creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

공학석사 학위논문

대조적 표현 학습을 통하여 그룹, 유저, 아이템의 구조를 활용하는 추천 시스템

Recommender System Exploiting Structure of Group, User, and Item via Contrastive Representation Learning

2023년 2월

서울대학교 대학원
전기·정보공학부
김진우

대조적 표현 학습을 통하여 그룹, 유저, 아이템의 구조를 활용하는 추천 시스템

Recommender System Exploiting Structure of Group, User, and Item via Contrastive Representation Learning

지도교수 심 규 석

이 논문을 공학석사 학위논문으로 제출함
2023년 2월

서울대학교 대학원
전기·정보공학부
김진우

김진우의 공학석사 학위논문을 인준함
2023년 2월

위 원 장	김태환	(인)
부위원장	심규석	(인)
위 원	홍성수	(인)

초 록

그룹 추천 시스템은 복수의 유저로 이루어진 그룹에게 아이템을 추천하는 시스템이다. 기존의 그룹 추천 시스템은 그룹-아이템 상호작용이 부족한 상황에서도 정확한 추천을 하기 위해 그룹의 임베딩과 해당 그룹의 구성원의 임베딩 사이의 상호 정보량을 최대화하여 아이템을 추천한다. 그러나 그룹-아이템 상호작용과 유저-아이템 상호작용이 모두 부족한 상황에서는 추천 성능이 떨어진다는 단점이 있다. 이를 해결하기 위하여 본 논문에서는 그룹과 유저에 대한 대조적 표현 학습뿐만 아니라 그룹과 아이템에 대한 대조적 표현 학습을 사용하는 모델을 제안한다. 이에 더해 적대적 생성 신경망을 적용한 협업 필터링을 사용하여 유저-아이템 상호작용 데이터를 증강시키는 방법과 기존의 그룹로부터 새로운 그룹을 만들어 데이터 증강을 하는 방법을 제시한다. 또한, 실험을 통하여 제안하는 방식이 그룹과 아이템, 유저와 아이템 간의 상호작용들이 부족한 상황에서도 추천 성능을 향상시킴을 확인한다.

주요어 : 그룹 추천, 신경망 기반 협업 필터링, 대조적 표현 학습, 데이터 희소성, 적대적 학습
학 번 : 2021-22993

목 차

제 1 장 서 론 ····· 1
제 1 절 연구의 배경 및 내용 ····· 1
제 2 장 관련 연구 ····· 4
제 1 절 그룹 추천 시스템 ····· 4
제 2 절 CFGAN ····· 10
제 3 장 제안하는 모델 ····· 12
제 1 절 문제 정의 ····· 13
제 2 절 그룹-아이템 쌍에 대한 대조적 표현 학습을 이용한 그룹 추천 ····· 14
제 3 절 CFGAN을 이용한 그룹 추천 ····· 16
제 4 절 그룹에 대한 데이터 증강을 이용한 그룹 추천 ····· 18
제 4 장 실 험 ····· 19
제 1 절 실험 환경 및 실험 데이터 ····· 19
제 2 절 성능 평가 지표 및 실험 설정 ····· 19
제 3 절 실험 결과 및 분석 ····· 21
제 5 장 결 론 ····· 23
참 고 문 헌 ····· 24
Abstract ····· 26

표 목 차

[표 1] Weeplaces 데이터셋의 각 그룹의 구성원 수에 대한 통계 ···· 18

[표 2] 유저-아이템 상호작용 샘플링 비율에 따른 Weeplaces에 대한 그룹 추천 결과 ····· 21

그 림 목 차

[그림 1] 신경망 기반 그룹 추천 시스템의 기본 구조 ····· 6

[그림 2] GroupIM의 구조 ····· 7

[그림 3] 그룹-아이템 쌍에 대한 대조적 표현 학습 ····· 14

[그림 4] CFGAN을 이용한 유저-아이템 데이터 증강 ····· 16

제 1 장 서 론

제 1 절 연구의 배경 및 내용

그룹 추천 시스템(group recommendation system)은 복수의 유저로 이루어진 그룹에게 아이템을 추천하는 시스템이다. 이러한 시스템은 실생활에서 숙박 시설의 예약, 가족과의 외식, 친구와의 영화 관람, 축제 참여와 같은 다양한 상황에 쓰일 수 있다. 예를 들어, 영화를 같이 보고자 하는 친구들을 하나의 그룹으로 볼 수 있고 영화에 대한 그룹 추천 시스템은 해당 그룹의 모든 구성원들이 보고 싶어할 만한 영화를 추천할 때 쓰일 수 있다.

유저에 대한 추천 시스템에서는 일반적으로 유저가 아이템을 구매한 기록을 활용하여 해당 유저가 구매할 만한 아이템을 추천한다. 반면에, 그룹 추천 시스템에서는 그룹이 아이템을 구매한 기록들을 바탕으로 해당 그룹이 구매할 만한 아이템을 추천한다. 그룹이 아이템을 구매한다는 것은 그룹의 모든 구성원이 해당 아이템을 구매함을 뜻한다. 본 논문에서는 유저가 아이템을 구매하는 것을 유저-아이템 상호작용(user-item interaction)으로, 그룹이 아이템을 구매하는 것을 그룹-아이템 상호작용(group-item interaction)으로 지칭한다.

그룹-아이템 상호작용을 이용한 그룹 추천 시스템에 관한 연구가 진행되었다[2]. MoSAN[2]에서는 그룹을 이루는 유저들의 임베딩을 집계(aggregate)하여 만든 그룹의 임베딩과 아이템의 임베딩으로부터 그룹이 아이템을 구매할 확률의 예측값을 사용하여, 그룹이 실제로 구매한 아이템에 대해 모델이 예측하는 구매 확률을 높이도록 학습한다.

MoSAN은 이와 같이 그룹-아이템 상호작용을 이용하여 그룹 추천을 한다. 그러나 그룹의 모든 구성원들이 공통의 아이템을 구매할 확률은 낮기에 그룹은 평균적으로 소수의 아이템만을 구매하며 이에 따라 그룹-아이템 상호작용의 수는 매우 적다. 이러한 데이터의 특징

을 그룹-아이템 상호작용의 희소성(sparsity)이라 한다. 이러한 희소성으로 인해 그룹과 아이템 사이의 상관관계를 학습할 때 필요한 데이터의 양이 부족하여 MoSAN과 같이 그룹-아이템 상호작용만을 학습에 사용하는 그룹 추천 시스템은 낮은 그룹 추천 성능을 보인다.

이러한 문제점을 해결하기 위해 GroupIM[1]에서는 유저의 아이템 구매 기록을 추가적으로 이용하는 방법을 제안한다. GroupIM은 유저-아이템 상호작용을 이용하여 유저의 선호도가 그룹에 따라 달라진다는 점, 그룹 구성원들의 선호도가 비슷하다는 점을 모델 학습에 반영한다. 이에 따라 GroupIM은 그룹-아이템 상호작용이 희소한 상황에서도 높은 그룹 추천 성능을 보인다. 하지만 유저-아이템 상호작용 또한 유저가 구매한 아이템이 전체 아이템에 비해 매우 적기 때문에 많은 경우에 희소성을 보인다. 이렇게 유저-아이템 상호작용 또한 희소한 경우에는 그룹-아이템 상호작용만 희소한 상황에 비해 GroupIM의 그룹 추천 성능이 크게 떨어진다는 문제점이 있다.

