

# 유사 아이템 정보를 이용한 콜드 아이템 추천성능 개선

한정규<sup>†</sup>, 천세진<sup>\*\*</sup>

## Addressing the Item Cold-Start in Recommendation Using Similar Warm Items

Jungkyu Han<sup>†</sup>, Sejin Chun<sup>\*\*</sup>

### ABSTRACT

Item cold start is a well studied problem in the research field of recommender systems. Still, many existing collaborative filters cannot recommend items accurately when only a few user-item interaction data are available for newly introduced items (Cold items). We propose a interaction feature prediction method to mitigate item cold start problem. The proposed method predicts the interaction features that collaborative filters can calculate for the cold items. For prediction, in addition to content features of the cold-items used by state-of-the-art methods, our method exploits the interaction features of k-nearest content neighbors of the cold-items. An attention network is adopted to extract appropriate information from the interaction features of the neighbors by examining the contents feature similarity between the cold-item and its neighbors. Our evaluation on a real dataset CiteULike shows that the proposed method outperforms state-of-the-art methods 0.027 in Recall@20 metric and 0.023 in NDCG@20 metric.

**Key words:** Item Cold Start, Cold Start, Recommender System, Recommendation, Attention Network, Collaborative Filter, Contents-based Filter.

### 1. 서 론

추천 시스템에서 널리 사용되는 알고리즘인 협업 필터(Collaborative Filter) [1]는 사용자의 취향이나 아이템의 특성을 유사한 사용자-아이템 상호작용(클릭, 구입 등)을 보인 다른 사용자나 아이템의 상호작용 패턴을 이용하여 추론한다. 상호작용 패턴을 이용하기 때문에, 예를 들어 추천 시스템에 등록된 후 충분한 시간이 경과하지 않은 사용자나 아이템은 유

사도 계산에 필요한 상호작용 정보가 적어 협업필터를 사용하여 사용자에게 정확한 추천을 제공하기 어렵다. 이러한 문제를 콜드 스타트(Cold Start) 문제라고 지칭하며, 상호작용이 적은 주체가 무엇이나에 따라 사용자 혹은 아이템 콜드 스타트(User or Item Cold Start) 문제[2]라 지칭한다.

최신 연구는 콜드 스타트 문제를 개선하기 위해 상호작용이 적은 아이템과 사용자를 뜻하는 “콜드 아이템(Cold item)”과 “콜드 사용자(Cold user)”에

\* Corresponding Author : Sejin Chun, Address: RS-625, Dong-a University, 37 Nakdong-daero 550(obaegosip)be, Hadan 2(i)-dong, Busan, Republic of Korea, TEL : +82-51-200-7923, E-mail : sjchun@dau.ac.kr

Receipt date : Aug. 25, 2021, Revision date : Nov. 18, 2021  
Approval date : Dec. 9, 2021

<sup>†</sup> Division of Computer Engineering and AI, Dong-A University (E-mail : jkhan@dau.ac.kr)

<sup>\*\*</sup> Division of Computer Engineering and AI, Dong-A University

\* This work was supported by the National Research Foundation of Korea(NRF) grant funded by the Korea government(MSIT) (No. 1711140476).

\* This research was supported by the MSIT(Ministry of Science and ICT), Korea, under the ITRC(Information Technology Research Center) support program(IITP-2021-2020-0-01797) supervised by the IITP(Institute for Information & Communications Technology Planning & Evaluation).

대해 추천 시스템에 등록되는 시점부터 알 수 있는 사용자 혹은 아이템의 특징을 설명하는 정보인 “컨텐츠자질(Content Feature)”을 입력으로, 협업필터를 사용하여 계산하는 상호작용 패턴의 특징을 표현하는 정보인 “상호작용자질(Interaction Feature)”을 인공신경망을 사용하여 예측하는 방법을 제안하였다[3,4].

앞에서 설명한 최신 연구들은[3,4] 유사한 컨텐츠자질을 가진 아이템들에 대한 사용자의 행동 패턴은 유사하다는 가정을 전제로 하고 있다. 그러나 실제로는 유사한 컨텐츠자질을 가진 아이템이라도, 아이템 컨텐츠의 일부 특정 요소가 사용자의 행동에 큰 영향을 끼칠 수 있다. 예를 들어 영국 프로축구팀에 관한 뉴스 기사들은 영국 프로축구를 좋아하는 사용자가 많이 읽지만, 영국 프로축구팀의 한국 선수에 관한 기사는 평소 영국 프로축구 기사를 잘 읽지 않는 한국 사용자도 즐겨 읽을 수 있다. 이와 같이 컨텐츠의 일부 특정 요소가 상호작용에 큰 영향을 주는 경우, 아이템 컨텐츠의 주요 특징으로부터 상호작용 패턴의 미세한 차이를 예측하기 어렵다.

