

2단계 이동패턴 모델링을 이용한 사용자의 의도 추론

박문희⁰ 홍진혁 조성배

연세대학교 컴퓨터과학과

{moonypark⁰, hjinh}@sclab.yonsei.ac.kr, sbcho@yonsei.ac.kr

User's Intention Inference by Two Stage Movement Pattern Modeling

Moon Hee Park⁰, Jin-Hyuk Hong, Sung-Bae Cho

Dept. of Computer Science, Yonsei University

요 약

최근 이동통신 기술의 급격한 발전과 PPC(Pocket PC), 노트북 등의 휴대단말기의 보급 확산에 따라 위치기반 서비스(Location Based Service:LBS)가 주요한 응용분야로 부상하고 있다. 위치 정보에 대한 정확한 위치 추적 및 활용 방안에 대한 활발한 연구가 진행되고 있지만, 대부분 제공되는 서비스는 현재 사용자의 위치에 기반한 정적인 서비스를 제공하는 초보적인 단계에 있다. 이동경로는 사용자의 성향이나 상태를 반영하기 때문에 사용자의 이동패턴을 예측하거나, 사용자의 현재 상태를 추론하는데 도움을 줄 수 있다. 본 논문에서는 이동패턴에 따른 사용자의 의도를 예측하여 개별화 된 서비스 제공을 위해, RSOM(Recurrent Self Organizing Map)과 마르코프 모델을 단계적으로 구성하여 사용자의 이동패턴을 모델링하는 방법을 제안한다. 실제 연세대학교 캠퍼스 내에서 실제 대학원생의 생활을 모델로 GPS(Global Positioning System)데이터를 수집하여, 이동패턴을 모델링하고 개별화된 서비스를 제공함으로써 제안하는 방법의 유용성을 검증하였다.

1. 서 론

최근 모바일 컴퓨팅의 발전으로 시간과 장소에 구애받지 않고 컴퓨팅 자원을 이용할 수 있게 되었다. 특히 위치정보를 이용하여 서비스를 제공하는 LBS는 국내외에서 지속적인 성장 가능성을 가진 기술이며, 위치 정보에 대한 정확한 위치 추적 및 활용 방안에 대한 활발한 연구가 진행되고 있다.

기존 위치기반서비스(LBS)는 정적인 사용자의 위치에 기반하며 교통정보, 미팅, 채팅 및 게임 등의 서비스를 제공하는 수준에 머물러 있었다. 하지만 동일한 위치에서도 다양한 활동이 가능하기 때문에, 사용자의 성향이나 현재 상태를 고려하여 그에 적절한 서비스를 명시적 요청 없이 제공하는 기술의 필요성이 요구된다.

본 논문에서는 사용자의 위치이동패턴을 학습하여, 다음 이동경로를 예측하여 사용자의 의도를 추론하고 상태와 이동목적을 추론하고 서비스를 자동으로 제공하는 기법을 제안한다. 제안하는 방법은 적절한 시퀀스 데이터 모델링에 적절한 RSOM과 마르코프 모델을 단계적으로 구성한다.

2. 관련연구

M. Albanese 등은 GIS(Geographical Information System)을 이용하여 지속적으로 사용자의 위치정보를 기록하고, 이를 바탕으로 박물관이나 고대 유적지를 방문할 때, 사용자의 개인의 취향에 맞는 유물의 관람을 추천하기 위해 사용자 행동을 예측하는 방법을 제안하였다[5]. D. Patterson 등은 이를 위해 GPS 신호로 사용자 위치를 추적하고 베이지안 네트워크로 GPS 신호를 모델링하여 현재 사용자가 이용하고 있는 이동수단을 예측하는 방법을 제안하였다[2]. D. Ashbrook 등은 GPS 데이터를 k -means 알고리즘을 사용해 클러스터링하여 사용자가 오래 머무르는 유효한 위치를 찾아내고 이 위치간의 이동을 마르코프 모델을 사용하여 모델링 하여 사용자 위치를 예측하도록 하였다[3]. 하지만 사용자가 머무르는 위치만을 사용하기 때문에 이동 중 경로에 따른 예측이 불가능하다.

