

## m-CRM을 위한 음악추천시스템: 웹 마이닝과 서열척도를 이용한 협업 필터링

이 석 기\*

### A Music Recommender System for m-CRM: Collaborative Filtering using Web Mining and Ordinal Scale

Seok Kee Lee \*

#### 요 약

모바일 웹(Web)과 관련한 기술이 점점 발달함에 따라 모바일 전자상거래 시장, 그 중에서도 벨소리나 컬러링과 같은 음악 다운로드 시장의 크기는 괄목할 만한 성장을 거듭하고 있다. 하지만, 이러한 급성장에도 불구하고 소비자들은 여전히 자신이 원하는 음악을 찾는 과정에서 많은 불편함을 겪고 있다. 이는 소비자들의 음악에 대한 재구매율을 저하시키게 되고, 모바일 음악을 제공하는 서비스 업체 입장에서도 수익 정체에 원인으로 작용할 수 있다. 따라서 고객관계 관리 측면에서 모바일 고객의 불편을 최소화함으로써 결국 수익을 더욱 많이 창출하기 위한 새로운 방법이 절실한 상황이다. 이에 본 연구는 모바일 웹 환경 하에서 소비자들이 편리하게 자신이 원하는 음악을 검색할 수 있도록 하기 위하여, 모바일 웹 마이닝과 서열척도를 활용하는 협업 필터링 기반의 새로운 음악 추천 시스템을 제안한다. 또한 실험을 통해 우리가 제안하는 새로운 추천 시스템이 기존의 추천 시스템들에 비하여 우수한 성능을 나타냄을 입증하고자 한다.

#### Abstract

As mobile Web technology becomes more increasingly applicable, the mobile contents market, especially the music downloading for mobile phones, has recorded remarkable growth. In spite of this rapid growth, customers experience high levels of frustration in the process of searching for desired music contents. It affects to a re-purchasing rate of customers and also, music mobile content providers experience a decrease in the benefit. Therefore, in aspects of a customer relationship management (CRM), a new way to increase a benefit by providing a convenient shopping environment to mobile customers is necessary.

As an solution for this situation, we propose a new music recommender system to enhance the customers' search efficiency by combining collaborative filtering with mobile web mining and ordinal scale based customer preferences. Some experiments are also performed to verify that our proposed system is more effective than the current recommender systems in the mobile Web.

▶ Keyword : CRM(고객관계관리); Recommender System(추천 시스템); Collaborative Filtering (협업필터링)

• 제1저자 : 이석기

• 접수일 : 2007. 11. 14, 심사일 : 2007. 11.20, 심사완료일 : 2007. 12.15.

\* KAIST 테크노경영대학원 경영공학 박사과정

## 1. 서론

모바일 웹 기술과 관련 H/W의 비약적인 발전으로 인해 모바일 웹을 통한 음악(mp3, 벨소리, 컬러링, MOD 등) 다운로드 서비스 시장의 규모는 비약적으로 증가하는 추세에 있다. 그러나 소비자들은 모바일 웹이 제공하는 비효율적인 검색방식으로 인해 그들이 원하는 음악을 찾는데 여전히 많은 어려움을 겪고 있으며 이는 모바일 장치가 갖는 고유한 특징 - 작은 화면, 제한된 CPU 성능, 불편한 입력 방식, 단순한 브라우저 등 [6]-으로 인해 인터페이스가 기존의 웹에 비해 사용자 친화적이지 못하다는 데서 그 원인을 찾을 수 있다. 따라서 현재의 모바일 웹 콘텐츠 시장을 보다 활성화시키기 위해서는 이러한 단점을 극복하면서 소비자가 적은 시간과 비용을 들여서 자신이 원하는 음악을 찾을 수 있도록 도와주는 새로운 검색 메커니즘이 필요한 상황이다.

이를 만족할 수 있는 대안 중의 하나가 소비자가 자신이 원하는 콘텐츠를 쉽게 찾을 수 있도록 도와주는 추천 시스템(recommender system)의 활용이다. 기존 웹 환경에서는 개인화 된 추천 서비스를 위한 여러 기법들이 소개되고 있는데, 현재까지 많은 성공 사례를 가지고 있는 대표적인 기법이 협업 필터링(collaborative filtering) 기반의 추천 시스템이다[1, 8]. 모바일 웹 환경이 기존 웹 환경과 매우 유사하다는 점을 감안할 때, 모바일 웹 환경에서도 협업 필터링 기반의 개인화 된 추천 시스템이 성공적으로 활용될 수 있는 가능성이 존재한다. 그러나 모바일 웹 환경에서 협업 필터링 기반의 추천 시스템을 구축하는 경우에는 아래와 같은 두 개의 문제점들이 나타날 수 있다.

첫 번째 이슈는 sparsity 문제이다[1,9,10]. 모바일 음악 다운로드 서비스 CP(content provider)들이 보유하고 있는 음악 수에 비해서 사용자들이 실제 경험하고 평가하는 아이템 수는 매우 미미하여 협업 필터링의 정확성을 저하시킬 가능성이 높다. 웹 환경에서는 이러한 sparsity를 해결하기 위한 노력이 다양하게 이루어지고 있는데(예. hybrid filtering, product taxonomy, implicit ratings)[7], 본 연구에서는 그 중에서도 implicit rating을 활용하여 사용자들의 상품에 대한 선호도 정보를 간접적으로 파악하는 모바일 웹 마이닝(Mobile Web Mining) 기법을 제안한다. 이는 모바일 로그에 담겨 있는 사용자들의 행동정보를 분석하여 선호도를 파악하는 방법으로써, 기존의 웹 환경에서 많이 활용되고 있는 웹 마이닝(web usage mining) 기법과 유사하다. 모바일 환경이 장치의 제한성이나 인터페이스의 열악함 등의 문제를 내포

하고 있어서 사용자에게 특정 콘텐츠에 대한 선호도를 직접 평가하게 하는 것이 불편할뿐더러 통신비용 면에서도 추가적 부담이 된다는 점을 감안할 때, 모바일 웹 마이닝을 통한 간접적인 사용자의 선호도 평가는 모바일 웹의 환경적 요인을 고려한 효과적인 선택이 될 수 있다.

