



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](#)

공학석사 학위논문

도메인 특성을 고려한 사용자
임베딩과 그래프 어텐션 네트워크를
이용한 교차 도메인 추천 모델

Cross-Domain Recommendation
by Using Domain Specific User Embedding
and Graph Attention Network

2020년 8월

서울대학교 대학원

전기·정보공학부

김 영 빈

도메인 특성을 고려한 사용자
임베딩과 그래프 어텐션
네트워크를 이용한 교차 도메인
추천 모델

지도교수 심 규 석

이 논문을 공학석사 학위논문으로 제출함
2020년 5월

서울대학교 대학원
전기·정보공학부
김 영 빈

김영빈의 공학석사 학위논문을 인준함
2020년 6월

위 원 장 김태환 (인)

부위원장 심규석 (인)

위 원 홍성수 (인)

초록

추천 시스템은 오늘날 우리의 생활에 많은 부분을 차지한다. 추천 시스템 중 교차 도메인 추천은 연관된 도메인으로부터 정보를 전달받아 희소한 데이터에 대해 성능이 떨어지는 단일 도메인 추천 모델의 문제를 경감시킨다. 교차 도메인 추천 모델 중 전이 학습을 도입한 모델은 두 도메인에서 같은 사용자 임베딩 행렬을 사용하여 사용자의 특성이 도메인에 따라 달라질 수 있다는 점을 고려하지 않았다. 본 논문에서는 첫 번째 모델로 이 특성을 고려하여 추천 성능을 향상시킨 모델을 제안하였다. 또 다른 교차 도메인 추천은 사용자와 상품으로 그래프를 만들고, 그래프 합성곱 신경망(graph convolution networks)을 사용하여 사용자와 상품간의 복잡한 관계까지 고려하여 성능을 높인 모델이 제안되었다. 그러나 이 모델은 모든 상품과 사용자 간의 중요도를 동일하게 보아 추천의 정확도가 떨어질 수 있는 문제가 있다. 따라서 본 논문에서는 두 번째 모델로 상품과 사용자 간의 중요도를 고려하기 위해 어텐션 메커니즘(attention mechanism)을 적용한 모델을 제안하였다. 또한, 실생활 데이터를 이용해 모델의 추천 정확도 향상을 확인하였다.

주요어 : 추천 시스템, 전이 학습, 그래프 어텐션 네트워크

학 번 : 2018-25877

목 차

제 1 장 서론	1
제 1 절 연구의 배경 및 내용	1
제 2 장 관련 연구	3
제 1 절 추천 시스템	3
제 2 절 다중 작업 학습	12
제 3 절 전이 학습	13
제 4 절 그래프 신경망 네트워크	14
제 3 장 제안하는 모델	18
제 1 절 문제정의	18
제 2 절 도메인 특성을 고려한 교차 도메인 추천	19
제 3 절 그래프 어텐션 네트워크를 이용한 교차 도메인 추천	21
제 4 장 실험	24
제 1 절 실험 데이터와 비교 모델	24
제 2 절 성능 평가 지표 및 실험 설정	24
제 3 절 실험 결과 및 분석	26
제 5 장 결론	29
참고문헌	30
Abstract	32

표 목 차

[표 1] 데이터셋 통계	24
[표 2] 사용자 특성을 고려한 사용자 임베딩과 SCoNet 비교 ..	26
[표 3] 실험결과	27

그 립 목 차

[그림 1] 신경 협업 필터링 중 MLP의 구조	6
[그림 2] NeuMF 구조	7
[그림 3] SCoNet의 구조	8
[그림 4] PPGN의 구조	10
[그림 5] 하드 변수 공유 구조	12
[그림 6] 소프트 변수 공유 구조	13
[그림 7] 그래프 합성곱 신경망의 구조	14
[그림 8] 하나의 노드에 대한 그래프 합성곱 신경망	16
[그림 9] GAT 구조	17
[그림 10] GAT 전체 구조	17
[그림 11] SCoNet+의 구조	19
[그림 12] CDRGAT 구조	21
[그림 13] 그래프 구조	22

제 1 장 서론

제 1 절 연구의 배경 및 내용

추천 시스템은 소셜 네트워크, 온라인 매장 등 다양한 온라인 서비스 분야에서 널리 사용된다. 추천 시스템은 온라인 서비스에서 많은 상품이나 서비스들 중 만족도가 높은 선택을 추천하여 사용자들의 선택을 도와준다[1]. 사용자들이 온라인 서비스를 이용하면서 상품을 클릭하거나 동영상을 조회하는 등과 같은 행동은 사용자와 상품 간에 인터랙션(interaction)을 생성한다. 추천 시스템은 이런 인터랙션들을 바탕으로 사용자들의 선호도를 파악해 사용자들에게 상품을 추천한다.

추천 모델 중 협업 필터링(collaborative filtering)은 비슷한 행동을 보이는 사용자들은 상품의 선호도가 비슷할 것이라는 가정하에 사용자들에게 상품을 추천한다[2]. 하나의 도메인을 사용하는 협업 필터링 중 대표적인 행렬 분해(matrix factorization)[3] 방식은 각 사용자와 상품의 특징(feature)을 벡터(vector)로 임베드(embed)하고 사용자와 상품 간 얼마나 관련되어 있는지에 대한 점수를 예측하기 위해 사용자 벡터와 상품 벡터를 내적 한다. 또한, 사용자와 상품 간의 관련성 점수를 예측하기 위해 신경망을 사용한 신경 협업 필터링(neural collaborative filtering) 방식도 있다[1]. 이런 하나의 도메인만을 사용하는 추천 모델은 데이터가 희소(sparse)해지면 추천의 정확도가 떨어지는 문제점이 있다. 이런 문제점을 보완하고자 두 개의 도메인을 사용하는 교차 도메인 추천 모델이 등장하였다.

교차 도메인 추천 모델 중 SCoNet(sparse collaborative cross networks for cross-domain recommendation)[4]은 두 도메인에서 공통된 사용자 임베딩 행렬(embedding matrix)을 사용하고 전이 학습(transfer learning)을 적용해 연관된 도메인으로부터 정보를 주고받아 데

이터가 최소화할 때 추천 정확도가 떨어지는 문제점을 보완하였다. 그러나 두 도메인에서 공통된 사용자 임베딩 행렬을 사용해 사용자의 특성이 도메인에 따라 달라질 수 있다는 점을 반영하지 않았다. 이에 본 논문에서는 첫 번째 제안 모델로 사용자의 도메인 특성을 고려하기 위해 사용자 임베딩 행렬을 일부만을 공유하는 모델을 제안한다.

또한, 교차 도메인 추천 모델 중 그래프 합성곱 신경망(graph convolution network)을 적용하여 상품과 사용자 간의 복잡한 관계를 고려한 PPGN(preference propagation graphnet)[5]이 있다. 이때, 그래프는 상품과 사용자를 모두 노드(node)로 보고 상품과 사용자 쌍에 인터랙션이 존재할 때 간선(edge)을 추가하여 만든다. PPGN은 사용자와 상품 간의 중요도를 모두 동일하게 보아 추천 정확도가 떨어질 수 있다는 문제점이 있다. 이에 본 논문에서는 두 번째 모델로 사용자와 상품 간의 중요도를 고려한 모델을 제안한다. 2장에서는 관련 연구를 소개하며, 3장에서는 본 논문에서 제안하는 두 가지 모델을 소개한다. 4장에서는 제안한 모델과 기존 연구들의 성능을 비교하고 실험 결과를 분석한다. 마지막으로 5장에서 결론을 맺는다.

제 2 장 관련 연구

제 1 절 추천 시스템

추천 시스템은 사용자의 과거 행동이나 평점 등으로부터 학습하여 사용자에게 아직 선택하지 않은 상품 중 적합한 상품을 추천하는 것이다. 추천 시스템은 크게 두 가지로 나뉜다. 암묵적 피드백(implicit feedback) 데이터를 사용한 것과 명시적 피드백(explicit feedback) 데이터를 사용한 것이다.

암묵적 피드백은 사용자들의 행동을 인터랙션으로 표현한 것을 말한다. 암묵적 피드백 행동들의 종류에는 상품 조회, 영화 감상 여부 등이 있다. 예를 들어, 영화에 대한 암묵적 피드백은 사용자가 어떤 영화를 보았는지, 보지 않았는지로 나뉜다. 따라서, 영화를 보지 않았다고 해서, 보지 않은 영화에 대한 부정적인 피드백(negative feedback)을 의미하지 않고, 영화를 보았다고 해서 그 영화가 사용자의 취향(preference)을 의미하지 않는다. 반면에 명시적 피드백은 사용자들의 선호가 평점과 같은 것으로 직접 반영된다.

암묵적 피드백은 사용자의 행동만 있으면 되지만, 명시적 피드백은 사용자의 평점이 필요하므로 명시적 피드백을 항상 사용할 수 있는 것은 아니다[6]. 따라서, 본 논문에서는 암묵적 피드백에 집중한다.

단일 도메인 추천(single-domain recommendation): 단일 도메인의 정보만을 사용하여 추천하는 것이다. 대부분의 추천 시스템이 단일 도메인 추천이다.

