

협동적 여과를 위한 희소 데이터 변형 기법

김형일^o 김준태

동국대학교 컴퓨터공학과

{hikim^o, jkim}@dongguk.edu

Modifying Sparse Data for Collaborative Filtering

Hyungil Kim^o Juntae Kim

Dept. of Computer Engineering, Dongguk University

요약

협동적 여과를 이용한 추천 시스템은 데이터의 희소성 문제(sparseness problem)와 초기 추천 문제(cold-start problem)에 대해 취약점을 가지고 있다. 협동적 여과를 이용한 추천 시스템에서 사용하는 선호도 데이터에 아이템들의 전체 수량에 비해 매우 적은 양의 아이템 선호도만 존재한다면 사용자들의 유사도 측정에 문제를 발생시켜 극단적인 경우엔 협동적 추천이 불가능할 경우가 발생한다. 이와 같은 문제는 선호도 데이터에 나타난 아이템들의 총수에 비해 사용자가 선호(구매)한 아이템이 극히 적은 수량으로 존재하기 때문이며, 새로운 사용자의 경우에는 아이템 선호도 정보가 전혀 없기 때문에 유사 사용자를 추출하지 못하여 아이템을 전혀 추천할 수 없는 문제가 발생한다. 본 논문에서는 희소성이 높은 선호도 데이터를 희소하지 않은 상태로 변형하는 희소 데이터 변형 기법을 제안한다. 희소 데이터 변형 기법은 희소 데이터에 나타난 사용자와 아이템의 추가 속성 정보를 이용하여 알려지지 않은 선호도 값을 예측함으로써 희소성이 높은 선호도 데이터를 변경하고, 변경된 선호도 데이터를 협동적 추천에 적용하여 추천 성능을 향상시킨다. 이와 같은 선호도 데이터 변경 기법을 데이터 블러링(data blurring)이라 한다. 몇 가지 실험 결과를 통해 제안된 기법의 효과를 확인하였다.

1. 서론

추천 시스템은 사용자의 선호도를 분석하고, 아이템들에 대한 사용자의 선호도를 예측하여 책, 영화, 음악, 새로운 기사, 웹 페이지 등과 같은 아이템들을 추천한다. 다양한 추천 기법 중에 협동적 여과는 상용화된 시스템에 성공적인 적용이 이루어진 기법이다.

협동적 여과기반 추천 시스템은 아이템들에 대한 각 사용자들의 평가 정보를 이용한다[1-4]. 가장 일반적인 접근 방식은 사용자들 사이의 평가 정보를 비교하여 유사 사용자를 추출하고, 아이템에 대한 유사 사용자의 선호도를 기반으로 특정 아이템에 대한 사용자의 선호도를 예측하는 것이다. 협동적 여과 분석은 아이템의 내용 정보를 필요로 하지 않기 때문에 내용을 분석하기 어려운 음악이나 영화 같은 아이템을 추천할 수 있다.

협동적 여과는 많은 장점이 있으며, 다양한 응용 시스템에 성공적으로 적용된 기법이지만 데이터의 희소성 문제(sparseness problem)와 초기 추천 문제(cold-start problem)에 취약하다. 만약 매우 적은 선호도 정보가 존재한다면 많은 유사 사용자를 찾기 어려우며, 따라서 추천의 정확도는 낮아지게 된다. 이러한 취약점은 특히 시스템의 초기나 새로운 사용자에게 아이템을 추천할 경우에 결정적인 단점으로 작용한다. 새로운 사용자는 아이템에 대한 선호도 정보가 없기 때문에 유사 사용자를 추출할 수 없으며, 따라서 시스템은 아이템을 전혀 추천할 수 없게 되는데, 이를 초기 추천 문제라 한다.

