

휴대폰에서의 경량 상황추론을 위한 모듈형 베이지안 네트워크의 선택적 추론

(Selective Inference in Modular Bayesian Networks for
Lightweight Context Inference in Cell Phones)

이승현[†] 임성수[†] 조성배[‡]
(Seung-Hyun Lee) (Sungsoo Lim) (Sung-Bae Cho)

요약 모바일 기기에서 얻을 수 있는 로그 데이터는 다수의 유의미한 정보를 담고 있다. 그러나 모바일 기기의 연산능력 제약과 정보 분석 자체의 어려움 등으로 상황정보를 활용한 모바일 에이전트의 구현이 쉽지 않다. 본 논문에서는 제한적인 모바일 플랫폼에서 효율적인 상황인지를 위한 베이지안 네트워크 응용 기법을 제안한다. 베이지안 네트워크는 다수의 세부 모듈로 구성되며, 모듈간 인파성을 가상증거를 통해 보존된다. 각 모듈은 이전 증거값과 추론결과를 저장하고, 현재 증거값과 비교하여 전체 네트워크에 변화를 주는 경우에만 선택적으로 추론을 수행한다. 다양한 수집 주기의 모바일 데이터를 이용한 추론결과의 신뢰성을 높이기 위해 기억감소함수를 이용하여 결과를 보정하는 방법을 살펴본다. 마지막으로 실제 모바일 환경에서의 실험을 통해 제안하는 방법의 유용성을 확인한다.

키워드 : 모바일 에이전트, 모듈형 베이지안 네트워크, 선택적 추론, 기억감소이론

Abstract Log data collected from mobile devices contain diverse and meaningful personal information. However, it is not easy to implement a context-aware mobile agent using this personal information due to the inherent limitation in mobile platform such as memory capacity, computation power and its difficulty of analysis of the data. We propose a method of selective inference for modular Bayesian Network for context-aware mobile agent with effectiveness and reliability. Each BN module performs inference only when it can change the result by comparing to the history module which contains evidences and posterior probability, and gets results effectively using a method of influence score of the modules. We adopt memory decay theory and virtual linking method for the evaluation of the reliability and conservation of causal relationship between BN modules, respectively. Finally, we confirm the usefulness of the proposed method by several experiments on mobile phones.

Key words : Mobile agent, Modular Bayesian network, Selective inference, Memory decay theory

• 이 논문은 2010년도 정부(교육과학기술부)의 재원으로 휴먼인지환경사업본부-신기술융합형 성장동력사업의 지원(No. 2010K001173)과 지식경제부 산업원천기술개발사업(10035348, 모바일 플랫폼 기반 계획 및 학습 인지 모델 프레임워크 기술 개발)의 지원으로 수행되었음

† 학생회원 : 연세대학교 컴퓨터과학과
e2sh83@sclab.yonsei.ac.kr

lss@sclab.yonsei.ac.kr

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

논문접수 : 2010년 4월 13일

심사완료 : 2010년 9월 2일

Copyright©2010 한국정보과학회: 개인 목적이나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.

정보과학회논문지: 소프트웨어 및 응용 제37권 제10호(2010.10)

1. 서 론

최근 스마트폰의 발전과 대중의 인식 변화에 따라 모바일 플랫폼에서의 지능형 서비스에 대한 관심이 증가되고 있다. 모바일 기기에서 수집 가능한 개인의 일상정보(통화 기록, SMS, 사진, MP3, 가속도, GPS, PIMS, 웹 등)를 활용하여 상황에 적절한 서비스를 제공하는 것이다. 사용자의 음성을 인식하여 식사예약, 비행기 시 간확인 등의 정보검색과 추천을 해주는 Siri(<http://siri.com>)와 친구의 위치와 행동 등의 정보를 공유해주는 Foursquare(<http://foursquare.com>) 등이 대표적이다. 이렇듯 유용한 개인의 일상 정보와 주변환경 정보를 담고 있고, 개인이 항상 휴대한다는 모바일 장치의 특성은 사용자의 편의를 위한 다양한 서비스 제공의 가능성을

열어주었다.

하지만, 모바일 기기는 PC에 비해 상대적으로 적은 메모리 용량, 느린 CPU 처리속도, 조악한 화면 크기, 제약적인 입력 인터페이스, 제한된 배터리 용량 등의 한계를 가지고 있다. 한편 모바일로 수집 가능한 데이터는 사용자 행동의 불규칙성, 센서 정보의 불확실성, 사용자 의도의 불확실성 등을 내포하기 때문에 이를 활용하는 것이 쉽지 않다. 또한 변화가 심한 실세계 환경에서 작동하기 때문에 더욱 능동적이고 효과적인 적용 가능성이 요구되는 점 등 개발에 어려움이 있다. 이를 효과적으로 해결하기 위해 확률적 접근방법이 활용되고 있다. R. Vertegall 등의 통화중인 사용자의 상태 추론[1], MIT reality mining 그룹의 모바일 라이프 로그 요약 어플리케이션[2], A. Krause 등의 모바일 사용자의 상황예측[3] 등이 대표적이다.

베이지안 네트워크(Bayesian Network: BN)는 구성하는 노드와 상태의 수, 그리고 연결의 수가 많아질수록 더 복잡한 계산을 필요로 한다. 정확한 추론결과의 계산은 NP hard 문제로 밝혀졌으며, 노드 수와 상태에 따라 지수적으로 시간 복잡도가 증가하기 때문에[4] 모바일 기기에서의 활용에 제약이 많다. 뿐만 아니라 센서별로 데이터의 수집 주기가 다른 경우, 추론시 수집한 증거값의 동기화 및 이의 활용에 문제가 있을 수 있다. 이러한 제약적인 모바일 장치, 그리고 다양한 센서로부터의 증거수집 주기가 다를 수 있는 모바일 데이터의 특성을 고려한 상황인지 모바일 에이전트의 적용 방법이 필요하다.

