



### 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 원 저작자를 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 권리와 책임은 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)



공학석사 학위논문

추천시스템의 예측점수 제약을  
통한 인기편향의 해소

2023년 2월

서울대학교 융합과학기술대학원

지능정보융합학과

이 원 도

# 추천시스템의 예측점수 제약을 통한 인기편향의 해소

지도 교수 서봉원

이 논문을 공학석사 학위논문으로 제출함  
2022년 12월

서울대학교 융합과학기술대학원  
지능정보융합학과  
이원도

이원도의 공학석사 학위논문을 인준함  
2022년 12월

위 원장 이교구 (인)

부위원장 서봉원 (인)

위 원 이원종 (인)

## 초 록

추천시스템의 예측은 아이템의 인기도에 의해 왜곡될 수 있다. 추천시스템은 한 유저가 동등하게 좋아하는 두 아이템에 대해, 데이터에 더 많이 포함된 아이템을 더 높은 추천점수로 예측하는 인기편향을 보일 수 있다. 이러한 추천시스템의 인기편향에 따라 인기도가 높은 아이템이 지나치게 추천 돼 개인화된 추천을 해칠 수 있다. 본 연구는 이러한 인기편향 문제를 해결하기 위해 손실함수에 제약항을 추가하는 방법을 제시한다. 구체적으로 기존의 손실함수에 유저가 좋아한 긍정과 부정 아이템들의 각 점수차이를 최소화하는 제약항을 추가해 추천시스템의 정확도를 유지하며 인기편향을 줄인다. 본 연구는 제안방법의 효과를 보이기 위해 가상 데이터를 설계해 실험하여, 긍정 아이템과 부정 아이템의 예측점수의 합이 0이 되도록 제약하는 Zerosum 제약항이 추천시스템의 정확도를 유지하며 인기편향을 해소함을 보인다. 본 연구는 가상 데이터를 활용한 정량적, 정성적 평가를 통해 제안방법이 선행연구의 방법론보다 정확도와 인기편향 해소 성능이 뛰어나고 계산적 타당성과 효율성 측면의 장점이 있음을 보고한다. 이어 4개의 벤치마크 데이터를 활용한 귀납실험을 통해 제안방법이 3개의 데이터에서 낮은 정확도 손실과 높은 인기편향 해소를 보이며 기존 방법론에 비해 향상된 성능을 보임을 보고한다. 결과적으로 본 연구는 추천시스템의 인기편향 문제를 해결하는 새롭고 효과적인 방법론을 제공한다.

주요어 : 추천시스템, 인기편향, 제약항

학 번 : 2021-20929

# 목 차

제 1 장 연구의 배경과 내용.....	1
제 1 절 연구의 배경 .....	1
제 2 절 연구의 내용 .....	2
제 2 장 관련연구와 선행지식 .....	4
제 1 절 암묵적 추천시스템.....	4
제 2 절 추천시스템과 인기편향 .....	5
제 3 절 인기편향 해소를 위한 방법론.....	7
제 4 절 대조학습 .....	9
제 3 장 인기편향의 시각화와 측정 .....	11
제 1 절 가상 데이터를 활용한 인기편향의 시각화.....	11
제 2 절 인기편향의 지표 .....	13
제 3 절 인기편향의 측정 .....	15
제 4 장 제안방법 – 예측점수 제약을 통한 인기편향 해소.....	18
제 1 절 제약항을 이용한 추천시스템의 예측점수 규제 .....	18
제 2 절 제안방법의 효과와 특징 .....	20
제 3 절 하이퍼파라미터 조절의 효과 .....	22
제 4 절 제약항의 비교.....	24
제 5 장 선행연구와 비교한 Zerosum 제약항의 장점.....	26
제 1 절 인기편향 해소를 위한 선행연구의 방법론 .....	26
제 2 절 점수조정 방법과 비교한 장점 .....	29
제 3 절 상관계수 제약방법과 비교한 장점 .....	32
제 4 절 Zerosum 방법의 인기도 불변성 .....	33

제 6 장 귀납실험 .....	35
제 1 절 귀납실험의 환경 .....	35
제 2 절 평가지표 .....	37
제 3 절 귀납실험의 결과 .....	38
제 7 장 결론.....	41
제 1 절 연구의 요약 .....	41
제 2 절 연구의 의의 .....	42
제 3 절 연구의 한계 .....	45
제 4 절 후속연구 .....	46
참고문헌 .....	47
Abstract.....	53

## 표 목차

[표 1] BPR 손실함수의 성능 .....	17
[표 2] 제안방법의 성능.....	22
[표 3] 제안방법의 성능(가중치 증가) .....	23
[표 4] 기존 방법론의 성능 .....	27
[표 5] NeuCF 모델 학습시의 성능 .....	31
[표 6] 벤치마크 데이터셋 명세.....	35
[표 7] 귀납실험의 결과.....	39

## 그림 목차

[그림 1] 가상 데이터와 추천시스템의 점수예측 결과 .....	12
[그림 2] 아이템 인덱스에 따른 평균 순위 분위수.....	16
[그림 3] 가장 점수가 높은 아이템의 인기도 분위수 .....	16
[그림 4] 제안방법의 점수예측과 인기편향 .....	21
[그림 5] 제약항의 가중치 증가시의 점수예측과 인기편향.....	23
[그림 6] 기존 방법론의 점수예측과 인기편향 .....	27
[그림 7] NeuCF 모델 학습시의 점수예측과 인기편향 .....	31

# 제 1 장 연구의 배경과 내용

## 제 1 절 연구의 배경

추천시스템은 다양한 아이템 중 사용자의 취향에 맞는 아이템을 추천하는 알고리즘으로, 이커머스, 영화, 음악을 포함한 다양한 분야에서 활용된다 [4, 5, 19]. 추천시스템의 학습에는 흔히 유저의 클릭, 구매, 아이템 소비와 같은 암묵적 피드백 정보가 활용된다 [17, 26, 42].

한편, 추천시스템은 다양한 형태의 ‘인기편향’에 노출될 우려가 있다 [2, 8, 9, 29]. 첫째로 인기편향을 ‘데이터 측면’에서 바라볼 수 있다. 추천시스템의 학습에 사용되는 유저-아이템의 상호작용 데이터의 아이템 인기도는 불균형하다. 즉, 유저들의 아이템 소비의 대부분은 적은 수의 인기 있는 아이템에 몰려 있다 [2, 25]. 다음으로, 인기편향을 ‘추천시스템 모델 측면’에서 바라볼 수 있다. 종종 추천시스템은 아이템의 인기도가 불균형한 데이터를 학습하여, 유저가 두 아이템을 동일하게 좋아함에도 불구하고, 인기도가 높은 아이템에 더 높은 선호점수를 예측해 인기도가 높은 아이템을 우선해 추천한다. 이에 따라 인기도가 높은 아이템은 데이터에 아이템이 포함된 비율보다 더욱 빈번히 추천되고, 인기도가 낮은 아이템은 유저가 좋아함에도 추천이 되지 못하는 모델 측면의 인기편향이 발생해 개인화된 추천을 해치는 것이다 [3, 34, 42].

이런 다양한 인기편향을 해결할 때, 각 인기편향을 구분하고 개별적으로 해결해야 한다. 가령, ‘데이터 측면의 인기편향’(이하 데이터

인기편향)은 데이터 수집 단계에서 노출편향을 줄임으로써 개선할 수 있다 [8, 9]. 다음으로 ‘추천시스템 모델 측면(이하 모델 인기편향)’의 인기편향은 수집된 데이터에 대한 잘못된 기계학습의 결과라 할 수 있다 [34, 42]. 따라서 추천시스템 엔지니어는 추천시스템 모델의 기계학습적 개선을 통해 추천시스템이 유저가 선호하는 아이템을 인기도와 무관하게 추천하도록 해야 한다. 본 연구는 ‘추천시스템 모델 측면의 인기편향(모델 인기편향)’의 해결에 집중한다. 본 연구는 모델 인기편향을 줄일 수 있는 새로운 방법론을 제안하고 그 효과를 입증한다. 본 연구는 저자가 RecSys 2022 학회에 게재한 학술논문<sup>①</sup>을 기반으로 내용을 보충하고 정리해 구성한 연구다.

## 제 2 절 연구의 내용

본 연구는 ‘추천시스템 모델 측면의 인기편향(모델 인기편향)’을 해결하기 위한 방법론을 제안한다. 본 연구는, 추천시스템의 학습에 사용되는 기준의 손실함수는 추천시스템이 유저가 좋아하는 아이템들의 예측점수에 차이가 발생해도 이를 제약하지 않음에 주목한다 [26]. 결국 유저가 동일하게 좋아한 아이템들이라도 인기도에 따라 추천시스템의 선호점수 예측에 차이가 나고, 더 인기도가 높은 아이템이 높은 점수를 받게 되는 것이다.

따라서 본 연구는 추천시스템 모델이 유저가 좋아하는 아이템에

---

<sup>①</sup> Rhee, W., Cho, S. M., & Suh, B. (2022, September). Countering Popularity Bias by Regularizing Score Differences. In *Proceedings of the 16th ACM Conference on Recommender Systems* (pp. 145–155).

대해 최대한 동일한 선호점수를 예측하도록 유도하는 제약항을 추가한다.

이러한 제약항을 통해 추천시스템 모델이 인기도가 높은 아이템에 대해 과도하게 높은 선호점수를 예측하는 것이 방지되고 모델 인기편향이 크게 해소될 수 있다. 동시에 기존의 손실함수에 의해 여전히 추천시스템은 정확도 높은 추천을 진행해 결과적으로 추천시스템은 높은 정확도와 인기편향 해소를 모두 달성한다.

본 연구는 다음과 같이 구성된다. 우선 제 2장에서 관련연구와 연구의 선행지식이 개괄된다. 이에 따라 추천시스템의 학습, 인기편향, 인기편향을 해소하기 위한 기준 방법론, 그리고 대조학습의 개념이 설명된다. 다음으로 제 3장에서 본 연구에서 다루는 모델 인기편향을 구체적으로 이해하기 위한 가상 데이터와 모델 인기편향을 측정할 지표가 소개된다. 다음으로 제 4장에서 추천시스템의 예측점수를 제약해 모델 인기편향을 줄이는 본 연구의 제안방법이 본격적으로 설명된다. 제 4장의 1절에서 인기편향을 줄이기 위한 다양한 제약항이 제시되고 2절과 3절에서 제약항의 실제적 효과를 분석해 최종적으로 4절에서 Zerosum 제약항이 우수한 성능을 보임을 확인한다. 제 5장에서는 제안방법을 인기편향을 줄이기 위한 선행연구들의 방법론과 비교해 Zerosum 제약항의 장점을 정리한다. 마지막으로 제 6장에서 4개의 벤치마크 데이터와 4개의 추천시스템을 활용한 귀납실험을 통해 제안방법과 선행연구의 방법론을 정확도와 편향감소의 측면에서 비교한다. 귀납실험의 결과, 전반적으로 Zerosum 제약항을 활용한 제안방법이 정확도와 편향감소의 측면에서 기존연구보다 뛰어남을 확인한다. 마지막으로 제 7장 결론에서 본 연구를 요약하고, 연구의 의의를 제시한다. 최종적으로 연구의 한계와 후속연구를 제시한다.

## 제 2 장 관련연구와 선행지식

### 제 1 절 암묵적 추천시스템

암묵적 추천시스템은 아이템(Implicit Recommender System)은 클릭, 조회, 소비와 같은 유저의 선호를 알 수 있는 암묵적 피드백 정보를 활용해 추천시스템을 학습한다 [14, 17, 26]. 암묵적 선호정보 데이터는, 유저  $u \in U$ , 아이템  $i \in I$ 에 대해, 유저  $u$ 가 아이템  $i$ 를 소비했다는 정보를 나타내는 튜플  $(u, i)$ 로 구성되어 있다. 본 연구에서는 유저가 소비한 아이템을 유저의 긍정적 선호를 암묵적으로 나타낸다는 의미에서 유저  $u$ 의 긍정 아이템이라고 표기한다. 유저  $u$ 의 전체 긍정 아이템의 집합을  $Pos_u$ 라고 표기한다. 반대로, 유저  $u$ 가 소비하지 않은 아이템을 부정 아이템이라고 부르고, 유저  $u$ 의 부정 아이템 전체의 집합을  $Neg_u$ 라고 표기한다. 암묵적 추천시스템은 유저의 선호 정보를 학습해 아이템  $i$ 에 대한 유저  $u$ 의 선호점수  $\hat{y}_{u,i}$ 를 예측한다. 특히 추천시스템은 긍정 아이템에 높은 선호점수, 부정 아이템에 낮은 선호점수를 예측하도록 학습된다. 추천시스템은 유저가 아직 접하지 못한 아이템 중 선호점수가 가장 높은 아이템을 유저에게 추천한다.

암묵적 추천시스템 모델은 전통적인 행렬분해 기반 모델인 MF(Matrix Factorization)부터 [26], MF를 뉴럴 네트워크 기법으로 확대한 NeuCF(Neural Collaborative Filtering) 모델 [15], 최신 그래프 뉴럴 네트워크를 사용한 NGCF(Neural Graph Collaborative Filtering) [35]과 LightGCN(Light Graph Convolutional Network) 모델 [14] 등 지속적으로 연구되고 있는 추천시스템 모델의 형태다. 이에 따라 본

연구에서도 암묵적 추천시스템을 배경으로 인기편향의 해소를 다룬다. 이하 본 연구에서 ‘추천시스템’은 암묵적 추천시스템을 의미한다.

많은 경우 추천시스템의 학습에는 짹 지은 아이템의 순위에 기반한 손실함수를 사용한다. 이 중, 베이지안 개인화 순위 손실함수(Bayesian Personalized Ranking Loss ; BPR Loss)가 널리 사용된다 [14, 15, 26]. BPR 손실함수의 수식은 (1)과 같다.  $\sigma()$  는 시그모이드 함수를 의미한다. 원 논문에 포함된 L2 제약항은 표기의 간결함을 위해 생략한다.

$$Loss_{BPR} = -\sum_{u \in U} \sum_{p \in Pos_u, n \in Neg_u} \log \sigma(\hat{y_{u,p}} - \hat{y_{u,n}})$$

학습된 추천시스템의 정확도 성능을 평가하기 위해 주로 Hit 과 NDCG 와 같은 지표가 측정된다 [17]. 학습에 사용되지 않은 테스트 아이템들을 활용해, 유저의 긍정 아이템과 여러개의 부정 아이템의 리스트를 묶은 후 아이템들을 예측점수 순으로 나열해 긍정 아이템의 순위에 기반해 정확도 성능을 측정한다.