데이터 희소성 문제와 초기 추천 문제를 해결하기 위한 하나의 방법은 희소성이 높은 선호도 데이터의 희소성을 감소시키는 것이다. 선호도 데이터의 희소성이 감소하면 유사 사용자 추출이 쉬워지며, 사용자의 성향에 맞는 아이템 추천이 가능해진다. 본 논문에서는 희소 데이터에 나타난 사용자와 아이템의 추가 속성 정보를 이용하여 알려지지 않은 선호도 값을 예측함으로써 희소성이 높은 선호도 데이터를 변경하고, 변경된 선호도 데이터(희소하지 않은 선호도 데이터)를 협동적 여과기반 추천에 적용하여 추천 성능을 향상시킨다. 이와 같이 알려지지 않은 선호도 값을 예측하여 희소 데이터를 희소하지 않은 데이터로 변경하는 기법을 데이터 블러링(data blurring)이라 한다.

2. 관련연구

협동적 여과기반 추천 시스템은 많은 사용자로부터 추천이 이루어진 아이템에 대한 평가를 활용한 기법이다. 근접이웃기반 협동적 여과는 사용자들 사이의 평가 정보를 비교하여 유사

사용자들을 추출하고, 유사 사용자들의 선호도를 기반으로 사용자의 아이템 선호도를 예측한다.

GroupLens[3]와 같은 협동적 여과 시스템에서는 사용자의 선호도를 예측하는데 상관관계(correlation)기반 기법이 사용되었고, 다양한 변형된 기법들이 추천 시스템의 정확도 향상을 위해 제안되었다. Billsus와 Pazzani[1]는 충분한 정보가 없을 때 사용자의 선호도 예측을 위해 속성 추출 기술을 적용하였으며, 사용자-아이템 선호도 행렬의 차원을 줄이기 위하여 SVD(Singular Value Decomposition)를 사용하였다. Breese 등[5]은 사용자로부터의 평가 정보가 없는 아이템에 대해 기본 평가 값을 사용하였고, 각 아이템에 얼마나 많은 사용자가 평가를 수행했느냐에 따라 서로 다른 가중치를 적용하였다. Herlocker 등[2]은 다양한 유사도 계산 방식과 유사도 가중치 방법에 대한 실험을 수행하였다. 유사도 계산에는 피어슨 상관계수, 스피어만 상관계수, 벡터 유사도, 엔트로피를 이용하였고, 선호도 값을 구하는 방법으로 평균 가중치, 유사 사용자의 아이템 선호도의 가중치 합, z 평균 방법을 이용하였다. Shardanand[4]는 사용자 사이의 유사도가 아닌 아이템-아이템 유사도를 이용하는 방법을 제안한 바 있다.

Basul[6], Claypool[7] 등은 협동적 추천과 내용기반 추천 결과를 결합하는 방식의 복합 추천을 제안하였고, Pazzani[8]는 사용자의 내용기반 프로필 사이의 유사도로 사용자 사이의 유사도 계산함으로써 협동적 여과와 내용기반 여과를 혼합하는 시도를 하였다. 또한 통합적인 추천값 예측 모델을 시도한 예로서 Condliff 등[9]은 베이지안 혼합 효과 모델에서 사용자의 평가 값과 사용자와 아이템의 속성 값을 통합하는 시도를 하였고, Popescu 등[10]은 three-way aspect 모델에서 내용 정보와 사용자와 아이템의 동시 발생 데이터를 결합한 통합 확률 모델을 제안한 바 있다.

본 연구에서는 아이템과 사용자의 일반적인 속성들을 모두 사용하여 알려지지 않은 아이템의 선호도 값을 예측하고, 예측된 선호도 값을 이용하여 희소 데이터를 희소하지 않은 데이터로 변형하는 기법을 제안한다.

