

Modified Bayesian personalized ranking for non-binary implicit feedback

Dongwoo Kim^a · Eun Ryung Lee^{b,1}

^aDepartment of Statistics, Seoul National University;

^bDepartment of Statistics, Sungkyunkwan University

(Received October 20, 2017; Revised November 5, 2017; Accepted November 8, 2017)

Abstract

Bayesian personalized ranking (BPR) is a state-of-the-art recommendation system techniques for implicit feedback data. Unfortunately, there might be a loss of information because the BPR model considers only the binary transformation of implicit feedback that is non-binary data in most cases. We propose a modified BPR method using a level of confidence based on the size or strength of implicit feedback to overcome this limitation. The proposed method is useful because it still has a structure of interpretable models for underlying personalized ranking i.e., personal pairwise preferences as in the BPR and that it is capable to reflect a numerical size or the strength of implicit feedback. We propose a computation algorithm based on stochastic gradient descent for the numerical implementation of our proposal. Furthermore, we also show the usefulness of our proposed method compared to ordinary BPR via an analysis of steam video games data.

Keywords: recommendation system, implicit feedback, level of confidence, matrix factorization, Bayesian personalized ranking

1. 서론

개인화추천시스템(personalized recommendation system)은 평점, 거래, 클릭수, 감상 내역 등과 같은 사용자의 과거 행적 자료로부터 상품에 대한 사용자의 선호도를 예측하고자 한다. 이와 같이, 개인의 선호도에 맞는 상품을 자동 추천하는 시스템을 개발하는 일은 많은 전자상거래 산업에서 필수적이며 이는 많은 기업에서 적극적으로 활용되고 있다. 예를 들면, 가장 큰 온라인 쇼핑몰 중 하나인 아마존(Amazon)은 고객의 특성에 맞춘 추천 상품을 제시하고, 온라인 영화서비스를 제공하는 넷플릭스(Netflix)는 고객 맞춤형 영화 리스트를 추천한다. 이런 기업들은 개인에게 맞춘 추천 시스템을 사용하여 판매량을 증진시켜 왔다.

추천시스템을 개발하기 위해 분석할 수 있는 자료에는 크게 두 가지 유형, 명시적피드백(explicit feedback) 자료와 내재적피드백(implicit feedback) 자료가 있다. 명시적피드백은 사용자가 주는 1-5 평점

Research of Eun Ryung Lee was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIP) (No. NRF-2016R1C1B1011874).

¹Corresponding author: Department of Statistics, Sungkyunkwan University, 25-2, Sungkyunkwan-ro, Jongno-gu, Seoul 03063, Korea. E-mail: silverryuee@gmail.com

처럼 ‘매우나쁨’에서 ‘매우 좋음’에 이르기까지 사용자의 선호도를 직접적으로 드러내는 자료를 말한다. 많은 통계적 모델링 기법들을 사용하여 이와 같은 명시적피드백 자료로부터 사용자의 상품에 대한 선호도를 예측하는 분석을 시도해왔다. 예를 들어, 상품기반협업필터링(item-based collaborative filtering) (Sarwar 등, 2001), 행렬인수분해(matrix factorization; MF) (Koren 등, 2009)와 같은 기존 연구가 있다. 반면, 내재적피드백은 사용자가 상품을 조회한 횟수/클릭 수 및 사용자의 구매 내역처럼 상품에 대한 사용자의 선호도를 간접적으로 드러낼 수 있는 행동 자료를 말한다. 일반적으로 사용자의 내재적피드백 자료가 명시적피드백에 비해 흔하고 얻기 쉽다. 더욱이 명시적피드백이 없는 경우에도 내재적피드백자료는 존재할 수 있다. 따라서, 이러한 내재적피드백 자료부터 적절한 개인화추천시스템을 개발하는 것은 중요한 과제라 할 수 있다.

내재적피드백은 자료의 고유 특성상 부정적인 피드백을 관측할 수 없고, 자료의 수치적인 크기는 그 피드백이 얼마나 확실한지를 보여주는 것으로 해석할 수 있다 (Hu 등, 2008; Oard와 Kim, 1998; 등 참조). 예를 들어, 상품 A를 10번 구매하고 상품 B를 1번, 상품 C를 0번 구매한 고객을 생각했을 때, 그 고객이 구매횟수가 적은 상품 B나 C를 명확히 싫어한다고 보기는 어렵지만 상품 A를 상품 B, C보다는 분명히 더 선호할 것이라 이해할 수 있다. 즉, 상품 A가 상품 B, C에 비해 개인화 선호의 확실함 정도(level of confidence)가 높다고 할 수 있겠다.

이런 성질을 지닌 내재적피드백 자료를 분석하여 추천시스템을 개발하려는 연구가 시도되어 졌다. 예를 들어, Hu 등 (2008)는 명시적피드백 자료분석에 사용하던 Koren 등 (2009)의 행렬인수분해모형을 내재적피드백 자료로 확장했다. 최근 Rendle 등 (2009)은 사용자의 개인화순위, 즉, 상품 간의 선호도를 확률 모형화하여 베이زي안개인화순위(Bayesian personalized ranking; BPR) 방법을 제안했다. 베이زي안개인화순위 방법은 receiver operating characteristic (ROC) 곡선아래의 영역(area under ROC curve; AUC)을 최대화하는 문제와 연관을 가지고 있어 개인화순위를 최적화시키는 개인화추천시스템의 목표를 직접적으로 다루고 있다. 또한 경험적으로 많은 경우 기존의 추천시스템 기법들에 비해 우수한 성능을 보여주는 것으로 알려졌다. 하지만, 이 베이زي안개인화순위 방법은 사용자가 상품에 대한 (내재적) 피드백을 제공했는지 안했는지 정보만을 이용하기 때문에 정보손실이 발생할 수 있다. 앞에서 언급한 거래, 클릭수, 감상 내역의 예처럼 내재적피드백 자료는 대부분 이진 형태를 가지지 않기 때문이다. 또한 내재적 자료의 수치적 크기는 피드백의 확실함 정도로 볼 수 있고 이는 개인의 선호도에 관한 유용한 정보가 될 수 있다. 이에 착안하여 본 논문에서는 내재적 피드백의 존재 여부 뿐 아니라 피드백의 확실함 정도를 함께 고려하는 변형 베이زي안개인화순위 방법을 제안할 것이다.