두 번째 이슈는 평가 척도(measurement scale)의 문제이다. Implicit rating을 통해 사용자의 선호도를 파악할 경우, 이를 표현하기 위한 주요 척도로는 등간, 비율 척도를 포함한 카디널 척도(cardinal scale)와 서열 척도(ordinal scale) 등이 있다. 일반적으로 카디널 척도는 사용자가 직접 특정 상품에 대해 실제 자신이 가지고 있는 선호도에 근접하는 정확한 값을 표현할 수 있다는 점에서 대부분의 추천 시스템 관련 연구에서 서열 척도보다 많이 활용되어 왔다. 하지만 이는 사용자가 직접 선호도를 표현하는 경우에 해당되는 것으로서 implicit rating과 같이 간접적으로 선호도를 파악하는 시스템에서도 서열척도보다 우수한 척도일 것이라는 결론을 내리기는 힘들다. Wang et al. 은 자신들의 연구에서 간접적인 선호도 예측(estimation)을 위해 필요한 관련정보가 충분히 제공되지 않는 상황에서는 상대적으로 덜 정확한 척도법이 오히려 더 나을 수 있다는 사실을 입증한 바 있다[13]. 이는 정보가 불충분한 상황에서 지나치게 정확한 값을 요구하는 척도의 경우 오히려 측정된 값의 분산을 증가시켜서 결과적으로 예측오차(estimation error) - 실제 선호도와 예측된 선호도 값과의 차이를 증가시키기 때문이다. 모바일 환경 하에서 사용자의 실제 선호도는 그 사용자가 가지고 있는 다양한 속성들의 종합체(comprehensive mixture)로 이해할 수 있는데, 이러한 속성들에는 개인의 인구통계학적 특징과 더불어 상품 구매과정에서 보인 행동들, 구매 당시의 심리적인 상황 등이 모두 포함된다. 하지만 implicit rating을 통해 사용자의 선호도를 파악하고자 하는 경우, 이들 속성 중의 일부는 충분히 파악되지 않는 경우가 많다. 예를 들어 구매 시점에서의 사용자의 심리적인 특징과 같은 정보는 걸로 드러나지 않기 때문에 획득하기가 거의 불가능 하다. 따라서 implicit rating은 불가피하게 위의 속성들 중 일부를 획득하지 못하는 환경(정확한 선호도 파악을 위한 정보가 불충분한 상황)에서 수행되는 경우가 많으며 이를 고려할 때, implicit rating 하에서는 일반적으로 카디널 척도보다 덜 민감한(sensitive) 특성의 서열척도를(카디널 척도보다 덜 정확하지만) 사용하는 것이 더 나을 수 있다.

결론적으로, 모바일 웹 환경을 고려한 상품 추천을 위해서는 상품에 대한 사용자의 선호도를 간접적으로 파악하고 이를 서열척도로 계량화 할 수 있는 메커니즘이 필요하다. 따라서

본 연구에서는 효과적인 고객관계관리(CRM) 차원에서 개인별로 맞춤형 된 음악 콘텐츠의 추천을 가능케 하는 새로운 음악 추천 시스템(MMRS, Mobile Music Recommender System)을 제안 하고자 한다. 아울러 실험을 통하여 본 연구에서 제안하는 추천 시스템의 성능을 평가하고 현존하는 다른 추천 시스템과 비교하여 제안된 시스템의 우수성을 입증하고자 한다.

## II. 관련문헌 연구 (Related works)

### 1. 협업 필터링 (Collaborative Filtering)

협업 필터링 기반의 추천 시스템들은 일반적으로 아래와 같은 절차를 거쳐서 목표 고객에게 상품을 추천한다 [8, 9, 12]. (1) 고객들은 시스템에게 자신들이 상품에 대해 선호/비선호 하는 정보를 제공하며 시스템은 이를 근거로 고객 프로필을 작성한다. (2) 이후 시스템들은 다양한 통계기법이나 기계학습 방법 등을 활용하여 이웃(neighbor)이라고 알려진 일련의 고객 집단을 규명한다. 이들은 목표 고객과 유사한 선호도 정보를 가지거나 유사한 상품을 구매한 경험이 있는 집단이다. 일반적으로 이러한 이웃들은 고객들 간의 유사도(similarity) 계산에 의해 판별된다. (3) 이웃 고객군이 식별되면, 이웃 고객군이 높은 선호도 혹은 구매비율을 갖는 상품에 대해서 목표고객이 높은 선호도를 보일 것인지 여부를 계산하여서 선호할 확률이 높은 일련의 상품 목록을 고객에게 추천하게 된다. 이러한 협업 필터링은 이미 기존 웹 환경 하에서 가장 성공적인 추천 시스템으로 평가되고 있다 [1,4,10].

최근에 추천 시스템의 평가 척도와 관련해서도 서열 척도를 활용하려는 노력들이 있다. 그 중 대표적인 예가 Kamishima [4]의 연구인데, 협업필터링을 활용한 추천 시스템 상에서 서열 척도를 사용하는 것이 기존의 카디널 척도를 사용한 시스템보다 성능면에서 더 낫다는 것을 입증하고 있다. 그러나, 이 연구에서 제안한 추천시스템에서는 고객의 선호도를 파악함에 있어서 웹 마이닝 등을 통한 간접적인 방법이 아니라 직접적인 입력(explicit rating)을 전제하고 있기 때문에 본 연구가 다루고자 하는 바-implicit rating을 쓸 수 밖에 없는 모바일 웹 환경 하에서 서열 척도를 사용하는 추천 시스템의 효율성-을 입증하기에는 한계점을 가지고 있다.

### 2. 웹 마이닝 (Web Usage Mining)

웹 마이닝은 방대한 양의 웹 로그 데이터에 기반하여 그 속에 의미 있게 숨겨져 있는 사용자의 어떤 행동 패턴을 발견해 내는 것이며, 이를 위해 다양한 데이터 마이닝 기술들을 적용하는 과정을 일컫는다. [3]. 웹 마이닝의 일반적인 절차는 크게 데이터 전처리 (data pre-processing)와 패턴 발견 (pattern discovery)의 두 과정으로 나뉜다. 데이터 전처리는 웹 로그 데이터로부터 의미 있는 사용자의 행동 패턴을 마이닝 해내기 위한 전단계로서 구체적으로 데이터 정제(data cleansing), 사용자 식별(user identification), 세션 식별(session identification), 경로 완성(path completion)등의 절차를 포함하고 있다. 우리가 제안하는 방법론에서는 이러한 웹 마이닝 기술을 활용하여서 모바일 로그 데이터와 사용자의 구매 데이터를 분석하고, 이를 통해 얻어진 선호도 정보에 근거하여 해당 고객이 선호할 것으로 예상되어지는 음악을 추천하는 알고리즘을 제시하고 있다. 기본적으로 웹 서버 내에는 이러한 데이터가 방대하게 존재하고 있고 이를 잘 활용할 경우 높은 품질의 추천 서비스가 가능하게 된다. 뿐만 아니라, 모바일 로그에는 사용자의 음악 아이템에 대한 구매 기록 이외에도 다양한 부가적 정보(additional information)가 포함되어 있다. 따라서 이를 구매 기록과 함께 활용할 경우 사용자의 선호도를 보다 정확하게 파악할 수 있게 되고 이에 따라 질(quality) 높은 상품 추천 서비스가 가능해 질 것이다. 뿐만 아니라, 모바일 로그는 모바일 장치의 느리고 제한된 연산처리 능력 때문에 불필요한 그림파일(\*.jpg, \*.bmp...)이나 하이퍼링크 등을 포함하고 있지 않아서 기존의 웹 로그(typical web log)에 비해 매우 간결하고, 사용자 식별 작업이 매우 용이하여 기존 웹 로그에 비해 데이터 전처리(data pre procession)도 훨씬 간단하게 이루어질 수 있다.

