

추천시스템을 위한 베이지안 협력-경쟁 필터링

임희진⁰ 최재득 석재현 김기응

한국과학기술원 전산학과

{hlim, jdchoi, jhseok}@ai.kaist.ac.kr, kekim@cs.kaist.ac.kr

Bayesian Collaborative Competitive Filtering

Heejin Lim⁰ Jaedeug Choi Jae-Hyun Seok Kee-Eung Kim

Department of Computer Science, KAIST

요 약

추천시스템은 시스템이 제공하는 추천과 이에 따른 사용자의 응답이라는 상호작용을 수반하는 시스템이다. 이러한 상호작용 과정을 추천모델의 학습에 사용하는 협력-경쟁 필터링(collaborative competitive filtering)이라는 선택기반의 추천시스템이 최근 제안되었다. 하지만 이 알고리즘은 많은 계산비용을 수반하는 정규화 매개변수(regularization parameter) 조정과정이 필요하다는 단점이 존재한다. 본 논문에서는 협력-경쟁 필터링에 베이지안(Bayesian)기법을 적용하여 매개변수의 조정과정이 필요하지 않은 베이지안 협력-경쟁 필터링(Bayesian collaborative competitive filtering)을 제안한다. 또한, 모델에서의 효과적인 추론을 위한 마르코프 사슬 몬테카를로(Markov chain Monte Carlo) 알고리즘을 소개하며, 대규모의 데이터세트에서의 실험을 통하여 베이지안 협력-경쟁 필터링이 협력-경쟁 필터링보다 우수함을 확인하였다.

1. 서론

추천시스템은 정보 필터링 시스템의 한 종류로서 사용자의 상품에 대한 평가(rating) 혹은 선호도를 예측하는 시스템이다. 최근 온라인 쇼핑이 성장하면서 이러한 추천시스템의 중요성이 대두되고 있다. 이러한 필요성에도 불구하고 데이터 희소성이라는 문제 때문에 효과적인 추천시스템의 구현은 여전히 힘든 과제로 남아있다. 협력 필터링(collaborative filtering)은 이러한 문제를 다루기 위하여 가장 많이 사용되는 기법의 하나로서, “사용자 A와 B가 특정 상품들에 대하여 비슷한 선호도를 보인다면, 다른 상품에 대해서도 비슷한 선호도를 가질 것이다”라는 가정하에 사용자들에게 상품을 추천해주는 시스템이다. 현존하는 대부분의 추천시스템은 평가기반의 추천시스템으로서, 사용자가 과거에 상품들에 부여한 평가를 기반으로 동작한다. 하지만 이러한 평가기반의 추천시스템은 사용자가 상품을 선택할 당시의 사용자 시스템간의 상호작용을 간과하고 있다. 추천시스템에서의 사용자-시스템 상호작용은 크게 세 단계로 나뉜다. 1) 사용자가 시스템에 추천을 요청한다. 2) 이에 응하여 시스템은 사용자에게 상품의 집합인 선택집합(choice set)을 제공한다. 3) 사용자는 주어진 선택집합에서 하나의 상품을 선택한다. 기존의 평가기반의 추천시스템에서는 이러한 상호작용을 배제한 채 오로지 각 상품에 대한 평가만을 사용하였다. 반면 선택기반의 추천시스템은 이러한 상호작용에서의 사용자의 선택행동양식을 모델링하여 선호도 학습에 사용한다. 이러한 추가적인 모델링을 통해 선택기반 추천시스템은 기존의 평가기반 추천시스템보다 좀 더 정확한 정보들을 학습할 수 있다.

최근 Yang et al.[1]이 협력-경쟁 필터링(collaborative competitive filtering)이라는 선택기반의 추천 알고리즘을 제안하였다. 이 알고리즘에서는 다항로짓모델(multinomial logit model)을 사용하여 사용자의 선택행동양식을 모델링 하였다. 하지만 협력-경쟁 필터링 모델의 학습에는 정규화 매개변수(regularization parameter)에 대한 조정과정이 필요하다는 단점이 있다. 본 논문에서는 베이지안 기법을 활용하여 이러한 과정이 필요하지 않은 베이지안 협력-경쟁 필터링(Bayesian collaborative competitive filtering)을 제안한다. 또한 모델의 효과적인 학습을 위한 마르코프 사슬 몬테카를로(Markov chain Monte Carlo) 알고리즘 또한 제안한다. 본 논문에서는 협력 필터링의 성능평가에 널리 쓰이는 두 개의 영화 데이터세트를 사용하였으며, 두 데이터세트에서 모두 베이지안 협력-경쟁 필터링이 협력-경쟁 필터링 보다 AUC의 관점에서 우수함을 보였다.

