

# 세션 기반 추천 시스템을 위한 개선된 사용자 의도 인식 그래프 신경망

유소영, 김정현

세종대학교

yooso0731@sju.ac.kr, j.kim@sejong.ac.kr

## Enhanced INT-GNN: Enhanced user intention aware graph neural network for session-based recommender systems

Soyoung Yoo, Junghyun Kim

Sejong Univ.

### 요약

본 논문은 세션 기반 추천 시스템을 위한 개선된 사용자 의도 인식 그래프 신경망 모델을 제안한다. 구체적으로 우리는 GNN이 두 계층 쌓인 GNN 모듈을 통해 세션 데이터로부터 복잡적이고 순차적인 특성들을 추출하고, 채널 및 공간 측면에서 중요한 정보를 포착하는 어텐션 모듈인 CBAM을 활용하여 기존 사용자 의도 인식 그래프 모델의 성능을 개선시키고자 했다. 실험을 통해 제안 모델이 기존 모델과 비교하여 성능지표 P에서는 1, MRR에서는 0.5 정도의 개선 효과가 있음을 확인했다.

### I. 서론

세션 기반 추천 시스템은 진행 중인 세션 내에서의 사용자 행동 정보를 사용하여 다음 행동을 추천하는 시스템이다. 이는 주로 개인 정보 보호 정책에 의해 특정 사용자의 과거 활동 기록과 같은 추가적인 정보를 사용할 수 없을 때 사용된다 [1]. 사용자의 동적 선호도를 효과적으로 모델링하기 위해 주로 시계열 정보 처리에 효과적인 순환 신경망(RNN), 주요 정보를 추출하기 위한 어텐션 기반 모델 등이 적용되어 왔다.

최근에는 사용자의 잠재 의도를 효과적으로 마이닝하기 위해 그래프 신경망(Graph neural network, GNN)을 활용한 모델인 Int-GNN(user intention aware graph neural network)이 제안됐다 [2]. GNN은 점과 그 점들을 잇는 선들로 이루어진 그래프 형식의 데이터를 분석하기 위해 고안된 모델이다. 이 연구에서 GNN은 특정 세션 내에서 발생 item 간의 상호작용을 다양하게 포착하기 위해 사용되었다. 저자들은 크게 세 개의 모듈로 이루어진 제안 모델을 통해 사용자의 의도를 인식하고자 했으며, 실험을 통해 여러 실생활 데이터셋에서 선행 모델들의 성능을 능가함을 보였다. 구체적으로 Int-GNN은 해당 세션에서 특정 행동(item)이 발생한 횟수를 고려하여 사용자의 관심 정보를 추출하는 Item Occurrence-Graph Neural Network(IO-GNN) 모듈과 행동 순서 및 동일 행동 간 간격을 통해 사용자의 행동 상호작용 정보를 포착하는 Interaction Position-Graph Neural Network(IP-GNN) 모듈, 그리고 추출된 특성들을 통해 추천 확률을 최종적으로 예측하는 Multi-scores generator 모듈로 구성된다. 이때 IO-GNN과 IP-GNN 모듈 내에서는 포착하고자 하는 특성에 따라 임베딩 벡터를 생성한 후 GNN 레이어를 통해 복잡한 특성을 추출하는데, 저자들은 하나의 GNN 레이어만을 사용했다. 또한 이 두 모듈을 통해 계산된 특성 맵은 단순히 더해진 후 Soft-attention 모듈을 통과하면서 item의 특성 관점에서 중요한 정보를 추출한다.

본 논문에서는 세션 데이터로부터 복잡적이고 순차적인 특성을 추출하고, 세부 모듈을 통해 계산된 특성 맵을 효과적으로 결합할 수 있도록 개선한 모델 Enhanced Int-GNN을 제안한다. 구체적으로, 우리는 GNN과

ReLU 활성화 함수 계층이 두 번 쌓인 GNN 모듈을 설계했으며 사용자의 행동 특성과 선호도를 효과적으로 결합하기 위해 Convolutional Block Attention Module(CBAM) [3]을 적용한다. 일반적으로 세션 기반 추천 시스템에서 많이 사용되는 데이터셋을 이용하여 실험을 진행하며, 선행 모델과의 성능 비교를 통해 제안 모델의 성능 개선 효과를 확인한다.