## III. 제안 내용 (Methodology)

일반적으로 협업 필터링 기반의 추천 시스템들은 다음과 같은 절차에 의해 추천(recommendation)을 수행하게 된다 [9]. (1) 고객은 아이템들에 대한 선호도 평가 정보를 시스템에 제공하고, 시스템은 이를 고객 프로필에 저장한다. (2) 시스템은 통계적 혹은 기계적인 학습 기법을 통해 '유사 고객군(neighbor)'이라고 알려진, 목표 고객과 유사한 구매 기록이나 성향을 가진 고객군을 찾아낸다. (3) '유사 고객군(neighbor)'들이 과거에 높은 선호도를 보였던 아이템 중에

서 대상 고객이 경험해 보지 못한 아이템 목록들을 제시해 준다.

본 연구에서는 사용자 선호도 프로필을 모바일 웹 마이닝(mobile web mining)과 순위 척도(ordinal scale)를 활용하여 구성하게 되므로, 위 (1)번 단계를 로그 데이터를 가공하는 전처리(pre processing) 단계와 전처리 된 데이터를 통해 순위 기반의 선호도를 생성해 주는 단계로 세분화 할 필요가 있다. 본 추천 시스템(MMRS)의 방법론상의 전체적인 절차(overall procedure)는 아래 <그림 1>과 같다.

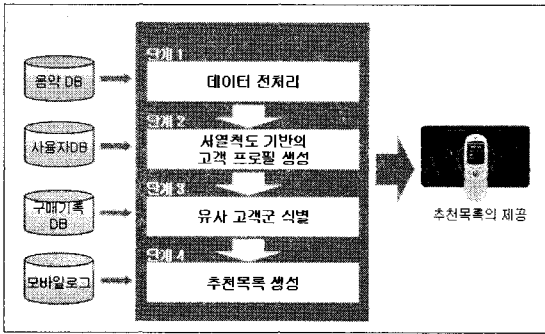


그림 1-추천 목록 생성절차  
Fig 1-Overall procedure of recommendation

단계 1. 전처리

데이터 전처리(data preprocessing)는 사용자의 access log로부터 data cleaning, user identification, session identification, path completion의 과정을 거쳐 user session을 파악해 내는 작업을 말한다[3].

모바일 웹 환경에서는 사용자의 휴대폰 번호를 통한 user identification이 용이하며, 특정 아이템의 구매나 혹은 모바일 웹에 대한 접속 종료 시점을 기준으로 session을 파악할 수 있고, 불필요한 데이터가 최소화 되어 기존의 웹 환경보다 데이터 전처리 작업이 훨씬 수월 하다고 볼 수 있다. 일정 기간 동안 누적된 사용자 A의 surfing history가 <표 1>과 같다고 가정하자.

표 1-사용자 A의 웹 서핑 기록  
Table 1-Surfing history of customer A

| Access Time         | Full Path of Profile                                     |
|---------------------|--|
| 2004.08.03<br>13:34 | $m_6^s, m_5^s, m_2^s, m_3^s, m_1^s, m_2^s, m_1^p$        |
| 2004.08.07<br>06:37 | $m_5^s, m_1^s, m_6^s, m_2^s, m_3^s, m_2^s$               |
| 2004.08.11<br>13:54 | $m_5^s, m_4^s, m_3^s, m_1^s, m_6^s, m_5^s, m_1^s, m_3^s$ |
| 2004.08.25<br>17:24 | $m_1^s, m_4^s, m_6^s, m_5^s$                             |
| 2004.09.02<br>16:10 | $m_3^s, m_1^s, m_4^s, m_6^s, m_1^s$                      |

$$*M_i = \{m_1, \dots, m_{|M|}\}; \text{ 음악 아이템 집합}$$

$$\text{Transaction } T = \langle m_1^t, m_2^t, \dots, m_i^t \rangle$$

$$\text{where } t = \begin{cases} p, & \text{if } m_i \text{ is purchased} \\ l, & \text{pre-listened} \\ c, & \text{one-clicked} \end{cases} \quad (2.1)$$

음악 다운로드 서비스와 관련하여 사용자 A는 휴대폰 화면에 제시된 음악 리스트 중에서 특정 아이템을 '구매'하거나(purchase, P), 구매하지는 않았지만 '미리듣기'를 해 보거나(pre listen, L), 단순히 관심이 있어서 '클릭'해 보거나(one click, C), '관심 없이 지나치기'(ignore, I) 등의 behavior pattern을 가질 수가 있으며 이러한 behavior pattern 간에는 사용자의 선호도 차이가 존재한다고 가정한다(<표 2> 참조). 즉, 구매한 아이템에 대한 선호도가 가장 높고, 관심 없이 지나친 아이템에 대한 선호도가 가장 낮다 ( $P > L > C > I$ ). 이러한 가정을 근거로 사용자 A의 surfing history에서 중복되는 action을 제거한 뒤 <표 2>에서 정의한 behavior pattern을 근거로 일정기간 동안 사용자 A의 log 정보를 재정의 한 결과는 <표 3>에 나타나 있다.