본 논문에서는 아이템 컨텐츠의 일부 요소가 상호작용에 큰 영향을 줄 수 있는 경우도 고려할 수 있도록 하여 콜드 아이템 추천성능을 개선하기 위해, 콜드 아이템의 컨텐츠자질뿐만 아니라 충분한 상호작용 데이터도 보유하고 있는 워밍 아이템(Warm Item)에서 예측하려는 콜드 아이템과 매우 유사한 컨텐츠자질을 가지는 아이템들의 상호작용자질도 입력으로 사용하여 콜드 아이템의 상호작용자질을 예측하는 방법을 제안한다.

제안 방법은 Fig. 1과 같이, 컨텐츠자질이 매우 유

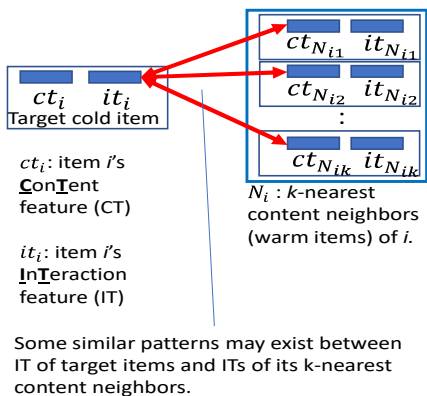


Fig. 1. The idea of proposed method.

사한 아이템들은 상호작용 패턴에 영향을 주는 컨텐츠자질의 특정 요소도 유사할 가능성이 높으며, 따라서 이들의 상호작용자질을 이용하면 콜드 아이템의 상호작용 자질도 더 정확히 예측할 확률이 높다는 가정을 바탕으로, 유사한 워밍 아이템의 상호작용자질로부터 적절한 상호작용 패턴을 추출하여 예측에 활용하기 위해 어텐션 네트워크[5]를 사용한다.

본 논문의 구조는 다음과 같다. 2장에서, 우리는 관련 연구 및 제안 방법과 밀접히 관련되어 있는 인공신경망을 이용한 상호작용자질 예측 연구에 대해 살펴본다. 3장에서 제안 방법을 설명하고, 4장에서 실제 데이터를 사용하여 제안 방법의 성능을 평가한다. 마지막으로, 5장에서 본 논문을 정리한다.

## 2. 관련 연구

### 2.1 협업필터 (Collaborative Filter)

행렬분해(Matrix Factorization) 기반의 협업 필터[6,7]가 대부분의 추천 방법에서 널리 사용된다[8, 9,10,11,12]. Fig. 2와 같이,  $m$ 명의 사용자,  $n$ 개의 아이템이 존재하는 추천 시스템에서 행렬분해는, 행렬의 각 행이 각각의 사용자, 각 열이 각각의 아이템을 나타내고,  $u$ 행,  $i$ 열의 원소가  $u$ 번째 사용자의  $i$ 열 아이템에 대한 상호작용 (클릭 여부, 5 단계 평점 등)을 나타내는  $m \times n$  레이팅 행렬(Rating Matrix)  $R$ 을 행렬 분해하여  $m \times d^{it}$ ,  $n \times d^{it}$ 의  $P$  행렬,  $Q$  행렬을 각각 계산한다.  $P$  행렬의 각 행은 각각의 사용자에 대한  $d^{it}$ 차원 상호작용자질,  $Q$  행렬의 각 행은 각각의 아이템에 대한  $d^{it}$ 차원 상호작용자질을 나타낸다.  $P \times Q^T \approx R$  을 만족하도록  $P, Q$ 를 계산함으로써 임

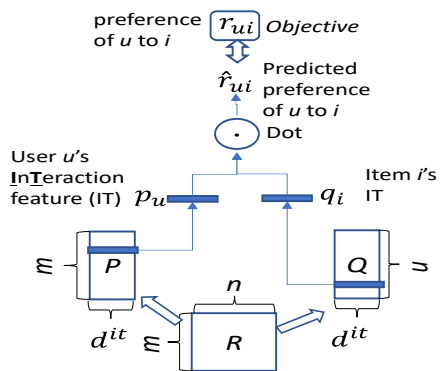


Fig. 2. Matrix Factorization [6].

의 사용자  $u$ 의 임의의 아이템  $i$ 에 대한 상호작용은  $P$  행렬의  $u$ 행과,  $Q$  행렬의  $i$ 행의 내적(dot product)으로 계산할 수 있다.  $R$ 이 사용자-아이템 상호작용 정보를 저장하고 있으므로,  $P$ ,  $Q$  행렬에는 사용자-아이템의 상호작용 패턴의 특징이 각각 사용자 상호작용자질, 아이템 상호작용자질의 형태로 압축되어 저장된다. 협업 필터는 상호작용 정보를 바탕으로 상호작용 자질을 계산하므로 상호작용 정보가 부족한 콜드 스타트 상황에서 정확한 추천성능을 발휘하기 어렵다.

