

모바일 디바이스 상에서의 특이성 탐지를 위한 베이지안 추론 모델

황금성⁰, 조성배
연세대학교 컴퓨터과학과
{yellowg⁰, sbcho}@sclab.yonsei.ac.kr

Bayesian Inference Model for Landmark Detection on Mobile Device

Keum-Sung Hwang⁰, Sung-Bae Cho
Dept. of Computer Science, Yonsei University

요 약

모바일 디바이스에서 얻을 수 있는 로그에는 다양한 개인정보가 풍부하게 포함되어 있으면서도 제약이 많아 활용이 어렵다. 그 동안은 모바일 장치의 용량, 파워의 제약과 정보 분석의 어려움으로 로그 정보를 무시해온 것이 일반적이었다. 본 논문에서는 모바일 디바이스의 다양한 로그 정보를 분석하여 사용자에게 의미 있는 상황(특이성)을 탐지해낼 수 있는 정보 분석 방법을 제안한다. 불확실한 상황에서의 정확성 향상을 위해 규칙/패턴 분석에 의한 특이성 추론뿐만 아니라 베이지안 네트워크를 활용한 확률적인 접근 방법을 활용한다. 이때, 복잡하지 않고 연산이 효율적으로 이루어질 수 있도록 BN을 모듈화하고, 모듈화된 BN의 상호보완적인 확률 추론을 위한 BN 처리 과정을 제안한다. 그리고, 특이성 추출 모듈을 주기적으로 업데이트함으로써 성능을 향상시키기 위한 학습 알고리즘을 소개한다.

1. 서 론

모바일 환경은 여러 가지 면에서 기존의 컴퓨팅 환경과 다른 특성을 가진다. 먼저, 모바일 디바이스는 통화 기록, SMS, 사진, MP3, GPS 등과 같은 다양한 정보를 다루고 수집할 수 있다. 또한, 모바일 디바이스는 개인성이 강한 장비이므로 개인의 기호나 성향에 따라 적응되어 특화될 수 있다. 그리고, 모바일 디바이스는 사용자가 항상 휴대하기 때문에 사용자의 일상정보를 효과적으로 수집하고 이해하여 사용자에게 도움을 줄 수 있다. 이러한 모바일 디바이스의 특성은 사용자 편의를 위한 다양한 서비스 제공의 가능성을 열어 주었으며, 연구 및 개발의 대상으로 많은 관심을 받고 있다.

하지만, 모바일 디바이스는 PC에 비해서 적은 메모리 용량, 적은 CPU 처리용량, 작은 화면 사이즈, 불편한 입력 인터페이스, 제한된 배터리 용량 등의 한계를 가지고 있으며, 변화가 심한 실세계 환경에서 작동하기 때문에 더욱 능동적이고 효과적인 적응 기능이 요구되는 점 등이 개발의 어려움으로 작용하고 있다.

본 논문에서는 모바일 환경에서 수집된 로그 정보를 효과적으로 분석하고 효율적으로 고수준의 의미정보 및 특이성(Landmark, 특별히 기억에 남을 정보)을 추출하기 위한 방법을 제안한다. 제안하는 방법은 모바일 환경에서 발생하는 다양한 불확실성(①실생활의 불규칙성, ②유저 의도 및 감정의 불확실성, ③센서의 불확실성, ④인과 관계의 불확실성)을 효율적으로 다루기 위해 베이지안(Bayesian) 확률 모델을 채택하였으며, 베이지안 확률 모델이 모바일 환경에서 효과적으로 동작할 수 있도록 하기 위해 협력적 모듈 베이지안 네트워크(Cooperative modular Bayesian network) 모델을

제안한다. 또한 베이지안 추론 모델을 단기학습 및 장기학습을 통해 관리하는 방법에 대해서도 소개한다.