이러한 문제점을 해결하기 위해 본 논문에서는 GroupIM[1]에 대조적 표현 학습(contrastive representation learning)을 추가적으로 적용하는 방법을 제안한다. 유저-아이템 상호작용의 희소성으로 인해 유저가 평균적으로 구매한 아이템의 수는 적지만 그룹의 각각 구성원들이 구매한 아이템들의 합집합에 들어있는 아이템 수는 상대적으로 많다. 대조적 표현 학습은 그룹의 구성원들이 구매한 아이템들의 합집합으로부터 샘플링한 아이템에 대해서도 모델이 예측하는 구매 확률을 높이도록 학습하여 그룹 추천 성능을 향상시킨다. 대조적 표현 학습은 자기 지도 학습의 일종으로 비슷한 성질의 데이터들은 높은 유사도(similarity)를, 다른 성질의 데이터들은 낮은 유사도를 갖도록 임베딩을 학습하는 기법이다. 본 논문에서는 각 그룹에 대해 양성 아이템과 음성 아이템을 샘플링한 후에 그룹 임베딩과 양성 샘플의 임베딩 간의 코사인 유사도(cosine similarity)를 그룹 임베딩과 음성 샘플의 임베딩 간의 코사인 유사도보다 더 높은 값을 가지도록 모델을 훈련시킨다.

또한 본 논문에서는 적대적 생성 신경망(generative adversarial network)[4]을 적용한 추천 시스템인 CFGAN[3]을 이용하여 유저-아이템 상호작용 데이터를 증강하는 방법과 기존의 그룹으로부터 새로운 그룹을 만들어 그룹-아이템 상호작용 데이터를 증강하는 방법을 제시한다. 전자는 CFGAN이 예측하는 유저가 아이템을 구매할 확률을 이용하며 예측된 확률이 높은 경우 유저가 아이템을 구매하였다고 가정함으로써 유저-아이템 상호작용 데이터를 증강한다. 후자는 그룹의 구성원 중 한 명이라도 구매하지 않은 아이템은 그룹-아이템 상호작용에 포함되지 않지만, 해당 구성원을 제외하여 만든 새로운 그룹에서는 해당 아이템을 그룹-아이템 상호작용에 포함시킬 수 있다는 점을 이용한다. 제시한 두 방법 모두 상호작용 데이터의 희소성을 완화시켜 GroupIM[1] 등의 그룹 추천 시스템이 높은 그룹 추천 성능을 낼 수 있도록 한다. 실험을 통하여 제안하는 방법들이 그룹과 아이템, 유저와 아이템 간의 상호작용들이 부족한 상황에서도 높은 추천 성능을 보이는 것을 확인한다.

본 논문의 구성은 다음과 같다. 2장에서는 관련 연구들을 소개하며, 3장에서는 문제 정의와 본 논문에서 제안하는 세 가지 프레임워크를 소개한다. 4장에서는 실험을 통해 제안한 방식들과 기존 모델의 성능을 비교하고 실험 결과를 분석한다. 마지막으로 5장에서 결론을 맺는다.

제 2 장 관련 연구

제 1 절 그룹 추천 시스템

정보 과잉의 시대에서 사용자에게 필요한 정보를 효과적으로 제공하기 위해 전자 상거래 플랫폼, 소셜 미디어 사이트, 뉴스 포털 등과 같은 온라인 정보 시스템에 추천 시스템이 널리 쓰인다. 효과적인 추천 시스템은 서비스 제공자가 얻는 이익을 증대시킬 뿐만 아니라 고객이 원하는 아이템을 더 쉽게 찾을 수 있도록 한다[5, 6, 7]. 우리는 개인 사용자에게 아이템을 추천하는 기존의 태스크에서 벗어나, 그룹 사용자에게 아이템을 추천하는 서비스를 제공하는 데에 초점을 맞춘다. 그룹 추천은 추천의 대상이 되는 그룹의 종류인 지속 그룹(persistent group)과 단기 그룹(ephemeral group)에 따라 두 가지 범주로 나뉜다.

지속 그룹 추천(persistent group recommendation):

기존의 연구들은 지속 그룹에 대한 추천을 목표로 한다. 지속 그룹은 다수의 아이템을 구매한 이력이 있고 멤버의 구성이 거의 변하지 않는 안정적인 그룹을 뜻한다. 지속 그룹에 대한 추천 시스템은 두 가지 범주로 나뉜다. [8]과 같은 휴리스틱 룰 기반 집계(heuristic rule-based aggregation) 방식, 그리고 확률적 모델(probabilistic model)[9, 10]과 신경망 선호도 집계(neural preference aggregator)[2, 11]와 같은 데이터 기반 방식이 있다. 이러한 방식은 개인 사용자의 아이템 구매 기록을 고려하지 않거나 유저의 역할, 즉 그룹 구매에 대한 영향력이 유저가 속한 모든 그룹에서 동등하다는 문제점이 있다. 이러한 표현력(expressivity)의 부족은 아이템과의 상호작용이 부족한 단기 그룹에 대해서 추천 성능의 악화를 불러일으킨다.

단기 그룹 추천(ephemeral group recommendation):

단기 그룹은 구성원들이 그룹으로서 아이템을 구매한 기록이 거의 없는 그룹을 뜻한다. 예를 들어, 두 사람 A, B가 각자 자신의 가족들과 여러 음식점에 방문한 기록이 있다고 하자. 그러나, A와 B의 가족이 처음으로 만나 같이 식사를 하게 되었을 때, 이 그룹에 대한 음식점 방문 기록은 존재하지 않는다. 이와 같이 단기 그룹은 같이 아이템을 구매한 기록이 거의 없는 그룹을 뜻하며, 완전 단기 그룹은 같이 아이템을 구매한 기록이 전혀 없는 그룹을 뜻한다.

단기 그룹 추천 문제의 정의는 다음과 같다. 유저의 집합 $U=\{u_1, u_2, ..., u_{|U|}\}$, 아이템의 집합 $I=\{i_1, i_2, ..., i_{|I|}\}$, 그룹의 집합 $G=\{g_1, g_2, ..., g_{|G|}\}$가 주어져 있으며, 이들 사이의 구매 이력인 $|U|\times|I|$ 크기의 유저-아이템 상호작용 행렬 X_{UI}, $|G|\times|I|$ 크기의 그룹-아이템 상호작용 희소행렬(sparse matrix) X_{GI}가 암시적 피드백으로 주어져 있다. 각 그룹 $g_k(k=1,2,...,|G|)$는 유저의 집합 U의 부분집합으로 주어지며, 유저 u와 그룹 g의 아이템 상호작용은 각각 $x_u \in \mathbb{R}^{|I|}$, $x_g \in \mathbb{R}^{|I|}$로 표기한다.