## 제 2 절 추천시스템과 인기편향

추천시스템 분야에서는 다양한 형태의 인기편향이 연구되었다. 첫째로, 인기편향을 데이터의 측면에서 살펴볼 수 있다 [2, 8, 25, 36, 38]. 대개 추천시스템 학습에 사용되는 유저-아이템 상호작용 데이터의 아이템 인기도는 긴 꼬리 분포를 띤다 [2, 25]. 이는 인기 있는 아이템이 사용자에게 더 노출된 노출편향 때문일수도 있지만 [8, 9],

아이템에 대한 유저의 취향 자체가 불균형하기 때문일 수 있다 [38, 39].

둘째로, 인기편향을 추천시스템 모델의 점수예측에서 살펴볼 수 있다. 일부 선행연구는 추천시스템이, 인기도가 불균형한 데이터를 학습함에 따라, 인기도가 높은 아이템을 지나치게 추천해 데이터의 편향을 더 심화시킬 수 있음을 지적했다 [3, 7, 34, 38, 42]. 특히, [42]는 이러한 ‘모델 인기편향’을 측정하기 위해, 긍정 아이템에 대한 추천시스템의 예측 점수와 아이템의 인기도의 상관관계를 이용했다. 마지막으로 일부 연구는 인기도가 높은 아이템이 과도하게 추천 돼, 이것이 차례로 높은 인기도의 아이템의 노출과 소비를 높이는 피드백 고리에 대해 연구했다 [12, 22, 23].

이러한 다양한 인기편향의 문제에 대해 개별적 해결이 필요하며, 본 연구에서는 ‘모델 인기편향’의 해결에 집중하고, ‘데이터 인기편향’이나 ‘피드백 고리’에 대한 해결은 다루지 않는다. ‘데이터 인기편향’은 데이터의 수집단계에서 인기 있는 아이템의 불공평한 노출을 통제하고 [8, 9], 유저의 정확한 선호 정보를 수집해 해결해야 된다. 더욱이, 데이터의 불균형한 아이템 빈도수는 유저의 실제 불균형한 아이템 선호를 정확히 반영하고 있는 것일 수 있다. 따라서 데이터 인기편향을 줄이기 위해 피상적으로 데이터 빈도수의 균형을 맞추는 것이 바람직하지 않을 수 있다 [38, 39]. 반면 ‘모델 인기편향’은 추천시스템 모델이 수집한 데이터의 정보를 정확히 반영하지 않고 인기도가 높은 아이템에 치중된 추천을 하는 의도치 않은 기계학습적 오현상이다. 따라서 추천시스템 모델의 학습을 개선해 추천시스템이 인기도에 따라 치중되지 않고 유저의 취향을 균등하게 반영하도록 해야 한다. 마지막으로 피드백 고리는 실제 추천시스템의 운용 과정에서 발생되는 문제며 [6, 22], 본 연구의 범위를 벗어난다. 정리하자면 본 연구는

인기편향 중 ‘모델 인기편향’의 해결에 집중한다.

### 제 3 절 인기편향 해소를 위한 방법론

인기편향을 해소하기 위해 다양한 방법론이 제안되었다. 본 연구에서는 다양한 인기편향 해소 방법론을 동작 방식에 따라 두 가지 분류로 뚫는다. 첫째 뚫음은 인기편향을 줄이기 위해 아이템의 인기도에 비례해 추천시스템의 예측 점수 혹은 순위를 조정하는 방법론이고, 두 번째 뚫음은 아이템의 인기도와 아이템의 예측점수의 상관관계를 제약하는 방법론이다. 각 방법론의 구체적 설명과 약점은 다음과 같다.

우선 아이템의 인기도에 비례해 추천시스템의 예측점수나 순위를 조정하는 방법론에는 역확률가중치 (Inverse Propensity Weighting ; IPW) 방법론 [16, 27], 인과개입(Causal Intervention) 방법론 [34, 36, 38, 40], 순위 재조정(Reranking) 방법론이 해당한다 [2, 37]. IPW는 학습상황에서 아이템 인기도의 역에 비례하는 가중치를 학습에 부여해 편향되지 않은 추천시스템 학습을 시도한다 [16, 27, 29]. 다음으로 인과개입 영역의 방법론들은 대개 아이템의 인기도와 모델 예측점수의 인과 그래프를 가정하고, 인기도가 예측점수에 주는 영향을 제거해 반사실적 예측점수를 계산하려 한다 [34, 36, 38]. 인과개입 방법론 중 한 연구는 편향이 없는 학습 데이터를 활용해 편향되지 않은 아이템 임베딩을 학습하려 한다 [40]. 마지막으로 순위 재조정 방법론은 모델이 예측한 추천순위에 대해 아이템의 인기도를 기반으로 재조정 한다 [2, 37].

위의 방법들은 추천시스템 학습의 전 또는 후의 단계에서 아이템의

인기도에 따른 가중치나 점수의 조정을 실시해 인기편향을 해소하려 한다. IPW는 인기도가 높은 아이템의 학습 가중치를 상대적으로 낮추고, 인기도가 낮은 아이템의 가중치를 높인다 [27, 29]. 인과추론 방법론들은 대개 아이템의 예측점수에서 인기도에 비례한 수치를 차감하거나 나누는 방식으로 반사실적 예측점수를 계산한다 [34, 36, 38]. 순위 재조정 방법은 직접적으로 인기도가 높은 아이템의 순위를 깎고 인기도가 낮은 아이템의 순위를 높인다 [2, 37]. 하지만 이런 방법들은 인기도에 따른 점수조정 과정에서 ‘긍정’ 아이템의 예측점수를 지나치게 깎고, ‘부정’ 아이템의 예측점수를 지나치게 높여, 인기편향의 해소 과정에서 정확도를 희생시킬 잠재적 우려가 있다. 더욱이, 이런 점수조정 방법 중 인과개입 방법 [34, 36, 38, 40]은 인기편향을 해소하기 위한 일종의 휴리스틱에 의존하며, 다양한 추천시스템 모델에서 범용적인 성과를 나타내지 못할 수 있다.

다음으로 두번째 방법론은 긍정 아이템에 한해 아이템의 인기도와 아이템의 예측점수의 상관관계를 줄이는 방법이다. 구체적으로 일부 연구는 긍정 아이템의 인기도와 예측점수의 Pearson 상관계수의 절대값을 제약하는 항을 학습에 추가했다 [7, 42]. 이는 앞서 살펴본 점수조정 방법론들이 긍정과 부정 아이템에 통틀어 점수를 조정한 것과 다르게, 긍정 아이템에 한해 점수를 조정한다는 점에서 정확도의 손실을 덜 유발할 것이라 예상할 수 있다. 또한 인기도와 예측점수의 상관계수를 제약해 인기편향을 줄이겠다는 발상도 타당하다. 하지만 본 연구의 추후 실험에서 해당 상관계수 제약 방법론의 단점이 드러났다. 첫번째 단점은 아이템의 인기도와 예측된 선호점수의 상관계수를 줄이는 것이 의도한 인기도와 선호점수의 독립으로 이어지지 않는다는 문제였으며, 두번째 단점은 상관계수를 계산하는 것이 많은 연산을

필요로 한다는 문제였다.

따라서 선행연구에서 제안된 인기편향 해소방법의 단점을 극복할 방법이 필요하다. 이때, 점수조정 방법보다 상관계수 제약방법의 정신을 따라, 부정 아이템의 점수를 높이지 않으면서 긍정 아이템 내의 예측점수를 인기도와 무관하게 예측하도록 학습하는 것이 바람직하다. 또, 연산양이 많지 않고 모든 모델에 걸쳐 사용할 수 있는 직관성을 띠는 방법이 바람직하다.

## 제 4 절 대조학습

본 연구에서 제안 할 인기편향 해소 방법은 대조학습과 관련성이 높아 관련 연구를 소개한다. 최근 머신러닝과 딥러닝 연구에서 대조학습이 널리 사용된다 [18, 21]. 특히 딥러닝 연구에서 데이터의 내재적 표현 및 임베딩을 효과적으로 학습하기 위해 대조학습이 사용되며, 같은 카테고리의 데이터의 임베딩을 가깝거나 유사하게, 다른 카테고리의 데이터의 임베딩을 멀거나 유사하지 않게 딥러닝 모델이 학습된다 [18]. 대조적 손실함수(contrastive loss) [11], 세쌍 손실함수(triplet loss) [28], infoNCE 손실함수 [24] 등이 대표적인 대조학습에 사용되는 손실함수다.

추천시스템 영역에서도 앞서 소개한 BPR 손실함수가 유저의 긍정 아이템과 부정 아이템의 점수차를 최대화한다는 점에서 대조학습과 정신이 맞닿아 있다 [26]. 하지만, BPR 손실함수는 비록 다른 카테고리 아이템(긍정-부정)의 점수 차이를 극대화하지만, 같은 카테고리 아이템(긍정-긍정 또는 부정-부정)의 점수 차이를 최소화하는 기능이

없다는 점에서 다른 대조학습 함수와 차이가 있다. 따라서 BPR 손실함수를 확장하여 유저의 긍정 아이템의 점수 차이를 줄이는 항을 추가한다면 정확도는 유지하며 인기편향을 줄이는데 도움이 될 것이라 예상할 수 있다.

이렇게 대조학습의 발상을 추천시스템의 인기편향을 감소하는데 사용한 연구는 없다. 선행연구를 탐색한 결과 머신러닝 및 딥러닝 영역 전반에서 아이템간 예측점수를 최소화하는 손실함수는 연구되지 않았다. 이는 머신러닝 및 딥러닝 영역에서, 데이터 인스턴스들의 예측점수 간 차이가 나는 것이 문제적이지 않아, 집중적으로 탐구되지 않아서 그런 것이라 생각할 수 있다. 하지만 추천시스템의 영역에서 이러한 아이템 간의 예측점수의 편차는 인기편향 문제가 된다. 추천시스템의 점수예측의 편차를 줄이는 손실함수 또한 인기편향의 해소에 적합하게 되어 새로운 가치를 확보할 수 있다.

추천시스템 영역에서 대조학습을 활용하는 연구가 일부 있었지만, 이는 주로 학습과정에서 부정 아이템을 샘플링하는 전략에 초점을 맞쳤을 뿐 [20, 41], 긍정 아이템의 점수차를 직접적으로 줄이는 식으로 동작하지 않았다. 대조학습과 무관한 추천시스템의 한 연구만, 아이템을 장르와 같은 그룹별로 묶고, 아이템 예측점수의 그룹간 평균의 차이를 제약해 아이템 그룹간 공평한 추천을 이루고자 했다 [43]. 하지만 해당 선행연구는 개별 아이템 단위의 긍정 아이템의 예측점수 차이를 줄이는 섬세한 방법을 제안하지 못했다. 결국 본 연구는 모델 인기편향을 줄이기 위해 긍정 아이템의 예측 점수를 최소화하는 참신하고 효과적인 방법을 제안한다.

## 제 3 장 인기편향의 시각화와 측정

### 제 1 절 가상데이터를 활용한 인기편향의 시각화

제 1 절에서는 추천시스템의 학습에서 발생할 수 있는 모델 인기편향을 직관적으로 파악하기 위해, 아이템 인기도에 차이가 있는 가상 데이터를 구성해 활용한다. 해당 가상 데이터에 추천시스템을 학습 할 때 나타나는 인기편향을 관찰한다.

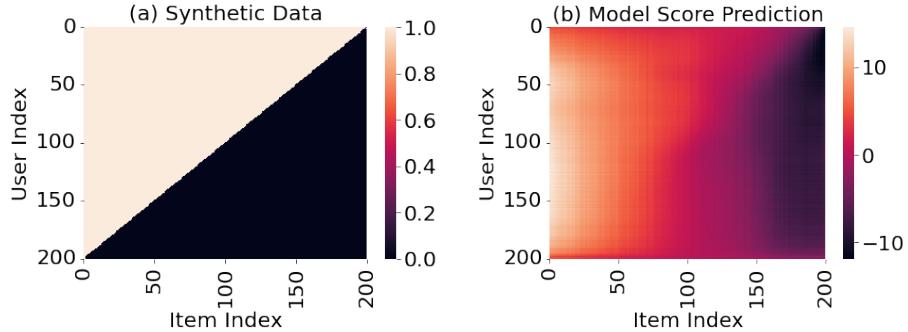
구체적으로 가상 데이터는  $200 \times 200$ 의 유저-아이템 상호작용 행렬  $R$ 이다. 행렬은 유저가 아이템을 소비한 정보를 표현한 0 또는 1의 이진 데이터로 이루어져 있으며, 그 수식은 다음과 같다. 이는 인덱스가 0인 아이템의 인기도가 가장 높고, 인덱스가 높아지며 아이템의 인기도가 선형적으로 감소하는 방식으로, 데이터 인기편향이 보이는 행렬이다. 해당 가상 데이터는 추천시스템의 학습에 활용되는 실제 데이터와 거리가 멀지만, 인기편향에 대한 체계적 분석을 가능케 한다는 점에서 효과적이다.

$$R[i, j] = 1 \quad \text{if} \quad i + j \leq 200$$

$$R[i, j] = 0 \quad \text{o.w.}$$

모델 인기편향을 시각화 하기 위해, 해당 데이터에 기본적인 암묵적 추천시스템 모델인 Matrix Factorization(MF) 모델을 BPR 손실함수를 이용해 학습한다 [26, 30]. [그림 1]의 (a)는 학습에 사용된 인기편향이 있는 가상 데이터를 보여준다. [그림 1]의 (b)는 해당 데이터에 추천시스템 모델을 학습해 선호점수를 예측했을 때의 결과를 보여준다.

$u$ 행  $i$ 열 값은 추천시스템이 예측한 선호점수  $\hat{y}_{ui}$ 값이 들어간다.



[그림 1] 좌측의 (a)는 가상 데이터를 나타낸다. 위의 흰색 삼각형은 유저가 소비한 아이템에 해당하며, 아이템의 인덱스가 작을 수록 아이템의 인기도가 높다. 우측의 (b)는 가상 데이터에 추천시스템을 학습했을 때의 점수예측 결과다. 같은 유저에 대해 인기도가 높은 아이템의 예측 점수가 높은 편향을 보인다.

