

협업적 여과 추천 시스템을 위한 에러반영 모델 구축

김 흥 남[†] · 조 근 식^{**}

요 약

협업적 여과는 추천 시스템을 구축하는데 가장 널리 보급된 정보 여과 기법으로 사용자 각 개인의 관심에 적합한 정보 및 아이템을 추천함으로써 사용자들의 의사 결정에 도움을 준다. 그러나, 협업적 여과 기법은 우수한 추천 성능에도 불구하고 초기 진입 문제와 같은 대표적인 한계를 가지고 있다. 본 논문에서는 초기 진입 문제의 한계점을 보완하기 위해 새로운 모델 구축 방법과 구축된 모델들을 적용한 효율적인 협업적 추천 시스템을 제안한다. 제안된 협업적 여과 방법은 크게 2단계로 나뉘어질 수 있다. 첫 번째는 사전에 미리 사용자들이 선호 평가한 아이템에 대한 선호도 예측 에러 정보를 반영하여 모델을 구축하는 과정으로 대부분의 작업이 오프라인에서 수행된다. 두 번째는 미리 구축된 모델들을 적용하여 온라인에서 사용자에게 적합한 개인화된 아이템 추천 및 예측을 하는 과정이다. 사전에 측정된 에러 정보를 반영한 모델은 목적 사용자와 유사한 사용자 및 목적아이템과 유사한 아이템의 사전 평균 예측 에러를 활용하는 에러반영 모델로써 초기 진입 문제를 보완하면서 선호도 예측의 성능을 높이기 위한 모델이다. 또한 모델 기반의 협업적 여과의 단점인 재구축 비용을 감소시키고 사용자들의 새로운 선호도 피드백 정보에 대하여 계속적으로 반영 가능하게 하기 위해 점진적으로 새로운 정보를 갱신할 수 있는 구축 방법을 제안한다.

키워드 : 추천 시스템, 협업적 여과, 초기 진입 문제

Building Error-Reflected Models for Collaborative Filtering Recommender System

Heung Nam Kim[†] · Geun Sik Jo^{**}

ABSTRACT

Collaborative Filtering (CF), one of the most successful technologies among recommender systems, is a system assisting users in easily finding the useful information. However, despite its success and popularity, CF encounters a serious limitation with quality evaluation, called cold start problems. To alleviate this limitation, in this paper, we propose a unique method of building models derived from explicit ratings and applying the models to CF recommender systems. The proposed method is divided into two phases, an offline phase and an online phase. First, the offline phase is a building pre-computed model phase in which most of tasks can be conducted. Second, the online phase is either a prediction or recommendation phase in which the models are used. In a model building phase, we first determine a priori predicted rating and subsequently identify prediction errors for each user. From this error information, an error-reflected model is constructed. The error-reflected model, which is reflected average prior prediction errors of user neighbors and item neighbors, can make accurate predictions in the situation where users or items have few opinions; this is known as the cold start problems. In addition, in order to reduce the re-building tasks, the error-reflected model is designed such that the model is updated effectively and users' new opinions are reflected incrementally, even when users present a new rating feedback.

Keywords : Recommender System, Collaborative Filtering, Cold Start Problems

1. 서 론

인터넷과 World Wide Web의 사용이 보편화된 오늘날의 정보화 사회에서는 하루에도 헤아릴 수 없는 정보와 콘텐츠가 웹이란 공간에서 생산되고 소비되고 있다. 이러한 정보

화 환경에서 사용자들은 더욱 다양하고 많은 정보를 손쉽게 얻을 수 있게 되었지만, 오히려 과다한 정보로 인해 어떻게 자신들에게 가치 있고 적합한 정보를 찾아 낼 것인가의 문제에 부딪치게 되었다. 추천 시스템(recommender system)은 이러한 과다 정보 문제(information overload problem)의 대안으로 등장한 자동화된 정보 여과 시스템으로, 사용자 각 개인의 관심에 적합한 정보 및 아이템을 추천함으로써 사용자들의 의사 결정에 도움을 준다[11]. 협업적 여과(collaborative filtering)는 추천 시스템을 구축하는데 가장 널리 보급된 정

[†] 정 회 원 : 인하대학교 BK21 정보기술사업단 박사후 연구원
^{**} 종 신 회 원 : 인하대학교 컴퓨터정보공학과 교수
논문접수 : 2009년 3월 3일
수 정 일 : 1차 2009년 5월 8일
심사완료 : 2009년 5월 11일

보 여과 기법으로 학문적으로뿐만 아니라 상업적으로도 가장 많이 이용되고 있다. 이는 특정 사용자와 유사한 성향을 가진 다른 사용자들의 의견을 기반으로 하는 사회적 정보 여과 방법으로써 자동화된 "Word of Mouth," 현상을 이용한 추천이라 할 수 있다[16]. 최초로 유즈넷 기사를 자동으로 추천한 GroupLens 시스템[9, 12]의 개발 이후 사용자의 과거 구매 정보를 바탕으로 책을 추천해주는 Amazon.com [10], 사용자의 선호도 점수를 활용하여 DVD를 추천해주는 온라인 비디오 대여 서비스 Netflix.com, 온라인 음악 추천 사이트 Last.fm, 자동화된 온라인 뉴스 서비스 Google News[2] 등 협업적 여과는 다양한 도메인의 추천 시스템에 성공적으로 적용되어 사용되고 있다.

그럼에도 불구하고 협업적 여과는 실제 응용에서 초기 진입 문제(cold start problems)가 야기된다[15]. 즉, 협업적 여과 추천 시스템은 아직충분한 선호도 정보가 쌓이지 않은 사용자들 또는 아이템들에 대한 추천의 정확성을 향상시켜야 한다. 초기 진입 사용자는 사용자의 선호를 파악하기 위해 사용되는 선호 점수가 매우 적기 때문에 그 사용자의 선호 파악 및 이웃 집단 구성이 어려워 추천의 정확성이 떨어진다. 따라서 이들이 지속적으로 시스템을 활용하여 선호 평가를 하도록 유도해야 하지만 불충분한 정보로 예측된 부정확한 성능은 초기 사용자들로 하여금 시스템의 신뢰를 떨어뜨리고, 그 결과 사용자들의 시스템 이탈 및 활발한 활동을 저해 시키는 요인이 된다. 마찬가지로 초기 진입 아이템들은 역시 아직 사용자들로부터 충분한 선호 정보가 쌓이지 않았기에 지속적으로 선호도가 축적된 아이템들에 비하여 정확한 예측이 어렵고, 상대적으로 사용자들에게 추천되기가 어렵다. 따라서 본 논문에서는 협업적 여과의 초기 진입 문제를 보완할 수 있는 새로운 모델들과 그 구축 방법을 제안한다. 그리고 그 모델들을 적용한 효율적인 협업적 추천 시스템을 제안한다. 제안된 협업적 여과 방법은 크게 2단계로 나뉘어질 수 있다. 첫 번째는 사전에 미리 사용자와 아이템 간의 관계를 나타내는 모델들을 구축하는 과정으로 대부분의 작업이 오프라인에서 수행된다. 두 번째는 미리 구축된 모델들을 적용하여 온라인에서 사용자에게 적합한 개인화된 아이템 추천 및 예측하는 과정이다.

본 논문의 전체 구성은 다음과 같다. 2장에서는 이론적 고찰로 추천 시스템 기법 중 협업적 여과 방법에 대하여 기술한다. 3장에서는 사용자들이 이미 선호 평가한 아이템에 대하여 사전에 미리 선호도를 예측 방법에 대해서 기술한다. 그리고 이를 토대로 에러반영 모델을 구축하는 방법과 구축된 모델들을 이용한 새로운 협업적 여과 방법을 기술한다. 4장에서는 실험 및 분석을 통하여 본 연구의 타당성을 검증한다. 그리고 마지막으로 5장에서 결론을 맺고 향후 연구에 대해 논한다.

2. 협업적 여과 기반의 추천 시스템

정보 사회의 요구로부터 발달한 추천 시스템은 광범위하

게 연구되어 왔다. 본 장에서는 추천 시스템을 구축하는 데 가장 널리 사용되는 협업적 여과 기반의 추천 방법에 초점을 맞추어 기술한다.

비록 협업적 여과 기법은 다양한 도메인의 정보 여과 문제에 사용되며 연구되고 있지만, 일반적으로 m 명의 사용자들의 n 개의 아이템에 대한 각 개인의 과거 선호도 평점(rating) 정보를 사용한다. 이 선호도의 정보는 정의 1과 같이 $m \times n$ 선호도 행렬로 표현될 수 있다.

[정의 1] (사용자-아이템 선호도 행렬, R). m 명의 사용자 집합 $U = \{u_1, u_2, \dots, u_m\}$ 의 각 사용자가 n 개의 아이템 집합 $I = \{i_1, i_2, \dots, i_n\}$ 의 각 아이템에 대한 선호도는 $m \times n$ 사용자-아이템 선호도 행렬(user-item rating matrix)로 표현할 수 있다. 여기서 행은 사용자를, 열은 아이템을 의미하며, $R_{u,j}$ 는 사용자 u 의 아이템 j 에 대한 수치적 선호도 값을 나타낸다.