### 2.2 콘텐츠필터 및 하이브리드 방식

콜드 스타트 상황에서 추천성능을 개선하기 위한 방법으로 콘텐츠필터 (Contents Filter) 방식 [13,14]과, 이와 협업필터를 혼합한 하이브리드 방식 [15,16,17]이 연구되었다.

콘텐츠필터 방식은 상호작용 정보와 무관한, 아이템의 콘텐츠 정보 (예를 들어 영화라면 장르, 감독, 배우, 줄거리 등)를 이용하여, 추천 대상 사용자를 해당 사용자가 소비한 아이템의 콘텐츠 정보에 대한 누적 분포로 나타내고, 사용자의 콘텐츠 정보 분포와 추천 대상이 되는 아이템의 콘텐츠 정보 분포의 유사성을 계산하여 더 유사한 아이템을 추천한다.

콘텐츠필터 방식은 상호작용 정보를 사용하지 않아 콜드 스타트 상황에서도 비교적 정확한 추천이 가능하나 상호작용 정보를 충분히 사용할 수 있는 경우의 협업필터 방식과 비교하면 추천성능의 정확도가 떨어진다. 하이브리드 방식은, 상호작용 정보가 충분한 아이템은 콘텐츠 정보와 상호작용 정보를 모두 사용할 수 있어 협업필터 대비 추천성능이 개선되나 콜드 아이템 추천성능은 콘텐츠필터 방식과 유사하다.

### 2.3 인공지능망을 이용한 협업필터 정보 예측

최근에는 콘텐츠 정보와 상호작용 정보를 상호 보완적으로 이용하는 것이 아니라, 인공지능망을 사용하여 콘텐츠 정보로부터 상호작용 정보를 예측하여 콜드 스타트 추천성능 개선에 활용하려는 방법이 연구되고 있다. 구체적으로, Volkovs 등이 제안한 DropoutNet[3]은 사용자와 아이템 각각에 대한, 행렬분해로 계산한 상호작용자질과 콘텐츠로부터 계산한 콘텐츠자질의 총 4종류의 자질을 인공지능망의 입력

으로 사용하여 사용자와 아이템의 상호작용자질의 내적 값을 예측하는 모델을 학습시킨다. 학습 과정에서 일정 확률로 상호작용자질을 모델 입력에서 제거(Dropout)[18]함으로써 모델이 콘텐츠자질로부터 상호작용자질을 예측할 수 있도록 학습시킨다. 이 방식은 주어진 사용자의 상호작용자질과 아이템의 상호작용자질 사이의 내적값 예측을 목적함수로 설정함으로써 상호작용자질 예측 자체는 학습의 제거과정에서 얻어지는 간접적인 학습 효과에 중점을 둔다.

한편, Zhu 등이 제안한 Heater[4]는 두 종류의 서로 다른 목적함수를 동시에 만족시키는 모델을 학습하는 것이 특징이다. 콘텐츠자질로부터 상호작용자질을 예측하는 것 자체를 첫번째 목적함수로 두고, 예측한 상호작용자질을 사용하여 실제 상호작용 여부를 예측하는 것을 두 번째 목적함수로 둔다. 특히 콘텐츠자질로부터 상호작용자질을 예측하는데 있어서 콘텐츠자질을 여러 다른 관점에서 분석하기 위해 Mixture-of-Expert [19] 구조를 사용한 것이 특징이다.

DropoutNet과 Heater는 예측하려는 사용자 혹은 아이템의 자질 정보만을 사용한다. 이는 예측하려는 아이템과 유사한 콘텐츠 자질을 가지는 워밍 아이템의 자질 정보도 사용하는 제안 방법과 차이가 있다.

## 3. 제안 방법

본 장에서는 먼저 제안 방법의 개요를 설명하고, 이후에 제안 방법의 핵심 부분인 최근접 아이템 기반 상호작용자질 예측 방법과 모델학습 및 추론에 대해 구체적으로 설명한다.

### 3.1 모델의 개요

Table 1에 제안 방법의 설명에 사용하는 기호를 정리하였다. 이후 특별한 언급이 없으면 기호  $u$ 는 추천 대상 사용자,  $i$ 는  $u$ 의 취향 강도를 예측하고자 하는 추천 아이템 후보가 되는 콜드 아이템을 표기하기 위해 사용한다.

Fig. 3에 제안 방법의 개요를 나타내었다. 제안 방법은 사용자  $u$ 의 상호작용자질, 콜드 아이템  $i$ 의 콘텐츠자질, 상호작용 데이터를 충분히 보유하고 있는 워밍 아이템 중에서  $i$ 와 콘텐츠자질이 가장 유사한  $k$ 개의 아이템 (이후  $i$ 의 “ $k$ -최근접 아이템”)으로 표기한다.

Table 1. Notations.