[그림 1]의 (b)의 추천시스템 학습결과로부터 추천시스템의 높은 정확도와 높은 모델 인기편향을 확인할 수 있다. 우선 정확도 측면에서, 추천시스템은 유저의 긍정 아이템을 부정 아이템보다 높은 선호점수로 예측하므로 정확도가 높음을 가시적으로 확인할 수 있다.

다음으로 모델 인기편향 측면에서, 학습된 추천시스템이 높은 모델 인기편향을 보임을 알 수 있다. 즉, 유저가 소비한 긍정 아이템에 대해 추천시스템의 예측 결과를 한정했을 때, 각 유저에 대해 인기가 높은 긍정 아이템의 예측점수가 다른 긍정 아이템에 비해 높은 것이다. 이에 따라 선호점수가 가장 높은 아이템을 각 유저에게 추천한다면, 긍정 아이템 중에서 아이템 인기도가 높은 긍정 아이템만이 유저들에게 지나치게 추천돼 유저의 개인화된 취향이 무시될 것이다.

## 제 2 절 인기편향의 지표

앞서 살펴본 추천시스템의 정확도와 인기편향을 계량적으로 측정하기 위한 지표를 설정할 필요가 있다. 우선 정확도를 측정하기 위해 현재의 예시에서는 모든 유저의 긍정-부정 아이템 짝에 대해 추천시스템이 긍정 아이템을 더 높은 점수로 예측한 비율을 사용한다. [그림 1] (b)의 시각적 결과에서도 쉽게 유추할 수 있듯, 측정한 정확도는 99%에 가깝게 매우 높은 정확도를 보여 오차율인 0.01%를 보고한다.

다음으로 추천시스템의 모델 인기편향을 측정하기 위해 선행연구의 한가지 지표를 소개하고, 새로운 지표를 제안한다. 선행연구 [42]는 모델 인기편향을 측정하기 위한 지표인 인기도-순위 상관계수 (popularity-rank correlation for items ;  $PRI$ )를 제안한다. 인기도-순위 상관계수는, 긍정 아이템에 대해, 아이템의 인기도와 아이템의 평균 추천순위의 Spearman 순위 상관계수를 측정한다. 원 논문에 제안된 인기도-순위 상관계수의 수식은 다음과 같다.

$$PRI = -SRC(popularity(I), avg\_rank(I))$$

이때 아이템  $i$ 의  $avg\_rank$ 는 다음과 같이 계산된다. 먼저 아이템  $i$ 에 대해, 아이템  $i$ 를 소비한 각 유저  $u$ 에 대해, 아이템  $i$ 의 긍정 아이템에서의 순위를 0에서 1 사이 분위수로 표현한다(이때 순위의 분위수가 0에 가까우면  $u$ 의 긍정 아이템 중 상대적 점수가 높고, 분위수가 1에 가까우면  $u$ 의 긍정 아이템 중 상대적 점수가 낮음을 의미한다). 다음으로  $i$ 를 소비한 모든 유저에 대해 앞서 구한 아이템  $i$ 의

분위수를 평균내  $avg\_rank(i)$ 를 계산한다. 결국,  $PRI$ 가 1에 가까운 값을 가진다면, 이는 인기도가 높은 긍정 아이템의 평균 순위가 높음(즉, 예측 점수가 상대적으로 높음)을 의미한다.  $PRI$ 가 0에 가까운 값을 가진다면 긍정 아이템의 인기도와 평균 순위의 상관관계가 약함을 의미하고,  $PRI$ 가 -1에 가깝다면 긍정 아이템의 인기도가 높을수록 평균 순위가 낮음(즉, 예측 점수가 상대적으로 낮음)을 의미한다.

본 연구에서는 모델 인기편향을 측정하기 위한 또 하나의 지표를 제안한다. 해당 지표는 각 유저의 긍정 아이템 중 가장 높은 점수로 예측된 긍정 아이템이 가장 높은 인기도의 긍정 아이템인지를 측정한다. 이를 측정하기 위해 각 유저 별로 가장 높은 예측 선호점수를 받은 긍정 아이템에 대해, (해당 유저의 긍정 아이템에서의) 인기도의 분위수를 구해, 각 유저별로 구한 인기도의 분위수를 최종적으로 평균낸다. 수식은 다음과 같다.

$$PopQ@1 = \frac{1}{|U|} PopQuantile_u(\ argmax_{i \in Pos_u} (\widehat{y_{ui}}) )$$

이때,  $PopQuantile_u(x)$  는  $Pos_u$ 에서 아이템  $x$ 의 인기도 분위수를 계산한 것이다. 즉,  $Pos_u$ 의 아이템 중 가장 높은 인기도의 아이템  $x$ 는  $PopQuantile_u(x)$  값이 0이고, 가장 낮은 인기도의 아이템  $x$ 의  $PopQuantile_u(x)$  값은 1이다. 결국  $PopQuantile$  값들의 평균인  $PopQ@1$  값이 0에 가까운 것은 가장 높은 예측점수의 긍정아이템은 주로 인기도가 가장 높은 긍정 아이템임을 의미하며, 모델 인기편향이 높음을 의미한다.  $PopQ@1$  값이 0.5에 가까운 것은 모델 인기편향이 거의 없는 것을 의미한다고 볼 수 있고,  $PopQ@1$  값이 1에 가까운 것은 반대

방향으로 모델 인기편향이 높은 것을 의미한다.  $PRI$  는 모든 긍정 아이템에 걸쳐 아이템의 인기도와 예측점수의 관련성을 비교한 것이라면,  $PopQ@1$  는 실제 추천될 가능성이 높은, 유저의 가장 높은 점수의 아이템을 대상으로 인기편향을 측정한 것이라는 차이가 있다.  $PRI$  와  $PopQ@1$  외에 인기편향을 측정할 지표를 생각할 수 있다. 가령,  $PopQ@1$  을 통해 연구자는 인기도 분위수의 분포가 결국 균등분포에 가까운지를 측정하는 것이 목표다. 이에 따라 유사한 목표를 달성하기 위해 인기도 분위수의 엔트로피(entropy), 또는 인기도 분위수와 균등분포의 쿨백-라이블러 발산(Kullback-Leibler Divergence)를 측정할 수도 있다. 하지만 엔트로피, 쿨백-라이블러 발산의 수치는 인기도 분위수가 균등분포에 가까운지 여부만을 나타낼 뿐, 실제적으로 편향이 어떤 방식 (예 : 인기 있는 아이템이 점수가 더 높다)으로 나타내는지를 쉽게 표시하지 못한다. 결국 본 연구에서는 주로  $PRI$ ,  $PopQ@1$  측정 지표를 통해 모델 인기편향을 측정하며, 추후 연구에서 다양한 측정 지표가 연구될 수 있다.

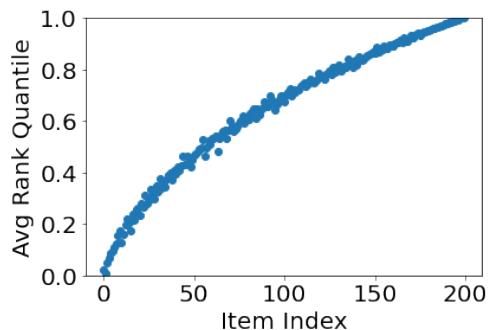
결국 추천시스템의 정확도 지표는 추천시스템이 긍정 아이템을 부정 아이템보다 높은 점수로 예측하는지를 측정하고, 모델 인기편향 지표는 추천시스템이 ‘긍정 아이템에 한해’ 아이템의 인기도와 예측점수 사이의 상관관계를 측정한다는 차이가 있다. 따라서 정확도 지표와 모델 인기편향 지표의 측정 범위는 독립적이며, 추천시스템이 양 지표에서 높은 성능을 보이도록 학습하는 것이 바람직하다.

한편, 정확도를 향상시키고 인기편향을 줄이는 것을 목표로 하되, 추천시스템의 인기편향을 줄이는 과정에서 추천시스템의 정확도가 훼손돼선 안된다. 높은 정확도가 전제되지 않은 상태로 인기편향만을 줄이는 것은 가령 아이템을 무작위로 추천하는 것과 마찬가지로 개인화된

추천을 달성하지 못한다. 결국, 모델 인기편향을 줄이는 과정에서 추천시스템의 정확도를 유지하는 것에 유의해야한다.

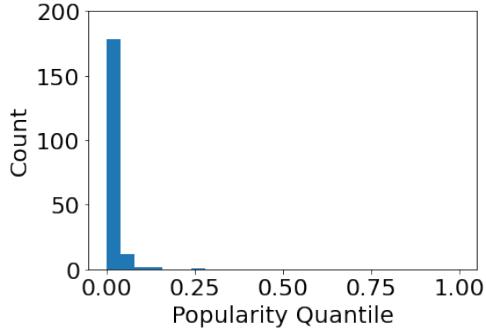
### 제 3 절 인기편향의 측정

이제 제 1 절에서 시작적으로 살펴본 추천시스템의 인기편향 정도를 계량적으로 살펴보자. 우선  $PRI$ 와 관련된 [그림 2]를 보면, 긍정 아이템의 인덱스와 긍정 아이템의 평균 순위를 비교한 것을 볼 수 있다. 아이템의 인덱스가 작을수록(인기도가 높을수록), 평균 순위 분위수가 0에 가까운 것(점수가 높다)을 볼 수 있다.  $PRI$ 값은 0.99로 1에 가깝다. 다음으로  $PopQ@1$ 과 관련된 [그램 3]을 볼 때, 각 200명 유저의 가장 높은 점수로 예측된 긍정 아이템의 인기도 분위수가 히스토그램으로 나타나 있다. 대부분의 인기도 분위수가 0(가장 높은 인기도)에 몰려 있다. 즉 대부분의 경우 유저의 긍정 아이템 중 가장 높은 점수로 예측된 긍정 아이템은, 가장 높은 인기도의 긍정 아이템이기도 한 것이다. 200개의 인기도 분위수의 평균을 낸  $PopQ@1$  값은 0.02이며 0에 가깝다. 이는 모두 추천시스템 모델이 높은 모델 인기편향을 보임을 나타낸다.



[그림 2] 가상 데이터에서의 긍정 아이템의 인덱스(작을수록 인기도가 높음)와 긍정

아이템의 평균 점수 순위의 분위수(0에 가까울수록 상대적으로 높은 점수)를 비교한 그레프다. 아이템의 인기도가 높을수록 예측 점수가 상대적으로 높다. 추천시스템이 높은 모델 인기편향을 보임을 알 수 있다.



[그림 3] 가상 데이터의 유저에 대해, 각 유저별 가장 높은 점수로 예측된 긍정 아이템의 인기도의 분위수(0에 가까울수록 상대적 인기도가 높음)를 나타낸다. 대부분의 인기도 분위수가 0에 밀집되어 있다. 즉, 유저별 가장 높은 점수로 예측된 긍정 아이템은 대부분 가장 높은 인기도의 긍정 아이템이다. 추천시스템이 높은 모델 인기편향을 보임을 알 수 있다.

정확도와 인기편향에 관련한 수치적 결과를 정리하면 [표 1]과 같다. 이 모든 결과는 가상 데이터를 활용해 기본적인 추천시스템을 학습한 결과, 추천시스템의 정확도는 높지만, 높은 정도의 모델 인기편향이 나타난다는 결과를 보여준다. 따라서 추천시스템의 모델 정확도를 유지할 수 있으며, 인기편향을 줄일 수 있는 방법이 필요하다.

	BPR Loss
Acc/Error	0.01%
PRI	0.99
PopQ@1	0.02

[표 1] BPR 손실함수를 이용해 학습한 추천시스템의 정확도와 인기편향 지표다. 추천시스템이 높은 정확도와 높은 모델 인기편향을 보이는 것을 알 수 있다.

# 제 4 장 제안방법 – 예측점수 제약을 통한 인기편향 해소

## 제 1 절 제약항을 이용한 추천시스템의 예측점수 규제

정확도를 유지하며 인기편향을 줄일 수 있는 방법을 본격적으로 소개한다. 앞서 추천시스템의 학습에 사용된 BPR 손실함수를 살펴보면, BPR 손실함수는 추천시스템으로 하여금 긍정 아이템과 부정 아이템의 점수 차이를 극대화하도록 학습시키지만, 긍정 아이템 내의 점수 차이를 제어하는 기능은 없음을 알 수 있다. 따라서 만약 기존의 BPR 손실함수의 작용에 긍정 아이템의 점수 차이를 줄이는 제약항을 추가한다면, 모델 인기편향을 줄일 수 있을 것이다. BPR 손실함수의 작용으로 여전히 긍정 아이템과 부정 아이템 간의 점수 차이가 발생해 정확도가 유지되며, 동시에 추가한 제약항으로 인해 긍정 아이템 내의 점수 차이가 줄어들어 인기편향이 해소된다는 논리다. 이에 따라 본 연구는 다음 형태와 같이 제약항이 추가된 추천시스템의 학습을 제안한다.

$$\text{Total Loss} = \text{BPR Loss} + \alpha \text{ Reg Term}$$

구체적으로, 다음과 같은 3가지 종류의 제약항을 제시하고 그 효과를 실험해 본다.