2. 관련 연구

로그 정보를 분석하여 향상된 서비스를 제공하고자 하는 시도는 이미 존재한다. Andreas Krause 등은 모바일 장치에서 수집된 센서 및 로그 정보를 클러스터링하고 유저의 기호를 반영하는 컨텍스트에 매칭하도록 학습시켜 유저의 상황 예측 및 서비스 제공을 하였다[1]. 이때 컨텍스트에 대한 서비스 선택 방법으로 베이지안 네트워크(BN)를 사용하였다. E. Horvitz 등은 PC에서 수집된 로그를 바탕으로 사람의 인지 행동을 베이지안 네트워크로 자동 모델링하여 특이성 (Landmark) 을 탐지하고 예측하는 방법을 제안하였다 [2]. 하지만 이러한 방법들은 용량 및 파워가 제한된 모바일 환경에서 그대로 사용하기엔 제약이 많다. 따라서 모바일 환경에 좀더 최적화된 방법이 요구된다.

3. 모바일 로그에서의 특이성 탐지

본 논문에서 모바일 환경에서 수집된 로그를 분석하여 특이성을 추출하는 과정은 그림으로 표현하면 그림 1과 같다. 모바일 장치에서 수집된 다양한 로그는 전처리를 거쳐 특이성 추론 모듈에 의해 특이성이 결정된다. 패턴 인식이나 간단한 규칙 추론은 규칙 모듈에서 수행되고, 복잡한 확률적 추론은 BN 모듈에서 수행된다. 여기서 베이지안 네트워크는 노드의 연결 관계를 표현하는 방향성 비순환 그래프(DAG: directed acyclic graph) 형태를 가지고 있으며, 이 구조에 따라 정의된 조건부 확률 테이블(CPT: conditional probability table)에 의해 적은

비용으로 많은 확률 관계를 효율적으로 표현 및 계산할 수 있는 모델이다[3]. 그림 2는 실제로 설계된 BN의 예를 보여준다.

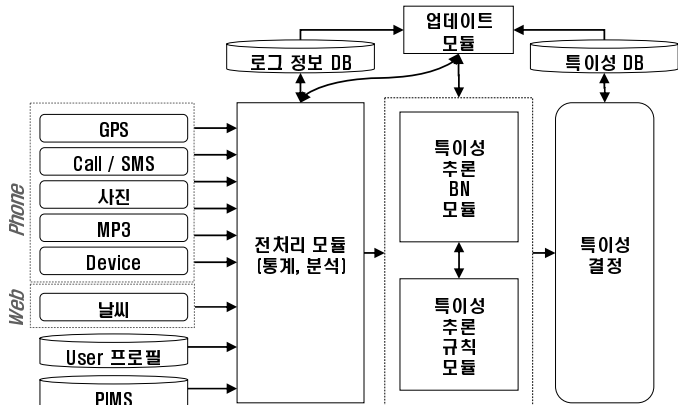


그림 1. 모바일 로그에서의 특이성 추출 과정

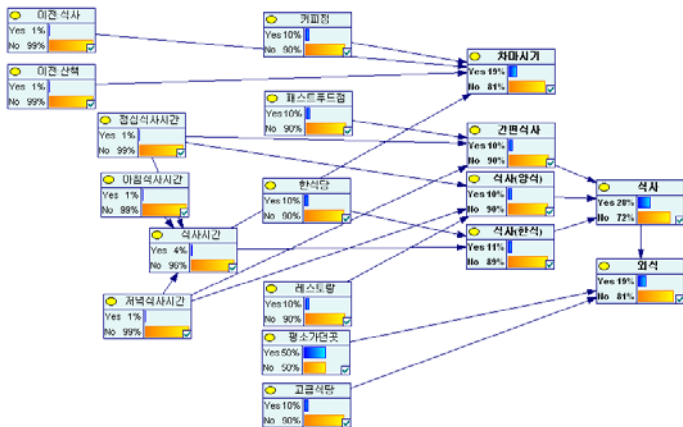


그림 2. 본 논문에서 사용된 '외식지역 행동' 특이성 추론 BN

3.1. 협력적 모듈 베이지안 네트워크

본 논문에서 제안하는 베이지안 네트워크는 기존의 방법과 다른 점이 크게 두 가지이다. 첫 번째, 확률 추론 모델을 분할된 도메인에 따라 모듈화 하여 사용한다. 베이지안 네트워크 특성상 노드와 연결의 수가 많아질수록 더 많은 컴퓨팅 파워를 요구하게 된다. 특히, 하나의 노드에 여러 원인 노드가 연결될 경우 복잡도가 αk^N (k 는 상태의 수, N 은 부모의 수)에 비례하기 때문에 BN이 작을수록 모바일 환경에 유리하다.

