

단일-클래스 환경에서 무관심 상품 결정 기술들의 성능 평가*

이연창, 김상욱†
한양대학교 컴퓨터·소프트웨어학과
e-mail: {lyc0324, wook}@hanyang.ac.kr

Performance Evaluation of Techniques Determining Uninteresting Items in One-Class Setting

Yeon-Chang Lee, Sang-Wook Kim
Dept. of Computer and Software, Hanyang University

요 약

협업 필터링 기술은 명시적 피드백이 아닌 암시적 피드백이 주어졌을 때 다음과 같은 문제 (단일-클래스 협업 필터링 문제)를 갖는다: (1) 사용자의 취향을 정확하게 파악하기 어렵다; (2) 상대적으로 더 희소(sparse)하다. 최근, 이러한 단일-클래스 협업 필터링 문제를 완화하기 위해, 사용자가 관심이 없을 것으로 예상되는 무관심 상품을 추가로 활용하는 기술이 제안되었다. 그러나, 이 기술은 무관심 상품을 찾는 과정에서 사용자가 평가하지 않은 상품에 대한 선호 정도를 추론할 때 한 가지 기술만을 사용하였다. 본 논문에서는, 다양한 기술들을 기반으로 무관심 상품을 찾은 후 각 기술에 의한 무관심 상품의 정확도를 비교함으로써, 어떠한 기술이 무관심 상품 결정에 가장 효과적인지를 분석하고자 한다.

1. 서론

추천 시스템의 목표는 사용자들의 과거 이용 기록을 분석하여 사용자의 취향을 추론하고, 이를 기반으로 해당 사용자가 선호할 만한 상품을 찾아 제시해 주는 것으로, 다양한 응용 분야에서 활용되어 오고 있다(예: 영화 추천, 음악 추천)[1]. 협업 필터링(collaborative filtering, CF)은 추천 기술 중 가장 활발히 연구되어 오고 있는 기술이다. 이 기술은 사용자가 상품들에 표현한 선호도를 기반으로 수행되는데, 이러한 선호도는 크게 명시적 피드백(다중-클래스 환경)과 암시적 피드백(단일-클래스 환경)으로 표현된다.

실세계에서는 다중-클래스 환경보다 단일-클래스 환경의 데이터 집합이 더 흔하게 사용되지만, 이러한 단일-클래스 환경에 기존 협업 필터링 기술들을 적용할 경우 다음과 같은 두 가지 문제 상황들이 발생할 수 있다. 우리는 이러한 문제들을 단일-클래스 협업 필터링(one-class collaborative filtering, OCCF) 문제[2]라 부른다. 첫째, 단일-클래스 환경의 데이터 집합은 사용자들의 평가 혹은 구매 유무의 정보만을 가지기 때문에, 평가 혹은 구매한 상품들에 대한 사용자의 상대적인 선호도가 구별되지 않는다. 둘째, 대부분의 단일-클래스 환경의 데이터 집합은 다중-클래스 환경의

데이터 집합보다 상대적으로 더 희소(sparse)하다고 알려져 있다[2].

최근 이러한 OCCF 문제를 다루기 위해, 사용자가 관심이 없을 것으로 예상되는 무관심 상품(uninteresting items, U-items)[3]을 추가로 활용하는 gOCCF 라는 기술이 제안되었다[4]. 그러나, 이 기술은 무관심 상품을 찾는 과정에서 사용자가 평가하지 않은 상품에 대한 선호 정도를 추론할 때, 기존에 잘 알려진 WRMF 기술[2]만을 사용하였다.

따라서, 본 논문에서는 다양한 기술들에 의해 결정된 무관심 상품들의 정확도를 비교함으로써, 어떠한 기술이 단일-클래스 협업 필터링 환경에서 무관심 상품을 결정하는 데 가장 효과적인지 분석하고자 한다.

2. 관련 연구

2.1 Zero-Injection

Hwang et al[3]은 다중-클래스 환경에서 사용자가 평가하지 않은 상품들 중 $\theta\%$ 를 무관심 상품으로 도출하여 추가적인 부정적인 선호도(0 점)로 활용하는 Zero-Injection 기술을 제안한 바 있으며, 이러한 기술은 기존 CF 추천 방안들의 정확도를 획기적으로 향상시킨다. Zero-Injection 기술은 다음 4 가지 단계를 거쳐 사용자 별 선호 상품을 추천한다: (1) 먼저 관찰된

* 본 연구는 (1) 한국연구재단(NRF-2017R1A2B3004581), 그리고 (2) 한국연구재단-차세대정보·컴퓨팅기술개발사업(NRF-2017M3C4A7083678, NRF-2017M3C4A7069440)의

지원을 받아 수행된 연구임.

† 교신 저자

데이터 집합을 WRMF 기술로 분석하여 관찰되지 않은 데이터 집합 내의 사용자-상품 쌍들의 관심 정도를 추론한다; (2) 상품들의 관심 정도를 내림차순으로 정렬한 뒤, 하위 $\theta\%$ 를 무관심 상품으로 결정한다; (3) 결정된 $\theta\%$ 의 사용자-상품 쌍을 부정적인 선호도로 바라보고, 해당 쌍들의 평점을 0 점으로 할당한다; (4) 기존에 사용자들에 의해 매겨진 평점 정보와 새롭게 추가(inject)된 0 점으로 만들어진 사용자-상품 평점 행렬을 이용하여 기존 CF 추천 방안들을 수행한다.

