

이윤 고려 추천 시스템에 대한 비교 평가

장해리¹, 배홍균², 김상욱^{3*}

¹ 한양대학교 컴퓨터소프트웨어학과 석사과정

² 한양대학교 컴퓨터소프트웨어학과 박사과정

³ 한양대학교 컴퓨터소프트웨어학과 교수

{harryyyyy, hongkyun, wook}@hanyang.ac.kr

Profit-aware Recommender Systems: A Comparative Study

Hae-Ri Jang¹, Hong-Kyun Bae², Sang-Wook Kim^{3*}

Dept. of Computer Science, Hanyang University

요 약

추천 시스템 연구들 중 사용자의 추천 만족도와 플랫폼의 이윤 측면을 함께 고려한 여러 연구들이 제안되어 왔다. 그런데 그동안 플랫폼의 이윤을 고려한 추천 시스템의 경우 방법들 간 분석 및 성능 비교가 되어오지 않았다. 본 논문에서는 먼저 기존 이윤 고려 추천 시스템들의 방법을 분석하고, 실 세계 데이터셋을 이용한 실험을 통해 추천 정확도 및 플랫폼 이윤 측면에서 이들 간의 성능을 비교하였다. 그 결과, 추천 정확도와 플랫폼 이윤 간의 상충 관계가 있음을 확인할 수 있었고, 이윤 고려 추천 시스템 방법들이 이윤을 고려하지 않은 일반적인 추천 방법 대비 7~35%의 플랫폼 이윤 향상 효과가 있음을 관찰할 수 있었다.

1. 서론

추천 시스템은 사용자가 과거에 이용했던 아이템들의 기록을 이용하여 사용자의 취향을 추론하고, 사용자가 선호할 만한 아이템들을 추천하는 방법이다. 이에 추천 시스템을 위한 연구는 주로 사용자의 추천 만족도 향상을 위해, 추천 정확도를 높이는 것에 목표를 두고 진행되어 왔다.

반면, 추천 시스템을 제공하는 플랫폼 서비스 (예: 아마존, 타오바오 등) 입장에서는 추천 시스템의 정확도 향상뿐만 아니라, 추천 시스템을 통한 사용자들로부터의 직접적인 수익 (이윤) 증가 또한 중요한 목표가 될 수 있다. 이를 위해, 각 아이템이 플랫폼에 주는 이윤을 고려하여, 각 사용자에게 사용자가 만족할 뿐만 아니라 이윤이 높은 아이템들을 추천함으로써 플랫폼의 이윤을 높이고자 하는, 이윤 고려 추천 시스템에 관한 연구가 수행되어 왔다.

이윤 고려 추천 시스템은 특히 산업계에서 활발히 연구되어 왔으며, 대표적인 방법들로는 HPPRS [1], PUMA [2], LETORIF [3], Sponsored-Rec [4], CXR-RL [5],

PE-LTR [6], RevMan [7]이 존재한다. 하지만, 해당 연구들 간의 방법론적인 분석 및 성능 비교는 그동안 거의 이루어지지 않았다. 이에 본 논문에서는 각 이윤 고려 추천 시스템을 소개하고, 여러 협업 필터링 추천 모델들을 베이스 모델로 이용하여, 추천 정확도와 플랫폼 이윤 측면에서 이윤 고려 추천 시스템들의 성능을 비교해보고자 한다.

본 논문 구성은 다음과 같다. 2 장에서 대표적인 이윤 고려 추천 시스템들에 대해 소개한다. 3 장에서는 해당 방법들의 추천 정확도 및 플랫폼 이윤 측면에서의 성능 분석을 수행한 실험 결과를 보인다. 4 장에서는 결론으로 끝을 맺는다.

2. 이윤 고려 추천 시스템들

본 장에서 대표적인 이윤 고려 추천 시스템들[1, 2, 3, 4, 5, 6, 7]에 대해 요약한다.

이윤 고려 추천 시스템의 기존 연구들은 주로 사전 학습된 추천 모델에 대한 사용자의 아이템 예측 선호도와 아이템의 이윤을 결합하여 사용자에게 아이템을 추천한다. 이 때 초기 연구[1, 2]는 사용자의 아이템

* 교신 저자

예측 선호도와 아이템의 이윤을 곱한 값이 높은 순, 즉 예측된 기대 수익이 높은 순으로 사용자에게 아이템을 추천하였다. 또한 LETORIF [3]는 클릭 예측 모델과 구매 예측 모델을 각각 두고 추천 모델을 학습하여 예측된 클릭 확률, (클릭 시) 예측된 구매 확률, 아이템 이윤의 곱이 높은 순으로 아이템을 추천하였다. Sponsored-Rec [4]은 플랫폼에게 이윤을 주는 일부 광고 아이템들의 존재를 가정하고, 사용자의 아이템 예측 선호도와 아이템의 이윤을 선형 결합한 값이 높은 순으로 사용자에게 아이템을 추천하였다.