단일 도메인 추천은 대부분 협업 필터링(collaborative filtering)을 기반으로 한다. 협업 필터링이란 사용자의 선호를 사용자와 상품 간의 상호작용을 바탕으로 예측하는 것이다. 본 논문에서는 암묵적 피드백을 위

한 협업 필터링 방식들만을 소개할 것이다. 그중에서도 암묵적 피드백의 행렬분해 방식인 베이지안 개인화 순위(bayesian personalized ranking)와 신경 협업 필터링(neural collaborative filtering)을 소개할 것이다.

베이지안 개인화 순위[3]는 $(u, i) \in S$ 라는 집합을 정의하는데, 쌍(pair) (u, i) 는 사용자 u 가 상품 i 와 인터랙션 했을 때를 의미한다. 또한, $D_s : U \times I \times I$ 를 식 (2-1)과 같이 정의한다. 이때, 위 첨자 +는 인터랙션이 있는 사용자 또는 상품을 의미한다. 즉, 아래 식 (2-1)의 I_u^+ 는 사용자 u 가 인터랙션한 상품들의 집합이다. D_s 는 사용자 u 가 관측한 상품 i 를 인터랙션 하지 않은 상품 j 보다 더욱 선호한다는 가정을 뜻한다. $i >_u j$ 로도 표현할 수 있다.

$$D_s := \{(u, i, j) | i \in I_u^+ \wedge j \in I - I_u^+\} \quad \text{식 (2-1)}$$

베이지안 개인화 순위에서 사용자 u 가 상품 i 를 상품 j 에 비해 실제로 선호하는 확률을 식 (2-2)와 같이 정의한다. 이때, σ 는 논리적 시그모이드 함수이고, \hat{x}_{uij} 는 $\hat{x}_{ui} - \hat{x}_{uj}$ 로 정의된다. \hat{x}_{ui} 는 사용자 u 가 상품 i 를 선호할지 모델이 예측한 값이다. θ 는 사용자 u 와 상품 i , 상품 j 와의 관계를 포착한다.

$$p(i >_u j | \theta) := \sigma(\hat{x}_{uij}(\theta)), \sigma(x) := \frac{1}{1 + e^{-x}} \quad \text{식 (2-2)}$$

베이지안 개인화 순위의 사용자들은 독립적이라고(independent) 가정하였으므로 가능도(likelihood) 함수는 식 (2-3)과 같이 모든 사용자 U 에 대해 단일 밀도의(single density) 곱으로 나타낼 수 있다.

$$\prod_{u \in U} p(>_u | \theta) = \prod_{(u, i, j) \in U \times I \times I} p(i >_u j | \theta)^{\delta((u, i, j) \in D_s)} \cdot (1 - p(i >_u j | \theta))^{\delta((u, i, j) \notin D_s)} \quad \text{식 (2-3)}$$

이때, δ 는 지시 함수로(indicator function) 식 (2-4)와 같다.

$$\delta(b) := \begin{cases} 1 & \text{if } b \text{ is true,} \\ 0 & \text{else} \end{cases} \quad \text{식 (2-4)}$$

식 (2-3)은 식 (2-5)와 같이 단순하게 바뀔 수 있다.

$$\prod_{u \in U} p(>_u | \theta) = \prod_{(u, i, j) \in D_s} p(i >_u j | \theta) \quad \text{식 (2-5)}$$

베이지안 개인화 순위의 로그 최대 사후 확률(maximum likelihood estimation)은 식 (2-6)과 같이 정의된다. 베이지안 개인화 순위의 목표는 식 (2-6)을 최대화(maximize)하는 것이다. λ_θ 는 모델의 정규화(regularization) 계수이다.

$$\ln p(\Theta | \mathcal{D}_s) = \sum_{(u,i,j) \in \mathcal{D}_s} \ln \sigma(\widehat{x}_{uij}) - \lambda_\theta \|\Theta\|^2 \quad \text{식 (2-6)}$$

위 식 (2-6)을 풀기 위해서는 경사 하강법(gradient descent)를 사용하면 된다.

위에서 소개한 베이지안 개인화 순위보다 더 깊은 관계를 학습하기 위해 협업 필터링에 신경망 네트워크가 도입되었다. 신경 협업 필터링[1]은 신경망을 사용한 협업 필터링이다. 신경 협업 필터링은 두 가지의 모델을 사용하는데, 일반화 행렬 분해(generalized matrix factorization, GMF)와 다층 퍼셉트론(multi-layer perceptron, MLP)이다.

먼저 일반화 행렬 분해 방식에 대해 설명한다. 기존 행렬 분해 방식을 신경망을 이용해 일반화시킨 것이다. 사용자 임베딩 행렬을 U , 상품 임베딩 행렬을 V 라고 하자. 사용자 u 와 상품 i 의 임베딩 벡터(embedding vector)는 각각 U_u 와 V_i 이다. 일반화 행렬 분해는 아래 식 (2-7)처럼, 사용자 임베딩 벡터와 상품 임베딩 벡터를 요소별(element-wise) 곱을 하고 신경망 한 층을 통과시켜 활성화 함수(activation function) a_{out} 을 통과시키면 사용자 u 가 상품 i 를 선호하는지에 대한 점수를 예측할 수 있다. 이때, W 는 신경망의 가중치(weight)를 의미한다.

$$\hat{r}_{ui} = a_{out}(W^T(U_u \odot V_i)) \quad \text{식 (2-7)}$$

일반화 행렬 분해는 활성화 함수로 비선형 함수를 써서 기존 행렬 분해에 비선형성을 추가했다. 이때 활성화 함수로 시그모이드 함수(sigmoid function)를 사용하였다.

다층 퍼셉트론 모델은 다층 퍼셉트론을 협업 필터링에 적용한 것이다. 모델은 그림 1과 같다. 식 (2-8)과 그림 1을 보면, 행렬 분해 방식과는 다르게 사용자 임베딩 벡터와 상품 임베딩 벡터를 합친다(concatenate). 그런 후, 다층 퍼셉트론의 입력으로 넣어준다. 식 (2-8)의 W 와 b 는 각각

그 층의 가중치와 바이어스(bias)를 뜻한다. 다층 퍼셉트론 모델에서 활성화 함수로 ReLU[7]를 사용한다. 또한, 각 층의 크기는 위로 갈수록 작아지는 탑(tower) 구조를 띤다. 탑 구조는 위의 층일수록 압축된 특징(feature)을 배울 수 있다.

$$z_1 = \phi(U_u, V_i) = \begin{bmatrix} U_u \\ V_i \end{bmatrix}, \quad \text{식 (2-8)}$$

$$\phi_2 = a_2(W_2^T z_1 + b_2),$$

$$\dots$$

$$\phi_L(z_{L-1}) = a_L(W_L^T z_{L-1} + b_L),$$

$$\hat{r}_{ui} = \sigma(h^T \phi_L(z_{L-1}))$$




그림 1 신경 협업 필터링 중 MLP의 구조

일반화 행렬 분해와 다층 퍼셉트론 모델 모두 같은 손실 함수를 사용한다. 손실 함수는 베이지안 개인화 순위와 비슷한 로그 가능도이며 아래 식 (2-9)와 같다.

$$L = - \sum_{(u,i) \in R \cup R^-} r_{ui} \log \hat{r}_{ui} + (1 - r_{ui}) \log (1 - \hat{r}_{ui}) \quad \text{식 (2-9)}$$

R 은 사용자 u 가 상품 i 와 인터랙션 했을 때 쌍 (u,i) 의 집합이고, R^- 은 쌍 (u,i) 의 집합으로 쌍 (u,i) 는 사용자 u 가 인터랙션 하지 않은 상품 i 의 쌍이다.

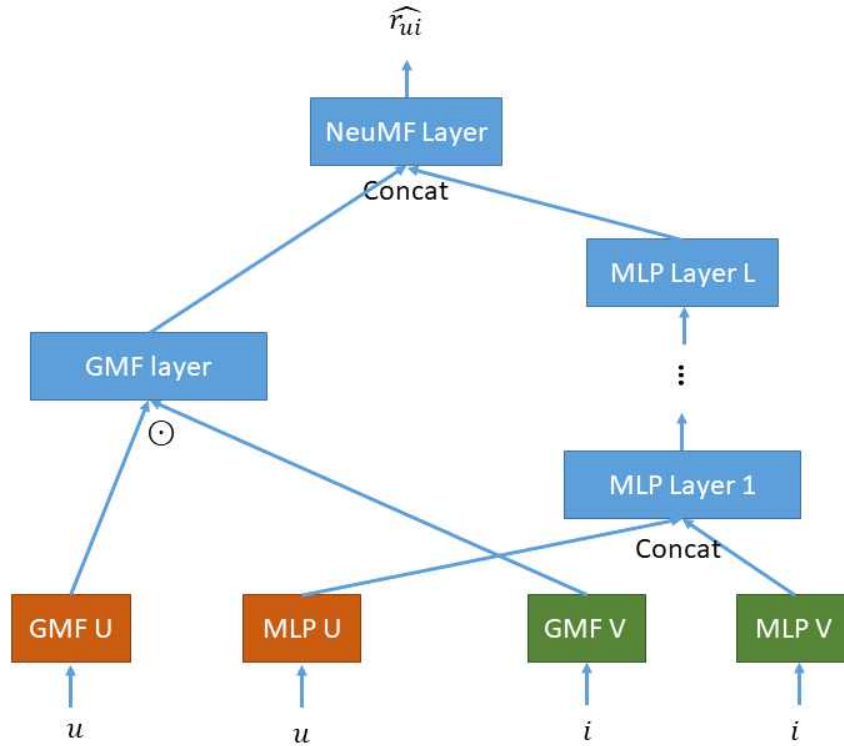


그림 2 NeuMF 구조

신경 협업 필터링은 일반화 행렬 분해와 다층 퍼셉트론 모델을 동시에 사용하는 NeuMF 모델을 제안한다. NeuMF의 구조는 그림 2에 나타난다. 일반화 행렬 분해로는 상품과 사용자 간의 선형적 관계를 학습하고, 다층 퍼셉트론 모델로는 비선형적인 관계를 학습한다. 일반화 행렬 분해와 다층 퍼셉트론 모델은 각각 다른 임베딩 행렬을 갖는다. 일반화 행렬 분해의 출력과 다층 퍼셉트론 모델의 출력을 합쳐서 다시 신경망 한 층을 식 (2-10)과 같이 통과시킨다.