여기서 아이템은 온라인 뉴스, 웹 페이지, UCC, TV 프로그램, 책, 영화, 음악, 논문, 사진 등으로 가정될 수 있으며 사용자들의 아이템에 대한 과거 선호도는 아래와 같은 수치적인 순서 척도(ordinal scale)로 나타내어진다. 즉, 정의 1에서 행렬의 요소 $R_{u,j}$ 는 양수 R_{\min} 에서 양수 R_{\max} 사이의 정수 값 또는 아직 평가하지 않은 경우 중 하나에 속한다. 일반적으로 R_{\min} 은 1을 사용하고 R_{\max} 는 5로 사용한다. 경우에 따라서 R_{\max} 을 10으로 사용할 수도 있다.

$$R_{u,j} \in \{ R_{\min}, \dots, R_{\max}, \perp \}$$

사용자 u 가 아이템 j 에 대하여 R_{\min} 에 가까운 선호도 점수를 부여하였다면 그 아이템은 사용자 u 의 취향에 맞지 않음을 의미한다. 반대로 R_{\max} 에 가까운 선호도 점수로 평가하였다면 자신의 취향에 부합되는 아이템임을 의미한다. 만약 $R_{u,j}$ 의 값이 \perp 라면 사용자 u 는 아직 아이템 j 에 대해 평가하지 않았음을 의미하며, 궁극적으로 사용자 u 에 대하여 $R_{u,*} = \perp$ 인 아이템들이 추천 대상이 되는 아이템들이라 말할 수 있다. 전통적인 협업적 여과 방법은 마지막 단계에서 이러한 아이템들에 대해 추천 대상 사용자가 얼마나 그 아이템을 선호할 것인가를 예측하는 과정을 수행한다. 즉, 선호도 행렬 R 에서 u 번째 행의 목적사용자의 선호도 값이 \perp ($R_{u,*} = \perp$)인 아이템들을 자신의 이전 선호도와 다른 사용자들의 선호도를 바탕으로 예측한다.

정의 1의 선호도 행렬 R 에서 각 사용자의 선호도 값의 분산은 사용자 별로 다르게 분포할 수 있다. 예를 들어, 특정 사용자는 자신이 어느 정도 선호하는 아이템이라면 대부분 5점으로 평가하고 선호하지 않은 아이템을 3점으로 평가하는 반면, 다른 사용자는 대체적으로 선호하는 아이템에 4점으로 평가하고 선호하지 않은 아이템을 1점으로 평가할 수 있다. 그리고 많은 수의 아이템들에 선호도 점수를 표현한 사용자들이 있는 반면에 비교적 적은 수의 아이템들에 선호도 점수를 표현한 사용자들이 존재할 수 있다. 이러한 선호도 행렬의 특성으로 인해 자칫 잘못된 유사 이웃 집단이 구성될 수 있으며 이는 시스템의 아이템 선호도 예측에 잘

못된 영향을 미칠 수 있다. 이러한 문제를 보완하기 위해 Herlocker et al.[6]은 선호도 값에 대하여 중요 가중치(significance weight), 분산 가중치(variance weight), z 점수(z-score) 가중치 등을 부여하는 것을 제안하였다. 그리고 Deshpande et al.[3]은 선호도 행렬 R의 각 행을 아이템에 대한 n 차원(dimension)으로 하는 벡터로 취급하여 벡터의 길이를 1로 정규화하여 이용하였다.

협업적 여과 기법은 메모리 기반과 모델 기반으로 크게 두 가지 접근 방법으로 발전되어왔다[1]. 이 중 유사한 성향을 가진 사용자들은 같은 아이템을 선호할 것이라는 사실에 기초한 사용자 기반 접근 방법[4, 9, 14], 유사한 아이템들에 대한 나의 과거 선호가 특정 아이템의 선호에 영향을 미치는 관계에 초점을 둔 아이템 기반 접근 방법[3, 10, 13]이 가장 대중적으로 이용되고 있다.

2.1 메모리 기반의 접근 방법

Resnick et al.[12]에 의해 제안된 전통적인 사용자 기반의 협업적 여과는 사용자 기반의 관점에서 어떤 아이템에 대한 목적사용자(target user)의 선호도 점수를 예측하는 추천 방법이다. 우선, 이웃(neighborhood)으로 지칭되는 유사한 사용자의 집단 KNN(K Nearest Neighbors)을 구성한다. 이를 위해 각 사용자 간의 유사성 정도를 측정하는데, 코사인 유사도[1]와 피어슨 상관 계수(Pearson correlation)[12] 기반의 유사도 측정 방법이 가장 대표적으로 사용된다. 목적사용자와 유사한 사용자들을 이웃 집단으로 구성하며, 이들의 유사도 값과 선호도 점수는 아직 선호 평가하지 않은 특정 아이템에 대한 목적사용자의 선호도가 어느 정도인지를 예측하는 데 사용된다. 이웃 집단을 구성하는 이웃의 수가 너무 적으면 올바른 예측이 어려우며, 이웃의 수가 늘어날수록 예측의 정확도가 높아질 수 있지만 그만큼 계산량이 늘어나므로 가장 효율적인 이웃 집단의 크기를 결정해야 한다[14]. 이와 같이 가장 유사한 이웃 집단을 구성하여 이를 바탕으로 추천하는 사용자 기반의 협업적 여과를 메모리 기반의 협업적 여과라고도 하는데, 비교적 높은 예측 성능에도 불구하고 확장성과 실시간 성능, 사용자-아이템 데이터의 희박성에 관련된 심각한 제약을 갖는다[13]. 사용자와 아이템의 수가 증가할수록 이웃 집단을 찾기 위한 유사도 계산의 복잡도는 크게 증가한다. 사용자의 수가 매우 많은 일반적인 상업적 웹 사이트의 경우, 추천을 위해 각 사용자에게 대한 이웃 집단을 구성하는 것은 엄청난 계산을 요구하고 지속적인 사용자의 변화가 발생하므로 미리 계산된 사용자 간의 유사도나 이웃 집단의 이득을 기대할 수 없다[2]. 또한 사용자 간의 유사도는 서로 다른 사용자가 같은 아이템에 매긴 점수를 바탕으로 계산되는데, 아이템의 수가 많으면 많을수록 동시에 점수가 매겨진 아이템(co-rated items)의 비율은 적어진다. 즉, 다른 사용자와 동시에 점수를 매긴 아이템을 전혀 가지고 있지 않은 사용자가 존재하여 상관관계를 계산할 수 없거나, 그러한 아이템을 가지고 있더라도 그 수가 매우 적어

추천의 정확성을 떨어뜨릴 수 있다.

2.2 모델 기반의 접근 방법

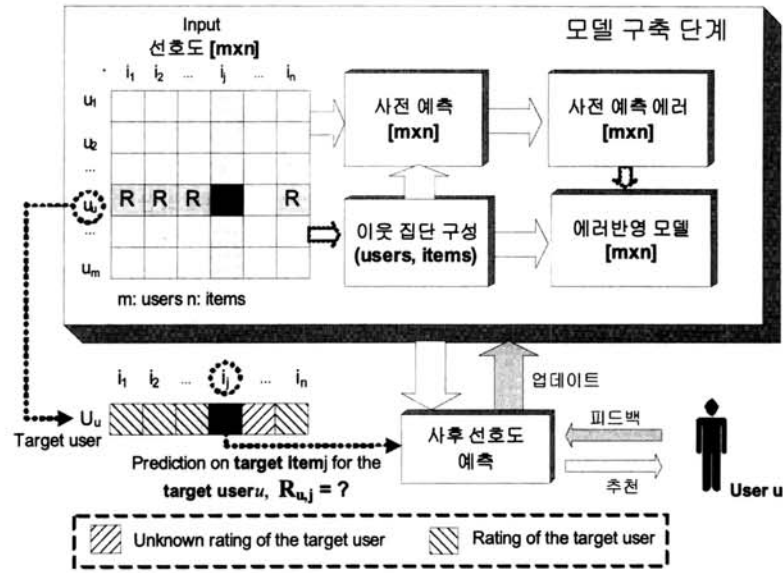
전통적인 협업적 여과의 문제점을 해결하기 위해 여러 모델 기반의 접근 방법이 제안되었다. 데이터의 희박성 문제를 해결하기 위한 접근 방법으로 SVD, LSI 등의 기법을 통하여 전체 사용자-아이템의 행렬의 차원을 줄이는 방법이 제안되었으며[7], 확률적 모델들이 제안되었다[8]. Breese et al.[1]은 예측과 상위 N 개 추천을 계산하기 위한 클러스터 모델과 베이저안 네트워크(Bayesian network)의 두 가지 모델을 제시하였다. 이와 같은 접근 방법은 미리 사용자와 아이템 간의 관계를 나타내는 모델을 구축하여 추천에 사용한다는 공통점을 갖는다. Sawar et al.[13]은 두 아이템 i 와 j 의 유사도를 사용자 전체 집합 U 에 포함된 모든 사용자가 두 아이템 i 와 j 에 매긴 선호도 점수를 이용하여 코사인 기반, 상관 계수 기반, 조정된 코사인 기반의 유사도 측정 방법을 제안했다. 즉, 사용자-아이템 행렬을 기반으로 아이템 간의 유사도를 얻으면 아이템-아이템 간의 유사도를 나타내는 행렬 형태의 유사도 모델을 구축할 수 있다. 아이템-아이템 행렬의 각 값은 해당되는 두 아이템 간의 유사도로 채워지며, 두 개 이상의 아이템에 대해 한 명의 사용자가 동시에 점수를 매긴 경우에만 이 유사도 값을 계산할 수 있다. 이 아이템-아이템 행렬을 바탕으로 하여, 가중치 합(weighted sum)으로 선호도를 예측할 수 있다[13]. 아이템 기반의 협업적 여과의 주요 동기는 사용자가 과거에 이미 선호한다고 표현한 아이템 집합과 유사한 아이템을 선호할 가능성이 높다는 사실에 있다. 사용자 간의 유사도가 아닌 아이템 간의 유사도를 계산하여 얻어진 유사 이웃 아이템 집합을 바탕으로 미리 특정 아이템에 대한 유사도 모델을 구축한다는 점에서 전통적인 협업적 여과와 구별된다. 미리 유사도 모델을 구축하여 사용함으로써 전통적인 방법에 비해 매우 빠른 추천이 가능하다. 또한 아이템 집합의 변화는 사용자 집합의 변화에 비해 매우 적으므로, 이미 구축되어 있는 아이템 유사도 모델을 재사용하더라도 초기의 추천 성능에 비해 정확도가 떨어지지 않는다는 장점이 있다[3].

