

하루 일과 계획을 위한 스마트폰-사용자 상호작용 기반 지속 발전 가능한 사용자 맞춤 위치-시간-행동 추론 방법

이범진^{1○}, 김지섭¹, 류제환², 허민오¹, 장병탁¹

¹서울대학교 컴퓨터공학부

²서울대학교 뇌과학협동과정

{bjlee, jkim, jhryu, moheo, btzhang}@bi.snu.ac.kr

Smartphone-User Interactive based Self Developing Place-Time-Activity Coupled Prediction Method for Daily Routine Planning System

Beom-Jin Lee^{1○}, Jiseob Kim¹, Je-Hwan Ryu², Min-Oh Heo¹, Byoung-Tak Zhang¹

¹School of Computer Science and Engineering, Seoul National University

²Interdisciplinary Program in Neuroscience, Seoul National University

요 약

과거 어플리케이션 다양성만 지향하던 시대에서 스마트폰의 고도화된 센서와 기계학습을 결합한 지능형 서비스가 각광받고 있다. 이러한 경향을 반영하여 본 논문에서는 스마트폰에 축적된 사용자의 라이프로그 데이터에서 의미있는 정보를 추출하고, 추출한 정보를 통해 체화된 인지(Embodied Cognition)개념의 스마트폰-사용자 상호작용 사용자 맞춤 위치-시간-행동 추론 기법을 제안한다. 제안 방법은 사용자의 라이프로그데이터를 DPGMM (Dirichlet Process Gaussian Mixture Model) 클러스터링 기법으로 사용자 주요 관심지역 POI(Point of Interest)를 추출하고, 강화학습의 한 종류인 POMDP(Partially Observable Markov Decision Process)를 사용하여 사용자의 위치-시간-행동을 추론 한다. 제안 방법으로 구현한 사용자 맞춤 일과 계획 시스템의 추론된 일과 계획은 약 70% 이상의 성능 보였으며, 지능형 서비스의 새로운 방향을 제시하고 있다.

1. 서 론

스마트폰의 대규모 시장성으로 인한 다양한 스마트폰의 보급과 스마트폰의 내장된 고성능 센서를 활용한 위치기반 서비스가 고도화 되고 있다. 과거 GPS 센서만을 이용한 서비스에서 발전된 종래기술은 과거 서비스의 문제점을 해결하려는 시도로 사용자의 스마트폰 사용 내역을 가공한 사용자 프로파일링[1-3]을 활용하여 서비스를 제공하거나 기계학습의 확률모델[3-8]을 사용하여 저수준 모바일 데이터와 고수준 행동간 연관규칙을 찾고 행동인식 추론을 하는 서비스를 제공한다.

기존 기계학습 기법들로는 나이브 베이즈(Naïve Bayes)[4], 베이지안 네트워크(Bayesian Network)[5]와 같은 순차적 의존성을 고려하지 않는 모델을 사용하는 반면, HMM(Hidden Markov Model)[6], 동적 베이지안 네트워크(Dynamic Bayesian Network, DBN)[7]처럼 순차적 의존성을 고려한 모델을 사용하기도 한다. 그 외 데이터를 벡터 양자화(vector quantization), KNN(K-Nearest Neighbor)[8]와 같은 양자화(Quantize)기법과 확률모델을 같이 사용하는 기법들도 존재한다. 다양한 시도들이 좋은 결과를 보이고 있지만 기존 방법들은

일괄처리(batch) 방식으로 학습하기 때문에 변화를 적용하는 모델의 재학습을 위해선 축적된 로그 데이터를 이용하여 다중의 계산적 반복절차가 필수불가결하고 모델과 사용자가 직접 상호작용하는 방법은 고려하지 않기에 해당 위치-시간별 사용자의 변화 행동은 추론하지 못하고 있다.