3. 제안하는 방법

본 논문에서는 외부환경에서의 서비스를 전제하여, GPS 장비를 이용하여 사용자의 이동 경로를 수집하였다. 제안하는 방법은 그림 1과 같이 4개의 단계로 구성된다. 측정단계는 GPS 센서를 이용하여 사용자의 이동경로 데이터를 수집한다. 발견단계에서는 시퀀스 데이터의 처리에 적합한 RSOM을 이용하여 수집된 데이터의 특징을 16×16 맵으로 특징을 축약한다. 학습단계는 발견단계에서 맵으로 구성된 각 지역문제를 마르코프 모델을 이용하여 학습한다. 마지막으로 실행단계는 이렇게 학습된 지역모델을 바탕으로 하여, 입력된 새로운 이동패턴을 평가하고 사용자의 현재 상황을 추론하여 가장 적절한 서비스를 제공한다.

3.1 RSOM을 이용한 이동패턴 분류

RSOM은 시퀀스 데이터의 처리에 적합하도록 SOM을 변형시킨 것으로 기본적인 SOM의 장점들을 가진다[4]. SOM은 비교사학습(unsupervised learning)을 하기 때문에 사전지식이 없이도 유사한 이동패턴들의 집합을 발견할 수 있어 사용자의 간섭 없이 일상적인 이동패턴을 군집화 할 수 있다. 또한 시퀀스 입력에 따른 최적합 노드(Best matching unit)의 변화 과정은 이동패턴의 상태 변화로 볼 수 있으므로 GPS 데이터 대신 이를 학습하여 문제의 복잡도를 감소시킨다. 사용자의 이동 중에 수집된 GPS 데이터 시퀀스들이 RSOM의 입력으로 사용되며 한 개의 시퀀스는 한 번의 이동을 나타낸다. RSOM의 학습 알고리즘은 그림 2와 같은 과정을 가진다.

먼저 코드북 벡터 $w_i(0)$ 을 임의의 난수를 할당하여 초기화한다. 경쟁(competition)단계에서는 $x(n)$ 를 시퀀스의 n 번째 데이터, α 를 현재 데이터에의 가중치, $w_i(n)$ 을 i 번째 노드의 가중치라고 할 때, 시퀀스의 n 번째 데이터에서 출력층의 i 번째 노드의 출력값 $y_i(n)$ 을 다음과 같이 계산한다.

$$y_i(n) = (1 - \alpha)y_i(n-1) + \alpha(x(n) - w_i(n)) \quad (1)$$

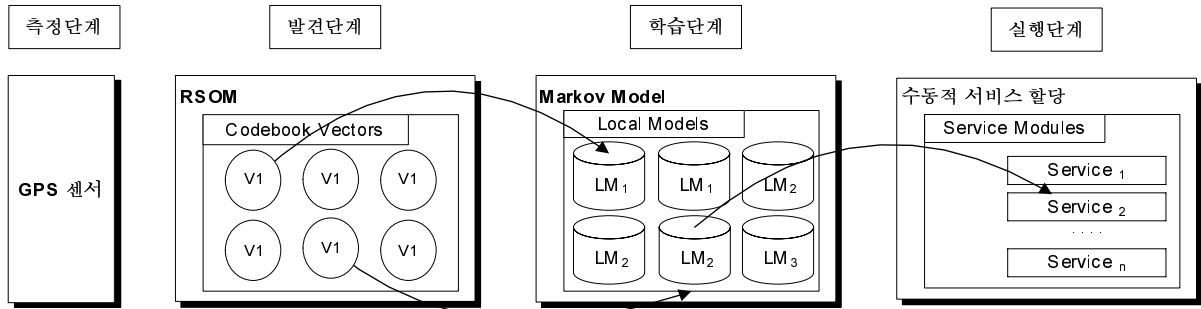


그림 1. 제안하는 방법의 개요

이때 바로 전 데이터 값의 출력 노드의 값 $y_i(n-1)$ 도 반영하여 데이터 사이의 상태정보를 유지한다. 시퀀스의 n 번째 단계에서 입력 시퀀스와 가장 가까운 최정합 노드 $b(n)$ 은 다음과 같이 계산한다.