PE-LTR [6]은 위 방법들과 달리 추천 모델 학습 단계에서 추천 정확도와 플랫폼 이윤을 함께 고려하는 방법이다. PE-LTR 은 다중 목표 달성을 위해 사용자 만족도를 위한 목적 함수와 플랫폼 이윤을 위한 목적 함수를 선형 결합한 다중 목적 함수를 통해 추천 모델을 학습하는 방법을 제안하였다. 이 때 두 목적 함수의 선형 결합 시 가중치를 고정된 값으로 사용하는 것이 아닌, 최적화 기법을 이용해 각 배치마다 모델 파라미터뿐만 아니라 가중치를 조절해 나가며 추천 모델을 학습하였다.

마지막으로, CXR-RL [5], RevMan [7]은 사전 학습된 추천 모델이 있을 때, 강화학습을 이용해 사용자의 아이템 추천 랭킹을 다시 매기는 모델을 추가적으로 학습하였다. 이 때 리워드를 플랫폼의 기대 이윤으로 정의하여 기대 이윤이 높아지는 방향으로 모델을 학습하였다. CXR-RL [5]은 사용자의 예측 선호도와 가격 간 중요도 조절 파라미터를, RevMan [7]은 각 아이템 별 순위 조절 파라미터를 학습하고, 사전 학습된 추천 모델과 강화학습을 통해 학습된 모델의 예측 결과를 결합하여 사용자에게 아이템을 추천하였다.

3. 실험

3.1 실험 환경

본 논문은 Amazon-video games 5-core 데이터셋을 이용해 실험을 수행하였다. 각 아이템의 이윤 정보는 Amazon 의 메타 데이터 내 아이템 가격 정보를 이용하였다. 이 때, 가격 정보가 존재하지 않는 아이템들은 실험에서 제외하였다. <표 1>은 우리가 사용한 데이터셋에 관한 통계 정보를 보인다. 데이터셋에 대해 트레이닝 셋, 검증 셋, 테스트 셋의 비율은 6:2:2 로 설정하였고, 실험 결과는 검증 셋에 대해 가장 높은 recall 값을 가지는 에폭을 기준으로 테스트 셋에 대한 모델 성능을 측정하였다.

<표 1> 데이터셋 통계 정보

사용자	아이템	상호작용	희소성
24,286	10,477	228,961	99.91%

3.2 실험 방법

성능 평가를 위해 사용자의 아이템 추천 정확도는 precision@100, recall@100, 플랫폼 이윤은 revenue@100 을 측정하였다. 이 때 플랫폼 이윤은 사용자가 플랫폼에 주는 아이템 이윤의 기댓값으로 정의했으며 구체적인 수식은 아래와 같다.

$$Revenue@K = \frac{1}{|U|} \sum_{u \in U} \sum_{r_u \leq K} (price(i) \cdot \varphi(u, i))$$

해당 척도는 각 사용자 u 에게 추천된 top-K 아이템 랭킹 리스트 r_u 에 대하여 사용자가 이용한 아이템들의 가격 합에 대한 사용자 별 평균값을 의미한다. $\varphi(u, i)=1/0$ 은 사용자 u 의 아이템 i 이용 여부를 뜻한다.

또한 비교 방법들로는 이윤에 대한 고려 없이 추천 정확도만 고려한 경우 (Baseline), HPPRS [1], Sponsored-Rec [4], PE-LTR [6]을 이용하였으며, 각 이윤 고려 추천 시스템을 위한 베이스 추천 모델들로는 대표적인 협업 필터링 기법들인 MF [8], NeuMF [9], AutoRec [10], CDAE [11]를 사용하였다.

Sponsored-Rec 의 경우, AutoRec, MF, CDAE, NeuMF 에 대한 선형 결합 가중치 값을 각각 0.003, 0.005, 0.005, 0.007 로 설정하였다. 또한 옵티마이저는 Adam, 학습률은 0.001, 트레이닝 셋의 네거티브 샘플링 비율은 1 배로 설정하여 실험을 수행하였다.

3.3 실험 결과

<표 2> 이윤 고려 추천 시스템들의 성능 분석

모델	방법	평가 척도		
		Precision	Recall	Revenue
MF	Baseline	0.0045	0.3006	23.12
	HPPRS	0.0035	0.2356	29.37
	Spons-R	0.0044	0.2928	26.10
	PE-LTR	0.0044	0.2848	22.69
NeuMF	Baseline	0.0033	0.2187	15.93
	HPPRS	0.0026	0.1817	21.54
	Spons-R	0.0032	0.2135	18.65
	PE-LTR	0.0033	0.2148	17.04
AutoRec	Baseline	0.0054	0.3542	27.56
	HPPRS	0.0051	0.3384	31.85
	Spons-R	0.0052	0.3455	30.45
	PE-LTR	0.0054	0.3557	29.45
CDAE	Baseline	0.0046	0.2995	23.16
	HPPRS	0.0038	0.2460	29.59
	Spons-R	0.0045	0.2898	26.51
	PE-LTR	0.0046	0.2853	25.53

<표 2>는 베이스 모델에 대한 이윤 고려 추천 시스템들의 성능을 보여준다. 베이스 모델에 따른 성능 차이는 있었지만, 이윤 고려 추천 시스템 방법들에 대해 일관성 있는 실험 결과를 확인할 수 있었다.

