

대화기반 사용자 피드백을 이용한 베이지안 네트워크 파라미터 학습

임성수 이승현 조성배

연세대학교 컴퓨터과학과

{lss, e2sh83}@sclab.yonsei.ac.kr, sbcho@cs.yonsei.ac.kr

Learning Bayesian Network Parameters using Dialogue based User Feedbacks

Sungsoo Lim, Seung-Hyun Lee, Sung-Bae Cho

Dept. of Computer Science, Yonsei University

요 약

사용자와 환경의 변화에 적응하기 위해서 베이지안 네트워크의 다양한 학습 방법들이 연구되고 있다. 기존의 많은 학습방법에서는 학습 데이터로부터 통계적 방법을 통해서 베이지안 네트워크 모델을 학습하는데, 이러한 접근 방법은 학습 데이터를 수집하기 어려운 문제에 적용하기 힘들며, 사용자의 의도를 데이터의 패턴들만으로 학습하므로 직접적으로 사용자의 의도를 반영할 수 없다. 본 논문에서는 대화에 기반하여 사용자의 의도를 직접적으로 수집하고, 이로부터 베이지안 네트워크의 파라미터를 학습하는 방법을 연구한다. 제안하는 방법에서는 사용자와의 대화를 통해서 현재의 모델의 잘못된 점 혹은 개선점을 직접적으로 입력 받고, 이를 바탕으로 베이지안 네트워크 모델을 수정하여 데이터의 수집 없이 빠른 시간에 사용자가 원하는 모델을 학습 할 수 있다. 기존의 통계적 기법을 이용한 대표적인 베이지안 네트워크 파라미터 학습 방법인 최대우도 추정(Maximum Likelihood Estimation; MLE) 방법과 제안하는 방법을 비교하여 제안하는 방법의 유용성을 확인한다.

1. 서 론

현실 세계의 응용 어플리케이션 환경은 시간이 지남에 따라서 변화하며 정확한 관측이 어려워 많은 불확실성을 포함한다. 최근 이러한 동적이고 불확실한 환경을 극복하기 위한 방법 중 하나로 베이지안 네트워크(Bayesian Network: BN)가 부각되고 있다[1]. BN은 방향성 비순환 그래프(Direct Acyclic Graph: DAG)로 각각의 노드는 확률 변수를 나타내고 각 노드를 연결하는 화살표는 변수들간의 인과관계를 표현한다.

보통 BN은 전문가의 지식을 바탕으로 설계된다. 이 방법은 전문가의 경험을 직접적으로 네트워크에 반영할 수 있는 장점이 있지만, 네트워크의 규모가 커지면 설계에 많은 시간이 들어가고 네트워크의 정확성을 보장할 수 없다. 따라서 사람이 직접 네트워크를 설계하기 보다는 데이터로부터 통계적으로 BN을 설계하는 방법이 연구되었다[2,3,4]. 만일 학습할 데이터가 완전하고 충분하게 준비되어 있다면 최대우도 추정(Maximum Likelihood Estimation: MLE) 방법을 이용하면 데이터에 적절한 네트워크에서 노드들의 조건부 확률 테이블(Conditional Probability Table: CPT)을 얻을 수 있다. 그러나 실제로 많은 문제에서는 완전한 데이터를 얻기 어렵다. 과거 몇 년간 이러한

데이터의 불완전함을 극복하기 위해서 순차적 학습, EM 알고리즘, Gibbs 샘플링 등이 연구되어 왔다[5,6]. 하지만 현실 문제에서는 학습을 위해서 필요한 데이터의 수가 충분하지 않은 경우가 종종 발생하며, 학습 데이터가 충분하다고 하더라도, 시간의 흐름에 따라서 데이터의 분포가 변화할 수 있다.

본 논문에서는 대화기반 사용자 피드백을 이용한 베이지안 네트워크 파라미터 학습 방법을 제안한다. 제안하는 방법에서는 대화를 통해서 사용자의 피드백을 얻고, 이로부터 생산 규칙(production rule)을 생성한다. 그리고 이렇게 생성된 생산 규칙을 BN 파라미터에 반영함으로써, 학습 데이터 없이 사용자의 의도를 직접적으로 BN 파라미터에 반영한다.