이 논문의 나머지 부분은 다음과 같이 구성된다. 2절에서는 기존의 베이زي안개인화순위 방법을 간략하게 리뷰하고 우리가 제안하는 변형 베이زي안개인화순위 방법을 소개하겠다. 3절에서는 제안한 방법을 수치적으로 구현하기 위해 확률그라디언트하강(stochastic gradient descent) 기법에 기반한 계산 알고리즘을 제시하고 4절에서는 스팀 비디오 게임(steam video games) 실제 데이터 분석을 통하여 제안방법의 우수성을 보여주겠다. 마지막으로 5장에서는 본 논문에서 제안한 방법과 성질을 요약하며 연구를 정리하겠다.

2. 모형 및 방법론 설명

이 절에서는 내재적피드백 자료를 분석하는 베이زي안개인화순위 방법 (Rendle 등, 2009)을 간략하게 설명하고 우리가 제안하는 방법을 설명하겠다. 본 논문에서, 상품 조회/클릭 횟수와 같은 사용자 u 의 상품 i 에 관한 내재적피드백 자료 r_{ui} 를 고려한다. 모든 사용자의 집합을 U , 모든 상품의 집합을 I 라 두면, $R = (r_{ui})_{(u,i) \in U \times I}$ 는 내재적피드백 자료를 원소로 갖는 $|U| \times |I|$ 행렬이 된다. 내재적피드백

$r_{ui} > 0$ 이 관측된 사용자-상품 쌍의 집합을 $S := \{(u, i) \in U \times I : r_{ui} > 0\}$, 사용자 u 가 내재적피드백을 보여준 상품들의 집합을 $I_u^+ := \{i \in I : (u, i) \in S\}$, 사용자 u 가 내재적피드백을 보여주지 않은 나머지 상품들의 집합을 $I_u^- := I \setminus I_u^+$ 라 두자. 논문에서 편의상 I_u^+, I_u^- 에 속하는 상품들을 사용자 u 의 긍정적상품(positive items), 부정적상품(negative items)이라 부르겠다. 마지막으로, 집합 D_S 는 아래처럼 정의한다:

$$D_S := \{(u, i, j) \in U \times I \times I : i \in I_u^+, j \in I_u^-\}.$$

2.1. Bayesian personalized ranking 방법

Rendle 등 (2009)이 제안한 기존 베이지안개인화순위(Bayesian personalized ranking; BPR) 방법을 소개하겠다. Rendle 등 (2009)은 사용자가 각 상품들의 모든 쌍에 관해 고유의 선호도가 있음을 가정하고 있다. 즉, 사용자 u 는 두 상품 i 와 j 중에서 선호도를 가진다. 사용자 u 가 상품 i 를 상품 j 보다 선호하는 경우 $i \geq_u j$ 라고 표기하겠다. 이와 같이 정의된 개인화 선호도 \geq_u (확률적인 의미에서) 전순서(total order)의 필수 성질(totality, antisymmetry, transitivity)을 만족해야 한다고 논했다. 베이지안개인화순위 모형은 사용자 u 가 상품 i 를 상품 j 보다 선호하는 이벤트 $i \geq_u j$ 의 확률을 스코어 y_{ui}, y_{uj} 를 추가적으로 도입하여 아래와 같이 모델링한다. 즉, 임의의 $u \in U$ 와 $i, j \in I, i \neq j$ 에 대해

$$\Pr(i \geq_u j) = \sigma(y_{ui} - y_{uj}) \quad (2.1)$$

이다. 여기서, $\sigma(x) = 1/(1 + \exp(-x))$ 는 시그모이드 함수이고, $\sigma(x) + \sigma(-x) = 1$ 이 성립하게 된다. 따라서, 식 (2.1)의 모델링은 $\Pr(i \geq_u j) + \Pr(j \geq_u i) = 1$ 을 만족하고, 또한 고려하고 있는 선호도 \geq_u 가 (확률적인 의미에서) 전순서의 필수성질 totality, antisymmetry를 자동적으로 만족하게 한다. 스코어는 사용자의 선호도를 결정하는 연속형 (미관측) 변수로 볼 수 있고 스코어 값 y_{ui} 이 상대적으로 높을 수록 해당 상품 u 의 선호도가 (확률적으로) 높아지게 된다. 스코어 y_{ui} 는 명시적피드백 추천시스템에서 사용하는 모형, 예를 들어, 행렬인수분해 모형

$$y_{ui} = \mu + b_u + b_i + \mathbf{p}_u^T \mathbf{q}_i \quad (2.2)$$

으로 모델링된다. 여기서, $\mu, b_u, b_i \in \mathbb{R}$, $\mathbf{p}_u, \mathbf{q}_i \in \mathbb{R}^k$ 이며 μ 는 전체 평균 스코어, b_u, b_i 는 사용자 u 와 상품 i 의 베이스라인 스코어 (주효과), $\mathbf{p}_u, \mathbf{q}_i$ 는 k 개 잠재 인자에 대한 사용자 u 의 스코어와 상품 i 의 k 개 인자의 구성비율로 해석할 수 있다.

