

이동 경로 및 도착지 예측에서의 동적 베이저안 네트워크에 대한 스무딩 기법

이상우°, 허민오, 장병탁
서울대학교 컴퓨터공학부
{slee, moheo, btzhang}@bi.snu.ac.k

Smoothing Techniques for Dynamic Bayesian Networks in Route and Prediction Problem

Sang-Woo Lee°, Min-Oh Heo, Byoung-Tak Zhang
School of Computer Science & Engineering, Seoul National University

요 약

동적 베이저안 네트워크가 이동 경로 및 도착지 예측에 오랫동안 연구되어 왔음에도 불구하고, 실제 응용 장면에서 이를 사용하는데 여러 어려움이 있었다. 본 논문에서는 대도시 환경의 실제 서비스 장면에서 나타날 수 있는 다양한 추론 상황을 정리하고, 기존에 연구된 동적 베이저안 네트워크 모델의 실제적인 문제에 대해 소개한 뒤에, 이를 해결하기 위한 방법을 제안한다. 실제 서비스 상황에서 다양한 예외 상황들이 등장함에도 불구하고, 우리는 다중 스위치 은닉 마코프 모델에 스무딩 기법을 적용하여 사용자의 도착지를 추론을 수행할 수 있었다. 사용된 모델링의 철학과 추론 기법의 타당성을 실험 결과를 통해 논증한다.

1. 서 론

이동 경로 및 도착지 예측 문제에 동적 베이저안 네트워크 (dynamic Bayesian networks, DBN)를 사용하는 방법이 10여년 전에 제안되었으며, 오랫동안 연구되어 왔다 [1, 2, 3(m1)]. 하지만 동적 베이저안 네트워크의 이론적인 타당성과 오랜 검토에도 불구하고 실제 기존 모델을 적용하는 데에 있어 몇 가지 문제점들이 보고되었다 [3(m1)]. 가장 큰 문제 중 하나는 추론 과정에서 종종 경로와 도착지에 대한 확률이 한쪽으로 수렴하는 것이다. 한편, 모델이 설명 학습한 데이터에 대하여 잘 추론을 하더라도, 실제 서비스 상황에서는 모델이 가정하지 않은 양상을 보이는 경로 역시 등장하며, 이 경우 모델이 새로운 이동 경로에 대해 잘 추론하는 것은 어려운 일이다. 본 논문에서는 이동 경로 및 도착지 예측 문제에서 동적 베이저안 네트워크 모델을 사용하는 데 생기는 어려움과 소개하고, 이를 해결하기 위해서 우리가 취한 방법을 소개한다. 특별히 본 논문에서는 학습한 모델의 분포가 너무 학습 데이터에 쏠리는 것을 방지하는 스무딩 (Smoothing) 기법에 주목할 것이다.

2. 이동 경로 및 도착지 추론을 위한 단층 모델

이동 경로 및 도착지 예측 문제는 이동하는 사람의 기기에서 나오는 센서 정보를 바탕으로 사용자의 이동 정보를 학습하고 이를 바탕으로 사용자가 실제 이동할 때에 사용자가 이동하고 있는 경로와 도착지에 대해 예측하는 문제이다. 이동 경로 및 도착지 예측 문제는 wearable 기기, 스마트폰, 자동차 등의 기기에서 많이

연구 되었다. 본 연구는 스마트폰 기기를 사용하는 상황에 집중한다. 이때, 동적 베이저안 모델은 학습 때 사용된 진행 경로의 동적인 변화 특성을 학습하여 경로와 도착지에 대한 추론을 수행한다.

기존에 위의 문제를 풀기 위하여 사용한 동적 베이저안 네트워크는 여러 개의 은닉 변수 층 (hidden layer)을 가진 위계적인 모델 (hierarchical model)이며 [1, 2, 3(m1)]으로 주로 파티클 필터 (예컨대, Rao-Blackwellised 파티클 필터)과 같은 근사적 추론 방법을 통해 학습과 추론을 수행한다. 하지만 이러한 근사적인 방법은 매 frame마다 확률에 대한 오류가 누적되는 소위 random walk 문제가 발생한다. 이 때, 그럴듯한 후보 이동 경로나 도착지의 경우의 수가 두 개 이상인 경우에도, 종종 한 이동 경로나 도착지로 확률이 수렴하는 문제가 생긴다. [4(m2)]에서는 이러한 문제점을 제시하고 이를 해결하기 위해 기존 위계적인 모델을 간략화한 다중스위치 마코프 모델 (multiswitch Hidden Markov Model, mHMM)을 제안한다. 본 연구에서는 mHMM을 사용하여 이동 경로 및 도착지를 추론한다. 사용된 모델의 확률 그래프 형태는 그림 1과 같다.