$$b(n) = \arg \min_{i \in V_M} y_i(n) \quad (2)$$

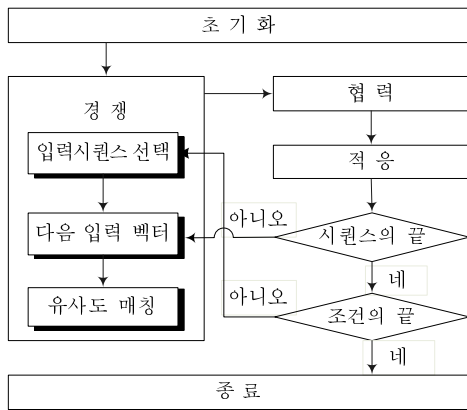


그림 2. RSOM의 분류 과정

적응단계에서의 가중치 $w_i(n+1)$ 은 경쟁단계에서 연산된 $b(n)$ 을 이용하여 이웃반경 함수 $h(b(n), i)$ 을 계산하고, $\gamma(n)$ 을 학습률이라고 할 때 다음과 같은 식을 통해 갱신한다.

$$w_i(n+1) = w_i(n) + \gamma(n)h(b(n), i)y_i(n) \quad (3)$$

이러한 과정을 거쳐 한 개의 입력 시퀀스의 처리가 끝나면 모든 출력 노드의 값을 0으로 설정한 후 새로운 데이터로 위의 과정을 출력층의 변화가 없을 때까지 반복한다. GPS 데이터 시퀀스는 가장 마지막 최정합 노드에 따라 클러스터링 되고 시퀀스 데이터 입력에 따른 최정합 노드 변화 시퀀스 $B = b(1), b(2), \dots, b(N)$ 의 집합은 지역 데이터 집합으로 사용된다.

3.2 Markov model을 이용한 지역모델 학습

RSOM을 이용해 지역 데이터 집합으로 구분된 사용자 이동 패턴은 마르코프 모델에 의하여 학습된다. RSOM의 출력 노드수 만큼의 지역 모델이 마르코프 모델을 이용하여 만들어진다. 마르코프 모델은 초기 상태 분포 Q 와 상태 전이 확률 분포 행렬 P 로 이루어진다. 시간 t 의 상태 i 에서 시간 $t+1$ 의 상태 j 로 전이 될 확률을 P_{ij} 라고 할 때 상태 전이 확률 행렬 P 는 다음과 같이 정의되는데 한 상태에서 다른 상태로 전이될 확률을 모두 합하면 1이 된다.

$$P = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1n} \\ p_{21} & p_{22} & \dots & p_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ p_{n1} & p_{n2} & \dots & p_{nm} \end{bmatrix} \quad (4)$$

$$\sum_{j=1}^{i=n} p_{ij} = 1 \quad (5)$$

시간 0에서 상태 i 가 될 확률을 q_i 라고 할 때 초기 확률 분포 Q 는 다음과 같다.

$$Q = [q_1 \quad q_2 \quad \dots \quad q_n] \quad (6)$$

마르코프 체인 모델의 학습은 데이터로부터 상태 전이 확률 분포 행렬과 초기 확률 분포를 얻어내는 과정이다. 시간 0부터 $n-1$ 까지의 상태변화 시퀀스 X_0, \dots, X_{n-1} 가 학습 데이터로 주어졌다고 할 때 다음과 같은 식에 의해 P 와 Q 를 얻어낼 수 있다.

$$p_{ij} = \frac{N_{ij}}{N_i} \quad \begin{matrix} N_{ij}: \text{시퀀스중 상태 } i \text{에서 } j \text{로의 전이 회수} \\ N_i: \text{시퀀스중 상태 } i \text{가 나타난 회수} \end{matrix} \quad (7)$$

$$q_i = \frac{N_i}{N} \quad \begin{matrix} N: \text{모든 관찰시퀀스의 수} \\ N_i: \text{시퀀스중 상태 } i \text{가 나타난 회수} \end{matrix} \quad (8)$$

