

# 개인화된 High Level Context 추출을 위한

## 퍼지 변수의 베이지안 추론

유지오<sup>0</sup> 김경중 조성배  
연세대학교 컴퓨터과학과

{taiji391<sup>0</sup>, uribyul}@sclab.yonsei.ac.kr, sbcho@cs.yonsei.ac.kr

### Bayesian Inference with Fuzzy Variables for Customized High Level Context Extraction

Ji-Oh Yoo<sup>0</sup>, Kyung-Joong Kim, Sung-Bae Cho  
Dept. of Computer Science, Yonsei University

#### 요 약

인간과 인간 사이에 컨텍스트의 역할이 중요한 것처럼 기계가 컨텍스트를 인식할 수 있는 능력을 갖는 것은 중요하다. 특히 지능적인 서비스를 제공하기 위해서는 고수준 컨텍스트를 추출하는 것이 필요하고, 최근 베이지안 네트워크를 이용해 컨텍스트를 추출하려는 연구가 많이 있었다. 그러나 대부분은 단순한 컨텍스트를 추출하는 연구들이고, 상황이나 사용자에 따라 다른 특성을 보이는 경우에 대한 처리는 하지 못하고 있다. 본 논문은 퍼지 소속 함수를 통해 각 센서에서 오는 정보를 전 처리하고, 이를 베이지안 네트워크를 이용해 고수준 컨텍스트로 추출하는 방법을 제안한다. 특히 여러 개의 퍼지 노드가 있을 경우 퍼지 소속값의 곱을 사용하여 베이지안 추론에 적용하였다. 각 센서의 정보를 처리하는 퍼지 소속 함수는 사용자가 쉽게 설계할 수 있고, 컨텍스트 추출 모듈과 별개로 설계가 가능하기 때문에 베이지안 네트워크의 유연하고 적응적인 특성을 유지하면서 개인화가 가능하다. 제안한 방법의 유용성을 보이기 위해 실제 세계의 문제를 모델링한 베이지안 네트워크의 예를 보이고 이를 분석한다.

#### 1. 서 론

인간과 인간의 상호 작용은 명시적인 정보 이외에 상대방의 표정이나 동작, 주변 상황 등 암시적인 정보를 통해 더욱 견고하고 효과적으로 이루어진다. 이와 같이 명시적으로 알려주지 않아도 상호 작용 과정에서 발생하는 개체, 장소, 상황에 대한 암묵적인 정보를 컨텍스트(Context)라고 정의할 수 있다. 기계에 인공적인 지능을 심어주려는 연구는 컴퓨터가 발명된 이래 오랜 기간 연구되어 왔지만, 기계와 인간과의 상호 작용에서 컨텍스트가 활용되는 연구는 최근에야 시작되고 있다. 이는 기계가 인간처럼 컨텍스트를 인식하고 추출하기 어렵기 때문이다. 그럼에도 불구하고 기계가 인간과 상호 작용을 하고 효율적이면서 정확한 서비스를 제공하기 위해서는 컨텍스트 인식 및 추출이 중요하다.

특히 더 지능적인 서비스를 제공하기 위해서는 사용자에게 맞는 고수준(High Level)의 컨텍스트를 추출하는 것이 필요하다. 그러나 기존의 컨텍스트 관련 연구는 naïve 베이지안 네트워크 등을 이용하여 센서 레벨에서의 불확실한 데이터를 처리하는 단순한 컨텍스트 추출 연구가 대부분이고, 좀 더 상위 수준의 컨텍스트 추출 연구는 최근에야 시작되고 있다[1]. 또한 사용자의 다양한 특성과 불확실한 환경에 적용하기 위한 컨텍스트 모델이 필요한데, 이에 대한 연구도 시작 단계에 있다.

본 논문에서는 퍼지 소속 함수를 통해 각 센서에서 오는 정보를 전 처리하고, 이를 베이지안 네트워크를 이용해 고수준 컨텍스트로 추출하는 방법을 제안한다. 각 센서에서 들어오는 값을 기호적인 표현으로 처리하는 퍼지 소속 함수는 사용자가 쉽게 설계할 수 있고, 컨텍스트 추출 모듈과 별개로 설계가 가능하기 때문에 개인화가 가능하다. 또한 베이지안 네트워크는 확률 기반의 모델로 변화하는 환경에 적응적이고 유연한 동작을 보여줄 수 있다.

