

개인화된 전문가 그룹을 활용한 추천 시스템

Personalized Expert-Based Recommendation

정연오* · 이성우* · 이지형*

Yeounoh Chung, Sungwoo Lee, and Jee-Hyong Lee[†]

*성균관대학교 정보 및 지능시스템 연구실

[†]Information & Intelligence System Lab., Sungkyunkwan University

요 약

전문가의 지식을 기반으로 한 추천시스템에 대한 다양한 연구가 최근 활발히 진행되고 있다. 지금까지의 전문가 기반 추천 시스템이 공통된 전문가 그룹의 지식을 바탕으로 모두에게 아이템을 추천하였다면, 본 논문에서는 개인의 필요와 전문가에 대한 관점을 반영한 개인화된 전문가 그룹의 지식을 기반으로 한 추천 시스템을 제안한다. 개인화된 전문가 그룹을 찾는 과정이 제안하는 추천 시스템에서 가장 중요한 부분이다. 이를 위해 개인화된 전문가를 효율적으로 찾아내는 지지 벡터 머신(SVM) 기반 기법을 제안한다. 추천 시스템에서 널리 사용되는 k 근접이웃 알고리즘과의 비교를 통하여 개인화된 전문가를 기반으로 한 협업 필터링 추천 시스템의 효용성을 입증한다.

키워드 : 지지 벡터 머신(SVM), 전문가 기반 추천시스템, k 근접이웃, 협업 필터링

Abstract

Taking experts' knowledge to recommend items has shown some promising results in recommender system research. In order to improve the performance of the existing recommendation algorithms, previous researches on expert-based recommender systems have exploited the knowledge of a common expert group for all users. In this paper, we study a problem of identifying personalized experts within a user group, assuming each user needs different kinds and levels of expert help. To demonstrate this idea, we present a framework for using Support Vector Machine (SVM) to find varying expert groups for users; it is shown in an experiment that the proposed SVM approach can identify personalized experts, and that the personalized expert-based collaborative filtering (CF) can yield better results than k -Nearest Neighbor (k NN) algorithm.

Key Words : Support Vector Machine (SVM), Expert-based Recommender System, k -Nearest Neighbor, Collaborative Filtering.

1. 서 론

근래 아마존(Amazon.com)과 같은 e-commerce 서비스들의 성공으로 추천시스템에 대한 관심이 커지고 있다. 이를 반영하듯 지난 십 수 년간 추천시스템에 대한 연구가 활발히 진행되었으며, 지속적으로 더 나은 추천시스템을 개발

하기 위한 노력이 기울여 지고 있다.

일반적인 추천시스템은 사용자의 과거 히스토리에 기반을 두어 사용자 프로파일을 생성하고, 이 프로파일 정보를 통해 다른 유사한 사용자들이 좋아한 아이템이나, 혹은 사용자가 좋아한 아이템과 유사한 아이템을 추천한다[8].

이러한 추천시스템의 추천 정확도를 높이기 위한 다양한 시도가 있었는데, 그러한 시도 중 전문가의 지식을 기반으로 아이템을 추천하는 연구가 있다. 사용자들은 대개 의사 결정 과정에서 전문가의 의견을 신뢰한다는 가정 하에 영화 평론가 등 실제 전문가들의 지식을 활용하거나[1] 사용자 그룹 내에 전문가를 찾아내는[2] 연구들이 진행되었다. 이러한 전문가 기반 추천시스템들이 상당히 의미 있는 결과들을 보여주었지만, 모든 사용자들에게 동일한 전문가 지식을 기반으로 추천을 한다는 점에서 여전히 제한적이다.

다양한 사용자들의 관점이나 필요는 서로 상이할 수 있다. 그렇기 때문에, 개인의 필요와 전문가에 대한 관점을 반영한 개인화된 전문가 그룹을 사용자들에게 소개할 필요가 있다. 본 논문에서는 각 사용자 별로 개인화된 전문가 그룹을 찾는 문제를 정의하고, 개인화된 전문가 지식을 활용하여 추천을 하는 추천시스템을 제안한다.