2.2 gOCCF

Lee et al[4]은 단일-클래스 환경에서 Zero-Injection 이 갖는 한계들을 극복하기 위해, 그래프 이론 관점에서 관찰된 데이터 집합을 분석한 결과를 기반으로 사용자 별 무관심 상품을 결정하여 활용하는 gOCCF 기술을 제안하였다. gOCCF 기술은 다음 4 가지 단계를 거쳐 사용자 별 선호 상품을 추천한다: (1) Zero-Injection 과 마찬가지로 관찰된 데이터 집합을 WRMF 기술로 분석하여 관찰되지 않은 데이터 집합 내의 사용자-상품 쌍들의 관심 정도를 추론한다; (2) 추론된 상품들의 관심 정도, 그래프 조각화(graph shattering) 이론, 정보 전파의 변화를 함께 고려하여, 사용자 별 무관심 상품의 수를 결정한다; (3) 사용자-상품 간의 관계와 새롭게 추론된 사용자-무관심 상품 간의 관계들을 그래프로 모델링한다; (4) 모델링된 그래프에 대해 잘 알려진 소셜 네트워크 분석 기술들을 수행하여 분석하고, 분석된 결과를 기반으로 추천을 수행한다.

3. 성능 평가

3.1 데이터

본 논문에서는 MovieLens 100K 데이터 집합을 사용하여 실험을 수행하였다. 해당 데이터는 943 명의 사용자, 1682 개의 상품, 그리고 100,000 개의 평점으로 구성된다. 평점은 1 부터 5 까지의 범위를 갖지만, 본 논문은 단일-클래스 환경을 목표로 하기 때문에 모든 평점을 1 로 변환했다.

3.2 실험 방법

본 논문에서 우리는 다음 4 가지의 OCCF 기술들과 3 가지의 CF 기술들에 대한 성능 평가를 수행하고자 한다: (1) OCCF 기술: WRMF[2], IdNMF[5], BPRMF[6], SLIM[7]; (2) CF 기술: BIM[3], SVD, PMF.

각 기술의 성능을 평가하기 위해, 우리는 각 기술에 의해 얼마나 많은 사용자 별 관심 상품이 무관심 상품으로 잘못 분류되는가를 나타내는 ‘에러율(error rate)’[3]이라는 척도를 사용한다.

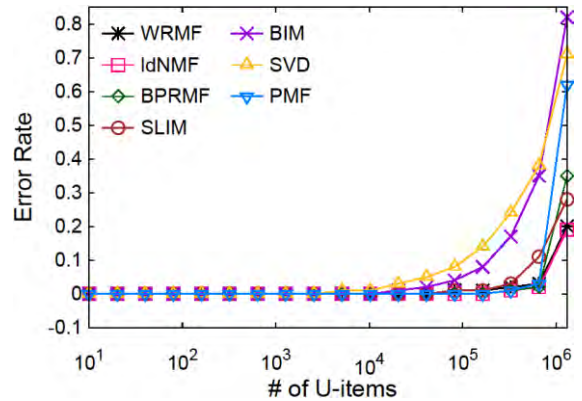
사용자들의 종합적인 에러율은 다음과 같이 계산된다:

$$err = \frac{\sum_i |I_i^{U-item} \cap I_i^{test}|}{\sum_i |I_i^{test}|}$$

위 식에서 I_i^{test} 는 테스트 셋에서 사용자 i 가 평가한 상품들의 집합을 나타내며, I_i^{U-item} 는 특정 기술에 의해 사용자 i 의 무관심 상품으로 결정된 상품들의 집합을 나타낸다. 다시 말해, 사용자들의 에러율이 낮아질수록, 해당 기술의 정확도는 높다는 것을 의미한다.

다.

3.3 실험 결과



(그림 1) 무관심 상품 수에 따른 에러율.

그림 1은 무관심 상품 수에 따른 각 기술들의 에러율의 변화를 보여준다. x 축은 무관심 상품 수를 나타내며, y 축은 각 기술에 의해 측정된 에러율을 나타낸다. 우리는 무관심 상품의 수를 10 개부터 시작하여 사용자들이 평가한 적 없는 사용자-상품 쌍의 90%가 포함될 때까지 2 배씩 늘려가며 에러율을 측정하였다. 전반적으로, 무관심 상품의 수가 증가할수록 모든 기술들의 에러율이 증가한다. 특히, CF 기술들의 에러율은 OCCF 기술들의 에러율보다 매우 빠르게 증가하는 것을 확인할 수 있다. 게다가, 우리는 OCCF 기술들 중에서는 WRMF와 IdNMF의 에러율이 가장 낮은 것을 확인하였다.

4. 결론

본 논문에서는 단일-클래스 협업 필터링 환경에서 무관심 상품을 결정할 수 있는 다양한 기술들의 성능을 평가하였다. 실험을 통해, 우리는 CF 기술들에 비해 OCCF 기술들의 성능이 더 우수한 것을 확인하였다. 또한, OCCF 기술들 중에서도 WRMF와 IdNMF의 성능이 가장 우수하다는 것을 보였다.

참고문헌

- [1] G. Adomavicius et al., Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-art and Possible Extensions, *IEEE TKDE*, 2005.
- [2] R. Pan et al., One-class Collaborative Filtering. In *IEEE ICDM*, pp. 502–511, 2008.
- [3] W. S. Hwang et al., “Told You I Didn't Like It”: Exploiting Uninteresting Items for Effective Collaborative Filtering, In *IEEE ICDE*, 2016.
- [4] Y.-C. Lee et al., gOCCF: Graph-Theoretic One-Class Collaborative Filtering Based on Uninteresting Items, In *AAAI*, 2018.
- [5] V. S. et al., One-Class Matrix Completion with Low-Density Factorizations, In *IEEE ICDM*, 2010.
- [6] S. Rendle et al., BPR: Bayesian Personalized Ranking from Implicit Feedback, In *UAI*, 2011.
- [7] X. Ning et al., SLIM: Sparse Linear Methods for Top-n Recommender Systems, In *IEEE ICDM*, 2011.