3. 사전 선호도 예측 에러를 반영한 협업적 추천 시스템

본 논문에서 제안된 협업적 여과 방법은 2단계로 나뉘어질 수 있다. 첫 번째 단계는 오프라인에서 협업적 모델을 구축하는 과정이고 두 번째 단계는 온라인에서 사용자에게 새로운 아이템 추천 및 선호도 예측하는 과정이다. (그림 1)은 사전 선호도 예측 에러가 반영된 모델을 적용한 협업적 여과 방법의 전체 흐름을 보여주고 있다.

3.1 사전 선호도 예측

본 논문에서는 사용자들이 아직 선호도를 평가하지 않은



(그림 1) 사전 선호도 예측 에러를 반영한 협업적 추천 시스템

아이템들을 예측하기 앞서 사용자들이 이미 평가한 아이템에 대한 사전 선호도를 예측한다. 실제로 사용자들이 평가한 선호도 점수에 대하여 제안된 알고리즘에 얼마나 정확한 예측을 했는가에 대한 평가를 통해 새로운 아이템에 대한 예측에 활용한다. 따라서 본 논문은 사용자에 대한 아이템의 선호도 예측을 정의 2와 정의 3과 같이 두 개로 정의할 수 있다.

[정의 2] (사전 선호도 예측, A Priori Prediction). 목적사용자 u 의 $R_{u,j} \neq \perp$ 인 아이템 j 에 대한 선호도 예측을 말하며, $P_{u,j}$ 로 표기한다. 즉, 사용자 u 가 이전에 선호도를 이미 평가한 아이템에 대한 예측을 일컫는다.

[정의 3] (사후 선호도 예측, A Posteriori Prediction). 목적사용자 u 의 $R_{u,j} = \perp$ 인 아이템 j 에 대한 선호도 예측을 말하며, $\hat{R}_{u,j}$ 로 표기한다. 즉, 사용자 u 가 아직 선호도를 평가하지 않은 아이템에 대한 예측을 일컫는다.

사용자들이 이미 선호 평가한 아이템들에 대한 사전 선호도 예측은 "All but 1" 프로토콜을 통하여 수행한다. "All but 1"은 목적사용자가 이미 선호 평가한 아이템 중 임의로 하나의 아이템을 선택하여 테스트로 사용하고, 그것을 제외한 나머지 데이터를 이용하여 테스트 아이템에 대한 예측을 수행하는 방법이다[1]. 사전 선호도는 특정 아이템에 대해 나와 비슷한 선호를 가진 사용자들의 선호 경향과 그 아이템과 유사한 아이템들에 대한 나의 이전 선호 경향을 기반으로 예측하고자 하는 아이템의 예측 선호도 값을 측정한다. 이를 수식으로 정의하면 식 (1)과 같이 표현할 수 있다.

$$P_{u,j} = R_{knn(u)}^j + \frac{\sum_{i \in MSI_u(j)} (R_{u,i} - R_{knn(u)}^i) \times \sigma(i,j)}{\sum_{i \in MSI_u(j)} \sigma(i,j)} \quad (1)$$

$P_{u,j}$ 는 사용자 u 의 아이템 j 에 대한 사전 선호도 예측 값이고, $MSI_u(j)$ 는 아이템 j 의 유사 아이템들 중에 사용자 u 가

선호 평가한 아이템 집합을 의미한다. $R_{knn(u)}^i$ 와 $R_{knn(u)}^j$ 는 각각 사용자 u 와 유사한 사용자들의 아이템 i 와 아이템 j 에 대한 평균 선호도 점수를 의미한다. 여기서 유사한 사용자들은 역 사용자 빈도수를 고려한 코사인 기반의 유사도를 이용하여 구성한다[1]. $\alpha(i, j)$ 는 역 아이템 빈도수를 고려한 두 아이템 간의 코사인 기반의 유사도 값으로 식 (2)를 이용하여 계산된다.

$$\sigma(i,j) = \frac{\sum_{u \in (U_i \cap U_j)} (R_{u,i} \cdot iif_u)(R_{u,j} \cdot iif_u)}{\sqrt{\sum_{u \in U_i} (R_{u,i} \cdot iif_u)^2} \sqrt{\sum_{u \in U_j} (R_{u,j} \cdot iif_u)^2}} \quad (2)$$

U_i 는 아이템 i 를 선호 평가한 사용자 집합을 의미하며 U_j 는 아이템 j 를 선호 평가한 사용자 집합을 의미한다. 전체 n 개의 아이템에 대해서 사용자 u 가 과거에 선호도를 평가한 아이템 수가 f_u 개라면 사용자 u 에 대한 역 아이템 빈도수 iif_u 는 $\log(n/f_u)$ 로 계산한다.

[정의 4] (사용자-아이템 사전 예측 행렬, P). m 명의 사용자 집합 $U = \{u_1, u_2, \dots, u_m\}$ 의 각 사용자의 n 개의 아이템 집합 $I = \{i_1, i_2, \dots, i_n\}$ 의 각 아이템에 대한 사전 선호도 예측 값은 $m \times n$ 사용자-아이템 사전 예측 행렬(user-item a priori prediction matrix)로 표현할 수 있다. 여기서 행은 사용자를, 열은 아이템을 의미하며, $P_{u,j}$ 는 사용자 u 의 아이템 j 에 대한 사전 예측한 선호도 값을 나타낸다.

정의 4에서 행렬의 요소 $P_{u,j}$ 는 R_{min} 에서 R_{max} 사이의 실수 값 또는 아직 평가하지 않은 경우 중 하나에 속한다.

$$P_{u,j} \in \{ R_{min}, \dots, R_{max}, \perp \}$$

사용자 u 의 아이템 j 에 대한 사전 예측한 값이 R_{min} 일 경우 그 아이템은 사용자 u 의 취향에 어울리지 않음을 예측한 경우이며, R_{max} 는 그 반대의 경우라 말할 수 있다. 경우에

따라서, 사용자 u 의 아이템 j 에 대한 사전 예측이 불가능 할 경우가 발생할 수 있다. 예측 불가능한 경우가 발생했을 경우, 본 논문에는 그 사용자의 평균 선호도 값을 $P_{u,j}$ 로 이용한다.

3.2 사전 선호도 예측 에러

사용자들에 대한 사전 선호도 예측이 완료되면 사전 선호도 예측 값이 실제 사용자의 선호도와 얼마나 유사하게 예측되었는가를 실제 선호도 값과 사전 예측된 값의 오차로 계산할 수 있다. 선호도 행렬 R 의 실제 선호도 값에 대응하는 사전 예측 행렬 P 의 사전 예측 선호도 값의 쌍 $\langle R_{u,j}, P_{u,j} \rangle$ 에 대하여 각각의 예측 에러는 (그림 2)과 같이 실제 선호도 값에서 예측된 선호도의 차로 계산한다. 즉, 이를 수식화 하면 식 (3)과 같다.

$$E_{u,j} = R_{u,j} - P_{u,j} \quad (3)$$

$R_{u,j}$ 는 사용자 u 의 아이템 j 에 대한 실제 선호도 값을 의미하며, $P_{u,j}$ 는 아이템 j 에 대한 사용자 u 의 사전 선호도 예측 값을 의미한다.

형식적으로, 사용자-아이템 선호도 행렬 R 과 사용자-아이템 사전 예측 행렬 P 로부터 사용자들에 대한 아이템의 예측 에러는 정의 5의 사용자-아이템 에러 행렬 E 로 표현될 수 있다.