단기 그룹 추천 문제는 아이템을 구매한 적이 없는 완전 단기 그룹(strict ephemeral group) $g \subset U$가 주어졌을 때, I에 속하는 아이템들에 대해 g의 선호도에 따른 순위 리스트(ranked list)를 생성하는 문제이다. 본 절에서는 단기 그룹 추천 문제에 대해 SOTA(state-of-the-art) 성능을 보이는 추천 시스템 GroupIM[1]에 대해 구체적으로 소개한다.

신경망을 사용한 다양한 그룹 추천 시스템[1, 2, 11]들이 높은 추천 성능을 보인다. 이러한 추천 시스템들은 선호도 인코더(preference encoder), 선호도 집계자(preference aggregator), 그리고 그룹 예측자(group predictor)로 구성된 기본 구조 R을 공유한다.

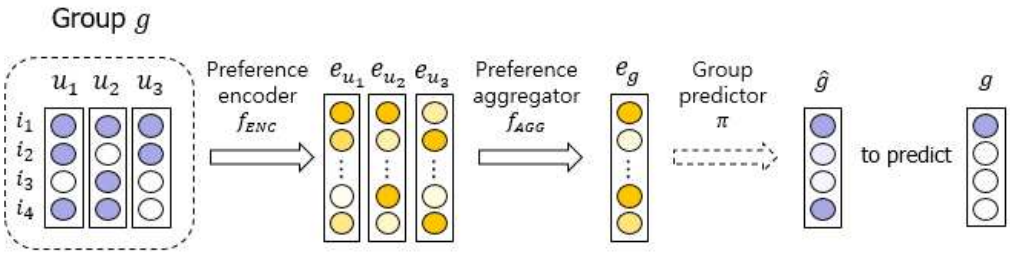

그림 1. 신경망 기반 그룹 추천 시스템의 기본 구조 R

그림 1에서 기본 구조 R은 선호도 인코더 f_{ENC}, 선호도 집계자 f_{AGG}, 그리고 그룹 예측자 π로 구성되어 있다. 선호도 인코더 f_{ENC}는 유저 u의 구매 내역 x_u가 주어졌을 때 유저 u의 선호도를 나타내는 임베딩 $e_u \in \mathbb{R}^d$를 출력한다. d는 임베딩 벡터의 차원이다. 선호도 집계자 f_{AGG}는 그룹 g의 모든 구성원들의 임베딩 $\{e_u : u \in g\}$을 집계(aggregate)하여 그룹 g의 선호도를 나타내는 임베딩 $e_g \in \mathbb{R}^d$를 출력한다. f_{AGG}에는 최대 풀링(max pooling), 평균 풀링(mean pooling), 그리고 어텐션 메커니즘(attention mechanism)이 사용된다. 본 실험에서는 가장 그룹 추천 성능이 좋은 어텐션 메커니즘을 사용하여 임베딩들을 집계한다. 그룹 예측자 π는 e_g를 입력으로 받아 그룹이 각 아이템을 구매할 확률 $\pi(e_g) \in [0,1]^{|I|}$를 구한다. 모델을 훈련시키기 위해 식 (2-1)과 같이 그룹과 유저에 대한 교차 엔트로피(cross-entropy) 손실 함수 L_G와 L_U을 합산한 L_R를 사용한다.

$$L_R = L_G + \lambda_U L_U \qquad \text{식 (2-1)}$$

$$L_G = -\sum_{g \in G} \frac{1}{|x_g|} \sum_{i \in I} x_{gi} \log \pi_i(e_g) \qquad \text{식 (2-2)}$$

$$L_U = -\sum_{u \in U} \frac{1}{|x_u|} \sum_{i \in I} x_{ui} \log \pi_i'(e_u) \qquad \text{식 (2-3)}$$

여기서 λ_U는 손실 함수의 비율을 결정하는 하이퍼파라미터이고, π'는 유저에 대한 예측자로 그룹 예측자 π와 구분된다. L_R을 통해 유저 임베딩 e_u와 그룹 임베딩 e_g가 각각 유저 u의 구매 내역과 그룹 g의 구매 내역을 예측할 수 있도록 학습된다.

GroupIM은 이와 같은 기본 구조에 두 가지의 정규화(regularization) 기법을 사용한다. 첫 번째 정규화에서는 유저들이 그룹의 구매 결정에 미치는 영향력을 학습하며, 두 번째 정규화에서는 학습한 영향력을 가중치로 사용하여 각 구성원이 그룹의 구매 결정에 미치는 영향력을 반영한다.

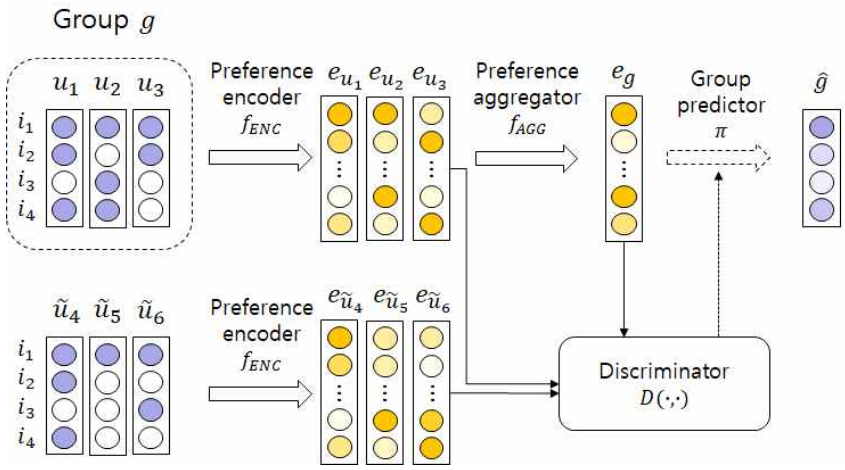

그림 2. GroupIM의 구조

그림 2는 GroupIM의 구조를 나타낸다. 선호도 인코더 f_{ENC}는 그룹 g의 구성원 u_1, u_2, u_3에 대한 선호도 임베딩 e_{u_1}, e_{u_2}, e_{u_3}과 음성 샘플링에 의해 선택된 그룹 g의 비구성원 $\tilde{u}_4$, $\tilde{u}_5$, $\tilde{u}_6$에 대한 선호도 임베딩 $e_{\tilde{u}_4}$, $e_{\tilde{u}_5}$, $e_{\tilde{u}_6}$를 리턴한다. 선호도 집계자 f_{AGG}는 그룹 구성원에 대한 임베딩 e_{u_1}, e_{u_2}, e_{u_3}을 집계하여 그룹 임베딩 e_g를 반환한다. 구별자(discriminator) 모델 D는 그룹 임베딩 e_g와 함께 구성원의 임베딩

e_{u_1}, e_{u_2}, e_{u_3} 또는 비구성원의 임베딩 $e_{\tilde{u}_4}$, $e_{\tilde{u}_5}$, $e_{\tilde{u}_6}$을 입력으로 받아 구성원의 경우 1에 가까운 높은 스코어(score)를, 비구성원의 경우 0에 가까운 낮은 스코어를 리턴하도록 학습한다. 구별자 모델 D가 리턴한 스코어는 손실 함수 L_{UG}에서 그룹 구성원에 대한 가중치로 사용되어 구성원마다 다른 그룹 구매에 미치는 영향력을 모델 학습에 반영한다.