2. 이산선택모델

추천시스템에서의 사용자-시스템 상호작용은 다음과 같이 나타낼 수 있다. 사용자 $u \in \mathcal{U}$ 와 상품 $i \in \mathcal{I}$ 가 존재한다. 사용자 u 가 추천을 요청하였을 때, 추천시스템은 선택집합(choice set) $\mathcal{C} = \{i_1, \dots, i_{|\mathcal{C}|}\}$ 를 추천한다. 이때 사용자 u 는 자신의 선호도와 가장 부합하는 상품 i^* 를 선택한다. 이러한 추천시스템에서의 사용자와 시스템간의 상호작용은 이산선택모델(discrete choice model)으로써 나타낼 수 있다[2]. 이산선택모델은 무작위효용모델(random utility model)로부터 다음과 같이 유도될 수 있다. 의사결정자 혹은 사용자 u 는 주어진 선택집합 \mathcal{C}

의 각각의 상품 i 로부터 효용 U_{ui} 를 얻을 수 있다. 이때 사용자는 효용을 최대화하는 상품 i^* 를 선택한다 ($U_{ui^*} > U_{ui}, \forall i \neq i^*$). 이산선택모델에서는 효용 U_{ui} 를 $U_{ui} = V_{ui} + \varepsilon_{ui}$ 로 정의한다. 여기서 대표효용 (representative utility) V_{ui} 는 사용자의 선호도를 특징짓는데, 이는 이미 알려진 사용자의 특성(feature)에 대한 결정함수로서 모델링 된다. 알려지지 않은 사용자의 특성으로 인한 불확실성은 ε_{ui} 로 나타내며, ε_{ui} 를 어떻게 모델링 하는지에 따라 이산선택모델의 종류가 결정된다.

다항로짓모델은 대표적인 이산선택모델로서, ε_{ui} 가 겐벨분포를 따른다고 가정한다. 이러한 가정을 따르면, 사용자 u 가 주어진 선택집합 \mathcal{C} 에서 상품 i 를 선택할 확률인 선택확률 P_{ui} 는 다음과 같이 유도된다.

$$P_{ui} = \frac{\exp(V_{ui})}{\sum_{j \in \mathcal{C}} \exp(V_{uj})}$$

3. 협력-경쟁 필터링

협력-경쟁 필터링 [1]은 다항로짓모델을 사용하여 추천시스템에서의 사용자-시스템 상호작용을 모델링한다. 잠재요인모델(latent factor model)을 사용하여 대표효용 V_{ui} 를 D 차원 벡터 ϕ_u 와 ϕ_i 의 내적으로 정의한다 ($V_{ui} = \phi_u^T \phi_i$). 수집된 N 개의 선택 데이터 $\mathcal{D}_{n=1}^N = \{(u_n, \mathcal{C}_n, i_n^*)\}_{n=1}^N$ 의 우도함수는 다항로짓모델과 잠재요인모델을 사용하여 다음과 같이 정의될 수 있다.

$$p(\{i_n^*\}_{n=1}^N | \phi_{u \in \mathcal{U}}, \phi_{i \in \mathcal{I}}, \{u_n, \mathcal{C}_n\}_{n=1}^N) = \prod_{n=1}^N \frac{\exp(\phi_{u_n}^T \phi_{i_n^*})}{\sum_{j \in \mathcal{C}_n} \exp(\phi_{u_n}^T \phi_j)}$$

주어진 우도함수를 기반으로 벌점최대우도법(penalized maximum likelihood)을 통해 도출한 목적함수에 대해 경사하강법(gradient descent)을 사용하여 최적화를 수행하면 최적의 사용자 특성벡터와 상품 특성벡터를 찾을 수 있다. 이러한 협력-경쟁 필터링의 단점은 모델의 복잡도 제어를 위해 정규화 매개변수를 수동으로 조정해야 한다는 점인데, 이 때 다수의 모델이 학습되어야 하므로 매우 큰 계산비용이 요구된다. 본 논문에서는 베이지안 기법을 사용하여 이러한 정규화 매개변수에 대한 조정과정 없이도 모델의 학습이 가능하고, 선호도 예측 성능 또한 협력-경쟁 필터링보다 뛰어난 베이지안 협력-경쟁 필터링을 제안한다.