Notation	Explanation
$u, i, n_{ik}$	Target user $u$ , target item $i$ , and $k$ -th contents nearest warm item of $i$ .
$d_{it}, d_{ct}$	Dimension of interaction and contents feature vectors.
$p_u, q_i$	$d_{it}$ -dimensional interaction feature vectors of user $u$ , and item $i$ .
$c_i$	Content feature vectors of item $i$ .
$N_i$	The set of $k$ -contents nearest Neighbor of $i$ .
$f_u, f_i, f_{N_i}$	$d_{it}$ -dimensional preference prediction vector of user $u$ , and item $i$ and $k$ -contents nearest warm items of $i$ .
$r_{ui}, \hat{r}_{ui}$	Preference of user $u$ to item $i$ (1 if interaction exists, else 0), and predicted preference of $u$ to $i$ (a real number value, bigger value indicates more preferred.)

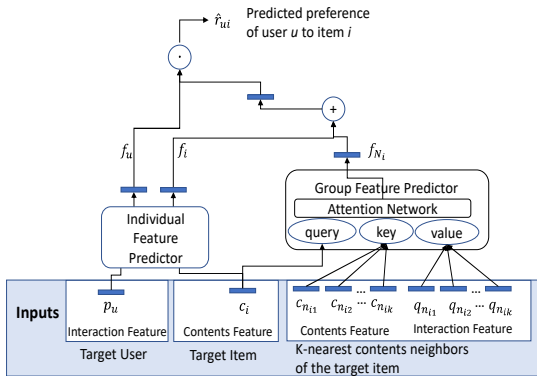


Fig. 3. Overview of the proposed method.

다.)들의 콘텐츠자질과 상호작용자질을 입력으로 하여,  $u$ 의  $i$ 에 대한 취향 강도를 예측한다. 이를 위해  $i$ 의 콘텐츠자질로부터  $i$ 의 상호작용자질을 예측하기 위한 개별자질 예측기 (Individual Feature Predictor)와  $i$ 의 “ $k$ -최근접 아이tem”의 정보로부터  $i$ 의 상호작용자질을 예측하기 위한 그룹자질 예측기 (Group Feature Predictor)로 구성된다.

개별자질 예측기는 사용자  $u$ 와, 콜드 아이tem  $i$ 의 상호작용자질을 예측하여 취향 예측 벡터 (preference prediction vector)  $f_u, f_i$ 의 형태로 출력한다.  $i$ 의 경우 콘텐츠자질이 입력으로 사용되나,  $u$ 의 경

우 상호작용자질이 입력되므로  $i$ 의 상호작용자질은 예측값을 출력하나,  $u$ 의 상호작용자질은 입력 정보를 그대로 형태만 변형하여 출력한다. 개별자질 예측기는 콘텐츠 자질로부터 상호작용자질을 예측할 수 있는 기존 모델 어떤 것이든지 사용할 수 있다. 본 논문에서는 Zhu 등이 제안한 Heater[4]를 사용하였다.

그룹자질 예측기는 콜드 아이tem  $i$ 의  $k$ -최근접 아이tem들의 상호작용자질을 기반으로 어텐션 네트워크를 사용하여 예측한  $i$ 의 상호작용자질 값인 취향 예측 벡터  $f_{N_i}$ 을 계산한다.

마지막으로  $f_i$ 와  $f_{N_i}$ 을 더해서 생성한 벡터와,  $f_u$ 의 내적으로  $u$ 의  $i$ 에 대한 예측 취향  $\hat{r}_{ui}$ 을 계산한다.

### 3.2 $k$ -최근접 아이tem 기반 상호작용자질 예측

본 장에서는 그룹자질 예측기에 대해 상세히 설명한다.

두 아이tem 사이의 콘텐츠가 서로 유사할수록 이들 아이tem에 대한 사용자의 상호작용 패턴도 유사해질 확률이 높으므로,  $i$ 의  $k$ -최근접 아이tem  $n_{ik}$ 의 상호작용자질  $q_{n_{ik}}$ 가  $i$ 의 상호작용자질 예측에 기여하는 정도는  $n_{ik}$ 와  $i$ 의 콘텐츠자질 ( $c_{n_{ik}}$ 와  $c_i$ ) 사이의 유사도에 비례할 확률이 높다. 따라서  $i$ 의  $k$ -최근접 아이tem 중 콘텐츠자질이  $i$ 의 콘텐츠자질과 더 유사한 아이tem이 그렇지 않은 아이tem보다  $i$ 의 상호작용자질 예측에 더 많이 반영되도록,  $i$ 의 콘텐츠자질  $c_i$ 를 질의 (Query),  $i$ 의  $k$ -최근접 아이tem의 콘텐츠자질  $c_{n_{ik}}$ 를 키(Key), 상호작용자질  $q_{n_{ik}}$ 를 값(Value)으로 사용하는 어텐션 네트워크[5]를 사용하여  $i$ 의  $k$ -최근접 아이tem 정보 기반 상호작용자질 예측값인  $f_{N_i}$ 를 계산한다.

