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

아이템 지식 정보를 이용한 임베딩 학습 및 추천 연구

2023년 2월

서울대학교 융합과학기술대학원

지능정보융합학과

이 재 홍

아이템 지식 정보를 이용한
임베딩 학습 및 추천 연구

지도 교수 서 봉 원

이 논문을 공학석사 학위논문으로 제출함
2023년 12월 9일

서울대학교 대학원
지능정보융합학과
이 재 홍(성명)

이재홍의 공학석사 학위논문을 인준함
2022년 12월 9일

위 원 장 _____ 이 교 구 _____ (인)

부위원장 _____ 서 봉 원 _____ (인)

위 원 _____ 이 원 종 _____ (인)

초 록

사용자가 물건을 구매하거나 클릭하는 등의 행동을 통해, 축적되는 로그 데이터를 바탕으로 사용자와 아이템 간 상호 관계에 대해 파악하고, 협업 필터링이나 콘텐츠 기반 필터링 등의 방법을 적용하여 아이템에 대한 추천을 수행하였다. 그래프 인공 신경망 기술의 발전으로 대상의 관계성을 잘 고려할 수 있는 추천 시스템 모델을 설계할 수 있게 되었으며, 기존 방법론에 비해 우수한 성능을 보여주었다. 또한 더 정확한 추천을 위해 사용자 정보나 아이템 지식 정보와 같은 각종 추가 정보를 활용하는데 유리하여 해당 방향으로의 연구가 활발히 진행되었다. 최근 연구에서 소셜 네트워크 데이터를 추가 정보로 활용하여 그래프 대조 학습을 수행하였으며, 여러 추천 데이터셋에 대해 좋은 성능을 보였다. 하지만 이러한 소셜 네트워크 데이터는 구하기 힘들고, 아예 없는 경우도 많아서 실제로 해당 방법을 활용하기 어렵다는 한계가 있었다. 따라서 본 연구에서는 소셜 네트워크 데이터 대신 아이템 지식 정보 데이터를 활용하여 추천 성능을 개선하는 방안을 제시한다. 소셜 네트워크 데이터를 추가 정보로 활용한 기존 연구와 비슷한 수준의 성능을 달성하였으며, 이는 소셜 네트워크 데이터가 없는 경우에도 높은 수준의 추천이 가능함을 보여준다.

주요어 : 추천 시스템, 추가 정보, 그래프 대조 학습

학 번 : 2021-25242

목 차

제 1 장 연구의 배경 및 목적 1
제 2 장 선행 연구 조사 5
제 1 절 추천 알고리즘 5
제 2 절 그래프 합성곱 신경망 기반 추천 시스템 10
제 3 절 그래프 대조 학습 18
제 3 장 연구 방법 22
제 1 절 실험 데이터셋 22
제 2 절 연구 설계 25
제 4 장 연구 결과 31
제 1 절 평가 지표 31
제 2 절 기존 연구와 성능 비교 33
제 3 절 View Ablation Study 39
제 5 장 결 론 44
제 1 절 연구 요약 44
제 2 절 연구 의의 46
제 3 절 연구의 한계점 및 향후 연구 47

표 목차

[표 1] 데이터셋 타입 1 통계량 23
[표 2] 데이터셋 타입 2 통계량 23
[표 3] 기존 연구 모델과 성능 비교 결과(LastFM) 33
[표 4] 기존 연구 모델과 성능 비교 결과(CiaoDVD) 34
[표 5] 기존 평점 예측 모델과 성능 비교 결과 36
[표 6] Ablation study Precision과 Recall 결과(1) 43
[표 7] Ablation study Precision과 Recall 결과(2) 43

수식 목차

[수식 1] 그래프 합성곱 신경망 일반식 10
[수식 2] InfoNCE Loss 19
[수식 3] 평가 지표 표현식 31

그림 목차

[그림 1] 연도별 Youtube 업로드 동영상 수 1
[그림 2] 협업 필터링 5
[그림 3] 콘텐츠 기반 필터링 8
[그림 4] 합성곱 신경망과 그래프 합성곱 신경망 모식도 10
[그림 5] NGCF에서 High – order connectivity graph 13
[그림 6] LightGCN에서 수행한 Ablation Study 13
[그림 7] 대조 학습 패러다임 18
[그림 8] LastFM 데이터셋 예시 22
[그림 9] Co-occurrence view 생성을 위한 행렬 연산 27
[그림 10] 그래프 뷰 생성 모식도 28
[그림 11] ItemGC 모델 전체 구조도 30
[그림 12] LastFM ablation study NDCG 39
[그림 13] CiaoDVD ablation study NDCG 40
[그림 14] MovieLens-smallest ablation study NDCG 40
[그림 15] MovieLens-100k ablation study NDCG 41
[그림 16] Amazon shopping ablation study NDCG 41

제 1 장 연구의 배경 및 목적

방송사나 신문사와 같이 한정된 곳에서 소수의 콘텐츠를 생성했던 과거와 달리 다양한 플랫폼과 한정되지 않은 대상으로부터 방대한 양의 콘텐츠를 공급받는 사회에 살고 있다. 이러한 변화는 양적 및 질적인 측면에서 콘텐츠의 발전을 가져왔으며 사용자들은 Youtube 나 Netflix 와 같은 플랫폼에 접속하여 수많은 콘텐츠들을 접할 수 있게 되었다. Youtube 의 발표에 따르면 2013 년 기준 매분 당 300 시간의 동영상 콘텐츠가 업로드되었고, 이 수치는 2015 년에는 분 당 400 시간, 2019 년에는 분 당 500 시간으로 꾸준히 증가하였다. 하지만 이러한 정보의 홍수는 오히려 선택에 어려움을 야기했다. 사용자가 명확히 원하는 콘텐츠가 있지 않는 이상, 수많은 선택지 중에서 어떤 것을 선택해야 할지 고민해야 했다. 이러한 배경에서 사용자의 결정을 도와줄 수 있는 기술인 추천 시스템이 등장하였다.

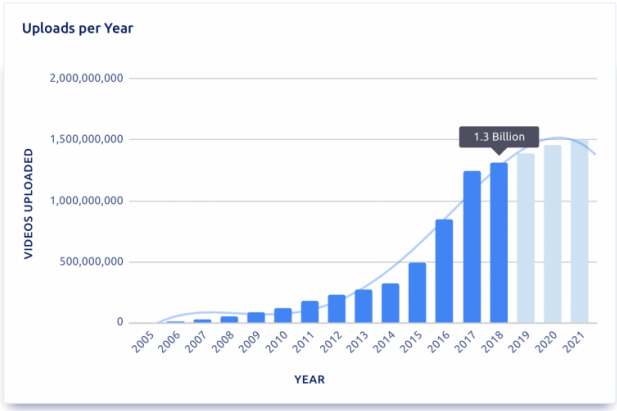

[그림 1] 연도별 Youtube 업로드 동영상 수

추천 시스템이란 정보 필터링 기술의 일종으로, 사용자의 선호도나 과거 행동 또는 메타 데이터 등을 분석하고 특정 알고리즘을 적용하여 적합한 콘텐츠(영화, 뉴스, 상품 등)를 제공하는 것이다. Amazon, 쿠팡과 같은 온라인 쇼핑을 통해 물품을 구매하거나, Youtube, Netflix 와 같은 OTT(Over the Top) 서비스에서 영상 콘텐츠를 소비할 때 자동으로 물품 또는 영상 콘텐츠를 추천해 주는 주는 등 이미 마케팅 산업에 필수적인 기술로 자리 잡았다. 사용자가 소비할 수 있는 콘텐츠는 그 수가 매우 많고, 지금도 꾸준히 증가하고 있다. 이러한 상황 속에서 사용자가 실제로 흥미를 가질만한 콘텐츠를 필터링해주어, 사용자의 한정된 시간을 효율적으로 투자할 수 있도록 도와준다. 또한, 서비스 제공자 입장에서는 고객의 니즈를 파악하여 맞춤화된 추천을 제공할 수 있어진다. 이는 사용자의 만족도를 높여주어 다양한 상품을 보다 더 판매할 수 있는 기회가 된다.

협업 필터링 방법(Collaborative Filtering, CF)은 추천 시스템을 구현하는 대표적인 알고리즘이다. 사용자가 어떤 아이템을 구매하였는지에 따라 사용자와 아이템에 대해 모델링하고 연산을 통해 아이템을 추천하는 방법이다. 따라서 좋은 성능의 추천을 얻기 위해서는 대상을 올바르게 모델링 하는 것이 중요하다. 이때, 사용자의 특성을 나타내는 사용자의 프로필 정보나 소셜 네트워크 정보, 아이템의 특성을

나타내는 아이템 지식 정보와 같은 추가 정보를 활용하여 더 정확한 모델링을 수행할 수 있다.

협업 필터링 방법을 구현하기 위해 다양한 시도가 있었다. 사용자 – 아이템 상호작용 데이터에 대해 특이값 분해(Singular Value Decomposition, SVD)하여 사용자와 아이템에 대해 모델링 하려는 행렬 분해(Matrix Factorization, MF) 방법은 단순한 구조임에도 좋은 성능을 보이는 방법이다. 최근접 이웃 협업 필터링(Nearest Neighbor Collaborative Filtering) 방법은 사용자 – 사용자 간 유사도 또는 아이템 – 아이템 간 유사도를 측정하여 아이템을 추천해 주는 방법이다.

최근에는 인공 신경망(Neural Network) 관련 연구가 주목받고, 다양한 분야에 걸쳐서 우수한 결과를 내고 있으며, 추천 분야에 인공 신경망 기반 모델을 적용하여 문제를 풀고 있다. 특히 대상 간의 관계성을 설명 가능하게 모델링 할 수 있는 그래프 인공 신경망 구조(Graph Neural Network, GNN)를 통해 협업 필터링 문제를 풀어보려는 많은 연구가 있다.

앞서 서술한 바와 같이 추가적인 정보를 활용하여 추천의 성능을 개선하려는 연구가 계속되어왔다. SOTA 모델인 SEPT[10]는 소셜 네트워크 데이터를 추가 정보로 학습에 활용하여 우수한 추천 성능을 보여주었다. 하지만 학습에 활용한 사용자 – 아이템 상호작용 데이터와 소셜 네트워크 데이터가 같이 있는 데이터셋은 그 수가 적고 획득하기

어려워 실제로 활용하는데 제약이 따른다. 따라서 본 연구에서는 아이템 지식 정보 데이터를 추가 정보로 활용하여 추천의 정확도를 높이는 시스템을 제안한다. 5 개의 추천 데이터셋에 대해 추천 성능을 측정해 본 결과, 기존 SOTA 모델에 준하는 성능을 보였다. 소셜 네트워크 데이터가 없는 경우에도 우수한 추천 성능을 달성한 것이 본 연구의 의의이다.

제 2 장 선행 연구 조사

제 1 절 추천 알고리즘

추천 시스템의 목적은 사용자와 아이템이 상호작용한 내용을 바탕으로 각 개체를 모델링 하여 조건에 맞는 아이템을 제시하는 것이다. 이 과정에서 리뷰 점수 정보와 같이 구체적인 스케일로 표현할 수 있는 명시적 정보(Explicit rating)를 활용하거나, 상품 페이지 방문 또는 클릭, 구매 정보 등 점수화할 수 없는 암묵적 정보(Implicit feedback)를 활용한다. 다만, 명시적 정보는 그 수가 적거나 점수의 편향으로 인한 해석이 난해한 경우가 많다. 따라서 모델링에는 주로 암묵적 점수를 더 많이 사용하는 추세이다.