2. 대화기반 사용자 피드백을 이용한 베이지안 네트워크 파라미터 학습

2.1 대화를 이용한 생산 규칙 생성

사용자는 자신이 원하는 결과대로 시스템이 동작하지 않은 경우 간단한 대화를 통해 시스템에 정보를 제공할 수 있다. 대화형 에이전트는 사용자의 피드백 속에 담긴 의미정보를 추출하고 이로부터 규칙을 학습하게 된다. 하지만 자연어 형태의 사용자 피드백으로부터 의미정보를 추출하는 것은 쉬운 일이 아니다. 본

논문에서는 사용자의 대화로부터 정보를 추출하고 관리하기 위한 방법으로 표 1과 같은 BNF 기반 언어를 제안한다.

언어 모델은 의미단위의 심볼과 심볼간의 관계를 정의하는 생산 규칙으로 구성된다. 심볼은 각기 고유한 값을 가지며, 어떠한 두 심볼도 같은 의미를 가지지 않는다. 한편 생산 규칙은 정의된 심볼집합 중에서 입력 심볼의 패턴과 이들이 의미하는 대체하는 상위수준의 결과 심볼로 구성된다.

표 1. 제안하는 BNF 기반 언어구조

Non-terminal	Predicates
<Production-rule-description>	::= IF <Pattern> THEN <Response>
<Pattern>	::= <Symbol-sequence> ⁺
<Symbol-sequence>	::= <Single-symbol> not <Symbol-sequence> (<Sequential-symbols>) (<Simultaneous-symbols>) (<Domain-specific-symbols>)
<Sequential-symbols>	::= <Single-symbol> then <Symbol-sequence>
<Simultaneous-symbols>	::= <Single-symbol> and <Symbol-sequence> <Single-symbol> or <Symbol-sequence>
<Domain-specific-symbols>	::= <Single-symbol> <Domain-specific-operator> <Symbol-sequence>
<Single-symbol>	::= <Value> null
<Value>	::= Symbol-name Domain-specific-characteristic
<Domain-specific-operator>	::= Domain-specific-operator-name
<Response>	::= <Single-symbol> ⁺

입력 심볼의 패턴은 의미 심볼간의 순차적 또는 동시적인 관계를 표현한다. 순차적 심볼은 입력 심볼들간에 시간적인 선후에 의미를 가지는 경우에 적용되며, 동시적 심볼은 같은 시간에 병렬적으로 발생하는 의미 심볼을 모델링한다. 입력심볼과 출력심볼의 관계를 나타내는 생산 규칙은 사용자의 대화로부터 인식한 도메인 관련 정보를 담는다. 다양한 도메인에 적용 하기 위해, 생산 규칙 뿐만 아니라 연산 등을 자유롭게 추가할 수 있도록 하였다.

사용자 대화의 의미 정보는 생산 규칙으로 표현되기 때문에, 자연어로부터 생산 규칙을 표현하기 위한 학습 방법이 필요하다. 이를 위해 제안하는 방법에서는 사용자의 단어를 심볼로 매핑하고, 'and' 와 'or' 같은

명령어는 미리 정의된 템플릿에 적용하는 방법으로 모델링한다. 즉, 사용자의 피드백 Q 는 의미를 가지는 단어의 집합 $W = \{w_1, w_2, \dots, w_n\}$ 으로 쪼개지고, 해당 패턴 W 를 템플릿과 비교하여 학습하는 것이다. 이를 위해 다음 표 2와 같이 학습을 위한 템플릿을 정의한다.

표 2. 생산 규칙 생성위한 템플릿 정의

T1	IF \$symbol ₁ 'is' \$symbol ₂ 'and' \$symbol ₃ THEN $F_{rule}(F_{and}(\$symbol_2, \$symbol_3), \$symbol_1)$ → IF (\$symbol ₂ and \$symbol ₃) THEN \$symbol ₁
T2	IF \$symbol ₁ 'is a sequence of' \$symbol ₂ 'and' \$symbol ₃ THEN $F_{rule}(F_{then}(\$symbol_2, \$symbol_3), \$symbol_1)$ → IF (\$symbol ₂ then \$symbol ₃) THEN \$symbol ₁
T3	IF 'if' \$symbol ₂ 'is occurred after' \$symbol ₃ 'then' \$symbol ₁ 'is activated' THEN $F_{rule}(F_{then}(\$symbol_2, \$symbol_3), \$symbol_1)$ → IF (\$symbol ₃ then \$symbol ₂) THEN \$symbol ₁
T4	IF \$symbol ₁ 'is true if' \$symbol ₂ 'is false' THEN $F_{rule}(F_{not}(\$symbol_2), \$symbol_1)$ → IF (not \$symbol ₂) THEN \$symbol ₁
T5	IF \$symbol ₁ 'is the sum of' \$symbol ₂ 'and' \$symbol ₃ THEN $F_{rule}(F_{specific}(\$symbol_2, \$symbol_3), \$symbol_1)$ → IF (\$symbol ₂ sum \$symbol ₃) THEN \$symbol ₁
T6	IF 'if a person' \$symbol ₂ 'then' \$symbol ₃ ', she/he' \$symbol ₁ THEN $F_{rule}(F_{then}(\$symbol_2, \$symbol_3), \$symbol_1)$ → IF (\$symbol ₂ then \$symbol ₃) THEN \$symbol ₁