[정의 5] (사용자-아이템 에러 행렬, E). 선호도 행렬 R 의 실제 선호도 값에 대응하는 사전 예측 행렬 P 의 사전 예측 선호도 값의 쌍 $\langle R_{u,j}, P_{u,j} \rangle$ 에 대하여 $m \times n$ 사용자-아이템 에러 행렬(user-item error matrix)로 표현할 수 있다. 여기서 행은 사용자를, 열은 아이템을 의미하며, $E_{u,j}$ 는 사용자

u 의 아이템 j 에 대한 사전 선호도 예측 에러 값을 나타낸다.

정의 5에서 행렬의 요소 $E_{u,j}$ 가 가질 수 있는 값은 $(R_{\min} - R_{\max})$ 에서 $(R_{\max} - R_{\min})$ 사이의 실수 값 또는 아직 평가하지 않은 경우 중에 하나에 속한다.

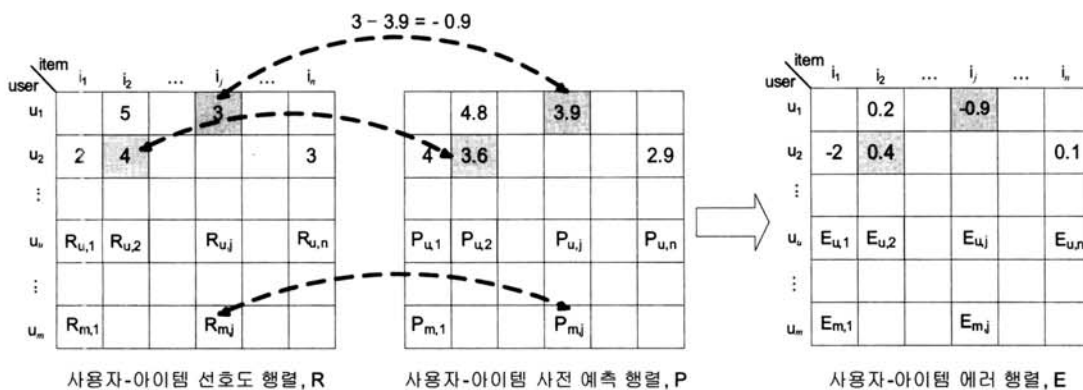
$$E_{u,j} \in \{ (R_{\min} - R_{\max}), \dots, 0, \dots, (R_{\max} - R_{\min}), \perp \}$$

사전 예측 값이 과대평가(overestimation) 되었다면, 예측 에러 값 $E_{u,j}$ 는 음의 값을 가지며, 과소평가(underestimation) 되었다면 $E_{u,j}$ 는 양의 값을 가지게 된다. $E_{u,j} = 0$ 일 경우는 시스템이 실제 선호도 값을 정확하게 예측했음을 의미하며, 0에 가까울수록 사전 선호도 예측의 정확도가 높다고 말할 수 있다.


3.3 사전 예측 에러반영 모델 구축

협업적 여과 기반의 추천 시스템의 쟁점 중의 하나로 시스템의 확장성 및 실시간 추천 성능이라 할 수 있다. 전통적인 근접한 이웃을 기반으로 하는 협업적 알고리즘(메모리 기반의 협업적 여과)은 사용자와 아이템의 수가 증가할수록 이웃 집단을 찾기 위한 유사도 계산의 복잡도는 크게 증가한다. 사용자의 수가 매우 많은 일반적인 상업적 웹 사이트의 경우, 추천을 위해 각 사용자에 대한 이웃 집단을 구성하는 것은 엄청난 계산을 요구하고, 그 결과 온라인 추천 속도의 성능이 저하된다. 이러한 문제를 보완하기 위해, 본 절에서는 추후 온라인 추천 및 예측에 활용하기 위해 사전에 미리 사용자와 아이템 간의 예측 에러반영 모델(error-reflected model)을 구축하는 방법을 기술한다.

사전 선호도 예측 에러는 이미 나와 유사한 사용자들의 의견과 나의 과거 선호도 성향을 반영하여 나온 결과이다. 따라서, 예측된 에러 정보는 실제로 사용자에게 추천 대상



(그림 2) 선호도 예측 에러 행렬 구축 과정



(그림 3) 사전 예측 값의 과대 평가와 과소 평가

이 되는 아이템들의 선호도 예측에 유용하게 이용될 수 있다. 앞 절에서 설명한 $m \times n$ 사용자-아이템 에러 행렬 E 자체를 사후 예측에 이용할 수 있으나, 이것은 계산 복잡도 증가를 초래한다. 또한, 불필요한 정보로 인하여 오히려 예측 정확도가 떨어질 수 있다. 따라서 효율적인 사후 예측을 위해 적절한 모델 크기를 결정해야 한다.

본 논문에서는 사후 예측의 정확성과 효율성을 높이기 위해 에러 임계값(error threshold)을 이용하여 임계값 이하의 데이터로 모델을 구축한다. 즉, 에러 행렬 E의 각 행에서 다음과 같은 조건을 만족하는 열을 선택한다.

$$|E_{uj}| < \theta, \text{ where } E_{uj} \neq \perp \quad (4)$$

여기서 θ 는 에러 임계값으로 0보다 큰 실수이다. 사전 예측 에러 값에 절대값을 고려하는 이유는 앞에서 언급했듯이 예측 에러는 과대 평가시 음의 값을 가지며, 과소 평가시 양의 값을 가지기 때문이다. 따라서 어느 정도의 에러 임계값을 설정해야 하는 것이 무엇보다 중요한 문제이다.

3.3.1 사용자 기반의 에러반영 모델

사용자 기반의 에러반영 모델(user-based error-reflected model)은 목적사용자 u 와 유사한 사용자 이웃들의 특정 아이템에 대한 사전 예측 에러를 이용하여 모델을 구축한다. 구축된 모델은 $m \times n$ 행렬 $\hat{E}^{(\theta)}$ 로 표현될 수 있다. $\hat{E}^{(\theta)}$ 에서 행은 사용자, 열은 아이템을 의미하며, u 번째 행의 j 열은 사용자 u 의 유사 사용자 이웃들에 대한 아이템 j 의 사전 예측 평균 에러의 값이다. 이를 수식화하면 식 (5)와 같다.

$$E_{u,j}^{\hat{(\theta)}} = \frac{\sum_{v \in KNN_j^{\theta}(u)} E_{v,j}}{|KNN_j^{\theta}(u)|} \quad (5)$$

$KNN_j^{\theta}(u)$ 는 사용자 u 의 유사 이웃들 중에서 아이템 j 의 사전 예측 에러의 절대값이 θ 보다 작은 사용자들의 집합을 말한다.

3.3.2 아이템 기반의 에러반영 모델

아이템 기반의 에러반영 모델(item-based error-reflected model)은 특정 아이템과 유사한 아이템들에 대하여 목적사용자 u 의 사전 예측 에러를 이용하여 모델을 구축한다. 이는 앞 절에서 설명한 사용자 기반의 에러반영 모델을 구축 방법과 유사하다. 단지 유사 사용자 이웃 집단 대신 유사 아이템 이웃 집단을 이용한다.

구축된 에러반영 모델은 $m \times n$ 행렬 $\check{E}^{(\theta)}$ 로 표현될 수 있다. $\check{E}^{(\theta)}$ 에서 행은 사용자, 열은 아이템을 의미하며, u 번째 행의 j 열은 아이템 j 와 유사 아이템들에 대한 사용자 u 의 사전 예측 평균 에러 값이다. 이를 수식화하면 식 (6)과 같다.

$$E_{u,j}^{\check{(\theta)}} = \frac{\sum_{i \in MSI_u^{\theta}(j)} E_{u,i}}{|MSI_u^{\theta}(j)|} \quad (6)$$

$MSI_u^{\theta}(j)$ 는 아이템 j 와 유사한 아이템들 중에서 사용자 u 의 사전 예측 에러의 절대값이 θ 보다 작은 아이템들의 집합을 말한다.

3.3.3 초기 진입 문제를 위한 에러가 반영된 모델

추천 시스템의 문제점 중에 하나인 초기 진입 사용자(cold start users) 및 아이템(cold start items)은 풍부한 선호도 정보를 가지고 있는 일반 사용자 및 아이템들에 비해 예측 및 추천의 어려움이 많다[15]. 초기 진입 사용자들은 아직 충분한 선호도 정보가 쌓이지 않았기에 일반적으로 정확한 예측 성능의 기대가 어렵기에 이들이 지속적으로 시스템을 활용하여 선호 평가를 유도하기 위한 동기가 필요하다. 하지만 불충분한 정보로 예측된 정확하지 않은 성능은 초기 사용자들로 하여금 시스템의 신뢰가 떨어지고, 그 결과 사용자들의 시스템 이탈 및 활발한 활동 동기를 저해 시키는 요인이 된다. 따라서 초기 진입 사용자들의 정확한 선호도 예측을 위한 차별화된 전략이 필요하다. 초기 진입 아이템들은 역시 아직 사용자들로부터 충분한 선호도 정보가 쌓이지 않았기에 지속적으로 선호도가 축적된 아이템들에 비하여 정확한 예측이 어렵고, 상대적으로 사용자들에게 추천되기가 어렵다. 본 논문에서는 초기 진입 사용자 및 아이템을 위한 예측 에러반영 모델들은 식 (5)과 식 (6)을 약간 수정하여 구축한다. 즉, 초기 진입 문제에 대한 사용자 기반의 모델과 아이템 기반의 모델은 각각 식 (7)과 식 (8)을 이용하여 계산한다.

$$E_{u,j}^{\hat{(\theta)}} = \frac{\sum_{v \in U_j} E_{v,j}}{|U_j|} \quad \text{if } j \in CSI \quad (7)$$

$$E_{u,j}^{\check{(\theta)}} = \frac{\sum_{i \in I_u} E_{u,i}}{|I_u|} \quad \text{if } u \in CSU \quad (8)$$

CSU와 CSI는 각각 초기 진입 사용자들과 초기 진입 아이템들의 집합을 나타내며, U_j 는 아이템 j 를 선호 평가한 사용자 집합, I_u 는 사용자 u 가 선호 평가한 아이템 집합을 의미한다.