표 2-사용자의 행동패턴 정의  
Table 2-Definition of behavior pattern

| Symbol | Behavior Pattern |
|--------|------------------|
| P      | 구매(Purchase)     |
| L      | 미리듣기(Pre-Listen) |
| C      | 단순클릭(one-Click)  |
| I      | 관심없음(Ignore)     |

표 3-사용자 A의 사용자 데이터 집합  
Table 3-Customer data set for customer A

| Transaction | $m_1$ | $m_2$ | $m_3$ | $m_4$ | $m_5$ | $m_6$ |
|-------------|-------|-------|-------|-------|-------|-------|
| 1           | P     | L     | L     | I     | I     | C     |
| 2           | L     | P     | L     | I     | C     | C     |
| 3           | L     | I     | P     | C     | L     | L     |
| 4           | C     | I     | I     | L     | P     | C     |
| 5           | L     | I     | C     | L     | I     | L     |

단계 2. 순위 선호도 기반의 고객 프로파일 생성

Step 1. 선호도 순위(Preference Ordering)와 선호 강도 행렬(Preference Intensity Matrix) 생성

위 단계 1의 <표 3>과 같이 한명의 사용자에게 대한 사용자 데이터 집합(user data set)이 완성 되면 이번 단계에서는 이를 바탕으로 협업 필터링(Collaborative Filtering)에서 사용하게 될 순위 선호도 기반의 고객 프로필을 생성하여야 한다. 선호도의 차이(degree of preference)를 반영하여 대상이 되는 아이템들을 선호도 순위(preference order) 기준으로 정렬해 주는 framework에 대한 연구는 Kemey and Snell[5]과 Cook and Kress[2] 등에 의해 이미 제시된 바가 있다. 이들이 제시한 framework은 우리의 연구에도 응용할 수 있는데, 우리가 제시하고 있는  $P > L > C > I$  라는 가정은 아래와 같이 4개의 slot을 가진 선호도 순위(preference ordering) 형태로 표현이 가능하다.

$$S = \begin{bmatrix} P \\ L \\ C \\ I \end{bmatrix}$$

사용자가 구매한 아이템(P)들이 첫 번째 선호 순위를 가지며, 리스트 상에 제시되었지만 사용자에게 의해 무시된 아이템(I)이 선호 순위에서 가장 뒤떨어짐을 표현하고 있다. <표 3>에 나타난 사용자 A의 transaction들도 아래와 같은 형태로 재구성할 수가 있다.

$$S_1 = \begin{bmatrix} m_1 \\ m_2, m_3 \\ m_6 \\ m_4, m_5 \end{bmatrix}, S_2 = \begin{bmatrix} m_2 \\ m_1, m_3 \\ m_5, m_6 \\ m_4 \end{bmatrix}, S_3 = \begin{bmatrix} m_3 \\ m_1, m_5, m_6 \\ m_4, \\ m_2 \end{bmatrix}, S_4 = \begin{bmatrix} m_5 \\ m_4 \\ m_1, m_6 \\ m_2, m_3 \end{bmatrix}, S_5 = \begin{bmatrix} - \\ m_1, m_4, m_6 \\ m_3 \\ m_2, m_5 \end{bmatrix}$$

그림 2-<표 3>에 대한 5개의 선호도 순위  
Fig 2- Five preference orderings for Table 3

위와 같이 구성된 선호도 순위(preference ordering)  $S_i$ 에서 4개의 slot은 사용자의 행동패턴(P, L, C, I) 별 선호도의 차이를 반영하고 있으며 이는 선호 강도 행렬(preference intensity matrix)에 보다 정확하게 표현될 수 있다. 사용자 A의 첫 번째 transaction을 의미하는 Preference ordering  $S_1$ 에 대한 선호 강도 행렬(preference intensity matrix)  $P^{S_1}$ 은 아래와 같다.

표 4- 선호강도행렬의 한 형태,  $P^{S_1}$   
Table 4- Example of preference intensity matrix,  $P^{S_1}$

|       | $m_1$ | $m_2$ | $m_3$ | $m_4$ | $m_5$ | $m_6$ |
|-------|-------|-------|-------|-------|-------|-------|
| $m_1$ | 0     | 1     | 1     | 3     | 3     | 2     |
| $m_2$ | -1    | 0     | 0     | 2     | 2     | 1     |
| $m_3$ | -1    | 0     | 0     | 2     | 2     | 1     |
| $m_4$ | -3    | -2    | -2    | 0     | 0     | -1    |
| $m_5$ | -3    | -2    | -2    | 0     | 0     | -1    |
| $m_6$ | -2    | -1    | -1    | 1     | 1     | 0     |

\* 임의의 preference ordering A에 대해서, 선호 강도 행렬(preference intensity matrix)  $P^A = (p_{ij}^A)$ 는 음악  $m_i$ 이  $m_j$ 에 대해 선호되는 간격 차이만큼을 나타내는  $(p_{ij}^A)$ 로 구성된 행렬(matrix)이다.

Step 2. 최종적 선호 순위(Consensus Ordinal Ranking) 생성

단계 3과 단계 4의 협업 필터링(Collaborative Filtering) 부분에서 사용자 A를 위해 사용될 선호도 프로필을 얻기 위해서는 5개로 구성된 선호 강도 행렬(preference intensity matrix)을 종합적으로 고려하여 이들을 가장 잘 대표할 수 있는 아이템간의 최종 선호도 순위를 계산해야 한다. 5개의 preference intensity matrix  $\{P^i\}_{i=1}^5$  ( $i=5$ )이 존재하는 상황에서 사용자 A의 아이템에 대한 최종적인 선호 순위(consensus ordinal ranking)  $\hat{B}$ 는

$$F(\hat{B}) = \sum_{l=1}^t d(A_l, \hat{B}) = \min_{B \in \beta} \sum_{l=1}^t d(A_l, B) \quad (2.2)$$

where  $d(A, B) = \frac{1}{2} \sum_{i,j} |P_{ij}^A - P_{ij}^B|$ ,  
 $\beta$ : 가능한 모든  $n \times n$  선호강도행렬의 집합

를 의미한다. 이는 최종적인 선호 순위  $\hat{B}$ 가 모든  $\{P^i\}_{i=1}^m$ 에 대해 공통적으로 가장 근접한 거리상에 위치하는 선호 강도 행렬  $\hat{X} = (\hat{x}_{ij})$ 여야 함을 알 수 있으므로 위의 (2.2)식은 아래와 같은 식으로 바꿀 수가 있다.

$$\min \sum_{i < j} \sum_{l=1}^t |p_{ij}^l - x_{ij}| \quad \text{subject to:}$$

$$x_{ik} - \sum_{j=i}^{k-1} x_{j+1} = 0, i=1, \dots, n-2 \text{ and } k=i+2, \dots, n$$

$$1-h \leq x_{ij} \leq h-1, x_{ij} = \text{integer}$$

$$h = \text{preference ordering 의 slot 개수} \quad (2.3)$$

위의 (2.3) 식을 만족시키는 최적의 해(  $x_{ij}^*$  )는 결국 아래와 같다.

$$x_{ij}^* = \text{median} \{p_{ij}^l\}$$

where  $l=1, \dots, t$  and  $i < j$  (2.4)

위의 (2.2)식에서 (2.4)식까지를 활용하여 앞에서 예시된 사용자 A의 최적 선호 강도 행렬(optimal preference intensity matrix) 와 최종적인 선호 순위  $\hat{B}$  는 아래 (표 5)와 식 (2.5)와 같이 구해진다.