두 번째, 모듈화된 BN에서의 상호 인과성을 반영하기 위해 그림 3과 같은 2단계의 추론 과정을 거친다. 이때 특이성 증거를 좀더 정확히 반영하기 위해 가상 노드 기법을 사용하였다. 이 방법은 확률적인 증거를 반영하기 위해 가상 노드를 추가하여 노드의 확률값(CPV: conditional probability value)을 통해 증거의 확률을 적용하는 방법이다[2].

3.2. 특이성 부가 정보 분석

BN 추론 모듈에서 추출되는 특이성의 확률값을 통해 특이성의 신뢰도를 알 수 있으며, 연결관계를 통해 특이성이 추론된 배경 및 인과 관계를 알 수 있다. 이때 인과성의 강도를 구분 짓고 계산하기 위해 NoisyOR 가중치를 계산하여 사용하였다. NoisyOR 가중치는 설계 및 학습 비용을 줄이기 위한 베이지안 확률 테이블 계산 방법의 하나인 NoisyOR BN 모델에서 사용되는 원인 별 조건부 확률의 연결 강도 S 를 나타내며 수식 (1)과 같이 계산된다.

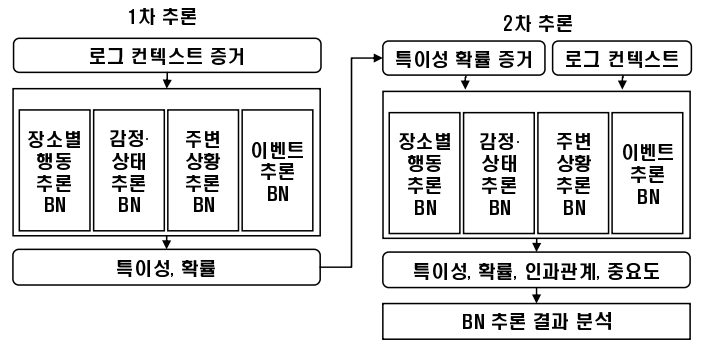


그림 3. 협력적 모듈 베이지안 네트워크의 2단계 추론 과정. (베이지안 추론에 의해 나온 결과를 다시 증거로 사용한다.)

$$S_i = (p_i / 0.5) - 1.0 \tag{1}$$

여기서 p_i 는 원인 x_i 가 활성화된 경우의 조건부 확률값을 나타낸다.

$$p_i = \Pr(y | \bar{x}_1, \bar{x}_2, \dots, x_i, \dots, \bar{x}_{n-1}, \bar{x}_n) \tag{2}$$

3.3. 추론 모듈의 업데이트

모바일 환경에서 사용자에게서 받은 피드백을 통해 특이성 추론 모델을 업데이트 하기 위한 방법으로 표 1과 같은 학습 단계를 제안한다. 사용자의 피드백에 의해 얻어진 데이터를 DB에 수집하고 이를 단기 학습과 장기 학습으로 나누어 학습하는 방법이다.

표 1. 추론 모듈 학습 방법

종류	학습 시기	저장공간	대상	학습 알고리즘
단기 학습	짧은 시간 뒤	short-term DB	규칙	통계적 패턴 분석
			BN	확률 파라미터 적응
장기 학습	장기간 데이터 수집 후	long-term DB	BN	Constrained K2 Learning Algorithm

단기 학습의 경우 규칙 학습은 통계적인 분석에 의해 파라미터를 업데이트 하는 방법을, BN 학습은 확률 파라미터만 업데이트 하는 방법을 제안한다. 확률 파라미터 적응을 위한 수식은 다음과 같다.

$$\Delta P(x|y) = -\eta \frac{1}{N} \sum_n \left(\frac{\partial \xi(n)}{\partial P(x|y)} \right) \tag{3}$$

여기서 $\xi(n)$ 는 n 번째 데이터에 대한 Least-square 에러 값이며, N 은 데이터 크기, n 는 학습률을 나타낸다[4].