첫 번째 정규화인 대조 정규화(contrastive regularization)에서 구별자 모델 D는 유저 임베딩 e_u와 그룹 임베딩 e_g를 입력으로 받아 유저 u가 그룹 g의 구매 결정에 미치는 영향력을 학습한다. D의 출력 $D(e_u, e_g) \in [0,1]$은 식 (2-4)와 같이 주어진다.

$$D(e_u, e_g) = \sigma(e_u^T W e_g) \qquad \text{식 (2-4)}$$

여기서 $W \in \mathbb{R}^{d \times d}$는 학습 가능한 파라미터이며, σ는 시그모이드(sigmoid) 함수를 나타낸다.

u가 g의 구성원인 경우 $D(e_u, e_g)$가 큰 값을 갖고 비구성원인 경우 작은 값을 갖도록 제어하기 위해 다음과 같은 상호 정보량 손실 함수(mutual information loss) L_{MI}를 사용한다.

$$L_{MI} = -\frac{1}{|G|}\sum_{g \in G}\left[\frac{1}{|g|}\sum_{u \in g}\log D(e_u, e_g) + E_{\tilde{u} \sim P_{N|g}}[\log(1 - D(e_{\tilde{u}}, e_g))]\right] \qquad \text{식 (2-5)}$$

식 (2-5)를 통하여 그룹 g와 구성원 u 사이의 $D(e_u, e_g)$를 최대화하고 그룹 g와 비구성원 $\tilde{u}$ 사이의 $D(e_{\tilde{u}}, e_g)$를 최소화하도록 학습한다. 여기서 α_g는 그룹 g의 총 유저 샘플의 개수이며, M_g는 그룹 g에 속하지 않는 비구성원 샘플의 개수이다. 비구성원 $\tilde{u}$를 선택하는 음성 샘플링(negative sampling) 확률분포 $P_N(\tilde{u}|g)$은 다음과 같이 정의된다.

$$P_N(\tilde{u}|g) \propto \tau I(x_{\tilde{u}}^T \cdot x_g > 0) + (1-\tau)\frac{1}{|U|} \qquad \text{식 (2-6)}$$

$I(p)$는 명제 p가 참일 때 1, 거짓일 때 0의 값을 가지는 지시 함수(indicator function)이고 τ는 I로 표시된 분포와 유저 균등 분포의 비율을 결정하는 파라미터이다. 위 분포에서 그룹과 구매 내역이 비슷한 비구성원일수록 음성 샘플로 선택될 확률이 높아진다. 그룹 구성원이 아니라면 해당 그룹과 선호도가 비슷하다 하더라도 D의 값이 작아진다는 것이다. 이러한 샘플링을 통해 해당 샘플이 해당 그룹에서 구성원이 될 수 없었던 잠재적인 이유를 반영할 수 있다.

두 번째 정규화에서는 학습한 $D(e_u, e_g)$를 구성원 u의 구매 내역인 x_u에 대한 가중치로 사용하여 각 구성원 u가 그룹 g의 구매 결정에 미치는 영향력을 학습에 반영한다. 이를 위해 다음과 같은 유저-그룹 손실 함수 L_{UG}를 사용한다.

$$L_{UG} = -\sum_{g \in G} \frac{1}{|x_g|} \sum_{u \in g} \sum_{i \in I} D(e_u, e_g) x_{ui} \log \pi_i(e_g) \qquad \text{식 (2-7)}$$

식 (2-7)은 교차 엔트로피 손실 함수이며, 그룹 g가 아이템 i를 구매할 확률인 $\pi_i(e_g)$를 구성원 u와 아이템 i의 상호작용 x_{ui}에 맞춘다.

위에서 설명한 식 (2-2), (2-5), 그리고 (2-7)에서 언급한 손실 함수들을 더하여 전체 모델을 학습하기 위한 손실 함수 $L_{GroupIM}$을 식 (2-8)과 같이 정의한다.

$$L_{GroupIM} = L_G + \lambda_{UG} L_{UG} + L_{MI} \qquad \text{식 (2-8)}$$

여기서 λ_{UG}는 양의 값을 가지는 정규화 상수(regularization coefficient)이다.

제 2 절 CFGAN

유저-아이템 상호작용이 부족한 상황에서 유저-아이템 상호작용 데이터를 증강하기 위해 본 논문에서 CFGAN[3]을 사용한다. CFGAN은 구별자 모델(discriminator)과 생성자 모델(generator)로 구성된 GAN[4]을 협업 필터링(collaborative filtering)에 적용하여 유저에 대한 추천 성능을 높인 프레임워크이다. 기존의 GAN에 기반한 추천 시스템[12, 13]들은 공통적인 문제점을 갖고 있는데, GAN이 주로 다루는 이미지 데이터와 달리 아이템 번호(index)는 이산적(discrete)이기 때문에 생성자가 생성한 거짓 아이템과 실제로 유저가 선호하는 아이템이 중복될 수 있다는 것이다. 중복된 아이템은 진실이자 동시에 거짓이 되어 구별자 모델의 학습을 방해하고 성능을 악화시킨다. 이는 또한 생성자 모델에 잘못된 신호를 주어 최종적으로 추천 성능을 악화시킨다.

이러한 문제를 해결하기 위하여 CFGAN은 아이템 번호를 생성하는 대신, 모든 아이템에 대하여 0과 1 사이의 실수 값을 가진 구매 내역(purchase vector)을 생성하여 중복되는 아이템의 생성을 방지한다. 이로써 구별자 모델은 입력으로 들어온 구매 내역이 유저의 실제 구매 내역인지, 생성자가 모방하여 생성한 거짓 구매 내역인지 구별할 수 있게 되어 생성자 모델과 함께 적대적 학습을 성공적으로 수행할 수 있게 된다. 구별자와 생성자의 손실 함수 J^D, J^G는 다음 식 (2-9), (2-10)과 같다.

$$J^D = -\sum_u (\log D(r_u | c_u) + \log(1 - D((\hat{r}_u \circ e_u) | c_u))) \qquad \text{식 (2-9)}$$

$$J^G = \sum_u (\log(1 - D((\hat{r}_u \circ e_u) | c_u)) \qquad \text{식 (2-10)}$$

여기서 D는 구별자 모델이 입력으로 들어온 벡터를 거짓 구매 내역 $\hat{r}_u$가 아닌 실제 유저의 구매 내역 r_u로 판단할 확률이며, e_u는 유저가 실제로 각 아이템을 구매하였는지를 나타내는 지시자(indicator

vector)로 유저가 구매한 아이템(ground truth)에 대해서만 학습에 반영하는 마스킹(masking) 역할을 한다.

그러나 이러한 방식에는 맹점이 있는데 생성자가 모든 아이템에 대하여 1을 출력하면 실제 구매 내역과 가장 유사한 벡터를 생성할 수 있다는 것이다. 하지만 이는 유저의 아이템 간 선호도의 차이를 반영할 수 없기에 매 에폭(epoch)마다 구매되지 않은 아이템들 중 일부를 무작위로 선택하여 음성 샘플로서 학습에 이용한다.