이러한 문제점을 해결하기 위해서 본 논문에서는 사용자의 행동을 추론할 수 있는 단위의 POI를 추출하는 점증적 클러스터링 기법과 사용자의 라이프로그를 모두 기록하고 사용자의 의도가 실시간으로 반영되어 추후 사용자의 의도를 추론 할 수 있는 스마트폰-사용자 일체화 개념을 도입한 강화학습 모델에 추출된 POI를 적용하여 사용자 맞춤 행동 예측 서비스를 제공, 지속적으로 사용자 피드백에 반응하여 성능 향상이 가능한 일과 계획 시스템을 제안하였다.

2. 시스템 개요 및 실험 방법

본 논문에서 제시하는 시스템의 흐름도는 그림 1과 같다. 시스템에서 DPGMM을 이용한 사용자 POI 클러스터링과 POMDP를 이용한 사용자 의도 행동 추론 모델을 학습하기 위해 다양한 직업군의 데이터 수집자

7명을 대상으로 40일간 라이프로그 데이터와 피드백 데이터를 수집하였다. 표 1은 라이프로그 데이터와 피드백 데이터의 사용자 별 수집 현황이며 라이프로그 데이터와 피드백 데이터는 표 2와 같은 형식으로 수집되었다. 그리고 사용자의 피드백데이터는 총 17개의 의도로 구분하였고 표 3에 수록되었다.

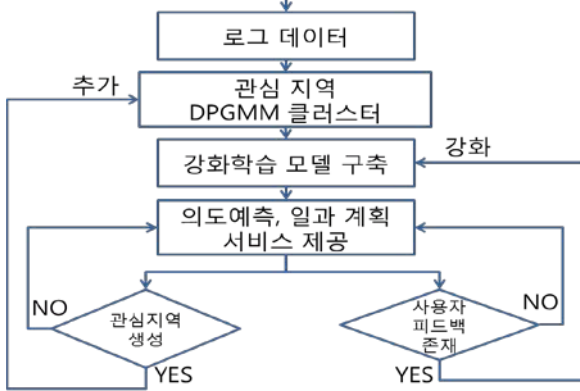


그림 1. 사용자 맞춤 위치-시간-행동 추론 및 일과 계획 시스템

실험자	라이프로그	피드백
A	373	321
B	1049	302
C	1789	821
D	485	358
E	1245	485
F	13039	652
G	6273	373

표 1. 데이터 수집

라이프로그 형식

날짜-시간	디바이스 정보	어플리케이션 정보	패키지 정보	패키지 카테고리	사용시간	현재위치 좌표
-------	---------	-----------	--------	----------	------	---------

사용자 피드백 형식

시간	좌표	의도 정답 여부1	의도 정답 여부2	의도 정답 여부3	의도
----	----	-----------	-----------	-----------	----

표 2. 데이터 형식

FOODIE, HAD FUN, HOTEL STAY, AIRPORT, TRANSPORT, SHOPPING, MEDICAL, SOME WORK, NIGHT LIFE, MOVIE, ENTERTAINMENT, WORKOUT, ACADEMIA, ART LOVER, PRAYER, CONVENTION, RESIDENCE

표 3. 정의한 17개 사용자 의도

2.1 DPGMM 클러스터링 기법

제안하는 시스템에서 클러스터링을 사용하는 가장 큰 목적은 사용자의 POI를 추출하는데 있다. POI는 사용자의 잦은 방문과 해당 지역에서 스마트폰을 가장 많이 사용하는 지점이라고 정의하게 되는데 이 POI는 사용자 별로 다양하게 분포하게 된다. 기존 정적 클러스터링 방법은 클러스터의 개수를 설계자가 직접 지정해 주어야 하는 문제점이 있다. 하지만 본 시스템에서 사용하는 DPGMM은 자동적으로 클러스터의

개수를 찾고 클러스터링을 함으로써 다양한 사용자들의 기호에 맞는 POI를 추출 할 수 있다. 아래는 DPGMM의 클러스터링 기법의 수식이다.

