

일상행위분석을 위한 희소 고차 마코프랜덤필드 학습 기법

Learning Sparse Higher-order Markov Random Fields for Human Activity Analysis

허민오 · 조세한 · 이상우 · 장병탁
Min-Oh Heo, Sae-Han Jo, Sang-Woo Lee and Byoung-Tak Zhang

서울대학교 컴퓨터공학부
Department of Computer Science and Engineering, Seoul National University

요약

스마트 기기가 보편화 되면서 사용자의 라이프로그를 자동적으로 수집할 수 있게 되었다. 이러한 개인 라이프로그는 기계학습 기술을 통해 개인화된 상황 및 일상행위를 이용할 수 있도록 하여 추천 및 비서 서비스의 질을 높일 수 있다. 본 고에서는 일상행위분석을 위한 새로운 학습 모델인 희소 고차 마코프랜덤필드를 제안하고 그 학습 알고리즘을 소개한다. 제안방법론의 검증은 위해 2 개월 간 3 명의 피험자가 실세계에서 스마트폰을 통해 라이프로그를 수집하였고 이를 모델 학습에 사용하였다. 학습결과로부터 제안방법이 사용자 일상의 주요패턴들을 설명하면서도, 또한 확률적인 예측도 수행할 수 있음을 확인하였다. 추론의 예제로서 오전행위로부터 오후행위를 추론하는 문제를 다루었다.

키워드 : 마코프랜덤필드, 라이프로그, 일상행위분석, 희소 모델 학습

1. 서론

다수의 사람들의 일상은 반복성을 가진다. 기계가 이러한 개인적인 일상 패턴을 알 수 있다면, 그 사람의 향후 상황과 행위를 예측하고 그에 따른 다양한 서비스를 제공하는 것이 가능해진다. 최근 스마트폰과 같은 스마트 기기가 보편화 되고, 기계학습 기술이 발전하면서 라이프로그를 학습하여 개인화 된 일상에 대한 모델을 얻고 사용자의 향후 상황/행위를 예측할 수 있게 되었다.

본 고에서는 스마트폰으로 수집한 라이프로그 데이터를 학습하여 개인화 된 일상행위 패턴을 추출하고 이를 통해 예측하는 문제를 다루고자 한다. 일상행위 패턴 추출과 예측을 통합적으로 다루기 위해 마코프랜덤필드(Markov random field (MRF))를 일반화한 새로운 확률 모델인 희소 고차 MRF(sparse higher-order MRF)를 제안하고 이를 위한 학습 알고리즘을 소개한다. 희소 고차 MRF는 전통적인 MRF와는 달리 potential 함수에 대한 차수의 제한을 풀되, sparsity를 부여하여 각 potential 함수가 가질 수 있는 표현력을 높이면서도, 크게 늘어날 수도 있는 파라미터의 수에 대한 문제를 완화하였다.

이후 논문에서는 고차 MRF, 희소 고차 MRF를 차례로 설명하고 이를 위한 학습 알고리즘을 소개한다. 또한, 실제로 수집한 라이프로그를 학습한 모델을 통해 실험결과를 보일 것이다.

2. 고차 마코프랜덤필드

MRF는 확률변수의 집합 X 에 대해 결합확률분포를 무방향 그래프로서 표현하는 확률그래프모델이다. 확률 변수 간의 의존관계가 하나의 변수에 대해 간선으로 연결된 주변 변수에만 의존적인 마코프 특성을 가지는 것




그림 1 MRF와 고차 MRF와의 관계

이 특징이다. 그림 1의 (a)와 같은 구조를 가질 경우, (b)와 같은 factor 그래프로 바꾸어 표현할 수 있다. 각 factor는 간선으로 연결된 변수들의 함수로 표현되며, (a)에서의 clique과 대응된다. 이 때, MRF를 다음과 같이 Gibbs 분포를 이용해 정의할 수 있다.

$$P(X) = \frac{1}{Z} \exp(-E(X)) = \frac{1}{Z} \exp(-\sum_{c \in C} \phi_c(X_c)) \quad (1)$$