3. 희소 데이터 변형을 위한 데이터 블러링

3.1 데이터 블러링의 개념

많은 실질적인 추천 시스템 응용 분야에서는 선호도 데이터 외에 여러 가지의 사용자 정보와 아이템 정보가 존재한다. 예를 들어 사용자에 대해서는 성별, 나이, 직업 등 인구통계학적 정보가 있을 수 있고, 아이템에 대해서는 영화의 장르와 같은 분류 정보 등이 있을 수 있다. 이와 같은 정보를 활용하면

데이터 희소성 문제와 초기 추천 문제를 완화시킴으로써 협동적 과거의 성능을 개선할 수 있다.

본 논문에서 제안하는 방법은 이러한 추가적인 속성 정보를 이용하여 알려지지 않은 선호도를 채워 넣는 것이다. 이러한 방법을 데이터 블러링이라고 한다. 즉 데이터 블러링은 추가적인 속성 정보로부터 계산될 수 있는 확률분포에 기반하여 알려지지 않은 선호도 데이터를 예측하여 선호도 데이터의 희소성을 없애는 것이다. 기본적인 개념은 사용자가 속성 값이 X인 아이템을 선호한다면, 그 사용자는 속성 값이 X인 다른 아이템들에 대해서도 어느 정도 선호도를 갖는다고 가정하는 것이다. 예를 들면 사용자 U1은 I1을 선호하며, I1의 장르가 A라는 것을 바탕으로 역시 장르가 A인 선호도가 나타나지 않은 I2에 대한 선호도 값이 1/2이라고 예상하는 것이다. 1/2은 장르가 A인 아이템들에 대한 U1의 평균 선호도이다. 이 방법은 사용자 속성에도 적용할 수 있다.

3.2 블러링 알고리즘

블러링 계산 과정을 설명하기 위해 사용하는 기호들은 다음과 같이 정의한다.

- P는 블러링 값으로 나타난 사용자와 아이템 사이의 선호도 행렬이다. 사용자 U_i 가 아이템 I_j 를 선호할 경우 $P_{ij} = 1$ 이고, 그 이외의 경우는 0이다.
- 사용자는 속성이 f_1, f_2, \dots, f_n 인 n개의 속성들을 가진다.
- 아이템은 속성이 g_1, g_2, \dots, g_m 인 m개의 속성들을 가진다.
- 사용자 U_i 의 속성 벡터는 $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$ 이다. x_{ik} 는 사용자 U_i 의 f_k 속성 값이다.
- 아이템 I_j 의 속성 벡터는 $Y_j = (y_{j1}, y_{j2}, \dots, y_{jm})$ 이다. y_{jk} 는 아이템 I_j 의 g_k 속성 값이다.
- $P_{ij} = 0$ 일 경우에 블러링을 적용하여 선호도 값을 채워 넣기로 한다.

P_{ij} 의 값은 아이템의 속성 정보나 사용자의 속성 정보를 이용하여 예측할 수 있으며, 전자를 행-방향 블러링, 후자를 열-방향 블러링이라 한다.

행-방향 블러링은 아이템의 속성 정보를 이용하여 알려지지 않은 P_{ij} 의 값을 생성한다. 사용자 U_i 가 아이템 I_j 를 선호할 확률을 $P(U_i|I_j)$ 라 하면, 이 확률은 아이템 속성의 확률분포를 이용하여 다음과 같이 계산될 수 있다.

$$P(I_j|U_i) = P(I_j|y_{j1}, y_{j2}, \dots, y_{jm}) \cdot P(y_{j1}, y_{j2}, \dots, y_{jm}|U_i) \quad (1)$$

$$\approx P(I_j|y_{j1}, y_{j2}, \dots, y_{jm}) \cdot \prod_{k=1}^m P(y_{jk}|U_i) \quad (2)$$

$$\approx \frac{N(I_j)}{N(y_{j1}, y_{j2}, \dots, y_{jm})} \cdot \frac{N(U_i, y_{j1}) + 1}{N(U_i) + k_1} \cdot \frac{N(U_i, y_{j2}) + 1}{N(U_i) + k_2} \cdot \dots \cdot \frac{N(U_i, y_{jm}) + 1}{N(U_i) + k_m} \quad (3)$$