접수일자: 2012년 10월 28일

심사(수정)일자: 2012년 10월 28일

게재확정일자: 2013년 2월 6일

[†] Corresponding author

본 논문은 본 학회 2012년도 추계 학술대회에서 선정된 우수논문입니다.

본 연구는 지식경제부 및 한국산업기술평가관리원의 산업융합원천기술개발사업(K1001810041244)에서 지원하여 연구하였습니다.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

제안하는 시스템에서는 개인화된 전문가 그룹을 찾는 과정이 가장 중요한 부분이라고 할 수 있다. 이 과정을 효율적으로 처리하기 위해서, 패턴인식이나 이진분류 문제에 널리 사용되는 지지 벡터 머신 기법을 사용하는데[6], 지지 벡터 머신 모델학습을 위해 실제 개인화된 전문가 트레이닝 샘플이 필요하다. 이러한 문제를 해결하기 위해 먼저 임의탐색을 사용하여 최적의 개인화된 전문가 그룹에 근사한 전문가들을 찾아낸다. 근사한 전문가들을 트레이닝 샘플로 활용해 개인화된 전문가 그룹을 효율적으로 찾는 지지 벡터 머신 기반 모델을 학습 시킨다.

k 근접이웃 알고리즘과의 비교 실험을 통하여 사용자 별로 상이한 개인화된 전문가가 존재한다는 것과 개인화된 전문가를 기반으로 한 추천시스템의 효용성을 입증하였다.

본 논문은 다음과 같은 순서로 구성되어 있다. 2장에서는 전문가 기반 추천시스템과 지지 벡터 머신을 활용한 추천시스템에 대한 관련 연구에 대해 기술한다. 3장에서는 개인화된 전문가를 찾는 문제를 정의하고, 이 문제를 풀기 위한 임의탐색 기법과 지지 벡터 머신 기법을 설명한다. 4장에서는 Netflix Prize 데이터를 사용한 실험결과를 제시한다. 5장에서는 결론 및 향후 연구에 대해 기술한다.

2. 관련연구

2.1 전문가 기반 추천시스템

기존 전문가 기반 추천시스템은 공통된 전문가들의 지식을 모든 사용자들에게 동일하게 적용하여 추천을 한다. Amatrianin 등은 소수의 영화 평론가의 의견을 종합하여 상대적으로 더 큰 사용자 그룹에게 추천을 하는 방식을 제안하였다[1]. 이를 통해 추천시스템에서 일반적으로 사용되는 협업 필터링 알고리즘의 문제점들(sparse data, cold start problem)을 완화하였을 뿐만 아니라, 전문가 지식이 실제로 추천시스템에서 활용될 수 있음을 보여주었다.

Sang 등은 사용자 그룹 내에서 전문가를 찾아내는 연구를 진행하였다[2]. 전문성을 세 가지 다른 수식으로 정의하고, 상대적으로 더 높은 전문성을 가진 사용자들을 기반으로 추천을 한다. 이를 통해 전문가 기반 추천시스템의 가능성을 보여주었을 뿐만 아니라, 정의된 전문성의 의미와 추천 성능과의 상관관계를 보여주었다.

2.2 지지 벡터 머신을 활용한 추천시스템

성능상의 문제로 지지 벡터 머신은 추천시스템에서 잘 사용되지 않는다. 대부분의 사용자가 존재하는 아이템 중 일부분만을 사용하고 평가한 경우, 사용자-아이템 매트릭스의 대부분이 비어있기 때문에(sparse data) 지지 벡터 머신의 학습이 어렵기 때문이다. 이러한 문제를 해결하고 지지 벡터 머신을 추천시스템에 활용하기 위한 연구를 진행하였으나[3], 여전히 개인화된 추천을 위해 사용자 마다 지지 벡터 머신 모델을 생성해야 하는 문제가 있다[4][5].

본 논문에서는 개인화된 전문가 그룹들을 찾는데 단 한 개의 지지 벡터 머신 모델을 사용하고, 추천에는 전문가들의 지식을 활용하는 협업 필터링 알고리즘을 활용한다.