본 논문에서는 모바일 플랫폼 상에서 효율적인 동작을 위한 모듈형 BN[5]의 선택적 추론 방법을 제안한다. 모듈형 BN을 구성하는 각 BN모듈은 현재 수집된 증거값이 히스토리 모듈에 저장된 값들과 일치하지 않을 경우에만 선택적으로 추론을 수행한다. 증거 수집 주기가 달라 이전 증거값을 적용하여 추론하는 경우, 기억감소 함수를 활용하여 계산된 신뢰도를 추론결과에 반영한다. BN간의 모듈별 인과성은 가상연결방법을 통해 보존되며, 모듈의 영향력 점수를 계산하여 모듈의 추론 회수를 최소화한다. 이를 통해 모바일 에이전트는 반복적 추론을 통한 상황인지가 가능하며, 실시간 인식 결과를 기반으로 즉각적 서비스 제공이 가능하다.

2. 관련연구

BN의 네트워크 구조에 기인하여 증가하는 추론의 복잡성을 극복한 효율적 응용을 위해 다양한 노력이 기울여졌다. 이러한 시도는 크게 BN의 구조적 제한을 통한 방법과 추론 알고리즘 수행과정의 연산의 복잡도를 줄이는 방법으로 분류할 수 있다.

M. Marengoni 등은 모델링 대상이 되는 개체를 다수계층으로 분류하고 각 계층간 인과관계의 방향을 통해 주는 계층적 모델링 방법을 제시하였다[6]. 인과관계의 상위 단에 위치하는 상위 계층의 개체부터 하위 계층과 각 개체의 하위 특징값 집합을 차례로 추론하는 순차적 접근 방법으로 BN에서의 추론 복잡도를 줄이고자 하였다. 하지만 개체간의 인과관계가 명확하지 않은 경우 적용이 어려우며, 하위 계층 특징값의 상위계층으로의 인과관계를 표현할 수 없다. 또한 모든 특징 값에 대한 효용함수의 반복적인 계산을 요구하여 효율성을 저하시킨다는 단점이 있다.

이와 유사하게 D. Brandherm 등은 동적 BN에서 노드별로 임계값을 설정하고, 이보다 낮은 수치를 가지는 BN 노드는 사용하지 않는 것으로 구별하여 시간 복잡도를 낮추고자 하였다[7]. 하지만 이는 DBN을 활용하는 경우에만 제한적으로 적용가능하며 넓은 범위의 일반적 BN에 적용이 불가능하다. Xiang 등은 단일 BN모델을 여러 개의 부분으로 분할함으로써 규모가 큰 BN에서의 효율적인 추론 가능성 보여주었다[8]. shafer-shenoy 알고리즘을 기반으로 지연전파(lazy propagation) 방법을 사용하였다. 이는 추론 수행중의 공간 복잡도를 감소시켰지만 시간 복잡도 자체를 낮추지는 못하였으며 특정 추론 알고리즘에 종속적이라는 한계가 있다.

추론과정 자체에 기인하는 복잡도를 낮추기 위한 대표적인 시도는 다음과 같다. A. Brogini 등은 타겟 변수에 영향을 줄 수 있는 특징노드를 마르코프 블랭킷(Markov blanket) 범위라고 가정하고, 전체 네트워크가 아닌 타겟노드와 영향력을 가진 특징노드 범위로 제한하여 결정트리(Decision tree)를 생성함으로써 BN의 복잡도를 감소시키고자 하였다[9]. 하지만 이 방법은 한정한 특징 노드에 따라 추론 정확도가 민감해지며, BN 모델 자체를 간소화하였지만 추론 과정을 경량화하지는 못하였다.

U. Kjaerulff는 약한 의존성을 제거하고 추론하는 방법으로 복잡도를 낮추고자 하였다[10]. 하지만 원래 BN 모델의 추론 결과와 차이가 존재하며, BN 자체에 약한 의존성이 없는 경우 적용이 불가능하다. 한편 F. Bacchus 등은 SAT 문제를 해결하는 알고리즘인 DPLL의 트리를 계산함에 있어 한번 계산한 모든 결과를 캐시 메모리에 저장하는 방법으로 추론 복잡도를 낮추고자 하였다[11]. 이 방법은 BN의 규모가 크거나 타겟 노드가 수시로 변하는 동적인 환경에서는 효율성을 유지하기 힘들다는 한계가 있다.

이와 같이 지금까지의 연구들은 BN 구조나 추론 과정을 각각 변화시킴으로써 BN의 복잡도를 제어하고자 하였다. 하지만 두 가지 장점 모두를 가지는 방법은 제

시되지 않았으며, 특히 모바일 환경에서 BN을 효율적으로 활용하기 위한 방법을 다루지 않았다. 제한적인 모바일 환경에서의 BN의 활용도를 극대화하기 위해서는 BN의 구조 자체에서 오는 효율성과 BN 추론 과정에서의 효율성을 기할 수 있는 방법이 필요하다.