식 (2)은 아이템 속성들이 서로 독립이라는 가정에 의해 확률 값을 근사시킨 것이다. 각 확률 값을 행렬 P에서 해당하는 1의 개수에 의해 추정된다. 식 (3)에서 $N(I_j)$ 는 아이템 I_j 에 대한 선호도 총수이며(행렬 P에서 j번째 열의 1의 개수), $N(y_{j1}, y_{j2}, \dots, y_{jm})$ 은 속성 값이 $y_{j1}, y_{j2}, \dots, y_{jm}$ 인 아이템에 대한 알려진 선호도 총수를 의미한다. $N(U_i)$ 는 사용자 U_i 의 선호도의 총수를 의미하고(행렬 P에서 i번째 행의 1의 개수), $N(U_i, y_{jk})$ 는 속성 값이 y_{jk} 인 아이템에 대한 사용자 U_i 의 선호도 수를 나타낸다. 확률 추정값이 0이 되는 경우를 배제하기 위하여 라플라스(Laplace) 근사값을 사용한다. 즉, k_i 는 아이템 속성 g_i 에 대한 서로 다른 값의 개수이다.

열-방향 블러링은 사용자의 속성 정보를 이용하여 P_{ij} 의 값을 생성한다. 아이템 I가 사용자 U_i 에 의해 선호될 확률을 $P(U_i|I)$ 라 하면, 이 확률은 사용자 속성의 확률분포에 의해 계산될 수 있으며, 계산 방식은 행-방향 블러링과 같다.

행-방향 블러링과 열-방향 블러링의 결과로 최종 값 $Blurring(i, j)$ 을 아래와 같이 결정할 수 있으며, α_r 과 α_c 는 각각 행-방향 블러링 인수와 열-방향 블러링 인수이다.

$$Blurring(i, j) = \alpha_r \cdot P(I_j|U_i) + \alpha_c \cdot P(U_i|I_j) \quad (4)$$

모든 알려지지 않은 선호도 값을 예측하고 나면, 변형된 선호도 행렬을 이용하여 협동적 여과를 수행한다.

4. 성능 실험

4.1 실험 방법

실험에서 사용한 EachMovie 데이터는 72,916명의 사용자가 1,628개의 영화들에 대해 선호도 평가를 수행한 것으로 사용자의 명시적 평가가 이루어진 데이터 집합이다. 사용자들은 각 영화에 대해 0.0부터 1.0까지의 범위에 포함된 6단계의 평가 값을 이용하여 영화에 대한 선호도 평가를 수행하였다.

실험용 데이터는 블러링 유무에 따라 원시 데이터와 블러링 데이터로 나뉘며, 두 개의 데이터는 평가 값의 형태에 따라 각각 실수형과 블러링형으로 나뉜다. 실수형 데이터는 명시적 선호도가 나타난 원시 데이터이고, 블러링형 데이터는 실수형 데이터를 블러링형으로 바꾼 데이터이다. 실수형 평가 값을 블러링 값으로 변형 할 때는 각 사용자의 평균 평가 값을 계산한 후, 평균보다 큰 평가 값은 1로 변환하고, 나머지는 0으로 변환한다. 따라서 '1'은 '선호한다'는 의미이고, '0'은 '선호도를 알 수 없다'의 의미이다. 이러한 변형은 아이템을 구매하는 행위나 웹 페이지를 클릭하는 행위 등 묵시적인 암성 평가만 얻어질 수 있는 일반적인 환경에서 제안된 기법을 테스트하기 위하여 수행되었다.