주어진 모델로부터 관찰된 상태변화 시퀀스 X_0, \dots, X_T 가 나올 확률 $P(X_0, \dots, X_T)$ 는 다음과 같이 얻어진다.

$$P(X_1, \dots, X_T) = q_{x_1} \prod_{t=2}^T P_{x_{t-1}x_t} \quad (9)$$

사용자의 이동에 따른 최정합 노드의 변화과정이 입력으로 사용되므로 마르코프 모델은 RSOM의 출력 노드 수만큼의 상태를 가진다.

3.3 이동경로 패턴에 따른 상태 예측과 개별화 서비스

마르코프 모델을 적용하여 구축된 지역모델을 사용하여 사용자 위치 이동을 예측하고, 사용자의 의도에 적합한 서비스를 제공한다. 이동에 따른 새로운 입력 시퀀스 X_0, \dots, X_t 가 지역모델 LM_p 에 의해 생성될 확률을 $P(X_0, \dots, X_t | LM_p)$ 라고 할 때, 다음과 같이 자신을 제외한 다른 모델의 평가값의 평균과의 차이가 일정 값 이상이 되는 모델이 있을 경우 해당되는 모델이 선택된다.

$$P(X_0, \dots, X_t | LM_p) - \sum_{\substack{k=1 \\ st. k \neq p}}^N \frac{P(X_0, \dots, X_t | LM_k)}{N-1} > threshold \quad (10)$$

이와 같은 방법으로 사용자가 이동 중에 유사하다고 판단되는 패턴이 선택되는 즉시 적절한 서비스를 제공한다. 그림 3은 이동경로 패턴에 따라 예측된 사용자의 상태에 적합한 서비스이다.



그림 3. 경로패턴에 따른 개별화된 서비스

4. 실험 및 결과분석

제안하는 방법을 검증하기 위해서 실제 대학원생의 일상생활을 모델로 연세대학교 캠퍼스 내에서 20일 동안 GPS데이터를 수집하였다. 수집된 데이터는 하루 4시간씩 총 80시간 동안 수집된 위치이동 데이터로 구성된다.

표 1. 사용자의 위치 이동경로

상황	장소	목적
1	공학원 ⇨ C 관 ⇨ 학생회관	식사
2	공학원 ⇨ 학생회관	개인업무
3	공학원 ⇨ 도서관	도서대출/반납
4	공학원 ⇨ 과학관 ⇨ 상대 (과학관 경유, 긴 코스)	수업1 (평상시)
5	공학원 ⇨ 학생회관 ⇨ 상대 (학생회관 경유, 짧은 코스)	수업2 (지각상태)
6	공학원 ⇨ 학생회관 ⇨ 동문회관 (교내통로)	대외협력체
7	공학원 ⇨ 학교밖 ⇨ 병원입구 ⇨ 치과	병원진료 (순환버스)
8	공학원 ⇨ 논지당	휴식

수집된 데이터는 대체로 표 1과 같이 8가지 사용자 의도로, 각 의도별 9개의 이동 데이터로 구성되어 있었다. 동일한 조건(출발지와 목적지가 동일한 상태)에서 사용자의 의도에 따라 이동경로가 달라지는 경우도 많았다. 상황 1과 상황 2는 이동목적이 다른 경우의 이동패턴을 나타내며, 상황 4와 상황 5는 사용자의 상태가 다른 경우의 이동패턴을 보여준다. 이동패턴에 따른 사용자의 의도를 추론하여 그림 3에서의 서비스에 연결하였으며, 사용자가 이동할 때 의도가 예측되면 적절한 서비스가 제공된다. 그림 3의 (a)와 (b)는 상황 1과 2, 그림 3의 (c)와 (d)는 상황 4와 5에 대응하는 서비스이다.