C 는 factor의 집합, ϕ_c 는 factor c 의 potential 함수, Z 는 normalization 상수이다. 위 식은 다음과 같이 log-linear 모델의 식으로 변형할 수 있다.

$$P(X) = \frac{1}{Z} \exp(-\sum_i w_i \cdot f_i(X_i)) \quad (2)$$

$f_i(X_i)$ 는 각 potential 함수에 연관된 변수들이 가질 수 있는 값의 조합에 대해, 매치되면 1, 그 외에는 0을 갖는 indicator 함수이며, w 는 각 경우에 대한 가중치이다.

그림 1의 (c)와 같이 모든 가능한 변수 조합에 대해 factor가 존재할 수 있다고 가정하면, 일반화된 고차 MRF를 얻을 수 있으며 log-linear 모델 틀은 유지된다.

3. 희소 고차 마코프랜덤필드 학습

상기 고차 MRF는 변수 수와 가능한 상태 수에 따라 거의 지수적으로 파라미터 수가 증가한다. 실제적으로 이를 모두 다룰 수 없으므로 sparse 모델이 되도록 학습하여 높은 표현력은 유지하면서도 이를 회피할 것이다.

제안 학습방법으로 (1) 희소화, (2) 파라미터 학습, (3)

감사의 글 : 이 논문은 정부의 재원으로 지원을 받아 수행된 연구임 (NRF-2010-0017734, Videome), (KEIT-10035348, mLife)

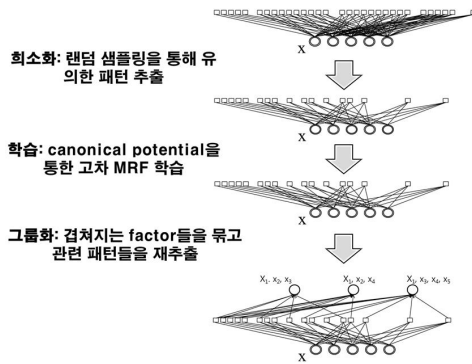


그림 2 최소 고차 MRF 학습 개요

그룹화를 거치는 3 단계 학습 방법을 설명한다. (그림 2)

3.1 최소화 (Sparsification)

먼저 파라미터가 지수적으로 느는 어려움을 피하기 위해 명시적으로 최소화 가능한 부분을 다룬다. 학습 데이터의 각 인스턴스에 대해 무작위로 변수를 선택하여 해당 변수와 값으로 $f_i(X_i)$ 에 대한 목록을 만든다. 그 후, $f_i(X_i)$ 와 매치되는 패턴이 최소빈도 N_{min} 을 넘고 유의성이 S_{min} 이상인 것들을 남긴다 [2]. 낮은 차수의 패턴이 조건에 맞지 않으면 관련된 높은 차수의 패턴은 모두 제거한다. 이를 차수가 낮은 것부터 높은 순으로 수행한다.

3.2 고차 MRF 학습

변수의 임의의 부분집합 D 에 대해 Markov blanket의 값을 고정하고 blanket 바깥 변수값을 무시한 빈도로 얻은 확률 P_D 를 추정할 수 있다[3]. 이를 MRF 파라미터 학습에 활용할 수 있다(canonical parameterization 방법). $f_i(X_i)$ 를 D 에 대해 표현하면 Markov blanket의 값에 따라 $f_{D|MB(D)}(d) = \exp(-E_D)$ 와 같으며, 구조가 고정된 고차 MRF에 대한 재귀적인 파라미터 학습방법을 유도할 수 있으며, 그 식은 다음과 같다. (단, $\phi_{MB(D)}$ 는 D 안의 값을 고정했을 때의 에너지이다.

$$E_D = \log P_D - \sum_{U \subset D} E_U - \phi_{MB(D)} \quad (3)$$

3.3 그룹화

고차 MRF 내에는 고차 패턴과 연관된 파라미터가 여러 개가 나타나게 되므로, 군집화를 통해 대표적 패턴을 도출한다. 구체적으로, 어떤 패턴 K 의 차수가 d_K 라고 할 때, K 를 완전히 포함하고 차수가 d_K+1 인 패턴 parent와 K 에 완전히 포함되고 차수가 d_K-1 인 child를 정의할 수 있다. 'parent의 빈도/child의 빈도' 비율이 0.7보다 크면 child를 제외하고 0.3보다 작으면 parent를 제외하고 남은 것들을 대표패턴으로 삼았다.