일반 실험에서는 EachMovie 데이터에서 1000명의 사용자를 랜덤하게 추출하고 여러 장면에 속하는 아이템들을 제외하여 100X1000 사이즈의 실험용 데이터(원시 상태의 실수형 데이터)를 생성하고, 실수형 선호도를 블러링 값으로 변환한 후 블러링형 데이터를 생성한다. 이렇게 생성된 실수형 원시 데이터와 블러링형 원시 데이터를 각각 블러링하여 실수형 블러링 데이터와 블러링형 블러링 데이터를 생성한다. 이와 같이 생성된 두 개의 원시 데이터와 두 개의 블러링 데이터를 실험용 선호도 데이터로 활용하여 추천 성능을 비교하였다.

희소성 실험에서는 중복된 장면에 포함되어 있지 않은 아이템들만 선호한 사용자들을 추출하였다. 생성된 실험용 데이터에 존재하는 사용자는 74명이고 아이템은 1000개로 실험용 데이터의 사이즈는 74X1000이다. 희소성 실험에 사용한 선호도 데이터는 일반 실험에서와 같이 4개가 존재한다. 희소성 실험에 사용된 실수형 원시 데이터의 선호도 총수는 214개로 전체 선호도의 0.29%에 해당하는 희소성이 대단히 높은 데이터이다.

실수형 데이터는 MAE(mean absolute error)로 추천 성능을 측정하고, 블러링형 데이터는 적중률(hit ratio)을 이용하여 추천 성능을 측정하였다. 사용자 유사도 측정에 벡터 유사도를 사용하고, 아이템 선호도 예측에는 K-NN(k-nearest neighbor)을 이용하여, 아이템 추천에서는 top-N을 적용하여 실험을 10-fold cross validation으로 수행하였다. 선호도 데이터를 블러링할 때 블러링 인수는 행-방향 블러링과 열-방향 블러링 모두 0.5로 하였다.

초기 추천 실험에서는 새로운 사용자를 생성하기 위해 테스트 집합에 소속된 사용자들의 선호도를 모두 없애고('1'을 '0'으로 변환), 새로운 사용자의 선호도 벡터를 블러링한 후에 선호도를 없앤 아이템을 테스트한다. 비교 대상인 원시 데이터를 활용한 추천에서는 사용자 선호도가 0 벡터로써 협동적 여과를 적용할 수 없기 때문에 이 실험에서는 모든 새로운 사용자에게는 가장 인기 있는 (사용자로부터 많이 선호된) top-N 아이템을 추천하는 방식을 취한다.

적중률을 K(유사 사용자 수)와 N(추천 아이템 수)의 값을 변화시키면서 구하여 블러링되지 않은 원시 데이터에 의한 추천 성능과 블러링된 데이터에 의한 추천 성능을 비교 실험하였다.

MAE에서는 K(유사 사용자 수)를 변화시키면서 예측 값과 실제 평가 값의 차를 이용하여 추천 성능을 비교 실험하였다.

$$MAE = \frac{\sum |P(\text{predicted rating}) - A(\text{actual rating})|}{\text{total number of tests}} \quad (5)$$

$$\text{Hit ratio} = \frac{\text{total number of hits}}{\text{total number of tests}(=\text{total number of } '1')} \quad (6)$$

4.2 실험 결과

일반 실험에 사용된 실수형 데이터의 아이템 선호도 총수는 28,777개로 전체 선호도의 2.88%에 해당하며, 블러링형 데이터

에 나타난 아이템 선호도 총수는 전체 선호도의 1.5%에 해당한다. 실수형 데이터와 블러린형 데이터에서 선호도 값들은 고른 분포를 이루지 않으며, 특정한 아이템들이 많은 선호도를 차지하고 있다. 사용자가 많이 선호하는 아이템을 기준으로 top-10에 해당하는 아이템들이 전체 선호도 데이터의 16%, top-20에 해당하는 아이템들이 전체 선호도 데이터의 28%를 차지한다.

표 1과 표 2는 일반 실험에 대한 MAE와 적중률 결과이고, 표 3과 표 4는 희소성 실험에 대한 MAE와 적중률 결과이며, 그림 1은 초기 추천에 대한 적중률 결과이다.