### II. 본론

#### 2.1 제안 모델

본 논문에서는 세션 데이터로부터 복잡한 특성을 추출하고, 이러한 특성들을 효과적으로 결합하여 사용자의 잠재 의도 점수를 추출하기 위해 제안 모델을 구성했으며 구조는 아래 그림 1과 같다. 기존 Int-GNN 구조에서 GNN을 1개에서 2개 계층으로 깊게 쌓고, Soft-attention을 CBAM 구조로 새롭게 설계하였다. 그림으로 볼 수 있듯이, 각 모듈 내에서 임베딩 벡터들은 GNN 모듈을 거쳐 복잡한 item 또는 position 특성이 포함된 특성 맵을 생성한다.

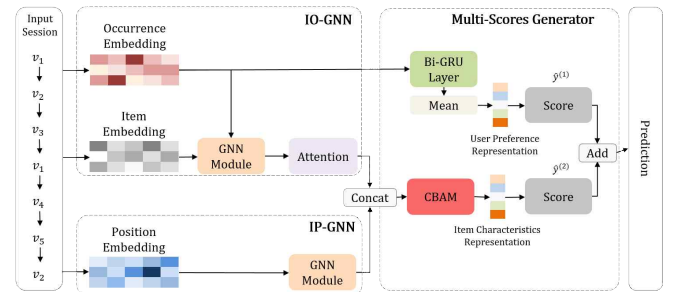


그림 1. Enhanced Int-GNN 구조.

IO-GNN 모듈을 통해 계산된 순차적 item 발생 특성은 IP-GNN 모듈을 통해 추출된 position 특성과 결합(concatenate)되며 CBAM에 입력된다. CBAM은 특성 맵의 주요 특성을 추출하기 위한 어텐션 모듈 중 하나로, 채널과 픽셀 측면에서 집중해야 할 정도를 학습하여 향상된 특성 추출을 돕는다. 선행 모델에서 사용한 Soft-attention과 CBAM의 구조는 그림 2




그림 2. 어텐션 모듈 구조: a) Soft-Attention; b) CBAM.

에서 비교한다. 그림에서  $t$ 는 한 세션에서의 발생 item 개수,  $h$ 는 임베딩 벡터 크기(hidden size)이다. Soft-attention은 각 모듈을 통해 계산된 두 특성 맵들을 단순히 더한 후 추출 특성 측면에서 중요한 정보를 포착하도록 진행된다. 우리는 이러한 데이터 공간 측면 뿐만 아니라 두 모듈을 통해 계산된 피쳐 맵의 채널 측면에서도 중요한 정보를 추출할 수 있도록 Channel Attention과 Spatial Attention으로 구성된 CBAM을 활용한다. 본 연구에서는 IO-GNN과 IP-GNN 모듈의 출력을 결합한 피쳐맵의 채널을  $1 \times 1$  Conv2d 레이어를 통해 2에서 128로 키운 후 어텐션 과정을 진행하고,  $1 \times h$  Conv2d 레이어를 거쳐 다운샘플링된다. 이후 item 특성 표현 벡터를 생성하여 item 측면 추천 확률을 예측한다. 이 값은 Bi-GRU를 통해 순차적인 사용자의 item 선호 특성을 추출한 후 계산된 시간 측면 item 추천 확률과 더해져 최종 추천 확률값으로 출력된다.

## 2.2 사용 데이터셋 및 평가 지표

실험에는 일반적으로 세션 기반 추천 시스템의 성능 확인에 사용되는 데이터 중 하나인 Tmall 데이터셋을 사용한다. Tmall은 익명 사용자의 쇼핑 로그로 구성된 데이터이다. 성능 평가에는 P@20, MRR@20, P@10, MRR@10이 사용되었다. 이때 P@N은 제안 모델이 이후에 발생할 것으로 예측한 상위 N(20 혹은 10)개의 item 중에서 정답이 포함된 경우 1, 포함되지 않은 경우 0을 부여하여 전체 세션에 대해 평균을 취한 값이며 Recall@N이라고도 한다. MRR@N (Mean Reciprocal Rank)은 예측한 상위 N개의 item 내에서 정답이 위치한 순위까지 측정된 지표이다. 이 지표는 상위 N개 item 중 정답이 없는 경우 0, 있는 경우 정답 item의 순위 역수를 부여한 후 전체 세션에 대해 평균을 취하여 계산된다. 즉 두 지표 모두 값이 클수록 추천 모델의 높은 성능을 의미한다.