3. 모듈형 베이지안 네트워크의 선택적 추론

본 논문에서 제안하는 모듈형 BN는 연산능력이 제한적인 모바일 플랫폼에서의 효율적인 추론을 지원한다. 특히 확률추론에 소요되는 시간을 대폭 줄여, 반복적, 실시간 확률 추론을 통한 상황인지를 가능하게 하고, 짧은 지연시간 내에 사용자에게 서비스 제공을 가능하게 한다. 이를 위해 각 BN모듈은 증거값 변동 상황에 따라 재추론 여부가 결정되며, 추론이 필요한 모듈만 선택적 추론을 통한 업데이트가 수행된다. 재추론이 되지 않는 BN모듈들은 마지막 추론 시점으로부터의 시간의 길이에 따라 계산된 BN모듈 추론 신뢰도 값에 따라 확률 추론값이 전체 추론에 반영된다. 그림 1은 선택적 추론을 수행하는 모듈형 BN 추론 시스템의 구조이다.

3.1 모듈형 베이지안 네트워크

모듈형 BN 모델은 다음과 같이 정의된다.

정의 1 (베이지안 네트워크): BN은 실세계 문제의 인과관계를 확률적으로 모델링하기 위한 도구로 랜덤변수 V 와 변수간의 조건부 확률테이블 $P(V)$ 로 구성된다. BN은 네트워크 그래프 G 와 확률값 P 의 튜플 (G, P) 로 표현되며, 그래프는 방향성 비순환 그래프(Directed acyclic graph) 형태의 랜덤변수 V 와 변수간의 에지 $E=(V_i, V_j)$ 로 구성된다. $Pa(V_i)$ 를 노드 V_i 의 부모 노드의 집합이라고 할 때, 확률테이블 P 는 G 에 속하는 모든 $V_i \in V$ 에 대한 $P(V_i|Pa(V_i))$ 의 집합으로 정의된다. 관찰되지 않은 노드를 V_u , 관찰된 증거값의 집합을 $\epsilon = \{\epsilon_1, \dots, \epsilon_m\}$ 이라고 할 때, 미관측 노드의 사후 확률값 $P(V_u|\epsilon)$

은 체인룰(Chain rule)에 의해 다음 식 (1)과 같이 계산된다.

$$\begin{aligned} P(V_u|\epsilon) &= \prod P(V_u|Pa(V_u)) \epsilon \\ &= \prod P(V_u|Pa(V_u)) \prod_{\epsilon_i \in \epsilon} \epsilon_i \end{aligned} \quad (1)$$

정의 2 (BN 모듈): BN 모듈 Ψ_i 은 그래프 $G_i = (V_{\Psi_i}, E_{\Psi_i})$ 와 확률값 P_i 의 튜플 (G_i, P_i) 로 구성된다[12]. 이 때 V_{Ψ_i} 는 G_i 에 속하는 랜덤변수의 집합이며, E_{Ψ_i} 는 X, Y 를 각각 V_{Ψ_i} 에 속하는 랜덤변수라 할 때 에지 $E_{\Psi_i} = (X, Y)$ 의 집합이다. BN 모듈은 문제 공간에서 관측되는 모든 랜덤 변수 집합 U 의 일부분 $V_{\Psi_i} \subset U$ 를 모델링하며, BN 모듈의 조건부 확률테이블 $P(V_{\Psi_i})$ 는 단일 BN 모델의 확률테이블 $P(U)$ 와 같은 값으로 정의된다. 따라서 BN 모듈은 단일 BN의 하위그래프라고도 할 수 있다.

정의 3 (모듈형 BN): 모듈형 BN \mathcal{Q} 는 BN 모듈 Ψ 과 모듈간의 관계 R 의 튜플 (Ψ, R) 로 구성된다. Ψ 는 \mathcal{Q} 내에 정의된 모든 BN 모듈의 집합을 의미하며, R 은 BN 모듈의 쌍 집합 $\langle \Psi_i, \Psi_j \rangle \mid i \geq 1, j \geq 1, i \neq j$ 으로 정의된다. 두 모듈 $\Psi_i = ((V_{\Psi_i}, E_{\Psi_i}), P_i)$, $\Psi_j = ((V_{\Psi_j}, E_{\Psi_j}), P_j)$ 는 각각 M 의 원소이며, 두 모듈을 구성하는 노드의 집합 V_{Ψ_i}, V_{Ψ_j} 간에는 최소 1개 이상의 노드를 공유한다. 모듈 쌍 $\langle \Psi_i, \Psi_j \rangle$ 는 모듈 Ψ_i 에서 모듈 Ψ_j 로의 BN 모듈간 인과성을 표현한다. 모듈간의 인과성은 각 모듈의 출력 노드와 다른 모듈에서의 입력노드를 통해 구체화된다.

$$R(\psi_i, \psi_j) = (V_{i,out}, V_{j,in}) \quad (2)$$

$V_{i,out}$ 은 각각 모듈 Ψ_i 에서 Ψ_j 모듈로 원인이 되는 노드의 집합을 나타내는 한편, $V_{j,in}$ 은 Ψ_i 로부터 입력을 받는 Ψ_j 노드의 집합을 의미한다. 이때 $V_{i,out}$ 과 $V_{j,in}$ 이 나타내는 실질적 의미 노드는 각각 동일하며, 두 BN 모듈간 상호 인과성이 반영되는 경우의 출력 노드는 모




그림 1 제안하는 모듈형 BN 추론 시스템 구조

들 공통 노드의 부분집합이 된다. 모듈형 BN은 다음과 같은 특징을 가진다.

- 모듈 쌍은 비대칭적이다. $\langle \psi_i, \psi_j \rangle$ 와 $\langle \psi_j, \psi_i \rangle$ 는 같지 않다.
- 모듈형 BN의 모듈은 자기 자신으로의 순환 루프(loop)를 포함하지 않는다. 예를 들어 $\langle \psi_i, \psi_j \rangle$ 와 같은 모듈 쌍은 존재하지 않는다.
- 모듈 쌍을 가지는 두 BN 모듈은 최소 1개 이상의 공통 변수를 가진다.
- 모듈간의 상호 인과성을 반영할 수 있다. 즉 입력, 출력 모듈이 상황에 따라 유동적으로 변화한다.