임의의 두 상품의 쌍 (i, j) 이 주어졌다고 가정하자. 그러면, 사용자 u 가 상품 i 를 상품 j 보다 선호하는 이벤트 $i \geq_u j$ 는 발생 확률이 $p_{uij} = \Pr(i \geq_u j)$ 인 베르누이 분포 Bernoulli(p_{uij})를 따른다고 할 수 있다. 한편, Rendle 등 (2009)은 긍정적상품과 부정적상품을 비교할 때 내재적피드백이 존재하는 긍정적상품을 사용자가 더 선호한 것으로 보았다. 즉, 모든 $(u, i, j) \in D_S$ 에 대해서 i 는 사용자 u 의 긍정적상품이고 j 는 부정적상품을 뜻하므로 해당 이벤트 $i \geq_u j$ 가 관측되었다고 보고, 이벤트 $i \geq_u j$ 가 서로 독립이라고 가정하면, 해당 조건부로그우도(conditional log-likelihood)는 다음과 같다.

$$\sum_{(u, i, j) \in D_S} \log \left\{ p_{uij}^1 (1 - p_{uij})^{(1-1)} \right\} = \sum_{(u, i, j) \in D_S} \log p_{uij} = \sum_{(u, i, j) \in D_S} \log \sigma(y_{ui} - y_{uj}).$$

여기에 추가적으로 (제곱 ℓ_2) 정규화(regularization)항을 고려하여 정규화된 (마이너스) 조건부 로그우도

$$\sum_{(u, i, j) \in D_S} -\log \sigma(y_{ui} - y_{uj}) + R_{uij}(\boldsymbol{\theta}) = \sum_{(u, i, j) \in D_S} -\log \sigma \left(b_i - b_j + \mathbf{p}_u^T (\mathbf{q}_i - \mathbf{q}_j) \right) + R_{uij}(\boldsymbol{\theta}) \quad (2.3)$$

를 최소화하는 것을 최종적으로 제안했고 이를 BPR-OPT 기준이라 부른다. 식 (2.3)의 등식은 스코어 인수분해모형 식 (2.2)에서 얻어졌으며 식 (2.2)의 매개변수 μ, b_u 는 BPR-OPT 방법에 영향을 미치지 않는 것을 확인할 수 있다. 따라서 매개변수 $b_i, \mathbf{p}_u, \mathbf{q}_i$ 가 θ 가 되고 임의의 $(u, i, j) \in D_S$ 에 대해 정규화항 $R_{uij}(\theta)$ 는 $2^{-1}\{\lambda_b(b_i^2 + b_j^2) + \lambda_u\|\mathbf{p}_u\|^2 + \lambda_+\|\mathbf{q}_i\|^2 + \lambda_-\|\mathbf{q}_j\|^2\}$ 로 정의한다.

2.2. Modified Bayesian personalized ranking (MBPR)

앞에서 본 것처럼, 기존의 베이지안개인화순위 방법은 BPR-OPT 기준에 주어진 내재적피드백 자료 r_{ui} 를 크기 정보를 사용하는 대신, $r_{ui} > 0$ 의 여부로 구한 집합 D_S 만을 사용한다. 하지만, 내재적피드백 자료에서는 발생 여부 뿐 아니라 자료의 크기는 피드백이 얼마나 확실한지 알려주는 중요한 정보가 될 수 있다 (Hu 등, 2008; Oard와 Kim, 1998). 이 점에 착안하여 내재적피드백 r_{ui} 의 크기 정보, 즉, 피드백의 확실함 정도를 함께 고려한 변형 MBPR-OPT 기준을 제안한다.

$$\begin{aligned} L(\theta) &:= \sum_{(u,i,j) \in D_S} -c_{ui} \log \sigma(b_i - b_j + \mathbf{p}_u^T(\mathbf{q}_i - \mathbf{q}_j)) + R_{uij}(\theta) \\ &:= \sum_{(u,i,j) \in D_S} l_{uij}(\theta) \end{aligned} \quad (2.4)$$

여기에서, (피드백의) 확실함의 정도 c_{ui} 는 내재적피드백 r_{ui} 의 증가함수로 주어지고 앞 절의 정규화항 $R_{uij}(\theta) = 2^{-1}\{\lambda_b(b_i^2 + b_j^2) + \lambda_u\|\mathbf{p}_u\|^2 + \lambda_+\|\mathbf{q}_i\|^2 + \lambda_-\|\mathbf{q}_j\|^2\}$ 를 똑같이 사용한다. 제안한 MBPR-OPT는 기존의 방법과 달리 사용자 u 의 관측된 선호도를 관련 피드백 r_{ui} 크기에 따라 다르게 고려하며, c_{ui} 은 r_{ui} 값에 따라 증가하기 때문에 더 강한 (약한) 피드백을 보여준 상품에 관해서는 더 높은 (낮은) 가중치를 둔다. 본 연구에서는 Hu 등 (2008)을 참고하여 다음과 같은 확실함의 정도

$$c_{ui} = 1 + \alpha \log\left(\frac{r_{ui}}{\beta}\right) \quad (2.5)$$

를 이용했다. 여기서, α, β 는 양수인 튜닝 파라미터(tuning parameter)로 $c_{ui} > 0$ 을 만족하게끔 설정한다. α 는 확실함의 정도 c_{ui} 의 범위(range)와 관련있고, β 는 c_{ui} 의 수평이동과 관련있다. 만약 $\alpha = 0$ 이면 MBPR-OPT 기준은 기존의 BPR-OPT 기준과 동일하여, 우리가 제시하는 방법은 베이지안개인화순위를 포함하게 된다.