표 5-사용자 A의 최적 선호 강도 행렬  
Table 5-Optimal preference intensity matrix for customer A

|       | $m_1$ | $m_2$ | $m_3$ | $m_4$ | $m_5$ | $m_6$ |
|-------|-------|-------|-------|-------|-------|-------|
| $m_1$ | -     | 1     | 1     | 3     | 2     | 2     |
| $m_2$ | -     | -     | 0     | 2     | 0     | 1     |
| $m_3$ | -     | -     | -     | 2     | 1     | 1     |
| $m_4$ | -     | -     | -     | -     | -     | -     |
| $m_5$ | -     | -     | -     | -     | -     | 0     |
| $m_6$ | -     | -     | -     | -     | -     | -     |

$$\text{사용자 A의 최종선호순위 } \hat{B} = \begin{bmatrix} m_1 \\ m_2, m_3 \\ m_5, m_6 \\ m_4 \end{bmatrix} \quad (2.5)$$

결론적으로 사용자 A가 보인 5회의 transaction을 종합해 보면, 사용자 A는  $m_1$  음악에 대한 선호도가 가장 높으며  $m_4$  음악에 대한 선호도가 가장 낮을 것이라는 예측이 가능해진다.

Step 3. 전체 사용자의 프로파일 생성 (Ordinal scale based Customer Profile Generation)

식 (2.5)에서 나타난 사용자 A의 선호도 정보는 다시 아

래  $O_a$  와 같은 sequence로 나타낼 수가 있다.

$$O_a = m_1 \succ m_2, m_3 \succ m_5, m_6 \succ m_4 \dots \dots \dots (2.6)$$

결국 모든 사용자 n명에 대해 위 step 1~step 2를 반복 수행하게 되면 전체 사용자에게 대한 '서열 척도 기반의 고객 프로파일 (Ordinal scale based Customer Profile)인

$D_s = \{O_1, O_2, \dots, O_{|D_s|}\}$  를 얻게 된다. A 이외에 5명의 사용자 (B, C, D, E, F)가 더 있다고 가정할 경우의 고객 프로파일은 아래 (표 6)과 같이 나타낼 수 있다.

표 6-고객 프로파일 DS 의 예  
Table 6-Example of customer profile, DS

|   | $m_1$ | $m_2$ | $m_3$ | $m_4$ | $m_5$ | $m_6$ | $m_7$ | $m_8$ | $m_9$ | $m_{10}$ | $m_{11}$ |
|---|-------|-------|-------|-------|-------|-------|-------|-------|-------|----------|----------|
| A | 1     | 2     | 2     | 4     | 3     | 3     |       |       |       |          |          |
| B | 2     | 2     | 1     | 3     | 2     |       | 1     | 1     |       | 3        | 4        |
| C | 1     | 2     | 3     |       | 1     | 2     | 3     | 1     | 2     |          |          |
| D | 2     | 1     |       | 4     | 3     | 4     |       | 4     | 2     |          | 2        |
| E | 1     | 2     | 3     |       | 3     | 4     | 3     | 2     | 1     |          | 1        |
| F |       | 3     |       | 3     | 2     | 4     |       | 1     | 4     | 1        | 2        |

단계 3. 유사 고객군 식별 (Neighborhood Formation)

이 단계에서는 고객 프로파일(  $D_s$  )상의 유사도(similarity)를 측정하여 목표 고객과 유사한 선호도를 갖는 유사 고객군을 식별해 낸다. 사용자 A와 사용자 B간의 유사도  $\text{sim}(a, b)$ 는 대개 상관관계(correlation) 혹은 코사인 계산법(cosine measure)를 통해 측정된다(9). 이전의 연구(11)에서 상관관계(correlation)를 통한 유사도(similarity) 측정의 우수함이 증명되었기 때문에 본 연구에서도 상관관계를 이용하여 유사도를 측정하되, 서열척도 기반으로 구성된 고객 프로파일을 활용할 수 있는 Nantonac Collaborative Filtering 기법을 활용한다(4).

사용자간 음악 아이템에 대한 선호에 있어서의 유사도 (  $R_{ai}$  )는

$$R_{ab} = \frac{\sum_{m_i \in M_{ab}} (*r(O_a, m_i) - \bar{r}_a)(r(O_b, m_i) - \bar{r}_b)}{\sqrt{\sum_{m_i \in M_{ab}} (r(O_a, m_i) - \bar{r}_a)^2} \sqrt{\sum_{m_i \in M_{ab}} (r(O_b, m_i) - \bar{r}_b)^2}} \quad (2.7)$$

Where  $M_{ab} = M_A \cap M_b$  and

$$\bar{r}_i = |M_{ab}|^{-1} \sum_{m_j \in M_{ab}} (r(O_a, m_j))$$

\*  $r(O_a, m_j)$ :  $j^{\text{th}}$  아이템에 대한 사용자 A의 선호도순위 (예:  $r(O_a, m_3) = 2$ )

와 같이 표현될 수 있다.

위의 같은 상관관계 측정을 통해 어떠한 유사 고객군이 사용자 A를 위한 음악 추천 과정에 활용될 수 있는지가 결정된다. 얼마나 많은 숫자의 유사 고객군(neighborhood)들이 선택이 될 지를 결정하는 데에는 일반적으로 2가지 기법 correlation thresholding과 best n neighbors -이 활용된다[12]. Correlation thresholding 기법은 정해진 threshold 값보다 큰 상관관계 계수 값을 갖는 사용자들을 유사 고객군으로 식별하는 방법이며, best n neighbors 기법은 상관관계가 가장 큰 순서대로 n 명의 사용자를 유사 고객군으로 식별하는 방법을 말한다. 본 연구에서는 best n neighbors 기법을 통해 유사 고객군을 식별한다. <표 6>에 제시된 고객 프로필을 근간으로 할 때, 사용자 A의 유사 고객군을 선별하기 위한  $R_{Ai}$  값은 각각  $R_{AB} = 0.62$ ,  $R_{Ac} = 0.42$ ,  $R_{AD} = 0.79$ ,  $R_{AE} = 0.65$ ,  $R_{AF} = 0.33$  과 같다. 따라서 best n neighbors 기법에서 N의 개수를 3으로 했다면 사용자 A의 유사고객은 사용자 B, D 그리고 E가 된다.

단계 4. 추천 음악 목록 생성

마지막 단계는 사용자 A의 유사 고객군으로부터 top N 추천 음악을 생성해 내는 것이다. 본 연구에서는 목표 고객이 가장 선호할 것으로 예상되는 N개의 음악 목록을 생성하여 추천하게 되며, 사용자의 구매 패턴을 확장하기 위해 이전에 이미 구매했던 음악은 추천 리스트 상에서 제외 한다.