3. 개인화된 전문가

3.1 문제 정의

사용자 그룹, $U = \{u_i\}$, 아이템 그룹, $I = \{i_j\}$, 그리고 아이템 선호도, r_{u_j} , 가 주어졌을 때 개인화된 전문가 그룹을 찾고자 한다. 여기서 전문가란 추천시스템의 정확도를 높이는 데 도움이 되는 아이템 선호도 정보나 히스토리를 가진 사용자들을 의미한다.

개인화된 전문가를 찾는 문제는 다음과 같이 공식화 될 수 있다:

$$\operatorname{argmax}_{f_w} \sum_i \tau(V_{f_w(u_i)}, V_{u_i}^*) \quad (1)$$

$V_{u_i}^* = \{v_{ij}^*\}$ 는 u_i 를 위한 최적의 개인화된 전문가 그룹이다. u_i 를 위한 개인화된 전문가 그룹, $V_{f_w(u_i)}$ 은 지지 벡터 머신이 학습한 f_w 을 통해 찾아낸다. $\tau(V_{f_w(u_i)}, V_{u_i}^*)$ 는 두 그룹간의 유사도를 측정하므로, 개인화된 전문가를 찾는다는 것은 최적의 개인화된 전문가 그룹에 가장 유사한 사용자 그룹을 찾아내는 f_w 을 찾는 의미를 갖게 된다.

3.2 개인화된 전문가를 위한 임의탐색 알고리즘

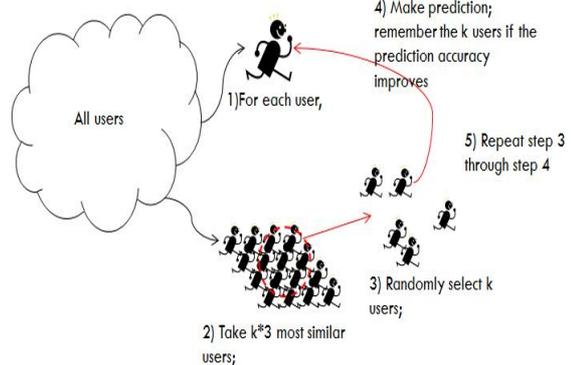


그림 1. 임의탐색을 이용해 찾은 개인화된 전문가 그룹을 활용한 협업 필터링 추천

Fig. 1. Collaborative Filtering based on personalized experts, identified by random search algorithm

지지 벡터 머신 모델학습을 위해 실제 개인화된 전문가 트레이닝 샘플이 필요하다. 이러한 문제를 해결하기 위해 먼저 임의탐색을 사용하여 최적의 개인화된 전문가 그룹에 근사한 전문가들을 찾아낸다.

임의탐색은 독립변수들(사용자)을 불규칙하게 선택하고, 선택된 독립변수들을 평가함수(추천 정확도)를 이용해 평가하게 된다. 충분한 수의 샘플이 사용된다면 결국 최적값을 찾을 수 있다[7].

더 나은 추천을 제공해 줄 수 있는 최적의 개인화된 전문가 그룹을 찾기 위해 모든 사용자의 추천 성능 이득을 평가해 보는 것은 계산 복잡도 측면에서 비현실적이다. 이러한 문제를 해결하기 위해서는 개인화된 전문가 그룹이 추천의 대상이 되는 사용자라 선호도 측면에서 어느 정도는 비슷할 것이라는 가정이 필요하다.

제안된 시스템에서는 추천 대상자와 선호도가 비슷한 사용자들 내에서 최적의 개인화된 전문가를 찾는다. 먼저, u_i 와 선호도가 유사한 사용자 그룹, $U_{u_i} = \{u_j\}$, 중 임의로 정

해진 숫자의 사용자들을 선택한다. 그리고 협업 필터링을 통해 추천을 하고 그 결과를 평가한다. 위 과정을 여러 번 반복하여 최적의 추천 성능을 내는 사용자 그룹 V_u 을 V_u^* 에 가까운 개인화된 전문가 그룹으로 설정한다.

추천 대상자와 선호도가 비슷한 사용자들 내에서 최적의 개인화된 전문가를 찾는 것은 여전히 계산 복잡도 측면에서 값비싼 작업이다. 다음 절에서는 개인화된 전문가를 효율적으로 찾기 위한 지지 벡터 머신 기법을 설명한다.