$$f_{N_i} = \sum_{n_k \in N_i} a_{n_k} \cdot \text{value}(q_{n_k}) \tag{1}$$

식 (1)처럼  $f_{N_i}$ 는  $i$ 의  $k$ -최근접 아이tem의 상호작용자질을 입력으로 계산한  $\text{value}(q_{n_k})$ 값의 가중합으로 계산한다. 가중치  $a_{n_k}$ 는 식 (2)처럼  $i$ 의 콘텐츠자질을 입력으로 계산한  $\text{query}(c_i)$ 와  $n_{ik}$ 의 콘텐츠자질을 입력으로 계산한  $\text{key}(c_{n_k})$ 의 소프트맥스로 계산된다.

$$a_{n_k} = \frac{e^{\text{query}(c_i) \cdot \text{key}(c_{n_k})}}{\sum_{n \in N_i} e^{\text{query}(c_i) \cdot \text{key}(c_n)}} \tag{2}$$

$query(c_i), key(c_{n_k}), value(n_{i_k})$ 는 각각 식 (3), (4), (5)을 사용하여,  $c_i, c_{n_k}, q_{n_k}$ 를 선형변환(Linear transformation)한 결과이다.  $W_{query}, W_{key}, W_{value}$ 는 각각의 입력 벡터  $c_i, c_{n_k}, q_{n_k}$ 를 상호작용자질의 차원인  $d_{it}$ 차원의 벡터로 변환하기 위한 가중 행렬(Weight Matrix)이고,  $b_{query}, b_{key}, b_{value}$ 는 각각의 변환에서의  $d_{it}$ 차원 바이어스 벡터이다.

$$query(c_i) = \tanh(W_{query} * c_i + b_{query}) \quad (3)$$

$$key(c_{n_k}) = \tanh(W_{key} * c_{n_k} + b_{key}) \quad (4)$$

$$value(q_{n_k}) = \tanh(W_{value} * q_{n_k} + b_{value}) \quad (5)$$

$i$ 의  $k$ -최근접 아이템 집합  $N_i$ 는,  $i$ 와 상호작용자질이 존재하는 다른 모든 워밍 아이템(Warm item) 각각에 대해 콘텐츠자질의 코사인 유사도를 계산하여 이중 유사도가 가장 높은  $k$ 개의 아이템으로 구성한다.

### 3.3 모델학습 및 추론

그룹자질 예측기를 사용하여 계산한  $f_{N_i}$ 을 식 (6)과 같이 개별자질 예측기에서 계산한  $i$ 의 취향예측 벡터  $f_i$ 와 더한 다음, 이를  $u$ 의 취향 예측벡터  $f_u$ 와 내적하여  $u$ 의  $i$ 에 대한 예측 취향  $\hat{r}_{ui}$ 을 계산한다.

$$\hat{r}_{ui} = f_u \cdot (f_i + f_{N_i}) \quad (6)$$

모델학습은 식 (7)의 목적함수를 최소화하는 모델 매개변수를 학습한다.

$$L = \sum_{(u,i) \in R^+ \cup R^-} |r_{ui} - \hat{r}_{ui}|^2 + \lambda \|\theta\|_F^2 \quad (7)$$

$\theta$ 는 모델의 모든 매개변수를 나타내는 기호이고  $\|\theta\|_F$ 는 프로베니우스 놈(Frobenius Norm)을 나타낸다.  $R^+$ 는 학습 데이터에서 상호작용이 관측된 사용자-아이템 쌍의 집합이고  $r_{ui}$ 의 값은 1이다.  $R^-$ 는 상호작용이 관측되지 않은 사용자-아이템 쌍의 집합이며  $r_{ui}$ 의 값은 0이다.

앞에서 설명한 바와 같이, 제안 방법은 모든 사용자-아이템 조합에 대해, 사용자 아이템 상호작용 예측 오차를 최소화하는 모델을 학습한다. 다만, 관측된 사용자-아이템 상호작용 조합의 개수에 비해 관측되지 않은 사용자-아이템 상호작용 조합의 개수가 매우 많으므로, 모델학습 속도 향상을 위해 관측된

상호작용 쌍 1개에 대해 관측되지 않은 상호작용 쌍을 5개 임의로 추출해서 학습하는 네거티브 샘플링(Negative Sampling) 방식을 사용한다.

제안 방법을 사용한 추천은 추천 대상 사용자  $u$ 와 추천 대상이 되는 콜드 아이템 집합  $I_c$ 가 주어질 경우, 모든  $\langle u, i \in I_c \rangle$ 쌍에 대해 식 (6)을 사용하여  $\hat{r}_{ui}$  값을 예측한 다음  $\hat{r}_{ui}$  값이 큰 순서대로 아이템을 정렬하고 이중 앞에서  $n$ 개의 아이템을 추천한다.

## 4. 실험 결과 및 고찰

본 장에서는 제안 방법 평가를 위한 실험 데이터, 평가지표 및 비교방법에 대해 설명하고 제안 방법의 성능 평가 결과를 분석한다.