3.4 에러반영 모델을 이용한 사후 선호도 예측

협업적 여과에서 마지막 단계는 사용자의 아이템 선호도를 예측하는 과정이다. 예측 대상이 되는 아이템은 특정 사용자가 아직 선호 평가 하지 않은 아이템을 말한다. 시스템에 있는 사용자들의 과거 정보를 바탕으로 특정 사용자가 특정 아이템을 얼마나 선호하는지를 정확하게 예측하는 것은 협업적 여과에서 무엇보다 중요한 문제이다. 이는 사용자들이 아이템을 구매, 선택, 또는 관람하는 의사 결정(decision making)에 직접적으로 영향을 주기 때문이다. 정확한 아이템 선호도 예측과 더불어 실시간으로 빠른 예측도 중요한 이슈이다. 에러반영 모델들은 온라인에서 사후 예측에 앞서 많은 작업

들이 오프라인에서 수행되기 때문에 빠른 온라인 성능을 제공할 수 있다[3]. 구축한 모델들을 이용한 사후 아이템 선호도는 다음과 같이 두 가지 접근 방법으로 예측할 수 있다.

첫 번째는 사용자 기반의 에러반영 모델을 활용한 접근 방법이다. 이 예측 방법의 기본 개념은 나와 유사한 사용자들이 예측하고자 하는 아이템에 대한 과거 선호도 점수에 그 아이템에 대한 유사 이웃들의 사전 예측이 과대평가되었는지 또는 과소평가되었는지를 반영한다. 공식적으로, 목적사용자 u 에 대한 특정 아이템 j 의 사후 아이템 선호도는 식 (9)를 이용하여 예측한다.

$$\check{R}_{u,j} = R_{km(u)}^j + \hat{E}_{u,j} \quad (9)$$

$\check{R}_{u,j}$ 는 목적사용자 u 에 대한 이전에 선호 평가하지 않은 아이템 j 의 예측된 선호도 값이다. $R_{km(u)}^j$ 는 사용자 u 와 유사한 사용자들의 아이템 j 에 대한 평균 선호도 점수를 의미하며, $\hat{E}_{u,j}$ 는 사용자 기반의 에러반영 모델 \hat{E} 에서 u 번째 행의 j 번째 열의 값을 의미한다.

두 번째 예측 방법은 아이템 기반의 에러반영 모델을 활용한 것이다. 이 접근 방법은 나와 유사한 사용자들의 예측하고자 하는 아이템에 대한 과거 선호도 점수에 그 아이템과 유사한 아이템들에 대하여 나의 사전 예측이 과대평가되었는지 또는 과소평가되었는지를 반영한다. 따라서, $\check{R}_{u,j}$ 는 식 (10)를 이용하여 예측될 수 있다.

$$\check{R}_{u,j} = R_{km(u)}^j + \check{E}_{u,j} \quad (10)$$

$\check{E}_{u,j}$ 는 아이템 기반 에러반영 모델 \check{E} 에서 u 번째 행의 j 번째 열의 값을 의미한다.

모델 기반의 협업 여과는 사전에 미리 구축된 모델을 사용한다는 면에서 일반적으로 메모리 기반의 접근 방법에 비하여 추천 시간이 더 빠르다. 그러나 이 접근 방법은 모델을 구축하는데 상당한 학습 시간을 필요로 하며 일단 모델이 구축되면 새로운 사용자의 피드백(feedback)을 즉각적으로 반영하기 어려운 단점이 있다[2]. 다시 말해, 사용자들의 아이템에 대한 새로운 선호도 정보는 모델이 재구축할 때까지 반영되기 힘들다. 모델 구축은 일반적으로 상당한 시간을 소요하기 작업이기에 갱신 및 재구축 작업은 빈번히 행해지지 않는다. 따라서, 새로운 정보를 빠르게 반영할 수 있는 효율적인 모델 갱신 방법은 모델 기반의 협업 여과 접근 방법에 또 다른 이슈라 할 수 있다. 이러한 모델 기반의 단점을 보완하기 위해, 선호도 예측 에러반영 모델은 점진적인 갱신(incremental update) 및 사용자들의 새로운 선호도 정보를 계속 반영할 수 있게 제안되었다. 예를 들어, 시스템에서 목적사용자 u 에 대한 아이템 j 의 선호도를 4.3으로 예측하고 사용자 u 에게 추천했다고 생각해 보자. 추천 받은 아이템 j 에 대하여 사용자 u 가 구매 또는 선택한 후 다시

자신의 실제 선호도를 4.0으로 시스템에 피드백을 주었다면, 실제 선호도 $R_{u,j} = 4.0$ 과 사후 예측 선호도 값 $\check{R}_{u,j} = 4.3$ 으로부터 다음과 같은 예측 에러 값을 계산할 수 있다.

$$R_{u,j} - \check{R}_{u,j} = 4.0 - 4.3 = -0.3$$

이는 실제 선호도와 사전 선호도 예측 값과의 사전 선호도 예측 에러를 측정할 때와 순서가 조금 바뀌었지만 기본적인 개념은 같다고 할 수 있다. 즉, 사후 선호도 예측 값에 대하여 실질적인 사용자의 선호도 정보가 추후 발생하면 예측 에러를 측정하여 모델을 동시에 갱신할 수 있다. 이로써 시스템은 다음 새로운 아이템에 대하여 보다 풍부한 사용자들의 정보가 반영된 에러반영 모델을 적용하여 예측할 수 있고, 그 결과 향상된 예측 성능을 제공할 수 있다. 이러한 점진적인 모델 갱신 및 새로운 사용자들의 선호도 정보를 추후 아이템 선호도 예측에 즉시 반영하는 것은 초기 사용자들에게 특히 효과적이라 기대된다.

3.5 계산 복잡도 분석

협업적 여과 추천 시스템에서 예측 및 추천의 정확성을 향상시키기 위해서는 종종 높은 계산 복잡도(computational complexity)의 비용이 요구될 수가 있다. 사용자의 수와 아이템의 수가 매우 많은 일반적인 상업적 추천 시스템에서는 성공적인 시스템 개발을 위해 확장성(scalability)이 중요한 이슈이다[7]. 모델 기반의 추천 시스템의 계산 복잡도는 미리 모델을 구축하는 오프라인(offline)과 특정 사용자에게 실시간 예측 또는 추천을 제공하는 온라인(online)으로 구분된다. 따라서 본 절에서는 제안된 모델들을 적용한 방법들의 사용자의 수 m , 아이템의 수 n , 사용자들의 아이템들에 대한 선호도(rating) 수 v , 모델 크기 k 에 따른 오프라인, 온라인 계산 복잡도를 각각 분석한다.

3.5.1 오프라인 계산 복잡도

에러반영 모델을 적용한 협업적 여과 방법의 계산 복잡도는 각 사용자의 사전 예측 에러를 계산하는데 소요되는 시간에 좌우된다. 사전 선호도 예측을 계산하기 위해서는 사용자들의 사용자 이웃 집단과 아이템들의 아이템 이웃 집단을 구성해야 하기에 최악의 경우 각각 $O(m^2n)$ 연산과 $O(mn^2)$ 연산이 필요하다. 그리고 에러반영 모델을 구축하기 위해 추가적으로 $O(kmn)$ 의 시간이 소요되기에 에러반영 모델 기반의 협업적 여과의 오프라인 총 계산 복잡도는 대략 $O(m^2n + mn^2 + kmn)$ 이 필요하다. 그러나 실제로는 사용자-아이템 선호도 행렬의 희박성 수준이 매우 높기에 사용자의 사전 선호도 예측 에러를 계산하는 실제 계산 복잡도는 대략 $O(mv+nv)$ 로 크게 감소될 수 있다.