위계적인 모델과 비교하여, 단층 모델은 그 표현력에 한계를 가지고 있다. mHMM에서는 스위치들을 사용하여 단층 모델의 단점을 극복한다. 예컨대, 주요 경로의 방향성을 표현하기 위하여 층을 여러 개 쌓는 대신에, 이동 방향에 대한 스위치를 별도로 달아 역방향 이동에 패널티를 부여한다. 이 모델은 실제 사용자의 행동을 추론하기 위하여 알아야 할 정보가, 단지 현재 어떠한 이동 경로를 통해 이동하고 있는 지

여부와 시작점에 크게 의존한다는 가정을 기반으로 하고 있다. 이렇게 제안된 모델은 선행 연구에서 그 성능을 입증 받았다. 자세한 실험 결과, 전처리, 모델의 설명 및 모델의 수식은 [4(m2)]와 유사하다.

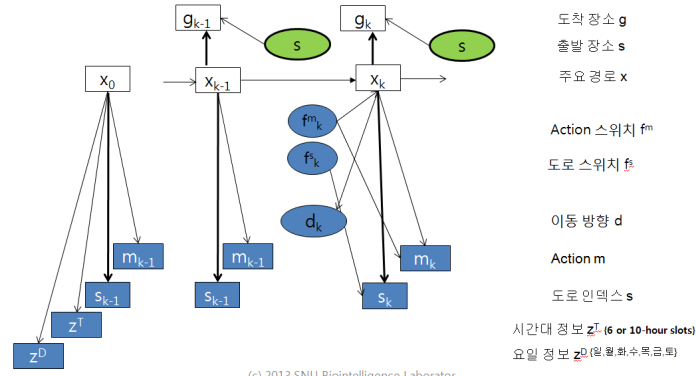


그림 1. 이동 경로 및 도착지 추론을 위한 다중스위치 은닉 마코프 모델 (mHMM) [4(m2)]

단, 기존 모델과 비교하여 시간을 반영하는 방법이 바뀌었으며, 시간은 초기 주요 경로의 확률을 결정하는데 사용된다. 이는 시간을 도착 장소와 직접적인 관련이 있는 것으로 가정하는 기존 방법이, 도착지 근처의 추론에서는 시간에 대해 너무 과도한 영향을 주 때문이다.

3. 적절한 테스트 데이터 추론을 위한 스무딩 기법

실제 서비스 상황에서 테스트 데이터의 양상이 항상 학습 데이터와 같지는 않다. 본 연구에서는 스마트폰 경로 및 도착지 예측 문제에 있어 학습 데이터에 대한 테스트 데이터의 유형을 표 1의 다섯 가지로 분류했다.

시나리오1	출발지와 도착지, 진행 경로가 모두 학습 데이터에 있는 경우
시나리오2	출발지가 같지만 진행 경로가 다른 경우
시나리오3	출발지에서 도착지에 간 적이 한 번도 없는 경우
시나리오4	두 개 이상의 시나리오가 붙어 있는 경우
시나리오5	도착지에 간 적이 없는 경우

표 1. 실제 추론 상황에서 등장하는 경로의 양상에 대한 분류

물론 시나리오 5처럼 한번도 도착해 본 적이 없는 도착지를 예측할 수는 없지만, 그 외의 상황에서는 학습 데이터와 공유되는 일부 경로에 대한 정보를 활용하여 적절히 도착지를 추론하는 것이 추론 모듈을 사용하는 서비스의 성능 향상에 큰 도움이 될 것이다. 본 연구에서는 가능한 모델의 기본 구조는 유지한 채, 스무딩 기법 혹은 파라미터 조절 등을 이용하여 추론 성능을 개선하는 원리적인 방법으로 문제를 해결하려 시도한다. 여기서, 스무딩 기법이란 학습한 파라미터를 학습 후에 조절하여 이전에 보지 못한 데이터에도 적절한 확률을 부여하는 일을 말한다. 우리는 위의

시나리오 중 1,2,3에서, 기존 학습 데이터와 실제 데이터의 양상이 다른 경우 어떻게 추론을 수행할 수 있는 지 논한다. 하지만, 설명하지 않은 것 중에서도 많은 스무딩 기법이 추론 성능을 개선시키는 데에 사용될 수 있다.