$$\text{Existing Cluster} : p(z_i = m) \sim p(y_i | \theta_i) * \frac{n_m}{N - 1 + \alpha}$$

$$\text{New Cluster} : p(z_i = M + 1) \sim \int p(y_i | \theta_i) d\theta * \frac{\alpha}{N - 1 + \alpha}$$

z_i : i번째 데이터 레이블

y_i : i번째 데이터

N : 총 데이터 개수

m : 레이블 인덱스

n_m : m 에 속해있는 데이터 개수

Θ_m : m 파라미터

α : Dirichlet 파라미터

2.2 POMDP 기반 위치-시간-행동 추론 모델

기존 스마트폰을 이용한 지능형 서비스는 사용자의 시간별 행동에 대한 개별적인 추론 결과를 제시하거나 단편적 행동 패턴을 제시했다. 하지만 본 논문에서는 그림 2와 같은 POMDP 강화학습법을 사용하여 사용자가 의도하는 일련의 행동 순서를 추론할 수 있는 모델로 사용되고 사용자 최적의 행동 일과(정책)를 PBVI(Point-based Value Iteration) 알고리즘 기반으로 추론한다. 제안하는 POMDP 모델 M 은 아래와 같이 구성되었다.

$$M = \langle S, A, Z, St, O, R, B \rangle$$

L (지평 길이): 24 (하루 24시간의 1시간 단위)

S (상태): 현재 사용자가 의도하는 행동 집합

A (행동): 다음 사용자가 의도하는 행동 집합

O (관찰 값): Time(시간대역), 클러스터링 된 개인 관심지역

St (상태 전이): $P(s_t | a_{t-1}, s_{t-1})$

R (보상): 사용자 시간, 의도 별 변화 보상 $R(s, a)$

$b(s)$: 상태 확신 확률

최적정책 π :

$$\pi_V(b) = \operatorname{argmax}_a R(b, a) + \gamma \sum_{o \in \Omega} \Pr(o|b) V(b^{a,a})$$




그림 2. 제안하는 POMDP 모델

본 논문이 다루는 문제는 모델이 사용자가 현재 의도하는 행동에 대해 정확한 상태를 알 수 없는 상황이 존재하고, 시간과 POI에 따라 그 의도가 변화할 수 있기 때문에 상태의 확신 정도에 의해 사용자의 상태를 판별하는 POMDP 모델을 사용하였고, 현재 의도에서 다음 의도를 선택하는데 사용되는 보상은 사용자의 피드백에 맞추어 자동적으로 업데이트 되어 사용자에게 가장 적합한 위치-시간-행동 추론을 수행할 수 있다.




그림 3. 사용자 G의 DPGMM 클러스터 결과

3. 실험 결과 및 토의

실험은 수집자들이 실제 자주 방문하는 곳과 DPGMM을 이용하여 추출한 POI를 비교해보고, 추출된 POI에 따른 POMDP의 사용자 최적 하루 일과 추론 결과를 실제 사용자의 하루 일과에 대해 수집한 피드백 데이터와 얼마나 일치하는지 비교해 보았다. 그리고 사용자의 피드백 데이터의 변화에 따라 최적 일과 추론 또한 변함을 볼 수 있다.

3.1 DPGMM 클러스터링 결과

그림 3과 같이 사용자가 POI로 생각되는 피드백 지점들(그림 3 왼쪽)과 라이프로그 데이터를 DPGMM으로 클러스터링한 결과(그림 3 오른쪽)가 상당히 일치하는 것을 볼 수 있다. 그리고 추출된 POI는 비슷한 의도를 갖는 지점들을 같은색으로 클러스터링한 결과를 볼 수 있다. DPGMM의 α 값은 1로 했으며 가장 최적의 값을 적용하여 실험한 결과이다.