### 4.1 데이터

CiteULike<sup>1)</sup>, 데이터 집합을 사용하여 제안 방법의 성능을 평가하였다. CiteULike는 사용자가 읽거나 흥미를 가져 본인의 논문 리스트에 등록된 학술논문을 기록한 데이터이다. 5,551명의 사용자와 16,980개의 논문, 그리고 204,986개의 상호작용(등록:  $r_{ui} = 1$ , 등록하지 않음  $r_{ui} = 0$ ) 데이터로 이루어져 있다. 논문의 콘텐츠 데이터로 논문 제목과 논문 초록이 제공된다. 콘텐츠 데이터를 [3,4]의 연구와 동일하게, 논문 문치(Corpus)에서 나타나는 단어에 대해 tf-idf로 중요도를 평가하여 tf-idf가 높은 8,000개의 단어를 선별한 다음, 각 논문에 대해 8,000개의 단어가 나타나는지의 여부를 벡터로 나타내고 이들을 특이값분해(Singular Value Decomposition)를 통하여 차원 축소하여 각 논문마다  $d_{ct} = 300$ 인 콘텐츠자질  $c_i$ 를 계산하였다. 사용자와 논문의 상호작용자질  $p_u, q_i$ 는 BPR[7]을 사용하여  $d_{it} = 200$ 인 벡터를 계산하였다.

CiteULike 전체 데이터에서 찾을 수 있는 논문 중 랜덤하게 추출한 4/5의 논문에 대한 상호작용 데이터를 모델학습에 사용하였다. 나머지 1/5의 논문은 상호작용 데이터 및 상호작용 자질을 사용할 수 없는 콜드 아이템으로 가정하고, 이 중 30% (전체의 3/50)를 모델 검증에, 나머지 70%(전체의 7/50)를 모델 테스트에 사용하였다. 검증 및 테스트에 사용한 콜드 아이템 각각에 대해 최근접 이웃은 학습에 사용한

1) <https://github.com/js05212/citeulike-a>

논문에서 콘텐츠자질이 가장 유사한 k개의 논문을 선택하여 사용하였다.

## 4.2 실험 환경

### 4.2.1 평가지표

$Precision@n$  ( $P@n$ )[20],  $Recall@n$  ( $R@n$ )[20],  $NDCG@n$  ( $N@n$ )[21]을 사용하여 평가하였다.  $Precision@n$ 은  $u$ 를 위해 추천된  $n$ 개의 아이템 중 몇 개가  $u$ 의 테스트 셋에 존재하는지 비율을 계산하고,  $Recall@n$ 은 테스트 셋에 존재하는  $u$ 가 상호작용한 아이템 중 몇 개가  $u$ 를 위해 추천된  $n$ 개의 아이템 중에 존재하는지의 비율을 계산한다.  $NDCG@n$ 은  $Recall@n$ 과 유사하나 상호작용한 아이템이 추천 리스트의 앞에 위치할수록 더 높은 점수가 부여되도록 계산된다. 예를 들어, 서로 다른 두 알고리즘이 사용자가 상호작용한 아이템을 동일한 개수 추천하였다 하더라도 상호작용한 아이템들을 추천 리스트의 상위에 더 많이 위치시키는 알고리즘이  $NDCG$ 가 더 높다. 앞의 세 지표 모두 1.0이 최상, 0.0이 최하의 성능을 뜻한다.  $n$ 으로는 10, 20, 50, 100을 사용하였으며 테스트시 모든 사용자는 2,378개의 추천 후보 아이템 중에서  $n$ 개의 아이템을 추천받는다.

### 4.2.3 비교 방법

(1) 랜덤하게 아이템을 추천하는 랜덤추천, 최신 방법인 (2) DropoutNet과 (3) Heater, 그리고 (4) 제안 방법(SimCSR)을 비교하였다. Tensorflow2.4 2)를 사용하여 구현하였으며, 최적화 알고리즘은 모멘텀 SGD (Momentum SGD) [22]를 사용하였다. 각 알고리즘에 대해 최고의 성능을 발휘하도록 설정값을 설정하였고 구체적인 값을 Table 2에 나타내었다. Table 2에 언급되지 않은 값은 각 논문에서 나타난 설정을 따랐다.

### 4.3 성능 평가 및 고찰

Table 3에 각 알고리즘의 성능 비교 결과를 나타내었다. 표의 결과와 같이, 모든 지표에 있어서 제안 방법이 다른 비교 방법들에 비해 뛰어난 성능을 보였다. 이는 상호작용자질 예측에 있어서 콘텐츠가 유사

Table 2. Model Configurations.

Model	Configurations
Random	N/A
DropoutNet	Dropout Rate=0.5, Internal network configuration: 1 layer 500 nodes, Learning rate: 0.0005, Regularization weight: 0.0001
Heater	Dropout Rate=0.5, The number of Experts = 5, Internal network configuration: 1 Layer 200 nodes, Learning rate=0.005.
SimCSR (Proposed)	$ N_i  = 5$ , $\alpha = 0.0001$ , $\lambda = 0.0001$ , Learning rate=0.005. For base model configurations, SimCSR follows Heater's configurations.