선택된 음성 샘플들을 어떠한 방식으로 사용하는지에 따라 다음과 같이 세 가지 방법을 정의한다. 음성 샘플들을 정규화(regularization)에 이용하는 방법, 음성 샘플들에 대해 마스킹을 해제하여 손실 함수 자체에 반영하는 방법, 두 가지를 모두 이용하는 방법이 있다. 본 실험에서는 학습이 가장 빠르게 진행되는 첫 번째 방법을 선택하였으며 각 모델의 손실 함수 J^D, J^G는 다음 식 (2-11), (2-12)와 같다.

$$J^D = -\sum_u (\log D(r_u | c_u) + \log(1 - D((\hat{r}_u \circ e_u) | c_u))) \qquad \text{식 (2-11)}$$

$$J^G = \sum_u (\log(1 - D((\hat{r}_u \circ e_u) | c_u)) + \alpha \sum_j (x_{uj} - \hat{r}_{uj})^2) \qquad \text{식 (2-12)}$$

여기서 α는 정규화 상수로 음성 샘플 j에 대한 생성자의 출력 $\hat{r}_{uj}$를 $x_{uj} = 0$에 가깝게 만들어, 모든 아이템에 대해 1을 출력하는 자명한 해(trivial solution)를 생성하는 것을 방지한다.

제 3 장 제안하는 모델

GroupIM[1]은 그룹-아이템 상호작용이 부족한 단기 그룹 추천 문제에 대해 높은 성능을 보이지만, 그룹-아이템 상호작용뿐만 아니라 유저-아이템 상호작용 또한 부족한 상황에서는 그룹 추천 성능이 두드러지게 악화된다는 단점이 있다. 예를 들어, 두 사람 A, B가 각자 자신의 가족들과도 음식점에 방문한 기록이 거의 없고, A와 B 본인들도 음식점에 방문한 기록이 거의 없으면 A와 B의 가족이 만나 처음으로 같이 식사를 하게 되었을 때, 이 그룹에 대해 음식점을 추천하는 것은 매우 어렵다. 이러한 문제점을 해결하기 위해 본 논문에서는 2장 관련 연구에서 소개한 GroupIM을 기반으로 한 세 가지 프레임워크를 제안한다. 첫 번째 프레임워크인 GroupCRL[14]은 그룹-아이템 쌍에 대하여 대조적 표현 학습을 적용하여 그룹 추천 성능을 향상시키며, 두 번째 프레임워크인 GroupCFGAN[15]에서는 부족한 유저-아이템 상호작용을 증강하기 위해 추천 시스템인 CFGAN[3]을 이용한다. 마지막으로 세 번째 프레임워크인 GroupAug[16]는 기존의 그룹들로부터 구성원을 한 명씩 탈락시켜 새로운 그룹을 만든 후 훈련 데이터셋에 포함시킨다.

제 1 절 문제 정의

유저의 집합 $U=\{u_1, u_2, ..., u_{|U|}\}$, 아이템의 집합 $I=\{i_1, i_2, ..., i_{|I|}\}$, 그룹의 집합 $G=\{g_1, g_2, ..., g_{|G|}\}$가 주어져 있으며, 이들 사이의 구매 이력인 $|U|\times|I|$ 크기의 유저-아이템 상호작용 행렬 X_{UI}, $|G|\times|I|$ 크기의 그룹-아이템 상호작용 행렬 X_{GI}가 암시적 피드백으로 주어져 있다. 각 그룹 $g_k(k=1,2,...,|G|)$는 유저의 집합 U의 부분집합으로 주어지며, 유저 u와 그룹 g의 아이템 상호작용은 각각 $x_u \in \mathbb{R}^{|I|}$, $x_g \in \mathbb{R}^{|I|}$로 표기한다.

단기 그룹 추천 문제는 아이템을 구매한 적이 없는 완전 단기 그룹(strict ephemeral group) $g \in G$가 주어졌을 때, I에 속하는 아이템들에 대해 g의 선호도에 따른 순위 리스트(ranked list)를 생성하는 문제이다. 본 논문에서는 단기 그룹 추천 문제를 확장하여 그룹-아이템 상호작용뿐만 아니라 유저-아이템 상호작용도 부족한 상황에서 아이템을 추천하는 문제를 다룬다.

제 2 절 그룹-아이템 쌍에 대한 대조적 표현 학습을 이용한 그룹 추천

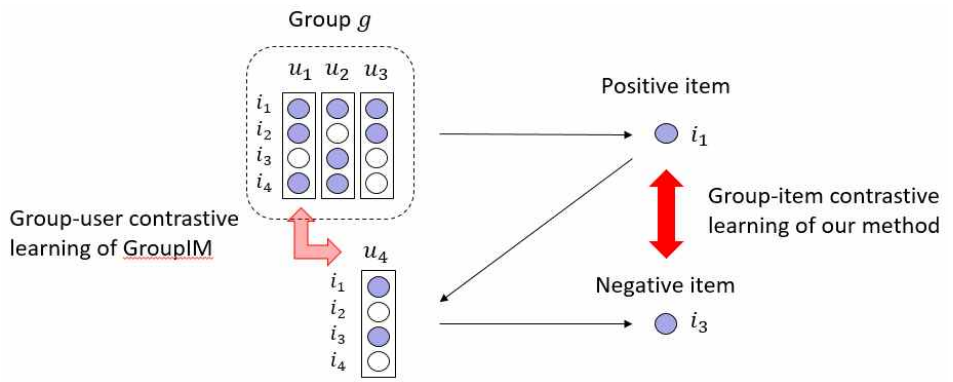

그림 3. 그룹-아이템 쌍에 대한 대조적 표현 학습

본 논문에서는 구성원-아이템 상호작용을 이용하여 그룹-아이템 쌍에 대해 대조적 표현 학습을 적용한 모델 GroupCRL을 제안한다. 그룹-아이템 쌍에 대한 대조적 표현 학습에서는 그룹이 좋아하는 아이템과 덜 좋아하는 아이템을 샘플링한 후, 두 아이템에 대한 상대적인 선호도의 차이를 반영하여 모델을 학습시킨다.

그림 3에서 그룹 g는 유저 u_1, u_2, u_3로 구성되어 있으며 각각의 유저들은 아이템 구매 내역을 가지고 있다. 많은 유저들이 구매한 아이템인 i_1가 그룹 g가 좋아하는 아이템으로 선택되고, 그룹 g에는 속하지 않지만 아이템 i_1를 구매한 기록이 있는 유저 u_4가 구매한 아이템인 i_3가 그룹 g가 덜 좋아하는 아이템으로 선택된다.