모듈형 BN은 센서 네트워크에서 이종의 저수준 센서 정보의 통합한 고수준 정보 추론[12], 모바일 장치로 수집되는 개인의 생활 정보를 이용한 랜드마크의 인식 등에 적용되었으며, 특히 모바일 도메인에 적용하기 위해서는 추론 효율성을 높이는 것이 필요한 실정이다.

3.2 재추론 BN모듈 선택

각 BN 모듈은 이전 시간의 증거값 집합 ϵ 과 모듈의 출력 노드 V_{out} 의 사후 확률값 $P(V_{out} | \epsilon)$ 을 저장한다. 모듈 ψ_i 의 증거값-추론결과 H_{ψ_i} 는 추론 시각과 함께 3-튜플 형태로 다음과 같이 표현된다.

$$H_{\psi_i} = \{ \langle \epsilon_i, P(V_{out_i} | \epsilon_i), t \rangle \mid \exists \epsilon_i \neq \epsilon_j, V_{out} \in V_i \} \quad (3)$$

동일한 증거 집합을 가지는 H_{ψ_i} 의 원소는 없으며, 동일 증거값 수집시 해당 증거값을 포함하는 원소의 시간 값이 갱신된다. 모듈형 BN 추론시, 이를 구성하는 각 BN 모듈은 전체 네트워크의 추론 결과에 변화를 줄 수 있는 경우에만 재추론 여부를 결정하고 선택적으로 추론을 수행한다.

모듈 ψ_i 의 재추론 필요성, I_{ψ_i} 는 식 (4)와 같이 현재 시점에 관측된 증거값의 집합과 저장된 증거값-추론결과 집합과의 비교를 통해 결정된다.

$$I_{\psi_i} = \begin{cases} \text{false}, & \text{if } \exists \epsilon_i \equiv \epsilon_t \quad (\epsilon_i \in Q_M) \\ \text{true}, & \text{otherwise} \end{cases} \quad (4)$$

현재 증거값이 이전 시간의 증거값과 같은 경우 파라미터나 구조에 변경이 없는 한 같은 추론값을 가지게 된다. 따라서 수집한 모바일 데이터의 양자화 결과 과거 추론에 사용된 조합과 같은 증거값을 관측한 경우 과거에 계산한 추론 결과값을 활용하여 해당 모듈의 확률추론에 소요되는 연산의 낭비를 막는다.

3.3 BN모듈 추론 신뢰도 평가

BN 모듈의 재추론이 필요하지 않은 경우는 다음과 같이 세분화할 수 있다.

- 이전 시각과 동일한 데이터를 수집한 경우
- 센서 데이터의 변동성이 적어 BN의 상태값을 변화시키지 못하는 경우
- 수집 주기에 차이가 있어 수집을 하지 못해 이전 증

거값을 사용해야 하는 경우

첫번째와 두번째와 같이 정보를 수집한 경우, 재추론하지 않고 이전 추론 결과값을 그대로 사용해도 무방하다. 하지만 마지막의 경우, 이전 결과가 현재의 상황정보를 온전히 반영하였다고 할 수 없다. 이와 같이 서로 다른 수집 주기로 정보의 동기화가 어려운 모바일 환경에서 추론의 신뢰도를 높이기 위해서는 수집 주기가 긴 데이터의 추론 결과를 보정할 수 있는 방법이 필요하다.

이를 위해 본 논문에서는 대표적 기억감소곡선 중 하나인 파워함수(power function) $f(t)$ 를 이용하여 각 BN 모듈의 신뢰도를 계산한다.

$$f(t) = a(t+1)^{-b} \quad (5)$$

t 는 증거를 마지막으로 수집한 이후 추론 시각의 흐름을 나타내며, a 와 b 는 망각 계수(forgetting coefficient)를 의미한다. BN모듈은 각각의 고유한 망각계수를 가지며, 모듈 내의 입력 노드에 대해 마지막으로 증거가 갱신된 시간을 관리한다. 파워함수는 시간의 흐름에 따른 기억의 잔존량, 즉 기억의 신뢰성을 나타내며, 시간의 흐름에 따라 신뢰도는 그림 2와 같이 지수적으로 감소하고 감소율은 망각계수의 크기에 따라 변화한다. 정보의 신뢰도가 갱신되지 않은 데이터에 의한 추론 결과를 기본으로 BN 모듈의 확률값 P 는 식 (6)과 같이 조정된다.




그림 2 시간에 따른 기억감소변화

$$R(P(v=true)) = P(v=true)f(t) + P(v=false)(1-f(t)) \quad (6)$$

$P(v=true)$ 은 BN 모듈의 추론 결과값을 의미하며, $f(t)$ 는 파워함수의 결과값을 의미한다. 파워함수의 망각계수 중 a 를 1보다 큰 값으로 설정하는 경우 $P(V)$ 의 결과값은 $(0, 1)$ 의 확률값 범위를 벗어난다. 이 경우에는 식 (7)과 같이 조정한다.

$$P(v=true) = \begin{cases} P(v=true), & \text{if } f(t) \geq 1 \\ R(P(v)) & , \text{ otherwise} \end{cases} \quad (7)$$

기억감소이론은 심리학자 에빙하우스를 시작으로 인

간 기억의 불완전성을 분석한 것으로, 시간에 따라 감소하는 기억의 신뢰도를 설명한다. 최근 인간 기억의 신뢰도를 망각함수(forgetting curve)를 이용해 수식적으로 표현하고자 하는 노력이 기울여졌으며, 파워함수나 지수함수 등을 통해 표현되었다. 이러한 기억감소이론은 실제적인 인간의 인지기능을 모방한 컴퓨터의 학습이나 신경망을 이용한 학습 알고리즘에 반영되기도 하였다.