사용자 A의 아이템 j에 대한 예상 선호도는 다음과 같이 계산 된다.

$$\tilde{r}_A + \frac{\sum_{i \in \tilde{M}_j} R_{Ai} \times (r(O_i, m_j) - \bar{r}_i)}{\sum_{i \in \tilde{M}_j} |R_{Ai}|} \quad (2.8)$$

Where  $\tilde{r}_A = |M_A|^{-1} \sum_{m_j \in M_A} r(O_A, m_j)$  and  $\tilde{M}_j = \{i | O_i \in D, s.t. m_j \in M_i\}$

단계 3에서 제시된 3명의 유사 고객군 (B, D, E)의 음악에 대한 선호도 정보를 이용하면 기존 유사 고객군들의 선호도는 있으나 사용자 A는 아직 접해보지 못한 음악들에 대한 예측 선호도 순위인  $\hat{r}_{Aj}$  값을 구할 수가 있다. 그 결과는 각각  $\hat{r}_{A7} = 2.44$ ,  $\hat{r}_{A8} = 2.57$ ,  $\hat{r}_{A9}$

$= 2.38$ ,  $\hat{r}_{A10} = 2.80$  그리고  $\hat{r}_{A11} = 2.62$ 와 같다.

$\hat{r}_{Aj}$ 의 결과 값이 적을수록 사용자 A의 선호도 측면에서 높은 순위를 갖는 음악일 것으로 예상되므로, N을 3으로 할 때 추천 목록  $R = \{m_9, m_7, m_8\}$  과 같은 음악 아이템들이 목표고객인 사용자 A에게 추천된다.

IV. 실험 (Experiment)

1. 실험 설계 (Experimental Design)

본 연구에서 제안한 음악 추천 시스템(MMRS)의 성능을 평가하기 위하여, 실제 모바일 환경에서 실험을 하기 힘든 국내 상황을 고려하여 기존의 휴대폰 기반의 추천 시스템과 동일한 환경(인터페이스, 페이지 반응시간, 음악 재생시간 등)을 갖는 인터넷 기반의 시스템을 구현하여 실험을 수행 하였다. 아울러 본 연구에서 제안된 시스템과의 상대비교를 위한 benchmark 시스템으로서 두 개의 추천 시스템을 더 개발하였는데, Pure CF와 mobile CF 시스템이 그것이다. Pure CF는 사용자의 구매 데이터만을 사용하여 추천 목록을 작성하며, mobile CF는 모바일 웹 마이닝을 적용하여 구매데이터 외에 모바일 로그 상의 행동데이터까지 추천 목록 작성에 사용 하지만, 이를 위한 고객 프로필의 구성은 카디널 척도로 한다는 점에서 본 연구에서 제안하는 MMRS 시스템과 다른 특징을 갖는다. 한편, 실험을 위해서 사용된 음악 컨텐츠의 경우 세 시스템이 공통적으로 국내 대중가요 400여 개의 mp3파일을 사용 하였고, 유사 고객군의 크기에 따라 추천의 품질이 영향 받는 점을 감안하여 세 시스템 모두 유사 고객군의 개수는 10으로 고정 되었다. 실제 웹상에 구현된 MMRS의 화면과 서비스 흐름도는 아래와 같다.

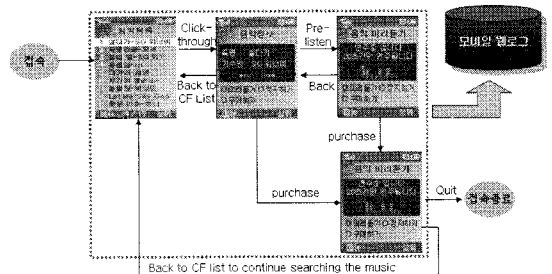


그림 3- MMRS의 시스템 구성도  
Fig 3- Architecture of MMRS

2. 데이터 수집 (Data Collection)

실험은 인터넷 상에서 총 7 주(2007.5.1 - 2007.6.18) 동안 실시간 환경 하에서 실시되었다. 기존의 이동통신 3사의 고객 중에서 음악 콘텐츠 (벨소리, 컬러링, mp3등) 구매 경험이 있는 317명이 실험에 참여 하였다. 최초로 우리는 이들을 세 그룹으로 분류한 뒤 각 그룹을 위에서 언급한 세 가지 시스템 중 한 시스템의 사용자 그룹으로 할당 하였다. 실험기간 동안 이들은 각자의 시스템에 의해서 생성되는 추천 음악 목록만을 받게 되며 해당 시스템 내에서 자유롭게 구매활동 및 음악 감상 등을 하도록 하였다. 이들이 시스템 내에서 보여 준 행동들은 로그아웃을 한 후에 각각의 서버에 자동으로 저장되는 방식으로 데이터가 수집되었으며, 이렇게 저장된 구매 데이터, 모바일 로그 데이터 및 고객 프로필 등은 차후에 그 사용자가 다시 로그인 했을 때 제공될 업데이트 된 추천 목록의 생성에 활용이 되었다. 6주 동안의 실험 종료 후에 데이터베이스에는 총 1791건의 유효한 transaction이 저장되었다.

3. 평가 척도 (Evaluation Metrics)

추천 시스템의 성능 평가에 주로 사용되는 지표에는 precision, recall 그리고 F1 값이 있다 [10, 11]. Precision은 추천된 목록 전체 중에서 실제 구매된 목록의 비율로써 시스템의 정확도라고도 하며, Recall은 구매된 목록 전체 중에서 추천된 목록이 포함된 비율로써 재현율 이라고도 한다. 위 두 가지 지표는 상당히 단순하고 직관적으로도 유용함을 알 수 있으나 둘 간의 관계는 서로 상충되는 면이 있어서 두 지표에 동일한 가중치를 부여하여 계산되는 F1 값까지를 주로 함께 살펴보는 경우가 많다. F1 값은 아래 수식과 같이 계산된다.

$$F1 = \frac{2 \times recall \times precision}{recall + precision} \quad (3.1)$$

본 연구의 실험에서도 이 세 가지 지표들을 이용하여 추천 시스템의 성능을 비교 하였다.

4. 실험결과 및 토의 (Results and Discussions)

4.1. 모바일 웹 마이닝 적용의 효과 검증

모바일 웹 마이닝을 통해 사용자의 선호도 파악을 하는 경우의 추천 품질 개선 정도를 입증하기 위하여 우리는 pure CF와 mobile CF의 평가 결과를 비교 하였다. 결과는 아래

<표 7>에 나타나 있다.