2.2 생산 규칙을 이용한 BN 파라미터 학습

본 논문에서는 생산 규칙으로부터 BN 파라미터를 생성할 때, 문제를 보다 쉽게 하기 위해서 다음과 같은 제약조건을 둔다. 첫째, BN의 각 노드는 최대 두 개의 상태 값을 갖는다. 만일 노드 x 가 n ($n > 2$) 개의 상태 값 s_1, s_2, \dots, s_n 을 갖는다면, True/False 값을 갖는 n 개의 노드로 분할하여 사용한다. 즉, $x=s_2$ 이라고 하면, $x_{s1}=false, x_{s2}=true, \dots, x_{s3}=false$ 와 같이 표현하면 동일한 표현이 가능하다. 둘째, BN의 구조는 알려져 있다. 만일 사용자가 'x=a 이면 y=b이다'라는 생산 규칙을 생성하였다면, BN 구조에서 노드 x 에서 y 로의 아크가 존재하거나, 노드 y 에서 x 로의 아크가 존재한다.

제안하는 방법은 이러한 두 가정을 바탕으로, 2.1절에서 생성된 생성한 생산 규칙을 바탕으로 BN 파라미터를 학습한다. BN 파라미터 학습 과정은 크게 세 부분으로 구성된다. 첫째, 노드 x 에 대한 Markov blanket M_x 를 찾는다. 둘째, 해당 M_x 와 노드 x 로 이루어진 BN의 부분집합에서 생산 규칙을 모두 만족하는 진리표를 구성한다. 마지막으로, 구성된 진리표를 바탕으로 BN의 파라미터를 설정한다.

노드 x 에 대한 Markov blanket M_x 는 노드 x 의

부모노드, 자식노드, 그리고 자식들의 다른 부모노드로 구성된 노드들의 집합이다. M_x 에 있는 노드들이 BN의 증거로 주어졌을 때, BN에 있는 모든 노드들은 노드 x 와 조건부 독립이 된다($P(x | M_x, y) = P(x | M_x)$). 이러한 특징에 의해서 BN의 근사계산을 할 때, Markov blanket이 종종 이용되는데, 본 논문에서도 하나의 BN에 대한 진리표를 생성할 때, 진리표의 크기가 기하급수적으로 커지는 것을 방지하기 위해서 Markov blanket을 이용한다.

노드 x 에 대한 Markov blanket을 M_x 를 구한 후, 생산 규칙에 맞는 진리표를 구한다. 진리표를 구하기 위해서 각 생산 규칙과 그 규칙의 대우 명제를 이용한다. 진리표의 값에서 생산 규칙의 명제 및 대우 명제가 가참이 되는 경우는 'T'로 명시하며, 거짓이 되는 경우는 'F'로 명시하고, 상관 없는 경우는 'X'로 명시한다. 표 3은 'x=T 이면 y=T이다'라는 생산 규칙으로부터 생성된 진리표를 보여준다.

표 3. 진리표

x	y	$x=1 \rightarrow y=1$
F	F	T
F	T	X
T	F	F
T	T	T

노드 x, y 가 모두 T의 값을 갖는 경우, 제시된 명제를 만족하며, 모두 F의 값을 갖는 경우는 제시된 명제의 대우 명제를 만족하므로 진리표에서 T로 명시하고, x 가 T일 때, y 가 F인 경우는 제시된 명제를 만족하지 않으므로 F로 명시한다. 그리고 x 가 F일 때, y 가 T인 경우는 해당 사항이 없으므로 X로 명시한다.

이렇게 얻어진 진리표는 최종적으로 BN의 조건부 확률 테이블 값을 얻기 위해서 다시 분포표로 변환이 되는데, 본 논문에서는 생산 규칙의 신뢰도를 a ($0 < a < 1$) 라고 하면, 진리표에서 T로 명시된 값에는 a 를 할당하고, F는 $1-a$ 를 할당하며, X의 경우는 확률의 중간 값인 0.5를 할당한다. 따라서 a 값이 0.9인 경우, 표 3의 진리표로부터 표 4와 같은 분포표를 얻을 수 있다.