그룹 g에 대하여 선호하는 아이템 i와 선호하지 않는 아이템 j를 선택한다. 많은 구성원들이 구매한 아이템일수록 그룹 또한 선호할 가능성이 높기에 i로 선택될 확률이 높아진다. 양성 샘플(positive sample) i를 선택하는 확률분포 P_P는 식 (3-1)과 같이 정의된다.

$$P_P(i|g) \propto \sum_{u \in g} x_{ui} \qquad \text{식 (3-1)}$$

아이템 i를 구매하였으나 그룹 g에는 속하지 않는 비구성원이 선호하는 아이템 j를 그룹 g가 선호하지 않는 아이템으로 정한다. GroupIM[1]의 대조 정규화와 마찬가지로 완전히 선호하지 않는 아이템보다는 덜 선호하는 아이템을 선택하여 더 정교하게 상대적인 선호도의 차이를 반영한다. 이를 위하여 아래 식 (3-2)와 같은 BPR (Bayesian Personalized Ranking)[17] 손실 함수 L_{BPR}을 제안한다.

$$L_{BPR} = \sum_{g,i,j} -\log \sigma(e_g w_{gi}^T - e_g w_{gj}^T) + \lambda \| e_g \|^2 + \lambda \| w_{gi} \|^2 + \lambda \| w_{gj} \|^2 \quad \text{식 (3-2)}$$

여기서 w_{gi}, w_{gj}는 그룹 g에서 선택된 아이템 i, j의 임베딩을 뜻한다. λ는 임베딩들을 정규화하는 하이퍼파라미터이다. 본래는 유저-아이템 쌍에 대해 정의된 BPR 손실 함수를 그룹-아이템 쌍에 대하여 변형하여 적용한 것이다.

학습에 사용되는 손실 함수 L_{CRL}은 식 (2-8)에서 보인 GroupIM의 손실 함수 $L_{GroupIM}$에 본 연구에서 제안하는 BPR 손실 함수 식 (3-2)를 더한 값이다.

$$L_{CRL} = L_{GroupIM} + \lambda_{BPR} L_{BPR} \quad \text{식 (3-3)}$$

여기서 λ_{BPR}은 BPR 손실 함수에 대한 하이퍼파라미터이다.

제 3 절 CFGAN을 이용한 그룹 추천

본 논문에서는 GroupCRL[14]을 훈련시키기에 앞서 추천 시스템 CFGAN[3]을 이용하여 부족한 유저-아이템 상호작용 데이터를 증강하는 프레임워크인 GroupCFGAN[15]을 제안한다. CFGAN은 2장 관련 연구에서 언급한 바와 같이, 주어진 유저에 대해 거짓 구매 내역을 생성하는 생성자와 이를 실제 구매 내역과 구별하는 구별자의 적대적 학습을 진행하며, 음성 샘플들을 통해 생성자의 출력을 정규화하는 방법을 사용한다.

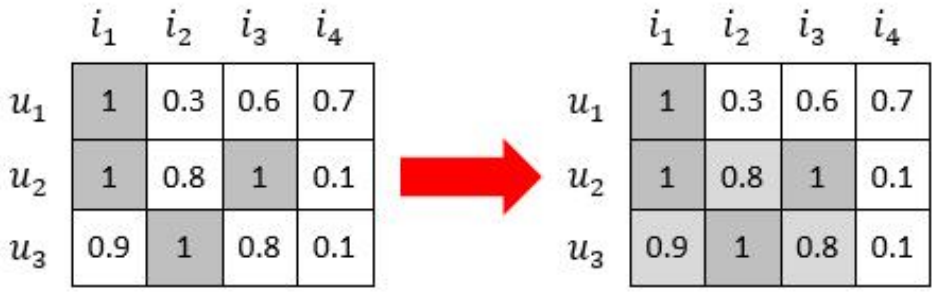

그림 4. CFGAN을 이용한 유저-아이템 데이터 증강

먼저 희소한 유저-아이템 상호작용 데이터를 사용하여 CFGAN을 훈련시킨다. 학습이 완료된 후 생성자는 각각의 유저들이 아직 구매하지 않은 모든 아이템에 대하여 구매할 확률을 예측한다. 이러한 확률에 임계점(threshold)을 두어 각 유저에 대해 차등적으로 아이템을 증강한다. 유저가 구매할 확률이 높은 아이템만 데이터 증강에 사용한다는 것이다. 그림 4는 CFGAN에 의한 유저-아이템 상호작용 증강을 보여준다. 진한 회색은 유저가 이미 구매한 아이템, 옅은 회색은 CFGAN이 예측하는 구매 확률이 임의로 정한 임계점 0.75를 넘어 증강된 유저-아이템 상호작용을 나타낸다. 증강된 유저-아이템 상호작용은 u_2-i_2, u_3-i_1, u_3-i_3 세 쌍이다. 이러한 과정에서 그룹의 모든 구성원들이 구매한 아이템이 생긴 경우 그룹 또한 해당 아이템을 구매한 것으로 간주하여 그룹-아이템 상호작용에 포함시킨다. 그림 4의

경우 i_1을 그룹의 모든 구성원 u_1, u_2, u_3가 구매하였기에 해당 그룹이 i_1을 구매한 것으로 간주한다. 이후 증강된 유저-아이템, 그룹-아이템 상호작용을 이용하여 GroupCRL을 학습시켜 그룹 추천 성능을 향상시킨다.

제 4 절 그룹에 대한 데이터 증강을 이용한 그룹 추천

본 논문에서는 GroupCRL[14]을 훈련시키기에 앞서 그룹에 대해 데이터 증강을 적용하는 GroupAug[16]를 제안한다. 기존의 그룹 g에서 구성원 한 명을 임의로 제외하여 새로운 그룹 g'을 만든 후 g'의 모든 구성원이 구매한 아이템을 그룹 g'이 구매한 아이템으로 간주한다. 이 과정에서 g'는 g가 구매하지 않은 아이템들을 구매하게 되는데 가능한 $|g|$개의 그룹 중에서 이러한 아이템이 가장 많은 그룹을 학습 데이터에 추가한다. 실험에 사용하는 POI(point-of-interest) 데이터셋의 경우 대개 그룹에 속하는 구성원 수가 작아 구성원을 두 명 이상 제외하지 않는다. 구성원 수가 1명 이하가 되어 그룹을 이루지 못하는 경우가 빈번하게 발생하기 때문이다. 표 1은 POI 데이터셋인 Weeplaces[18]의 각 그룹의 구성원 수에 대한 통계이다. 전체 22,733개의 그룹 중 구성원의 수가 3명 이하인 그룹의 수는 18,240개로 구성원을 두 명 제외한다면 해당 그룹들로부터 새로운 그룹을 만들지 못할 것이다.

#(member)	2	3	4	>4	total
#(groups)	12,653	5,587	2,202	2,291	22,733

표 1. Weeplaces 데이터셋의 각 그룹의 구성원 수에 대한 통계

이에 더해, g'에 포함되지 못한 g의 구성원은 GroupIM의 대조 정규화에서 구별자 D를 학습시킬 때 음성 샘플에 포함시키지 않는 예외 처리를 한다. g'은 본래 g로부터 생성한 그룹이므로 탈락된 유저가 g와 유사한 성질을 가지는 g'로부터 탈락한 이유를 반영한다면 학습에 악영향을 줄 수 있기 때문이다.