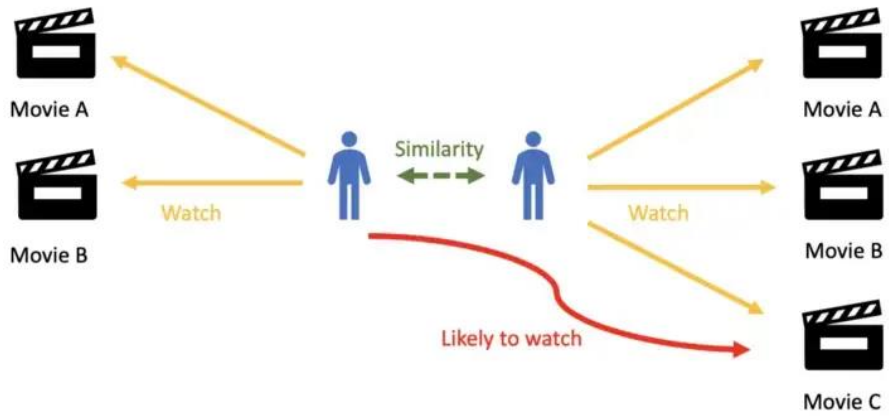

[그림 2] 협업 필터링

추천 시스템에는 주로 협업 필터링 기법을 사용한다. 협업 필터링(Collaborative Filtering, CF)은 명시적 정보나 암시적 정보를 바탕으로 사용자에게 콘텐츠를 추천해 주는 방법으로, “사용자 A 와 비슷한 취향을 가진 사람들이 선호하는 콘텐츠를 사용자 A 도 좋아할 것이다.” 라는 가정을 전제한다. 해당 방법은 추천을 하기 위해 정확하게 아이템에 대해 이해할 필요가 없으며, 사용자 – 아이템 상호작용에 집중한다.

메모리 기반 접근법(Memory – based approach)에서는 유사한 사용자나 아이템을 찾아내어 추천해 주는 방식으로 협업 필터링 방법에 접근한다. 특정 사용자와 유사한 사용자가 좋아한 아이템을 추천해 주거나(User – based filtering), 특정 아이템을 좋아한 사용자들이 공통적으로 좋아했던 다른 아이템을 추천해 주는 방법(Item – based filtering)이 있다. 코사인 유사도(Cosine similarity)나 피어슨 상관계수(Pearson correlation) 또는 유클리드 거리(Euclidean distance)를 이용하여 유사도를 계산한다. 최적화나 매개 변수 학습을 수행하지 않고 단순한 산술 연산만을 사용하기 때문에 쉽게 구현이 가능하며 도메인에 의존적이지 않다는 장점이다. 하지만 데이터가 너무 많아지면 속도가 저하된다는 단점이 있다.

모델 기반 접근법(Model – based approach)에서는 기계 학습 모델 또는 딥러닝 모델을 통해 아이템을 추천해 준다. 사용자 – 아이템 상호작용 행렬을 특이값 분해(Singular Value Decomposition, SVD)를 통해

잠재 벡터(Latent factor)를 얻어내는 행렬 분해 방법(Matrix Factorization, MF)과, KNN(K – nearest neighbor)와 같은 비지도 학습 모델을 통해 사용자와 아이템의 유사도를 구하는 방법이 있다. 최근에는 모델이 자체적으로 대상의 임베딩을 학습할 수 있도록 하는 모델을 만들고 최적화 알고리즘을 사용하여 학습하는 딥러닝 모델 기반 방법이 연구되고 있다. 모델 기반 접근법은 파라미터 학습을 통한 높은 수용력(Capacity)를 바탕으로 데이터의 확장 가능성을 담보할 수 있어서, 메모리 기반 접근법의 대안 방법으로 활발하게 연구되고 있다.

이렇듯 협업 필터링은 추천 시스템을 구현하는 강력한 알고리즘이지만 몇몇 한계점이 존재한다. 먼저, 추천을 새로 시작할 때 성능이 잘 나오지 않는다(Cold start problem). 협업 필터링을 구현하기 위해 사용자 – 아이템 상호 작용 데이터가 매우 중요한데, 신규 사용자나 신규 아이템이 추가되면 그에 대한 상호 작용 내역이 없기 때문에 모델이 정보를 모을 수 없고, 결과적으로 추천을 할 수 없다. 두 번째로, 사용자가 많아질수록 계산시간이 증가한다. 정확한 추천 결과를 내기 위해서는 많은 사용자의 로그를 필요로 하지만, 동시에 계산 시간이 증가된다는 모순점이 있다. 마지막으로 추천 내용이 편향적이게 될 수 있다(Long – tail problem). 사용자들이 관심을 많이 보이는 소수의 인기 있는 콘텐츠를 주로 추천하고, 다수의 비인기 콘텐츠는 관심 받지 못하여 단조로운 추천이 될 가능성이 있다.

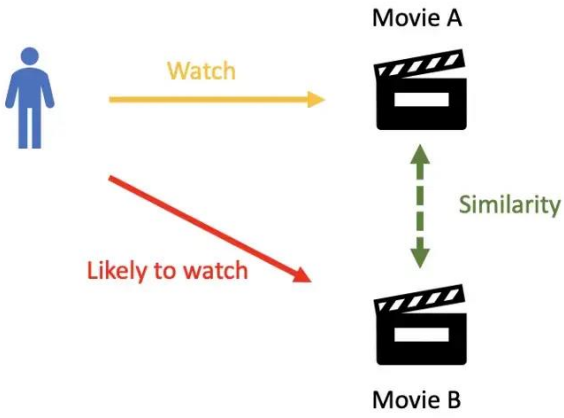

[그림 3] 콘텐츠 기반 필터링

위와 같은 협업 필터링 방법의 한계를 극복하기 위해 콘텐츠 기반 필터링(Contents based Filtering) 방법이 연구되었다. 이 방법은 아이템에 대한 세부 정보를 토대로 사용자가 과거에 소비했던 콘텐츠와 유사한 콘텐츠를 추천해 주는 방법이다. 다른 사용자의 데이터가 존재하지 않더라도, 아이템 정보를 분석하여 신규 사용자에게 추천해 줄 수 있다는 장점이 있다. 또한 새로 추가된 콘텐츠나 유명하지 않은 콘텐츠에 대해서도 추천이 가능하여, 앞서 말한 협업 필터링 방법이 가진 단점을 극복한 방법이다. 하지만 해당 방법으로는 개인의 성향을 세부적으로 파악하기 어렵고, 메타 정보의 한정성 때문에 대상의 프로파일을 모두 함축하는 데 한계가 있다.

협업 필터링 방법과 콘텐츠 기반 필터링 방법을 섞은 하이브리드 방법도 연구되고 있다. 두 방법이 가지는 장단점을 상호 보완하여 추천 시스템이 가지는 문제를 극복할 수 있다. 실제로 Netflix 에서 사용자가 높게 평가했던 영화와 비슷한 특성을 띄는 영화를 추천하는 콘텐츠 기반

필터링 방법과 비슷한 사용자들의 검색 습관과 시청을 비교하는 협업 필터링 방법을 혼합하여 콘텐츠를 추천해 준다.

본 연구에서는 대상을 더 정확하게 모델링 하기 위하여 사용자 – 아이템 상호작용 데이터와 아이템 지식 정보를 모두 활용하여 아이템에 대해 모델링 한다. 사용자 – 아이템 상호작용 데이터를 바탕으로 사용자의 관심이 반영된 그래프 뷰를 생성하고, 아이템 지식 정보를 바탕으로 아이템의 프로파일 정보가 반영된 그래프 뷰를 생성한다. 해당 데이터는 각각 협업 필터링과 콘텐츠 기반 필터링에서 모델링에 활용하는 데이터로, 연구에서 제안한 모델은 협업 필터링과 콘텐츠 기반 필터링이 결합된 하이브리드 모델이라 할 수 있다.

제 2 절 그래프 합성곱 신경망 기반 추천 시스템

그래프 합성곱 신경망

그래프 인공 신경망 모델은 그래프 구조가 동반되는 문제를 해결하는 데 효율성이 입증되었고, 많은 연구가 이루어지고 있다. 특히 그래프 합성곱 신경망(Graph Convolutional Network, GCN) [11]은 이미지 학습 분야의 대표적인 모델인 합성곱 신경망(Convolutional Neural Network, CNN) [18]의 알고리즘으로부터 영향을 받아 만들어진 모델로, 간단한 구조와 우수한 성능을 바탕으로 그래프 인공 신경망 모델 연구의 한 축을 담당하고 있다.

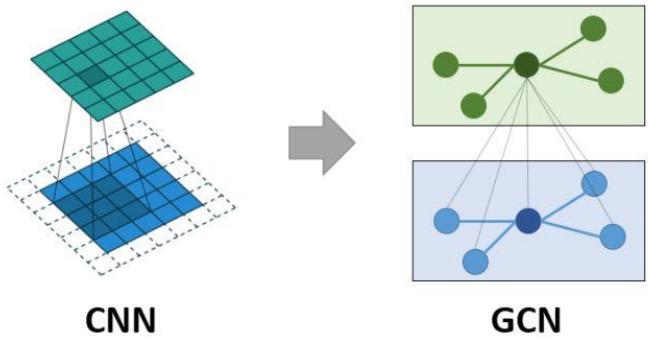

[그림 4] 합성곱 신경망과 그래프 합성곱 신경망 모식도

$$H^{l+1} = \sigma\left(\tilde{D}^{\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}H^{l}W^{l}\right)$$

[수식 1] 그래프 합성곱 신경망 일반식

그래프 합성곱 신경망(GCN)은 합성곱 신경망(CNN) 알고리즘에서 영감을 받아 만들어져 서로 유사한 학습 과정과 특징을 갖는다. 합성곱 신경망에서 기준 픽셀 주변에 있는 정보(Local feature)를 학습하기 위해 필터(Sliding window)를 옮겨가며 합성곱 연산 수행 후 값을 업데이트한다. 그래프 합성곱 신경망에서는 기준 노드 주변에 있는 노드 정보(Neighborhood node embedding)을 가중치 행렬(Weight matrix)과 인접 행렬(Adjacency matrix)에 곱하고 값을 업데이트한다. 두 모델은 학습 대상이 유클리드 공간에 있는 이미지인지 그렇지 않은 그래프인지에 대한 차이만 있을 뿐, 방법은 매우 유사하다. 연산 과정에서 파라미터를 공유하기 때문에 계산량이 적으며, 기준 픽셀 또는 노드 주변에 대한 지역적인 특성을 학습한다는 특징 또한 공유한다.

그래프 합성곱 신경망을 이용한 추천

과거 추천 시스템은 전통적인 행렬 분해를 통한 방법부터 딥러닝을 통한 방법까지 꾸준히 진화해왔다. 가장 최근에는 그래프 합성곱 신경망을 이용한 추천 시스템이 SOTA 를 달성해왔으며, 그래프 합성곱 신경망이 추천 문제를 잘 다룰 수 있었던 이유는 다음과 같다.

먼저, 그래프 합성곱 신경망 모델은 다룰 수 있는 데이터의 범위가 넓어 학습에 유리하다. 온라인 플랫폼에서 모은 사용자 – 아이템 상호작용 데이터, 사용자 또는 아이템 프로파일 데이터들은 다양한 형태를

띤다. 기존 추천 시스템 모델은 다양한 형태의 데이터를 다루지 못했고, 단지 특정 형태의 데이터에만 집중할 수밖에 없어서 Sub – optimal problem 에 봉착하였다. 이에 반해 그래프 합성곱 신경망에서는 모든 데이터를 노드와 간선으로 표현함으로써 데이터를 통합하여 활용할 수 있도록 하였다. 따라서 사용자나 아이템에 대한 좋은 퀄리티의 임베딩을 얻을 수 있었고, 이를 통해 우수한 추천 성능을 가지는 모델을 만들 수 있게 되었다.

또한, 먼 거리의 이웃 노드 정보를 활용할 수 있다는 점도 추천 시스템에 그래프 합성곱 신경망을 도입한 이유 중 하나이다. 그래프 합성곱 신경망이 가지는 'Embedding propagation' 성질은 주변 노드의 임베딩 정보를 반복적으로 가져올 수 있게 해준다. 한 층의 레이어는 기준 노드에서 1 의 거리에 있는 노드(1 – hop node)의 정보를 가져와서 기준 노드의 정보를 업데이트하는데, N 개 층의 레이어를 쌓으면 N 의 거리에 있는 노드(N – hop node)의 정보를 가져올 수 있다. 그래프 구조를 다루던 기존 방법론들이 단지 1 의 거리에 해당하는 노드에 접근할 수 있었던 반면, 여러 층의 레이어를 쌓음으로써 더 먼 거리의 이웃 노드에 대한 정보에 접근할 수 있었다. 구조적인 데이터를 처리하고, 구조 정보를 탐색하는 것에 대한 장점으로 그래프 합성곱 신경망 기반 방법은 추천 시스템의 새로운 최첨단 접근 방식이 되었다.