식 (2.4)에서 $\sigma(b_i - b_j + \mathbf{p}_u^T(\mathbf{q}_i - \mathbf{q}_j))$ 항은 $\Pr(i \geq_u j) = p_{uij}$ 와 같기 때문에, 모든 $(u, i, j) \in D_S$ 에 대해 이벤트 $i \geq_u j$ 가 서로 독립이라는 가정을 이용하면 MBPR-OPT 기준에서 고려하고 있는 조건부우도는 아래와 같다.

$$\prod_{(u,i,j) \in D_S} p_{uij}^{c_{ui}} = \prod_{u \in U} \prod_{i \in I_u^+} \prod_{j \in I \setminus I_u^+} p_{uij}^{c_{ui}} \quad (2.6)$$

$$= \prod_{u \in U} \prod_{i \in I_u^+} \left(\prod_{j \in I \setminus I_u^+} p_{uij} \right)^{c_{ui}} \quad (2.7)$$

$$= \prod_{u \in U} \prod_{i \in I_u^+} \Pr(i \geq_u j, \forall j \in I_u^-)^{c_{ui}} \quad (2.8)$$

여기에서, 항 $(i \geq_u j, \forall j \in I_u^-)$ 은 사용자 u 가 상품 i 를 그의 모든 부정적상품 $j \in I_u^-$ 들 보다 선호하는 이벤트를 뜻한다. 만약 c_{ui} 가 정수라 가정한다면 식 (2.6)은 이벤트 $(i \geq_u j, \forall j \in I_u^-)$ 가 시행횟수가

c_{ui} 이고 발생확률이 $p_{ui} := \Pr(i \geq_u j, \forall j \in I_u^-)$ 인 이항분포 $\text{Bin}(c_{ui}, p_{ui})$ 를 따르고 그 이벤트가 c_{ui} 번 관측되었을 때의 우도와 일치한다. 즉, c_{ui} 는 사용자 u 가 부정적상품들보다 i 를 선호하는 것을 관측한 횟수, 혹은 관측값의 확실함 정도로 이해할 수 있고, 우리가 제안한 MBPR-OPT 방법은 기존의 방법처럼 상품 쌍에 대한 사용자의 선호도(개인화순위)에 대한 확률적 모형으로 해석할 수 있다.

한편, 베이지안개인화순위에 비슷한 접근법을 사용한 Wang 등 (2012)은 사용자가 받은 트윗들 중 어떤 것들을 리트윗 할지 추천하는 추천시스템을 다뤘다. 앞에서 사용한 표기법으로 설명하면, $(u, i, j) \in D_S$ 에 대해서 트윗 i 는 받은 트윗들 중 사용자 u 가 리트윗 했던 트윗을 의미하고, 트윗 j 는 리트윗하지 않은 트윗을 나타낸다. Wang 등 (2012)은 베이지안개인화순위방법에 확실함의 정도를 고려한 기준

$$\sum_{(u,i,j) \in D_S} -\log \sigma(c_{uij}(y_{ui} - y_{uj})) + R_{uij}(\theta)$$

을 제안했다. 여기서, $c_{uij} = 1/(t_i - t_j)$ 이고, t_i 는 트윗 i 를 받은 시점으로 정의된다. 이 경우 우리 방법과 달리 확실함의 정도 c_{uij} 의 해석은 쉽지 않다. 또한, 정의에 의해 $c_{uij} = -c_{uji}$ 를 만족하므로

$$\Pr(i \geq_u j) = \sigma(c_{uij}(y_{ui} - y_{uj})) = \sigma(c_{uji}(y_{uj} - y_{ui})) = \Pr(j \geq_u i).$$

이 성립한다. 이것은 $\Pr(i \geq_u j) + \Pr(j \geq_u i) \neq 1$ 을 의미한다. 따라서 Wang 등 (2012)에서 고려하는 개인화선호도 \geq_u 는 totality, antisymmetry와 같은 전순서의 속성을 만족하지 않고 개인화선호도와 연관한 직관적인 설명력을 잃게 된다.

3. 최적화 알고리즘

이 절에서는 식 (2.4)에서 정의된 우리가 제안한 MBPR-OPT 기준 $L(\theta)$ 을 수치적으로 최소화하는 문제를 다루고 이를 구현하기 위한 확률그라디언트하강 알고리즘을 소개한다. 이것은 기존의 BPR-OPT 방법에서 제안한 Rendle 등 (2009)의 확률그라디언트하강 알고리즘을 우리 세팅에 맞추어 변형한 것이다.