## 2.3 실험 및 성능 비교

본 논문에서 모든 실험은 선행 연구와 동일하게 세션 내 발생 item 개수  $t$ 는 최대 100 이내에서 가변적으로 설정했고, 임베딩 벡터 크기  $h$ 는 100으로 설정했다. 손실 함수는 Cross-entropy를 사용한다. 모든 파라미터는 표준 정규분포에 따라 초기화되며 학습률은 0.00128로, Adam optimizer에 의해 최적화된다. 학습은 배치 사이즈 512에서 5번 반복 진행한다.

표 1은 실험을 진행한 결과이다. Int-GNN은 선행 모델, Enhanced Int-GNN은 본 논문의 제안 모델이며, Int-GNN(GNN 2)와 Enhanced Int-GNN(GNN 1)은 성능 비교 모델이다. 순서대로 Int-GNN(GNN 2)은 선행 모델에 GNN 계층을 하나 더 추가한(2개 계층) 모델이고, Enhanced Int-GNN(GNN 1)은 CBAM 구조를 사용한 제안 모델에서 GNN 계층을 한 층만 적용한 모델이며, GNN 모듈과 CBAM 구조 사용에 따른 성능 개선 효과를 확인하기 위해 실험을 진행하였다. 우선, 표 1에서 보이는 것처럼 모든 평가 지표에서 제안 모델의 성능이 기존 모델보다 높은 성능을

보인다. 추천 item의 확률 순위 값까지 반영된 MRR에서는 약 0.5, P에서는 약 1 정도의 성능 개선이 있었다. 또한 비교 모델의 성능을 통해 단순히 GNN 레이어를 2개로 키운 경우보다 활성화 함수를 포함하여 모듈화한 후 CBAM을 통해 특성 맵의 중요 정보를 적절하게 결합했을 때 성능 개선의 효과가 향상됨을 확인할 수 있었다.

Metrics	P@20	MRR@20	P@10	MRR@10
Int-GNN [2]	44.4243	19.5887	39.5783	19.2430
Int-GNN (GNN 2)	44.4706	20.1188	39.8371	19.7851
Enhanced Int-GNN (GNN 1)	45.0305	19.7260	40.3927	19.3927
<b>Enhanced Int-GNN</b>	<b>45.4321</b>	<b>20.0771</b>	<b>40.5282</b>	<b>19.7254</b>

표 1. 성능 비교 표.

## III. 결론

본 논문에서는 세션 기반 추천 시스템을 위한 개선된 그래프 기반 모델 Enhanced Int-GNN을 제안하였다. 구체적으로, 기존 사용자 의도 인식 그래프 모델(Int-GNN)의 추천 성능 개선을 위해 그래프 신경망의 계층을 추가한 GNN 모듈을 설계하고 채널 및 픽셀 측면에서 특성 추출에 효과적인 어텐션 모듈 CBAM을 활용하였다. 실험을 통해 제안 모델은 모든 성능 평가 지표에서 0.5 이상의 성능 개선 효과가 있음을 확인하였다.

향후 연구에서는 Diginetica, RetailRocket 등 Tmall보다 크기가 큰 데이터셋에서의 추천 성능을 확인할 예정이며, CBAM 외 다른 어텐션 모듈 또한 적용하여 성능 개선 효과를 비교하고자 한다.

## ACKNOWLEDGMENT

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(RS-2023-00271991).

## 참고 문헌

- [1] Wang, S., Cao, L., Wang, Y., Quan, Z. S., Orgun, M., Lian, D., "A Survey on Session-Based Recommender Systems," Association for Computing Machinery, vol.54, no.7, pp. 1-38, Sep. 2022.
- [2] Xu, G., Yang, J., Guo, J., Huang, Z. and Zhang, B., "Int-GNN: A User Intention Aware Graph Neural Network for Session-Based Recommendation," in Proc. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pp. 1-5, Jun. 4-10, 2023.
- [3] Woo, S., Park, J., Lee, JY., Kweon, I.S., "CBAM: Convolutional Block Attention Module," in Proc. European Conference on Computer Vision (ECCV), pp. 3-19, Sep. 8-14, 2018.