제 4 장 실 험

제 1 절 실험 환경 및 실험 데이터

GroupIM[1]과 마찬가지로 미국 주요 도시의 POI 체크인 내역을 기록한 데이터셋인 Weeplaces[18]를 사용하였다. 총 8,643명의 유저, 22,733개의 그룹, 25,081개의 아이템이 있다. 총 1,358,458개의 유저-아이템 상호작용이 있으며, 180,229개의 그룹-아이템 상호작용이 있다. POI 데이터셋은 기본적으로 그룹-아이템 상호작용을 가지지 않기에 GroupIM의 그룹-아이템 상호작용 데이터 생성을 차용하였다. GroupIM에서는 체크인 내역과 소셜 네트워크의 정보를 이용하여 그룹-아이템 데이터를 생성하는데, 소셜 네트워크 상에서의 친구들이 같은 POI에 15분 이내에 체크인을 하였다면 해당 친구들로 이루어진 그룹이 해당 POI와 상호작용을 한 것으로 간주한다. 또한 5개 이상의 상호작용을 한 유저 또는 아이템만 데이터셋에 포함시키는 전처리를 하였다.

실험을 위하여 Intel i7-6700 CPU와 GEFORCE GTX 1080 Ti GPU를 사용하였다. 우분투 18.04 운영체제에서 Pytorch 1.1과 Tensorflow-gpu 1.15 라이브러리를 사용하여 코드를 작성하였다.

제 2 절 성능 평가 지표 및 실험 설정

모델의 성능을 평가하기 위하여 상위 K개의 아이템에 대한 NDCG(normalized discounted cumulative gain)와 재현율(recall)을 사용하였으며 표 2에서는 N@K, R@K로 표기하였다. NDCG와 재현율의 식은 각각 아래 식 (4-1), (4-2)와 같다.

$$NDCG@K = \frac{1}{|G|}\sum_{g=1}^{|G|}\sum_{i \in I_g, v_i \le K}\frac{1}{\log_2(v_i+1)} \qquad \text{식 (4-1)}$$

$$Recall@K = \frac{1}{|G|}\sum_{g=1}^{|G|}\frac{1}{|I_g|}\sum_{i \in I_g} I(v_i \le K) \qquad \text{식 (4-2)}$$

여기서 v_i는 그룹 g에 대한 테스트 아이템의 집합인 I_g에 속하는 아이템 i가 그룹 g에 대해 모델이 예측한 순위 리스트에서 몇 번째 위치에 있는지를 나타낸다. $I(\cdot)$는 지시 함수(indicator function)이다.

데이터셋을 생성할 때 모든 그룹들의 집합을 훈련 데이터(70%), 검증 데이터(10%), 그리고 테스트 데이터(20%)로 나눈다. 테스트 그룹의 상호작용은 모두 테스트 용도로 사용하며 따라서 단기 그룹에 대해 모델을 훈련시키고, 완전 단기 그룹에 대해 모델을 테스트한다.

유저 및 그룹 임베딩의 크기는 {32, 64, 128}의 범위에서 튜닝하였으며 최종적으로 64로 정하여 실험하였다. GroupIM과 제안한 모델들에 대해 $f_{ENC}(\cdot)$의 두 은닉층(hidden layer)의 크기를 64로 정하였다. 그룹-유저 쌍에 대한 대조 정규화에서는 각 그룹에 대해 5개의 음성 샘플을 사용하였으며, 그룹-아이템 쌍에 대한 대조 정규화에서는 그룹 별로 5쌍의 양성 샘플-음성 샘플을 사용하였다. 드롭아웃은 모 0.4를 사용하였고, L2 정규화의 계수는 0으로 두었다. 미니 배치의 크기는 256이다. 검증 데이터셋에 대한 테스트를 5 에폭마다 진행하여 최적의 NDCG@100을 기준으로 훈련을 조기 종료(early stopping)하였다.

제 3 절 실험 결과 및 분석

Sampling ratio	20%			40%			60%		
	N@100	R@20	R@50	N@100	R@20	R@50	N@100	R@20	R@50
GroupIM	0.2154	0.3196	0.4579	0.2884	0.4175	0.5687	0.3677	0.5078	0.6485
GroupCRL	0.2321	0.3396	0.4774	0.2989	0.4319	0.5790	0.3763	0.5230	0.6587
GroupCFGAN	**0.2333**	0.3399	0.4779	**0.3033**	0.4354	0.5824	**0.3791**	0.5235	0.6603
GroupAug	0.2321	**0.3426**	**0.4814**	0.3000	**0.4393**	**0.5921**	0.3638	**0.5279**	**0.6644**

표 2. 유저-아이템 상호작용 샘플링 비율에 따른 Weeplaces에 대한 그룹 추천 결과

표 2에서 GroupIM[1]의 경우 그룹-아이템과 유저-아이템 상호작용이 동시에 부족한 상황에서 성능이 얼마나 악화되는지를 보여준다. 본 실험에서는 유저-아이템 상호작용 행렬을 희소하게 만들기 위해 유저-아이템 상호작용을 특정한 비율로 샘플링한 다음, 그룹-아이템 상호작용은 해당 그룹의 모든 구성원들이 해당 아이템을 구매했을 경우에만 샘플링하였다.

GroupCRL에 대해서는 그리드 탐색을 이용하여 찾은 최적의 하이퍼파라미터 $\lambda_{BPR} = 0.002, \lambda = 0.2$를 이용하였으며 동일한 하이퍼파라미터를 GroupCFGAN과 GroupAug에도 적용하였다.

GroupCFGAN에서 CFGAN[3]의 에폭 수는 500으로 설정하였으며 500번의 에폭 중에서 Precision@5가 가장 높은 모델을 저장하여 사용하였다. α는 [3]에서 최고의 성능을 보이는 0.1로 고정하였으며, 임계점은 $sigmoid(1.2) \simeq 0.769$로 두었다. 아이템을 구매할 확률이 76.9%를 넘는 경우에만 증강하였다는 뜻이다.

표 2에서는 유저-아이템 상호작용이 전체의 20%, 40%, 60%만 주어진 상황에서 기존 모델인 GroupIM과 본 연구에서 제안한 모델들의 성능을 비교하였다. 그 결과, 재현율에 대해서는 GroupAug가, NDCG에 대해서는 GroupCFGAN이 가장 우수한 성능을 보였다. 특

히 GroupCFGAN의 경우 20%의 상호작용 비율에서 NDCG@100 기준으로 GroupIM[1] 대비 최대 8.31%까지 성능이 향상되는 것을 확인하였다.

GroupAug이 NDCG@100에서 다른 제안한 모델에 비해 우위를 보이지 못하는 이유는 다음과 같다. 증강된 그룹-아이템 상호작용은 구성원들의 POI 체크인 시각을 고려하지 않은 가상의 데이터이다. 이러한 데이터를 실제 상호작용으로 간주하고 모델을 훈련시키면 실제로 구매하지 않은 아이템이 높은 구매 확률을 갖게 되어 순위 리스트에서 높은 순위를 차지하게 되는 문제점이 발생하기 때문이다.