4. 베이지안 협력-경쟁 필터링

베이지안 협력-경쟁 필터링은 협력-경쟁 필터링에서의 정규화 매개변수를 모델의 초모수로 놓음으로써 모델 스스로가 주어진 데이터를 가지고 초모수를 학습하도록 하였다. 따라서 협력-경쟁 필터링과는 달리 정규화 매개변수의 조정과정이 필요치 않다. 베이지안 협력-경쟁 필터링의 그래프 모델은 그림 1과 같다.




그림 1 베이지안 협력-경쟁 필터링의 그래프 모델

베이지안 협력-경쟁 필터링에서는 사용자와 상품 특성벡터의 사전분포는 가우시안분포를 따른다고 가정한다. 그리고 가우시안분포의 초모수 $\theta_{user} = \{\mu_{user}, \Lambda_{user}\}$ 와 $\theta_{item} = \{\mu_{item}, \Lambda_{item}\}$ 은 가우시안-위샤트분포를 따른다고 가정한다. 가우시안-위샤트분포의 초모수인 $\theta_0 = \{\mu_0, \beta_0, \mathbf{W}_0, \mathbf{v}_0\}$ 는 협력-경쟁 필터링과는 달리 알고리즘의 성능에 큰 영향을 미치지 않으므로, 단순히 $\mu_0 = 0, \beta_0 = 1, \mathbf{W}_0 = \mathbf{I}, \mathbf{v}_0 = D$ 로 설정하여 사용한다. 이처럼 정의된 그림 1의 그래프 모델의 결합분포는 다음과 같다.

$$p(\{i_n^*\}_{n=1}^N, \phi_{u \in \mathcal{U}}, \phi_{i \in \mathcal{I}}, \theta_{user}, \theta_{item} | \{u_n, \mathcal{C}_n\}_{n=1}^N, \theta_0) = \prod_{n=1}^N \frac{\exp(\phi_{u_n}^T \phi_{i_n^*})}{\sum_{j \in \mathcal{C}_n} \exp(\phi_{u_n}^T \phi_j)} \prod_{u \in \mathcal{U}} \mathcal{N}(\phi_u | \mu_{user}, \Lambda_{user}^{-1}) \prod_{i \in \mathcal{I}} \mathcal{N}(\phi_i | \mu_{item}, \Lambda_{item}^{-1}) \mathcal{N}(\mu_{user} | \mu_0, (\beta_0 \Lambda_{user})^{-1}) \mathcal{W}(\Lambda_{user} | \mathbf{W}_0, \mathbf{v}_0) \mathcal{N}(\mu_{item} | \mu_0, (\beta_0 \Lambda_{item})^{-1}) \mathcal{W}(\Lambda_{item} | \mathbf{W}_0, \mathbf{v}_0)$$

위와 같이 주어진 결합분포에서 모든 사용자와 상품에 대한 대표효용 $\mathbf{V} = \{V_{ui} | \forall u \in \mathcal{U}, \forall i \in \mathcal{I}\}$ 의 분포 $p(\mathbf{V} | \mathcal{D}_{n=1}^N, \theta_0)$ 를 근사하기 위하여 마르코프 사슬 몬테카를로 알고리즘을 사용한다(그림 2). 모델의 모수인 ϕ_u 와 ϕ_i 의 경우 사전분포인 가우시안분포가 다항로짓의 켈레 사전분포(conjugate prior)가 아니므로, 초모수와는 달리 사후분포에서 직접 표본추출을 하는 것이 불가능하다. 이를 해결하기 위하여 메트로폴리스-해스팅스(Metropolis-Hastings) 알고리즘을 사용하여 모수의 표본을 취하였다.

