

# Graph-Mamba 기반 POI 추천 시스템

최민규, 임성수\*  
충남대학교

mingyu@g.cnu.ac.kr, \*sungsu@cnu.ac.kr

## POI Recommendation System Based on Graph-Mamba

Mingyu Choi, Sungsu Lim\*  
Chungnam National University

### 요약

관심지점(POI) 추천 시스템에서 사용자의 이전 방문 기록과 방문 순서를 고려하는 것은 중요하다. 또한, POI 추천에서 그래프 모델링 기법이 높은 성능을 달성할 수 있음이 입증되었다. 본 논문에서는 최신 그래프 기반 추천 모델인 Graph-Mamba의 구조를 활용하여 POI 추천 시스템에서의 활용 가능성을 연구하였다. 특히, 사용자와 POI 간의 상호작용 및 시계열 정보를 통합적으로 고려하기 위해 그래프신경망(GNN)과 Mamba를 결합한 모델을 제안하였다. 실험 결과, 제안한 모델은 기존의 GNN 및 트랜스포머 기반 추천 모델과 유사한 높은 성능을 보였다. 이를 통해 Graph-Mamba 모델이 POI 추천 시스템에서 유망한 접근법임을 확인하였다.

### 1. 서론

위치 기반 소셜 네트워크(Location-based Social Networks, LBSNs)는 사용자가 위치정보를 공유하며 다른 사용자와 소통할 수 있는 서비스이다. 사용자 맞춤형 서비스를 제공하기 위해, 각 사용자의 취향에 맞는 관심지점(Point-of-Interest, POI)을 추천하는 것이 필수적이다. POI 추천에서는 사용자의 방문 위치와 그 순서를 고려하는 것이 중요하다. 특히, 사용자의 방문 시퀀스를 잘 반영하기 위해 그래프신경망(Graph Neural Networks, GNNs) 또는 트랜스포머(Transformer) 모델을 활용할 수 있다.

트랜스포머는 컴퓨터 비전 및 자연어 처리 분야에서 우수한 성능을 보이며 널리 사용되고 있다. 그러나 대규모 계산이 필요해 계산 과부하와 긴 추론 시간의 단점이 있다. 이를 해결하기 위해 상태 공간 모델(State Space Model, SSM)을 활용한 Mamba[1]가 제안되었고, 트랜스포머에 준하는 성능과 메모리 사용량이 적고 추론 시간이 빠르다는 장점으로 주목받았다. 이를 기반으로, 순차적 추천(sequential recommendation)을 수행하는 Mamba4Rec[2] 모델이 제안되었고, 기존 트랜스포머 기반 추천 모델보다 우수한 성능을 보였다.

또한, Graph-Mamba[3] 모델은 그래프 내의 노드 및 링크 예측을 위해 GNN과 Mamba를 결합한 모델로, 우수한 성능을 넘겨 동시에 효율적인 추론 성능을 제공한다. 본 연구에서는 Graph-Mamba 모델 구조를 활용하여, GNN의 관계 학습 능력과 Mamba의 시계열 데이터 분석 능력을 결합한 POI 데이터에 대한 시계열 추천 실험을 수행하고 분석하였다.

본 연구를 통해 POI 추천 시스템에서 Graph-Mamba 모델을 적용한 결과, 실세계 네트워크 데이터셋에서 높은 성능을 제공할 수 있음을 확인하였다. 이러한 결과는 Graph-Mamba 모델이 POI 추천 시스템에서 유망한 접근법임을 시사하며, 향후 다양한 위치 기반 서비스에서의 활용 가능성을 제시한다.

### 2. 제안 방법

본 논문에서는 GraphSAGE[4]와 Mamba[1] 모델을 사용하여 POI 추천 모델을 학습하는 방법을 제안한다. GraphSAGE는 큰 그래프 데이터에서 각 노드의 임베딩을 학습하기 위해 이웃 노드들의 정보를 샘플링하고 집계하여 효율적으로 노드 표현을 생성하는 효율적인 GNN 모델이다. 데이터의 시계열 정보까지 모델링하기 위하여 Mamba를 함께 사용하였다.