#### 2. 배경 지식

##### 2.1 베이지안 네트워크 (Bayesian Network)

베이지안 네트워크는 각 환경 변수 간의 인과 관계를 나타낸 확률 기반의 그래프 모델이다. 각 환경 변수는 노드로 표현되고 각 환경 변수 간의 인과 관계는 노드와 노드 사이의 아크로 표현된다. 각 노드는 여러 가지 상태 값과 그에 대한 조건부 확률 테이블을 속성으로 가진다. 베이지안 네트워크는 방향성 비순환 그래프로 그 구조는 보통 전문가에 의해 설계되고, 각 노드의 조건부 확률 테이블은 전문가에 의해 설계되거나 표본 데이터로부터 계산된다.

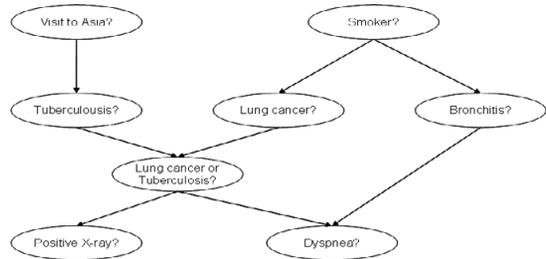


그림 1. 베이지안 네트워크 (ASIA)

그림 1은 베이지안 네트워크의 대표적인 예인 ASIA 네트워크이다. 이 네트워크는 환자 상태와 상황에 따라 환자가 병에 걸릴 확률이 얼마나 되는지를 추론한다. 예를 들어 환자가 아시아를 최근에 방문한 적이 있으면 "Visit to Asia?" 노드의 상태 값은 True가 되고, 이 때 "Tuberculosis?" 노드의 true 상태가 될 확률이 높아지도록 설계되어 있다.

2.2 퍼지 표현 (Fuzzy Representation)

퍼지 표현은 0과 1로 구분되는 Boolean 논리와 달리 “많다,” “적당하다,” “적다” 등의 애매모호한 인간의 언어를 0.2, 0.8 등의 퍼지 소속 값으로 표현하는 방법이다. 연속 값으로 입력되는 실제 값을 퍼지 논리의 논리 상태 값으로 매핑하기 위해서 퍼지 소속 함수를 정의해 사용한다.

그림 2는 현재 기온에 대한 퍼지 소속 함수를 나타낸 것이다. 그림에서 표시된 현재 온도는 퍼지 논리에 따르면 “적당”한 정도가 0.2 정도이고, “덥다”일 정도가 0.8 정도로 표현되고, 이 값을 논리 연산에 이용할 수 있다.

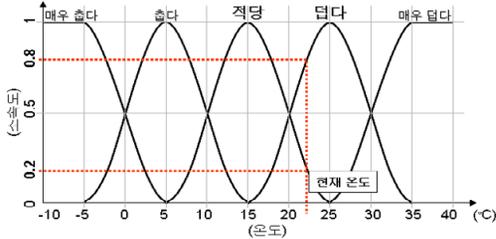


그림 2. 퍼지 소속 함수

3. 퍼지 변수의 베이저안 추론

3.1 동기

컨택스트 시스템에서 불확실성 처리는 중요한 주제이다. 어느 한 쪽 상태로 단정 지을 수 없는 상황에서 적당한 컨택스트를 추출할 수 있어야 그에 따른 행동이나 서비스가 지능적으로 동작할 수 있는 것이다. 예를 들어 노인 보조를 위한 로봇에 탑재된 컨택스트 시스템은 노인이 현재 상황에 어떻게 인지하고 있는지(덥다고 느끼는 정도, 춥다고 느끼는 정도), 혹은 노인의 행동이 부자연스러운지, 각 노인이 느끼는 정도가 어떻게 다른지 등의 컨택스트 정보를 판단할 수 있어야 적절한 서비스를 제공할 수 있을 것이다.

일반적으로 확률 기반의 베이저안 네트워크는 자체적으로 불확실성을 통계적 확률에 근거하여 어느 정도 유연한 처리가 가능하다. 그러나 기본적으로 베이저안 네트워크는 기호적인 표현 방법을 쓰기 때문에 연속 값으로 표현되는 센서 값을 입력으로 사용하기 위해서는 기호적인 표현으로 매핑해 주어야 하는데 이를 정확하게 하기 힘들다. 또한 사용자나 상황에 따라 센서가 반응하는 현상에 대한 기호나 특성이 조금씩 다를 수 있기 때문에 이를 반영하기 위해서는 상황 별로 여러 개의 베이저안 네트워크를 구축해야 한다는 문제가 있다.