수집된 사용자 로그를 표 1에서의 8가지 상황으로 분류하여 제안하는 방법을 적용하였다. 사용자가 목적지에 도착할 때까지 반복적으로 의도를 예측하여 임계치가 넘는 상황이 발견되면 대응하는 서비스가 선택되는 것을 목적으로 실험을 수행하였다. 거부율은 목적지에 도착할 때까지 예측이 끝나지

않은것을 나타낸다. 데이터의 양이 많지 않기 때문에 신뢰도를 높이기 위하여 9-fold cross validation을 적용하였다. GPS 데이터의 분류를 위한 RSOM의 출력층의 크기는 16×16, 초기반경은 4, 초기 학습률은 0.03, 반복횟수는 1,000번이며 현재 데이터에의 가중치 α=3으로 설정하였다. 표 2는 테스트 데이터에 대한 예측결과의 혼동행렬이다.

표 2. 혼동행렬

		예 측								정확율	
		1	2	3	4	5	6	7	8		거부
실 제	1	6	0	0	2	0	0	0	1	0	0.67
	2	1	2	1	0	2	0	0	1	2	0.28
	3	1	2	4	2	0	0	0	0	0	0.44
	4	4	0	0	4	0	1	0	0	0	0.44
	5	0	1	4	1	2	0	0	1	0	0.22
	6	0	1	1	0	1	6	0	0	0	0.67
	7	0	1	0	0	0	0	8	0	0	0.89
	8	1	2	0	0	0	1	0	2	0	0.29

5. 결론 및 향후연구

본 논문에서는 사용자의 이동패턴을 모델링하여 이동경로를 예측하고, 그에 따라 사용자의 상태 및 이동목적지를 추론하여 개인에게 가장 적합한 서비스를 제공하는 방법을 제안하였다. GPS를 이용하여 수집된 데이터를 RSOM 통해 지역모델을 생성하여 문제의 복잡도를 감소시켰으며, 이 지역모델을 마르코프 모델을 이용하여 학습시켰다. 새로운 위치 시퀀스가 입력되었을 때, 지역모델의 패턴과 유사하며 일정한 값 이상이 되면 지역모델에 할당된 서비스를 즉각 제공한다.

제안하는 방법은 위치정보만으로 사용자의 평소 이동패턴을 이용하여 이동 의도를 추론하고자 하였으나, 단순히 위치정보만을 이용해서 사용자의 의도를 정확하게 예측하는 지능형 서비스를 수행하기에는 한계가 있다. 향후 연구로는 시간, 사진, 스케줄 등의 다양한 부가 정보를 포함한 패턴으로 사용자의 상태를 추론하고, 이동목적에 적합한 개별화된 서비스를 제공하는 연구가 이루어져야 할 것이다.

참고 문헌

[1] J. Hightower and G. Borriello, "Location systems for ubiquitous computing," *IEEE Computer*, vol. 34, no. 8, pp. 57-66, 2001.

[2] D. Patterson, L. Liao, D. Fox and H. Kautz, "Inferring high-level behavior from low-level sensors," *Proc. of 5th Int. Conf. on Ubiquitous Computing*, pp. 73-89, Seattle, WA, October, 2003.

[3] D. Ashbrook and T. Starner, "Learning significant locations and predicting user movement with GPS," *Proc. of IEEE 6th Int. Symp. on Wearable Computing*, Seattle, WA, October 2002.

[4] T. Koskela, M. Varsta, J. Heikkonen and K. Kaski, "Temporal sequence processing using recurrent SOM," *Proc. of 2nd Int. Conf. on Knowledge-Based Intelligent Engineering Systems*, vol 1, pp. 290-297, Adelaide, Australia, April 1998.

[5] M. Albanese, A. Picariello and A. Rinaldi. "A technological framework for personalized museum visiting," *Pro. of 10th Int. Conf. on Information Systems Analysis and Synthesis and Int. Conf. on Cybernetics and Information Technologies, Systems and Applications*, pp 273-278, Orlando, Florida, USA, July 21-25, 2004.