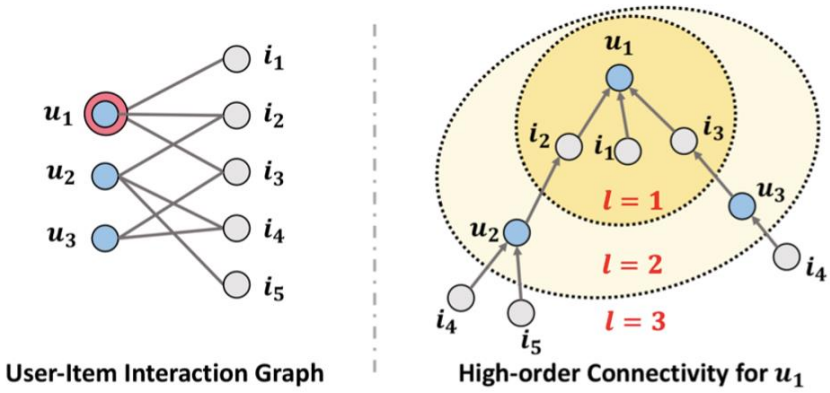

[그림 5] NGCF에서 High – order connectivity graph 정의

그래프 합성곱 네트워크를 추천 시스템에 적용한 대표적인 연구인 NGCF[12]는 이분 그래프 형식으로 나타나는 사용자 – 아이템 상호작용 데이터를 'High−order connectivity graph'로 표현하여, 높은 차수(Order)를 갖는 이웃으로부터 효과적으로 'Collaborative signal'을 활용하였다. 협업 필터링 방법에 GCN 계열 모델을 적용한 최초의 연구로, 기존 SOTA 모델보다 우수함이 증명하였다.

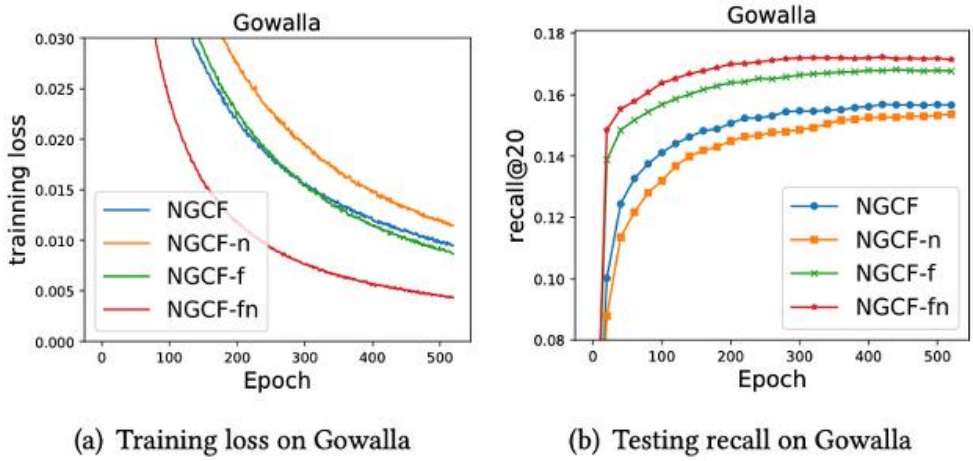

[그림 6] LightGCN에서 수행한 Ablation Study

LightGCN[13]에서는 기존 연구(NGCF)에 적용한 그래프 합성곱 신경망 구조의 각 부분을 실험적으로 분석하였다. [그림 6]에서 실험 결과는 기존 그래프 합성곱 신경망의 연산 과정 중 가중치 곱 과정(Feature transformation)과 활성화 함수 적용 과정(Non – linear activation function)을 제거했을 때의 결과를 나타낸다. 가중치 곱 과정이 생략된 모델(NGCF – f)과 활성화 함수 적용 과정(NGCF – n)이 추천 문제를 다룰 때 학습 과정과 결과에 부정적인 영향을 준다는 것을 실험적으로 파악하였다. 또한 해당 실험을 통해 그래프 합성곱 신경망의 필수적인 요소(Neighbor aggregation)만 포함한 경량화된 모델을 제안하였다.

앞서 소개한 연구들은 추천 문제를 다루기 위해 그래프 인공 신경망 모델 중 하나인 그래프 합성곱 신경망 구조를 채택하였으며, 해당 구조가 가지는 특징과 우수한 표현 성능을 바탕으로 해당 분야의 기반 연구로 여겨진다. 특히 LightGCN 모델은 간단한 구조로 높은 활용성과 그에 비해 우수한 추천 성능으로 인해, 종종 타 연구의 기본 인코더나 기반 모델로 활용되며, 본 연구에서도 그래프 뷰의 사용자 노드와 아이템 노드를 학습하는 과정에서 기본 인코더로 사용하였다. 또한 라벨링을 수행하기 위해 비교가 되는 샘플 임베딩을 반복적으로 형성하는 과정에서 적은 연산량을 위해 위 모델을 사용하였다.

추가 정보를 활용한 그래프 합성곱 신경망 추천

좋은 추천 결과를 위해서 사용자 또는 아이템을 모델링 하는 것은 매우 중요하다. 하지만 추천 시스템 데이터셋의 특징상 모델링 대상의 수에 비해 학습할 정보량이 부족하다(Sparsity issue). 기존 협업 필터링 기반 추천 알고리즘에서는 해당 한계점을 극복하기 위해 콘텐츠 기반 방법을 추가한 하이브리드 방법을 고안하였다. 이를 통해 사용자 – 아이템 상호 작용 데이터뿐만 아니라 사용자 프로파일, 아이템 프로파일, 소셜 네트워크 데이터와 같은 다양한 종류의 추가 정보를 활용하였다.

그래프 합성곱 신경망을 이용한 추천 모델에서도 비슷한 방법으로 데이터를 보완하여 더 나은 사용자 및 아이템 모델링을 목표한다. 사용자와 아이템 간 다양한 관계 정보를 노드와 간선으로 나타내어 사용자 – 아이템 이분 그래프의 부족한 정보를 보충하고 이를 학습한다. 여기서 어떤 방식으로 다양한 종류의 정보를 합쳐 그래프를 생성할지, 대상이 갖는 의미를 어떤 방식으로 모델링 할지에 대해 연구하고 있다.

소셜 추천(Social recommendation) 분야는 사용자 – 아이템 상호 작용 데이터와 사용자 간 관계 정보가 있는 소셜 네트워크 데이터를 이용하여 대상을 학습한다. 해당 분야의 연구는 “사용자의 선호는 그 주변 사용자로부터 영향을 받거나 비슷한 경향이 있다.[19]”라는 전제를 바탕으로 소셜 네트워크 데이터를 활용한다.

DiffNet[2]은 여러 층의 그래프 합성곱 신경망 레이어를 쌓아 Multi – hop 거리에 있는 높은 차수의 사회적 관계(High – order social relations)를 학습한 대표적인 연구이다. 해당 연구는 주변 사용자로부터 영향을 받는다는 기존 가정을 넘어, 지인의 주변 사람들에게도 역시 영향을 받을 수 있음을 새롭게 가정하고 모델링 하였다. 그러나 위 방법처럼 여러 층의 레이어를 쌓는 것은 오버스무딩 문제(Over – smoothing)[16]를 낳게 되어, 추천 성능 저하로 이어졌다. 이러한 점을 극복하기 위해 MHCN[17] 연구에서 하이퍼 그래프(Hyper – graph)를 이용하였다. 하이퍼 그래프는 두 개 이상의 노드를 이을 수 있는 하이퍼 간선(Hyper – edge)를 통해 높은 차수의 관계를 효과적으로 표현할 수 있어, 소셜 네트워크와 같이 높은 차수의 관계 데이터를 효과적으로 모델링 할 수 있었다.

지식 기반 추천(Knowledge graph aware recommendation) 분야는 사용자 – 아이템 상호 작용 데이터와 아이템 지식 정보를 이용하여 대상을 학습한다. “사용자는 대체로 기존 관심 아이템과 비슷한 특성을 가진 아이템에 흥미를 갖는다”라는 가정을 전제하여 추가 정보를 활용한다. 카테고리, 태그, 아티스트, 장르와 같은 정보가 내포되어 있으며, 이를 통해 사용자 – 아이템 상호작용 데이터만으로는 알 수 없는 아이템 간의 관계를 표현할 수 있다.

PUP[20]는 아이템 지식 정보 중 하나인 가격 정보와 카테고리 정보를 바탕으로 사용자 구매 의도를 예측하는 방법을 제안하였다. 가격

정보가 사용자의 구매 결정에 미치는 영향력과 민감도는 알 수 없으며, 구매한 항목에 대해서만 암시적으로 알 수 있다. 이 점을 극복하기 위해 그래프 합성곱 신경망 구조를 적용하여 아이템을 매개로 사용자에게 가격의 영향을 전파하여 사용자가 가격을 인식하도록 학습하였다. 또, 아이템의 가격은 카테고리별로 사용자의 구매 의도에 다른 영향력을 미치는데, 이 점을 고려하여 모델링 하기 위해 학습 과정에서 가격 정보와 카테고리 정보를 동시에 전파시켰다.

위에서 소개한 연구들은 사용자 – 아이템 상호작용 데이터의 부족한 협업 필터링 신호를 보완하기 위해 추가 정보를 바탕으로 학습 대상이 되는 그래프를 재구성하였다. 이 과정에서 소셜 네트워크 데이터나 아이템 지식 정보 데이터와 같은 정보가 사용되었으며, 이를 통해 사용자 및 아이템에 대해 더 좋은 모델링을 수행하였다. 대부분의 연구에서 사용자 – 아이템 상호 작용 데이터와 여러 종류의 추가 정보를 이종 그래프의 형태로 합쳐 하나의 완전한 학습 그래프를 생성하려고 하였다. 하지만 해당 방법은 학습 대상 그래프의 크기가 지나치게 커지면 학습 속도가 느려지고, 높은 차수(High – order)가 형성되어 오버스무딩 문제가 생길 수 있다. 본 연구에서는 다양한 정보를 가진 추가 정보를 이용하여 그래프를 형성하고, 이를 결합하지 않고 동종 그래프 형태로 각각 학습하여 그래프 대조 학습에 적용한다는 점에서 기존 연구와 차이가 있다.

제 3 절 그래프 대조 학습

학습할 수 있는 데이터가 많아짐에 따라 라벨링을 통한 기존 지도 학습 방법을 현실 문제에 적용하기에는 많은 비용이 들기 시작했다. 이런 배경에서, 모델이 원본 데이터의 패턴과 상관관계를 파악하고 스스로 라벨링 하여 이를 모델 훈련에 사용하는 자가 지도 학습(Self – supervised learning, SSL)이 대안으로 떠올랐다. 자가 지도 학습 기반 모델을 통해 라벨이 없는 데이터 또는 제한된 수의 라벨 데이터를 학습하거나, 사전 학습(Pre – training)을 통해 다운스트림 태스크(Downstream task)에 적용할 수 있게 되었다. 또한, 추가적인 학습을 통해 주요 작업(Main task)의 성능을 높이기 위한 보조 작업으로 사용할 수 있어 다양한 분야에서 연구되기 시작하였다.