1: 특성벡터 $\{\phi_{u \in \mathcal{U}}, \phi_{i \in \mathcal{I}}\}$ 를 초기화한다.

```

2: for m = 1 ... M
3:    $\theta_{user} \sim p(\theta_{user} | \phi_{u \in \mathcal{U}}, \theta_0)$ 
4:    $\theta_{item} \sim p(\theta_{item} | \phi_{i \in \mathcal{I}}, \theta_0)$ 
5:   for u  $\in \mathcal{U}$ 
6:      $\phi_u \sim p(\phi_u | \mathcal{D}_{n=1}^N, \phi_{i \in \mathcal{I}}, \theta_{user})$ 
7:     for i  $\in \mathcal{I}$ 
8:        $\phi_i \sim p(\phi_i | \mathcal{D}_{n=1}^N, \phi_{u \in \mathcal{U}}, \phi_{i \in \mathcal{I}}, \theta_{item})$ 

```

그림 2 마르코프 사슬 몬테카를로 알고리즘의 의사코드

5. 실험 결과

선택기반의 협력필터링 알고리즘을 평가하기 위해서는 선택집합에 대한 정보가 포함된 데이터셋이 필요한데, 안타깝게도 이러한 정보를 제공하는 선택 데이터셋을 찾을 수가 없었다. 따라서 [1]에서처럼 선택 데이터셋을 평가 데이터셋으로부터 생성한다. 본 논문의 실험에서 생성되는 선택집합의 크기는 10으로 설정하였다. 또한, 알고리즘의 평가는 [3]에서와 유사하게 크기가 1,001인 재고목록을 생성하였다. 이렇게 생성된 재고목록을 기준으로 두 협력필터링 알고리즘의 평균 AUC 성능을 평가하였다.

5.1 MovieLens 데이터셋

MovieLens 데이터셋은 대표적인 협력필터링 데이터셋이다. 10개 미만의 평가를 지닌 사용자와 상품의 필터링 이후, 데이터셋에는 총 5천명의 사용자와 2천개의 상품과 19만개의 선택 데이터가 존재한다. 협력-경쟁 필터링과 베이지안 협력-경쟁 필터링 모두 10차원($D = 10$)의 특성벡터를 사용하였다. 데이터셋을 총 5번 무작위로 생성한 뒤 평균을 낸 결과를 보고하였다(그림 3). 실험 결과의 표준오차는 $1e-4$ 이하였으므로 보고하지 않았다.




그림 3 MovieLens 데이터셋에서의 AUC 성능

베이지안 협력-경쟁 필터링의 경우 모든 가능한 정규화 매개변수를 암시적으로 고려하여 모델을 학습하므로 협력-경쟁 필터링보다 더 좋은 성능을 보였다. 반면, 베이지안 협력-경쟁 필터링의 경우 한번의 반복수행마다 협력-경쟁 필터링보다 2배 정도의 시간이 필요하다. 하

지만 협력-경쟁 필터링은 최적의 정규화 매개변수를 찾으려면 다수의 모델을 학습하여야 하므로, 베이지안 협력-경쟁 필터링이 오히려 더 적은 학습 시간이 필요하면서 더 좋은 성능을 보인다고 해석할 수도 있다.

5.2 Netflix 데이터셋

Netflix 데이터셋에서의 실험 또한 MovieLens 데이터셋에서의 실험과 동일하게 수행되었다. 20개 미만의 평가를 지닌 사용자와 상품의 필터링 후, 데이터셋에는 총 25만명의 사용자, 1만 5천개의 상품, 1천 8백만개의 선택 데이터가 존재한다. 그림 4는 Netflix 데이터셋에서의 두 알고리즘의 성능을 비교한다.




그림 4 Netflix 데이터셋에서의 AUC 성능

6. 결론

협력-경쟁 필터링은 사용자의 선택행동양식을 다항로짓모델로써 모델링하는 선택기반의 추천시스템이다. 이 모델의 학습에는 정규화 매개변수의 수동조정을 필요로 한다는 단점이 있다. 본 논문에서는 이러한 절차가 필요하지 않은 베이지안 협력-경쟁 필터링을 제안하였다. 또한 베이지안 협력-경쟁 필터링 모델에서의 효과적인 추론을 위하여 마르코프 사슬 몬테카를로 알고리즘도 제안하였으며, 이를 통해 두 개의 매우 큰 데이터셋에 대하여 기존의 협력-경쟁 필터링보다 AUC 성능이 향상된 것을 보였다.

참고문헌

[1] S. H. Yang, B. Long, A. Smola, H. Zha, and Z. Zhang. Collaborative competitive filtering: Learning recommender using context of user choice. *In Proc. of SIGIR*, 2011.

[2] K. E. Train. *Discrete Choice Methods with Simulation*. Cambridge University Press, 2009.

[3] P. Cremonesi, Y. Koren, and R. Turrin. Performance of recommender algorithms on top-n recommendation tasks. *In Proc. of RecSys*, 2010.