3.3 개인화된 전문가를 위한 지지 벡터 머신 기법

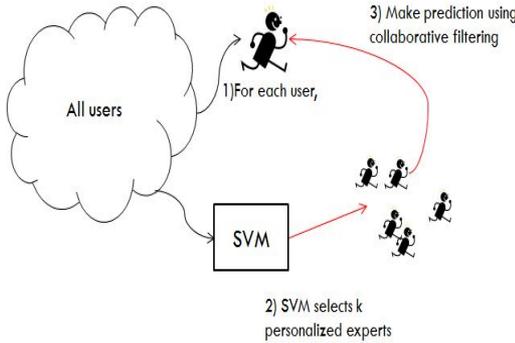


그림 2. 지지 벡터 머신을 이용해 찾은 개인화된 전문가 그룹을 활용한 협업 필터링 추천
Fig. 2. Collaborative Filtering based on personalized experts, identified by SVM

개인화된 전문가를 찾는 문제를 지지 벡터 머신 최적화 문제로 옮기면 다음과 같다:

$$\begin{aligned} \min_{\vec{w}} \quad & \frac{1}{2} \vec{w} \cdot \vec{w} + C \sum_i \sum_j \xi_{ij} \quad (2) \\ \text{s.t.} \quad & y_{ij} (\vec{w} \cdot \vec{X}_{ij} + b) \geq 1 - \xi_{ij}, \\ & \text{for all } \{(\vec{X}_{ij}, y_{ij})\} \text{ and } \xi_{ij} \geq 0 \end{aligned}$$

전문성 벡터 \vec{x}_{ij} 은 u_i 가 u_j 를 얼마나 전문가로 보는지를 표현한다. 임의탐색을 통해 u_i 의 최적의 개인화된 전문가 그룹에 가까운 전문가 그룹을 정답으로 가정하고, 모든 u_i 와 u_j 에 대해 전문가 라벨 y_{ij} 을 준다. y_{ij} 와 \vec{x}_{ij} 을 가지고 지지 벡터 머신 모델을 생성하고 $f_{\vec{w}}$ 을 학습시킨다.

3.3 전문성 벡터

전문성 벡터 \vec{x}_{ij} 은 u_i 가 u_j 를 얼마나 전문가로 보는지를 표현한다. 지지 벡터 머신 생성을 위해 모든 u_i 와 u_j 에 대해 다음 네 가지 관점에서 전문성 벡터를 생성하게 된다.

첫째, u_i 와 u_j 사이에 조정 코사인 유사성(adjusted cosine similarity)은 두 사용자의 선호도가 얼마나 비슷한지를 측정한다. 비슷하지 않은 선호도를 가진 전문가보다는, 비슷한 선호도를 가진 전문가의 의견이 더 의미가 있을 수 있다. 일반적인 추천 시스템에서는 유사도만을 활용하여 추천을 한다:

$$\frac{\sum_{m \in I(u_i) \cap I(u_j)} (R_{um} - \bar{R}_u)(R_{um} - \bar{R}_j)}{\sqrt{\sum_{m \in I(u_i) \cap I(u_j)} (R_{um} - \bar{R}_u)^2 \sum_{m \in I(u_i) \cap I(u_j)} (R_{um} - \bar{R}_j)^2}} \quad (3)$$

둘째, u_i 가 u_j 에 비해 얼마나 더 자주 서비스를 사용하는지를 측정한다. 서비스를 자주 사용하는 사용자가 해당 서비스나 도메인에 더 높은 전문성을 가질 수 있다:

$$\frac{|I(u_j)| - |I(u_i)|}{|I|} \quad (4)$$

셋째, u_j 가 u_i 에게 새로운 아이템들을 얼마나 많이 이용해 봤는지를 측정한다. u_i 가 이미 사용해 본 아이템들만을 사용해 본 사용자의 지식은 u_i 입장에서 상대적으로 비전문가 지식이거나 필요 없는 지식일 수 있다:

$$\frac{|I(u_j) - I(u_i)|}{|I|} \quad (5)$$

넷째, u_j 와 u_i 간의 평균 선호도 차이를 측정한다. 다른 사용자가 모든 아이템에 대해서 상대적으로 후하게 평가를 한 경우 전문성에 대한 신뢰성이 영향을 받을 수도 있다:

$$\frac{\bar{R}_u - \bar{R}_u}{\max(\bar{R}) - \min(\bar{R})} \quad (6)$$

u_i 와 u_j 사이에 전문성 벡터를 생성하기 위해 사용자의 선호도 히스토리 정보 $\langle u_i, i_j, r_{u_i} \rangle$ 만을 사용한다. 누구를 전문가로 보는지에 대한 사용자 피드백 없이 추천하는 것은 실제 시스템의 효용성을 위해 중요하다.

4. 실험결과

4.1 실험 데이터

실험에는 Netflix Prize¹⁾ 데이터를 사용하였다. Netflix Prize 데이터는 480,189 사용자, 17,770개 아이템(영화)에 대한 선호도 정보, $\langle u_i, i_j, r_{u_i} \rangle$ 를 포함하고 있다. 효율적인 실험 진행을 위해 전체 데이터에서 10,000명의 사용자와 1,000개의 아이템(영화)에 대한 선호도, $\langle u_i, i_j, r_{u_i} \rangle$, 데이터만을 가지고 실제 실험을 진행하였으며, 이를 사용자들 기준 으로 다시 9000명의 사용자로 이루어진 트레이닝 데이터와 1000명의 사용자로 이루어진 테스트 데이터로 구분한다.

4.2 k 근접 이웃 알고리즘

1)Netflix Prize: 미국 넷플릭스(Netflix)사에서 2006년부터 2009년 까지 자사의 데이터를 공개하고 진행한 영화 추천 시스템 관련 경진대회. 우승팀인 BellKor의 협업 필터링 기반 솔루션은 RMSE가 0.86 이었다[9][10].

협업 필터링 기반 추천 시스템에서 널리 사용되는 k 근접이웃 알고리즘의 추천 성능과의 비교 실험을 통해 제안된 추천 시스템의 효용성을 입증하고자 한다.

k 근접이웃 알고리즘에서는 이웃의 크기, 즉 k 값에 따라 추천예측의 정확도가 달라지는데, 추천의 정확도는 테스트 데이터에 대한 선호도 예측과 실제 선호도간의 표준오차 (RMSE)를 통해 측정한다:

$$\sqrt{\frac{1}{|S_{test}|} \sum_{(u,i) \in S_{test}} (R_{u,m} - P_{u,m})^2} \quad (7)$$

추천에 사용되는 근접 이웃의 사이즈가 17일 때 표준오차가 0.77로 가장 작았다.

표 1. k 근접이웃 알고리즘을 이용한 추천의 표준오차
Table 1. RMSE of k -Nearest Neighbor algorithm

| | | | | | |
|------|------|------|------|------|------|
| k | 5 | 14 | 17 | 20 | 40 |
| RMSE | 0.90 | 0.78 | 0.77 | 0.78 | 0.79 |

무조건 더 많은 사람들의 의견을 반영하는 것 보다는 적절한 수의 이웃들의 의견을 반영하는 것이 더 정확한 추천 결과를 나타낸다.

4.3 개인화된 전문가

개인화된 전문가 기반 추천 시스템의 효용성을 입증하기 위해서, 먼저 개인화된 전문가 지식이 단순히 유사한(근접) 이웃들의 지식보다 추천에 더 효과적임을 보여준다. 각 사용자 별로 최적의 개인화된 전문가 그룹의 크기를 17명으로 고정한 후 추천의 정확도를 평가한 결과는 아래(표 2)와 같다. 최적의 개인화된 전문가 그룹은 임의탐색 기법을 통해 찾아낸 개인화된 전문가 그룹을 최적의 개인화된 전문가 그룹으로 가정한다.