표 1 일반 실험에서의 MAE(실수형 데이터, 1000X1000)

K=1	K=5		K=10		K=20		K=50		
	Original	Blurred	Original	Blurred	Original	Blurred	Original	Blurred	
0.4192	0.4180	0.3826	0.3820	0.3831	0.3823	0.3873	0.3866	0.3983	0.3976

표 2 일반 실험에서의 적중률(블러린형 데이터, 1000X1000)

K	N=10		N=20		N=30		N=40	
	Original	Blurred	Original	Blurred	Original	Blurred	Original	Blurred
1	19.5	25.6	24.1	37.1	26.4	45.1	27.6	51.5
5	39.1	40.0	47.5	50.1	52.5	56.7	55.7	61.7
10	43.0	43.3	53.3	54.2	59.5	61.0	63.4	65.6
20	44.1	44.2	55.9	56.1	62.5	62.8	67.4	68.0
50	43.5	43.4	56.1	56.3	63.6	63.7	68.8	68.8

표 3 희소성 실험에서의 MAE(실수형 데이터, 74X1000)

K	K=1		K=3		K=5	
	Original	Blurred	Original	Blurred	Original	Blurred
MAE	0.7448	0.6769	0.7418	0.6731	0.7432	0.6720

표 4 희소성 실험에서의 적중률(블러린형 데이터, 74X1000)

K	N=3		N=5		N=7		N=10	
	Original	Blurred	Original	Blurred	Original	Blurred	Original	Blurred
1	1.61	4.03	1.61	7.26	1.61	12.10	1.61	22.58
3	4.84	7.26	4.84	9.68	4.84	12.90	4.84	17.74
5	5.65	5.65	8.06	11.29	8.06	12.10	8.06	15.32




그림 1 초기 추천에 대한 적중률 그래프(블러린형 데이터)

일반 실험에 대한 MAE와 적중률 결과를 보면 블러링된 데이터가 원시 데이터보다 모든 K에서 우수한 성능을 나타낸다. 표 2의 원시 데이터에서 나타난 결과를 보면 K=1에서는 N이 증가 하더라도 추천 정확도 향상이 크게 나타나지 않고 있다. 이는 원시 선호도 데이터가 희소하여(1.5%) 단일한 유사 사용자만을 이용하는 경우 목표 아이템 아예 추천 대상이 되지 않는 경우가 많기 때문이다. 블러링 데이터에서는 K=1에서도 N의 증가에 따라 성능 향상이 크게 나타난다. 블러링 데이터는 희소하지 않기 때문에 K=1일 경우에도 유사 사용자를 추출할 수 있어 높은 추천 성능을 나타낸다. K=1일 때 블러링 데이터는 원시 데이터에 비하여 top-10 추천에서 6.1%, top-40 추천에서 23.9%의 성능 향상을 나타낸다. 성능의 향상은 K가 작을수록 높게 나타나며, 이는 블러링된 데이터에는 알려지지 않은 선호

도가 존재하지 않음으로 적은 유사 사용자를 활용하여도 목표 아이템에 대한 추천 값을 얻을 수 있기 때문이다.

희소성 실험에 대한 MAE와 적중률 결과를 보면 블러링된 데이터가 모든 조건에서 우수한 추천 성능을 나타내며, 특히 희소성 실험 결과가 일반 실험 결과보다 우수하게 나타난다. 일반 실험에 비해 희소성 실험에서 블러링 데이터가 원시 데이터보다 특히 높은 추천 성능을 나타내는 이유는 희소성 실험에 사용한 데이터가 일반 실험에 사용한 데이터보다 대략 10배 정도 더 높은 희소성을 나타내기 때문이다. 따라서 데이터 블러링은 희소성이 높은 데이터의 경우에 더욱 효과적이다.