- Pos2 제약항 : 학습시 유저의 긍정 아이템을 두개씩 샘플링 해, 두 아이템의 선호점수의 차의 절대값이 0에 가깝도록 제약한다.

$$Reg\ Term = -\sum_{u \in U} \sum_{p_1, p_2 \in Pos_u} \log (1 - \tanh (|\widehat{y_{u,p_1}} - \widehat{y_{u,p_2}}|))$$

- Pos2Neg2 제약항 : 학습시 유저의 긍정 아이템과 부정 아이템을 각각 두개씩 샘플링 해, 긍정 아이템과 부정 아이템 각각의 선호점수의 차의 절대값이 0에 가깝도록 제약한다.

$$\begin{aligned} Reg\ Term &= -\sum_{u \in U} \sum_{p_1, p_2 \in Pos_u, n_1, n_2 \in Neg_u} \log (1 - \tanh (|\widehat{y_{u,p_1}} - \widehat{y_{u,p_2}}|)) \\ &\quad + \log (1 - \tanh (|\widehat{y_{u,n_1}} - \widehat{y_{u,n_2}}|)) \end{aligned}$$

- Zerosum 제약항 : 학습시 유저의 긍정 아이템과 부정 아이템을 하나씩 샘플링해, 두 아이템의 선호점수의 합이 0에 가깝도록 제약한다. 학습이 진행되며 무작위의 긍정-부정 아이템 쌍에 제약이 가해져, 긍정과 부정 아이템의 점수가 대칭을 이루게 될 것으로 기대할 수 있다. 차례로 긍정 아이템의 점수는 하나의 양수값으로 수렴하고 부정 아이템의 점수는 그와 대칭되는 값으로 수렴할 것이다.

$$Reg\ Term = -\sum_{u \in U} \sum_{p \in Pos_u, n \in Neg_u} \log (1 - \tanh (|\widehat{y_{u,p}} + \widehat{y_{u,n}}|))$$

제약항들은 모두 긍정(및 부정) 아이템 내의 점수 차이를 최소화한다. 시그모이드 함수와 로그 함수를 활용한 BPR 손실함수의 모양을 쌍곡 탄젠트 함수와 로그 함수를 이용해 모방해, 아이템들의 점수 차이가 최소인 0이 되면 손실도 최소가 되고, 점수 차이가 늘어나면 손실도 커지도록 구성했다. BPR 손실함수와 제약항의 함수를 유사하게 구성하고 함수의 치역 범위를 동일하게 구성해 BPR 손실함수와 제약항의 값의 균형을 추구하는 것이 목적이다. 추가적으로

제약항의 가중치 값을 하이퍼파라미터로 삼아 조절함으로써 BPR 손실함수와 제약항의 효과를 조절하고 균형을 찾을 수 있다.

이러한 제약항 방법은 몇가지 장점이 있다. 첫째로 추가한 제약항은 구조적인 정확도의 손실을 유발하지 않는다. 제약항의 작용 범위(각 긍정/부정 아이템의 점수 내)는 BPR 손실함수의 작용 범위(긍정 아이템과 부정 아이템 간)와 다르기 때문이다. 인기편향을 줄이기 위한 제약항은 긍정 아이템 내의 점수의 동일화를 추구하며, 긍정과 부정 아이템의 점수차를 극대화하는 BPR 손실함수와 그 효과가 병행해 작동할 수 있다. 즉, 선행연구의 일부 점수조정 방법론처럼 긍정 아이템의 점수를 희생해 부정 아이템의 점수를 증가시키는 방식으로 작동하지 않는다. 제안방법의 두번째 장점은 그 단순함과 직관성에 있다. 제안방법의 원리는 직관적으로 타당하며, BPR 손실함수를 이용해 학습하는 일반적인 추천시스템에 대해 추가적인 학습이나 점수조정 단계 없이 간단히 적용 가능하다는 범용성을 뛴다.

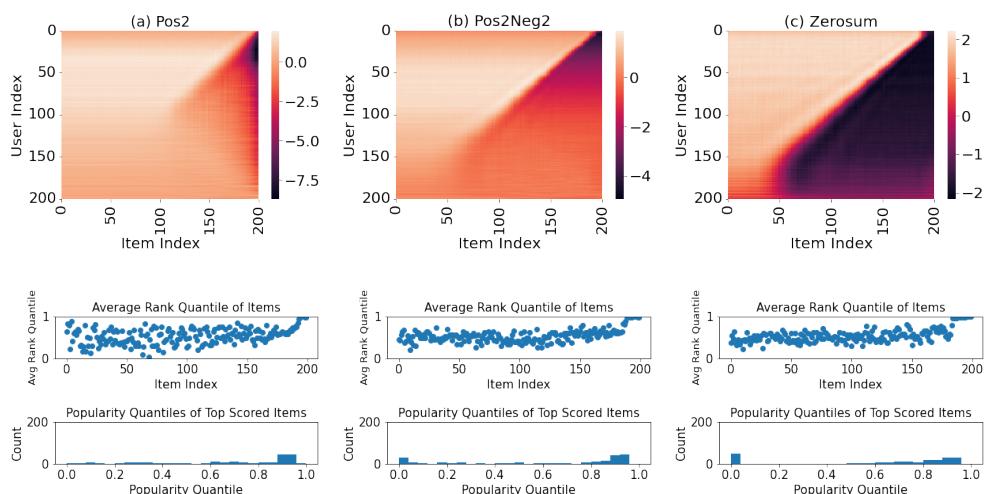
## 제 2 절 제안방법의 효과와 특징

가상 데이터를 활용해 제안방법의 효과를 확인한다. 즉, 앞서 제 3장에서 BPR 손실함수를 활용해 학습한 MF 추천시스템 모델을, 이번에는 BPR 손실함수에 각 제약항을 추가한 제안방법을 활용해 학습해 이때의 추천시스템의 정확도와 인기편향 결과를 측정하는 것이다.

그 결과는 [그림 4]와 같다. 직관적으로 모델 인기편향이 줄었음을 파악할 수 있다. 3개의 제약항의 경우, BPR 손실함수를 단독으로 사용했을 때 보다 각 유저의 긍정 아이템에 대한 점수 분포가 동일한

점수대를 가지게 됨을 알 수 있다. 추가로 (b)와 (c)의 Pos2Neg2, Zerosum 방법은 여전히 긍정 아이템의 예측점수가 부정 아이템에 비해 뚜렷하게 높아 정확도 역시 유지가 되었음을 짐작할 수 있다. 반대로 (a)의 Pos2의 경우, 아이템 소비가 낮은 유저들의 긍정 아이템과 부정 아이템의 점수가 명확히 구분되지 않아 정확도가 훼손되었음을 짐작할 수 있다. 추천시스템의 예측점수를 제약할 때 긍정과 부정 아이템의 점수 모두 제약해야 안정된 결과를 얻을 수 있음을 알 수 있다.

[그림 4]의 하단에는 인기편향 지표인  $PRI$  와  $PopQ@1$ 의 측정과 관련한 그래프가 그려져 있다. 우선 3가지 제약항 모두에 대해  $PRI$ 의 측정과 관련한 중간의 그래프를 보면, 아이템의 인덱스와 아이템의 평균 점수 순위의 상관관계가 약해진 것을 볼 수 있다. 하지만 아이템 인덱스 180 ~ 200에 해당하는 인기도가 낮은 아이템의 경우 여전히 하위권의 점수로 예측 돼 인기편향이 완벽히 해소되지 못한 모습을 보인다. 다음으로  $PopQ@1$ 의 측정과 관련한 하단의 그래프를 보면, 각 유저 별 예측점수가 가장 높은 긍정 아이템의 인기도의 분위수가 0부터 1까지 고르게 분포하게 되었다. 즉, 인기편향이 해소가 된 것이다.



[그림 4] 제안방법의 3가지 제약항을 사용해 추천시스템을 학습했을때의 예측 점수와 인기편향 측정그래프다. BPR 손실함수만을 이용해 학습했을때에 비해, 유저별 긍정 아이템의 점수가 엇비슷해지며 모델 인기편향이 해소되었음을 알 수 있다.

결과에 대해 정확도와 모델 인기편향 측정 지표를 활용해 수치적으로 평가해보자. 우선 정확도를 살펴보면, Pos2 제약항을 사용한 추천시스템 학습의 경우, BPR 손실함수의 경우에 비해 정확도가 눈에 띄게 감소했지만, Pos2Neg2와 Zerosum 제약항의 경우 BPR 손실함수의 경우와 정확도가 비슷했다. 심지어 Zerosum 제약항을 사용했을 때는 정확도가 소폭 향상됐다. 다음으로 인기편향 지표에 대해 제약항 방법 모두 PRI가 BPR 손실함수로 학습했을 때의 0.99에서 0.3~0.5의 값으로 줄어들었고, PopQ@1의 경우 또한 0.01에서 0.5에 가까운 0.6~0.7의 값에 대폭 가까워졌다. 결국 제안방법 중 Pos2Neg2와 Zerosum 제약항은 의도한대로 추천시스템의 정확도를 유지하며 인기 편향을 줄이는데 효과적이었다.

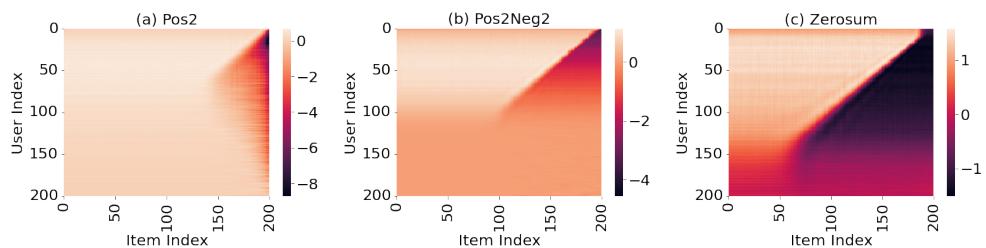
	BPR	Pos2	Pos2Neg2	Zerosum
Acc(Error)	0.011%	0.979%	0.028%	0.007%
PRI	0.99	0.33	0.42	0.50
PopQ@1	0.01	0.68	0.62	0.61

[표 2] 제안방법의 3 제약항으로 학습했을 때의 추천시스템의 정확도와 인기편향 결과다. Pos2는 정확도가 떨어졌지만, Pos2Neg2와 Zerosum은 정확도를 유지했다. Pos2, Pos2Neg2, Zerosum 방법 모두 모델 인기편향을 크게 줄인다.

### 제 3 절 하이퍼파라미터 조절의 효과

다음으로 BPR 손실함수와 제약항의 효과를 조절하기 위해 제약항의 가중치인 하이퍼파라미터  $\alpha$ 의 값을 변화시킬 때의 영향을 실험해본다. 앞서 제 2절의 실험은  $\alpha$ 의 가중치를 0.1로 놓았을 때의 결과다. 이번엔  $\alpha$ 의 가중치를 1로 높여 제약항의 효과를 높일 때의 변화를 파악해본다. 실험의 모델 예측점수와 정확도, 인기편향 지표의 결과값이 각각 [그림 5]와 [표 3]에 있다.

먼저 [그림 5]를 보면, 3가지 제약항의 경우 모두, 제약항의 가중치 증가에 따라 긍정 아이템 소비가 적은 유저들에 대해 추천시스템이 긍정과 부정 아이템의 점수를 구별하지 못하는 현상이 나타남을 볼 수 있다. 나아가 [표 3]의 수치적 결과값을 보면, 이에 따라 정확도에도 큰 손실이 발생함이 보고된다. 세 제약항 방법 모두 정확도가 감소했는데, 특히 앞서 제 2절의 실험에서 높은 정확도를 보인 Pos2Neg2 제약항의 경우 오차율이 눈에 띄게 상승했다. 한편 Zerosum 방법의 오차율도 증가를 했지만 지나친 정확도의 손실을 보이지는 않았다.



[그림 5] 제안방법의 제약항의 가중치를 높였을 때의 점수예측 결과다. 아이템 소비가 적은 유저들 위주로 긍정 아이템과 부정 아이템의 정확한 예측이 이루어지지 않음을 알 수 있다.

	BPR	Pos2	Pos2Neg2	Zerosum
Acc(Error)	0.011%	10.241%	4.276%	0.022%
PRI	0.99	0.12	0.10	0.31
PopQ@1	0.01	0.54	0.69	0.62

[표 3] 제안방법의 제약항의 가중치를 높였을 때의 정확도와 인기편향 측정 결과다.

Pos2Neg2 방법의 정확도가 크게 감소했으며, Zerosum 방법의 정확도는 감소했지만 여전히 경쟁력 있는 정확도를 보임을 알 수 있다.

이러한 실험을 통해 제안방법의 동작을 더 잘 이해할 수 있다. 즉, 정확도를 유지하며 인기편향을 줄이기 위해 제약항의 적당한 가중치를 설정할 필요가 있는 것이다. 가상 데이터에 대한 귀납적 탐색의 결과  $\alpha$ 에 0.1의 작은 가중치를 주는 것으로도 정확도를 유지하며 인기편향을 크게 줄일 수 있었다.

또, 제약항의 가중치 변화에 대한 영향을 파악함에 따라, 소비한 긍정 아이템이 적은 유저일수록 예측 정확도에 타격을 입는 것을 알 수 있다. 이에 따라 아이템 소비 수가 적은 유저에 대해 제약항의 가중치를 더 약하게 설정해 정확도 손실을 방지하는 설계도 고려할 수 있을 것이다. 본 연구에서는 귀납적 실험을 통해 제약항의 가중치를 0.1로 고정한 결과 추천시스템의 정확도가 만족스럽게 유지 돼, 가중치를 변동하는 심화된 조정법을 탐구하지 않았다.

#### 제 4 절 제약항의 비교

앞선 제 2절, 제 3절의 실험 결과에서 Pos2 제약항 방법보다 Pos2Neg2와 Zerosum 제약항 방법이 정확도 측면에서 성능이

뛰어났다. 이에 따라 예측점수를 제약하는 제안방법을 사용할 때 긍정 아이템의 점수만을 제약하는 것보다 긍정과 부정 아이템의 점수 모두를 제약하는 것이 정확도 유지에 효과적임을 알 수 있다.

다음으로 Pos2Neg2와 Zerosum 방법을 세부적으로 비교해보면, Zerosum 방법이 Pos2Neg2 방법보다 정확도가 더 높고, 특히 제약항의 가중치를 증가했을 때도 더 적은 정확도 손실을 보임을 확인했다. 이런 Zerosum 방법의 높은 정확도의 원인에 대해 다음과 같은 두가지 이유를 제시한다.

첫번째 이유는 Zerosum 방법이 Pos2Neg2 방법보다 더 다양한 학습이 가능하다는 점이다. Pos2Neg2 제약항은 학습시, 유저의 긍정 아이템 두개를 무작위로 짹지어 점수가 유사하도록 학습을 한다. 하지만 긍정 아이템의 소비가 적은 유저의 경우, 학습이 가능한 긍정 아이템 짹의 수가 적어 다양한 학습이 이루어지지 않을 수 있다. 반면 Zerosum 방법은 유저의 긍정 아이템을 부정 아이템과 짹지어 학습하기 때문에, 긍정 아이템의 소비가 적은 유저의 경우에도 다양한 부정 아이템과 짹지어 학습이 가능해 더 원활한 학습이 일어난다고 볼 수 있다. 두번째 이유는 Zerosum 방법이 긍정과 부정 아이템의 대칭적 점수를 유도한다는 점이다. [그림 4]의 Pos2Neg2와 Zerosum 방법의 예측점수를 보면, Pos2Neg2는 유저별로 부정 아이템의 예측점수가 다르지만, Zerosum 방법은 유저별로 부정 아이템의 예측점수가 엇비슷하고, 동시에 부정 아이템의 점수가 긍정 아이템의 점수와 대칭적임을 알 수 있다. 즉, Pos2Neg2의 경우, 유저별로 다른 부정 아이템의 예측점수가 학습 과정에서 의도치 않은 차이를 부여해, 유저별로 고르지 못한 학습을 유발 했을 수 있다. 반면 Zerosum 방법은 유저별로 긍정 및 부정 아이템의 점수 분포가 비슷해 학습과정에 유저별

차이가 없어 고른 학습을 진행시켰다고 볼 수 있다.