$$\hat{r}_{ui} = \sigma(W^T [\phi^{GMF} \phi^{MLP}]) \quad \text{식 (2-10)}$$

로컬 옵티멈(local optimum)에 빠지지 않도록 NeuMF를 학습시킬 때는 사전 학습(pre-trained)한 GMF와 MLP 모델로 초기화하고, 사전 학

습된 파라미터를 사용하기 위해 출력층을 아래 식 (2-11)과 같이 바꿔준다. W^x 는 각각 MLP와 GMF로 사전학습된 가중치를 말하고, α 는 하이퍼파라미터(hyperparameter)이다. 베이지안 개인화 순위와 같이 경사 하강법을 사용해 학습한다.

$$W \leftarrow \begin{bmatrix} \alpha W^{GMF} \\ (1-\alpha) W^{MLP} \end{bmatrix} \quad \text{식 (2-11)}$$

지금까지 서술한 단일 도메인 추천 모델은 하나의 도메인만을 사용하는 추천 모델로 데이터가 희소해지면 추천 정확도가 떨어진다는 문제점을 가지고 있다. 이런 문제점을 보완하려는 방법으로 모델 학습 시 다른 도메인의 정보를 사용하는 교차 도메인 추천 모델이 등장하였다.




그림 3 SCoNet의 구조

교차 도메인 추천(cross-domain recommendation): 연관된 도메인의 정보(knowledge)를 이용해 사용자에게 상품을 추천하는 것이다. 교차 도메인 추천은 데이터가 적어(sparse) 추천 성능이 떨어지는 단일 도메인 추천의 문제를 효과적으로 완화한다.

SCoNet[4]은 암묵적 피드백 교차 도메인 추천 모델이다. 구조는 그림 3에서 볼 수 있다. SCoNet은 두 도메인에서의 사용자가 같다고 가정한다.

다. 즉, 도메인 D_a 에서 사용자가 어떤 상품과 인터랙션 했다면, 그 사용자는 도메인 D_b 에서도 도메인 D_a 의 상품과 인터랙션 했다.

ScoNet은 신경 협업 필터링[1]을 기반으로 전이학습(transfer learning)을 교차 도메인 추천에 적용하였다. 그림 3과 같이 두 도메인에서 각각 신경 협업 필터링 모델 중 다층 퍼셉트론 모델을 사용한다.

ScoNet은 연관된 도메인의 정보를 사용하기 위해 두 가지 방식을 취한다. 첫 번째는, 사용자 임베딩 행렬을 두 도메인에서 모두 같은 것을 사용한다. 두 번째는, 교차 연결 단위(cross connection unit)를 도입한다. 교차 연결 단위는 식 (2-12)에서 볼 수 있듯이 각 층의 정보를 도메인 D_a 에서 도메인 D_b 로, 도메인 D_b 에서 도메인 D_a 로 전달해 주는 역할을 한다.

$$\begin{aligned} z_a^{\ell+1} &= \sigma(W_a^\ell z_a^\ell + H^\ell z_b^\ell) \quad \text{식 (2-12)} \\ z_b^{\ell+1} &= \sigma(W_b^\ell z_b^\ell + H^\ell z_a^\ell) \end{aligned}$$

교차 연결 단위에 대해 $z_a^{\ell+1}$ 는 두 가지의 정보를 받는다. 하나는 같은 도메인에서 오는 정보인 $W_a^\ell z_a^\ell$ 이고 다른 하나는 다른 도메인에서 오는 $H^\ell z_b^\ell$ 이다. $\sigma(\cdot)$ 는 활성화 함수로 ReLU[7]를 사용한다. 여기서 H 는 전달 행렬(transfer matrix)로 한 도메인에서 다른 도메인으로 정보가 전달되도록 한다. 다른 도메인에서 오는 모든 정보가 유용한 정보가 아닐 수 있으므로 H 가 선택적으로 정보를 전달할 수 있도록 H 를 L1 정규화 해준다.

손실 함수는 도메인 D_a 의 손실 함수와 도메인 D_b 의 손실 함수를 더 해준다. 각 도메인의 손실 함수는 크로스 엔트로피 손실을 사용하였다.

$$L = - \sum_{(u,i) \in R^+ \cup R^-} r_{ui} \log \hat{r}_{ui} + (1 - r_{ui}) \log (1 - \hat{r}_{ui}) + \Omega(H) \quad \text{식 (2-13)}$$

그러나 ScoNet은 사용자의 특성이 도메인에 따라 달라질 수 있다는 점을 고려하지 않고 두 도메인에서 같은 사용자 임베딩 행렬을 쓴다는 단점이 있다.

PPGN[5]은 교차 도메인 추천 모델에 그래프 합성곱 신경망을 적용한 것으로 모델 구조는 그림 4와 같다. 두 도메인 D_a 와 D_b 에서의 사용자들

과 상품들을 노드로 하고, 인터랙션이 존재하는 각각의 사용자와 상품 쌍에 간선으로 연결하여 사용자-상품 인터랙션 그래프를 만든다. 사용자들의 수는 두 도메인에서 공통되게 n 이고, D_a 의 상품 수는 p 이며, D_b 의 상품 수는 q 이다. 이렇게 만들어진 그래프의 인접 행렬(adjacency matrix) A 의 크기는 $\mathbb{R}^{(m_a+n+m_b) \times (m_a+n+m_b)}$ 이고 사용자와 상품 쌍에 인터랙션이 존재할 때 1이고, 그 외는 0이다. 학습의 안정성을 위해 사용자-상품 인터랙션 그래프에 자기 자신으로 가는 셀프 루프(self-loop)를 만들어준다. 이 셀프 루프를 만들기 위해 인접 행렬에 단위 행렬 I 를 더하고 차수 행렬(degree matrix) D 로 정규화(normalization) 해준다.

$$I \in \mathbb{R}^{(m_a+n+m_b) \times (m_a+n+m_b)}, D \in \mathbb{R}^{(m_a+n+m_b) \times (m_a+n+m_b)} \quad \text{식 (2-14)}$$

I 와 D 의 크기는 식 (2-14)와 같고, 인접 행렬 A 에 셀프 루프를 추가하여 만든 인접 행렬 \hat{A} 를 식으로 나타내면 식 (2-15)와 같다.

$$\hat{A} = D^{-1}(A + I) \quad \text{식 (2-15)}$$

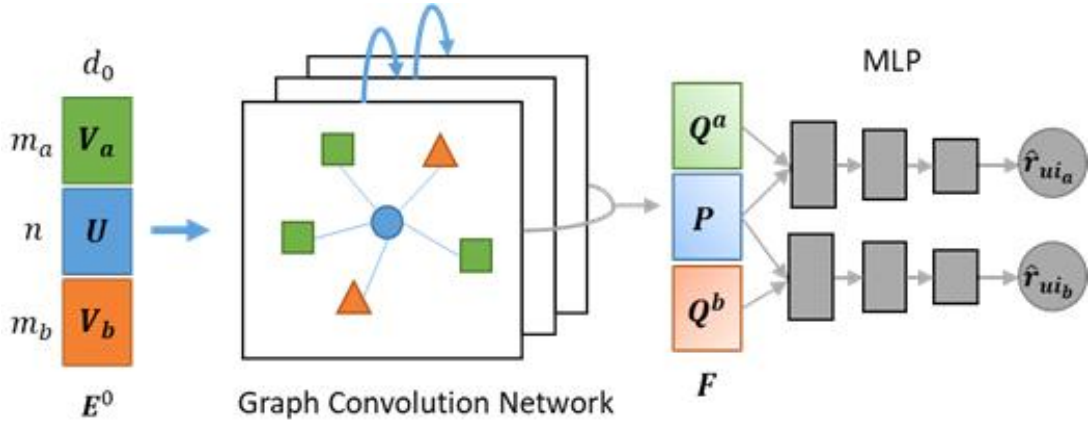


그림 4 PPGN의 구조

그래프에서 상품과 사용자들을 모두 같은 노드로 보므로 각 도메인의 상품 임베딩 행렬 V_a , V_b 와 사용자의 임베딩 행렬 U 를 합쳐(concatenate) 식 (2-16)과 같이 하나의 임베딩 룩업 테이블(embedding loop-up table)을 만든다.