임의탐색 기법의 계산 복잡도로 인하여, 각 사용자 별 17명의 개인화된 전문가들을 찾을 때에는 17의 3배수인 51명의 가장 유사한 사용자만을 고려한다. 탐색은 3,000번 씩 반복되어지며, 최적의 전문가 그룹을 활용한 추천 표준오차는 0.06 이었다.

k 근접이웃 알고리즘의 결과에 비해 92% 향상된 결과는 추천에 더 큰 도움을 줄 수 있는 사용자 그룹, 즉 개인화된 전문가 그룹이 존재함을 보여준다.

표 2. k 근접 이웃을 활용한 추천과 최적의 개인화된 전문가를 활용한 추천의 표준오차 비교

Table 2. k NN vs. Optimal Personalized Expert based Collaborative Filtering (CF)

| | |
|--|------|
| CF Algorithm | RMSE |
| k Nearest Neighbor ($k=17$) | 0.77 |
| Personalized Expert (Random Search, $k=17$) | 0.06 |

지지 벡터 머신을 이용해 개인화된 전문가 그룹을 찾는 경우, 사용자 별로 개인화된 전문가 그룹을 찾는 데 드는 비용을 현저하게 줄일 수 있다. 또한 사용자 별로 필요한 전문가 그룹의 크기가 다를 수 있기 때문에, 지지 벡터 머신

모델은 추천 대상자의 관점에서 모든 개인화된 전문가들을 찾아내도록 한다. 표 3의 결과는 개인화된 전문가 그룹의 크기가 고정(17명)일 때 보다, 사용자 별로 필요한 만큼의 전문가를 의뢰했을 때(평균 214명) 더 나은 추천이 가능할 수 있음을 보여준다.

표 3. 개인화된 전문가 그룹 크기를 17명으로 고정된 경우와 고정하지 않은 경우에 따른 표준오차 비교

Table 3. RMSE of Personalized Expert based recommendation with different k

| | |
|--|------|
| CF Algorithm | RMSE |
| Personalized Expert (SVM, $k=17$) | 1.15 |
| Personalized Expert (SVM, avg. $k=214$) | 0.99 |

임의탐색을 통해 찾아낸 최적의 개인화된 전문가 그룹을 활용한 경우 대비, 지지 벡터 머신이 찾아낸 개인화된 전문가 그룹을 활용한 추천의 정확도가 떨어지는 것을 볼 수 있다. 개인화된 전문가의 수는 일반 사용자에게 비해 상대적으로 매우 적기 때문에 지지 벡터 머신은 클래스 불균형 데이터(class imbalanced data)에서 전문가를 찾아내는 규칙을 학습해야 하는 어려움이 있다.

표 4. 지지 벡터 머신의 개인화된 전문가 분류 결과
Table 4. Results of SVM for personalized expert identification

| | | |
|-------------|--------------|-----------|
| Accuracy(%) | Precision(%) | Recall(%) |
| 84.26 | 81.91 | 84.38 |

지지 벡터 머신이 전문가라고 판별한 사용자 중에 실제 전문가가 얼마나 되었는지를 나타내는 Precision이 81.91%로 나타났다. 정확한 추천을 위해서는 적절한 양의 의견들을 종합하여야 할 뿐만 아니라, 도움이 되는 의견들을 종합하는 것이 중요하다. 지지 벡터 머신이 더 정확하게 실제 전문가들을 판별해 낼 수 있다면, 전체 추천 시스템의 성능이 최적의 개인화된 전문가 그룹을 활용한 경우만큼 향상될 것 이다.

5. 결론 및 향후 연구

본 논문에서는 개인화된 전문가 그룹을 찾는 문제를 정의하고, 개인화된 전문가 그룹을 활용한 추천 시스템을 기술한다.

방대한 양의 실제 사용자와 아이템간의 선호도 정보를 담고있는 데이터를 사용한 실험을 통해서 사용자 마다 최선의 추천을 제공해 줄 수 있는 서로 다른 전문가 그룹이 존재함을 확인하였으며, 이를 임의탐색과 지지 벡터 머신 모델을 사용해 찾는 방법을 제안한다.