확률그라디언트하강 알고리즘은 그라디언트하강 알고리즘의 (확률적) 변형이라 할 수 있다. $L(\theta)$ 를 최소화하는 그라디언트하강 알고리즘은 매개변수 θ 가 수렴할 때까지

$$\theta^{\text{new}} = \theta^{\text{old}} - \eta \nabla L(\theta^{\text{old}}). \quad (3.1)$$

업데이트하는 것으로 주어진다. 여기에서 $\nabla L(\theta^{\text{old}})$ 은 최소화하고자 하는 목적함수 $L(\theta)$ 의 θ^{old} 에서의 그라디언트값으로 주어지며 $\eta > 0$ 는 각 업데이트에서의 step size를 의미한다. 그라디언트하강 알고리즘은 어떤 함수의 음의 그라디언트 값이 해당 지점에서 가장 빠르게 함수값을 감소시키는 방향인 것에 착안하여, 그 방향으로 step size η 만큼 조금씩 움직여가며 함수값을 최소화한다. η 가 너무 작으면, 함수값의 최저점에 수렴하기까지 너무 오래걸릴 수 있고, η 가 너무 크면, 함수값이 최저점에 수렴하지 않을 수 있다.

우리의 $L(\theta)$ 는 일반적으로 원소의 수가 매우 많은 집합 D_S 에 관한 합 $L(\theta) = \sum_{(u,i,j) \in D_S} l_{uij}(\theta)$ 으로 주어지기 때문에 식 (3.1)의 업데이트 계산은 어려울 수 있다. 따라서, Rendle 등 (2009)의 계산 아이디어를 따라 D_S 에서 하나의 (u, i, j) 를 무작위 샘플링 하고 샘플링된 (u, i, j) 에 관련한 매개변수를 업데이트하는 확률그라디언트하강 알고리즘을 사용한다. 다시 말해, $l_{uij}(\theta)$ 를 최소화하는 그라디언트하강 알고리즘, 즉, $L(\theta)$ 대신 $l_{uij}(\theta)$ 을 대입한 식 (3.1)을 이용한다.

```

Initialize  $b_i, \mathbf{p}_u, \mathbf{q}_i$  for all  $u \in U, i \in I$ 
while it does not converge do
  Uniformly sample  $(u, i, j) \in D_S$ 
  update  $b_i, b_j, \mathbf{p}_u, \mathbf{q}_i, \mathbf{q}_j$  via the equations (3.2)
end

```

Figure 3.1. Stochastic gradient descent algorithm optimizing MBPR-OPT. MBPR = modified Bayesian personalized ranking.

먼저, $(u, i, j) \in D_S$ 가 무작위 샘플링되었다고 가정하자. 주어진 (u, i, j) 에 대해 식 (2.4)로부터 그라디언트 $\nabla l_{uij}(\boldsymbol{\theta})$ 는 다음과 같이 계산된다.

$$\begin{aligned} \frac{\partial l_{uij}(\boldsymbol{\theta})}{\partial b_i} &= -c_{ui} (1 - \sigma(y_{ui} - y_{uj})) + \lambda_b b_i, \\ \frac{\partial l_{uij}(\boldsymbol{\theta})}{\partial b_j} &= c_{ui} (1 - \sigma(y_{ui} - y_{uj})) + \lambda_b b_j, \\ \frac{\partial l_{uij}(\boldsymbol{\theta})}{\partial \mathbf{p}_u} &= -c_{ui} (1 - \sigma(y_{ui} - y_{uj})) (\mathbf{q}_i - \mathbf{q}_j) + \lambda_{uf} \mathbf{p}_u, \\ \frac{\partial l_{uij}(\boldsymbol{\theta})}{\partial \mathbf{q}_i} &= -c_{ui} (1 - \sigma(y_{ui} - y_{uj})) \mathbf{p}_u + \lambda_+ \mathbf{q}_i, \\ \frac{\partial l_{uij}(\boldsymbol{\theta})}{\partial \mathbf{q}_j} &= c_{ui} (1 - \sigma(y_{ui} - y_{uj})) \mathbf{p}_u + \lambda_- \mathbf{q}_j. \end{aligned}$$

이에 따라, 업데이트 식은 다음과 같이 주어진다:

$$\begin{aligned} b_i^{\text{new}} &= b_i^{\text{old}} - \eta \left\{ -c_{ui} (1 - \sigma(y_{ui}^{\text{old}} - y_{uj}^{\text{old}})) + \lambda_b b_i^{\text{old}} \right\}, \\ b_j^{\text{new}} &= b_j^{\text{old}} - \eta \left\{ c_{ui} (1 - \sigma(y_{ui}^{\text{old}} - y_{uj}^{\text{old}})) + \lambda_b b_j^{\text{old}} \right\}, \\ \mathbf{p}_u^{\text{new}} &= \mathbf{p}_u^{\text{old}} - \eta \left\{ -c_{ui} (1 - \sigma(y_{ui}^{\text{old}} - y_{uj}^{\text{old}})) (\mathbf{q}_i^{\text{old}} - \mathbf{q}_j^{\text{old}}) + \lambda_{uf} \mathbf{p}_u^{\text{old}} \right\}, \\ \mathbf{q}_i^{\text{new}} &= \mathbf{q}_i^{\text{old}} - \eta \left\{ -c_{ui} (1 - \sigma(y_{ui}^{\text{old}} - y_{uj}^{\text{old}})) \mathbf{p}_u^{\text{old}} + \lambda_+ \mathbf{q}_i^{\text{old}} \right\}, \\ \mathbf{q}_j^{\text{new}} &= \mathbf{q}_j^{\text{old}} - \eta \left\{ c_{ui} (1 - \sigma(y_{ui}^{\text{old}} - y_{uj}^{\text{old}})) \mathbf{p}_u^{\text{old}} + \lambda_- \mathbf{q}_j^{\text{old}} \right\}. \end{aligned} \quad (3.2)$$

이를 정리하면 확률그래이언드하강 알고리즘은 Figure 3.1과 같다.