$$E^0 = [V_a, U, V_b]^T \quad \text{식 (2-16)}$$

이제 E^0 와 \hat{A} 를 여러 층의 그래프 합성곱과 전파 층(propagation

layer)들을 통과시킨다. 이때 그래프 합성곱의 커널(kernel)의 크기를 점 점 작게 한다. 커널의 크기를 점차 줄이는 것은 너무 멀리 떨어진 노드의 영향을 줄이기 위해서다. 전과 과정을 식으로 나타내면 식 (2-17)과 같다.

$$E^\ell = \sigma(\hat{A}E^\ell W^\ell + b^\ell) \quad \text{식 (2-17)}$$

위 식에서 $W^\ell \in \mathbb{R}^{d_{\ell-1} \times d_\ell}$ 은 가중치이고 $b^\ell \in \mathbb{R}^{d_\ell}$ 은 바이어스이다. $d_\ell, d_{\ell-1}$ 은 현재 층의 크기와 그 전 층의 크기를 말한다. $\sigma(\cdot)$ 은 활성화 함수로 ReLU[7]를 사용한다.

L 번의 전과가 이뤄지면서 $L+1$ 개의 임베딩 룩업 테이블들 $E^0 \in \mathbb{R}^{(m_a+n+m_b) \times d_0}$ 부터 $E^L \in \mathbb{R}^{(m_a+n+m_b) \times d_L}$ 까지를 얻는다. 이제 이 임베딩 룩업 테이블들을 모두 합쳐 하나의 임베딩 룩업 테이블 F 를 만든다.

$$F \in \mathbb{R}^{(m_a+n+m_b) \times \sum_{i=0}^L d_i} \quad \text{식 (2-18)}$$

F 는 사용자 임베딩 행렬과 각 도메인의 상품 임베딩 행렬로 이루어져 있으므로 이 임베딩 룩업 테이블로부터 식 (2-19)와 같이 사용자 임베딩 행렬 P 와 각 도메인의 상품 임베딩 행렬 Q^a, Q^b 를 얻을 수 있다.

$$F = [E^0, E^1, \dots, E^L] = [Q^a, P, Q^b]^T \quad \text{식 (2-19)}$$

점수 예측을 위한 입력으로 D_a 의 상품 i_a , D_b 의 상품 i_b , 공통된 사용자 u 가 들어간다. 사용자 임베딩 행렬과 상품 임베딩 행렬을 얻은 후 식 (2-20)과 같이 사용자 임베딩 벡터와 상품 임베딩 벡터를 합쳐 여러 층의 전방 전달 층을 통과시킨다. 마지막 층에서 나온 점수가 사용자와 상품의 예측 점수 \hat{r} 이다.

$$\begin{aligned} h_a^0 &= [Q_{i_a}^a, P_u], h_b^0 = [Q_{i_b}^b, P_u] & \text{식 (2-20)} \\ h_a^1 &= \sigma(W_a^1 h_a^0 + b_a^1), h_b^1 = \sigma(W_b^1 h_b^0 + b_b^1) \\ &\dots \\ h_a^{L_{mlp}} &= \sigma(W_a^{L_{mlp}} h_a^{L_{mlp}-1} + b_a^{L_{mlp}}), h_b^{L_{mlp}} = \sigma(W_b^{L_{mlp}} h_b^{L_{mlp}-1} + b_b^{L_{mlp}}) \end{aligned}$$

손실 함수는 SCoNet과 같이 각 도메인에서 크로스 엔트로피 손실 함수를 구하고 두 도메인의 손실 함수를 더해 최종 손실 함수를 구한다.

제 2 절 다중 작업 학습

다중 작업 학습(multi-task learning)이란 여러 학습 작업을 병렬로 학습하면서, 공통된 표현(representation)을 사용하는 것이다. 따라서, 다중 작업 학습은 연관된 작업의 학습으로 얻어진 도메인별(domain-specific) 정보를 사용해서 일반화(generalization) 성능을 향상시킨다[8].

심층 신경망(deep neural network)을 이용한 다중 작업 학습을 수행하려는 방법으로 크게 두 가지가 가장 흔하게 쓰인다.

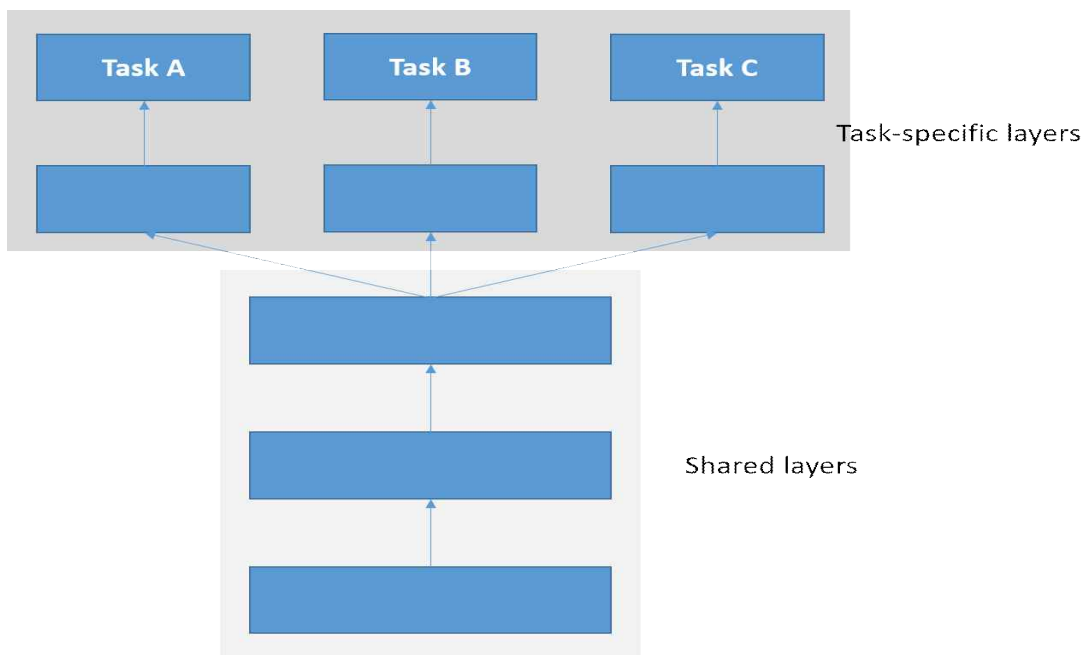


그림 5 하드 변수 공유 구조

하드 변수 공유(hard parameter sharing): 신경망을 이용한 다중 작업 학습에서 가장 많이 쓰는 접근법이다. 하드 변수 공유는 그림 5와 같이 작업별(task-specific) 출력층(output layer)을 유지하면서 모든 작업에서 은닉층들을 공유한다.

공통된 은닉층들로 여러 작업을 학습해야 하므로 하드 변수 공유는 과적합(overfitting)의 위험을 줄여준다.

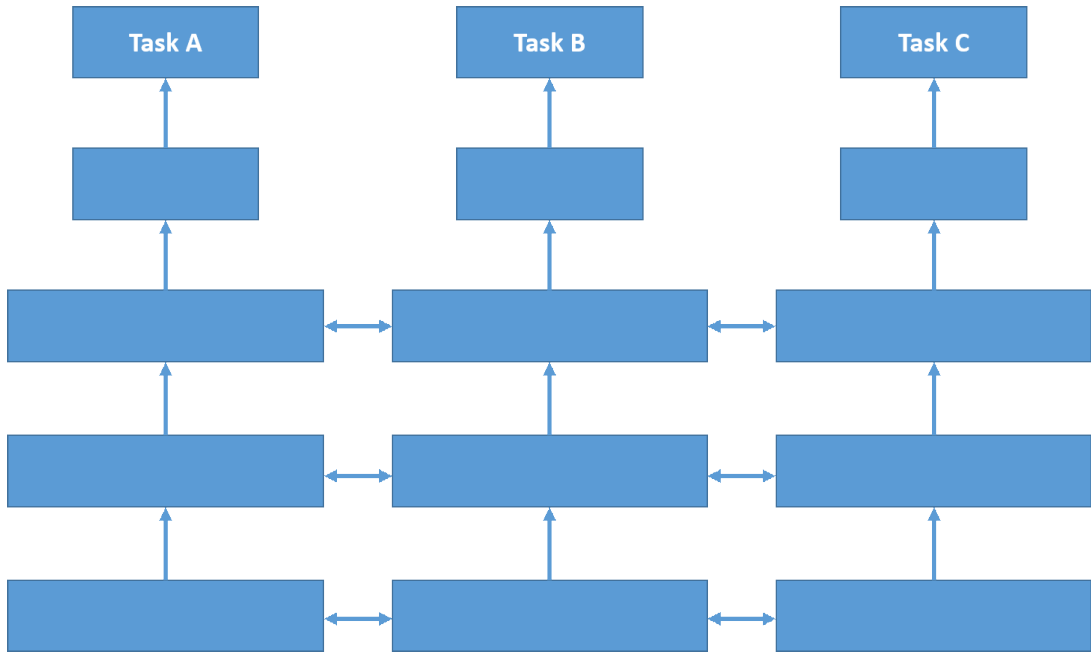


그림 6 소프트 변수 공유 구조

소프트 변수 공유(soft parameter sharing): 그림 6과 같이 각 작업이 각각의 변수를 갖는 개별적인 모델을 갖는다. 각 작업 변수가 서로 비슷해지도록 변수들의 차이를 L2 정규화와 같은 방식으로 정규화한다.