표 7-Pure-CF와 mobile-CF의 성능 비교 결과  
Table 7-Performance comparison between pure-CF and mobile-CF

| System    | Measure   | Periods |       |       |       |       |       |       | t-value |
|-----------|-----------|---------|-------|-------|-------|-------|-------|-------|---------|
|           |           | 1       | 2     | 3     | 4     | 5     | 6     | 7     |         |
| Pure-CF   | Precision | 0.071   | 0.076 | 0.081 | 0.091 | 0.106 | 0.114 | 0.118 | 3.96*   |
|           | Recall    | 0.235   | 0.241 | 0.252 | 0.265 | 0.318 | 0.319 | 0.322 | 16.25*  |
|           | F1        | 0.110   | 0.115 | 0.123 | 0.134 | 0.159 | 0.167 | 0.172 | 5.43*   |
| Mobile-CF | Precision | 0.112   | 0.119 | 0.146 | 0.157 | 0.165 | 0.166 | 0.169 |         |
|           | Recall    | 0.258   | 0.280 | 0.293 | 0.357 | 0.369 | 0.375 | 0.389 |         |
|           | F1        | 0.156   | 0.167 | 0.195 | 0.218 | 0.228 | 0.230 | 0.235 |         |

\* p < 0.01. p is the probability that the null hypothesis is true

위의 <표 7>에 나타난 것과 같이, 7주 (1 period = 1주일) 간의 실험이 진행된 후의 precision, recall, F1 값에 있어서 mobile CF의 결과 (0.118, 0.322, 0.172)가 pure CF의 결과 (0.169, 0.389, 0.235)보다 각각 (43%, 20%, 36%) 더 높으며 또한 T test 결과 p < 0.01 이므로 이 차이는 유의한 것임을 알 수가 있다. 이러한 성능 차이는 본 연구에서 주장하는 바대로 모바일 웹 마이닝을 통한 정확한 사용자 선호도의 파악에서 나오는 것이라고 할 수 있겠다. Mobile CF가 모바일 웹 마이닝 기법을 통해 모바일 로그 등의 추가적인 정보를 선호도 파악에 활용함으로써 고객 프로필이 더 많은 선호도 정보를 반영하게 됨으로써 이후에 유사 고객군의 식별 작업이 보다 정확해지고 결과적으로 추천 시스템의 전반적인 성능 향상에 도움을 주기 때문이다.

4.2. 서열 척도 적용의 효과 검증

사용자의 선호도를 표현하여 저장하는 고객 프로필을 구성함에 있어 서열 척도를 이용하는 경우의 추천 시스템의 성능 개선 정도를 입증하기 위하여 우리는 mobile CF와 MMRS의 평가 결과를 비교 하였다. 두 시스템은 공통적으로 모바일 웹 마이닝을 통해 사용자 선호도를 파악하지만, 그 정보를 표현함에 있어서는 각각 카디널 척도와 서열 척도를 사용하는 차이점이 존재한다. 두 시스템의 성능 역시 precision, recall, F1 값을 통해 비교하였으며 결과는 아래 <표 8>에 나타나 있다.

표 8-Mobile-CF와 MMRS의 성능 비교 결과  
Table 8-Performance comparison between mobile-CF and MMRS



| System    | Measure   | Periods |       |       |       |       |       |       | t-value |
|-----------|-----------|---------|-------|-------|-------|-------|-------|-------|---------|
|           |           | 1       | 2     | 3     | 4     | 5     | 6     | 7     |         |
| Mobile-CF | Precision | 0.112   | 0.119 | 0.146 | 0.157 | 0.165 | 0.166 | 0.169 | 4.19**  |
|           | Recall    | 0.258   | 0.280 | 0.293 | 0.357 | 0.369 | 0.375 | 0.389 | 4.23**  |
|           | F1        | 0.156   | 0.167 | 0.195 | 0.218 | 0.228 | 0.230 | 0.235 | 3.54**  |
| MMRS      | Precision | 0.106   | 0.131 | 0.155 | 0.174 | 0.192 | 0.208 | 0.217 |         |
|           | Recall    | 0.234   | 0.290 | 0.307 | 0.376 | 0.395 | 0.411 | 0.422 |         |
|           | F1        | 0.155   | 0.189 | 0.212 | 0.238 | 0.258 | 0.276 | 0.286 |         |

\*\*p < 0.01 p is the probability that the null hypothesis is true.

위의 <표 8>에 나타난 대로, MMRS의 precision, recall 그리고 F1 값이 실험 기간 전반에 걸쳐 mobile CF에 비해 우수하게 나타남을 알 수가 있다. 7주간의 실험기간이 경과한 후의 결과 값은 mobile CF(0.169, 0.389, 0.235) vs. MMRS(0.217, 0.422, 0.286)이며 MMRS가 각각 28%, 9%, 22%만큼 더 우수함을 볼 수가 있다. 또한 이러한 수치는 T test 결과 p < 0.01 수준에서 유의한 의미를 가지고 있는 것을 알 수가 있다. MMRS가 mobile CF와 비교하여 서열척도를 썼다는 점 이외에 여타 부분에서는 동일한 방법론이므로 이러한 성능상의 개선은 서열 척도의 사용에서 비롯된 것이라고 짐작할 수가 있다. 서열 척도가 implicit rating 환경 하에서 시스템에 의해 예측된 값들 (estimated values)의 분산을 줄이고 나아가 예측 오차(estimation error)를 감소 시켜주기 때문에 MMRS가 추천 품질에 있어 여타의 다른 추천 시스템들보다 우수한 성능평가 결과를 나타내기 때문이다.

서열척도를 사용하는 추천 시스템의 우수성을 다른 측면에서도 검증해 보기 위하여 mobile CF와 MMRS의 pure CF에 대한 performance gain도 측정해 보았다. 그 결과는 아래의 <표 9>에 나타나 있다.

표 9-Mobile-CF와 MMRS의 performance gain 비교 (pure-CF에 대한)

Table 9-Performance gain comparison between mobile-CF and MMRS (about pure-CF)

| Methodology | F1 Score        |                 |                 |                 |                 |                 |                 |
|-------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
|             | Period 1        | Period 2        | Period 3        | Period 4        | Period 5        | Period 6        | Period 7        |
| Mobile-CF   | 0.156<br>(42%)† | 0.167<br>(44%)† | 0.195<br>(58%)† | 0.218<br>(50%)† | 0.228<br>(44%)† | 0.230<br>(38%)† | 0.235<br>(37%)† |
| MMRS        | 0.146<br>(33%)† | 0.181<br>(58%)† | 0.206<br>(68%)† | 0.236<br>(63%)† | 0.258<br>(62%)† | 0.276<br>(65%)† | 0.287<br>(68%)† |