HPPRS [1] 방법의 경우 이윤이 높은 아이템들을 상위 랭킹에 노출함으로써 플랫폼 이윤을 가장 크게 증가시킬 수 있는 것으로 확인했다. 해당 방법은 MF,

NeuMF, AutoRec, CDAE 에서 baseline 대비 각각 플랫폼 이윤 측면에서 27%, 35%, 15%, 27%의 향상을 보였다. 그러나 추천 정확도의 경우, baseline 대비 precision 은 6~23%, recall 은 5~22%의 손실이 나타남을 확인하였다. 즉, 해당 방법은 단기적으로 플랫폼 이윤을 높일 수는 있으나 사용자 만족도를 크게 해치기 때문에 도입에 있어 신중한 고려가 요구되며, 두 목표 간 상충 관계가 있음을 확인할 수 있었다.

반면 Sponsored-Rec 과 PE-LTR 방법의 경우 추천 정확도만 고려한 방법 대비 추천 정확도의 손실이 거의 일어나지 않으며, 플랫폼 이윤을 향상시킬 수 있음을 확인하였다. Sponsored-Rec 은 MF 와 CDAE 에서 추천 정확도에서 약 3% 내의 손실이 있었으나 플랫폼 이윤에서 12~14%의 향상이 있음을 확인하였다. PE-LTR 은 AutoRec, NeuMF 에서 0~2%의 추천 정확도 손실이 있었으나, 플랫폼 이윤 측면에서 약 7%의 향상이 있음을 확인하였다.

4. 결론

본 논문에서 이윤 고려 추천 시스템들의 방법들을 분석하고, (1) 추천 정확도 관점 (2) 플랫폼의 이윤 관점에서 성능을 비교했다. 실험을 통해 추천 정확도와 플랫폼의 이윤 간 상충 관계가 있을 수 있으며, 이윤 고려 추천 시스템 중 Sponsored-Rec, PE-LTR 방법의 경우 추천 정확도의 큰 손실 없이 플랫폼의 이윤을 향상시킬 수 있음을 보였다.

사사

이 논문은 2023 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구이고(No.RS-2022-00155586, 실세계의 다양한 다운스트림 태스크를 위한 고성능 빅 하이퍼그래프 마이닝 플랫폼 개발(SW 스타랩), 2022 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2022-0-00352). 또한, 2018 년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No.2018R1A5A7059549).

참고문헌

- [1] L. Chen et al., “Developing recommender systems with the consideration of product profitability for sellers,” in *Information Sciences*, Vol.178, Issue 4, pp. 1032–1048, 2008.
- [2] A. Azaria et al., “Movie Recommender System for Profit Maximization,” in *ACM Conference on Recommender Systems*, 2013, pp. 121–128.
- [3] L. Wu et al., “Turning Clicks into Purchases Revenue Optimization for Product Search in E-commerce,” in *ACM SIGIR Conference on Research & Development in Information Retrieval*, 2018, pp. 365-374.
- [4] EC. Malthouse et al., “An Algorithm for Allocating Sponsored Recommendations and Content: Unifying

Programmatic Advertising and Recommender Systems,” in *Journal of Advertising*, Vol. 48, Issue 4, pp. 366-379, 2019.

- [5] C. Pei et al., “Value-aware Recommendation based on Reinforcement Profit Maximization,” in *International Conference on World Wide Web*, 2019, pp. 3123-3129.
- [6] X. Lin et al., “A Pareto-Efficient Algorithm for Multiple Objective optimization in e-commerce recommendation,” in *ACM Conference on Recommender Systems*, 2019 pp. 20-28.
- [7] Y. Li et al., “RevMan: Revenue-aware Multi-task Online Insurance Recommendation,” in *AAAI Conference on Artificial Intelligence*, 2021, pp. 303-310.
- [8] Y. Koren et al., “Matrix Factorization Techniques for Recommender Systems,” in *Computer Society*, Vol. 42, Issue 8, pp. 30-37, 2009.
- [9] X. He et al., “Neural collaborative filtering,” in *International Conference on World Wide Web*, 2017, pp. 173-182.
- [10] S. Sedhain et al., “AutoRec: Autoencoders Meet Collaborative Filtering,” in *International Conference on World Wide Web*, 2015, pp. 111-112.
- [11] Y. Wu et al., “Collaborative denoising auto-encoders for top-N recommender systems,” in *ACM International Conference on Web Search and Data Mining*, 2016, pp.153-162.