(1) 시나리오 1 - 이동 시간이나 경로에 약간 차이가 있는 경우

단지 수 frame의 시간 동안의 지속적이고 부정확한 GPS noise나, 교통 체증만으로 기존 동적 모델에서는 추론에 큰 영향을 받는다. 즉, 출발지와 진행 경로가 기존 학습 데이터에 있는 시나리오 1에서도 동적 모델의 추론이 잘 되는 것을 보장할 수는 없다. 이를 해결하기 위하여, 본 연구에서는 도로 스위치를 사용, 움직이고 있는 경우와 머물러 있는 경우 아래와 같이 서로 다른 관측 행렬 값을 적용한다.

$$p(s_k | x_k, f_k^s = \text{street change}) \sim N(\Delta d, \sigma_0)$$

$$p(s_k | x_k, f_k^s = \text{street not change}) \sim N(\Delta d, \sigma_0^2 \cdot \alpha)$$

이 때, α 는 일반적으로 1보다 큰 값을 가정한다. 우리는 GPS 관측치를 GIS 정보를 이용하여 도로에 사영하는데, 도로 스위치가 꺼진 경우 (현재 사영된 도로의 정보가 바뀌지 않은 경우)의 parameter의 패널티를 완화함으로써, 속도가 빠르게 움직이는 경우와 느리게 움직이는 경우와 순간적인 GPS noise가 발생하는 경우를 동시에 다룰 수 있다.

(2) 시나리오 2 - 기존에 출발지에서 도착지를 이동하는데 현 경로를 지난 적이 이전까지 없는 경우

매일 회사나 집을 오고 가더라도, 어느 날부터는 기존에 다니지 않던 새로운 샛길을 발견하여 그 길로 자주 다니게 될 수도 있다. 그러나 학습 데이터에는 그러한 길을 사용한 적이 없는 경우가 종종 있다. 이 경우는 시나리오 2에 해당한다.

출발지는 다르지만, 예측해야 할 경로와 비슷한 경로가 도착지로 이동할 때 사용이 된 경우, 그 정보를 이용할 수 있다. 하지만, 출발 지에서 이동한 지 한참 뒤에 예측해야 할 경로와 비슷한 경로를 만난 경우, DBN 모델의 입장에서 그 경로의 확률은 비슷한 경로를 만나기도 전에 0에 수렴하게 된다. 이 경우 그 경로를 현재 가고 있는 경로로 예측할 수 없게 된다. 이러한 문제를 해결하기 위하여 다양한 스무딩 기법을 이용할 수 있다. 단순히 생각하면, 모든 경로의 확률은 언제나 0보다는 약간 크다고 지정해 놓을 수도 있다.

$$\bar{p}(x_k) \propto p(x_k) + \epsilon$$

이 때, ϵ 의 값은 10^{-10} 과 같은 아주 작은 값을 지정하여도 좋다.

EM이나 경로를 사용하지 않는 추론 모델을 사용하는 방법 등이 시나리오 2의 다른 예외 상황에서 사용될 수 있다. 하지만 이는 본 논문의 범위를 넘기에, 후속 논문에서 다룰 것이다.

(3) 시나리오 3 - 출발지가 다른 경우

출발지가 다른 경우는 시나리오 3에 해당된다. 출발지를 명시적으로 관측값으로 사용하여 도착지의 확률을 예측하는 mHMM에서 시작점이 일치하지 않는 문제는 추론에 상당한 영향을 준다. 스마트폰이나 로거 앱을 중간에 키는 경우, 보통 시작점이 일치하지 않으며 이런 경우는 많이 발생한다. 하지만, 기존에는 도착점에만 적이 없는 출발지에서 출발하는 경우도 종종 발생한다. 이 때, 도착지 g , 은닉 변수 x , 출발지 s , 한 번이라도 간 적이 있는 이동 경로와 출발지의 조합 T , 그리고 학습 데이터 관측값 전체 O 에 대하여 다음 식을 사용할 수 있다.

