

그래프 학습을 통한 시공간 Attention Network 기반 POI 추천

조강¹, 조인휘²

^{1,2} 한양대학교 컴퓨터소프트웨어학과
cg1106@hanyang.ac.kr, iwjoc@hanyang.ac.kr

Spatial-temporal attention network-based POI recommendation through graph learning

Cao Gang¹, Inwhee Joe²

^{1,2}Dept. of Computer Science, Hanyang University

요 약

POI (Point-of-Interest) 추천은 다양한 위치 기반 서비스에서 중요한 역할을 있다. 기존 연구에서는 사용자의 모바일 선호도를 모델링하기 위해 과거의 체크인의 공간-시간적 관계를 추출한다. 그러나 사용자 궤적에 숨겨진 개인 방문 경향을 반영할 수 있는 structured feature 는 잘 활용되지 않는다. 이 논문에서는 궤적 그래프를 결합한 시공간 인식 attention 네트워크를 제안한다. 개인의 선호도가 시간이 지남에 따라 변할 수 있다는 점을 고려하면 Dynamic GCN (Graph Convolution Network) 모듈은 POI 들의 공간적 상관관계를 동적으로 집계할 수 있다. LBSN (Location-Based Social Networks) 데이터 세트에서 검증된 새 모델은 기존 모델보다 약 9.0% 성능이 뛰어나다.

1. 서론

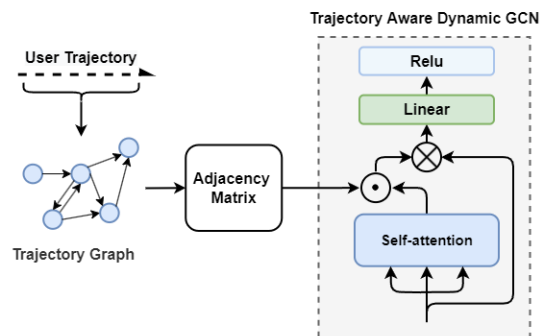
POI 추천은 과거 궤적과 현재 상태를 의하여 사용자의 이동 패턴을 마이닝하고 가까운 장래에 방문할 잠재적 위치를 추천하는 것을 목표로 한다 [1]. 정보 기술의 발전과 위치 데이터의 축적으로 POI 추천 Markov chains 및 Matrix Factorization 와 같은 전통적인 방법에서 딥러닝 방법으로 진화했다[2]. Self-attention mechanism 은 기계 번역에서 처음 제안되었으며 CV 및 NLP 등 다양한 분야에서 큰 성공을 거두었다. 마찬가지로 attention mechanism 은 POI 추천 분야에 도입된 후 CNN 및 RNN 기반 방법을 대체했으며 attention 기반 추천 모델은 점차 연구 중점이 되었다.

기존 연구 중에 [3]는 지리 정보를 더 효율적으로 활용하고 데이터 희소성 문제를 극복하기 위해 각 POI 좌표 인코딩을 이산화하는 hierarchical gridding 방법을 설계한다. [1]는 불연속적인 체크인 사이의 시공간 영향을 고려해서 이중 attention 아키텍처를 도입한다. 그러나 이전 연구는 시퀀스의 시공간 간격 관계에 초점을 맞추었고 POI 궤적 그래프에서 사용자 선호를 표현할 수 있는 structured feature 는 무시된다. 따라서 본 논문은 그래프 구조의 공간적 근접성을 고려하여 Trajectory-aware Dynamic GCN 를 제안한다. 이 모듈을 attention

network 에 통합한 후에 더 정확한 추천 결과를 얻을 수 있다.

2. 본론

A. 궤적 인식 Dynamic GCN



(그림 1) 궤적 인식 Dynamic GCN 모듈 개략도.

일반 GCN 은 서로 다른 인접 노드에 동일한 가중치를 할당하므로 POI 의 공간 정보 상관관계를 캡처하는 모델의 기능이 제한된다. 또한, POI 시퀀스는 시간 순서대로 배열되지만 GCN 은 시간에 민감하지 않는다. 즉, 그래프의 가중치 행렬은 언제든 변하지 않는다. 이 문제를 해결하기 위해 attention mechanism 을 결합하여 가중치 행렬을 동적으로 업데이트한다. 이 모듈의 개략도는 그림

1 에 나와 있으며 여러 공간 차원에서 POI 정보의 동적 feature 를 학습할 수 있으므로 모델이 사용자 선호도를 모델링하는 데 도움이 된다.

이 모듈의 수학적 표현은 공식 (1) 과 같으며, 여기서 L 은 정규화된 adjacency matrix, S 는 self-attention 으로 처리된 POI 시퀀스 embedding, W 는 선형 변환 행렬이다.

$$D^{(i)} = \sigma((L \odot S)D^{(i-1)}W^{(i)}) \quad (1)$$

B. 모델 아키텍처

본문의 모델은 Transformer 의 인코더-디코더 아키텍처를 따르며 세 가지 주요 구성 요소로 구성된다:

1) Context Embedding 모듈: POI 시퀀스의 지리적 좌표를 hierarchical gridding[3]로 처리하고 시공간 관계를 고려하여 더 조밀한 embedding 을 얻는다.

2) 인코더: Interval-aware attention 계층, 제적 인식 Dynamic GCN 계층 및 Feed-Forward 네트워크를 포함한다.

3) 디코더: target-aware attention 모듈을 사용하여 가중 POI 표현 및 후보 집합에서 사용자 선호도를 추출하고 추천 리스트를 생성한다.