본 논문에서는 다중 학습 작업에서 하드 변수 공유의 작업별 개별 변수와 작업 간 공유하는 변수를 사용해 학습하는 방식을 참고하여 교차 도메인 추천 모델에 적용한다[9].

제 3 절 전이 학습

전이 학습은 기계 학습(machine learning)의 한 방법으로 필요한 학습 데이터를 수집하고 모델을 재구성하는 노력을 줄이면서 더 빠르고 더 나은 모델을 제공한다. 문서, 음성 및 이미지 분류 영역에서의 큰 진전은 다른 도메인의 데이터, 정보를 사용, 학습함으로써 분류 성능을 향상시키는 전이 학습의 효능을 입증했다.

전이 학습의 정의에 대해 자세히 설명한다. 도메인 D_a 가 주어지고 D_b

에서 학습해야 하는 작업을 T_a 라고 하자. 그리고 도메인 D_b 에서 학습해야 하는 작업은 T_b 이다. 전이 학습은 도메인 D_a 의 작업 T_a 의 성능을 높이기 위해 도메인 D_b 의 정보와 T_b 의 정보를 사용하는 것이다. 이때, $D_a \neq D_b$ 와 $T_a \neq T_b$ 의 조건을 만족하여야 한다[10].

본 논문에서는 전이 학습을 활용하여서 한 도메인의 성능을 다른 도메인의 정보를 활용해 성능 향상 시킨다.

제 4 절 그래프 신경망 네트워크

그래프 신경망 네트워크(graph neural network)는 그래프 형태의 데이터를 학습하기 위해 신경망 네트워크를 적용한 것이다. 그중 그래프에 합성곱 신경망을 사용한 것이 그래프 합성곱 신경망이다. 그러나 그래프 합성곱 신경망은 모든 간선의 중요도를 동일하게 본다는 단점이 있다. 따라서 이 단점을 보완하고자 그래프 어텐션 네트워크가 제안되었다.




그림 7 그래프 합성곱 신경망의 구조

그래프 합성곱 신경망[11]: 그래프 형태의 데이터들의 분류(classification)를 위해 합성곱 신경망을 그래프에 적용한 것이 그래프

합성곱 신경망이다. 그래프 합성곱 신경망 구조를 나타내면 그림 7과 같다.

그래프 합성곱 신경망은 그림 7과 같이 그래프 구조와 초기화된 노드들의 은닉 벡터가 여러 은닉층으로 들어가 학습된 노드들의 최종 은닉 벡터를 얻을 수 있게 한다. 그림 7에서 입력층과 출력층에 여러 겹으로 층이 쌓여 있는 것은 다중 채널(multi-channel)을 말한다. 즉, 노드의 은닉 벡터의 크기를 말한다.

한 층의 그래프 합성곱 신경망을 식으로 나타내면 다음 식 (2-21)과 같다.

$$H^{\ell+1} = (\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}}) H^{\ell} \Theta^{\ell} \quad \text{식 (2-21)}$$

H^{ℓ} , $H^{\ell+1}$ 은 노드들의 ℓ 과 $\ell+1$ 번째 은닉 벡터들을 행렬로 나타낸 것이고, \tilde{A} 는 그래프의 인접 행렬 A 에 단위 행렬 I 를 더한 것이다. 즉, \tilde{A} 는 기존 그래프에 셀프 루프를 추가한 그래프의 인접 행렬이다. \tilde{D} 는 \tilde{A} 의 차수 행렬이다. Θ^{ℓ} 은 ℓ 번째 신경망 파라미터(parameter)를 말한다.

그래프 합성곱 신경망을 하나의 노드 관점에서 더 자세히 보면, 다음 식 (2-22)와 같다.

$$h_i^{\ell+1} = \sigma(\Theta \sum_{v_j \in \mathcal{N}(v_i) \cup v_i} h_j^{\ell}) \quad \text{식 (2-22)}$$

노드 v_1 을 기준으로 그래프 합성곱 신경망을 설명한다. 그림 8에서 노드 v_1 의 $\ell+1$ 번째 은닉 벡터를 구하고자 한다. 노드 v_1 의 $\ell+1$ 번째 은닉 벡터를 구하기 위해 노드 v_1 과 인접한 노드들 v_3, v_5, v_8 과 자기 자신만이 사용된다. 이 노드들의 은닉 벡터를 더하고 파라미터들을 곱하면 위 식과 같이 노드 v_1 의 ℓ 번째 은닉 벡터를 구할 수 있다.

그래프 합성곱 신경망은 그래프의 구조를 고려하면서 각 노드들의 은닉 벡터를 학습할 수 있지만, 인접한 노드 간의 중요도 즉 간선의 중요도를 모두 동일하게 보아 분류 성능이 떨어진다는 단점이 있다. 이 단점을 보완하기 위해 어텐션 메커니즘(attention mechanism)을 도입한 그래프 어텐션 네트워크가 등장하였다.




그림 8 하나의 노드에 대한 그래프 합성곱 신경망

그래프 어텐션 네트워크[12]: 그래프 합성곱 신경망을 보완하기 위해 등장한 것이 그래프 어텐션 네트워크이다. 2.4.1의 그래프 합성곱 신경망 처럼 하나의 노드에 대해 나타내면 식 (2-23)과 같다. 식 (2-22)와 비슷하지만, 인접한 간선들에 중요도가 명시적으로 주어진다.

$$h_i^{\ell+1} = \sigma(\Theta \sum_{v_j \in \mathcal{N}(v_i) \cup v_i} \alpha_{ij} h_j^{\ell}) \quad \text{식 (2-23)}$$

$$\alpha_{ij} = \frac{\exp(\text{LeakyReLU}(a^T [\Theta h_i^{\ell} \parallel \Theta h_j^{\ell}]))}{\sum_{v_k \in \mathcal{N}(v_i)} \exp(\text{LeakyReLU}(a^T [\Theta h_i^{\ell} \parallel \Theta h_k^{\ell}]))} \quad \text{식 (2-24)}$$

인접한 간선들의 중요도를 구하면 식 (2-24)와 같다. 여기서 a 는 중요도를 계산해주는 한 층의 신경망이다. 그림 9를 보면 그래프 합성곱 신경망인 그림 8과 달리 간선의 중요도인 a 가 추가된 것을 찾을 수 있다.

식 (2-23)과 식 (2-24)를 그림으로 나타내면 그림 10과 같다. 자기 자신과 인접한 노드의 은닉 벡터가 합쳐져 a 로 들어가서 나온 값에 소프트맥스(softmax)를 취하면 간선들의 중요도를 구할 수 있다.

간선들의 중요도가 계산에 반영되어 그래프 어텐션 네트워크는 분류의 정확도를 그래프 합성곱 신경망보다 향상하게 시켰다. 따라서 본 논문에서는 교차 도메인 추천 모델에 그래프 어텐션을 적용한다.




그림 9 GAT 구조

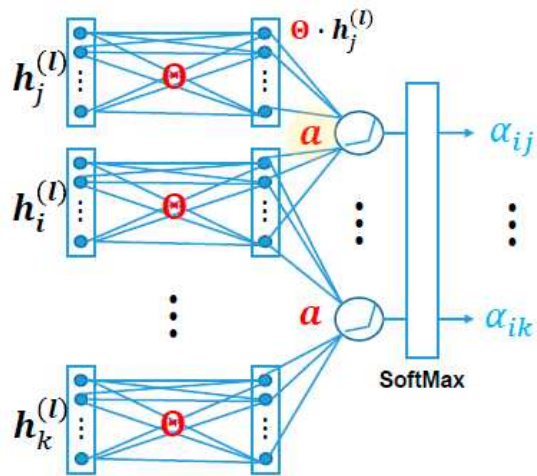


그림 10 GAT 전체 구조

제 3 장 제안하는 모델

본 논문에서는 교차 도메인 추천 모델 SCoNet[4]을 기반으로 하는 두 가지 모델을 제안한다. SCoNet은 사용자의 특성이 도메인에 따라 달라질 수 있다는 점을 고려하지 않고 두 도메인에서 동일한 사용자 임베딩 행렬을 사용해 추천 정확도가 떨어진다는 단점이 있다. 이에 본 논문에서는 제안하는 첫 번째 모델 SCoNet+[13]는 도메인의 특성을 고려한 사용자 임베딩과 두 도메인에서 동일한 사용자 임베딩 행렬을 모두 사용하여 사용자의 도메인 특성을 고려하여 추천 성능을 향상시켰다. 두 번째로 제안한 모델은, 임베딩 행렬 학습 시 그래프 어텐션 네트워크를 사용하여 PPGN[5]이 사용자와 상품간의 중요도를 모두 동일하게 보는 점을 보완하여 사용자와 상품 간의 좀 더 복잡한 관계를 고려하였다.