#### 2.1 Mamba

Mamba는 시계열 데이터에서 장기 의존성을 효율적으로 모델링할 수 있는 상태 공간 모델(SSM)이다. 일반적인 상태 공간 모델은 식 (1), (2)와 같이 상태 방정식과 관측 방정식으로 표현된다.

$$h'(t) = \mathbf{A}h(t) + \mathbf{B}x(t) \quad (1)$$

$$y(t) = \mathbf{C}h(t) \quad (2)$$

여기서  $x(t)$ 와  $y(t)$ 는 각각 현재 입력과 출력,  $h(t)$ 와  $h'(t)$ 는 각각 현재와 다음 상태이며, 행렬  $\mathbf{A}, \mathbf{B}, \mathbf{C}$ 는 상태와 입력에 곱해지는 행렬이다. 위 식을 통해 현재 상태가 어떻게 변하고, 출력값으로 나타나는지 설명할 수 있다. 하지만 위 식은 연속적인 상태를 다루기 때문에, 이산적인 시계열 데이터를 처리하려면 위 식을 이산화(discretization)할 필요가 있다. Mamba는 zero-order hold 방식을 사용하여 이산화를 수행한다.

$$\bar{\mathbf{A}} = \exp(\Delta\mathbf{A}), \quad \bar{\mathbf{B}} = (\Delta\mathbf{A})^{-1}(\exp(\Delta\mathbf{A}) - \mathbf{I}) \cdot \Delta\mathbf{B} \quad (3)$$

여기서  $\Delta$ 는 행렬의 이산화 정도를 조절하는 학습 가능한 파라미터이다. 위 식 (3)을 통해 식 (1), (2)를 이산화하여 재귀적인 형태로 표현할 수 있다.

$$h_t = \bar{\mathbf{A}}h_{t-1} + \bar{\mathbf{B}}x_t \quad (4)$$

$$y_t = \mathbf{C}h_t \quad (5)$$

시간  $t$ 가 증가할수록, 식 (4)를 식 (5)에 대입하면,  $C$ 와  $\bar{B}$ 는 고정되어 있고,  $\bar{A}$ 만 계속 곱해지는 경향을 관찰할 수 있다. 최종적으로, 이를 합성곱 연산 형태로 나타낼 수 있다.

$$\bar{K} = (C\bar{B}, C\bar{A}\bar{B}, \dots, C\bar{A}^k\bar{B}, \dots) \quad (6)$$

$$y = x * \bar{K} \quad (7)$$

본 연구에서는 위와 같은 연산을 수행하는 Mamba 레이어를 생성한 다음, 여러 개의 레이어를 쌓아 Mamba 블록을 구성하여 활용하였다.




그림 1 Graph-Mamba 를 활용한 POI 추천 모델 프레임워크.

## 2.2 모델 구조

그림 1 은 본 연구에서 사용한 POI 추천 모델의 프레임워크이다. 전체 모델은 Graph-Mamba 블록과 Recommender 블록으로 구성된다. Graph-Mamba 블록에서 입력 그래프의 노드 표현을 학습할 수 있다. 다음 POI 추천을 위해 GNN 과 트랜스포머를 사용한 추천 모델인 MAERec [5]의 방법을 차용하여 계산된 노드 표현들의 시퀀스를 입력으로 한 트랜스포머 모델로 Recommender 블록을 구성하였다.

Graph-Mamba 블록은 GNN 레이어와 Mamba 레이어로 구성되어 있다. GNN 레이어는 그래프 내에서 타겟 노드의 이웃 노드 정보를 사용하여 노드 임베딩을 계산하고, Mamba 레이어는 사용자의 방문 POI 시퀀스를 사용하여 노드 임베딩을 계산한다. 각 레이어에서 계산한 노드 임베딩을 연결하여 최종 노드 임베딩을 생성할 수 있다. 최종 노드 임베딩을 사용하여 그래프 내에서 두 노드 사이에 연결이 존재하는지 예측하는 과정을 통해 노드 임베딩을 학습한다. POI 추천은 Recommender 블록에서 이뤄진다. Recommender 블록에서는 POI 시퀀스를 입력받아 다음 POI 를 예측하는 과정을 통해 Recommender 블록을 학습시킬 수 있다.