결국, 본 연구는 제안방법의 3가지 제약항이 질적인 차이가 있고, Zerosum 방법이 가장 높은 정확도를 보임을 제 2절, 제 3절의 가상 데이터의 귀납적 실험으로 확인해 Zerosum 방법을 최종적인 제안방법과 연구의 주요 기여점으로 제시한다. 이하 본 연구에서 ‘제안방법’은 Zerosum 제약항을 사용한 인기편향 해소방법을 의미한다.

## 제 5 장 선행연구와 비교한 Zerosum 제약항의 장점

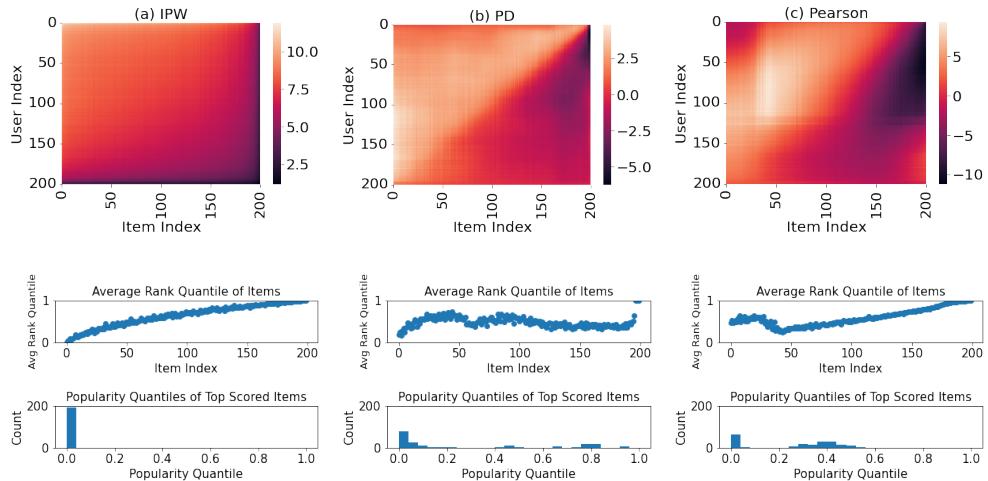
### 제 1 절 인기편향 해소를 위한 선행연구의 방법론

Zerosum 제약항을 이용한 제안방법을 선행연구의 다양한 인기편향 해소 방법론들과 비교해 제안방법의 장단점을 분석한다. 우선 본 연구는 기존의 인기편향 해소 방법론을 크게 아이템의 인기도에 따라 예측점수를 조정해 인기편향을 해소하는 점수조정 방법론과, 궁정 아이템의 인기도와 예측점수의 상관계수를 제약하는 상관계수 제약 방법론으로 나눈다.

구체적으로 점수조정 방법론은 역학률 가중치(IPW) 방법론 [16, 27], 인과개입 방법론 [36, 38, 40], 순위 재조정 방법론 [2, 37] 등이 포함된다. 이 중 제안방법과 비교를 위해 IPW 방법론, 그리고 인과개입 방법론 중 가장 높은 성능을 보고한 PD(Popularity-bias Deconfounding) 방법론을 비교한다 [38]. 한편 순위 재조정 방법론은

모델 인기편향 측정의 맥락에서는 정답을 알고 있는 상태에서 정답을 맞추는 방식에 대응되기 때문에 비교하기에 적절하지 않다. 결국 IPW, PD 방법론, 그리고 [42]에서 제안된 Pearson 상관계수 제약방법론의 성능을 측정하고 제안방법과 비교한다.

앞서 제 4 장의 실험과 마찬가지로 IPW, PD, Pearson 방법을 각각 사용해 가상 데이터에 Matrix Factorization 모델을 훈련시켰을 때의 정확도와 인기편향 성능을 측정한다. 그 결과는 [그림 6]과 [표 4]에서 볼 수 있다.



[그림 6] 선행연구의 인기편향 해소 방법론을 이용해 추천시스템을 학습한 결과다. IPW 방법론은 인기편향 해소 효과가 없다. PD 방법론은 아이템 별로 인기편향 해소 효과가 고르지 않다. Pearson 상관계수 제약방법은 인기도가 높은 아이템의 점수를 과도하게 떨어트린다.

	BPR	Zerosum	IPW	PD	Pearson
Acc/Error)	0.01%	0.007%	0.05%	0.01%	0.01%
PRI	0.99	0.50	0.99	-0.52	0.80
PopQ@1	0.02	0.61	0.0	0.35	0.31

[표 4] 제안방법과 기존 인기편향 해소 방법론들의 정확도와 인기편향 해소 성능이다.

제안방법인 Zerosum 방법론은 기존의 선행연구 방법론에 비해 정확도와 인기편향 성능에서 우월하다.

[그림 6]의 (a)는 IPW 방법의 결과를 보여준다. (a)의 상단은 추천시스템의 예측점수 결과다. 얼핏 볼 때 긍정 아이템과 부정 아이템 모두 비슷한 점수를 예측한 것으로 보인다. 하지만 (a)의 중간과 하단의 인기편향 측정의 그래프를 보면 인기도가 높은 긍정 아이템의 점수 순위가 높아 인기편향이 전혀 줄어들지 않았음이 보인다. [그림 6]의 (b)의 PD 방법의 경우 어느정도 인기편향이 감소한 것처럼 보인다. 하지만 이러한 인기편향 감소의 효과가 Zerosum 방법의 경우보다 고르지 않음을 알 수 있다. 이는 인기편향을 측정한 (b)의 중간과 하단의 그래프에서도 나타난다. 아이템 인덱스별로 예측점수의 평균 분위수를 측정한 가운데 그래프는 S자형을 띠며, 여전히 인기도가 가장 높은 아이템의 평균 순위가 가장 높다.  $PopQ@1$  측정을 위한 하단의 그래프에서 여전히 상당수 유저 (약 80)의 가장 높은 점수의 긍정 아이템은 여전히 가장 인기 있는 긍정 아이템이었음을 확인할 수 있다. 마지막으로 [그림 6]의 (c)에서 Pearson 상관계수 제약방법의 결과를 볼 수 있다. Pearson 제약 방법의 경우, 유저 인덱스 0~20번에 대해서는 가장 인기도가 높은 아이템의 예측 점수가 오히려 매우 낮아짐을 볼 수 있다. 즉, Pearson 제약방법을 사용할 때, 추천시스템의 학습이 가장 인기도가 높은 아이템의 예측 점수 일부는 높고, 다른 일부는 낮게 예측하도록 유도해, 상관계수의 결과 값만 0에 가깝도록 유도한 것이다. Pearson 상관계수를 제약한 결과 목표로 한 긍정 아이템의 인기도와 예측점수의 독립이 달성되지 않았으며, 수치적 계산을 했을 때 선형적 상관성이 나타나지 않도록 피상적으로 조정된

것에 불과하다. 하지만 이런 조정은 인기편향을 효과적으로 없애지 못한다. 왜냐하면 이제 유저 인덱스 0~20번 대의 유저들에게는 인기 있는 아이템들이 추천이 배제되는 식의 변형된 인기편향이 발생하기 때문이다. (c)의 가운데의 그래프를 볼 때, 아이템 인덱스가 0~30에 해당하는 인기 있는 아이템의 예측점수의 순위는 0.5에 가깝게 이상적으로 조정되었지만 이후의 아이템들은 여전히 편향된 점수 결과를 보이는 것을 알 수 있다. (c)의 하단의 그래프는 가장 높은 점수의 아이템의 인기도의 분포가 어느정도 고르다.

[표 4]는 세 방법의 정확도와 인기편향의 수치적 지표를 보고한다. 우선 정확도를 볼 때, 모든 선행방법이 Zerosum 방법보다 정확도에서 좋지 못한 성능을 보인다. 다음으로 인기편향 성능에서도 IPW는 편향 감소 효과가 전혀 없고, PD는  $PopQ@1$ 의 값이 0.35로서  $PopQ@1$  값이 0.61인 Zerosum 방법보다 0.5로부터 차이가 나고, Pearson 방법은 PRI의 값이 1에 가까운 높은 값을 보이며,  $PopQ@1$ 의 값 역시 0.31 정도로 Zerosum의 경우보다 0.5로부터 차이가 난다. 가상데이터를 활용한 실험에서 Zerosum 방법은 기존의 편향해소 방법보다 정확도와 인기편향 감소 측면에서 우월한 것이다.

## 제 2 절 점수조정 방법과 비교한 장점

Zerosum 제약항이 점수조정 방법에 비해 가지는 장점에 대해 추가적으로 논의한다. 점수조정 방법은 인기도에 따라 모델의 예측점수를 조정하도록 해, 인기도가 높은 아이템의 점수를 낮추고, 인기도가 높은 아이템의 점수를 높이는 방향으로 작동한다. 하지만

이러한 점수조정 방식은 인기도에 따라 점수를 가감하는 과정에서 궁정 아이템의 점수를 지나치게 낮추고 부정 아이템의 점수를 지나치게 높여 추천시스템 모델의 정확도를 손실 시킬 구조적 우려가 있다. 점수조정 방법은 하이퍼파라미터의 조정을 통해 정확도 손실과 인기편향 해소를 조정한다.

한편, Zerosum 방법은 점수조정 방법에 비해 계산적 타당성 측면에서 장점이 있다. 이는 점수조정 방법이 인기편향을 줄이기 위해 점수를 조정하는 방식이 종종 휴리스틱에 의존적이기 때문이다. 점수조정 방법은 학습 데이터 혹은 추천시스템 모델이 달라지는 경우 그 효과가 유지되지 않을 수 있다. 앞서 점수조정 방법 중 좋은 성능을 보인 PD 방법을 예로 들어보자. PD 방법이 예측점수로부터 인기도에 따른 점수를 조정해 반사실적 점수를 계산하는 수식은 다음과 같다 [38].

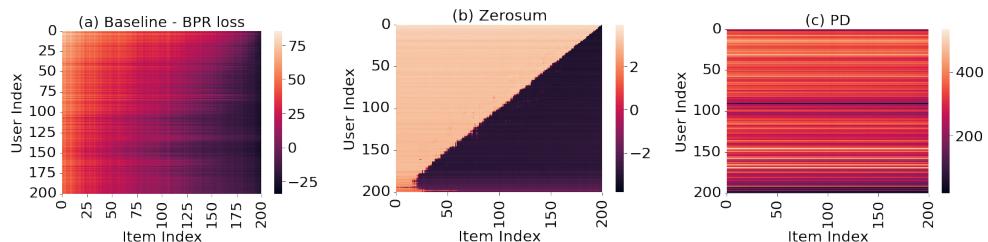
$$\text{Model score} = \text{ELU}(\text{debiased score}) \times (\text{item pop})^\alpha$$

하지만 이러한 PD의 수식 설계는 추천시스템 모델의 계산에 근거한 것이 아닌, 인기도에 따라 예측점수가 증가하는 경향성에 착안한 것이다. 결국 PD 방법론은 데이터와 추천시스템의 예측에 맞는  $\alpha$ 를 귀납적으로 최적화하기 위한 하이퍼파라미터의 탐색에 의존한다. 하지만 이러한 휴리스틱적 방법에 근거한 하이퍼파라미터 조정은 특정 데이터나 추천시스템 모델을 활용했을 때 잘 작동했더라도, 데이터의 분포나 사용된 추천시스템 모델이 달라진 경우 그 효과를 잃게 될 수 있다.

특히 추천시스템 모델의 계산 방법은 최근의 뉴럴 네트워크 방법론을 도입하며 계산과정이 복잡해지고 있다 [14, 15, 35]. 따라서

점수조정 방법론이 서로 다른 추천시스템 모델에서 범용적 효과를 보이지 않을 것이라 예상할 수 있다. 이 지점을 부연설명하기 위해 우리는 앞서 가상 데이터를 활용한 실험에서 추천시스템 모델을 선형 모델인 MF로부터 비선형 뉴럴 네트워크 모델인 NeuCF(Neural Collaborative Filtering) 모델로 수정한 후 실험을 재차 진행한다. BPR 함수만 사용한 베이스라인, Zerosum 방법, PD 방법론을 이용해 학습을 진행한다.

실험의 결과를 [그림 7]과 [표 5]에서 확인할 수 있다. [그림 7]에서 기본 추천시스템 모델을 변경한 결과, BPR 함수만을 사용한 베이스라인의 경우부터 예측점수가 달라졌음을 알 수 있다. 나아가 PD 방법은 (하이퍼파라미터를 ‘새로 조정했음에도’ 불구하고) 정확도와 인기편향 성능이 큰 폭으로 떨어져 더 이상 효과적인 인기편향 방법으로 활용하기 어려웠다. 하지만 Zerosum 방법은 (하이퍼파라미터를 ‘조정하지 않았음에도’ 불구하고) 예측양상이 달라졌음에도 여전히 높은 정확도, 그리고 효과적인 인기편향 해소 성능을 보임을 알 수 있다. 결과적으로 Zerosum 방법은 점수조정 방법에 비해 원리가 직관적으로 타당하고, 다양한 추천시스템 모델에 대해서도 범용적인 결과를 보이며 계산적 타당성을 확보한다.



[그림 7] NeuCF 추천시스템 모델에서 BPR 손실함수, Zerosum, PD 방법론을 이용해 학습한 결과다. MF 추천시스템 모델을 사용했을 때와 예측양상이 달라졌으며, Zerosum 방법은 달라진 모델에서도 높은 성능을 보이지만 PD는 더이상 효과적이지 않다.

	BPR	Zerosum	PD
Acc(Error)	0.11%	0.03%	0.35%
PRI	0.99	0.62	0.95
PopQ@1	0.00	0.68	0.00

[표 5] NeuCF 추천시스템 모델에서 BPR 손실함수, Zerosum, PD 방법론을 이용해 학습했을 때의 정확도와 인기편향 결과다. Zerosum 방법은 높은 정확도, 인기편향 해소 성능을 보이지만, PD는 낮은 정확도와 낮은 인기편향 해소 성능을 보인다.