제 1 절 문제 정의

두 도메인 a 와 b 가 있고, 두 도메인에서 사용자들의 집합은 \mathcal{U} 로 동일하며 크기는 n 이다. 두 도메인 D_a 와 D_b 상품들의 전체 개수를 각각 m_a , m_b 라 한다. 두 도메인의 암묵적 피드백에 대한 정보로 이진 행렬 $R_a \in \mathbb{R}^{n \times m_a}$, $R_b \in \mathbb{R}^{n \times m_b}$ 가 주어지는데, 인터랙션이 있는 사용자, 상품 쌍에 해당하는 원소들은 1, 나머지는 0이다. 여기서 인터랙션이란 사용자가 상품을 조회하거나 클릭한 것을 말한다. 본 논문의 목표는 각 도메인에서 사용자의 선호도가 높은 top-K개의 상품을 사용자에게 추천하는 것이다.

제 2 절 도메인을 특성을 고려한 교차 도메인 추천

본 논문에서는 SCoNet[4]을 기반으로 두 도메인 간의 일반적 경향만을 반영하는 SCoNet을 보완하기 위해 두 도메인 간의 일반적 경향을 반영하면서도 도메인에 따라 달라질 수 있는 사용자의 특성을 반영하기 위해 그림 11과 같이 모델을 설계하였다.




그림 11 SCoNet+ 구조

임베딩 층(embedding layer): SCoNet과 같이 두 도메인에서 공통된 사용자 임베딩 행렬을 사용하면 두 도메인에서 공통된 사용자의 선호도의 경향을 잘 반영할 수 있다. 그러나 일반적 경향에서 벗어나 특정 도메인에 대한 특징적인 사용자들에 대해서는 추천 성능이 떨어지게 된다. 따라서 두 도메인 간의 일반적 경향을 반영하면서도 도메인에 따라 달라

질 수 있는 사용자의 특성을 반영하기 위해 SCoNet과 같이 두 도메인에서 공통된 사용자 임베딩 U_{share} 와 각 도메인의 특성을 반영하는 사용자 임베딩 행렬 U_a, U_b 을 합쳐 사용자 임베딩 행렬로 사용한다. 즉 D_a 의 사용자 임베딩은 $[U_{share}, U_a]$ 와 같다.

점수 예측: SCoNet과 동일하다[4]. D_a 를 기준으로 설명하면, 첫 번째 은닉층 입력으로 사용자 임베딩 벡터와 상품 임베딩 벡터가 합쳐 들어간다. 첫 번째 입력은 $[U_{share}, U_a, V_a]$ 와 같다. 그런 후 교차 연결 단위들을 통과하게 된다. 교차 연결 단위는 식 (3-1)과 (3-2)에서 볼 수 있듯이 다른 도메인과 정보 교환을 가능하게 한다. D_a 의 g_a^ℓ 는 $g_a^{\ell-1}$ 이 $\ell-1$ 번째 은닉층을 통과한 것과 D_b 의 $\ell-1$ 번째 은닉층의 출력에 전달 행렬 H 를 곱한 것을 더하고 활성화 함수를 취한 것이다.

$$g_a^\ell = \sigma(W_a^{\ell-1}g_a^{\ell-1} + H^{\ell-1}g_b^{\ell-1}) \quad \text{식 (3-1)}$$

$$g_b^\ell = \sigma(W_b^{\ell-1}g_b^{\ell-1} + H^{\ell-1}g_a^{\ell-1}) \quad \text{식 (3-2)}$$

교차 연결 단위는 H 를 통해 도메인 간의 오고 가는 정보를 조절한다. 다른 도메인에서 H 를 통해 정보를 전달받으므로 도메인의 데이터가 희소할 때에도 여전히 좋은 표현을 학습할 수 있다. 또한, 다른 도메인에서 전달된 모든 표현(representation)이 유용한 것은 아니므로, H 가 선택적으로 전달하게 하려고 H 를 정규화한다.

상품과 사용자가 얼마나 관련됐는지 나타내는 점수의 예측을 위해 마지막 은닉층에서 나온 출력을 sigmoid 함수를 취해 점수 \hat{r} 을 예측한다.

각 도메인 $x \in \{a, b\}$ 의 손실 함수로 식 (3-3)과 같은 크로스 엔트로피 손실을 사용하였고, 식 (3-4)와 같이 최종 손실 함수로 각 도메인의 손실 함수를 더했다.

$$L_x = - \sum_{(i,j,r_{ij}) \in T^x} r_{ij} \log \hat{r}_{ij}^x + (1-r_{ij}) \log (1-\hat{r}_{ij}^x) \quad \text{식 (3-3)}$$

$$L = L_a + L_b \quad \text{식 (3-4)}$$

여기서 T 는 긍정적 샘플들과 부정적 샘플들이 포함된 집합을 의미하고, r_{ij} 는 각 도메인에 대한 정답 레이블(label)을 의미한다.

제 3 절 그래프 어텐션 네트워크를 이용한 교차 도메인 추천

그래프 어텐션 네트워크를 이용한 교차 도메인 추천 CDRGAT(Cross-Domain Recommendation using Graph Attention Networks)는 PPGN[5]과 SCoNet[4]을 기반으로 하며, 인접한 노드들의 중요도를 모두 동일하게 보는 PPGN의 그래프 합성곱 신경망을 보완하기 위해 그래프 어텐션 네트워크를 적용하였다. 모델 구조는 그림 12와 같다.

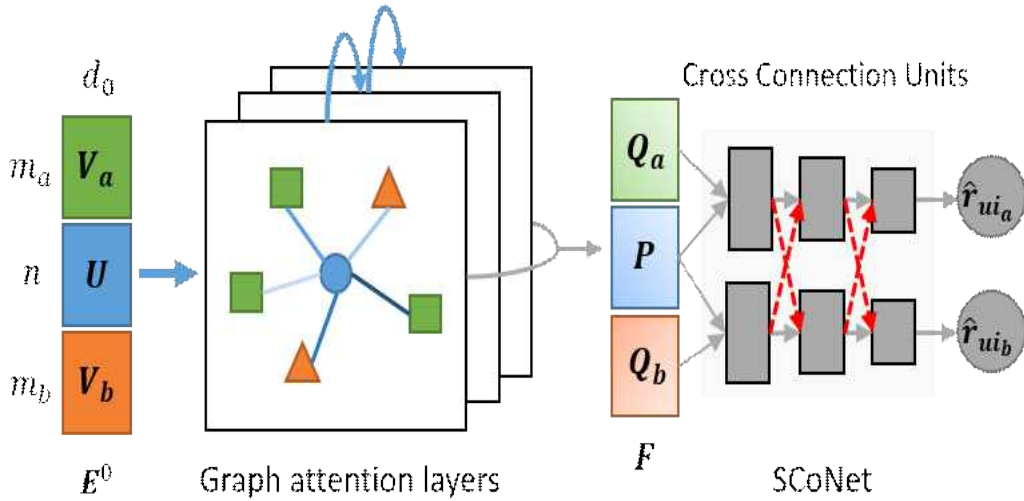


그림 12 CDRGAT 구조

임베딩 층: 임베딩 행렬의 구성은 PPGN[5]과 동일하다. 사용자 임베딩 행렬 $U \in \mathbb{R}^{n \times d_0}$ 는 두 도메인에서 공유한다. 각 도메인 a 와 b 의 상품 임베딩 행렬은 각각 $V_a \in \mathbb{R}^{m_a \times d_0}$ 와 $V_b \in \mathbb{R}^{m_b \times d_0}$ 이다. d_0 는 초기 임베딩 크기를 말한다. 3.3.1에서 서술할 임베딩 전파층에서 사용자와 상품은 모두 동일하게 그래프의 노드로 간주하므로, 앞서 언급한 임베딩 벡터들을 결합(concatenate)하여 하나의 임베딩 룩업 테이블(embedding look-up table) E^0 을 만든다. E^0 의 크기와 행렬식을 식 (3-5)에 나타냈다.

$$E^0 = [V_a, U, V_b]^T \in \mathbb{R}^{(m_a + n + m_b) \times d_0} \quad \text{식 (3-5)}$$

임베딩 전파 층(embedding propagation layer): 임베딩 록업 테이블을 학습하기 위해 여러 층의 그래프 어텐션 층(graph attention layer)에 통과시킨다. 우선 각 도메인의 암묵적 피드백에 대한 정보가 담긴 이진 행렬 R_a 와 R_b 로부터 그래프를 만든다. 사용자와 각 도메인의 상품이 노드가 되고, 인터랙션이 있을 때 간선이 추가 된다. 만들어진 그래프의 인접 행렬은 아래와 같다.

$$A = \begin{bmatrix} 0 & R_a & 0 \\ R_a^T & 0 & R_b \\ 0 & R_b^T & 0 \end{bmatrix} \in \mathbb{R}^{(m_a+n+m_b) \times (m_a+n+m_b)} \quad \text{식 (3-6)}$$