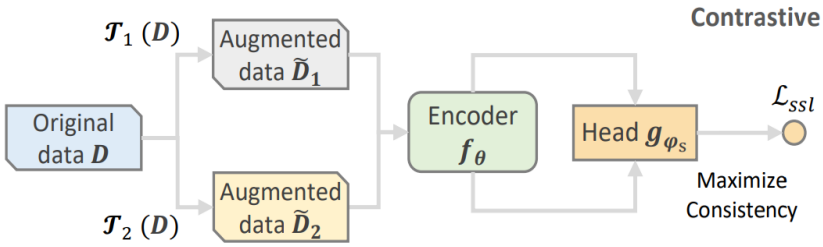

[그림 7] 대조 학습 패러다임

대조 학습은 자가 지도 학습의 한 방법으로, self – supervision 을 활용하여 데이터의 표현을 학습하고, downstream task 를 위한 사전 학습을 수행한다. 학습 과정에서 데이터 쌍(Data – data pairs)을 필요로

하며, Positive pair 와 Negative pair 를 구분하는 방식으로 학습한다. 해당 과정은 주로 InfoNCE loss[14]를 통해 학습된다.

$$\mathcal{L}_N = -\mathbb{E}_X \left[\log \frac{f_k(x_{t+k}, c_t)}{\sum_{x_j \in X} f_k(x_j, c_t)} \right]$$

[수식 2] InfoNCE Loss

[수식 2]은 InfoNCE Loss 에 대한 수식으로, 대조 학습에 적용되는 목적 함수이다. 분자는 positive sample 에 대한 결괏값을, 분모는 positive sample 과 negative sample 에 대한 결괏값의 합을 나타낸다. 결과적으로 InfoNCE Loss 를 최적화(optimization) 하면, Positive sample 간의 임베딩 거리는 가까워지도록, Positive sample 과 Negative sample 간의 임베딩 거리는 멀어지도록 임베딩을 학습한다.

그래프 대조 학습은 그래프 구조에 대조 학습을 적용한 방법이다. 원본 그래프를 여러 개로 증강하여(View augmentation) 서로 다른 그래프 뷰를 형성한 후 노드 또는 간선에 대한 임베딩을 구한 후, 이를 다른 그래프 뷰의 개체와 대조하여 표현을 학습하는 방식으로 노드 정보를 학습한다[5]. 그래프 뷰를 형성하기 위해 노드 / 간선 드롭 아웃(Dropout) 기법을 사용하거나, 랜덤워크(Random walk) 기반 서브 그래프(Subgraph) 생성 등 다양한 그래프 변형 기법을 사용할 수 있다.

그래프 대조 학습 분야에 대한 연구가 진행되면서 이를 그래프 인공 신경망을 이용한 추천 문제에 이식하려는 시도가 있었다. Hao 의 연구[21]에서 Cold – start 사용자나 아이템에 대해 그래프 기반 모델을 사전 교육하기 위해 그래프 대조 학습을 이용하였다. S – MHCN[17] 모델과 DHCN[22] 모델은 소셜 추천 또는 세션 기반 추천 시나리오를 다루기 위해 하이퍼 그래프를 통해 문제를 재구조화하였으며, 이를 대조학습 하여 아이템을 추천하였다. Liu 의 연구[23]에서 그래프 인공 신경망 기반 추천 시스템 모델의 추천 편향을 개선하기 위해 그래프 대조 학습을 활용하였다. 위와 같이 기존 그래프 구조를 이용한 추천 연구 분야가 갖는 문제점을 극복하기 위해 그래프 대조 학습을 적용하였으며, Cold – start problem 을 해결하거나 추천 모델을 위한 사전 학습이 가능하다는 점에서 많은 문제를 극복할 수 있었다.

한편, 그래프 대조 학습에 활용하는 효과적인 그래프 뷰를 생성하여 추천의 성능을 개선하려는 연구도 있었다. 노드 드롭아웃 또는 간선 드롭아웃을 통해 변형된 그래프 뷰를 형성하거나[6, 24], 그와 반대로 그래프에 새로운 간선을 더하는 방법(Graph diffusion – based augmentation)을 통해 뷰를 생성하여[25] 대조 학습에 적용하였다. 또한, 랜덤워크(Random walk)와 같은 방법을 통해 일정 비율의 노드와 간선을 샘플링하여 부분 그래프(Subgraph)를 형성하여 그래프 뷰를 형성하는 방향의 연구가 있었다[26]. 위 연구들은 주로 사용자 –

아이템 상호작용 데이터로부터 만든 그래프를 변형하여 그래프 대조 학습을 통한 추천을 수행하려 하였다.

SEPT[10]에서는 사용자 – 아이템 상호작용 데이터를 중점적으로 변형하여 사용했던 기존 연구와 다르게 소셜 네트워크 정보를 추가 정보로 활용하여 새로운 그래프 뷰를 생성하였다. 또한, 단순 인덱스 기반 라벨링을 수행하여 대조 학습의 Ground-truth 를 지정했던 기존 연구와 달리, 임베딩의 의미론적 유사도를 고려한 라벨링을 수행하여 학습을 진행하였다. LastFM, Douban-Book, Yelp 세 개의 데이터셋에 대해 실험을 진행하였으며, SOTA 성능을 달성하였다.

위에서 소개한 SEPT 모델은 추가적인 뷰를 생성하기 위해 소셜 네트워크 데이터를 활용하였다. 여러 추천 데이터셋에 대해 우수한 성능을 달성하였지만 사용자 – 아이템 상호작용 데이터와 소셜 네트워크 데이터가 같이 있는 연구용으로 사용 가능한 오픈 데이터셋은 거의 존재하지 않기 때문에 다른 데이터셋에 적용해 보거나, 실험을 확장하기 쉽지 않다는 한계점이 존재한다. 이 점을 보완하기 위해, 본 연구에서 쉽게 구할 수 있는 아이템 지식 정보를 활용하여 아이템의 특성을 나타내는 그래프 뷰를 형성한다. 이를 통해 대조 학습을 진행하여 사용자 – 아이템 상호 작용 정보의 학습을 보조하고, 학습된 사용자 임베딩과 아이템 임베딩을 바탕으로 추천 성능을 개선한다.

제 3 장 연구 방법

제 1 절 실험 데이터셋

데이터셋 소개

본 연구에서는 아이템 지식 정보를 그래프 대조 학습에 활용했을 때 추천 성능 변화에 대해 알아본다. 소셜 네트워크 정보를 활용하여 학습한 기존 SOTA 모델과 성능 비교를 하기 위해 사용자 – 아이템 상호작용 데이터, 아이템 지식 데이터 그리고 소셜 네트워크 데이터가 모두 있는 데이터셋 LastFM, CiaoDVD 을 활용한다(데이터셋 타입 1). 아래 [그림 8]은 LastFM 데이터셋의 일부를 나타내며, 사용자 – 아이템 상호 작용 데이터(좌), 아이템 지식 데이터(중앙)와 소셜 네트워크 데이터(우)에 대한 테이블이다.

	userID	artistID
0	2	51
1	2	52
2	2	53
3	2	54
4	2	55
...	...	...
92829	2100	18726
92830	2100	18727
92831	2100	18728
92832	2100	18729
92833	2100	18730

	artistID	tagID
0	52	13
1	52	15
2	52	18
3	52	21
4	52	41
...	...	...
186474	16437	4
186475	16437	292
186476	16437	2087
186477	16437	2801
186478	16437	3335

	userID	friendID
0	2	275
1	2	428
2	2	515
3	2	761
4	2	831
...	...	...
25429	2099	1801
25430	2099	2006
25431	2099	2016
25432	2100	586
25433	2100	607

[그림 8] LastFM 데이터셋 예시

또한 데이터 증강을 통해 생성된 각각의 뷰에 대한 Ablation study 를 진행한다. MovieLens – smallest, MovieLens – 100k, Amazon shopping 데이터셋에서 추가 실험을 진행하여 어떤 정보를 가진 뷰가 학습에 유용한 정보를 더 많이 함의하는지, 성능 향상에 유의미한지 파악한다(데이터셋 타입 2).

위에서 소개한 데이터셋에서 아이템 지식 정보는 태그 정보로 나타나며 카테고리, 장르, 아티스트 등 아이템을 설명할 수 있는 내용이 내포되어 있다.

사용한 데이터셋의 통계 정보를 나타내면 [표 1], [표 2]와 같다.

Dataset	User(U)	Item(I)	Tag(T)	U-U	U-I	I-T
Lastfm	1892	17632	9749	25434	92834	109750
CiaoDVD	17615	16121	18	40133	72665	16121

[표 1] 데이터셋 타입 1 통계량

Datasets	User(U)	Item(I)	Tag(T)	U-I	I-T
Movielens-smallest	610	9724	20	100836	22084
Movielens-100k	943	1682	19	100000	2892
Amazon shopping	55223	17408	150	497577	62347

[표 2] 데이터셋 타입 2 통계량

위의 [표 1]과 [표 2]에서 U－U는 사용자 간 관계를 나타내는 소셜 네트워크 정보의 수를, U－I는 사용자와 상호 작용이 있었던 아이템에 대한 로그 정보의 수를, I－T는 아이템에게 부여된 태그 정보의 수를 나타낸다.

데이터셋 전처리

모델의 효율적인 학습을 위해 유용한 정보를 선별적으로 제공할 필요가 있다. 따라서 학습에 불필요하다고 판단되는 데이터는 삭제하거나 형태를 수정하였다.

아이템 지식 데이터의 모든 아이템이 사용자 – 아이템 상호작용 데이터에 나타나지는 않는다. 상호작용 내역이 없는 아이템은 학습에 불필요한 정보이며 노이즈로 작용할 여지도 있다. 따라서 두 테이블에 공통으로 존재하는 아이템이 아닌 항목들을 필터링해주었다. 마찬가지로, 소셜 네트워크 데이터와 사용자 – 아이템 상호작용 데이터에 대해서도 비슷한 전처리를 수행하였다. 소셜 네트워크 데이터에 있는 모든 사용자가 사용자 – 아이템 상호작용 데이터에 존재하지 않기 때문에, 불필요한 사용자에 대한 정보를 필터링해주었다. 결과적으로 두 종류의 추가 정보는 사용자 – 아이템 상호작용 데이터에 존재하는 아이템 간의 관계 또는 사용자 간의 관계를 나타내도록 수정하였다.

제 2 절 연구 설계

본 연구는 소셜 네트워크 정보를 활용한 기존 연구의 한계점을 보완하려는 시도로서, 아이템 지식 정보 데이터를 추가 정보로 활용한다. 아이템 지식 정보 데이터를 바탕으로 여러 개의 그래프 뷰를 형성하고, 이를 이용하여 아이템 임베딩에 대해 학습하여 추천 성능을 개선하는 시스템 ItemGC 를 제안한다. 그래프 대조 학습 과정을 통해 아이템 임베딩을 개선하며, 개선된 아이템 임베딩과 초기 사용자 임베딩을 바탕으로 추천의 성능을 측정한다. 제안한 ItemGC 모델의 추천 성능을 소셜 네트워크 정보를 활용한 기존 연구와 비교해 본다. 또한 사용한 추가 정보가 추천 결과에 유의미한 영향을 미치는지에 대해 평가해 본다.

그래프 뷰 생성

본 연구에서는 사용자 – 아이템 상호 작용 데이터와 아이템 지식 정보를 학습하기 위해 그래프 인공 신경망 구조를 활용한다. 또한, 다양한 정보를 활용할 때 하나의 이종 그래프를 형성하여 학습하는 기존 연구와 달리, 추가 정보로부터 여러 개의 동종 그래프를 형성하여 대조 학습을 통해 모델링을 수행한다. 위와 같은 방법은 여러 종류의 추가 정보를 단순히 그래프화하여 쉽게 학습에 활용할 수 있으며, 정보가

추가됨에 따라 발생할 수 있는 오버스무딩 문제를 효과적으로 극복할 수 있다.

본 모델의 가장 첫 단계에서 사용자 – 아이템 상호 작용 데이터와 아이템 지식 데이터를 테이블 형태로 입력받아 대조 학습을 위한 그래프 뷰를 생성한다. 테이블 데이터를 인접 행렬화하여 그래프를 생성할 수 있으며, 데이터 증강을 통해 총 세 개의 그래프를 생성한다. 먼저 User – item view 는 사용자 – 아이템 상호 작용 데이터를 바탕으로 만든 그래프 뷰로, 협업 필터링 신호를 나타내는 이분 그래프의 모양을 갖는다. 사용자와 아이템을 노드로 표현하고, 사용자와 상호 작용이 있었던 아이템과의 관계를 간선으로 나타낸다. Tag view 는 아이템 지식 데이터를 바탕으로 만든 그래프 뷰로, 아이템에 대한 추가 정보를 갖는 이분 그래프 모양을 갖는다. 아이템과 태그 정보를 노드로 표현하고, 아이템에 부여된 태그 정보를 간선으로 표현한다. 여기서 태그 정보는 데이터셋에 따라 카테고리, 장르와 같은 추가 정보를 의미한다.
마지막으로 Co – occurrence view 는 사용자 – 아이템 상호 작용 데이터를 바탕으로 [그림 9]의 행렬 연산을 통해 생성하며, 같이 구매한 아이템에 대한 정보를 그래프로 표현한다. 아이템을 노드로 표현하고, 사용자에 의해 같이 구매된 아이템 사이의 관계를 간선으로 표현한다.