3.5.2 온라인 계산 복잡도

대부분의 추천 시스템에서는 오프라인 계산 복잡도 보다 는 사용자들이 아직 선호 평가하지 않은 아이템에 대한 사

후 선호도를 예측하는 온라인 계산 복잡도가 중요하다. 제안된 에러반영 모델들을 이용한 경우 목적사용자 u 의 특정 아이템 j 에 대한 $\hat{R}_{u,j}$ 을 예측하기 위해서는 k 명의 유사한 사용자들에 대한 $O(k)$ 의 연산이 필요하다. 따라서 목적사용자 u 가 아직 선호 평가하지 않은 모든 아이템의 예측에 대한 계산 복잡도는 최악의 경우 $O(kn)$ 이 된다. 본 논문의 실험에서는 모델 크기 k 가 50~70 사이 일 때 비교적 안정적인 예측 정확성을 제공하였다.

4. 실험 분석 및 결과

본 장에서는 제안된 사전 선호도 예측 에러반영 모델을 적용한 추천 시스템의 성능에 대한 실험을 하고 그 결과에 대한 분석을 기술한다.

4.1 실험 평가 방법

제안된 모델들의 성능 평가 실험은 *MovieLens* 데이터 집합(dataset)을 사용하였다. *MovieLens*는 *GroupLens*[12]에서 연구를 목적으로 운영하는 웹 기반의 추천 시스템으로, 사용자들이 자신이 본 영화에 대하여 1(R_{\min})부터 5(R_{\max})사이의 선호도를 평가할 수 있다. 데이터는 각 사용자마다 최소 20개 이상의 아이템에 대한 선호도 정보를 가지고 있으며, 많은 협업적 여과 관련 연구에서 실험 데이터로 활용되고 있다. 데이터에는 943명의 사용자가 1,682개의 아이템에 대한 100,000개의 선호도 점수를 포함하고 있다. 실험은 각 데이터 집합을 학습 데이터 집합(training set)과 테스트 데이터 집합(test set)으로 나누어, 학습 데이터만을 이용하여 테스트 집합에 있는 아이템에 대한 사용자의 선호도를 예측하였다.

본 논문에서는 제안된 모델을 적용한 추천 시스템의 성능을 평가하기 위해 협업적 여과 추천 시스템에서 가장 보편화된 예측의 정확성 평가 방법인 MAE(Mean Absolute Error)[1, 5, 13]의 측정식을 이용하였다. MAE는 테스트 집합에 있는 실제 선호도와 시스템에 의해 예측된 선호도의 평균 절대 편차를 평가하는 통계적인 측정 방법으로써 식 (11)에 의해 정의된다.

$$MAE(u) = \frac{\sum_{j \in IT_u} |R_{u,j} - \hat{R}_{u,j}|}{|IT_u|} \quad MAE = \frac{\sum_{u \in UT} MAE(u)}{|UT|} \quad (11)$$

$MAE(u)$ 는 테스트 집합에 있는 사용자 u 에 대한 평균 절대 사용자 오차(Mean Absolute User Error)이다. IT_u 는 테스트 데이터에서 사용자 u 가 선호 평가한 아이템 집합이며, UT 는 테스트 데이터에 있는 사용자 집합을 의미한다. $\langle R_{u,j}, \hat{R}_{u,j} \rangle$ 는 사용자 u 의 아이템 j 에 대한 실제 선호도 값과 예측된 선호도 값의 쌍이며 MAE가 최소화될수록 시스템의 예측 정확도가 높다고 말할 수 있다.

제안된 모델들의 예측 정확성을 평가하기 위해, 협업적

여과 추천 시스템에서 가장 널리 알려진 두 가지 방법, 피어슨 상관 계수 유사도를 이용한 사용자 기반의 협업적 여과 기법[1, 9]과 코사인 유사도를 이용한 아이템 기반의 협업적 여과 기법[3, 13]의 성능과 비교하였다. 실험에서 사용자 기반의 협업적 여과는 *UserCF*, 아이템 기반의 협업적 여과는 *ItemCF*로 각각 표기하였다. 그리고 제안된 에러반영 협업적 여과에서 식 (9)의 사용자 기반의 에러반영 모델을 이용한 경우 *UErrorCF*, 식 (10)의 아이템 기반의 에러반영 모델을 이용한 경우 *IErrorCF*로 표기하였다.

4.2 예측 정확성의 성능 평가

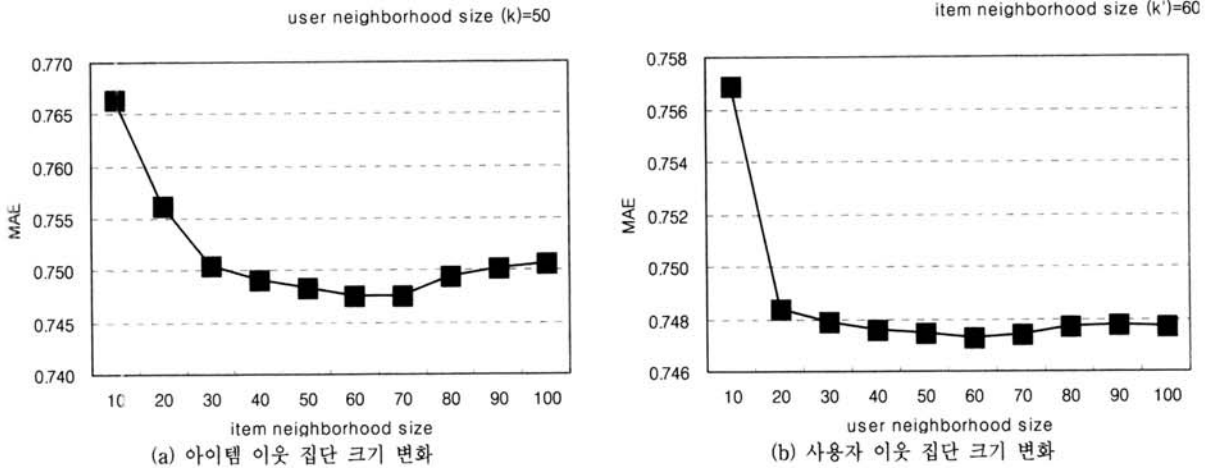
예측 정확성을 평가하기 위한 실험은 *MovieLens* 데이터의 전체 100,000개의 선호도를 임의로 80%의 학습 데이터 집합(80,000개 선호도)과 20%의 테스트 집합(20,000개 선호도)으로 분리하여 진행하였다.

4.2.1 이웃 크기에 따른 사전 예측 정확성

제안된 사전 선호도 예측 결과는 예측에 사용될 유사 사용자 이웃 집단의 크기 *KNN*과 유사 아이템 이웃 집단 *MSI*에 영향을 받는다. 따라서, 정확한 사전 예측 에러반영 모델을 구축하기 위해서는 적절한 사용자 및 아이템 이웃의 크기를 선택해야 한다. 이를 위해, 이웃의 크기를 변경함에 따라 사전 선호도 예측 정확도를 비교 평가하였다.

우선 아이템 이웃 집단의 크기 k 를 변경하면서 사전 선호도 예측의 정확성을 측정하였다. 사용자 이웃 집단의 크기 k 는 많은 선행 연구들의 실험을 바탕으로 50 ($k=50$)으로 설정하였다. (그림 4)의 (a)는 식 (1)에서 아이템 이웃 집단의 크기의 변화에 따른 사전 선호도 예측의 MAE를 나타낸다. 실험 그래프 결과에서 볼 수 있듯이 사전 선호도 예측에 사용된 유사 아이템의 수는 예측 정확도에 영향을 미쳤다. 아이템 이웃 크기가 10에서 60까지 점점 증가할수록 예측 성능이 향상되다가, 이웃 크기가 60일 때를 전후해서 그 감소의 정도가 완만해지는 것을 확인할 수 있다. 그리고 이웃 크기가 80일 때 이후로 MAE 값이 증가하였다. 즉, 이웃의 크기가 너무 작은 경우 사전 선호도 예측의 성능이 현저하게 떨어졌으며, 이웃의 크기가 너무 크면 사전 선호도 예측에 좋지 않은 영향을 미쳐 예측의 성능이 오히려 낮아졌다.

다음 실험에는 유사 사용자 집단의 크기에 따른 사전 선호도 예측 성능을 살펴보았다. 선행 실험 그래프의 곡선이 완만해지는 지점인 유사 아이템 집단의 크기 k 를 60으로 설정하고 유사 사용자 집단의 크기를 변경하면서 사전 선호도 예측의 정확성을 측정하였다. 실험 결과 사용자 이웃 집단 크기 역시 사전 선호도 예측 결과에 영향을 미쳤다. 그러나 아이템 이웃 집단 크기 실험 결과와 다르게 상대적으로 작은 크기에서부터 그래프의 곡선이 완만해졌다. (그림 4)의 (b)의 그래프 곡선을 분석해 보면, 사용자 이웃 수가 20명 이후로 매우 미세한 MAE 값의 변동이 있었으나 대체적으로 만족할 만한 예측 성능을 보임을 알 수 있다. 사용자 이웃 크기가 10인 경우에는 특정 아이템에 대한 사전 선



(그림 4) 이웃 집단 크기 변화에 따른 사전 예측 선호도의 MAE

호도 예측시 유사 사용자들이 그 아이템에 대해 전혀 선호 평가하지 않은 경우가 다수 존재하였다.