한 다른 아이템의 상호작용자질 정보를 활용할 수 있음을 보여주고 있다.

Fig. 4에 제안 방법의  $k$ -최근접 아이템의 아이템 개수( $k$ ) 변화에 따른 제안 방법의  $Recall@20$  변화를 나타내었다.  $k$ 가 증가해감에 따라 성능도 증가하다가  $k=5$ 에서 포화상태가 되었다.

Fig. 5는 주어진 아이템에 대한 9개의 최근접 아이




Fig. 4. Recall@20 w.r.t. the number of neighbors ( $k$ ).




Fig. 5. Avg. Cosine similarity to  $k$ -th similar neighbors.

2) <https://www.tensorflow.org/>

Table 3. Model Performance. +3 indicates performance improvement to Heater is statistically significant for  $p < 0.001$  judged by paired t-test.

method	Random			DropoutNet			Heater			SimCSR		
	P@n	R@n	N@n	P@n	R@n	N@n	P@n	R@n	N@n	P@n	R@n	N@n
10	0.002	0.004	0.215	0.099	0.215	0.224	0.118	0.257	0.270	0.129 +3	0.281 +3	0.297 +3
20	0.002	0.009	0.325	0.077	0.325	0.270	0.090	0.375	0.315	0.096 +3	0.402 +3	0.338 +3
50	0.002	0.022	0.513	0.051	0.513	0.328	0.055	0.554	0.358	0.058 +3	0.575 +3	0.375 +3
100	0.002	0.042	0.659	0.034	0.659	0.357	0.035	0.685	0.375	0.036 +3	0.703 +3	0.387 +3

템의 콘텐츠자질의 코사인 유사도 평균과 상호작용 자질의 코사인 유사도 평균을 나타내었다. 첫 번째 최근접 아이템과 다섯 번째 최근접 아이템의 콘텐츠 자질 유사도와 상호작용자질 유사도의 차이가 각각 0.11, 0.05로 0.03, 0.02인 다섯 번째 최근접 아이템과 아홉 번째 최근접 아이템 사이의 차이에 비해 두 배 이상 큰 차이가 관측된다. 또한  $k = 5$  이상부터는 차이가 작아져 최저값으로 수렴하는 경향을 보인다. 이는  $k = 5$ 를 기점으로 최근접 아이템이 추천성능 향상에 이용할 새로운 정보를 제공하기 어렵다는 것을 의미하며,  $k = 5$  이상의 최근접 아이템을 사용해도  $Recall@20$  성능이 개선되지 않는 결과로 이어졌다고 생각된다.

### 5. 결 론

본 논문에서는 아이템 콜드 스타트 추천을 개선하기 위해 콜드 아이템의 콘텐츠자질과 해당 콜드 아이템의  $k$ -최근접 아이템의 상호작용자질을 함께 사용하여 콜드 아이템의 상호작용자질을 예측하는 인공지능망 알고리즘을 제안한 다음, CiteULike 데이터를 사용하여 평가하여 제안 방법이 콘텐츠자질로 단어와 같은 비범주형 콘텐츠 정보를 가지는 아이템 추천에 대해 관련 최신 알고리즘보다  $Recall@20$  기준 0.027,  $NDCG@20$  기준 0.023 만큼 성능을 개선함을 보였다. 따라서 제안 기법을, 예를 들어 뉴스기사 추천과 같은 아이템의 특징이 문서와 같은 비범주형 데이터로 정의될 수 있으며 아이템의 가치가 시간 경과와 함께 급격히 떨어지기 때문에 상호작용자질을 계산하기 위한 정보가 충분하지 않은 환경에서의 아이템 추천성능 개선에 적용할 수 있을 것이다.

### REFERENCE

- [ 1 ] F. Ricci, L. Rokach, and B. Shapira, "Introduction to Recommender Systems Handbook," *Recommender Systems Handbook*, Springer, 2011.
- [ 2 ] J. Bobadilla, F. Ortega, A. Hernando, and J. Bernal, "A Collaborative Filtering Approach to Mitigate the New User Cold Start Problem," *Knowledge-Based Systems*, Vol. 26, pp. 225-238, 2012.
- [ 3 ] M. Volkovs, G. Yu, and T. Poutane, "Dropout-net: Addressing Cold Start in Recommender Systems," *Proceedings of Advances in Neural Information Processing Systems*, 2017.
- [ 4 ] Z. Zhu, S. Sefati, P. Saadatpanah, and J. Caverlee, "Recommendation for New Users and New Items via Randomized Training and Mixture-of-Experts Transformation," *Proceedings of the 43rd International ACM SIGIR Conference*, pp. 1121-1130, 2020.
- [ 5 ] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A.N. Gomez, et al. "Attention is All You Need," *Proceedings of the 31st International Conference on Neural Information Processing Systems*, pp. 6000-6010, 2017.
- [ 6 ] Y. Koren, R. Bell, and C. Volinsky, "Matrix Factorization Techniques for Recommender Systems," *Computer*, Vol. 42, No. 8, pp. 30-37, 2009.
- [ 7 ] S. Rendle, C. Freudenthaler, Z. Gartner, and L.