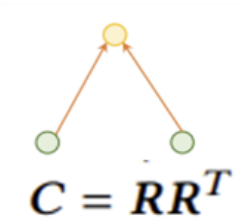

[그림 9] Co-occurrence view 생성을 위한 행렬 연산

이후, 기본 인코더 모델인 LightGCN 을 이용하여 각각의 그래프 뷰에 있는 노드의 임베딩을 구해준다. 해당 모델은 그래프 구조의 추천 문제를 효과적으로 풀 수 있는 그래프 인공 신경망 기반 모델로, 간단한 구조와 우수한 모델링 성능으로 본 연구에 사용할 기본 인코더 모델로 선택하였다. User – item view 로부터 사용자와 아이템에 대한 임베딩을, Tag view 로부터 아이템 임베딩을, 그리고 Co – occurrence view 로부터 아이템 임베딩을 구한다. 세 개의 그래프 뷰로부터 생성된 아이템 임베딩은 다른 측면의 아이템 특성을 반영하며, 이후 학습을 통해 다른 뷰의 정보를 받아들여 임베딩을 개선할 필요가 있다. 따라서 이 과정에서 구한 아이템 임베딩은 라벨링을 통해 대조 학습을 수행하며, 사용자 임베딩은 아이템 추천에 대해 학습하기 위해 이후 과정에 사용된다.

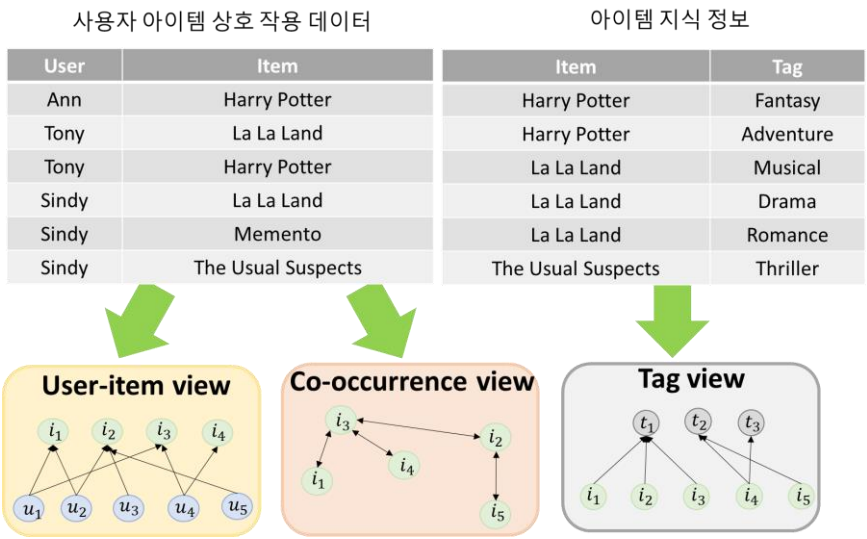

[그림 10] 그래프 뷰 생성 모식도

의사 라벨(Pseudo label) 생성 및 대조 학습

대조 학습은 라벨링 정보 없이 데이터 사이의 특징을 파악하여 임베딩을 학습한다. 이 과정에서 Positive sample 과 Negative sample 에 대한 정보를 생성해서 어떤 데이터에 가깝게 학습해야 할지(Positive sample), 또는 멀게 학습해야 할지(Negative sample)에 대한 지표를 설정해 주어야 한다. 본 모델의 그래프 뷰 생성 과정에서 사용자와 아이템의 임베딩을 구해주었다. 이렇게 얻은 임베딩에 의사 라벨을 생성해 주어서 대조 학습의 방향성에 대해 설정해 줄 필요가 있다.

본 모델에서 그래프 뷰로부터 생성한 임베딩에 의사 라벨을 부여하기 위해 의미론적으로 비슷한 임베딩을 찾아내어 Positive

sample 로 정한다. 이는 기존에 단순 노드 ID 기반으로 라벨링 하여 대조 학습하는 것보다 의미가 비슷한 임베딩을 Positive sample 로 정하여 대조 학습하였을 때 더 좋은 결과를 얻은 기존 연구의 결과를 활용한다. 라벨링을 위해 먼저 User – item view 를 그래프 합성곱 연산하여 Unlabeled example set 을 생성한다. 다음으로 그래프 뷰에서 생성한 아이템 임베딩과 의미가 비슷한 Positive sample 을 Unlabeled example set 에서 찾는다. 이 과정은 아이템 임베딩과 Unlabeled example set 의 임베딩간 코사인 유사도 점수를 기준으로 수행하며, 다른 두 개의 뷰에서 구한 점수를 더하여 상위 K 개의 아이템에 대해 Positive sample 로 설정하고, 나머지 아이템은 Negative sample 로 설정한다. 예를 들어, User – item view 의 n 번째 아이템의 Positive sample 을 정하기 위해서 Tag view 와 Co – occurrence view 의 아이템의 유사도 점수를 각각 더해 상위 K 개를 선택한다.

위와 같은 과정을 통해 아이템별로 Positive sample 과 Negative sample 을 구분하고 대조 학습을 수행하여 아이템 임베딩을 개선한다. 앞서 언급하였듯이 대조 학습은 비슷한 데이터는 임베딩 공간에서 더 가깝게, 비슷하지 않은 데이터는 더 멀게 학습하는 과정이다. 학습이 진행됨에 따라 인코더는 개선된 모델링을 제공하고, 이로써 더 정확한 의사 레이블을 생성하며, 이는 다시 인코더의 모델링에 도움을 주어 궁극적으로 아이템 임베딩과 사용자 임베딩을 개선한다.

전체 모델 학습 및 평가

본 모델에서는 아이템 및 사용자에 대해 모델링 하는 서브 태스크와 학습된 임베딩을 바탕으로 추천을 수행하는 메인 태스크를 수행한다. 본 모델에서는 두 가지 태스크에 대한 손실 함수(Loss function)을 일정 비율로 합하여 통합된 손실 함수를 만들고, 이를 최적화하는 멀티태스크 학습(Multitask - learning) 방법을 채택하였다. 서브 태스크에 해당하는 아이템 임베딩 개선 과정에는 대조 학습에 많이 쓰이는 infoNCE Loss[14]을 사용하고, 최적의 아이템 추천을 위한 학습 과정에는 BPR Loss[15]를 사용한다. 이 과정에서 사용자 임베딩과 아이템 임베딩 쌍이 필요한데, User - item view 에 있는 임베딩을 구하여 BPR Loss 를 계산한다.

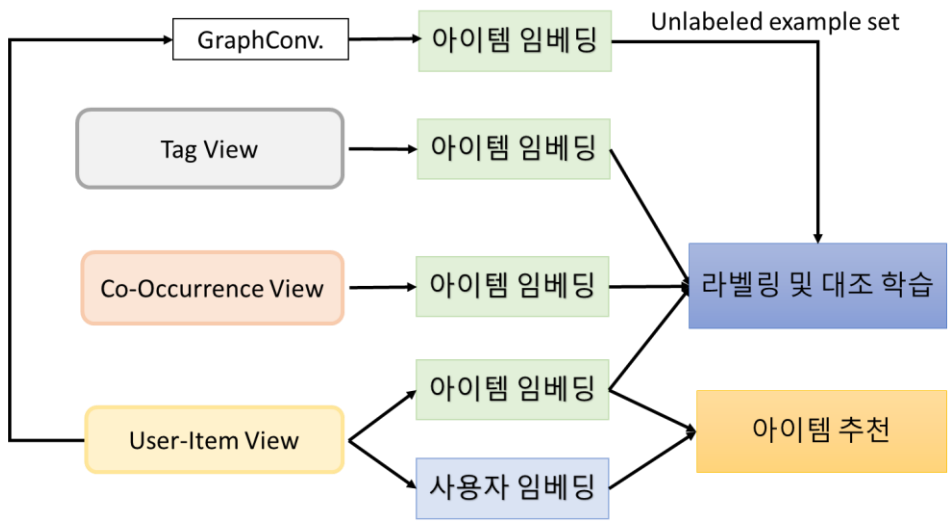

[그림 11] ItemGC 모델 전체 구조도

제 4 장 연구 결과

제 1 절 평가 지표

본 연구에서 아이템 임베딩에 대해 학습한 결과를 Downstream task 인 추천에 적용하고, 그 성능을 측정하여 학습된 임베딩을 평가해 본다. 실험에서 사용한 평가 지표는 다음과 같다.

- Precision@K : 모델이 추천한 아이템 K 개 중에 실제 사용자가 관심 있는 아이템의 비율
- Recall@K : 사용자가 관심 있는 모든 아이템 중에서 내가 추천한 아이템 K 개가 얼마나 포함되는지에 대한 비율
- NDCG@K : 추천한 K 개 아이템의 관련도를 순서에 따라 할인(Discount) 하여 합한 값(DCG)과 이상적인 추천 값(IDCG)의 비율

$$\text{Precision} = \frac{\#\text{ of our recommendations that are relevant}}{\#\text{ of items we recommended}}$$

$$\text{Recall} = \frac{\#\text{ of our recommendations that are relevant}}{\#\text{ of all the possible relevant items}}$$

$$DCG_p = rel_1 + \sum_{i=2}^{p} \frac{rel_i}{\log_2 i}$$

$$NDCG_p = \frac{DCG_p}{IDCG_p}$$

[수식 3] 평가 지표 표현식

실험에서 평가 대상이 되는 추천 아이템 개수(K)는 10 으로 고정하여 측정하였다. 실험은 5 개의 시드(1, 10, 100, 1000, 10000)를 설정하여 진행되었으며, 각각의 결과에 대한 평균 값으로 기록하였다. 모델 간 비교할 때 최고 성능은 순위 정보를 고려한 평가 지표인 NDCG 를 기준으로 결정하였다.

제 2 절 기존 연구와 성능 비교

본 절에서는 모델이 학습한 아이템 지식 정보가 추천 성능 개선을 가져왔는지에 대해 검증한다. 이를 검증하기 위해 기본 인코더 모델(LightGCN)과 이전 연구 모델(SEPT) 그리고 ItemGC 모델의 성능을 비교한다. LightGCN 은 사용자 – 아이템 상호 작용 데이터만을 사용하여 학습하고, SEPT 는 사용자 – 아이템 상호 작용 데이터와 소셜 네트워크 데이터를 학습한다. 마지막으로 본 연구에서 제안한 ItemGC 는 사용자 – 아이템 상호 작용 데이터와 아이템 지식 데이터를 활용하여 학습한다. 앞서 언급한 바와 같이, SEPT 모델과 성능 비교를 하기 위해서는 사용자 – 아이템 상호작용 데이터, 아이템 지식 데이터, 소셜 네트워크 데이터가 모두 있는 데이터셋을 사용하여 실험하여야 한다. 조건에 부합하는 LastFM 과 CiaoDVD 데이터셋에 대해 실험을 진행하였고, 결과는 [표 3], [표 4]와 같다.