장기 학습의 경우에는 데이터가 충분히 모였기 때문에 BN의 구조 학습도 수행하였다. 이 경우 증거 노드와 특이성 노드의 방향성을 유지하기 위해 레벨 수준에 따른 학습이 가능한 BN 제한 학습 방법을 사용하였다[5]. 이때 과적응 현상을 방지하기 위해 그림 4와 같은 과정을 통해 선택된 구조를 사용한다.

4. 실험 및 결과

본 논문에서 사용하는 로그 데이터는 GPS, Call, SMS, 사진 촬영, MP3 청취, 기기 충전 로그 및 웹에서 수집된 날씨 정보에서 추출된 로그 컨텍스트 데이터이다. 그리고 설계된 BN은 총 39개(장소 별 행동 추론 BN 18개, 감정·상태 추론 BN 9개, 주변상황 추론 BN 5개, 이벤트 추론 BN 2개)이며 노드의 총 수는 587개, 그 중 특이성 노드의 수(중복 포함)는 224개이다.

제안하는 특이성 추론 모델의 성능을 관찰하기 위해

시나리오를 설정하고 실험을 수행하였다. 그림 5는 실험에서 사용된 시나리오를 나타낸다. 실제 실험에 사용된 BN은 {외식, 사진, 이동행동, 자연, 즐거움, 집}의 6개이다. 표 2는 이 6개의 BN에 증거로 사용될 로그 컨텍스트를 나타낸다. 그림 6은 표2의 로그 컨텍스트를 하루 분량 생성한 뒤 이를 이용해 특이성을 추론한 결과를 나타낸다. 해당 시간에 특이성의 확률이 높아지는 것을 관찰할 수 있다.

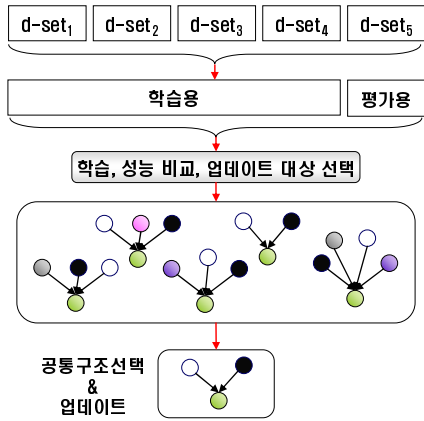


그림 4. 학습에 의한 베이저안 네트워크 업데이트, 교차 학습을 한 뒤 성능이 좋아진 특이성의 공통 구조 선택 및 업데이트 함.

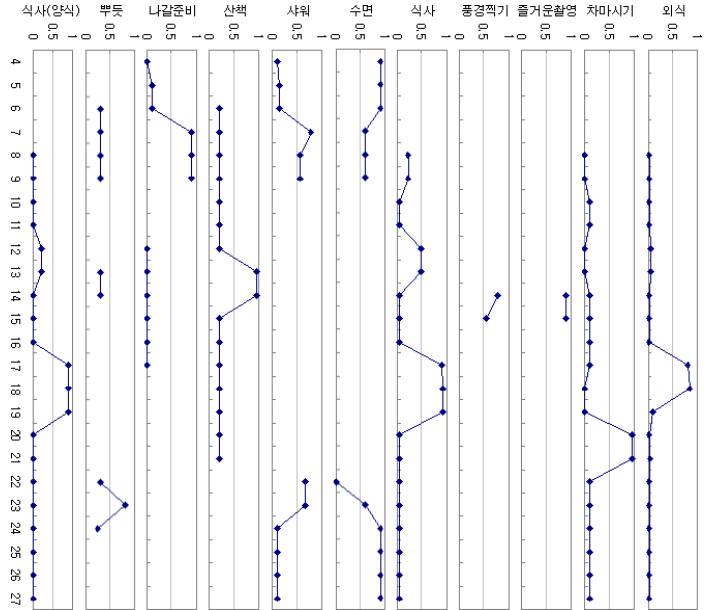


그림 6. 시나리오에서 의도한 11개의 특이성 확률 변화 관찰. 11개의 특이성에 대해 04시~27시(다음 날 새벽 3시)까지의 특이성 확률 변화 표시. 해당 BN에 관련 증거가 들어온 경우에만 그래프로 표시됨.