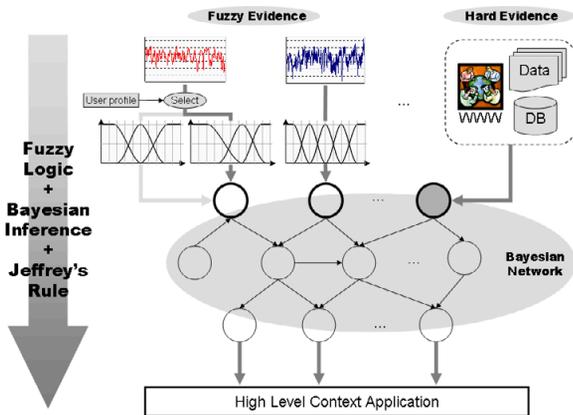


그림 3. 제안한 방법

3.2 제안한 방법

네트워크의 입력의 불확실성을 처리하고, 개인화를 하기 위해 본 논문은 베이저안 네트워크의 입력에 퍼지 논리를 적용하며 퍼지 노드가 두 개 이상인 경우에 대해 적절한 소속도 결합 연산자를 사용을 제안한다.

그림 3은 본 논문에서 제안하는 방법의 흐름도이다. 제안한 방법에서는 베이저안 네트워크의 입력 방식을 퍼지를 적용한 fuzzy evidence와 기존의 입력 방식인 hard evidence, 두 가지로 구분한다. Hard evidence는 기존의 방법대로 입력하고, fuzzy evidence는 주로 센서 등에서 입력된 연속 값을 퍼지 소속 함수를 거쳐서 노드의 각 상태 값에 대한 belief 정도를 네트워크의 입력으로 한다. 만약 퍼지 소속 함수가 사용자마다 다르게 구축되어 있다면, 사용자 프로필을 통해 각 개인에 맞는 퍼지 소속 함수를 선택하여 처리한다.

Fuzzy evidence가 입력된 후 베이저안 네트워크에서 목적 노드에 대한 추론(Bayesian Inference)을 하게 된다. Fuzzy evidence의 여러 상태에 대한 belief 정도를 추론에 적용시키기 위해 Jeffrey's Rule[2]를 사용한다. 목적 노드 A의 확률 값을 P(A)라고 하고, 부모 노드의 모든 상태 값 조합을 e, n은 조합의 수, 퍼지 소속 함수를 통해 계산된 각 상태 값에 대한 belief 정도를 Belief(e<sub>i</sub>)라고 할 때, P(A)는 Jeffrey's Rule에 의해 다음과 같이 계산된다(α는 정규화 상수이다).

$$P(A) = \alpha \sum_{i=0}^n P(A | e_i) Belief(e_i)$$

퍼지가 적용된 evidence 노드가 하나라면 Belief(e<sub>i</sub>) 값은 퍼지 소속 함수에서 나온 값 그대로 적용시키면 되지만, 노드가 여러 개일 경우, Belief(e<sub>i</sub>)를 결정해 줄 필요가 있다. 이는 퍼지 소속 값을 퍼지 집합 이론의 AND 연산을 사용해 결합하여 사용했다. 퍼지 집합에서 AND 연산을 하는 방법은 두 가지가 있는데 각 소속 값 중 최소 값을 취하는 방법과 각 소속 값을 곱하는 방법이 있다.

일반적으로 퍼지 집합에서의 AND 연산은 최소 값을 취하지만, 베이저안 추론 과정에서 이 방법을 사용하여 Belief(e<sub>i</sub>)를 계산할 경우, 각 노드의 독립/비독립성이 깨질 수 있다. 만약 A 노드와 B 노드가 서로 영향을 받지 않는 독립된 노드일 때, 소속 값을 곱하는 방법을 사용하면 A 노드의 상태가 바뀌어도 B 노드의 각 상태의 확률 값에 영향을 주지 않지만, 최소 값을 취하는 방법을 사용하면 B 노드의 확률 값이 A 노드 상태에 따라 바뀔 수 있는 것이다. 본 논문에서는 각 노드의 독립/비독립성을 유지하기 위해 각 소속 값을 곱하는 방법을 사용했다.