Figure 3.1의 알고리즘에서 우리는 Rendle 등 (2009)의 방법을 따라 무작위랜덤추출방법을 샘플링방법으로 이용했지만 다른 샘플링방법 또한 적용할 수 있다. 다양한 샘플링 방법과 이에 관한 논의를 찾아보려면 Rendle와 Freudenthaler (2014)를 참조할 수 있다.

4. 실증 예제: Steam video games 자료

이 절에서는 실제 데이터에 우리가 제안한 MBPR-OPT 기준을 최적화하는 추천시스템을 적용한 과정과 결과를 제시한다. 사용한 데이터는 Steam video games로 Steam 사의 자료를 Tamber 팀에서 정리하여 Kaggle에 공개한 것이다. Steam은 가장 인기있는 PC 게이밍 허브로, 이 자료는 Steam 사용자들의 게임 사용 기록을 포함하고 있다. 이 자료의 변수는 user-id, game-title, behavior-name, value 으로 구성되어있다. 여기서 user-id는 사용자의 ID를, game-title은 게임명을 의미한다. behavior-name은

Table 4.1. Configuration of data

	# of users	# of games	# of feedbacks
Training data	4,791	3,555	61,494
Validation data	1,207	503	1,207
Test data	1,207	510	1,207

Table 4.2. Samples of the training data

User ID	Game	Playtime (hours)
297811211	ARK Survival Evolved	29.0
297811211	Team Fortress 2	10.1
297811211	Unturned	5.6
218323237	Dota 2	14.8
218323237	Tomb Raider	8.8
218323237	TERA	0.9
⋮	⋮	⋮

‘play’나 ‘purchase’로 표시되는데, ‘play’일 경우 value 변수는 게임 플레이 시간을 의미하며, ‘purchase’의 경우 value 변수는 해당 게임의 구입여부를 1로 표현한다 (구입한 자료이기 때문에 전부 1로 구성되어있다). 자료와 자료에 대한 자세한 설명은 <https://www.kaggle.com/tamber/steam-video-games> 를 참고하길 바란다.

우리는 이 데이터에서 behavior-name이 ‘play’인 것들만 사용하였고 playtime을 내재적피드백으로 활용하였다. 또한, 콜드 스타트(cold-start) 문제를 피하기 위해 적어도 2개 이상의 게임을 플레이한 사용자들의 자료만 고려하였다. 튜닝에 사용할 평가자료(validation data)와 모형 성능 비교에 사용할 시험자료(test data)를 구성하기 위해, 다음의 과정을 거쳤다. 먼저, 5개 이상의 게임을 플레이한 사용자들의 자료에서 각 사용자별 임의로 1개씩 자료를 추출하고 남은 자료를 훈련자료(training data)로 사용한다. 추출한 자료 중 훈련 자료에 포함된 게임들을 가져와서 임의로 반으로 나누어 각각 평가자료와 시험자료로 사용한다. 이에 따라, 피드백이 관측된 (u, i) 의 집합 S 는 각각 훈련자료, 평가자료, 시험자료에 대응되는 $S_{train}, S_{val}, S_{test}$ 로 나뉜다. 이러한 과정으로 최종적으로 구성된 훈련자료, 평가자료, 시험자료의 사용자 수, 게임 수, 피드백의 수는 Table 4.1과 같다. Table 4.2는 훈련자료 중 일부를 (User ID, Game, Playtime)의 형태로 나타낸 것이다.

튜닝 파라미터에 해당하는 것은 $\mathbf{p}_u, \mathbf{q}_i$ 의 차원, 즉, 인자의 수 k 와, 업데이트 식 (3.1)에서 나타나는 $\eta, \lambda_b, \lambda_{uf}, \lambda_+, \lambda_-$, 그리고 식 (2.5)에서 확실함의 정도 c_{ui} 에 영향을 주는 α, β 이다. MBPR-OPT와 BPR-OPT를 비교하기 위해 인자의 수 $k = 20, 30, 40, 50$ 마다 $\alpha = 0, 0.05, 0.10, 0.15$ 중에 뛰어난 α 를 선택하는 작업을 하였다. η 는 Rendle와 Freudenthaler (2014)와 같이 고정된 값으로 주었고, 여기서 $\eta = 0.1$ 로 정하였다. 나머지 튜닝 파라미터들은 동일하게 $\lambda_b = 1.0, \lambda_{uf} = 0.0025, \lambda_+ = 0.0025, \lambda_- = 0.00025, \beta = \exp\{(1/|S_{train}|) \sum_{(u,i) \in S_{train}} \log(r_{ui})\}$ 로 설정하였다. 여기서 β 는 c_{ui} 의 크기로 인해 정규화 파라미터 $\lambda_b, \lambda_{uf}, \lambda_+, \lambda_-$ 의 영향력이 달라지는 것을 방지하기 위해, $(1/|S_{train}|) \sum_{(u,i) \in S_{train}} c_{ui} = 1$ 이 되도록 정한 것이다.