임의탐색을 사용해 찾아낸 개인화된 전문가 그룹을 활용할 경우 k 근접이웃을 활용하는 경우보다 추천의 정확도를 92% 높일 수 있었다. 지지 벡터 머신 모델은 계산 복잡도

나 연상량의 측면에서 임의탐색에 비해 훨씬 효율적이다. 하지만, 전문가의 수가 일반 사용자에게 비해 상대적으로 매우 적기 때문에 일반적인 지지 벡터 머신의 정확한 학습에 어려움이 있다.

향후 연구로는 지지 벡터 머신을 클래스 불균형 데이터에서의 학습성과 성능을 최적화 하여 개인화된 전문가 기반 추천 시스템의 효용성과 성능을 향상 시키는 연구와, 확률 추론 기반 모델을 통해 개인화된 전문가를 찾아내는 연구를 진행할 계획이다.

References

- [1] X. Amatrian, N. Lathia, J. M. Pujol, H. Kwak, and N. Oliver. "The Wisdom of The Few: A Collaborative Filtering Approach Based On Expert Opinions From The Web," *Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval (SIGIR'09)*. pp. 532-539. 2009.
- [2] S. Song, S. Lee, S. Park, and S.-g. Lee. "Determining User Expertise For Improving Recommendation Performance," *Proceedings of the 6th International Conference on Ubiquitous Information and Communication 2012 (ICUIMC 2012)*. 2012.
- [3] Z. Xia, Y. Dong and Y. Xing. "Support Vector Machines For Collaborative Filtering," *Proceedings of the 44th Annual Southeast Regional Conference*. pp. 169-174, 2006.
- [4] J. A. Xu and K. Araki. "A SVM-based Personal Recommendation System for TV Programs," *Proceedings of the 12th International Conference on Multi Media Modeling (MMM 2006)*. 2006.
- [5] S. Min and I. Goo. "Recommender Systems Using Support Vector Machines" *Proceedings of the 5th International Conference on Web Engineering (ICWE 2005)*. pp. 387-393, 2005.
- [6] V. N. Vapnik. *The Nature of Statistical Learning Theory*. Springer-Verlag. 1995.
- [7] Z. Zabinsky. (2009, April 5). "Random Search Algorithm". Available: <http://courses.washington.edu/inde510/516/RandomSearch4.05.2009.pdf>. 2009. [Accessed: Sep. 15. 2012]
- [8] Z. Wen. (2008, December 12). "Recommendation System Based on Collaborative Filtering". Available: <http://cs229.stanford.edu/proj2008/Wen-RecommendationSystemBasedOnCollaborativeFiltering.pdf>. 2008. [Accessed: Sep. 15. 2012]

- [9] R. Bell and Y. Koren, "Scalable Collaborative Filtering with Jointly Derived Neighborhood Interpolation Weights," *Proceedings of the 2007 Seventh IEEE International Conference on Data Mining (ICDM'07)*. pp. 43-52. 2007.
- [10] J. Herlocker, J. Konstan, L. Terveen, and J. Riedl, "Evaluating collaborative filtering recommender systems," *ACM Transactions on Information Systems (TOIS)*. Vol. 22. no. 1. pp. 5-53. 2004.

저 자 소 개



정연오(Yeounoh Chung)

2008년: Cornell Univ. 전자공학과 학사
 2009년: Cornell Univ. 전산학과 석사
 2012년~현재: 성균관대학교
 컴퓨터공학과 연구원

관심분야 : 통계학이론, 기계학습
 Phone : +82-31-290-7987
 E-mail : yeounohster@gmail.com



이성우(Sungwoo Lee)

2009년: 성균관대학교 컴퓨터공학과 학사
 2013년: 성균관대학교 컴퓨터공학과 석사
 2013년~현재: 농협중앙회

관심분야 : 웹, 데이터마ining, 지능시스템
 Phone : +82-31-290-7987
 E-mail : lsmoney@skku.edu



이지형(Jee-Hyong Lee)

1993년: 한국과학기술원 전산학과 학사
 1995년: 한국과학기술원 전산학과 석사
 1999년: 한국과학기술원 전산학과 박사
 2002년~현재: 성균관대학교
 정보통신공학부 부교수

관심분야 : 퍼지이론, 지능시스템, 기계학습
 Phone : +82-31-290-7154
 E-mail : john@skku.edu