### 제 3 절 상관계수 제약방법과 비교한 장점

Zerosum 방법과 선행연구에서 제안된 Pearson 상관계수 제약 방법은 목적은 일부 유사하다. 두 방법론 모두 긍정 아이템에 대해서 아이템 인기도가 예측점수에 영향을 미치지 않도록 학습해 인기편향을 줄이는 것이 목적이다. 이는 점수조정 방법론이 긍정 아이템의 점수를 줄이고 부정 아이템의 점수를 늘려 정확도를 훼손하기 때문에 지니는 구조적 위험성을 극복하는 접근이다.

한편 기존의 상관계수 제약 방법은 계산적 타당성과 효율성의 측면에서 한계가 있다. 계산적 타당성의 측면에서, 앞서 [그림 6]의 (c)의 결과에서 상관계수 제약방법을 사용시 의도한 인기도와 예측점수의 독립을 이루지 못했음을 확인했다. 반면 Zerosum 방법은 보다 직관적 방법으로 긍정 아이템의 점수차를 직접적으로 줄여 효과적으로 인기편향을 줄였음을 확인했다.

다음으로 계산적 효율성 측면에서, 상관계수 제약법은 한 횟수의 학습을 위해 모든 긍정 아이템의 인기도와 점수를 예측해 상관계수를 계산해야 되므로 많은 연산양을 요구한다는 한계가 있다. 더욱이, 본 연구는 제 4장의 제 2절에서 Pos2 방법의 효과를 분석하며 긍정

아이템의 점수뿐만 아닌 부정 아이템의 점수도 같이 제약해야 안정된 인기편향 감소를 달성하는 것을 확인했다. 기존의 상관계수 제약 방법도 마찬가지로 부정 아이템으로 제약항을 확대할 경우 더 안정된 성능을 보일 것이라 예상할 수도 있다. 하지만 추천시스템 데이터의 특성상, 부정 아이템의 양이 긍정 아이템보다 압도적으로 많기 때문에 [10, 13, 31-33], 이는 연산 부담을 대폭 늘리는 접근이기에 적용하기 어렵다. 반면, Zerosum 방법은 상관계수 제약법과 유사한 계산을 미니배치 형식으로 학습해 효율적 연산이 가능하며 긍정과 부정 아이템 모두에 대해 적절하게 점수 제약의 효과를 가져 안정된 예측을 가능케 한다. Zerosum 방법은 계산적 효율성 측면에서 장점이 있는 것이다.

## 제 4 절 Zerosum 방법의 인기도 불변성

마지막으로 Zerosum 방법은 기존 대부분의 인기편향 해소 방법과 다르게 아이템의 인기도에 불변(invariant)하다는 특징이 있다. 즉, 기존 방법론들은 아이템의 인기도 정보를 활용해 점수를 조정하거나 상관계수를 제약하는데, Zerosum 방법은 아이템의 인기도 정보를 사용하지 않는다. 이는 쉽게 부각되지 않는 장점이지만, Zerosum 방법이 다양한 데이터 형태에서 범용적인 성능을 보일 수 있음을 시사한다. Zerosum 방법의 인기도 불변성 특성이 효과적일 수 있는 두가지 경우를 제시한다.

첫째는 데이터의 인기도 분포가 달라지는 경우며, 두번째 경우는 데이터 전체의 아이템 인기도와 국소적인 아이템 인기도가 다른 경우다. 첫째 경우인 데이터의 인기도 분포가 달라지는 경우는 아이템의 추가 및 유저들의 소비가 달라지는 실제 추천시스템 상황에서 쉽게 발생할 수

있는 경우다. 이때, 귀납적 데이터에 맞춰 하이퍼파라미터를 튜닝하는 대부분의 점수조정 방법론은 데이터의 추가에 따라 재학습은 물론 하이퍼파라미터도 새로 탐색해야 한다. 하지만 Zerosum 방법은 데이터의 인기도를 계산에 활용하지 않으므로 하이퍼파라미터를 수정할 필요가 없다.

두번째 방법의 경우인 데이터 전체의 아이템 인기도와 국소적 아이템 인기도가 차이가 나는 경우를 평가해보자. 다음과 같은 극단적 예시를 들어 Zerosum 방법의 효과를 부각할 수 있다. 제 2 장에 소개된 가상 데이터에 200명의 유저의 데이터를 추가하는데, 추가된 200명의 아이템 소비가 기존 200명과 정반대인 경우를 생각해보자. 즉 기존의 가상 데이터는 0번 인덱스 아이템을 모든 유저가 소비하고, 199번 인덱스 아이템을 아무도 소비하지 않았는데, 반대로 추가한 데이터는 0번 인덱스 아이템을 아무도 소비하지 않고, 199번 아이템을 모두가 소비한 경우다. 이러한 데이터를 추가한다면, 기존의 유저 200명과 새로운 유저 200명의 아이템 소비는 각 집단별로 아이템 인기도에 차이를 보이지만, 전체적으로는 200개의 아이템의 인기도는 소비수가 200개로 동일하게 된다. 이 경우 선행연구의 점수조정 방법론, 그리고 상관계수 제약방법 모두 추천시스템에서 발생하는 인기편향을 줄일 수 없다. 하지만 Zerosum 방법은 유저 별로 궁정 아이템의 점수 예측을 같게한다는 간단하면서도 강력한 논리를 통해 인기도 정보 없이 국소적 인기도까지 고려한 인기편향 해소를 달성할 수 있음을 알 수 있다.

종합적으로 Zerosum 방법은 기존 방법에 비해 가상 데이터에 대한 계량적 결과가 뛰어나고, 추가적으로 계산적 타당성, 계산적 효율성, 그리고 인기도 불변성의 다양한 장점을 지닌 좋은 방법이다.

## 제 6 장 귀납실험

### 제 1 절 귀납실험의 환경

마지막으로 제안방법의 효과를 실제 데이터에서 입증하기 위해 4개의 벤치마크 데이터와 4개의 추천시스템 모델을 활용해 귀납실험을 진행한다.

귀납실험을 위해 4개의 벤치마크 데이터를 활용하며 데이터는 구체적으로 MovieLens [13], Gowalla [10], Goodreads [32, 33], Ciao [31] 데이터다. 데이터의 유저 수, 아이템 수, 상호작용 수, 밀도는 [표 6]과 같이 주어진다. 양, 밀도에 차이가 있는 다양한 데이터를 활용해 제안방법의 성능을 확인한다.

	#users	#items	#interactions	sparsity
MovieLens	6,040	3,260	998,539	0.0507
Gowalla	65,253	57,445	1,339,108	0.0003
Goodreads	14,512	12,385	3,053,619	0.0169
Ciao	4,920	4,394	100,000	0.0046

[표 6] 귀납실험에 사용된 4개의 데이터의 특성이 나타난다.

귀납실험을 위해 4개의 추천시스템 모델을 활용한다. 활용한 모델에는 전통적인 행렬분해 방법론인 Matrix Factorization 추천시스템 모델인 BPR-MF부터 [26], 뉴럴 네트워크를 활용한 NeuCF 모델 [15], 그리고 최신 기법인 그래프 뉴럴 네트워크를 활용한 NGCF [35], LightGCN 모델 [14]을 활용한다. 이를 통해 다양한 추천시스템 모델에 대한 제안방법의 범용적 성능을 확인한다.

귀납실험을 위해 제안방법과 기존 선행연구의 편향해소 방법을 비교한다. 비교에 활용되는 방법론을 나열하면 다음과 같다. 우선 ‘Baseline’은 BPR 손실함수만을 활용해 각 추천시스템 모델을 학습하는 방법론으로 [26], 인기편향을 해소하지 않은 상태의 추천시스템 모델을 나타낸다. ‘IPW’는 역확률 가중치(Inverse Propensity Weighting) 방법론으로 [27], 학습 단계에서 아이템의 인기도의 역만큼의 가중치를 가해 인기편향을 줄이려고 한다. ‘PD(Popularity-bias Deconfounding)’는 인과개입 방법론 중 정확도와 인기편향 해소에 가장 높은 성능을 보고한 방법이며 [38], 인기편향을 제거하기 위해 추천시스템이 예측한 선호점수에서 아이템의 인기도에 비례한 값을 나누어 준다. 하이퍼파라미터  $\gamma$  는 [0.05, 0.25]의 범위에서 튜닝을 실시한다. ‘MACR(Model Agnostic Counterfactual Reasoning)’은 인과개입 방법론의 하나며 [36], 인기편향을 제거하기 위해 추천시스템이 예측한 선호점수에서 아이템의 인기도에 비례한 값을 빼준다. 하이퍼파라미터  $c$  는 [0, 30]의 범위에서 튜닝을 실시한다. ‘Pearson’ 방법은 Pearson 상관계수의 값을 제약하는 방법으로 [42]에 소개되었다. 선행연구는 유저의 긍정 아이템에 대해 아이템 인기도와 모델의 예측점수 사이의 상관관계를 제약하는 제약항을 학습단계에 추가했다. 제약항의 가중치는 {1e1, 1e2, 1e3, 1e4}의 범위에서 튜닝을 실시한다. ‘Post-Process’ 방법은 예측점수에서 인기도에 비례한 점수를 조정하는 방식이며, Pearson 상관계수 제약 방법을 제안한 [42]에서 소개되었다. 저자들은 ‘Post-Process’ 방법이 Pearson 상관계수 제약방법보다 성능이 우월하다고 보고했다. 하이퍼파라미터  $\alpha$ ,  $\beta$ 는 각각  $\alpha$  는 [0.1, 1.5],  $\beta$  는 [0.0, 1.0]의 범위에서 튜닝되었다. 마지막으로 ‘Zerosum’ 방법은 본 연구의 제안방법으로 BPR 손실함수에 제약항을

추가해 유저의 긍정 아이템과 부정 아이템의 점수의 합이 0이 되도록 제약하는 방법이다. 제약항의 가중치는 모든 실험에서 0.1로 고정해 별도의 하이퍼파라미터 튜닝 없이 사용했다.

## 제 2 절 평가지표

귀납실험을 위한 추천시스템 모델의 학습은 다음과 같다. 우선 각 데이터마다 긍정 데이터를 60%, 20%, 20%로 나누어 학습(train), 테스트(test), 검증(validation) 데이터로 삼는다. 각 유저에 대해 100개의 테스트 부정 아이템을 학습 이전에 선택한다. 각 [데이터 x 추천시스템 모델 x 편향감소 방법]의 성능을 확인할 때 동일한 실험 환경을 구성한다. 즉, 동일한 learning rate (0.001), 미니배치 사이즈 (2048), 임베딩 차원 (MF, NeuCF는 64차원, NGCF, LightGCN은 10차원에 3개의 GCN 층)이 실험에 사용되었다.

귀납실험을 위한 추천시스템 모델의 평가는 다음과 같다. 정확도를 평가하기 위해, 유저의 각 긍정 아이템을 학습 이전 준비해둔 유저의 100개 부정 테스트 아이템과 짹지어 예측점수의 상대적 순위를 비교한다. 정확도 지표로 Hit@10과 NDCG@10이 사용된다. Hit@10, NDCG@10이 높을수록 더 높은 정확도를 나타낸다. 인기편향의 감소 성능을 측정하기 위해 PopQ@1 지표를 활용한다. 긍정 테스트 아이템이 최소 5개 이상인 유저에 대해 PopQ@1 지표를 측정한다. 이는 긍정 테스트 아이템의 소비가 지나치게 적으면 PopQ@1의 값이 극단적 값을 가지기 쉽기 때문이다. PopQ@1은 값이 0.5에 가까울수록 인기편향이 적음을 시사하고, 0 또는 1에 가까울수록 인기편향이 높음을 시사한다.

한편 귀납실험의 결과, 대부분의 편향해소 방법은 인기편향의 감소와 더불어 정확도의 손실을 같이 보였다. 이에 따라 정확도와 인기편향 두가지 성능을 같이 고려할 기준이 필요했다. 본 연구에서는 정확도의 손실이 기준치 아래(즉, Hit@10 손실이 2% 아래)이며, 동시에 일정 수준 이상의 인기편향 감소(PopQ@1의 수치가 0.07 이상 증가)를 보일 때 좋은 성능을 보이는 것으로 평가하기로 했다.

### 제 3 절 귀납실험의 결과

귀납실험 결과는 [표 7]과 같다. 표는 위에서 아래로 4개의 데이터셋 구분에 맞춰 4칸으로 크게 나뉘어져 있다. 표의 4개의 큰 열은 사용된 4개의 추천시스템 모델에 대응해 나뉘져 있다. 각 칸에는 7개의 편향감소 방법의 정확도와 인기편향 감소 성능이 수치적으로 적혀 있다. 각 칸의 맨 위는 BPR 손실함수를 사용한 베이스라인으로, 높은 정확도, 그리고 높은 인기편향을 보임을 알 수 있다. 굵은 폰트로 표시된 결과는 해당 편향감소 방법이 적은 정확도 손실과 일정 수준 이상의 편향감소를 달성한 좋은 결과임을 나타낸다.

결과에서 Zerosum 방법은 우선 MovieLens, Gowalla, Goodreads 데이터에 대해서 좋은 성능을 보인 것을 알 수 있다. 이 3 데이터에 대해, 특히 MF, NGCF, LightGCN의 추천시스템 모델에서 좋은 성능을 보였다. 하지만 NeuCF의 경우에 대해서는 MovieLens 데이터에서만 좋은 성능을 보이고 나머지 데이터에서는 그렇지 않았다. 또한 Zerosum 방법은 Ciao 데이터에 대해서도 좋은 성능을 보이지 못했다.