실험자	A	B	C	D	E	F	G
개수	15	15	10	15	10	20	15

표 4. 사용자별 POI 클러스터 개수

3.2 POMDP 추론 결과

표 5에서는 실제 사용자의 순차적 위치 이동 피드백과 POMDP로 추론한 순차적 의도 예측 결과를 비교한 결과이다. 모든 사용자의 평균은 약 70퍼센트이며, F사용자와 G사용자의 경우 데이터 수집에 문제로 인해 성능의 저하를 보이고 있다. 고정된 위치와 시간에서 POMDP로 사용자 별 최적 하루 일과의 결과와 하루 의도 피드백을 비교한 것은 표 6에서 볼 수 있다. 약 50%의 성능을 보이고 있으며 표5의 결과와 표 6의 결과를 합친다면 사용자의 하루 일과를 계획하는데 충분한 가능성을 보이고 있다.

3.3 토의

본 논문에서는 확률모델만을 기반으로 스마트폰에서 지능형 서비스 제공하는 기존 방법과는 달리 강화학습법을 적용하여 스마트폰과 사용자가 직접 상호작용 가능한 지능형 서비스의 방법을 제시하였다. 본 방법은 사용자의 피드백을 이용하여 사용자의 시간대별 변화하는

행동을 모델에 적용하여 즉각적 사용자 맞춤 서비스 제공이 가능하다. 본 방법을 가장 최적으로 사용할 수 있는 방법은 사용자 하여금 서비스의 사용 횟수증가와 사용자가 서비스를 사용함으로써 입력되는 로그를 사용자의 의도로 추론 할 수 있는 피드백으로 가공 할 수 있는 방법을 고안한다면 최적의 서비스를 제공 할 수 있다.

실험자	A	B	C	D	E	F	G
정확도	84	85	70	60	84	44	58

표 5. POMDP 순차적 위치 변화 예측 정확도(%)

실험자	A	B	C	D	E	F	G
정확도	67	69	21	60	26	44	44

표 6. POMDP 고정적 위치의 하루 일과 예측 정확도(%)

Acknowledgement

본 논문은 2014년도 삼성전자의 지원을 받아 수행된 연구이며, 정부(미래창조과학부 및 산업통상자원부)의 재원으로 한국연구재단(NRF-2010-0017734-Videome)과 정부(산업통상자원부)의 재원으로 한국산업기술평가관리원 지원(KEIT-10035348-mLife, KEIT-10044009)을 일부 받았음.

참고문헌

- [1] G. Hache, E.D. Lemaire, N. Baddour "Mobility change-of-state detection using a smartphone-based approach," Proc.of IEEE International Workshop on Medical Measurements and Applications (MeMeA), pp.43-46, 2010
- [2] H. Verkasalo, "Analysis of smartphone user behavior," ICMB-GMR2010, pp 258-263, 2010
- [3] A. Papliatseyeu, and M. Oscar, "Mobile habits: Inferring and predicting user activities with a location-aware smartphone," In 3rd Symposium of Ubiquitous Computing and Ambient Intelligence 2008, vol. 51, pages 343-352, 2009
- [4] B. Longstaff, S. Reddy, D. Estrin, "Improving activity classification for health applications on mobile devices using active and semi-supervised learning," Pervasive Computing Technologies for Healthcare, pp. 1-7, 2010
- [5] G. M. Weiss, J. Lockhart, "The impact of personalization on smartphone based activity recognition," AAAI Workshop on activity Context Representation: Techniques and Languages, 2012
- [6] Y. Lee and S.-B. Cho. "Activity recognition using hierarchical hidden markov models on a smartphone with 3D accelerometer." Hybrid Artificial Intelligent Systems. Springer Berlin Heidelberg, 460-467, 2011
- [7] S.-I. Yang, J.-H. Hong, S.-B. Cho, "Activity recognition based on multi-modal sensors using dynamic Bayesian networks," J. KIISE: Computing Practices and Letters 15(1), 72-76, 2009
- [8] S. Kaghyan, and H. Sarukhanyan, "Activity recognition using K-nearest neighbor algorithm on smartphone with tri-axial accelerometer," International Journal "Information Models and Analyses, Vol.1, 2012