4. 실험결과

방법론 검증을 위해 2 개월 동안 3 명의 스마트폰 사용자가 라이프로그를 수집하여 데이터로 사용하였다. 하루를 12등분 하여 2시간 단위로 표현하였고 이를 위해 30분 단위별로 최빈값을 구해 k -means clustering으로 2시간 단위 워드를 생성한 후(그림 3), 제안방법으로 학습하였다. 그림 4는 학습된 주요 일상행위패턴이다.¹⁾ 확률 모델을 학습하였기 때문에 다양한 추론 문제에 활용할 수 있다. 그 예로서 오전행위를 알 때, 오후에 어떤 행위를 할 지 예측하는 문제를 실험하였다(그림 5)²⁾.

1) 표의 각 행이 도출된 각 패턴이며, 흰 부분은 don't care condition과 같은 부분이다. 3 명 모두 밤에는 자거나 쉬고, 낮에는 일하는 전형적인 패턴을 가진다. User B는 비교적 규칙적인 정시 출퇴근을 하며, User C는 일상행위 패턴이 4시간 쪼뉘뉘 밀려있어 올빼미형 생활을 하는 것을 짐작케 한다.

를 할 지 예측하는 문제를 실험하였다(그림 5)²⁾.




그림 3 행위로그의 통계 및 전처리 결과

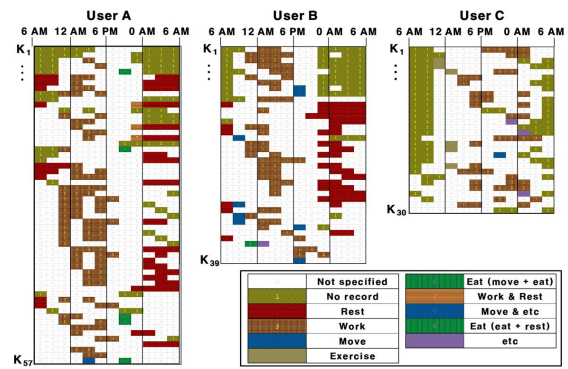


그림 4 학습으로 얻은 주요 일상행위패턴




그림 5 오전행위에 따른 오후행위 예측 성능

5. 결론

새로이 제안된 방법론이 스마트폰 사용자의 일상행위분석 및 예측에 적용가능하다는 것을 실생활 데이터를 통해 보였다. 향후 기반기법으로 쓰일 수 있을 것으로 기대한다.

참고 문헌

[1] V. Pejovic, and Mirco Musolesi. "Anticipatory mobile computing: A survey of the state of the art and research challenges," arXiv preprint arXiv:1306.2356, 2013.

[2] A. K. Wong, and Y. Wang "High-order pattern discovery from discrete-valued data," IEEE Trans. on Knowledge and Data Engineering, 9(6), 877-893, 1997.

[3] P. Abbeel, D. Koller, and A. Y. Ng, "Learning factor graphs in polynomial time and sample complexity," Journal of Machine Learning Research, 7, pp. 1743-1788, 2006.

2) 수집 데이터에는 수집기가 꺼져 NoRecord가 포함된 경우가 있어, NoRecord를 제외한 성능도 함께 표시하였다. 성능은 개인별 생활 스타일에 따라 다소 상이하지만, 어느 정도의 성능을 기대해 볼 수 있는 문제이다. User C의 경우 성능이 다소 낮게 나오는데, 이는 올빼미 스타일의 삶으로 인해 오전의 행위가 대개 수면/휴식이어서 좋은 cue가 되지 못하기 때문이다.