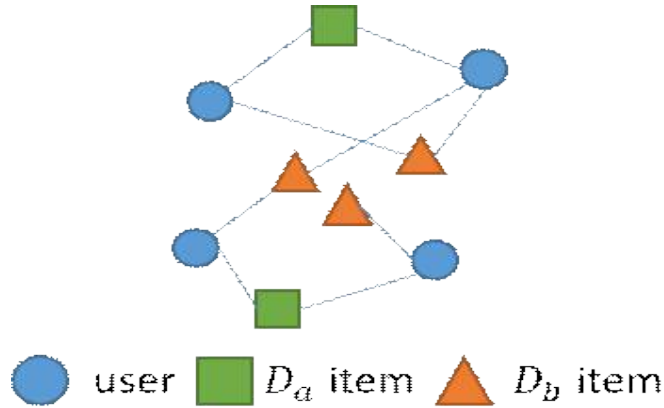


그림 13 그래프 구조

L 개의 그래프 어텐션 층이 사용되는데 그래프 어텐션 층의 구조에 관해 설명한다. 각 노드 i 의 인접한 노드들의 집합을 \mathcal{N}_i 라 한다. 노드 i 에 대한 인접한 노드 $j \in \mathcal{N}_i$ 의 중요도인 어텐션 계수(attention coefficients) c_{ij} 를 구하기 위해 아래와 같이 노드 i 에서 셀프 어텐션(self-attention)을 수행한다.

$$c_{ij}^\ell = f^\ell(E_i^{\ell-1} W^\ell, E_j^{\ell-1} W^\ell) \quad \text{식 (3-7)}$$

위 식에서 W 는 특징(feature)을 배우기 위한 가중치이고, f 는 어텐션 계수를 계산해주는 한 층의 전방 전달 층이다. $d_\ell, d_{\ell-1}$ 은 $\ell, \ell-1$ 층의 은닉 벡터의 크기를 뜻한다. 최종적인 어텐션 가중치는 다음 식 (3-8)과 같이 어텐션 계수들에 소프트맥스를 취해 얻어진다.

$$\alpha_{ij}^\ell = \text{softmax}_j(c_{ij}^\ell) = \frac{\exp(c_{ij}^\ell)}{\sum_{k \in \mathcal{N}_i} \exp(c_{ik}^\ell)} \quad \text{식 (3-8)}$$

$$E_i^\ell = \sigma\left(\sum_{j \in \mathcal{N}_i} \alpha_{ij}^\ell E_j^{\ell-1} W^\ell\right) \quad \text{식 (3-9)}$$

ℓ 층의 그래프 어텐션 층을 통과한 노드 i 의 임베딩 벡터를 구하면, 식 (3-9)와 같다.

여기서 $\sigma(\cdot)$ 는 비선형성을 위해 사용된 활성화 함수이며 본 논문에서는 leakyReLU[14]를 사용하였다.

L 개의 그래프 어텐션 층을 통과해서 얻은 총 $L+1$ 개의 임베딩 록업 테이블 $E^0 \in \mathbb{R}^{(m_a+n+m_b) \times d_0}, \dots, E^L \in \mathbb{R}^{(m_a+n+m_b) \times d_L}$ 을 모두 결합하여 아래 식 (3-10)과 같이 하나의 임베딩 록업 테이블 F 를 만든다. 여기서 F 는 두 도메인의 최종 상품 임베딩 행렬 Q_a, Q_b 와 최종 사용자 임베딩 행렬 P 로 구성되어 있다.

$$F = [E^0, \dots, E^L] = [Q_a, P, Q_b]^T \quad \text{식 (3-10)}$$

점수 예측은 3.2.2와 같이 임베딩 행렬로부터 임베딩 벡터를 구해 SCoNet을 사용한다.

제 4 장 실험

제 1 절 실험 데이터와 비교모델

실험 데이터로는 J. McAuley가 공개한 아마존(Amazon) 리뷰 데이터셋[15]을 사용하였다. 아마존 리뷰 데이터는 1-5점으로 이루어져 있어, 암묵적 피드백이라는 가정에 맞추기 위해 모든 평점을 1로 보았다. CDs and Vinyl, Digital Music과 Movies and TV, Kindle Store 두 쌍의 데이터를 사용하였다. 아래 표 1에 데이터셋 통계가 요약되어 있다.

데이터셋	사용자 수	상품 수	평점 수	밀도 (%)
CDs and Vinyl	5331	55848	376347	0.126
Digital Music		3563	63303	0.333
Movies and TV	2754	23610	68779	0.106
Kindle Store		26760	50098	0.068

표 1 데이터셋 통계

S-CoNet은 신경 협업 필터링을 기반으로 전이학습을 교차 도메인 추천에 적용한 모델이다. PPGN은 그래프 합성곱 신경망을 적용하여 임베딩 행렬을 학습해 추천에 사용한 교차 도메인 추천 모델이다.

제 2 절 성능 평가 지표 및 실험 설정

성능 평가 지표: 상품 추천에서 일반적으로 사용되는 leave-one-out

(LOO) 평가방법[1]을 사용하였다. 각 사용자에게 대해 하나의 인터랙션과 99개의 부정적 샘플들 중 하나의 인터랙션 순위를 잘 매기는지 평가한다. top-K 상품 추천을 목표로 하므로, 이에 대한 성능 평가 지표인 hit ratio (HR), normalized discounted cumulative gain (NDCG)와 mean reciprocal rank (MRR)을 사용하였다[4]. 그에 대한 식은 아래 식 (4-1)과 같다.

$$\begin{aligned}
 HR &= \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \delta(p_u \leq K) && \text{식 (4-1)} \\
 NDCG &= \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \frac{\log 2}{\log(p_u + 1)} \\
 MRR &= \frac{1}{|\mathcal{U}|} \sum_{u \in \mathcal{U}} \frac{1}{p_u}
 \end{aligned}$$

p_u 는 사용자의 인터랙션에 대한 추천 순위이고, $\delta(\cdot)$ 는 지시 함수(indicator function)이다. 순위 리스트를 자르는 기준을 $K=10$ 으로 하였다.

실험 설정: SCoNet+를 제외한 모든 모델의 다층 퍼셉트론은 [64, 32, 16, 8]로 하였다. SCoNet+의 다층 퍼셉트론은 [128, 64, 32, 16]으로 하였다. SCoNet+의 실험 설정에 대해 먼저 서술한다. 각 신경 네트워크의 파라미터들은 가우시안 분포 $N(0, 0.02^2)$ 로 랜덤하게 초기화하였다. 미니 배치(mini batch) 크기는 256이며, 상품 임베딩 크기는 128로, 사용자 임베딩 중 사전 학습된 임베딩과 사전 학습되지 않은 임베딩 모두 각각 64로 하였다. CDRGAT의 실험 설정에 대해 서술한다. 초기 임베딩 행렬 크기는 64이고, Xavier[16]로 초기화하였다. 그래프 어텐션 네트워크는 PPGN과 동일하게 [32, 32, 16, 16, 8]로 하였다. 다층 퍼셉트론의 첫 번째 층 출력은 배치 정규화(batch normalization)을 하였다. 드롭아웃(dropout)은 모든 층에서 0.3으로 하였다. 정규화(regularization)로 L2 정규화를 사용하였고, 계수는 10^{-4} 이다. 미니 배치 크기는 1024이다. SCoNet과 PPGN은 저자 코드를 사용하였다[17, 18].

제 3 절 실험 결과 및 분석

여기서는 실험한 결과와 그에 대한 분석에 대해 서술한다.

도메인을 특성을 고려한 교차 추천 모델의 사용자 임베딩 분석: 3.2에서 제안한 도메인 특성을 고려한 교차 도메인 추천 모델의 사용자 임베딩을 세 가지로 나눠서 추천 정확도 비교하였다. 먼저 사용자 임베딩의 도메인 특성이 있는 U_a 와 U_b 를 사전학습 시키고 전체 모델을 학습 시 고정(freeze)한 사용자 임베딩을 실험하였다. 첫 번째 방법을 SCoNet+(freeze)라고 하자. 두 번째 방법은 SCoNet+(learn)이라고 하고 U_a 와 U_b 를 사전학습 시키고 전체 모델을 학습 시 U_a 와 U_b 도 학습하도록 한다. 세 번째는 SCoNet+(without pretrain)이라고 하고 U_a 와 U_b 를 U_{share} 처럼 사전학습 하지 않고 전체 모델을 학습시킬 때 같이 학습한다.