4.2.2 에러 임계값 θ 변화에 따른 성능 평가

예측 에러반영 모델을 적용한 사후 예측은 어떠한 모델을 이용하느냐에 따라 예측 결과가 달라진다. 본 절에서는 3.3 절에 기술된 두 개의 에러반영 모델 $\hat{E}^{(6)}$ 와 $\check{E}^{(6)}$ 의 에러 임계값 θ 값 변화에 따른 사후 예측 성능에 대한 결과를 분석한다. 선행 실험 결과를 바탕으로 각 모델을 구축하는데 사용된 사용자 이웃 집단 크기와 아이템 이웃 집단 크기는 각각 50과 60으로 설정하였다 ($k=50, k'=60$).

(그림 5)는 θ 값을 0.2에서 2.0으로 변화시키에 따른 MAE의 성능 변화를 나타낸다. 그래프 곡선의 변화에서 유추되듯이, $UErrorCF$, $IErrorCF$ 의 사후 예측 성능은 에러 임계값 θ 값에 유사한 영향을 받았다. $UErrorCF$ 경우에는 θ 값이 1.2까지, $IErrorCF$ 는 1.6까지 각각 하향 곡선을 보였고, 그 이후 서서히 상향 곡선을 보였다. 두 방법에서 가장 높은 예측 성능을 비교해보면, $UErrorCF$ 의 MAE는 0.7584($\theta=1.2$), $IErrorCF$ 의 MAE는 0.7556($\theta=1.6$)였다. 실험 결과를 바탕으로 본 논문에서는 각 방법의 예측 성능이 가장 우수한 에러 임계 값을 선택한다. 즉, $UErrorCF$ 는 모델 $\hat{E}^{(1,2)}$,


$IErrorCF$ 는 모델 $\check{E}^{(1,6)}$ 를 각각 이용한다.

4.2.3 예측 성능 비교 평가

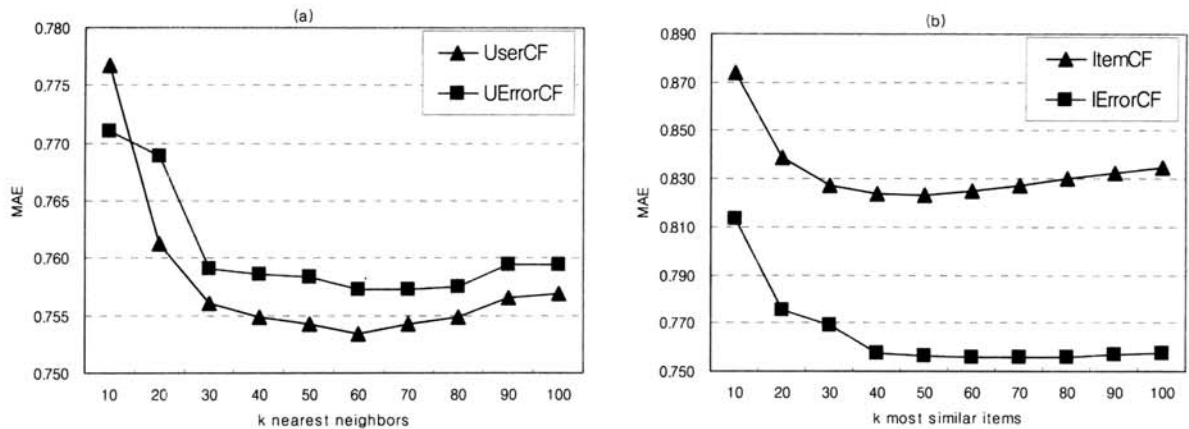
제안된 사전 예측 에러반영 모델들을 적용한 협업적 여과 방법의 성능을 평가하기 위해 피어슨 상관 계수를 이용한 사용자 기반 협업적 여과 방법 $UserCF$ 및 코사인 아이템 유사도를 이용한 아이템 기반의 협업적 여과 방법 $ItemCF$ 와 예측 성능을 비교하였다. 제안된 방법과 유사하게 기존의 $UserCF$ 와 $ItemCF$ 역시 각각 형성된 사용자 이웃 집단과 아이템 이웃 집단에 예측 성능이 영향을 받는다[14]. 따라서 $UserCF$ 의 사용자 이웃 집단의 크기 k 를 변화시키면서 $UErrorCF$ 와 성능 비교하였고, $ItemCF$ 의 아이템 이웃 집단의 크기 k' 를 변화시키면서 $IErrorCF$ 와 성능 비교하였다.

(그림 6)의 (a)는 $UserCF$ 와 $UErrorCF$ 의 사용자 이웃 집단의 크기 변화에 따른 MAE를 나타낸다. $UErrorCF$ 에서 사용자 이웃 집단 크기의 변화란 식 (5)에서 $\hat{E}^{(6)}$ 를 구축하는데 사용되는 유사 사용자의 수의 변화를 의미한다. 실험 결과, 대부분의 이웃 집단 크기 변화에서 $UserCF$ 의 예측 성능이 제안된 $UErrorCF$ 의 예측 성능보다 전반적으로 우수하였다. 사용자 이웃의 수가 적은 경우, 즉 k 가 10일 때 $UErrorCF$ 의 MAE가 $UserCF$ 의 MAE보다 낮은 결과를 얻을었다. 이는 협업적 여과에서 희박한 데이터 및 초기 사용자에게 $UErrorCF$ 가 $UserCF$ 보다 높은 예측 성능을 제공할 수 있음을 내포한다.

(그림 6)의 (b)는 $ItemCF$ 와 $IErrorCF$ 의 아이템 이웃 집단의 크기 변화에 따른 MAE를 나타낸다. 마찬가지로, $IErrorCF$ 에서 아이템 이웃 집단 크기의 변화란 식 (6)에서 $\check{E}^{(6)}$ 를 구축하는데 사용되는 유사 아이템의 수의 변화를 의미한다. $IErrorCF$ 에서 사후 예측에 사용된 아이템들에 대한 평균 선호도는 유사 사용자들 50명으로부터 계산되었다. 실험 결과, 제안된 $IErrorCF$ 가 모든 아이템 이웃 집단에 우수한 성능이 보였다. 결과 그래프에서 볼 수 있듯이 아이템 이웃 집단의 크기가 너무 작으면 두 방법 모두 예측 성능이 현저하게 떨어졌다. 이는 예측하고자 하는 아이템과 유사한



(그림 5) 에러 임계값 θ 값 변화에 따른 MAE 성능 평가



(그림 6) (a) 사용자 수 변화에 따른 UserCF와 UErrorCF 성능 비교와 (b) 아이템 수 변화에 따른 ItemCF와 IErrorCF 성능 비교

아이템에 대한 목적사용자의 과거 선호 경향을 기반으로 하는 아이템 기반 접근 방법의 특성 때문이라 분석된다. ItemCF는 아이템 집단의 크기가 커짐에 따라 예측 성능이 높아지다가 적정 수준의 크기($k=50$) 이후에는 다시 낮아졌다. 이에 반하여 IErrorCF는 적정 수준의 크기 이후에 예측 성능의 변화가 거의 일어나지 않았다. 실험 결과를 바탕으로 UserCF, ItemCF, UErrorCF, IErrorCF 각 방법에서 가장 예측 성능이 좋은 결과를 비교하였다. MAE 예측 성능 비교 결과, 제안된 모델들 기반의 방법들이 UserCF보다는 미세하게 좋지 않았으나 실용적으로 큰 차이가 없었으며, ItemCF보다는 약 7%의 향상된 성능 차이를 보였다.

4.3 초기 진입 문제에 대한 예측 성능 평가

본 절에서는 협업적 여과 방법에서의 초기 진입 문제에 대해 제안된 모델 기반의 예측 성능을 평가하고 분석한다. 본 실험에서 초기 진입 사용자는 시스템에서 선호 평가한 아이템의 정보가 최소 한 개 이상에서 최대 다섯 개 이하인 사용자로 정의하였으며, 초기 진입 아이템은 시스템에서 선호 평가한 사용자들의 정보가 최소 한 개 이상에서 최대 다섯 개 이하인 아이템으로 정의하였다.

우선 초기 진입 아이템들에 대한 예측 정확성을 분석하기 위해, 가장 성능이 우수했던 선행 예측 실험 결과들에서 학습 데이터 집합의 각 아이템에 대해 선호 평가한 사용자 수에 따른 MAE를 분석하였다. <표 1>은 그 결과를 보여준다. MAE 결과에서 나타나듯이, 모든 협업적 예측 방법들이 아이템에 대한 사용자의 선호도 정보가 많아질수록 예측 성능이 향상되었다. 학습 데이터 집합에서 368개의 초기 진입

아이템들의 예측 성능을 비교해보면, 에러반영 모델 기반의 협업적 여과 방법들이 대체로 정확한 예측을 제공하였다. 특히, UErrorCF는 IErrorCF보다 1.3%, UserCF보다 2.5%, ItemCF보다는 12.6% 향상된 성능 차이를 보였다.