- Schmidt-Thieme, "BPR: Bayesian Personalized Ranking From Implicit Feedback," *Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence*, pp. 452-461, 2009.
- [8] D. Lian, C. Zhao, X. Xie, G. Sun, E. Chen, and Y. Rui, "GeoMF: Joint Geographical Modeling and Matrix Factorization for Point-of-Interest Recommendation," *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '14)*, 2014.
- [9] I. Christensen and S. Schiaffino, "Matrix Factorization in Social Group Recommender Systems," *Proceedings of 12th Mexican International Conference on Artificial Intelligence*, pp. 10-16, 2013.
- [10] F. Yuan, J. M. Jose, G. Guo, L. Chen, H. Yu, and R.S. Alkhalaf, "Joint Geo-Spatial Preference And Pairwise Ranking for Point-of-Interest Recommendation," *Proceedings of 2016 IEEE 28th International Conference on Tools with Artificial Intelligence (ICTAI)*, pp. 46-53, 2016.
- [11] N. Koenigstein, G. Dror, and Y. Koren, "Yahoo! Music Recommendations: Modeling Music Ratings with Temporal Dynamics and Item Taxonomy," *Proceedings of the Fifth ACM Conference on Recommender Systems (Rec Sys '11)*, pp. 165-172, 2011.
- [12] E. Im and H. Yong, "PARAFAC Tensor Reconstruction for Recommender System based on Apache Spark," *Journal of Korea Multimedia Society*, Vol. 22, No. 4, pp. 443-454, 2019.
- [13] S. Kim, I. Na, and J. Shin, "A Method on Associated Document Recommendation with Word Correlation Weights," *Journal of Korea Multimedia Society*, Vol. 22, No. 2, pp. 250-259, 2019.
- [14] D. Wang, Y. Liang, D. Xu, X. Feng, and R. Guan, "A Content-Based Recommender System for Computer Science Publications," *Knowledge-Based Systems*, Vol. 157, pp. 1-9, 2018.
- [15] J. Basilico and T. Hofmann, "Unifying Collaborative and Content-Based Filtering," *Proceedings of the 21th International Conference on Machine Learning*, 2004.
- [16] R. He and J. McAuley. "VBPR: Visual Bayesian Personalized Ranking from Implicit Feedback," *Proceedings of the 30th AAAI Conference on Artificial Intelligence*, pp. 144-150, 2016.
- [17] B. Walek and V. Fojtik, "A Hybrid Recommender System for Recommending Relevant Movies Using an Expert System," *Expert Systems with Applications*, Vol. 158, 2020.
- [18] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *The Journal of Machine Learning Research*, Vol. 15, Issue 1, pp. 1929-1958, 2014.
- [19] N.M. Shazeer, A. Mirhoseini, K. Maziarz, A. Davis, Q.V. Le, G.E. Hinton, and J. Dean, "Outrageously Large Neural Networks: The Sparsely-Gated Mixture-of-Experts Layer," *arXiv preprint*, arXiv:1701.06538, 2017.
- [20] W. Niu, J. Caverlee, and H. Lu, "Neural Personalized Ranking for Image Recommendation," *Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining (WSDM'18)*, pp.423-431, 2018.
- [21] X. He, L. Liao, H. Zhang, L. Nie, X. Hu, and T.S. Chua, "Neural Collaborative Filtering," *Proceedings of the 26th International Conference on World Wide Web (WWW '17)*, pp. 173-182, 2017.
- [22] N. Qian, "On the Momentum Term in Gradient Descent Learning Algorithms," *Neural Networks, The Official Journal of the International Neural Network Society*, Vol. 12, No. 1, pp. 145-151, 1999.





한 정 규

2005년 2월 서울대학교 컴퓨터공학부(공학학사)

2007년 2월 서울대학교 전기컴퓨터공학부(공학석사)

2018년 3월 Waseda University, Computer Science and Communications Engineering (공학박사)

2020년 9월~현재 동아대학교 컴퓨터AI공학부 조교수

2018년 6월~2020년 8월 NAVER AiRS 근무

2007년 7월~2014년 4월 NTT Software Innovation Center 근무

관심분야: 추천 시스템, 정보 검색, 데이터 마이닝



천 세 진

2009년 8월 서울시립대 컴퓨터과학부 (공학사)

2018년 8월 연세대 컴퓨터과학과 (공학박사)

2021년 3월~현재 동아대학교 컴퓨터AI공학부 조교수

2018년 10월~2020년 8월 미국 표준기술연구원(NIST) ITL 근무

관심분야: 지식그래프 표현 및 추론, 온톨로지 기반 모델링, 스트림 데이터 처리