표 4. 분포표

x	y	Distribution
F	F	0.9
F	T	0.5
T	F	0.1
T	T	0.9

이 분포표를 이용하여 최종적으로 BN 파라미터 값을 얻는다. $D(x,y)$ 를 분포표의 값이라고 하면, $P(x=T | y=T)$ 의 확률값은 아래와 같이 얻는다.

$$P(x=T | y=T) = D(x=T, y=T) / (D(x=T, y=T) + D(x=F, y=T)) = 0.9 / (0.9 + 0.5) \approx 0.64286$$

3. 실험 및 결과

실험은 스마트 홈 환경을 도메인으로 크게 세 가지 학습 방법을 비교하는 방법으로 구성하였다. 첫 번째는 데이터 기반 학습 방법(algorithm 1)만을 적용한 경우, 나머지는 대화학습과 데이터 기반 학습 방법을 적용하여 학습률을 고정한 경우(algorithm 2)와 수집 데이터의 수에 따라 조정된 경우(algorithm 3)으로 나뉜다. 각 알고리즘을 그림 1과 같은 집안 관리 에이전트의 상황인지를 위한 BN에 적용하였다. 집안 내의 온도 조절을 위한 가전기와 창문, 날씨 등의 관계를 모델링한다.




그림 1. 집안관리 에이전트의 상황인지 BN모델

실험은 가상의 집안 환경에서 가능한 상황정보 2000개를 생성하여 진행하였다. 그 중 1000개는 데이터 학습에 사용되었으며, 나머지는 정확도 실험을 위해 사용하였다. 학습한 BN의 정확도는 학습한 BN의 사후 결과 값과 데이터 셋의 타겟 노드의 추론결과를 비교함으로써 계산하였다.

대화를 통한 학습을 위해 다음 표 5와 같은 사용자 대화 입력을 설정하였다. 각각의 입력은 사용자가 실내에서 온도와 관련하여 발생할 수 있는 상황의 대화를 표현한다. 대화 입력은 앞서 설명된 템플릿을 통해 학습된다. 본 실험에서는 편의를 위해 한 시점에 일괄적으로 적용된다고 가정하였다. 예를 들어 각 알고리즘에서 대화학습을 통한 BN 파라미터의 조정은 데이터가 50, 100, 200, 300, 그리고 400개가 각각 주어졌을 때 일어난다.

표 5. 자연어 형태의 사용자 대화 입력

상황	사용자 대화 입력
C1	밖은 날씨 좋던데 안은 너무 덥구나. 창문 열자.
C2	오늘 너무 더워서 견딜 수가 없다. 에어컨 켜자.
C3	오늘 날씨가 꽤 춥다. 창문 닫자.
C4	안에 좀 추운 것 같구나. 창문 닫자
C5	에어컨 켜으니 창문 다 닫자.
C6	오늘 비바람이 심하구나. 창문을 좀 닫자.