4. 동작의 예

이 절에서는 기후에 따라 옷 추천을 해주는 간단한 베이저안 네트워크를 통해 제안한 방법이 어떻게 동작하는지 설명한다.

4.1 퍼지가 적용된 베이저안 추론

그림 4는 그날의 온도와 습도 상태, 그리고 웹으로부터 받은 일기 예보 상황에 따라 계절을 추론하고, 사용자에게 우산을 들고 나갈지, 혹은 어떤 옷(하의)을 입고 나갈지를 추천해주는 간단한 베이저안 네트워크이다. 각 노드와 조건부 확률 테이블은 전문가가 직접 설계했으며, T 노드와 H 노드는 센서로부터 입력받아 퍼지로 처리하는 퍼지 노드이다. 각각의 퍼지 소속 함수는 그림 5와 같다.

그림 5에서 (a1)과 (a2)는 T 노드에 대한 퍼지 소속 함수이다. 만약 그 해의 평균 기온이 평년에 비해 2도 정도 높고 온도의 변화 폭이 좁다면 (a2)를 사용하고, 평년의 기온이라면 (a1)을 사용하는 식으로 현재 해에 해당하는 프로필을 선택해

개인화(혹은 특성화)를 시킬 수 있다. (b)는 습도에 대한 퍼지 소속 함수이다.

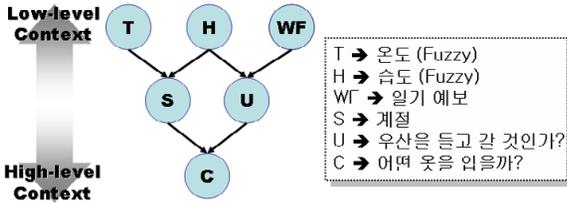


그림 4. 예제 Bayesian Network

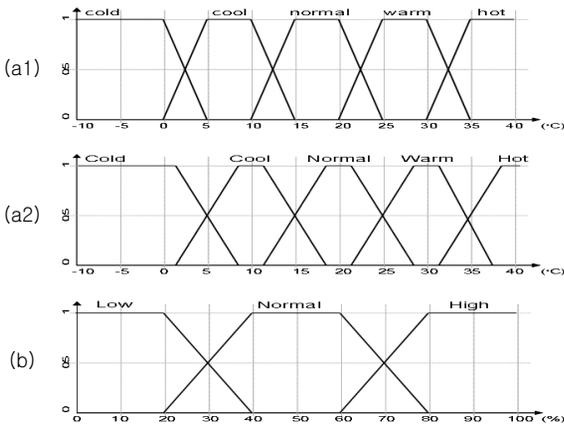


그림 5. 퍼지 소속 함수

만약 현재 센서가 감지한 온도가 22도이고, 습도는 78%, 그리고 그 해의 평균 기온이 평년과 비슷하다고 알려져 있고(그림 5의 (a1) 사용, 그날의 일기 예보가 구름 낀 날씨라고 가정했을 때 U 노드와 C 노드는 Jeffrey's Rule에 의해 다음 표 1과 같이 계산된다.

표 1. Jeffrey's Rule

WF 노드의 상태	Cloudy	Cloudy	Cloudy	Cloudy
T 노드의 상태	Normal	Normal	Warm	Warm
$M(T) \dots (1)$	0.6	0.6	0.4	0.4
H 노드의 상태	Normal	High	Normal	High
$M(H) \dots (2)$	0.1	0.9	0.1	0.9
$Belief(e_i) = (1) \times (2)$	0.06	0.54	0.04	0.36
$P(U = Take   e_i)$	0.35	0.55	0.35	0.55
$P(C = ShortSkirt   e_i)$	0.25405	0.29216	0.31403	0.35446

$$\begin{aligned}
 P(U = Take) &= \alpha \sum_{e_i} P(U = Take | e_i) Belief(e_i) \\
 &= (0.35 \times 0.06 + 0.55 \times 0.54 + \\
 &\quad 0.35 \times 0.04 + 0.55 \times 0.36) / \sum_{e_i} Belief(e_i) \\
 &= 0.53 \\
 P(C = ShortSkirt) &= \alpha \sum_{e_i} P(C = ShortSkirt | e_i) Belief(e_i) \\
 &= (0.25405 \times 0.06 + 0.29216 \times 0.54 + \\
 &\quad 0.31403 \times 0.04 + 0.35446 \times 0.36) / \sum_{e_i} Belief(e_i) \\
 &= 0.3132
 \end{aligned}$$