3.4 가상증거 연결 기술

추론시 BN모듈간의 상호 인과성을 반영하기 위해 가상 증거 기술을 활용한다. 다른 BN모듈로부터 입력되는 노드의 확률 추론 결과값을 해당 모듈에 연결하여 증거값과 같이 설정한다[13]. 가상 노드 V_{in} 를 BN 모듈에 추가하고 입력 노드 V_{in} 의 자식노드로 연결을 생성하여 목표값에 맞게 확률 테이블 값은 설정하고 가상 노드에 증거를 설정해 주는 방식이다.




그림 3 모듈별 인과성 반영을 위한 가상증거기술

그림 3과 같이 한 모듈의 추론 결과값이 다른 모듈의 입력에 반영되는 경우를 가정하자. 노드 E 는 가상 증거가 설정되는 노드이며 노드 V 는 가상노드이고, 각각 2개의 상태값 $\{true(t), false(f)\}$ 을 가진다고 하자. 모듈 Ψ_i 의 입력노드의 가상증거 확률값을 a , 이를 위해 설정해 주어야 하는 가상노드의 확률 테이블 값 $P(V=t|E=t)$ 과 $P(V=t|E=f)$ 의 값을 각각 r , r' 이라고 할 때 r , r' 의 값은 다음 식 (8)과 같이 계산할 수 있다.

$$\frac{r}{r'} = \frac{\alpha \sum_{i=1}^n P(E=t|P_i)}{(1-\alpha) \sum_{i=1}^n P(E=f|P_i)} \quad (8)$$

증명과정은 다음과 같다. 가상노드 V 에 증거값이 설정되는 경우 연결 노드 E 의 확률값은 다음과 같다.

$$P(E=t|V=t) = \frac{P(V=t|E=t)P(E=t)}{P(V=t)} \quad (9)$$

$$P(E=f|V=t) = \frac{P(V=t|E=f)P(E=f)}{P(V=t)}$$

이를 베이즈 규칙을 적용시키면 식 (10), (11)과 같아

변형된다.

$$Bel(E=t) = \alpha P(V=t|E=t)P(E=t) \quad (10)$$

$$Bel(E=f) = \alpha P(V=t|E=f)P(E=f) \quad (11)$$

(10)을 (11)로 나누면 식 (12)와 같은 결과를 얻는다.

$$\frac{P(V=t|E=t)}{P(V=t|E=f)} = \frac{P(E=t|V)}{P(E=f|V)} \frac{P(E=f)}{P(E=t)} \quad (12)$$

좌변은 가상증거 설정시 필요한 확률값의 비, 우변의 원쪽항은 목표 가상증거값, 우변은 초기 연결 노드의 확률값이 나온다.

이와 같은 가상 증거기술은 확률 테이블에 설정해주는 확률값에 따라 입력노드 V_{in} 에 0, 1의 이산 증거값 뿐만이 아닌 연속적인 범위 $U(0, 1)$ 의 증거값을 설정할 수 있다. 뿐만 아니라 사전 확률값을 변경해주는 기준의 방법에 비해, 가상 증거값이 설정된 V_{in} 의 사후 확률값은 고정되기 때문에 보다 정확한 추론을 수행할 수 있다.

3.5 모듈별 추론 우선순위 결정

모듈형 BN을 구성하는 각 모듈은 최소 한 개의 다른 모듈의 원인이나 결과로 연결되기 때문에 전체 추론시 세부 모듈별 추론 순서는 인과성의 실질적 반영에 영향을 줄 수 있다. 이전 연구에서는 이와 같은 문제를 해결하기 위해 모듈별로 최소 2회 이상의 반복적 추론을 통해 모듈간의 인과성을 충분히 반영하고자 하였다. 본 논문에서는 보다 효율적인 모바일 환경에서의 모듈형 BN의 추론을 위해 모듈별 영향력 점수를 이용하여 모듈별 추론 우선순위를 결정하도록 한다. BN모듈 Ψ 의 영향력 점수는 다음과 같이 계산된다.

$$InfluenceScore(\Psi) = N(V_{out}) - N(V_{in}) \quad (13)$$

$N(V_{out})$ 과 $N(V_{in})$ 은 각각 BN모듈 Ψ 에서 다른 모듈로 출력되는 노드의 수와 다른 모듈로부터 Ψ 으로 입력되는 노드의 수를 의미한다. $N(V_{out})$ 과 $N(V_{in})$ 은 다음과 같이 정의된다.

$$N(V_{out}) = \sum_{\Psi_i \neq \Psi} R(\Psi, \Psi_i) \quad (14)$$

$$N(V_{in}) = \sum_{\Psi_i \neq \Psi} R(\Psi_i, \Psi)$$

다른 모듈에 더 많은 입력노드를 가지는 모듈의 영향력 점수가 높게 평가되며, 반대로 다른 모듈의 추론 결과에 영향을 많이 받는 모듈은 낮은 점수를 가지게 된다. 전체 MBN 추론시 영향력이 큰 BN모듈부터 추론함으로써 다른 모듈에 해당 모듈의 결과값이 전달될 수 있다. 만약 두 모듈이 동일한 영향력 점수를 가진 경우, BN 모듈에 입력을 가지는 원인 모듈들의 영향력 점수의 합을 추가로 합하여 영향력 값을 계산한다.

$$InfluenceScore(\Psi) = InfluenceScore(\Psi) + \sum_{\Psi_i} N(V_{out}) - N(V_{in})$$

$$(V_{out}, V_{in} \in \Psi_i, \forall \Psi_i \text{ with } R(\Psi_i, \Psi)) \quad (15)$$

3.6 모듈형 베이지안 네트워크의 추론

선택적 추론 모듈형 BN의 전체적 알고리즘은 표 1과 같다.