평가방식	데이터셋	SCoNet	SCoNet+(freeze)	SCoNet+(learn)	SCoNet+(without pretrain)
HR	CDs and Vinyl	0.7130	0.7338	0.7278	0.7279
	Digital Music	0.9582	0.9678	0.9651	0.9662
	Movies and TV	0.3488	0.5267	0.5310	0.5298
	Kindle Store	0.4092	0.4211	0.4356	0.4395
MRR	CDs and Vinyl	0.4565	0.4656	0.4615	0.4586
	Digital Music	0.5968	0.6812	0.7250	0.7296
	Movies and TV	0.2287	0.3062	0.3107	0.3082
	Kindle Store	0.2611	0.2668	0.2803	0.2810
NDCG	CDs and Vinyl	0.4975	0.5105	0.5063	0.5032
	Digital Music	0.6822	0.7505	0.7822	0.7858
	Movies and TV	0.2110	0.3240	0.3301	0.3274
	Kindle Store	0.2535	0.2628	0.2744	0.2793

표 2 사용자 특성을 고려한 사용자 임베딩과 SCoNet 비교

실험 결과 표 2를 확인하면 3가지 모두 SCoNet보다 성능이 좋은 것을 확인 할 수 있다. 따라서 도메인 특성을 고려한 사용자 임베딩이 두

도메인에서 공통된 사용자 임베딩을 사용하는 것보다 추천 정확도가 높다고 할 수 있다. 세 가지 사용자 임베딩에 대해서는 HR, MRR, NDCG에 대해 모두 우위를 갖는 것이 없다고 보아 도메인 특성을 고려하기만 한다면 추천 정확도에서는 큰 차이가 없는 것으로 보인다. 따라서, 두 쌍의 데이터셋에서 HR, MRR, NDCG 중 가장 좋은 성능을 보이는 것이 많은 SCoNet+(without pretrain)을 SCoNet+라고 한다.

실험 결과: 기존 교차 도메인 추천 연구인 SCoNet, PPGN과 제안 모델인 SCoNet+, CDRGAT의 실험결과를 표 3에 나타내었다. 각각 3번 씩 실험 후 HR, MRR, NDCG의 평균을 내었다.

평가방식	데이터셋	SCoNet	SCoNet+	PPGN	CDRGAT
HR	CDs and Vinyl	0.7130	0.7279	<u>0.7542</u>	0.8446
	Digital Music	0.9582	<u>0.9662</u>	0.9291	0.9763
	Movies and TV	0.3488	0.5298	<u>0.5347</u>	0.6162
	Kindle Store	0.4092	0.4395	<u>0.4406</u>	0.5597
MRR	CDs and Vinyl	0.4565	<u>0.4586</u>	0.4451	0.5779
	Digital Music	0.5968	<u>0.7296</u>	0.4834	0.7479
	Movies and TV	0.2287	<u>0.3082</u>	0.2323	0.3751
	Kindle Store	0.2611	<u>0.2810</u>	0.2377	0.3558
NDCG	CDs and Vinyl	0.4975	0.5032	<u>0.5186</u>	0.6411
	Digital Music	0.6822	<u>0.7858</u>	0.5894	0.8036
	Movies and TV	0.2110	<u>0.3274</u>	0.3024	0.4302
	Kindle Store	0.2535	0.2793	<u>0.2855</u>	0.4034

표 3 실험결과

밑줄 친 값은 SCoNet, SCoNet+와 PPGN 중 HR, MRR, NDCG가 가장 높은 것을 가리킨다. SCoNet+가 기존 연구인 SCoNet에 비해 HR, MRR, NDCG 모두 향상시킨 것을 확인할 수 있다. PPGN과 SCoNet+를 비교 시 SCoNet+가 조금 더 우세한 것을 확인할 수 있다. PPGN은 임베딩 행렬 학습 시에만 다른 도메인과 정보 교환을 하고 점수 예측 시에는 정보 교환을 하지 않아 SCoNet+가 조금 더 좋은 결과를 내는 것으로 보인다. CDRGAT가 모든 비교 모델 중 가장 좋은 추천 정확도를 보

였다. CDRGAT는 임베딩 행렬 학습 시와 점수 예측 시 모두 다른 도메인과 정보를 교환하고, 사용자와 상품 간의 중요도를 고려해 가장 좋은 성능을 내는 것으로 보인다. 또한, 밀도가 낮은 Movies and TV와 Kindle Store 쌍의 데이터셋에 대해 추천 정확도 향상이 더 높은 것으로 보아 낮은 밀도에서도 좋은 추천 정확도를 낸다는 것을 확인할 수 있다.

제 5 장 결론

본 논문에서는 두 가지 교차 도메인 추천 모델을 제안하였다. 도메인 특성을 고려한 사용자 임베딩을 기반으로 한 교차 도메인 추천 SCoNet+가 두 도메인에서 같은 사용자 임베딩을 쓴 SCoNet보다 향상됨을 아마존 리뷰 데이터로 확인하였다.

또한, 두 번째 모델로 그래프 어텐션 네트워크로 임베딩 행렬을 학습하고 점수 예측 때 SCoNet을 사용한 교차 도메인 추천 모델 CDRGAT를 제안하였다. 상품과 사용자들을 노드로 하는 그래프 구조를 만들고, 상품과 사용자들 간의 중요도를 다르게 보도록 어텐션 매커니즘을 적용하였다. CDRGAT는 임베딩 행렬 학습 때와 점수 예측 때 모두 연관된 도메인의 정보를 교환한다. 이 CDRGAT가 SCoNet, SCoNet+, PPGN 중 추천 정확도가 가장 높다는 것을 아마존 리뷰 데이터로 확인하였다. 본 논문에서 제안한 기법은 아마존, 쿠팡 등 여러 도메인을 다루는 많은 온라인 서비스들의 추천 성능을 향상시킬 수 있을 것으로 생각된다.

참 고 문 헌

- [1] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, T. Chua, "Neural Collaborative Filtering", Proc. of the 26th WWW, pp. 173-182, 2017.
- [2] X. Wang, X. He, M. Wang, F. Feng, T. Chua, "Neural Graph Collaborative Filtering", Proc. of the 42nd SIGIR, pp. 165-174, 2019.
- [3] S. Rendle, C. Freudenthaler, Z. Gantner, L. Schmidt-Thieme, "BPR: Bayesian Personalized Ranking from Implicit Feedback", Proc. of the 25th UAI, pp. 452-261. 2012
- [4] G. Hu, Y. Zhang, Q. Yang, "CoNet: Collaborative Cross Networks for Cross-Domain Recommendation", Proc. of the 27th CIKM, pp. 667-676, 2018.
- [5] Cheng Zhao, Chenliang Li, Cong Fu, "Cross-domain recommendation via preference propagation graphnet", Proc. of the 28th CIKM, pp. 2165-2168, 2019.
- [6] Y. Hu, Y. Koren, C. Volinsky, "Collaborative Filtering for Implicit Feedback Datasets", Proc. of the 8th ICDM, pp. 263-272, 2008.
- [7] R. Hahnloser, R. Sarpeshkar, M. A. Mahowald, R. J. Douglas, H. S. Seung, "Digital selection and analogue amplification coexist in a cortex-inspired silicon circuit", Nature, pp. 947 - 951, 2000.
- [8] R. Caruana, "Multitask Learning", Machine Learning, pp. 41-75, 1997.
- [9] S. Ruder, "An Overview of Multi-Task Learning in Deep Neural Networks", arXiv:706.05098, 2017.
- [10] Y. Lin, T. Jung, "Improving EEG-based emotion classification using conditional transfer learning", Frontiers in Human Neuroscience, 2017.
- [11] T. Kipf, M. Welling, "Semi-Supervised Classification with Graph Convolutional Networks", Proc. of the 5th ICLR, 2016.

- [12] Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Liò, Yoshua Bengio, “Graph attention networks”, Proc. of the 6th ICLR, 2018.
- [13] 김영빈, 홍대영, 심규석, “도메인 특성을 고려한 사용자 임베딩 기반 교차 도메인 추천”, 한국정보과학회 학술발표논문집, pp. 78-80, 2019.
- [14] A. Maas, A. Hannum, A. Ng, “Rectifier Nonlinearities Improve Neural Network Acoustic Models”, Proc. of the 30th ICML, 2013
- [15] R. He, J. McAuley, “VBPR: visual Bayesian Personalized Ranking from implicit feedback”, Proc. of the 13th AAAI, pp. 133-150, 2016.
- [16] X. Glorot, Y. Bengio, “Understanding the difficulty of training deep feedforward neural networks”, Proc. of the 13th MLR, pp. 249-256, 2010.
- [17] <http://home.cse.ust.hk/~ghuac/>
- [18] <https://github.com/WHUIR/PPGN>

Abstract

Cross-Domain Recommendation by Using Domain Specific User Embedding and Graph Attention Network

Youngbin Kim

Electrical and Computer Engineering

The Graduate School

Seoul National University

The recommendation system is a big part of our lives today. Among the recommendation systems, cross-domain recommendation mitigates the problem of a single domain recommendation model that has poor performance for sparse data by receiving information from associated domains. One of the cross-domain model using transfer learning does not take into account that the characteristics of users may vary depending on the domain by using the same user embedding matrix

in both domains. Thus, we proposed the first model improves the recommendation performance by considering user's domain specific characteristic. Another cross-domain recommendation uses a graph that consists of users and products, and improves performance by considering complex relationships between users and products using graph convolution networks. This model has a problem that importance between all products and users is the same. Therefore, in this paper, a second model was proposed to apply the attention mechanism to consider the importance between the product and the user. In addition, it was confirmed that the recommendation accuracy of the model was improved by conducting experiments with real-life data.

keywords : recommedation system, transfer learning, graph attention network

Student Number : 2018-25877