Dataset	LastFM					
Model	Precision@10		Recall@10		NDCG@10	
LightGCN (base)	19.21	0.00%	19.48	0.00%	23.39	0.00%
SEPT (SOTA)	**20.19**	**5.10%**	**20.49**	**5.18%**	24.51	4.79%
ItemGC (Proposed)	20.13	4.79%	20.46	5.03%	**24.79**	**5.99%**

[표 3] 기존 연구 모델과 성능 비교 결과(LastFM)

Dataset	CiaoDVD					
Model	Precision@10		Recall@10		NDCG@10	
LightGCN (base)	1.115	0.00%	6.356	0.00%	4.064	0.00%
SEPT (SOTA)	**1.161**	**4.13%**	6.604	3.90%	**4.209**	**3.57%**
ItemGC (Proposed)	1.16	4.04%	**6.618**	**4.12%**	4.208	3.54%

[표 4] 기존 연구 모델과 성능 비교 결과(CiaoDVD)

기본 인코더 모델인 LightGCN 과 비교해 보았을 때, 두 데이터셋의 모든 평가 지표에서 4% 이상의 유의미한 성능 향상을 보였다. LightGCN 에서는 사용자 – 아이템 상호 작용 데이터만 학습하였으므로, 다른 두 모델에 비해 적은 양의 데이터로부터 학습하였고, 이로 인해 추천 성능이 떨어진다. 그에 반해 SEPT 와 ItemGC 는 사용자 – 아이템 상호 작용 데이터에 각각 소셜 네트워크 정보와 아이템 지식 정보를 추가적으로 학습하였다. 더 많은 데이터로부터 풍부한 정보를 학습하였고, 이로 인해 좋은 추천 성능을 달성하였다. 또한, SEPT 와 ItemGC 모델이 사용한 기본 인코더 모델이 LightGCN 이라는 점에서 추가 정보를 활용하여 대조 학습을 수행하였을 때 추천 성능 향상이 있었음을 알 수 있다.

ItemGC 모델을 SEPT 와 성능을 비교해 보았을 때, 각기 다른 추가 정보를 활용했음에도 불구하고 SOTA 에 준하는 성능을 보여준다.

특히 LastFM 데이터셋의 NDCG 평가 지표에서는 기존 모델을 크게 웃도는 성능을 보여준다. 이 결과로 보아 아이템 지식 데이터를 추가 정보로 활용하여 우수한 추천 성능을 달성할 수 있다는 점을 확인하였다. 또한, ItemGC 의 학습 데이터인 아이템 지식 정보가 SEPT 의 학습 데이터인 소셜 네트워크 정보보다 훨씬 구하기 쉽다는 점에서 활용성이 우수하고, 소셜 네트워크 데이터셋이 없어도 비슷한 수준의 성능을 보여줄 수 있는 것을 확인하였다.

다음으로, 본 연구 모델의 평점 예측 성능에 대해 알아보기 위해 선행 연구 모델과 비교하였다. 비교 대상 모델은 다음과 같다.

- GC - MC[30] : 그래프 기반 Auto Encoder 모델로, 평점 예측을 위해 이분 그래프에 GNN 을 적용하였다.
- IGMC[31] : 추가 정보를 학습하는 대신 로컬 그래프 패턴에 대해서 학습(Inductive learning)하여 추천하는 모델이다.
- Multi-modal RS[32] : Visual Features, textual feature, audio feature 와 같은 추가 정보를 학습하여 아이템이나 사용자의 표현에 대해 학습한 Graph Attention Network 기반 모델이다.
- GLocal - K[33] : 추가 정보 없이 사용자 - 아이템 상호 작용 그래프에서 중요 특징을 포착하기 위해 pre-training 단계의 local kernel 과 fine-tuning 단계의 global kernel 의 이점을 활용한 Auto Encoder 기반 모델이다.

- GHRS[34] : 사용자 및 아이템 추가 정보를 활용하여 유사성 기반 클러스터링 및 Auto Encoder 를 통한 특성 추출(Feature extraction)을 통해 여러 추가 정보를 학습한 모델이다.

평점 정보가 있는 MovieLens - 100k 데이터셋의 80%를 training data 로, 20%를 test data 로 해서 RMSE 를 측정하였으며, 그 결과는 [표 5]와 같다.

Model	RMSE
GC-MC(w/o side information)	0.910
GC-MC	0.905
IGMC	0.905
Multi-modal RS	0.904
GLocal - K	0.889
GHRS	0.887
ItemGC(w/o side information)	0.910
ItemGC	0.898

[표 5] 기존 평점 예측 모델과 성능 비교 결과

먼저, 본 연구 모델이 아이템 추가 정보를 학습한 경우 0.012 정도의 RMSE 의 유의미한 성능 향상이 있었다. 이를 통해 평점 예측에서도 본 연구의 아이템 추가 정보 활용 방법이 유의미하다는 것을 확인할 수 있다.

Auto encoder 기반의 GCMC 모델은 사용자의 나이, 성별, 직업과 아이템의 태그 정보를 학습하였다. 추가 정보를 고려하지 않았을 때에는 ItemGC 에서 추가 정보를 학습하지 않았을 때와 성능이 비슷하였으나, 추가 정보를 학습하였을 때 ItemGC 의 성능 향상 정도가 더 컸다. 이를 보아 GCMC 모델에서 보다 본 연구의 ItemGC 모델이 추가 정보를 더 효율적으로 학습하였다고 볼 수 있다.

그에 반해 또 다른 Auto encoder 기반 모델인 GLocal-K 는 아무런 추가 정보를 활용하지 않고도 ItemGC 보다 좋은 성능을 달성하였다. 해당 모델의 Main contribution 인 Local kernelized weight matrix 를 통한 사전 학습과 Global kernel based matrix 를 통한 fine tuning 이 희소한(sparse) 사용자 - 아이템 상호작용 데이터의 연결 관계를 보다 빽빽하게(denser) 만들어주어 보다 정확한 학습에 기여했기 때문으로 볼 수 있다.

IGMC 모델은 추가 정보에 대한 학습 의존을 벗어나고자 사용자 - 아이템 상호작용 그래프의 패턴에 대해 집중하여 학습한 모델이다. 적은 정보만을 가지고 효율적으로 SOTA 의 성능을 달성하였지만, 본 연구의 ItemGC 모델이 해당 모델의 성능을 넘어섰다. 단순히 그래프 구조에 대한 학습보다 아이템 추가 정보를 활용하여 더 명확한 학습 그래프를 형성해 주는 것이 성능 향상에 도움이 되었다고 볼 수 있다. 따라서 MovieLens - 100k 의 밀도(6.30%)보다 더 낮은 밀도를 갖는 LastFM(0.278%), Amazon-shopping(0.052%) 등의 데이터셋에서

추가 정보의 활용 여부가 더 큰 성능 격차를 가져올 것이라고 예측할 수 있다.

Multi-modal RS 모델은 평점을 예측하기 위해 아이템에 대한 요약 텍스트, 오디오나 비디오 정보와 같은 복잡한 추가 정보를 모두 학습하였다. 그에 반해 본 모델의 ItemGC 는 아이템의 태그 정보만을 추가로 학습하였고, Multi-modal RS 보다 좋은 성능을 달성하였다. 더 적은 정보를 학습하여 더 좋은 결과를 달성한 것으로 보아, 본 연구 모델이 우수하다는 것을 확인할 수 있다.

GHRS 는 사용자 추가 정보(Demographic information, social network information)와 아이템 설명(item description) 정보를 활용한 모델로, 비교 모델 중 가장 좋은 성능을 보였다. 입력 추가 정보들을 바탕으로 클러스터링 수행 및 특성 재추출 과정을 통해 효과적으로 모델을 학습해 이와 같은 결과를 달성한 것으로 볼 수 있다. 하지만 앞서 서술한 바와 같이, 사용자에 대한 추가 정보는 구하기 어려워 다양한 상황에서 활용하기 어렵다. 이에 반해, 본 연구 모델인 ItemGC 는 아이템 추가 정보를 학습하는 것으로도 성능 향상을 기대할 수 있으며, 사용자 추가 정보 없이도 우수한 성능을 달성할 수 있었다.

제 3 절 View Ablation Study

본 절에서는 아이템 지식 그래프를 활용하여 생성한 여러 개의 뷰가 추천 성능 향상에 영향을 주는지 검증해 본다. 그래프 데이터 증강을 통해 생성된 그래프 뷰는 현재 뷰에서 부족한 정보를 다른 뷰에서 가져와 학습하여 다양한 정보를 반영한 모델링을 가능케 하도록 하였다. 다른 정보를 바탕으로 생성된 각각의 뷰의 유무에 따라 추천 성능 향상 정도를 실험적으로 파악해 보고, 그 이유에 대해 분석해 본다. LastFM, CiaoDVD, Movielens-smallest, Movielens-100k, Amazon shopping(game) 데이터셋에 대해서 실험을 진행하였으며, 그 결과는 [그림 12] - [그림 16]과 같다.