표 1 제안하는 모듈형 BN의 추론 알고리즘

```

 $T = \text{Select\_targetModule\_by\_Context}(\Psi, C)$ 
foreach module  $\Psi_i$ 
     $InfluenceScore(\Psi_i) = N(V_{out}) - N(V_{in})$ 
 $L = \text{Sort\_module\_by\_InfluenceScore}(\Psi, R)$ 
foreach  $\Psi_i$  in  $L$ 
    if  $\Psi_i == T$ 
        return  $\text{BayesianInference}(\Psi_i, E_{current}, E_n)$ 
    else
        if  $E_{current} == \emptyset$  //시간 i에 수집한 증거가 없는 경우
             $E_{out} = P_{t-1}(V_{out}=\text{true} | E_{t-1}) \cdot f(t) + P_{t-1}(V_{out}=\text{false} | E_{t-1}) \cdot (1-f(t))$ 
        else if  $\exists E_i \text{ in } Queue_n == E_{current}$  //수집한 증거가 이전과 같은 경우
             $E_{out} = \text{BayesianInference}(\Psi_i, E_{current}, E_n)$ 
        else //새로운 증거값을 수집한 경우
             $E_{out} = \text{BayesianInference}(\Psi_i, E_{current}, E_n)$ 

```

모듈형의 세부 모듈 ψ 의 추론은 기본적으로 일반 BN의 추론 방법과 동일하다. 한 가지 다른 점은 다른 BN 모듈의 추론 결과값이 증거값으로 설정될 수 있고, 모듈의 추론 결과가 다른 모듈에 증거값이 될 수 있다는 점이다. 증거값으로 설정되지 않은 노드의 사후 확률값은 BN의 각 노드별로 정의된 사전 확률값 Y 의 집합 U 를 베이즈 규칙과 체인 규칙에 적용하여 계산할 수 있다. ψ 를 구성하는 노드의 집합을 V , V 에 대응하는 랜덤 변수를 X , 추론의 타겟이 되는 노드를 V_t , M 의 모든 증거값을 ε , 수집한 증거값 집합을 ε_a , 다른 BN 모듈에서 추론 결과로 들어오는 증거값을 ε_β 라고 할 때 다음과 같다.

$$\begin{aligned}
 P(X_i | \epsilon) &= \frac{P(\epsilon | X_t) P(X_t)}{P(\epsilon)} = \frac{P(X_t, \epsilon)}{P(\epsilon)} \propto P(X_t, \epsilon) \\
 &= \sum_{Y \in U \setminus X_t} P(X, \epsilon) \\
 &= \sum_{Y \in U \setminus X_t} \prod_{X_i \in X} P(X_i | X_{pa(v_i)}) \xi \\
 &= \sum_{Y \in U \setminus X_t} \prod_{X_i \in X} P(X_i | X_{pa(v_i)}) \xi_\alpha \xi_\beta \\
 &= \sum_{Y \in U \setminus X_t} \prod_{X_i \in X} P(X_i | X_{pa(v_i)}) \prod_{X_j \in X(\epsilon)} \xi_\alpha \prod_{X_j \in X(\epsilon)} \epsilon_\beta
 \end{aligned} \tag{16}$$

대표적인 추론 알고리즘인 LS 알고리즘의 추론 복잡도 $CMPX$ 는 n 을 노드의 수, k 를 노드가 가질 수 있는 최대 부모의 수, r 을 노드의 상태수, w 를 최대 클리크 (clique) 수라고 할 때 다음 (5)와 같다[14].

$$CMPX = O(k^3n^k + un^2 + (wr^w + r^w)n) \quad (5)$$

하지만 본 선택적 추론 방법을 적용한 경우, 모듈형 구조와 추론 과정에서의 연산 감소로 복잡도는 최대부 모수에 비례한 클릭 수를 w , 모듈형 BN의 모듈 수를 d 라고 할 때, 다음 (6)과 같이 감소함을 알 수 있다.

$$CMPX \cong O(k^3 \frac{n^k}{d^k} + k \frac{n^2}{d^2} + (k+1)r^w \frac{n}{r}) \quad (6)$$

4. 실험 및 결과 분석

4.1 실험 설계 및 환경

제안하는 MBN의 모바일 환경에서의 시간 효율성을 평가하기 위해, 그림 4와 같이 모바일 일정관리를 위한 BN을 설계하고 도메인별로 7개의 모듈로 구성하였다.

설계한 MBN의 테스트를 위해 한 대학원생의 학기 중 생활을 분석한 결과를 바탕으로 특정일정의 요일과




그림 4 일정관리를 위한 모듈형 BN

시간, 장소, 일정 상대와 기타 값을 포함하는 가상의 일정 데이터 1000개를 확률적으로 생성하였다. 특정 요소의 값은 임의의 확률로 손실되도록 생성하였으며, 같은 시점에 입력되는 증거값을 바탕으로 추론을 수행하였다. 추론의 대상은 사용자의 기본 일정정보의 요소를 기반으로 해당 일정의 우선순위를 가리는 것이며, 이를 바탕으로 에이전트는 일정의 종류에 얹매이지 않고 상황에 기반하여 지능적인 일정 조절에 도움을 줄 수 있다.