$$p(g | x_k, s) = \sum_{(x_k, s) \in T} p(g | x_k, s) p(x_k, s | O) ds$$

$$s.t. (h, s) \notin T$$

4. 실험 결과

위에서 제안된 방법의 추론 성능을 정량적으로 평가하기 위하여, 실제 3명의 스마트폰 사용자를 대상으로 이동 로그를 수집하였다. 실험 데이터에 대한 세부 사항은 표 2와 같다. 기존 [4(m2)]에서는 테스트 성능을 측정하기 위하여 10-cross validation을 사용하였다. 하지만 이는 현재의 테스트를 수행하기 위하여 미래의 데이터를 미리 보고 학습하는 경우가 발생한다는 점에서 그 검증 방법에 한계가 있다. 이에 본 연구에서는 더 많은 유저와 로그를 수집하고 학습 데이터와 테스트 데이터를 시간적으로 구분하였다. 실험 결과는 그림 2와 같다. 그림2는 테스트 경로 중 시나리오 5에 해당하는 경로를 제외한 시간에 따른 예측 성능을 보고하고 있다. 이 때, 시나리오 5에 해당하는 건수는 A,B,C 각각에 대해 0,1,12개였다.

	POI	trip	학습 경로	테스트 경로
user A	15	126	85개 (22일)	11개 (15일)
user B	13	122	44개 (55일)	16개 (18일)
user C	29	340	141개 (31일)	98개 (39일)

표 2. 실험 데이터의 주요 정보




그림 2. 이동 경과에 따른, 각 유저에 대한 모델의 성능

	user A	user B
시나리오 1	0 -> 0 / 0	9 -> 9 / 9
시나리오 2	0 -> 8 / 10	0 -> 0 / 0
시나리오 3	0 -> 0 / 0	1 -> 4 / 4
시나리오 4	0 -> 0 / 1	0 -> 1 / 2

표 3. 시나리오 별 smoothing의 성능 개선 효과

특히 4장에서 제안한 기법 중 출발지와 경로에 대한 스무딩 기법의 개선을 보이기 위하여, user A와 B에 대한 테스트 경로를 시나리오 1부터 시나리오 4까지 분류하였다. user B의 경우에는 시나리오 5에 해당하는 경로가 한 건 있었다. 표 3은 3장에서 설명된 스무딩 기법을 이용하여, 추론 결과가 얼마나 개선되었는지를 보인다. 표 3에 들어간 값은 완벽히 해당 경로가 추론되었는 지 여부이며, 그 기준은 도착지의 확률이 한번도 POI의 개수 분의 1 이내로 내려가지 않으며, 도착지에 도착하였을 때 도착지의 확률이 1등이어야 하며, 5분 이상 예측 경로가 실제 유저의 위치와 크게 벗어나지 않는 지에 대한 여부이다. 표 3을 통해 알 수 있는 또 다른 사실은 실제 추론 상황 중에 상당 수가 학습 데이터의 양상을 따르지 않는다는 점이다.

감사의 글

이 논문은 정부 (미래창조과학부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구이며(NRF-2010-0017734-Videome, NRF-2013M3B5A2035921-HyperIntelligence), 정부(산업통상자원부)의 재원으로 한국산업기술평가관리원 지원(KEIT-10035348-mLife, KEIT-10044009)을 일부 받았음.

참고 문헌

[1] L. Liao, D. J. Patterson, D. Fox, H. Kautz, Learning and Inferring Transportation Routines, *Artificial Intelligence*, 2007.

[2] V. Gogate, R. Dechter, B. Bidyuk, C. Rindt, J. Marca, Modeling Transportation Routines using Hybrid Dynamic Mixed Model, *Uncertainty in Artificial Intelligence*, 2005.

[3] 허민오, 강명구, 임병권, 황규백, 박영택, 장병탁, 확률 그래프 모델을 이용한 스마트폰 사용자의 이동경로 학습 및 실시간 예측 기법, *정보과학회논문지: 소프트웨어 및 응용*, 2012.

[4] 이상우, 허민오, 장병탁, 스마트폰 사용자의 이동 경로 및 도착지 예측을 위한 다중스위치 은닉 마코프 모델, *정보과학회논문지: 컴퓨팅의 실제 및 레터*, 2013.