다른 방법들의 성능을 비교해보면, PD와 Pearson 방법이 좋은 효과를 보일때도 간혹 있었다. 가령 MovieLens, Goodreads 데이터에서

	Dataset – MovieLens											
	MF			NeuCF			NGCF			LightGCN		
	Hit	NDCG	PopQ	Hit	NDCG	PopQ	Hit	NDCG	PopQ	Hit	NDCG	PopQ
Baseline	0.73	0.48	0.18	0.68	0.44	0.17	0.71	0.46	0.16	0.71	0.45	0.14
IPW	0.41	0.22	0.04	0.43	0.23	0.10	0.40	0.22	0.05	0.42	0.24	0.04
PD	<b>0.72</b>	<b>0.46</b>	<b>0.27</b>	0.40	0.20	0.64	0.70	0.44	0.19	0.68	0.43	0.12
MACR	0.48	0.27	0.02	0.33	0.18	0.07	0.48	0.27	0.02	0.48	0.27	0.02
Pearson	<b>0.73</b>	<b>0.46</b>	<b>0.41</b>	0.68	0.43	0.18	0.62	0.35	0.40	0.59	0.32	0.30
Post Process	0.68	0.37	0.52	0.69	0.43	0.23	0.62	0.32	0.58	0.67	0.38	0.43
Zerosum	<b>0.72</b>	<b>0.45</b>	<b>0.38</b>	<b>0.66</b>	<b>0.34</b>	<b>0.29</b>	<b>0.71</b>	<b>0.44</b>	<b>0.32</b>	<b>0.70</b>	<b>0.44</b>	<b>0.31</b>
	Dataset – Gowalla											
Baseline	0.92	0.71	0.14	0.85	0.61	0.21	0.90	0.66	0.13	0.88	0.62	0.10
IPW	0.86	0.62	0.10	0.19	0.12	0.22	0.30	0.16	0.19	0.77	0.52	0.13
PD	<b>0.92</b>	<b>0.69</b>	<b>0.22</b>	0.77	0.45	0.62	0.90	0.66	0.13	0.87	0.62	0.09
MACR	0.74	0.50	0.11	0.13	0.08	0.36	0.50	0.32	0.10	0.68	0.45	0.12
Pearson	<b>0.92</b>	<b>0.71</b>	<b>0.21</b>	0.81	0.55	0.32	0.90	0.65	0.19	0.86	0.60	0.15
Post Process	0.90	0.58	0.62	0.79	0.57	0.17	0.86	0.51	0.63	0.80	0.45	0.63
Zerosum	<b>0.92</b>	<b>0.69</b>	<b>0.23</b>	0.78	0.52	0.37	<b>0.90</b>	<b>0.60</b>	<b>0.24</b>	<b>0.87</b>	<b>0.58</b>	<b>0.20</b>
	Dataset – Goodreads											
Baseline	0.84	0.61	0.26	0.81	0.57	0.26	0.78	0.51	0.15	0.76	0.50	0.11
IPW	0.47	0.28	0.06	0.31	0.16	0.14	0.32	0.18	0.05	0.49	0.30	0.05
PD	<b>0.84</b>	<b>0.60</b>	<b>0.39</b>	0.68	0.41	0.71	<b>0.77</b>	<b>0.50</b>	<b>0.24</b>	<b>0.73</b>	<b>0.26</b>	<b>0.33</b>
MACR	0.54	0.33	0.01	0.68	0.41	0.71	0.77	0.50	0.24	0.73	0.50	0.33
Pearson	0.84	0.61	0.30	0.80	0.56	0.20	<b>0.77</b>	<b>0.50</b>	<b>0.23</b>	0.74	0.48	0.17
Post Process	0.79	0.46	0.79	<b>0.81</b>	<b>0.56</b>	<b>0.38</b>	0.65	0.33	0.77	0.65	0.33	0.64
Zerosum	<b>0.85</b>	<b>0.60</b>	<b>0.38</b>	0.80	0.52	0.31	<b>0.78</b>	<b>0.50</b>	<b>0.27</b>	<b>0.75</b>	<b>0.48</b>	<b>0.24</b>
	Dataset – Ciao											
Baseline	0.49	0.31	0.20	0.43	0.26	0.19	0.51	0.32	0.19	0.48	0.31	0.12
IPW	0.39	0.24	0.06	0.33	0.21	0.09	0.31	0.14	0.15	0.38	0.24	0.05
PD	0.47	0.29	0.25	0.28	0.13	0.51	0.49	0.30	0.22	0.48	0.30	0.15
MACR	0.42	0.27	0.11	0.31	0.20	0.14	0.36	0.22	0.08	0.40	0.26	0.11
Pearson	0.29	0.17	0.42	0.43	0.26	0.22	0.32	0.15	0.47	0.13	0.06	0.47
Post Process	0.44	0.24	0.36	0.45	0.29	0.12	0.42	0.20	0.46	0.43	0.25	0.27
Zerosum	0.44	0.29	0.20	0.41	0.25	0.23	0.50	0.31	0.22	0.47	0.29	0.16

[표 7] 귀납실험의 결과다. 굵은 글씨는 해당 편향해소 방법이 허용가능한 정확도

손실내에 기준치 이상의 인기편향 해소를 보인 좋은 성능임을 의미한다.

PD와 Pearson 방법이 좋은 경우가 있다. 하지만 이런 방법론들은 Zerosum 방법보다 좋은 성능을 보이는 빈도가 적다. 그외에 PD와 Pearson을 제외한 방법들은 정확도 성능이 비교가 안될 정도로 낮다. 또한 대다수의 방법들은 Zerosum 방법과 마찬가지로 NeuCF와 Ciao 데이터에서 좋은 성능을 보이지 않는다.

결국 Zerosum 방법은 4개 중 3개의 데이터셋에 대해 선행연구의 방법보다 높은 빈도로 정확도와 인기편향의 측면에서 좋은 성능을 보였다. 비록 기존 선행연구의 편향해소 방법의 성능이 Zerosum 방법보다 일부 좋은 경우도 있었지만, 귀납실험의 결과와 앞서 제 5장에서 살펴본 Zerosum 방법의 계산적 장점을 종합하여 Zerosum 방법이 기존 방법에 비해 전반적 향상을 보인다고 결론 내린다.

마지막으로 제안방법이 Ciao 데이터에 대해 좋은 성능을 보이지 않은 이유에 대해 분석한다. Ciao 데이터에 대해 Zerosum 방법은 정확도의 큰 손실을 보이지는 않았지만, 기준치 이상의 인기편향 해소를 보이지 못했다. 한편, Ciao 데이터는 다른 3개의 데이터에 비해 추천시스템들의 기본적인 예측 정확도가 낮은 것을 알 수 있다. 이는 기본적으로 Ciao 데이터는 긍정과 부정 아이템을 추천시스템이 학습하기에 어려운 데이터임을 시사한다. 이러한 데이터에 대해 Zerosum 방법을 적용한다면, 추천시스템이 긍정(부정) 아이템을 잘못 예측하기 때문에, Zerosum 방법은 추천시스템 모델이 예측한 긍정 아이템의 점수차를 줄이지만 실제 긍정 아이템의 점수차는 줄어들지 않을 수도 있다. 결국 Zerosum 방법은 추천시스템 모델의 정확도와 성능이 비례해, 추천시스템 모델의 정확도가 높으면 더욱 좋은 인기편향 해소 성능을 보이고, 추천시스템 모델의 정확도가 낮으면 인기편향 해소가 원활히 이루어지지 않을 수 있다.

## 제 7 장 결 론

### 제 1 절 연구의 요약

본 연구는 추천시스템이 유저가 동일하게 좋아한 아이템 중 인기도가 더 높은 아이템을 더 높은 점수로 추천하는 인기편향 문제를 해결하기 위한 방법을 제시했다. 추천시스템의 인기편향 문제는 유저가 좋아하는 아이템을 공평하게 추천하지 못하고 인기 있는 아이템을 과도하게 추천해 개인화된 추천을 해치는 문제다. 추천시스템의 인기편향을 해소하기 위한 다양한 선행연구가 제시되었는데 이들을 아이템의 인기도에 비례해 추천시스템의 점수를 조정하는 점수조정 방법과, 긍정 아이템의 인기도와 아이템의 예측점수의 상관계수를 제약하는 방법으로 나눌 수 있다. 하지만 선행연구의 방법은 인기편향을 해소하는데 계산적 타당성과 계산적 효율성 측면에서 한계가 있다. 점수조정 방법은 인기편향을 해소하는 과정에서 긍정 아이템의 점수를 낮추고 부정 아이템의 점수를 높여 추천시스템의 정확도를 훼손할 수 있다. 더욱이 많은 점수조정 방법의 원리는 인기도가 높은 아이템의 점수를 낮춘다는 휴리스틱에 기반해 있어 범용성이 떨어진다. 상관계수 제약법의 경우, 의도한 아이템 인기도와 예측점수의 독립이 일어나지 않을 수 있고, 방법 적용을 위해 높은 비용의 연산이 요구된다.

본 연구는 이러한 선행연구의 단점을 극복하고 추천시스템의 정확도 유지와 모델 인기편향을 해소하기 위한 효과적이고 새로운 제안법을 제시한다. 본 연구는 추천시스템의 학습에 사용되는 BPR 손실함수를 확장해 긍정(부정) 아이템들의 점수차를 줄이는 제약항을 이용해

추천시스템의 정확도를 유지하며 동시에 인기편향을 해소하는 방법을 제안한다. 본 연구는 제안방법의 효과를 정량적으로 분석하고 시각적으로 평가하기 위해 가상 데이터를 이용한 체계적인 실험을 진행한다. 인기도 분포에 차이가 나는 가상 데이터를 설계해 BPR 손실함수를 이용한 추천시스템의 학습 시 모델 인기편향이 나타나는 것을 확인한다. 나아가 가상 데이터를 활용한 실험에서 3가지 제약항을 사용하는 방법을 비교해, 유저의 긍정 아이템과 부정 아이템의 예측점수의 합이 0이 되도록 제약하는 Zerosum 제약항이 추천시스템의 정확도 유지와 모델 인기편향 해소에 효과적임을 확인한다. 본 연구는 Zerosum 방법을 선행연구의 방법론과 비교해 Zerosum 방법이 가상 데이터를 사용한 실험에서 선행연구의 방법론에 비해 정량적으로 높은 성능을 보이고, 계산적 타당성과 효율성 측면에서 장점이 있어 선행연구의 단점을 극복함을 보였다. 본 연구는 최종적으로 귀납실험을 통해 Zerosum 방법의 효과를 검증했으며 Zerosum 방법이 선행연구의 방법론에 비해 전반적으로 향상된 성능을 보이는 효과적인 방법론임을 선보였다.

결과적으로 본 연구는 추천시스템의 모델 인기편향을 줄이는 새로운 제안방법을 제시하고, 제안방법이 추천시스템의 정확도 유지와 인기편향 감소에 효과적이고, 선행연구의 인기편향 해소 방법론보다 뛰어남을 다방면의 근거를 통해 심도 있게 입증했다.

## 제 2 절 연구의 의의

본 연구의 의의를 크게 3가지로 정리할 수 있다. 첫째, 본 연구는

추천시스템의 인기편향을 해소하는 참신한 방법을 제시했다. 본 연구는 선행연구의 인기편향 해소 방법의 한계를 파악하고 이를 효과적으로 극복하기 위해 머신러닝의 대조학습의 정신에 기인한 해결책을 제시했다는 점에서 높은 독창성을 뛴다. 특히, 본 연구에서 제안된 제약항들은 머신러닝 및 딥러닝의 영역에서 집중적으로 탐구된 적이 없는 형태다. 머신러닝 및 딥러닝의 영역에선 데이터의 모델 예측점수에 차이가 나타나는게 큰 문제가 되지 않지만, 같은 현상은 추천시스템의 영역에서 인기편향이라는 문제가 되며, 본 연구와 같이 긍정 아이템의 예측점수의 격차를 줄이는 손실함수는 새로운 가치를 가진다. 본 연구는 추천시스템의 영역에서 나타나는 고유 문제를 해결하기 위해 머신러닝의 아이디어를 변형해 효과적으로 연결하여 독창적 가치를 창출했다. 이 결과 본 연구에서 제안된 방법은 기존 편향해소 방법에 기반한 점진적 향상이 아닌, 기존 방법과 질적으로 다르게 작동해 기존 방법의 단점을 극복하고 낮은 계산 비용으로 높은 성능을 보이는 인기편향 해소의 획기적인 새 방법론으로 기능한다.

둘째, 제안한 Zerosum 방법의 효과가 뛰어나다. 인기편향 해소 방법으로서의 Zerosum 방법은 다양한 이점을 가지고 있다. 첫째로 Zerosum 방법은 정량적 성능에서 강점을 가진다. 가상 데이터를 활용한 실험에서 Zerosum 방법은 추천시스템의 높은 정확도를 유지하며 인기편향을 대폭 감소하는 결과를 보이며, 선행연구보다 정확도와 인기편향의 측면 모두에서 우월한 성능을 보였다. 또, 귀납실험에서 Zerosum 방법은 선행연구의 방법론에 비해 더 빈번히 정확도 유지와 인기편향 감소에서 좋은 성능을 보였다. 둘째, Zerosum 방법은 계산적 타당성과 계산적 효율성 측면에서 강점을 가지며, 선행연구의 한계를 극복한다. 계산적 타당성의 측면에서 Zerosum 방법의 제약항은, 그

수식설계가 긍정(부정) 아이템 간의 점수차이를 줄일 뿐, 점수조정 방법과 같이 긍정 아이템의 점수를 희생해 부정 아이템의 점수를 높이지 않는다. 또한 Zerosum 방법은 수식설계의 직관성에 따라 범용적인 추천시스템 모델의 학습에 적용이 가능하다. 계산적 효율성의 측면에서 Zerosum 방법은 널리 사용되는 BPR 손실함수의 작은 수정만으로 쉽게 사용 가능해 인기편향 감소를 위한 추가적 학습이나 계산이 필요하지 않다. 그리고 Zerosum 방법은 미니배치 형식의 효율적인 학습으로 긍정 아이템의 점수와 부정 아이템의 점수 모두를 제약해 안정적인 인기편향 해소를 수행한다. 마지막으로 Zerosum 방법은 기존의 대부분의 인기해소 방법과 다르게 아이템의 인기도 정보를 활용하지 않으면서도 효과적이고 세부적인 인기편향 해소가 가능하다는 장점이 있다.