각 튜닝파라미터별로 모형적합 과정은 다음과 같이 이뤄졌다. $|S_{train}|$ 번의 업데이트가 이뤄질 때 마다, 평가자료에 대한 MBPR-OPT 값을 계산하여 제일 낮은 값을 갖는 시점의 매개변수들을 추천에 사용한다. 이때 평가자료에 대한 normalized discounted cumulative gain (nDCG) 값을 계산하여 가장 뛰어난 성능을 보인 α 들을 선택하였다. 여기서, nDCG는 추천 결과를 평가할 때 사용하는 척도 중에 하

Table 4.3. nDCG@10 on validation data over various k and α

k	α			
	0	0.05	0.10	0.15
20	0.1482	0.1500	0.1645	0.1667
30	0.1603	0.1598	0.1591	0.1611
40	0.1673	0.1664	0.1700	0.1745
50	0.1562	0.1631	0.1647	0.1643

nDCG = normalized discounted cumulative gain.

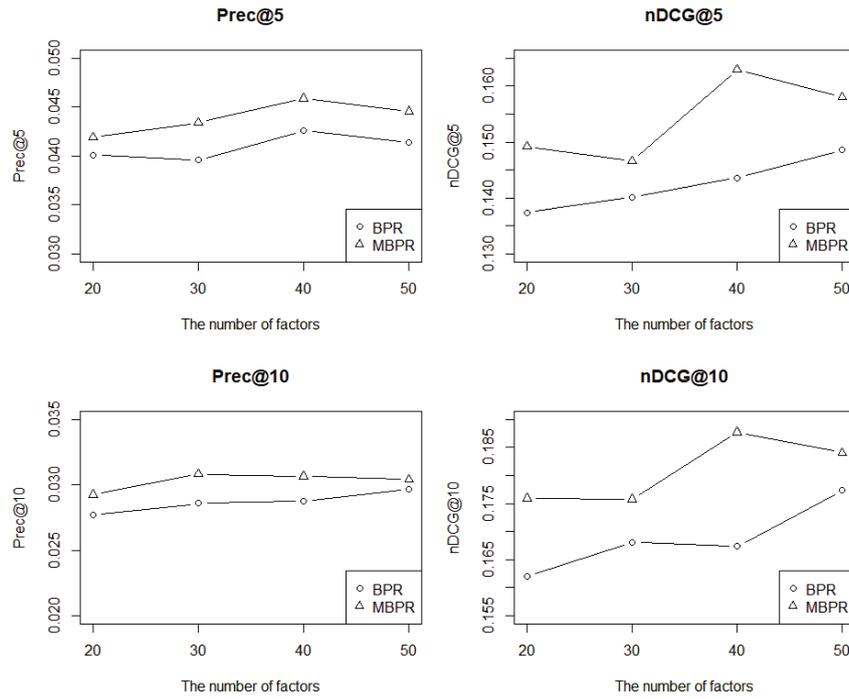


Figure 4.1. Comparison of precision and nDCG of BPR and MBPR on test data. For each k , MBPR's α is selected by Table 4.3. nDCG = normalized discounted cumulative gain; BPR = Bayesian personalized ranking; MBPR = modified Bayesian personalized ranking.

나로, 내재적피드백의 경우 다음과 같이 정의한다. 사용자 u 에게 N 개의 상품을 추천할 때의 nDCG, $nDCG_u@N$ 를

$$nDCG_u@N = \sum_{m=1}^N \frac{I(\text{rank}_u^{-1}(m) \in I_u^+)}{\log_2(1+m)}$$

로 정의한다. 여기서, $\text{rank}_u^{-1}(m)$ 는 사용자 u 에게 m 번째로 추천되는 상품을 의미한다. 종합적인 nDCG는 $nDCG_u$ 의 평균으로, 즉, $nDCG@N = (1/|U|) \sum_{u \in U} nDCG_u@N$ 으로 정의한다.

Table 4.3은 인자의 수 k 와 α 에 따른 평가자료에 대한 nDCG@10 값이다. Table 4.3의 튜닝결과에 따라, 각 k 별로 가장 높은 nDCG@10을 갖는 α 를 정하여 시험자료에 대한 precision과 nDCG를 구한 결과는 Figure 4.1과 같다. 여기서, 사용자 u 에게 N 개의 상품을 추천할 때의 precision, $\text{Prec}_u@N$ 은 다

Table 4.4. Test precision and nDCG of BPR and MBPR for all k and α

	$k = 20$				$k = 30$			
	$\alpha = 0$	$\alpha = 0.05$	$\alpha = 0.10$	$\alpha = 0.15$	$\alpha = 0$	$\alpha = 0.05$	$\alpha = 0.10$	$\alpha = 0.15$
Prec@5	0.0401	0.0409	0.0416	0.0419	0.0396	0.0406	0.0424	0.0434
Prec@10	0.0277	0.0283	0.0287	0.0292	0.0286	0.0287	0.0297	0.0308
nDCG@5	0.1374	0.1400	0.1487	0.1492	0.1402	0.1390	0.1456	0.1466
nDCG@10	0.1620	0.1657	0.1745	0.1760	0.1681	0.1666	0.1734	0.1758
	$k = 40$				$k = 50$			
	$\alpha = 0$	$\alpha = 0.05$	$\alpha = 0.10$	$\alpha = 0.15$	$\alpha = 0$	$\alpha = 0.05$	$\alpha = 0.10$	$\alpha = 0.15$
Prec@5	0.0426	0.0451	0.0446	0.0459	0.0414	0.0431	0.0432	0.0446
Prec@10	0.0287	0.0296	0.0304	0.0307	0.0297	0.0306	0.0309	0.0304
nDCG@5	0.1436	0.1571	0.1581	0.1630	0.1486	0.1516	0.1535	0.1558
nDCG@10	0.1674	0.1794	0.1840	0.1877	0.1773	0.1805	0.1835	0.1822

Prec = precision; nDCG = normalized discounted cumulative gain; BPR = Bayesian personalized ranking; MBPR = modified Bayesian personalized ranking.