다음 실험으로, 초기 진입 사용자들에 대한 예측 정확성을 평가하였다. 기존의 학습 데이터 집합에는 대부분의 사용자가 최소 10개 이상의 선호도 정보를 가지고 있어 본 논문에서 정의한 초기 진입 사용자 평가에 적합하지 않았다. 따라서, 실험을 위해 100명의 사용자를 선택하여 각 사용자마다 정확히 3개씩, 5개씩의 선호도만 학습 데이터에 남기고 나머지 선호도 정보는 제거하여 실험을 진행하였다. 그리고 생성된 초기 진입 사용자 100명을 대상으로 MAE를 측정하였다.

<표 2>는 초기 진입 사용자들에 대한 예측 MAE를 나타낸다. 초기 진입 사용자에 대한 예측 성능은 원본 예측 결과에 비하여 상당히 떨어지는 것을 볼 수 있다. 이는 초기 사용자의 선호 정보가 적어 선호 파악이 힘들기 때문이다. 각 여과 방법들의 예측 성능을 비교해 보면, 초기 진입 사용자들의 예측 정확성 측면에서 에러반영 모델 기반의 협업적 여과 방법이 안정적인 예측 성능을 보이는 것을 알 수 있다. 특히, 아이템 기반의 에러반영 모델을 이용한 IErrorCF의 예측 성능이 더 정확함을 보였다. 평균적으로, IErrorCF가 UErrorCF보다 3.5%, UserCF보다 17.5%, ItemCF보다 15% 향상된 예측 정확성을 제공하였다. 결론적으로, 본 논문에서 제안한 에러반영 모델을 활용한 협업적 여과 방법이 초기 진입 아이템뿐만 아니라 초기 진입 사용자들에게도 안정적인 예측 성능을 제공할 수 있음이 증명되었다.

<표 1> 초기 진입 아이템들에 대한 예측 MAE 비교

Test Item:	Cold start items (< 5)	< 10	< 15	< 20
# of items	368	573	690	782
UserCF	0.9661	0.9199	0.8734	0.8412
ItemCF	1.067	1.011	0.9976	0.9912
UErrorCF	0.9405	0.8878	0.87714	0.8632
IErrorCF	0.9542	0.9015	0.8908	0.8870

<표 2> 초기 진입 사용자들에 대한 예측 MAE 비교

Test user:	Cold start users			Original
	# of Ratings for each user:	3	5	
UserCF	1.2360	1.0730	1.1545	0.7942
ItemCF	1.2234	1.0365	1.1299	0.832
UErrorCF	0.9907	1.0374	1.0140	0.7915
IErrorCF	0.9846	0.9726	0.9786	0.8052

5. 결론 및 향후 연구

본 논문에서는 협업적 여과에서 발생할 수 있는 대표적인 문제점인 초기 진입 문제를 보완하기 위해 새로운 모델을 구축하는 방법들을 제시하였으며, 또한 그 모델들을 적용하여 개인화된 아이템을 추천하는 협업적 여과 방법을 제안하였다. 제안된 모델은 사용자들이 선호 평가하지 않은 아이템에 대한 선호도 예측에 앞서 사전에 미리 사용자들이 선호 평가한 아이템에 대한 선호도 예측 수행을 통한 에러 정보를 반영하여 구축하였다. 측정된 에러 정보를 반영하는 방법으로, 목적사용자와 유사한 사용자들의 특정 아이템에 대한 사전 평균 예측 에러를 의미하는 사용자 기반의 에러반영 모델과 특정 아이템과 유사한 아이템들에 대하여 목적 사용자의 사전 평균 예측 에러를 의미하는 아이템 기반의 에러반영 모델을 각각 구축하였다. 그리고 구축된 모델들을 적용한 새로운 협업적 여과 방법들을 제안하였으며, 그 방법들의 성능을 기존의 사용자 기반의 협업적 여과 및 아이템 기반의 협업적 여과와 예측 정확성을 비교하여 검증하였다.

제안된 모델들을 보다 실용적으로 활용하기 위해 개선해야 할 이슈 및 향후 연구 과제는 다음과 같다. 모델 기반의 협업적 여과의 단점 중 하나는 모델을 구축하는데 소요되는 시간과 비용이 상대적으로 크다는 것이다. 제안된 모델 역시 정확한 예측을 제공하는 최적의 모델을 선택하기 위한 파라미터들의 조율로 인하여 모델을 구축하고 선택하는데 있어서 오랜 시간이 소요되었다. 따라서 모델 구축 시간을 단축하면서 최적의 모델을 선택할 수 있는 병렬화된 협업적 여과(parallel collaborative filtering)와 같은 연구가 필요하다. 또한 최근 협업적 여과 추천 시스템에서 이슈가 되고 있는 악의적인 사용자들의 조작된 선호도 삽입에 대한 문제를 개선하기 위한 연구도 필요하다.

참고 문헌

[1] Breese, J. S., Heckerman, D., and Kadie, C., "Empirical Analysis of Predictive Algorithms for Collaborative Filtering," Proceedings of the 14th Annual Conference on Uncertainty in Artificial Intelligence, pp.43-52, 1998.

[2] Das A., Mayur Datar, M., Garg, A., and Rajaram, S., "Google News Personalization: Scalable Online Collaborative Filtering," Proceedings of the 16th International World Wide Web Conference, pp.271-280, 2007.

[3] Deshpande, M. and Karypis, G., "Item-based Top-N Recommendation Algorithms," ACM Transactions on Information Systems, Vol.22, pp.143-177, 2004.

[4] Herlocker, J. L., Konstan, J. A., and Riedl, J., "Explaining Collaborative Filtering Recommendations," Proceedings of the 2000 ACM Conference on Computer Supported Cooperative Work, pp.241-250, 2000.

[5] Herlocker, J. L., Konstan, J. A., Terveen, L. G., and Riedl, J. T., "Evaluating Collaborative Filtering Recommender Systems," ACM Transactions on Information Systems, Vol.22, ACM Press, pp.5-53, 2004.

[6] Herlocker, J.L., Konstan, J.A., Borchers, A., and Riedl, J., "An Algorithmic Framework for Performing Collaborative Filtering," Proceedings of the 22nd ACM SIGIR Conference on Research and Development in Information Retrieval, pp.230-237, 1999.

[7] Hofmann, T., "Latent Semantic Models for Collaborative Filtering," ACM Transactions on Information Systems, Vol.22, pp. 89-115, 2004.

[8] Jin, R. Si, L. and Zhai, C., "A Study of Mixture Models for Collaborative Filtering," Journal of Information Retrieval, Vol.9, pp.357-382, 2006.

[9] Konstan, J. A., Miller, B. N., Maltz, D., Herlocker, J. L., Gordon, L. R., and Riedl, J., "GroupLens: Applying Collaborative Filtering to Usenet News," Communications of the ACM, Vol.40, pp.77-87, 1997.

[10] Linden, G., Smith, B., and York, J., "Amazon.com Recommendations: Item-to-Item Collaborative Filtering," IEEE Internet Computing, Vol.7, pp.210-217, 2003.

[11] Manouselis, N. and Costopoulou, C., "Analysis and Classification of Multi-Criteria Recommender Systems," World Wide Web, Vol.10, pp.451-441, 2007.

[12] Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., and Riedl, J., "GroupLens: An Open Architecture for Collaborative Filtering of Netnews," Proceedings of the ACM Conference on Computer Supported Cooperative Work, pp.175-186, 1994.

[13] Sarwar, B., Karypis, G., Konstan, J., and Reidl, J., "Item-based Collaborative Filtering Recommendation Algorithms," Proceedings of the 10th International World Wide Web Conference, ACM Press, pp.285-295, 2001.

[14] Sarwar, B., Karypis, G., Konstan, J., and Riedl, J., "Analysis of Recommendation Algorithms for E-Commerce," Proceedings

of ACM Conference on Electronic Commerce, pp.158-167, 2000.

[15] Schein, A. I., Popescul, A., and Ungar, L. H., "Methods and Metrics for Cold-Start Recommendations," Proceedings of the 25th International ACM Conference on Research and Development in Information Retrieval, pp.253-260, 2002.

[16] Shardanand, U. and Maes, P., "Social Information Filtering: Algorithms for Automating Word of Mouth," Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, pp.210-217, 1995.



김 흥 남

e-mail : nami@eslab.inha.ac.kr
 2002년 인하대학교 컴퓨터공학과(학사)
 2004년 인하대학교 전자계산공학과(석사)
 2009년 인하대학교 정보공학과(박사)
 2009년~현 재 인하대학교 BK21 정보기술
 사업단 박사후 연구원

관심분야: 추천시스템, 데이터 마이닝, 시맨틱 웹 등



조 근 식

e-mail : gsjo@ inha.ac.kr
 1982년 인하대학교 전자계산학과(학사)
 1985년 Queens College/City University of
 New York (MA in Computer
 Science)
 1991년 City University of New York (Ph. D
 in Computer Science)

1991년~현 재 인하대학교 컴퓨터정보공학과 교수
 2006년~현 재 인하대학교 BK21 지능형 유비쿼터스 물류기술
 연구사업단장
 2008년 한국 지능정보시스템학회 회장
 관심분야: 인공지능, 온톨로지, CSP, 전자상거래 등