인코더 및 디코더의 각 모듈은 다음 계층으로 전달하기 전에 residual connection 및 layer normalization 을 수행한다.

C. 최적화

초기 연구에서는 binary cross-entropy loss 을 사용하여 모델을 최적화하지만 이 방법은 다음 POI 추천 상황에서 positive 샘플과 negative 샘플의 비율이 매우 불균형하여 효율적이지 않다. 하나의 샘플만 무작위로 추출되므로 많은 정보를 포함하는 다른 negative 샘플들이 무시된다. Loss 를 계산할 때 업데이트된 gradient 가 작아지고 모델 학습 프로세스가 느려진다. 따라서 논문[3]의 방법을 참고하여 중요도 샘플링 기반의 weighted BCE loss 함수를 사용한다. 구체적으로, 거리에 따라 target POI 과 가장 가까운 1000 개의 POI 를 선택하여 후보 세트를 구성하고, 그 중 10 개를 무작위로 negative 샘플로 선택하여 최적화를 수행한다.

D. 데이터세트 전처리

위치 기반 서비스 제공자가 수집한 LBSN 데이터 세트 TKY 및 CA 를 사용하여 모델의 성능을 평가한다. 사용자, POI, GPS 좌표, timestamp 정보가 포함된 체크인 시퀀스만 사용하고 POI 시퀀스를 최대 길이가 100 인 작은 시퀀스로 나눈다. 모델의 i 번째 학습 단계의 경우 첫 번째 POI 부터 i 번째 POI 까지가 모델 입력이고 $i+1$ 번째 POI 는 모델이 예측한 target POI 이다. Cold start 켈린지를 완화하기 위해 방문 횟수가 10 회 미만인 비활성 POI 를 제거하고 체크인 기록이 20 개 미만인 비활성 사용자를 제외한다. 전처리 후 데이터 세트의 주요 통계는 표 1 과 같다.

<표 1> 데이터세트 통계

Dataset	TKY	CA
#user	2263	4107
#POI	7873	13051
#check-in	443732	321203
Sparsity	97.51%	99.40%
Avg. seq. length	196.1	78.2

E. 성능 분석

추천 top-K 문제에 자주 사용되는 평가 메트릭 HR (hit-rate) 및 NDCG (Normalized Discounted Cumulative Gain)를 채택한다. 표 2 와 표 3 은 TKY 및 CA 데이터 세트에 대한 기준 방법 및 본문 모델의 성능을 보여준다. 위의 두 데이터 세트에 대해 우리의 방법은 [3]의 GeoSAN, [1]의 STAN, [2]의 STiSAN 을 포함한 모든 비교 모델보다 성능이 뛰어나다. 기존 SOTA 모델인 STiSAN 과 비교하면 각 지표에서 6.80~ 13.25% 향상된다. 실험 결과는 구조화된 공간적 이웃 특징을 추출하는 데 제안된 DGCN 모듈의 효율성을 보여준다. 실험 결과는 본 논문에서 제안한 DGCN 모듈이 구조화된 공간적 이웃 특징을 효과적으로 추출할 수 있음을 증명한다. 또한, CA 데이터 세트에 대한 모든 모델의 성능은 TKY 에 비해 저하되어 데이터 희소성이 추천 성능에 어느 정도 영향을 미친다는 것을 나타낸다.

<표 1> TKY 에 대한 성능 평가

Model	HR@5	NDCG@5	HR@10	NDCG@10
GeoSAN	0.3728	0.2711	0.4842	0.3058
STAN	0.3905	0.3048	0.4738	0.3373
STiSAN	<u>0.4326</u>	<u>0.3414</u>	<u>0.5332</u>	<u>0.3780</u>
Ours	0.4702	0.3753	0.5696	0.4074
Improv.	8.69%	9.93%	6.83%	7.78%

<표 2> CA에 대한 성능 평가

Model	HR@5	NDCG@5	HR@10	NDCG@10
GeoSAN	0.2486	0.1552	0.3283	0.2073
STAN	0.2349	0.1474	0.3037	0.1867
STiSAN	<u>0.2785</u>	<u>0.2023</u>	<u>0.3685</u>	<u>0.2336</u>
Ours	0.3007	0.2291	0.3975	0.2588
Improv.	7.97%	13.25%	6.80%	10.79%

3. 결론

본 연구에서는 새로운 궤적 인식 Dynamic GCN 을 제안하고 이를 Attention Network 에 통합한다. Dynamic GCN 모듈은 실시간으로 그래프의 가중치를 업데이트 하고 사용자의 개인화된 로컬 공간 관계를 학습할 수 있다. LBSN 데이터 세트에 대한 비교 실험을 수행하며 이 논문에서 제시한 방법의 추천 성능은 기존 모델에 비해 약 9% 향상된다. 앞으로는 사용자 간의 협동적인 요인이 사용자 선호도에 미치는 영향을 탐구할 것이다.

참고문헌

- [1] Luo, Yingtao, Qiang Liu, and Zhaocheng Liu. "Stan: Spatio-temporal attention network for next location recommendation." Proceedings of the Web Conference 2021. 2021.
- [2] Wang, En, et al. "Spatial-Temporal Interval Aware Sequential POI Recommendation." 2022 IEEE 38th International Conference on Data Engineering (ICDE). IEEE, 2022.
- [3] Lian, Defu, et al. "Geography-aware sequential location recommendation." Proceedings of the 26th ACM SIGKDD international conference on knowledge discovery & data mining. 2020.