제 5 장 결 론

본 논문에서는 주어진 데이터가 부족한 환경에서도 더 높은 성능의 그룹 추천을 하기 위한 세 가지 방법을 제안하였다. 첫 번째로 기존의 그룹 추천 시스템에 그룹-아이템에 대한 대조적 표현 학습을 적용하여 그룹의 아이템들에 대한 선호도의 차이를 반영하는 방법을 제안하였다. 실험을 통하여 제안한 방법을 사용한 모델이 기존 모델에 비해 우수한 성능을 보임을 Weeplaces 데이터셋에 대하여 확인하였다. 두 번째로 유저에게 아이템을 추천하는 일반적인 추천 시스템을 이용하여 부족한 유저-아이템 상호작용을 증강하는 방법을 제안하였다. 마지막으로 기존의 그룹으로부터 새로운 그룹을 만들어 데이터를 증강하는 방법 또한 제안하였다. 두 전처리 방법이 모두 첫 번째 제안한 모델의 그룹 추천 성능을 향상시키는 것을 확인하였다. 제안한 방법들은 행사 참여, 숙박 시설 예약 등 주변에서 일상적으로 볼 수 있는 상황에 대한 그룹 추천 성능을 향상시킬 수 있을 것으로 기대된다.

참 고 문 헌

[1] A. Sankar, Y. Wu, W. Zhang, and H. Sundaram. "GroupIM: A Mutual Information Maximization Framework for Neural Group Recommendation". In SIGIR, 2020.

[2] L. Tran, and X. Li. "Interact and Decide: Medley of Sub-Attention Networks for Effective Group Recommendation". In *SIGIR*, 2019.

[3] D. Chae, J.Kang, S, Kim, and J. Lee. "CFGAN: A Generic Collaborative Filtering Framework based on Generative Adversarial Networks". In *CIKM*, 2018.

[4] I. Goodfellow, and Y. Bengio. "Generative Adversarial Nets". In NIPS, 2014.

[5] D. Cao, X. He, L. Nie, and T. Chua. "Cross-platform app recommendation by jointly modeling ratings and texts". In *TOIS*, 2017.

[6] X. Wang, X. He, F. Feng, and T. Chua. "TEM: Tree-enhanced Embedding Model for Explainable Recommendation". In *WWW*, pp. 1543-1552, 2018.

[7] Q. Wang et al. "Enhancing Collaborative Filtering with Generative Augmentation". In *KDD*, 2019.

[8] L. Baltrunas, T. Makcinskas, and F. Ricci. "Group recommendations with rank aggregation and collaborative filtering". In *RecSys*, 2010.

[9] V. Rakesh, W. Lee, and C.K. Reddy. "Probabilistic group recommendation model for crowdfunding domains." In *WSDM*, ACM 2016.

[10] Q. Yuan, G. Cong, and C. Lin. "COM: a generative model for group recommendation". In *KDD*, ACM 2014.

[11] D. Cao, X. He, L. Miao, Y. An, C. Yang, and R. Hong. "Attentive group recommendation". In *SIGIR*, ACM 2018.

[12] Hongwei Wang et al. “GraphGAN: Graph representation learning with generative adversarial nets”. In *AAAI*, 2018.
[13] Jun Wang et al. “IRGAN: A minimax game for unifying generative and discriminative information retrieval models”. In *SIGIR*, ACM 2017.
[14] J. Kim, H. Goo, Y. Ahn, and K. Shim. "Item Recommendation System for Group using Contrastive Representation Learning". In *Proc. of the KIISE Korea Software Congress,* pp. 810-812, 2021. (in Korean)
[15] J. Kim, H. Goo, Y. Ahn, and K. Shim. "Recommender System Exploiting Structure of Group, User, and Item via Contrastive Representation Learning". In *KIISE Transactions on Computing Practices*, 2022. (in Korean)
[16] J. Kim, Y. Ahn, and K. Shim. "Ephemeral Group Recommendation System applying Group Data Augmentation". In *Proc. of the KIISE Korea Software Congress,* 2022. (in Korean)
[17] S. Rendle, C. Freudenthaler, and Z.Gantner. "BPR: Bayesian Personalized Ranking from Implicit Feedback". In UAI, 2009.
[18] https://www.yongliu.org/datasets/

Abstract

Recommender System Exploiting Structure of Group, User, and Item via Contrastive Representation Learning

Jinwoo Kim
Electrical and Computer Engineering
The Graduate School
Seoul National University

A group recommendation system is a system for recommending items to a group consisting of several users. Existing group recommendation systems recommend items by maximizing the mutual information between the embedding of the group and the embedding of the members of the group in order to make an accurate recommendation even in a situation where group-item interactions are sparse. However, a key weakness is that the recommendation performance is poor when both group-item interactions and user-item interactions are sparse. To solve this problem, this paper proposes a method using contrastive representation learning for groups and items as well as for groups and users. In addition, we propose a method to augment user-item interaction data using a collaborative filtering method based on a generative adversarial network and a method to augment data by creating a new group from an existing group. Our experimental results show that the proposed method improves recommendation

performance even when interactions between groups and items and between users and items are both sparse.

Keywords: group recommendation, neural collaborative filtering, contrastive representation learning, data sparsity, adversarial training
Student Number: 2021-22993

감사의 글

지난 2년 동안 무사히 석사과정을 마칠 수 있도록 도움을 주신 모든 분들께 감사의 인사를 드리고 싶습니다. 먼저 바쁘신 와중에도 열정을 가지고 제가 성장할 수 있도록 도와주신 지도 교수님이신 심규석 교수님께 감사드립니다. 귀중한 시간을 내어 심사위원장과 심사위원을 맡아주신 김태환 교수님과 홍성수 교수님께도 감사의 인사를 드립니다.

그리고 연구실 분들께도 감사의 인사를 드립니다. 몇 번 뵙지는 못했지만 너는 잘 할 수 있을 것 같다고 말씀하시며 자신감을 갖게 해주신 우환 선배, 성실하고 우직한 모습으로 귀감이 되는 성웅 선배, 연구실의 대소사를 도우며 저에게 조언과 도움을 아끼지 않으신 수용 선배와 한준 선배, 차분하고 논리적인, 때로는 장난스런 모습으로 연구실 생활을 알차게 해주신 대영 선배, 옆자리에서 잦은 도움 요청에도 항상 시간을 써주신 장혁 선배와 영준 선배, 마지막으로 여러모로 연구실 생활에 큰 힘을 주는 소중한 동기 아현이에게 감사드립니다. 지난 2년은 똑똑하고 올바른 분들 사이에서 함께 공부할 수 있었던 행운의 순간입니다.

또한, 먼저 석사과정을 마쳐 아낌없이 도움을 주는 우재, 학교에서 같이 연구실 생활을 하며 버팀목이 되어주는 경오와 창일, 옆에서 힘이 되어주는 미현이에게 감사의 말씀을 드립니다.

마지막으로 부모님에게 감사드립니다. 훌륭한 선배 연구자로서 항상 조언을 아끼지 않으시는 아버지와 세심하게 저를 챙겨주시는 어머니에게 진심으로 사랑한다고 말씀드리고 싶습니다.

많은 분들의 도움으로 석사과정을 무사히 마칠 수 있었습니다. 감사합니다.

2023. 02. 김진우 드림