음과 같이 정의한다.

$$\text{Prec}_u@N = \frac{\sum_{m=1}^N I(\text{rank}_u^{-1}(m) \in I_u^+)}{N}.$$

중합적인 precision은 $\text{Prec}_u@N$ 의 평균, 즉, $\text{Prec}@N = (1/|U|) \sum_{u \in U} \text{Prec}_u@N$ 으로 정의한다.

Table 4.4는 모든 k 와 α 에 따라 시험자료에 대한 precision과 nDCG를 계산한 결과를 나타낸다. 이 결과를 통해, Table 4.3에서 평가자료의 nDCG@10를 기준으로 선택한 α 가 시험자료에 대해서도 가장 높은 nDCG@10을 갖는 것을 알 수 있다. nDCG@10 외에도 대부분의 경우 튜닝으로 얻은 α 가 가장 좋은 성능을 보여준다.

5. 결론

우리는 Rendle 등 (2009)이 제안한 BPR-Opt 기준이 내재적피드백의 수치 정보들을 적극적으로 활용하지 않는 한계점을 극복하기 위해 확실함의 정도에 수치 정보를 활용하는 MBPR-Opt 기준을 제안했다. 이는 Hu 등 (2008)에서 제시한 행렬인수분해 방법으로 내재적피드백을 활용하는 접근법에서 착안한 것으로, 내재적 피드백이 큰 자료는 믿을만한 자료로 판단되며 이를 모형 적합에 보다 큰 영향력을 가지도록 한 것이다. 앞의 실제 데이터 적용 결과에서 보듯이, MBPR-Opt 기준이 기존의 BPR-Opt 보다 precision과 nDCG 값이 더 우수한 것을 확인할 수 있었다. 또한, 평가자료를 기준으로 튜닝한 결과가 시험자료에서도 좋은 성능을 보여주는 것을 확인하였다. 이 논문에서 제시한 MBPR-Opt 기준을 활용하면, 페이지안개인화순위를 사용하는 과정에 내재적피드백의 정보 손실을 줄임과 동시에 손쉽게 성능을 향상시킬 수 있을 것으로 기대한다.

References

- Hu, Y., Koren, Y., and Volinsky, C. (2008). Collaborative filtering for implicit feedback datasets. In *Proceeding ICDM '08 Proceedings of the 2008 Eighth IEEE International Conference on Data Mining*, 263–272.
- Koren, Y., Bell, R., and Volinsky, C. (2009). Matrix factorization techniques for recommender systems, *Computer*, **42**, 30–37.

- Oard, D. W. and Kim, J. (1998). Implicit feedback for recommender systems. In *Proceedings of the AAAI Workshop on Recommender Systems*, 81–83 .
- Rendle, S. and Freudenthaler, C. (2014). Improving pairwise learning for item recommendation from implicit feedback. In *Proceedings of the 7th ACM International Conference on Web Search and Data Mining*, 977–985.
- Rendle, S., Freudenthaler, C., Gantner, Z., and Schmidt-Thieme, L. (2009). BPR: Bayesian personalized ranking from implicit feedback. In *Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence*, 452–461.
- Sarwar, B., Karypis, G., Konstan, J., and Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. In *Proceedings of the 10th International Conference on World Wide Web*, 285–295 .
- Wang, S., Zhou, X., Wang, Z., and Zhang, M. (2012). Please spread: recommending tweets for retweeting with implicit feedback. In *Proceedings of the 2012 Workshop on Data-Driven User Behavioral Modelling and Mining from Social Media*, 19–22 .

비이진 내재적 피드백 자료를 위한 변형된 베이지안 개인화 순위 방법

김동우^a · 이은령^{b,1}

^a서울대학교 통계학과, ^b성균관대학교 통계학과

(2017년 10월 20일 접수, 2017년 11월 5일 수정, 2017년 11월 8일 채택)

요약

베이지안개인화순위(Bayesian personalized ranking) 방법은 내재적 피드백 자료를 분석하는 최첨단 추천시스템 통계기법 중 하나이다. 하지만, 기존의 베이지안개인화순위 방법은 내재적 피드백 자료를 변환한 이진 자료만을 고려하기 때문에 정보의 손실이 있을 수 있다는 단점이 있다. 이를 해결하기 위해 본 논문에서는 내재적 피드백 자료의 수치적 크기에 기반한 확실함의 정도(level of confidence)를 고려하는 변형베이지안개인화순위 방법을 제안한다. 제안한 방법은 기존 방법처럼 상품간의 개인 선호도에 관한 직관적인 확률모형 구조를 여전히 지니면서 내재적 피드백의 수치적 크기를 확실함의 정도로 반영할 수 있다는 점에서 유용하다. 또한 제안한 변형 베이지안개인화순위 방법을 수치적으로 구현하기 위해 확률그라디언트하강(stochastic gradient descent) 기법에 기반한 계산 알고리즘을 제시한다. 마지막으로, 스티프 비디오 게임 실제 데이터 분석을 통하여 기존방법에 비해 우수한 성능을 입증한다.

주요용어: 추천시스템, 내재적 피드백, 확실함의 정도, 행렬인수분해, 베이지안개인화순위

본 연구는 한국 연구재단의 지원을 받아 수행한 연구임 (No. NRF-2016R1C1B1011874).

¹교신저자: (03063) 서울시 종로구 성균관로 25-2, 성균관대학교 통계학과. E-mail: silveryyue@gmail.com