모델 학습 시 사용하는 손실함수  $\mathcal{L}$ 은 아래와 같이 정의되며, 여기서  $\mathcal{L}_p$ 는 그래프에서 연결 예측에 대한 손실함수,  $\mathcal{L}_r$ 은 다음 POI 예측에 대한 손실함수이다.

$$\mathcal{L} = \mathcal{L}_p + \mathcal{L}_r,$$

$$\mathcal{L}_p = - \sum_{(v,v') \in \mathcal{E}} \text{bg} \frac{\exp(s_{v,v'})}{\sum_{v'' \in \mathcal{V}} \exp(s_{v,v''})},$$

$$\mathcal{L}_r = - \sum_{u \in \mathcal{U}} \sum_{1 \leq t \leq l_u} \log \sigma(\tilde{E}_{u,t} \cdot \tilde{e}_{s_{t+1}}) + \log(1 - \sigma(\tilde{E}_{u,t} \cdot \tilde{e}_{s_{\bar{t}}}))$$

## 3. 실험

### 3.1 데이터셋

LBSNs 데이터셋은 사용자와 그 사용자의 장소 방문 기록으로 구성되어 있으며, 사용자와 방문한 장소 간의 연결관계를 그래프로 모델링 할 수 있다. 본 연구에서는 POI 추천 시스템의 성능을 검증하기 위해 Gowalla 데이터셋을 사용하였다. 이 데이터셋은 사용자의 장소 방문 기록을 포함하는 데이터셋으로, 사용자 ID, POI ID,

방문 시간, POI 의 위도와 경도를 포함한다. 효율적인 실험을 위해 각 사용자별 장소 방문 시퀀스의 길이가 100 이하인 사용자는 제거하였고, 최종적으로 7,706 명의 사용자와 106,836 개의 POI로 구성하였다.

본 연구에서는 전처리한 데이터셋으로 사용자 및 POI 사이의 연결로 이루어진 이종 그래프(heterogeneous graph)와, POI 사이의 연결로 이루어진 유향 그래프(directed graph)를 사용하여 두 그래프에 대한 성능비교를 수행하였다. 유향 그래프는 장소 방문 시퀀스에서 한 장소를 방문한 후 바로 다음에 방문한 장소 사이에 연결을 생성하여 구성하였다.

### 3.2 실험 결과

본 모델의 성능은 Hit Ratio@ $k$ , nDCG@ $k$ 를 사용하여 평가하였다. 각각  $k$  개의 추천 항목 중에 실제 정답이 포함되는지, 그리고 추천된 항목의 순위가 실제 선호도와 얼마나 일치하는지 평가하는 지표이다.

실험은 앞서 구축한 사용자-POI 이종 그래프와 POI 그래프에서 수행하였다. 본 모델에 대한 성능은 표 1 과 같이, 기존 추천 모델의 성능과 비교했을 때 비슷하거나 더 우수한 성능을 보였다. 특히, 단일 POI 노드만 존재하는 그래프보다 사용자와 POI 사이의 상관관계를 학습할 수 있는 이종그래프를 사용하는 경우, 학습한 모델의 성능이 더 뛰어난 것을 확인하였다.

	HR@5	HR@10	nDCG@5	nDCG@10
MAERec [5]	<b>0.8869</b>	<u>0.8953</u>	<b>0.8023</b>	<b>0.8051</b>
Graph-Mamba (User-POI)	<u>0.8376</u>	<b>0.9201</b>	<u>0.7045</u>	<u>0.7317</u>
Graph-Mamba (POI-POI)	0.7449	0.8443	0.5549	0.5875

표 1 Graph-Mamba 와 MAERec 의 성능 비교.

## 4. 결론

본 논문에서는 다음 POI 추천을 위한 Graph-Mamba 모델 프레임워크를 구현하고 평가하였다. 제안 모델은 Mamba 와 GNN 을 결합하여 시계열 추천 도메인에서 우수한 성능을 달성함을 확인하였다. 향후 연구에서는 Recommender 블록의 구조를 트랜스포머에서 Mamba 로 변경하여, 성능과 추론 시간을 더욱 개선할 예정이다.

## ACKNOWLEDGMENT

이 논문은 2024 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.RS-2022-00155857, 인공지능융합혁신인재양성(충남대학교)).

## 참고 문헌

- [1] Gu, A., & Dao, T. (2023). Mamba: Linear-time sequence modeling with selective state spaces. *arXiv preprint arXiv:2312.00752*.
- [2] Liu, C., Lin, J., Wang, J., Liu, H., & Caverlee, J. (2024). Mamba4rec: Towards efficient sequential recommendation with selective state space models. *arXiv preprint arXiv:2403.03900*.
- [3] Wang, C., Tsepa, O., Ma, J., & Wang, B. (2024). Graph-mamba: Towards long-range graph sequence modeling with selective state spaces. *arXiv preprint arXiv:2402.00789*.
- [4] Hamilton, W., Ying, Z., & Leskovec, J. (2017). Inductive representation learning on large graphs. *NIPS*.
- [5] Ye, Y., Xia, L., & Huang, C. (2023). Graph masked autoencoder for sequential recommendation. *SIGIR*.