† The performance gain of mobile-CF over pure-CF is (W-C)/C

‡ The performance gain of MMRS over pure-CF(C) is (M-C)/C

• C: F1 of pure-CF, W: F1 of mobile-CF, M: F1 of MMRS

위 <표 9>를 통해 알 수 있듯이, mobile CF와 MMRS의 pure CF에 대한 performance gain은 실험 초기부터 높은 값을 가짐을 볼 수가 있다. 이는 mobile CF와 MMRS가 사용자의 선호도를 파악함에 있어서 공통적으로 구

매 데이터 외에 사용자의 행동정보와 같은 부가적인 선호도 정보까지 사용함으로써 고객 프로필의 내용을 더 풍부하고 정확하게 만들어 주기 때문이다. 그러나 실험 주기가 경과함에 따라 performance gain 값의 증가 비율은 두 방법론이 차이가 난다. Mobile CF가 최종적으로 (pure CF와 비교해서) 37% 정도의 성능향상을 보이는 것에 반해, MMRS는 전 실험 주기에 걸쳐 고루 높은 성능향상을 보일 뿐만 아니라 최종적으로도 66%의 상대적 성능향상을 보이고 있다. 위에서 언급된 바대로 mobile CF와 MMRS의 차이점은 서열척도의 사용 여부에만 있으므로, 모바일 웹 마이닝과 서열척도를 병행하여 사용하는 MMRS는 (본 연구에서 의도한 바와 같이) 간접적으로 선호도를 파악할 수밖에 없는 모바일 환경 하에서의 추천 시스템의 성능을 효과적으로 향상시킨다는 것을 입증하고 있다.

## V. 결론

최근 모바일 음악 다운로드 시장의 성장은 많은 사용자와 많은 음악을 대상으로도 더욱 높은 품질(quality)의 추천을 해 줄 수 있는 효과적인 음악 추천 서비스를 필요로 하고 있다. 그러나 모바일 웹 환경이 가지고 있는 많은 제약 조건들은 효과적인 추천 서비스의 구현을 어렵게 함으로써 CRM 측면에서 기존의 웹에서와 마찬가지로 폭발적인 사용자의 증가를 이루지 못하고 있다. 이에 본 연구에서는 추천 서비스 이용자의 개인적 선호도를 보다 정확하게 반영할 수 있는 Mobile Web Mining과 서열척도 기반의 고객 프로필을 근간으로 하는 모바일 음악 추천 시스템(mobile music recommender system)을 제안 하였다. 또한 모바일 웹 환경을 시뮬레이션 한 실험을 통해 우리가 제안한 방법론이 현존하는 다른 추천 시스템에 비해 성능이 뛰어난임을 입증 하였다.

본 연구는 추천 시스템(recommender system) 관련 연구에 있어서 다음과 같은 의의가 있겠다.

첫째, 모바일 웹 환경에서 사용자 입장에서의 입력을 최소화 하면서도 음악에 대한 개인의 선호도를 효율적으로 반영할 수 있는 추천 시스템을 제시 하였다.

둘째, 모바일 웹 로그를 활용한 Mobile Web Mining 방법론을 제시 하였다.

셋째, 순위 척도(ordinal scale)를 사용한 사용자 선호도 파악의 가능성을 제시 하였다.

그러나 한편으로는, 실험을 통해 우리가 제안한 추천 시스템의 모바일 웹 환경 하에서 우수한 성능을 발휘할 수 있음을

입증하였으나 이러한 결과는 비교적 한정된 콘텐츠와 적은 숫자의 고객, transaction을 대상으로 한 것이다. 따라서 보다 풍부한 콘텐츠와 많은 수의 고객이 있는 실제의 모바일 음악 서비스 사이트를 대상으로 우리가 제안한 시스템을 평가해 보는 작업이 향후 필요할 것이다. 또한, 모바일 네트워크가 개방되어 있지 않은 국내 통신법의 제약을 벗어나서 실제 고객을 대상으로 한 마케팅 캠페인을 펼쳐 보는 것도 의미 있는 향후 연구 방향으로 생각되어 진다.

### 참고문헌

- [1] Claypool, M., Gokhale, A., Miranda, T., Murnikov, P., Netes, D., and Sartin, M. (1999). "Combining content based and collaborative filters in an online newspaper" Proceedings of the ACM SIGIR'99 Workshop on Recommender Systems, Berkeley, CA.
- [2] Cook, W.D. and Kress, M. (1985) "Ordinal Ranking with intensity of preference", Management Science, Vol.31, No.1, pp.26 32.
- [3] Cooley, R., Mobasher, B., and Strivastava, J. (1999). "Data Preparation for mining world wide web browsing patterns", Knowledge and Information Systems, Vol.1, No.1.
- [4] Kamishima, T. (2003) "Nantonac Collaborative Filtering: Recommendation Based on Order Response", SIGKDD 2003, pp.583 588.
- [5] Kemeny, J.G. and L.J.Snell. (1962) "Preference Ranking: An axiomatic approach", Mathematical Models in the Social Sciences", Ginn., New York, pp.9 23.
- [6] Lee, E.Y., and Benbasat, I. (2003). "Interface Design for Mobile Commerce", Communication of the ACM, Vol.46, No.12, pp.49 52.
- [7] Mobahser, B., Dai, H., Luo, T., and Zhu, J. (2000) "Integrating Web usage mining and content mining for more effective personalization", Proceedings of EC Web 2000, pp.165 176.
- [8] Sarwar, B., Karypis, G., Konsta, J., and Riedl, J. (2001). "Item based Collaborative Filtering Recommendation Algorithms", Proceedings of the WWW10 Conference, pp.1 16.
- [9] Sarwar, B., Karypis, G., Konstan, J., and Riedl, J. (2000). "Analysis of recommendation algorithm for e-commerce". Proceedings of ACM E Commerce 2000 conference, pp.158 167.
- [10] Sarwar, B. (2001) "Sparsity, scalability and distribution in recommender systems", PhD thesis, University of Minnesota.
- [11] Breese, J.S., Heckerman, D., and Kadie, C. (1998) "Empirical analysis of predictive algorithms for collaborative filtering" Proceedings of the 14th Conference on Uncertainty in Artificial Intelligence", pp.43 52.
- [12] Herlocker, J., Konstan, J., Borchers, A., and Riedl, J. (1999) "An algorithmic framework for performing collaborative filtering", Proceedings of the Conference on Research and Development in Information Retrieval, pp.230 237.
- [13] Wang, C., Wulf, W.A. (1997) "Towards a framework for security measurement", National Information Systems Security Conference, pp. 522 533.

### 저자소개



이석기

고려대학교 컴퓨터학과 학사  
 KAIST 테크노경영대학원 경영공학 석사  
 KAIST 테크노경영대학원 경영공학  
 박사과정  
 관심분야: CRM, 추천시스템, 데이터  
 마이닝