5. 결론 및 토의

본 논문에서는 모바일 디바이스 환경에 유리한 특이성 추론 모델 구조 및 학습 방법을 제시하였다. 모바일 환경에서의 효율적인 작동을 위해 모듈화된 구조를 제시하였으며, 모듈화된 상태에서의 유기적인 연결을 위해 가상 노드 개념을 이용해서 확률 증거 연결을 적용한 2 단계 추론 방식을 소개하였다. 추가된 데이터에 의한 단기학습 및 장기학습 방법을 제시하여 성능을 향상시킬 수 있는 방법도 제시하였다. 또한, 가상 데이터를 이용한 실험에서는 의도했던 특이성이 잘 추출됨을 보였다. 현재 이 연구는 계속 진행 중이며, 향후에는 좀더 넓은 실제 도메인에서 작동하는 특이성의 성능 평가 및 학습의 유용성에 대한 검증이 필요할 것이다.

감사의 글

본 연구는 정보통신부 및 정보통신연구진흥원의 대학 IT 연구센터 지원사업의 연구결과로 수행되었음, IITA-2005-(C1090-0501-0019).

• 참고 문헌

[1] A. Krause, A. Smailagic, D. P. Siewiorek, "Context-aware mobile computing: Learning context-dependent personal preferences from a wearable sensor array," *IEEE Trans.*, vol. 5, no. 2, pp. 113-127, 2006.
 [2] E. Horvitz, S. Dumais, P. Koch. "Learning predictive models of memory landmarks," *CogSci 2004: 26th Annual Meeting of the Cognitive Science Society*, 2004.
 [3] K. B. Korb and A. E. Nicholson, *Bayesian Artificial Intelligence*, Chapman & Hall/CRC, 2003.
 [4] B.P.L. Lo, S. Thiemjarus, G.-Z. Yang, "Adaptive Bayesian networks for video processing," *Int. Conf. on Image Processing*, vol.1, no.1, pp.889-892, 2003.
 [5] K.-S. Hwang, and S.-B. Cho, "Constrained learning method of Bayesian network structure for efficient context classification," *Proc. of KISS*, vol. 31, no. 2, pp. 112-114, 2004.

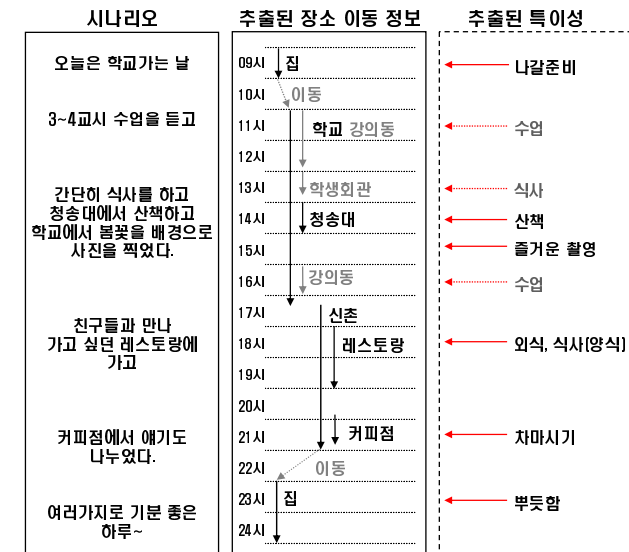


그림 5. 실험을 위한 시나리오. 대학생의 일상 생활을 가정함.

표 2. 로그 컨텍스트 리스트.

로그 컨텍스트	로그 컨텍스트	로그 컨텍스트
1 2시간이내:외출	12 오전	23 좋은날씨
2 강의동	13 외출전	24 즐거움많은하루
3 낮	14 이동중	25 집
4 레스토랑	15 일광시간	26 충전중
5 사진 많이찍음	16 자기전2시간이내	27 커피점
6 사진찍음	17 자연지역	28 평소가던 곳
7 식사시간	18 잘시간	29 학교지역
8 신촌	19 장치사용없음	30 학생회관
9 아침식사시간	20 저녁식사시간	31 GPS잡힘
10 아침식사전	21 저녁식사후	
11 야외활동성	22 점심식사시간	