그림 1은 새로운(초기) 사용자에 대한 적중률 결과이다. 원시 데이터의 경우 선호도가 인기 있는 소수의 영화에 집중되는 경향이 있기 때문에 항상 인기 순위 top-20 아이템을 추천하여도 약 28%의 적중률을 얻을 수 있다. 실험 결과를 보면 K가 5보다 큰 모든 경우에서 새로운 사용자를 블러링하여 아이템을 추천받은 결과가 인기도가 높은 상위 10개와 상위 20개를 추천한 결과보다 우수하게 나타난다. 이러한 결과는 새로운 사용자에 대한 아이템 추천 역시 데이터를 블러링함으로써 가능할 수 있다는 것을 나타낸다.

5. 결론 및 향후 연구

협동적 여과 방식은 데이터 희소성 문제와 초기 추천 문제에 취약하다.

본 논문에서는 협동적 여과의 문제점인 데이터 희소성 문제와 초기 추천 문제를 해결하기 위해 사용자와 아이템의 추가 속성 정보의 활용분포를 기반으로 알려지지 않은 선호도 값을 예측하여 희소성이 높은 선호도 데이터를 변경하는 데이터 블러링 기법을 제안한다. 블러링된 데이터는 희소하지 않은 상태로 존재하여 협동적 여과기반 추천의 경우에 높은 추천 성능을 나타낸다. 실험 결과에서 확인한 것과 같이 데이터 블러링 기법을 희소성이 높은 선호도 데이터에 적용함으로써 협동적 여과의 희소성 문제와 초기 추천 문제를 완화할 수 있다.

향후 연구로 아이템 및 사용자 속성의 중요도에 따른 블러링 인수 조정 방법에 관한 연구와 다양한 형태로 존재하는 선호도 데이터들의 특성에 따른 실험이 요구된다.

[참고문헌]

- [1] D. Billsus and M. J. Pazzani, "Learning Collaborative Information Filters," *Proceedings of the 15th International Conference on Machine Learning*, Wisconsin, 1998.
- [2] J. Herlocker, J. Konstan, A. Borchers, and J. Riedl, "An Algorithmic Framework for Performing Collaborative Filtering," *In Proceedings of ACM SIGIR-99*, 1999.
- [3] J. Konstan, B. Millr, D. Maltz, J. Herlocker, L. Gordon, and J. Riedl, "GroupLens: Applying Collaborative Filtering to Usenet News," *Communications of the ACM*, Vol.40, No.3, pp.77-87, 1997.
- [4] U. Shardanand and P. Maes, "Social Information Filtering: Algorithms for Automating 'Word of Mouth,'" *Proceedings of the Conference of Human Factors in Computing Systems*, 1995.
- [5] J. Breese, D. Heckerman, and C. Kadie, "Empirical Analysis of Predictive Algorithms for Collaborative Filtering," *Proceedings of the Fourteenth Annual Conference on Uncertainty in Artificial Intelligence*, 1998.
- [6] C. Basu, H. Hirsh, and W. Cohen, "Recommendation as Classification: Using Social and Content-Based Information in Recommendation," *Proceedings of the 15th National Conference on Artificial Intelligence*, 1998.
- [7] M. Claypool, A. Gokhale, T. Miranda, P. Murnikov, D. Netes and M. Sartin, "Combining Content-Based and collaborative Filters in an Online Newspaper," *Proceedings of the ACM SIGIR Workshop on Recommender Systems*, 1999.
- [8] M. Pazzani, "A Framework for Collaborative, Content-based and Demographic Filtering," *Artificial Intelligence Review*, pp.393-408, 1999.
- [9] M. Condliff, D. Lewis, D. Madigan, and C. Posse, "Bayesian Mixed-Effect Models for Recommender Systems," *Proceedings of Recommender Systems Workshop at SIGIR-99*, 1999.
- [10] A. Poposcul, L. Ungar, D. Pennock, and S. Lawrence, "Probabilistic Models for Unified Collaborative and Content-Based Recommendation in Sparse-Data Environments," *Proceedings of the 17th Conference on Uncertainty in Artificial Intelligence*, 2001.