마지막으로, 본 연구는 제안방법의 효과를 입증하기 위해 양적, 질적 분석을 포함해 심도 있는 근거를 제시했다는 의의가 있다. 연구의 높은 신뢰도에 기여한 요소는 다음과 같다. 첫째, 본 연구는 가상 데이터를 활용해 추천시스템에서 발생하는 인기편향과 각종 편향 해소 방법의 효과를 직관적으로 파악했다. 가상 데이터는 인기편향과 제안방법의 효과에 대해 정량적 분석과 더불어 정성적 분석도 가능하게 하며, 각종 편향해소 방법의 장단점과 동작을 파악하는데 도움을 줘 연구의 논리를 강화한다. 둘째, 본 연구는 제안방법의 특징에 대해 심도 있게 분석해 최고의 제약항을 제시했다. 본 연구는 Pos2, Pos2Neg2, Zerosum이라는 다양한 제약항의 형태와 하이퍼파라미터의 효과를 탐구해 제약항에 대한 이해를 높임과 더불어 Zerosum 제약항이 제시된 제약항 중 최고의 성능을 보임을 확인했다. 셋째, 본 연구는 제안방법의 독자적 성능만 분석한 것이 아닌, 제안방법을 선행연구의 다양한 인기편향 해소 방법과 비교해 제안방법이 기존 방법론의 단점을

극복하고 우수한 성능을 보임을 입증했다. 마지막으로 본 연구는 심도 있는 귀납실험을 통해, 실제 데이터와 추천시스템 모델에서 제안방법이 가지는 성능을 실험하고, 제안방법이 기존 방법론에 비해 전반적인 귀납적 성능 향상을 보임을 밝혔다.

### 제 3 절 연구의 한계

본 연구는 두가지 측면에서 한계가 있다. 첫째는 실제 데이터에서의 제안방법인 Zerosum 제약항의 효과가 가상 데이터에서의 효과만큼 뛰어나지 않다는 점이다. Zerosum 제약항은 가상 데이터에서는 완벽한 정확도 유지와 인기편향 감소를 보였지만, 실제 데이터를 사용한 귀납실험의 결과는 이에 미치지 못했다. 제안방법의 성능은 낮은 밀도와 높은 노이즈를 보이는 실제 데이터에서 한계를 보이는 것이다. 물론 Zerosum 방법은 귀납실험에서 다른 편향해소 방법보다 뛰어난 성능을 보인다는 점에서 유효하나, 후속 연구에서 실제 데이터에서도 제안방법의 높은 정확도와 인기편향 해소 성능을 유지할 수 있는 방법이 연구되어야 한다. 두번째 한계는 연구의 논리가 귀납적 검증에 의존하고 이론적 근거가 떨어진다는 점이다. 본 연구는 가상 데이터를 활용해 각종 편향해소 방법의 동작을 질적으로 분석해 논리를 전개했다. 이는 직관적인 타당성을 띠지만, 반대로 본 연구에서 제안방법의 효과를 입증하기 위한 수리통계적 근거를 제공하지 못했다는 한계가 있다. 본 연구의 귀납적 발견을 토대로 추후 제안방법의 논리를 보강할 이론적 연구가 수행 될 수 있다.

## 제 4 절 후속연구

본 연구는 대조학습의 정신을 추천시스템의 인기편향의 해소에 적용해, 인기편향 해소의 새로운 관점을 제공했다는 점에서 다양한 후속연구를 가능케 한다. 가령, 본 연구에서 실험한 제약항 이외에도 제약항의 형태를 일부 조절해 심화된 형태의 제약항을 실험할 수 있다. 유저의 긍정과 부정 아이템의 점수차를 벌리고, 유저의 긍정(부정) 아이템의 점수를 줄인다는 정신에 입각해 다양한 형태의 손실함수를 연구할 수 있는 것이다.

다음으로 앞서 연구의 한계로 지적된, 실제 데이터에서의 성능을 향상하는 방향의 후속연구다. 제안방법은 가상 데이터가 아닌 실제 데이터에서 정확도와 인기편향 해소 성능이 떨어졌으며, 가상 데이터를 활용한 실험에서도 아이템 소비가 적은 유저에 대해 취약한 면을 보였다. 이에 따라 가상 데이터 외의 데이터에서 제안방법의 성능을 향상시키고, 아이템 소비가 적은 유저에 대해서도 높은 정확도와 인기편향 해소 성능을 유도하도록 제안방법을 개선해야 한다. 이때, 제약항의 하이퍼파라미터를 유저의 소비 아이템에 따라 조절한다면 아이템 소비가 적은 유저의 정확도를 유지하며 인기편향을 해소할 수 있을 것이다. 마지막으로 본 연구에서 미흡한, 제안방법의 효과를 수리통계적으로 입증할 수 있는 이론적 연구가 가능하다. 가령 Pos2Neg2 방법과 Zerosum 방법 중 Zerosum 방법이 더 정확한 수리통계적 근거를 찾을 수 있다면 더 높은 정확도의 제약항을 개발할 수 있을 것이다. 후속연구를 통해 제안방법을 발전시키면 더 정확하고 편향이 없는 개인화된 추천을 달성할 수 있다.

## 참고 문헌

- [1] Abdollahpouri, H., Burke, R., & Mobasher, B. (2017, August). Controlling popularity bias in learning-to-rank recommendation. In *Proceedings of the eleventh ACM conference on recommender systems* (pp. 42–46).
- [2] Abdollahpouri, H., Burke, R., & Mobasher, B. (2019, May). Managing popularity bias in recommender systems with personalized re-ranking. In *The thirty-second international flairs conference*.
- [3] Abdollahpouri, H., Mansoury, M., Burke, R., & Mobasher, B. (2020, September). The connection between popularity bias, calibration, and fairness in recommendation. In *Fourteenth ACM conference on recommender systems* (pp. 726–731).
- [4] Adomavicius, G., Tuzhilin, A., Berkovsky, S., De Luca, E. W., & Said, A. (2010, September). Context-awareness in recommender systems: research workshop and movie recommendation challenge. In *Proceedings of the fourth ACM conference on Recommender systems* (pp. 385–386).
- [5] Anderson, A., Maystre, L., Anderson, I., Mehrotra, R., & Lalmas, M. (2020, April). Algorithmic effects on the diversity of consumption on spotify. In *Proceedings of The Web Conference 2020* (pp. 2155–2165).
- [6] Aridor, G., Goncalves, D., & Sikdar, S. (2020, September). Deconstructing the filter bubble: User decision-making and recommender systems. In *Fourteenth ACM Conference on Recommender Systems* (pp. 82–91).
- [7] Boratto, L., Fenu, G., & Marras, M. (2021). Connecting user and item perspectives in popularity debiasing for collaborative recommendation. *Information Processing & Management*, 58(1),

102387.

- [8] Chen, J., Dong, H., Wang, X., Feng, F., Wang, M., & He, X. (2020). Bias and debias in recommender system: A survey and future directions. *arXiv preprint arXiv:2010.03240*.
- [9] Chen, J., Wang, X., Feng, F., & He, X. (2021, September). Bias Issues and Solutions in Recommender System: Tutorial on the RecSys 2021. In *Fifteenth ACM Conference on Recommender Systems* (pp. 825–827).
- [10] Cho, E., Myers, S. A., & Leskovec, J. (2011, August). Friendship and mobility: user movement in location-based social networks. In *Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 1082–1090).
- [11] Chopra, S., Hadsell, R., & LeCun, Y. (2005, June). Learning a similarity metric discriminatively, with application to face verification. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)* (Vol. 1, pp. 539–546). IEEE.
- [12] Ge, Y., Zhao, S., Zhou, H., Pei, C., Sun, F., Ou, W., & Zhang, Y. (2020, July). Understanding echo chambers in e-commerce recommender systems. In *Proceedings of the 43rd international ACM SIGIR conference on research and development in information retrieval* (pp. 2261–2270).
- [13] Harper, F. M., & Konstan, J. A. (2015). The movielens datasets: History and context. *Acm transactions on interactive intelligent systems (tiis)*, 5(4), 1–19.
- [14] 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).

- [15] He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T. S. (2017, April). Neural collaborative filtering. In *Proceedings of the 26th international conference on world wide web* (pp. 173–182).
- [16] Joachims, T., Swaminathan, A., & Schnabel, T. (2017, February). Unbiased learning-to-rank with biased feedback. In *Proceedings of the tenth ACM international conference on web search and data mining* (pp. 781–789).
- [17] Koren, Y. (2008, August). Factorization meets the neighborhood: a multifaceted collaborative filtering model. In *Proceedings of the 14th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 426–434).
- [18] Le-Khac, P. H., Healy, G., & Smeaton, A. F. (2020). Contrastive representation learning: A framework and review. *IEEE Access*, 8, 193907–193934.
- [19] Li, M., Wu, H., & Zhang, H. (2019). Matrix factorization for personalized recommendation with implicit feedback and temporal information in social ecommerce networks. *IEEE Access*, 7, 141268–141276.
- [20] Liu, Z., Ma, Y., Ouyang, Y., & Xiong, Z. (2021). Contrastive learning for recommender system. *arXiv preprint arXiv:2101.01317*.
- [21] Lu, J., Hu, J., & Zhou, J. (2017). Deep metric learning for visual understanding: An overview of recent advances. *IEEE Signal Processing Magazine*, 34(6), 76–84.
- [22] Mansoury, M., Abdollahpouri, H., Pechenizkiy, M., Mobasher, B., & Burke, R. (2020, October). Feedback loop and bias amplification in recommender systems. In *Proceedings of the 29th ACM international*

*conference on information & knowledge management* (pp. 2145–2148).

- [23] Nguyen, T. T., Hui, P. M., Harper, F. M., Terveen, L., & Konstan, J. A. (2014, April). Exploring the filter bubble: the effect of using recommender systems on content diversity. In *Proceedings of the 23rd international conference on World wide web* (pp. 677–686).
- [24] Oord, A. V. D., Li, Y., & Vinyals, O. (2018). Representation learning with contrastive predictive coding. *arXiv preprint arXiv:1807.03748*.
- [25] Park, Y. J., & Tuzhilin, A. (2008, October). The long tail of recommender systems and how to leverage it. In *Proceedings of the 2008 ACM conference on Recommender systems* (pp. 11–18).
- [26] Rendle, S., Freudenthaler, C., Gantner, Z., & Schmidt-Thieme, L. (2012). BPR: Bayesian personalized ranking from implicit feedback. *arXiv preprint arXiv:1205.2618*.
- [27] Schnabel, T., Swaminathan, A., Singh, A., Chandak, N., & Joachims, T. (2016, June). Recommendations as treatments: Debiasing learning and evaluation. In *international conference on machine learning* (pp. 1670–1679). PMLR.
- [28] Schroff, F., Kalenichenko, D., & Philbin, J. (2015). Facenet: A unified embedding for face recognition and clustering. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 815–823).
- [29] Steck, H. (2011, October). Item popularity and recommendation accuracy. In *Proceedings of the fifth ACM conference on Recommender systems* (pp. 125–132).
- [30] Takács, G., Pilászy, I., Németh, B., & Tikk, D. (2008, October). Matrix factorization and neighbor based algorithms for the netflix prize

problem. In *Proceedings of the 2008 ACM conference on Recommender systems* (pp. 267–274).

[31] Tang, J., Gao, H., & Liu, H. (2012, February). mTrust: Discerning multi-faceted trust in a connected world. In *Proceedings of the fifth ACM international conference on Web search and data mining* (pp. 93–102).

[32] Wan, M., & McAuley, J. (2018, September). Item recommendation on monotonic behavior chains. In *Proceedings of the 12th ACM conference on recommender systems* (pp. 86–94).

[33] Wan, M., Misra, R., Nakashole, N., & McAuley, J. (2019). Fine-grained spoiler detection from large-scale review corpora. *arXiv preprint arXiv:1905.13416*.

[34] Wang, W., Feng, F., He, X., Wang, X., & Chua, T. S. (2021, August). Deconfounded recommendation for alleviating bias amplification. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining* (pp. 1717–1725).

[35] 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).

[36] Wei, T., Feng, F., Chen, J., Wu, Z., Yi, J., & He, X. (2021, August). Model-agnostic counterfactual reasoning for eliminating popularity bias in recommender system. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining* (pp. 1791–1800).

[37] Zhang, M., & Hurley, N. (2008, October). Avoiding monotony: improving the diversity of recommendation lists. In *Proceedings of the 2008 ACM conference on Recommender systems* (pp. 123–130).

- [38] Zhang, Y., Feng, F., He, X., Wei, T., Song, C., Ling, G., & Zhang, Y. (2021, July). Causal intervention for leveraging popularity bias in recommendation. In *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 11–20).
- [39] Zhao, Z., Chen, J., Zhou, S., He, X., Cao, X., Zhang, F., & Wu, W. (2022). Popularity bias is not always evil: Disentangling benign and harmful bias for recommendation. *IEEE Transactions on Knowledge and Data Engineering*.
- [40] Zheng, Y., Gao, C., Li, X., He, X., Li, Y., & Jin, D. (2021, April). Disentangling user interest and conformity for recommendation with causal embedding. In *Proceedings of the Web Conference 2021* (pp. 2980–2991).
- [41] Zhou, C., Ma, J., Zhang, J., Zhou, J., & Yang, H. (2021, August). Contrastive learning for debiased candidate generation in large-scale recommender systems. In *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining* (pp. 3985–3995).
- [42] Zhu, Z., He, Y., Zhao, X., Zhang, Y., Wang, J., & Caverlee, J. (2021, March). Popularity–opportunity bias in collaborative filtering. In *Proceedings of the 14th ACM International Conference on Web Search and Data Mining* (pp. 85–93).
- [43] Zhu, Z., Wang, J., & Caverlee, J. (2020, July). Measuring and mitigating item under-recommendation bias in personalized ranking systems. In *Proceedings of the 43rd international ACM SIGIR conference on research and development in information retrieval* (pp. 449–458).

## Abstract

# Reducing Popularity Bias in Recommendation System by Regularizing Model Prediction Scores

Wondo Rhee

Department of Information and Intelligence  
The Graduate School of Convergence Science and  
Technology  
Seoul National University

Recommendation system often suffers from popularity bias. In particular, the recommendation system can give higher recommendation score to items with higher popularity even among items the user equally liked. This can lead to over-recommendation of popular items, which can harm personalization. To solve this problem, we propose to add a regularization term to the loss function during training: a regularization term which minimizes the score differences of positive and negative items, respectively, is added to the original loss function. The Zerosum term which constraints the sum of the positive and negative item scores of a user to be 0 is proved to be effective. The effectiveness of the method is demonstrated using a synthetic data; the recommendation system accuracy is maintained while the popularity bias is reduced. Further comparison with earlier debias methods shows the proposed method has advantages in terms of computational validity and efficiency. Finally, experiments on 4

recommendation system models and 4 real world datasets reported the proposed method shows generally improved performances over earlier methods. Thus, this study proposes a novel and effective method to reduce popularity bias in recommendation system.

**Keywords :** recommendation system, popularity bias, regularization

**Student Number :** 2021-20929