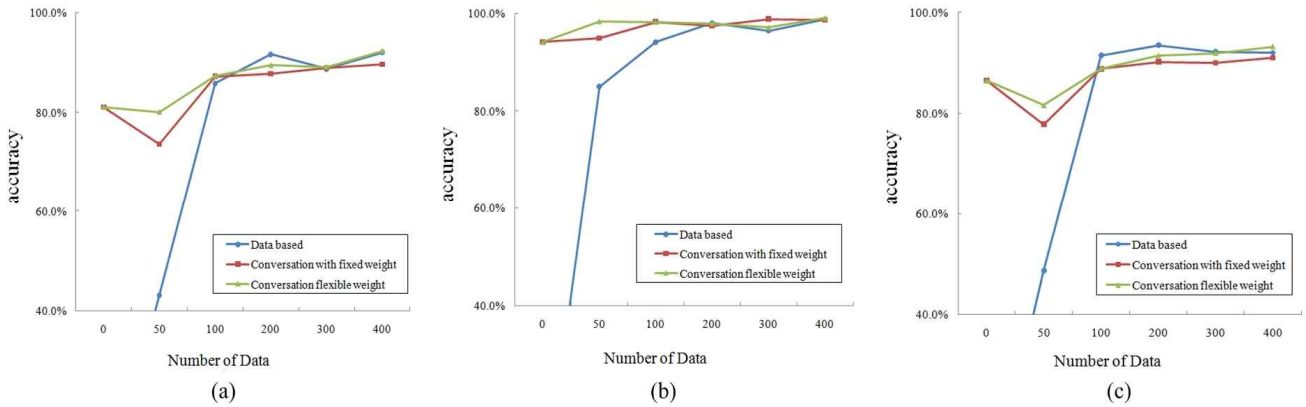


그림 2. 데이터 수에 따른 추론 정확도 변화

각 알고리즘에 대한 학습 결과는 그림 2와 같다. 세 학습 방법 모두 수집한 데이터의 양이 누적될 수록 환경에 잘 적응하는 경향을 보였다. 하지만 초기 학습률에 있어 대화 학습과 데이터 기반 학습 방법에 있어 큰 차이를 보였다. 대화 학습에서는 사용자의 간단한 피드백을 통해 빠른 시스템 안정이 있었던 반면, 데이터가 적은 경우에는 도메인을 적절히 반영하지 못하였다. 이는 데이터 기반 학습 방법의 선천적인 한계이며, 전문가에 비의존적인 방법인 사용자와의 대화를 통해 적은 노력으로 빠른 학습을 이뤄낼 수 있음을 보여준다.

뿐만 아니라 그림 2에 따르면 대화기반 학습은 데이터가 많이 수집된 이후에도 보다 정확한 결과를 보여주었다. 이는 대화기반 학습 방법이 시스템 초기의 안정화뿐만 아니라 안정적인 시스템의 유지에도 효율적이라는 것을 입증한다. 이러한 결과는 다음 표 6에 의해서도 입증된다. 데이터 기반 학습은 초기의 낮은 학습률 등으로 인해 낮은 추론 정확도를 보여주었지만, 대화를 통한 학습을 같이 적용한 경우 정확도가 크게 향상됨을 확인할 수 있다. 마지막으로 대화 학습을 병행함에 있어 학습률의 조절은 중요한 문제임을 보여준다.

표 6. 전체 추론 정확도

학습 알고리즘	창문	에어컨	전체
데이터 기반학습	69.7%	78.7%	66.9%
대화+데이터(고정 학습률)	87.4%	97.0%	84.7%
대화+데이터(변동 학습률)	88.9%	97.4%	86.5%

4. 결론 및 향후 연구

본 논문에서는 대화에 기반하여 사용자의 의도를 직접적으로 수집하고, 이로부터 베이지안 네트워크의 파라미터를 학습하는 방법을 제안했다. 제안하는 방법에서는 사용자와의 대화를 통해서 사용자의 의도를 직접적으로 반영할 수 있는 생산 규칙을 생성하고, 이를 바탕으로 베이지안 네트워크 모델을 수정하여 데이터의

수집 없이 빠른 시간에 사용자가 원하는 모델을 학습할 수 있다.

향후에는 BN 파라미터 뿐만 아니라 BN 구조도 대화기반 학습 방법으로 빠르게 학습할 수 있는 방법이 필요하며, 학습을 쉽게 하기 위해서 적용하였던 BN의 각 노드에 구조적 제한이 없는 상황에서도 학습이 가능하도록 하는 방법이 필요하다.

감사의 글

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단-신기술융합형 성장동력사업의 지원을 받아 수행된 연구임(No. 2009-0093676).

참고문헌

- [1] D. Heckeman, "Bayesian networks for data mining," *Data Mining and Knowledge Discovery*, vol. 1, pp. 79~119, 1997.
- [2] H.G. Cooper and E. Herskovitz, "A Bayesian method for the induction of probabilistic networks from data," *Machine Learning*, vol. 9, pp. 159~225, 1994.
- [3] W. L. Bunine, "Operations for learning with graphical models," *Journal of Artificial Intelligence Research*, vol. 2, pp. 159~225, 1994.
- [4] D. Heckerman, D. Geiger and D.M. Chickering, "Learning Bayesian networks: The combinations of knowledge and statistical data," *Machine Learning*, vol. 20, pp. 197~243, 1995.
- [5] R.G. Cowell, A.P. Dawid and P. Sebastiani, "A comparison of sequential learning methods for incomplete data," *In Bayesian Statistics*, vol. 5, pp. 533~542, 1996.
- [6] A. Dempster, D. Laird and D. Rubin, "Maximum likelihood from incomplete data via the EM algorithm," *Journal of the Royal Statistical Society, Series B*, vol. 39, pp. 1~38, 1977.