4.2 개인화 및 베이저안 네트워크 특성 유지

만일 그 해의 평균 기온이 평년보다 2도 정도 높다면 T 노드에 대한 퍼지 소속 함수를 그림 5의 (a2)를 사용하여 해당 해의 특성에 맞게 추론을 할 수 있을 것이다. 표 2는 4.1절과 같은 조건에서 퍼지 소속 함수에 따라 계절을 어떻게 판단하는지 나타낸다.

표 2. 계절 판단 (수치는 확률)

	봄	여름	가을	겨울
그림 5의 (a1)	0.2842	<b>0.4592</b>	0.2010	0.0556
그림 5의 (a2)	<b>0.3730</b>	0.2800	0.2650	0.0820

표 2에서 보는 바와 같이 그림 5의 (a1)은 현재 여름일 가능성이 높게 나오는 반면, (a2)는 아직 봄일 확률이 높음을 알 수 있다. 이는 (a2)가 (a1)에 비해 현재 해의 평균 기온이 2도 정도 높아졌음을 감안하고 정의된 퍼지 소속 함수이기 때문이다.

또한 표 3을 보면 S 노드의 확률 상태가 달라짐에 따라 C 노드의 각 확률 값이 달라져서 여름에는 좀더 짧은 차림의 하의를 입도록 추천할 수 있다. 이에 반해 U 노드는 네트워크의 구조 상 T 노드와 S 노드와의 연관성이 없도록 설계되어 있기 때문에 실제 확률의 변화가 없어야 한다. Jeffrey's Rule을 사용하는 과정에서  $Belief(e_i)$ 을 각 소속 값 중 최소 값을 사용한다면 U 노드가 T 노드의 영향에 의해 확률이 변하지만, 곱을 사용하면 일정하게 유지될 수 있기 때문에 본 논문에서는 소속 값의 곱을 사용하여  $Belief(e_i)$ 를 계산하였다.

표 3. C 노드와 U 노드의 확률 변화 비교

C 노드	짧은 바지	긴 바지	짧은 치마	긴 치마	연산자
(a1)	0.2895	0.1924	0.3132	0.2049	곱 사용
(a2)	0.2738	0.2162	0.2883	0.2216	
U 노드	우산 들고 나감		우산 놔두고 나감		최소값 사용
(a1)	0.5300		0.4700		
(a2)	0.5300		0.4700		
U 노드	우산 들고 나감		우산 놔두고 나감		최소값 사용
(a1)	0.5167		0.4833		
(a2)	0.5300		0.4700		

이와 같이 제안한 방법에서 퍼지 소속 함수의 정의만 바꾸어 주면 현재 네트워크를 변화시키지 않고 각 환경이나 개인의 특성에 맞게 입력을 조정할 수 있으면서, 원래 베이저안 네트워크의 특성을 유지할 수 있다.

5. 결론

본 논문에서는 퍼지를 이용해 전처리 단계를 거치고 베이저안 네트워크를 통해 컨텍스트를 추출할 수 있는 방법을 제안하고 유용성을 확인할 수 있었다. 특히 두 개 이상의 퍼지 노드가 있을 때 소속값의 곱을 이용하여 Jeffrey's Rule에 적용하는 것이 바람직하다는 사실도 확인했다.

그러나 Jeffrey's Rule을 사용할 때 계산 량이 증가한다던지, 네트워크의 자동 학습 문제 등 해결해야할 여러 가지 주제가 많이 있다. 향후 본 논문에서 제안한 방법을 기초로 하여 좀더 현실적인 상위 컨텍스트 추출기를 설계할 예정이다.

참고 문헌

[1] P. Korpipaa, J. Mantjarvi, J. Kela, H. Keranen, and E.-J. Malm, "Managing context information in mobile devices," *IEEE Pervasive Computing*, vol. 2, no. 3, pp. 42-51, 2003.

[2] J. Pearl, *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*, Morgan Kaufmann Publishers, Inc., 1988.