MBN 추론을 위해 피츠버그 대학의 Decision Systems Laboratory의 공개 라이브러리(SMILE)를 사용하였으며, 밝혀진 몇 가지 효율적인 추론 방법 중 가장 널리 사용되는 Lauritzen Spiegelhalter 알고리즘[15]을 기준으로 하였다. 모바일 기기는 삼성의 음니아 SCH-M490을 사용하였으며, 복잡도 비교를 위해 사용한 PC는 Intel Core 2 Duo E6750 2.66GHz, OS는 64비트 윈도우 7, 사용한 프로그래밍 언어는 C#이다.

4.2 MBN의 추론 효율성

표 2는 설계한 일정관리 MBN과 단일 BN을 각각 PC와 모바일 상에서 추론하는데 소요되는 시간을 보여준다. 먼저 PC와 모바일에서의 추론 소요시간에 큰 차이가 남을 확인할 수 있다. 단일 BN이나 모듈형 BN 모두 PC에서는 1회 평균 추론시 100배 이상의 시간이 소요되었다. 반응 속도에 따라 사용자의 편의를 좌우할 수 있는 모바일 폰에서 단일 BN 방법 적용시 긴 소요시간은 다른 서비스와 연동을 힘들게 할 수 있다. 뿐만 아니라 지속적이고 실시간 상황추론을 위한 반복적 추론이 필요한 상황에서, 시스템의 자원 소모를 높이고 배터리 소모 속도를 증가시키게 된다.

한편 모듈형 BN추론 방법은 단일 BN추론 방법에 비해 플랫폼에 상관없이 약 72%의 추론시간이 절감됨을 확인할 수 있다. 특히 모바일 플랫폼에서 0.47초 소요되던 1회 추론시간이 0.13초로 감소하였다. 이는 노드의 수와 연결의 수에 비례하여 증가하는 BN의 복잡도를 모듈화를 시킴으로써 감소시켰으며, 또한 세부 BN 모듈의 이전 추론 결과값을 활용하여 불필요한 재추론을 막아 추론 연산량을 급격히 줄였기 때문이다. (6)에 따르면 모듈의 수만큼 추론을 반복해야 하지만 Ⅵ에 지수적으로 감소하는 폭이 보다 더 크기 때문에 연산량이 감소할 수 있었다. 한편 평균적으로 단일 BN의 추론결과 확률과 비교해 1000회에 평균 0.18%의 추론결과의 차

표 3 기억감소 상수의 변화와 타겟 노드의 추론결과 오차율

b	0	0.1	0.5	1
오차율	0	0.013953	0.075153	0.138719

이를 보여 비교적 정확한 추론이 가능함을 보여주었다. 이와 같은 결과는 추론 시간을 절약하여 모바일 에이전트가 사용자를 위해 보다 신속한 대응을 가능하게 할 뿐만 아니라, 짧은 시간의 반복적 추론을 가능하게 하여 그 정보의 활용도를 높일 수 있다.

표 3은 기억감소 상수 b의 변화에 따른 단일 BN과 MBN의 타겟 노드의 추론 결과의 확률차이를 보여준다. b가 작을수록, 현 시점에서 수집하지 못한 데이터에 대한 신뢰도를 천천히 감소시키기 때문에 두 방법간의 결과차이가 적은 것을 확인할 수 있다. 특히 상수의 값이 0인 경우 이전 시점의 확률값에 신뢰도 조정없이 추론되므로 결과는 동일하였다. 상수 b의 값이 커질수록 오랫동안 수집하지 못한 데이터를 이용한 추론 결과의 신뢰도는 낮아져 단일 BN 결과와의 오차율은 커졌다. 하지만 이전 시점에 수집한 데이터를 사용해야 하는 단일 BN 방법의 한계를 미루어 볼 때, 어떠한 방법의 결과가 옳은 것인지 결론 내릴 수 없으며 오히려 MBN 방식이 현재 상황을 더 잘 반영한 추론 결과라고 볼 여지가 있다.

4.3. 히스토리 모듈의 크기에 따른 성능 분석

각 BN 모듈이 저장한 이전 증거값-추론결과값의 크기에 따라 추론 모듈의 재추론 회수는 달라질 수 있다. 많은 정보쌍을 담을수록 현재 증거값과 같은 경우의 추론값을 가질 확률이 높아진다. 그럼 5는 각 BN 모듈이 담는 증거값-추론결과의 정보의 범위를 low, normal, high의 세 단계로 구분하고 각각 1, 3, 5로 설정한 경우의 모듈형 BN과 단일 BN 모델의 소요된 추론 시간의 변화를 나타낸다.

많은 크기가 큰 경우, 보통인 경우, 작은 경우의 각각 평균 추론 소요시간은 0.06, 0.13, 0.31이며 선택적 추론을 하지 않는 단일 BN은 0.48초가 소요되었다. 저장하는 정보쌍의 크기가 작은 경우에도 추론 시간이 단일 BN 모델보다 약 35% 효율적인 것으로 나타났다. 이는 모듈형 구조 자체나 잘 변하지 않는 모바일 정보로 구성된 모듈에 기인한 것으로 분석된다. 하지만 일반적으로 정보쌍이 크기가 작은 경우, 세부 BN모듈의 많은 재추론이 필요한 것으로 나타났다. 가능한 많은 정보쌍을

표 2 PC와 모바일 상에서의 소요된 추론시간(단위: 초)

제약사항	PC 환경		모바일 환경	
	단일 BN	모듈형 BN	단일 BN	모듈형 BN
1회 평균 추론시간	0.004492	0.001341	0.475346	0.132902
1000회 총 추론시간	4.492	1.341	475.346	132.902




그림 5 히스토리 큐의 크기에 따른 소요 추론시간 변화 추이

관리하는 것이 시간 복잡도면에서 효율성을 증가시키지만 공간 복잡도를 높이는 트레이드오프(trade-off)가 존재한다.