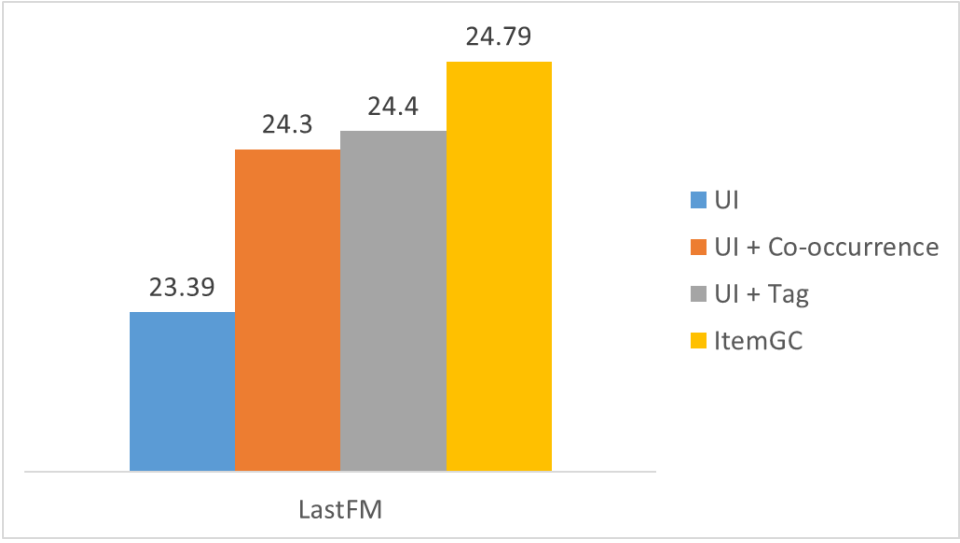

[그림 12] LastFM ablation study NDCG

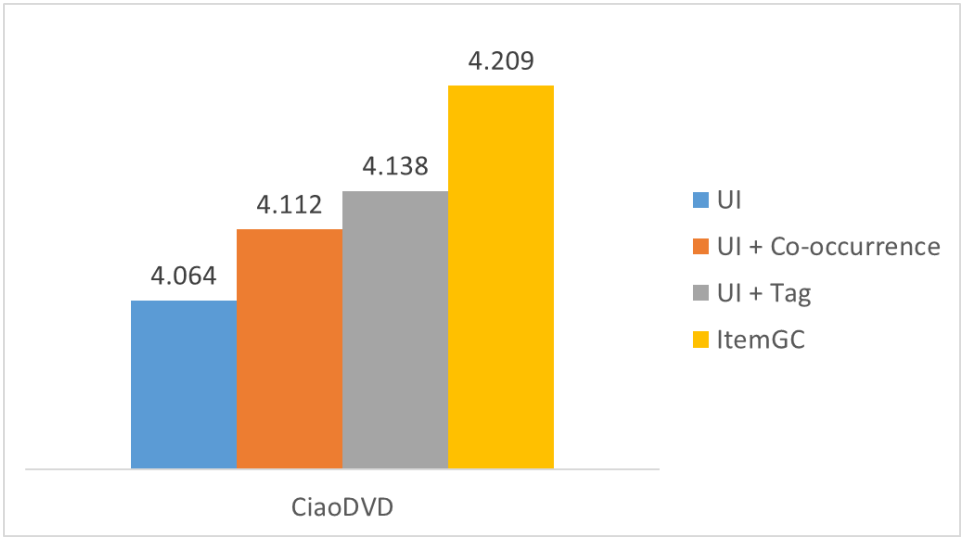

[그림 13] CiaoDVD ablation study NDCG

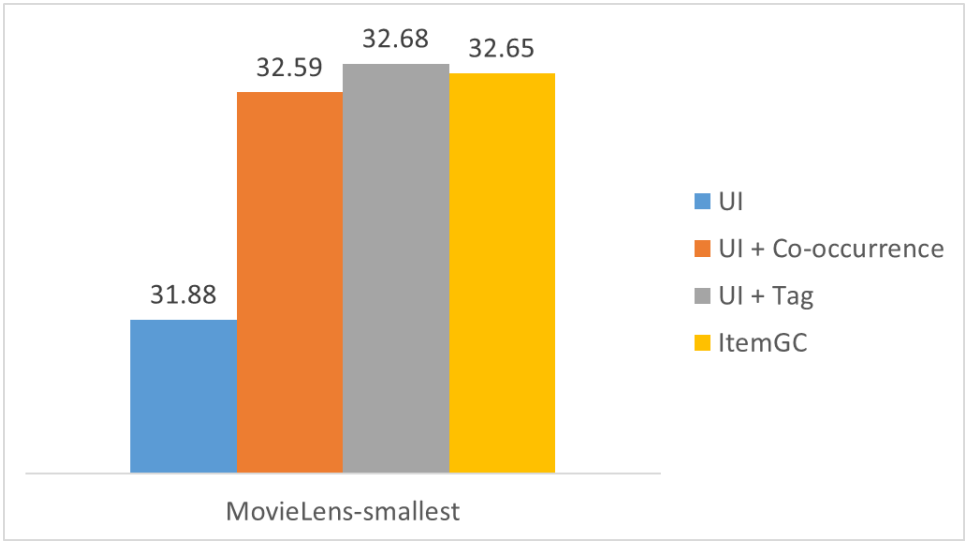

[그림 14] MovieLens-smallest ablation study NDCG

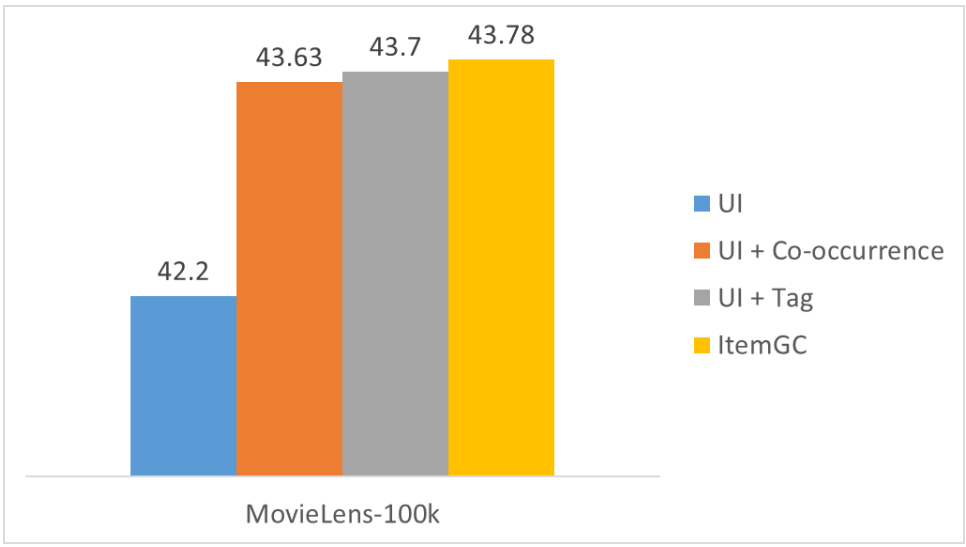

[그림 15] MovieLens-100k ablation study NDCG

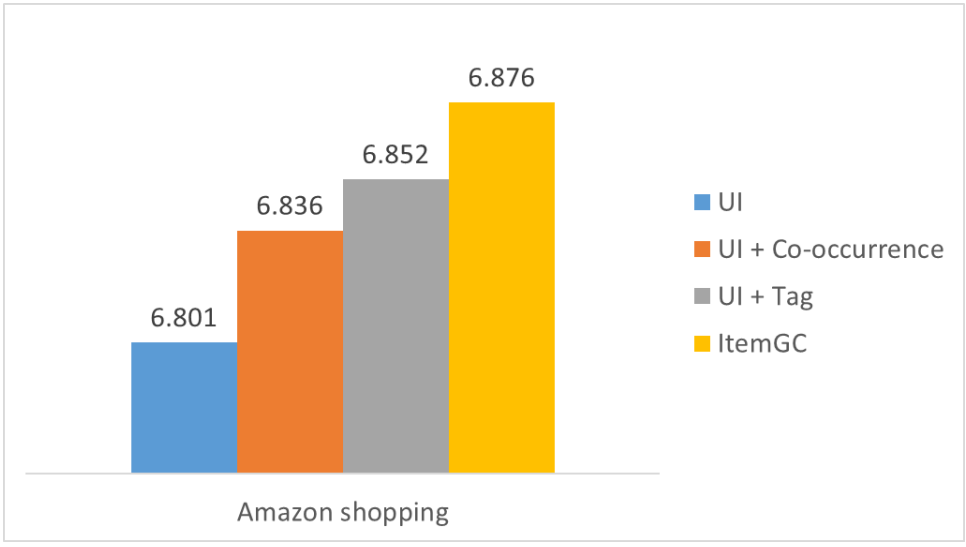

[그림 16] Amazon shopping ablation study NDCG

위 그림의 범례에서 UI 는 User-item view 만 있는 경우이고, UI + Co-occurrence 는 User-item view 에 Co-occurrence view 가

추가된 경우, UI + Tag 는 User-item view 에 Tag view 가 추가된 경우, ItemGC 는 세 가지 뷰가 모두 있는 경우를 뜻한다.

모든 데이터셋에 대해서 Co-occurrence view 나 Tag view 가 추가되었을 때 성능 향상이 존재하였다. 이는 추가로 생성한 뷰를 통해 사용자 - 아이템 상호 작용 데이터에서는 알 수 없는 정보를 학습했기 때문이라고 생각할 수 있다. 또한, Co-occurrence view 보다 Tag view 가 추가될 때 성능 향상이 큰 폭으로 일어난 것을 확인할 수 있다. 이는 User-item view 의 데이터를 변형하여 만든 뷰보다 추가 정보를 바탕으로 생성한 Tag view 에 학습할 정보가 더 많았기 때문으로 생각된다. 하지만 User - item view 를 단순 행렬 연산을 통해 약간만 변형해 주었음에도 성능 향상이 있었던 점은 고무적이며, Co - occurrence view 도 아이템 임베딩의 학습에 긍정적인 영향을 주었다고 생각할 수 있다.

대체로 User - item view 에 두 가지 뷰가 추가적으로 존재하는 ItemGC 가 성능이 가장 높게 나왔다. 이를 통해 Side information 을 활용하거나, 기존 데이터를 변형하여 다수의 뷰 만들고 대조 학습을 진행한다면 대상에 대해 더 잘 모델링 할 수 있다는 점을 확인하였다.

Precision 과 Recall 평가 지표에 대해 측정해 보았을 때 NDCG 와 비슷한 경향의 성능 향상을 보였다.[표 6], [표 7]

	LastFM		CiaoDVD	
	P@10	R@10	P@10	R@10
UI	19.21	19.48	1.115	6.356
UI + Co-occurrence	19.71	19.99	1.145	6.534
UI + Tag	19.73	20.02	1.146	6.563
ItemGC	**20.13**	**20.46**	**1.167**	**6.665**

[표 6] Ablation study Precision과 Recall 결과(1)

	MovieLens-smallest		MovieLens-100k		Amazon-games	
	P@10	R@10	P@10	R@10	P@10	R@10
UI	26.90	13.92	34.85	22.85	1.855	11.11
UI + Co-occurrence	27.61	14.65	35.89	23.47	1.856	11.22
UI + Tag	27.71	14.76	**35.97**	23.53	1.865	**11.26**
ItemGC	**27.74**	**14.78**	35.95	**23.63**	**1.866**	**11.26**

[표 7] Ablation study Precision과 Recall 결과(2)

제 5 장 결 론

제 1 절 연구 요약

본 연구에서는 기존 추천 분야 데이터셋이 가지는 sparsity 문제를 해결하고 임베딩 학습을 개선하기 위해 아이템 지식 정보를 활용하였다. 주어진 데이터셋을 효과적으로 학습하기 위해 그래프 인공 신경망 구조와 대조 학습 방법을 채택하였으며, 사용자 - 아이템 상호작용 데이터와 아이템 지식 데이터를 학습하여 추천 성능을 개선하였다.

첫 번째 실험(4 장 2 절)에서 기존 연구와 ItemGC 의 성능을 비교하였다. 추가 정보를 활용한 모델(SEPT, ItemGC)의 추천 성능이 사용자 - 아이템 상호 작용 데이터만 학습한 모델(LightGCN)보다 우수한 것으로 보아, 소셜 네트워크나 아이템 지식 정보와 같은 추가 정보가 추천 성능 향상에 도움을 줄 수 있다는 것을 확인하였다. 또한, 기존 SOTA 모델과 추천 성능 비교를 위해 사용자 - 아이템 상호 작용 데이터, 소셜 네트워크 데이터와 아이템 지식 정보가 모두 있는 LastFM, CiaoDVD 데이터셋으로 실험하였다. 이를 통해, ItemGC 모델이 소셜 네트워크 데이터 없이 기존 SOTA 모델(SEPT)에 준하는 성능을 달성한 것을 확인하였다. 마지막으로, 평점 예측 성능에 대해 알아보기 위해 기존 평점 예측 연구 모델과 추천 성능 비교를 진행하였다. 비록 SOTA 의 성능을 달성하지는 못했지만, 비교적 구하기 쉽고 적은

추가정보(아이템 태그 정보)를 활용하여 평점을 예측하여도 충분히 우수한 성능을 보임을 확인하였다.

두 번째 실험에서 그래프 대조 학습을 위해 생성한 여러 개의 뷰에 대한 Ablation study 를 진행하였다. User-item view, Tag view 그리고 Co-occurrence view 의 유무에 따라 추천 성능 변화를 측정해 보았다. 대부분의 경우에 그래프 뷰가 추가될 때마다 추천 성능이 향상된 것을 확인하였으며, 모든 뷰가 추가된 ItemGC 모델이 가장 높은 성능을 보였다. 또한, 기존 정보를 행렬 연산을 통해 변형한 Co-occurrence view 보다 새롭게 추가된 정보를 통해 생성된 Tag view 가 성능 향상에 더 많이 기여한다는 점으로 보아 추가 정보가 추천 성능 향상에 도움을 준다는 것을 확인하였다.

제 2 절 연구 의의

본 연구는 사용자 – 아이템 상호 작용 데이터와 아이템 지식 데이터를 대조 학습하여 임베딩을 개선하고 이를 바탕으로 추천을 수행하였다. 기존 연구 모델은 소셜 네트워크 데이터를 활용하였고, 본 연구 모델인 ItemGC 는 아이템 지식 데이터를 활용하여 모델을 학습하였다. 전혀 다른 추가 정보를 활용하여 학습했음에도 불구하고 SOTA 에 준하는 추천 성능을 달성하였다. 소셜 네트워크 데이터는 개인 정보로 취급되어 구하기 어려우며, 데이터 증강이 어렵다는 활용상의 단점이 있다. 반면에 아이템 지식 데이터는 훨씬 구하기 쉬우며, 다양한 종류의 추가 정보를 사용하여 더 많은 정보를 학습할 수 있다. 따라서 적은 제약 사항으로 기존 SOTA 연구에 준하는 정도의 성능에 도달할 수 있다는 점이 본 연구의 의의다.

본 연구에서 서로 다른 추가 정보를 활용하여 학습한 두 모델의 추천 성능에 대해 비교하였다(4 장 2 절). 이를 위해 하나의 사용자 – 아이템 상호작용 데이터를 공유하는 아이템 지식 데이터와 소셜 네트워크가 포함된 데이터셋을 채택하였으며, ItemGC 모델과 SEPT 모델에 대해 추천 성능을 비교하였다. 위와 같이 하나의 데이터셋에 파생되는 추가 정보의 종류에 따라 추천 성능을 비교한 최초의 실험으로, 공정한 비교를 통해 아이템 지식 데이터를 활용한 학습이 소셜 네트워크 데이터를 활용한 학습을 대체할 수 있다는 점을 실험적으로 증명하였다.

