-347, 1992.