5. 결론 및 향후연구

본 논문에서는 모바일 에이전트의 연산 효율성을 증대시키기 위한 방법으로 선택적 추론 모듈형 베이지안 네트워크 시스템을 제안하였다. BN모듈의 현재 증거값과 이전 저장된 증거값을 비교하여 재추론 여부를 결정하고, 증거값이 같은 경우 직전 결과값을 활용함으로써 모듈별로 최대 1회의 추론을 통해 결과를 구할 수 있게 하였으며, BN의 한계를 극복하고 보다 정확한 추론을 위해 기억감소함소에 기반한 방법으로 수집되지 않은 이전 증거값을 통한 추론 결과의 신뢰도를 평가, 조정하였다. 실험을 통해 제안하는 방법이 단일 BN추론 방법보다 시간 효율성이 좋아지는 것을 확인하였으며, 제약이 큰 모바일 환경에서 보다 큰 효과를 얻을 수 있음을 알 수 있었다. 본 연구를 통해 현재 제공되는 단순 서비스나 위치기반 서비스 외에도 모바일 기기에서 효율적인 상황인지 어플리케이션을 개발할 수 있는 방법론을 제시하였다. 향후연구로는 모듈별 입력변수의 특징에 따라 기억감소함수의 계수를 설정하는 방법을 구체화할 것이다. 이를 통해 단일 BN 추론 방법 이상의 정확한 상황추론 결과를 인식하는 효율적인 모바일 에이전트의 구성이 가능할 것이다.

참 고 문 헌

- [1] R. Vertegaal, C. Dickie and C. Sohn, "Designing Attentive Cell Phone using Wearable Eyecontact Sensors," *CHI Extended Abstracts on Human Factors in Computing Systems*, pp.646-647, 2002.
- [2] N. Eagle, "Machine Perception and Learning of Complex Social Systems," *Ph.D. Thesis, Massachusetts Institute of Technology*, 2005.
- [3] A. Krause, A. Smailagic, and D. P. Siewiorek, "Context-aware Mobile Computing: Learning Context-dependent Personal Preferences from a Wearable Sensor Array," *IEEE Trans. on Mobile Computing*, vol.5, no.2, pp.113-127, 2006.
- [4] G. F. Cooper, "The Computational Complexity of Probabilistic Inference using Bayesian Belief Networks," *Journal of Artificial Intelligence*, vol.42, pp.393-405, 1990.
- [5] K.-S. Hwang, S.-B. Cho, "Landmark Detection from Mobile Life Log using a Modular Bayesian Network Model," *Expert Systems with Applications*, vol.36, pp.12065-12076, 2009.
- [6] M. Marengoni, A. Hanson, S. Zilberstein and E. Riseman, "Decision Making and Uncertainty Management in a 3D Reconstruction System," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol.25, no.7, pp.852-858, 2003.
- [7] B. Brandherm and T. Schwartz, "Geo Referenced Dynamic Bayesian Networks for User Positioning on Mobile Systems," *Lecture Notes in Computer Science*, vol.3479, pp.223-234, 2005.
- [8] Y. Xiang and F. V. Jensen, "Lazy Inference in

- Multiply Sectioned Bayesian Networks Using Linked Junction Forests," *Studies in Fuzziness and Soft Computing*, vol.213, pp.175-192, 2007.
- [9] A. Brogini and D. Slanzi, "On using Bayesian Networks for Complexity Reduction in Decision Trees," *Statistical Methods and Applications*, vol. 19, no.1, pp.127-139, 2009.
- [10] U. Kjaerulff, "Reduction of Computational Complexity in Bayesian Networks through Removal of Weak Dependences," *Proceedings on Uncertainty in Artificial Intelligence*, pp.374-382, 1994.
- [11] F. Bacchus, S. Dalmao, and T. Pitassi, "Algorithms and Complexity Results for #SAT and Bayesian Inference," *IEEE Symposium on Foundations of Computer Science*, pp.340-355, 2003.
- [12] G. Pavlin, et al., "A Multi Agent Systems Approach to Distributed Bayesian Information Fusion," *Information Fusion*, vol.11, no.3, pp.267-282, 2009.
- [13] K. B. Korb., *Bayesian Artificial Intelligence*, Chapman & Hall/CRC, pp.62-68, 2004.
- [14] V. K. Namasivayam and V. K. Prasanna, "Salable Parallel Implementation of Exact Inference in Bayesian Networks," *International Conference on Parallel and Distributed Systems*, vol.1, pp.143-150, 2006.
- [15] C. Huang, and A. Darwiche, "Inference in Belief Networks: A Procedural Guide," *International Journal of Approximate Reasoning*, vol.15, no.3, pp.225-263. 1996.



이승현

2009년 2월 연세대학교 컴퓨터과학과(학사). 2009년~현재 연세대학교 컴퓨터과학과 석사과정. 관심분야는 상황인지, computational finance and economics, 베이지안 네트워크

임성수

정보과학회논문지 : 소프트웨어 및 응용
제 37 권 제 1 호 참조

조성배

정보과학회논문지 : 소프트웨어 및 응용
제 37 권 제 1 호 참조