제 3 절 연구의 한계점 및 향후 연구

4 장 2 절에서 기존 SOTA 연구와 추천 성능을 비교하기 위하여 LastFM 과 CiaoDVD 데이터셋을 사용하여 검증하였고, 비슷한 수준의 성능이 나온다는 것을 확인하였다. 두 종류의 데이터셋 밖에 사용하지 않은 이유는 앞서 언급했던 대로, 사용자 아이템 상호간 상호작용 데이터를 공유하는 소셜 네트워크 데이터 그리고 아이템 지식 정보 데이터가 모두 있는 데이터셋이 많지 않기 때문이다. 좀 더 정확한 실험 결과를 위해서 더 많은 데이터셋을 통해 검증할 필요가 있다. 추후에 조건에 부합하는 데이터셋이 제공된다면 추가 실험을 통해 검증의 신뢰도를 높일 필요가 있다.

4 장 3 절에서 여러 종류의 그래프 뷰가 모델에 추가되었을 때 가장 우수한 최종 추천 성능을 달성함을 확인과 동시에, Co-Occurrence view 의 성능 향상 정도는 상대적으로 적다는 점을 확인하였다. 새로운 정보를 바탕으로 생성된 Tag view 에 비해 기존의 데이터를 변형하여 생성된 그래프 뷰이기 때문에 위와 같은 결과가 나타났음을 유추할 수 있다. 따라서 더 나은 추천 성능을 위해 Co-occurrence view 의 부족한 정보량을 보완할 필요가 있다. 기존 정보를 바탕으로 Subgraph 를 생성하여 뷰를 생성하거나 가상 간선(Virtual edges)을 추가해 주는 등 본 연구에서 활용한 그래프 데이터 증강 방법 이외의 여러 방법을 수행하여, User-item view 의 부족한 정보를 보완하여

학습할 수 있도록 그래프 뷰를 수정해 성능 향상을 시도해 볼 수 있다. 또한, 새로운 종류의 아이템 지식 정보를 입력받아 네 번째 뷰를 추가 생성하는 방식으로 성능 향상을 기대할 수 있다.

SEPT 연구에서 소셜 네트워크 정보를 바탕으로 사용자 임베딩을 개선하였으며, 본 연구에서는 아이템 지식 정보를 바탕으로 아이템 임베딩을 개선하였다. 위에서 언급한 실험 내용 외에 사용자 아이템 상호 작용 데이터, 소셜 네트워크 데이터와 아이템 지식 정보 데이터를 모두 사용하여 사용자와 아이템 임베딩을 동시에 개선하여 더욱더 향상된 추천 결과를 얻으려고 시도해 보았다. 기존 방법과 유사하게 총 5 개의 그래프 뷰를 생성하고 라벨링 하여 대조 학습을 진행하여 사용자 임베딩과 아이템 임베딩을 얻었으나, 추천 성능을 측정해 보았을 때 ItemGC 나 SEPT 와 유사한 성능을 내었다. 이는 서로 다른 추가 정보는 많을수록 학습에 유리하다는 생각을 바탕으로 진행한 추가 실험이었지만 좋은 결과를 낼 수 없었다. 두 학습 결과를 단순히 결합하거나 멀티태스크 학습의 자율성에 맡기기보다 알맞은 방법으로 ItemGC 와 SEPT 의 결과에 대해 합칠 필요가 있다. 위와 같이 두 개 이상의 추가 정보를 활용한 학습을 통해 사용자 및 아이템을 적절히 모델링 할 수 있다면 우수한 추천 성능을 보이는 시스템을 만들 수 있을 것이다.

참고 문헌

[1] Fan, W., Ma, Y., Li, Q., He, Y., Zhao, E., Tang, J., & Yin, D. (2019, May). Graph neural networks for social recommendation. In *The world wide web conference*(pp. 417-426).

[2] Wu, L., Sun, P., Fu, Y., Hong, R., Wang, X., & Wang, M. (2019, July). A neural influence diffusion model for social recommendation. In Proceedings of the 42nd international ACM SIGIR conference on research and development in information retrieval(pp. 235-244).

[3] Wang, H., Zhao, M., Xie, X., Li, W., & Guo, M. (2019, May). Knowledge graph convolutional networks for recommender systems. In The world wide web conference (pp. 3307-3313).

[4] Wang, X., He, X., Cao, Y., Liu, M., & Chua, T. S. (2019, July). Kgat: Knowledge graph attention network for recommendation. In Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining(pp. 950-958).

[5] You, Y., Chen, T., Sui, Y., Chen, T., Wang, Z., & Shen, Y. (2020). Graph contrastive learning with augmentations. Advances in Neural Information Processing Systems, 33, 5812-5823.

[6] Wu, J., Wang, X., Feng, F., He, X., Chen, L., Lian, J., & Xie, X. (2021, July). Self-supervised graph learning for recommendation. In Proceedings of the 44th international ACM SIGIR conference on research and development in information retrieval(pp. 726-735).

[7] Liu, Z., Ma, Y., Ouyang, Y., & Xiong, Z. (2021). Contrastive learning for recommender system. arXiv preprint arXiv:2101.01317

[8] Wang, C., Liang, Y., Liu, Z., Zhang, T., & Philip, S. Y. (2021, December). Pre-training Graph Neural Network for Cross Domain Recommendation. In 2021 IEEE Third International Conference on Cognitive Machine Intelligence (CogMI)(pp. 140-145). IEEE.

[9] Yao, T., Yi, X., Cheng, D. Z., Yu, F., Chen, T., Menon, A., ... & Ettinger, E. (2021, October). Self-supervised learning for large-scale item recommendations. In Proceedings of the 30th ACM International Conference on Information & Knowledge Management (pp. 4321-4330).

[10] Yu, J., Yin, H., Gao, M., Xia, X., Zhang, X., & Viet Hung, N. Q. (2021, August). Socially-aware self-supervised tri-training for recommendation. In Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining(pp. 2084-2092).

[11] Kipf, T. N., & Welling, M. (2016). Semi-supervised classification with graph convolutional networks. arXiv preprint arXiv:1609.02907.

[12] Wang, X., He, X., Wang, M., Feng, F., & Chua, T. S. (2019, July). Neural graph collaborative filtering. In Proceedings of the 42nd international ACM SIGIR conference on Research and development in Information Retrieval(pp. 165-174).

[13] He, X., Deng, K., Wang, X., Li, Y., Zhang, Y., & Wang, M. (2020, July). Lightgcn: Simplifying and powering graph convolution network for recommendation. In Proceedings of the 43rd International ACM SIGIR conference on research and development in Information Retrieval (pp. 639-648).

[14] Hjelm, R. D., Fedorov, A., Lavoie-Marchildon, S., Grewal, K., Bachman, P., Trischler, A., & Bengio, Y. (2018). Learning deep

representations by mutual information estimation and maximization. arXiv preprint arXiv:1808.06670.

[15] Rendle, S., Freudenthaler, C., Gantner, Z., & Schmidt-Thieme, L. (2012). BPR: Bayesian personalized ranking from implicit feedback. arXiv preprint arXiv:1205.2618.

[16] Chen, D., Lin, Y., Li, W., Li, P., Zhou, J., & Sun, X. (2020, April). Measuring and relieving the over-smoothing problem for graph neural networks from the topological view. In Proceedings of the AAAI Conference on Artificial Intelligence (Vol. 34, No. 04, pp. 3438-3445).

[17] Yu, J., Yin, H., Li, J., Wang, Q., Hung, N. Q. V., & Zhang, X. (2021, April). Self-supervised multi-channel hypergraph convolutional network for social recommendation. In Proceedings of the Web Conference 2021 (pp. 413-424).

[18] LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). Backpropagation applied to handwritten zip code recognition. Neural computation, 1(4), 541-551.

[19] McPherson, M., Smith-Lovin, L., & Cook, J. M. (2001). Birds of a feather: Homophily in social networks. Annual review of sociology, 415-444.

[20] Zheng, Y., Gao, C., He, X., Li, Y., & Jin, D. (2020, April). Price-aware recommendation with graph convolutional networks. In 2020 IEEE 36th International Conference on Data Engineering (ICDE) (pp. 133-144). IEEE.

[21] Hao, B., Zhang, J., Yin, H., Li, C., & Chen, H. (2021, March). Pre-training graph neural networks for cold-start users and items representation. In Proceedings of the 14th ACM International Conference on Web Search and Data Mining (pp. 265-273).

[22] Xia, X., Yin, H., Yu, J., Wang, Q., Cui, L., & Zhang, X. (2021, May). Self-supervised hypergraph convolutional networks for session-based recommendation. In Proceedings of the AAAI conference on artificial intelligence (Vol. 35, No. 5, pp. 4503-4511).

[23] Liu, Z., Ma, Y., Ouyang, Y., & Xiong, Z. (2021). Contrastive learning for recommender system. arXiv preprint arXiv:2101.01317.

[24] Lee, D., Kang, S., Ju, H., Park, C., & Yu, H. (2021, July). Bootstrapping user and item representations for one-class collaborative filtering. In Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval (pp. 317-326).

[25] Yang, Y., Wu, L., Hong, R., Zhang, K., & Wang, M. (2021, July). Enhanced graph learning for collaborative filtering via mutual information maximization. In Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval (pp. 71-80).

[26] Yang, H., Chen, H., Li, L., Philip, S. Y., & Xu, G. (2021, December). Hyper Meta-Path Contrastive Learning for Multi-Behavior Recommendation. In 2021 IEEE International Conference on Data Mining (ICDM) (pp. 787-796). IEEE.

[27] Yu, J., Yin, H., Xia, X., Chen, T., Li, J., & Huang, Z. (2022). Self-Supervised Learning for Recommender Systems: A Survey. arXiv preprint arXiv:2203.15876.

[28] Liu, Y., Jin, M., Pan, S., Zhou, C., Zheng, Y., Xia, F., & Yu, P. (2022). Graph self-supervised learning: A survey. IEEE Transactions on Knowledge and Data Engineering.

[29] Wu, S., Sun, F., Zhang, W., Xie, X., & Cui, B. (2020). Graph neural networks in recommender systems: a survey. ACM Computing Surveys (CSUR).

[30] Berg, R. V. D., Kipf, T. N., & Welling, M. (2017). Graph convolutional matrix completion. arXiv preprint arXiv:1706.02263.

[31] Zhang, M., & Chen, Y. (2019). Inductive matrix completion based on graph neural networks. arXiv preprint arXiv:1904.12058.

[32] Chakder, D., Mondal, P., Raj, S., Saha, S., Ghosh, A., & Onoe, N. (2022, October). Graph Network based Approaches for Multi-modal Movie Recommendation System. In 2022 IEEE International Conference on Systems, Man, and Cybernetics (SMC) (pp. 409-414). IEEE.

[33] Han, S. C., Lim, T., Long, S., Burgstaller, B., & Poon, J. (2021, October). GLocal-K: Global and Local Kernels for Recommender Systems. In Proceedings of the 30th ACM International Conference on Information & Knowledge Management (pp. 3063-3067).

[34] Darban, Z. Z., & Valipour, M. H. (2022). GHRS: Graph-based hybrid recommendation system with application to movie recommendation. Expert Systems with Applications, 200, 116850.

Abstract

Enhancing Embedding Learning for Recommendation Utilizing Item Knowledge Information

Jaehong Lee

Department of Intelligence and Information

The Graduate School of Convergence Science and Technology

Seoul National University

Based on the log data accumulated by the user through actions such as purchasing or clicking an item, the relationship between the user and the item was identified, and recommendations for the item were made by applying methods such as collaborative filtering or content-based filtering. Advances in graph neural network(GNN) technology have enabled us to design a recommended system model that can well consider the relationship of the target, and demonstrated superior performance over existing methodologies. In addition, it is advantageous to utilize various additional information such as user profiles and item knowledge information for more accurate recommendation. In a recent study, graph contrast learning(GCL) was performed using social network data as additional information, and it showed good performance on several recommended datasets. However, such social network data is difficult to obtain, and there are many cases where there is no such

social network data, so it is difficult to use. Therefore, this study proposes a plan to improve the recommended performance by using item knowledge information data instead of social network data. We achieve similar levels of performance to existing study using social network data as additional information, which shows that high levels of recommendation are possible even in the absence of social network data.

Keywords : Recommender System, Side information, Graph Contrastive Learning
Student Number : 2021 – 25242