

개인화 큐레이션을 위한 감성 분류 및 평가

임지희*, 성주원*, 구형근*, 옥철영**, 장두성*

*KT 융합기술원, **울산대학교 컴퓨터정보통신공학과

jihui.im@kt.com, jwsung@kt.com, hk.koo@kt.com, okcy@ulsan.ac.kr, dschang@kt.com

Emotional Tag and Evaluation Method for Personalized Curation

Ji-Hui Im*, Joo-Won Sung*, Hyung-Keun Koo*, Cheol-Young Ock**, Du-Seong Chang*

*Institute of Convergence Technology, KT

**Dept of Computer Engineering and Information Technology, University of Ulsan

요 약

감성은 콘텐츠 구매과정에서 결정적인 요소로 작용하며, 영화 콘텐츠의 탐색/소비 과정에서도 콘텐츠 소비의 새로운 기준이다. 그러므로 본 연구에서는 콘텐츠의 내용과 감성을 반영하기 위한 감성분류체계를 제안하였다. 제안한 감성분류체계를 기반으로 사용자의 취향과 감성에 기반하여 콘텐츠를 분류/추천하여 개인화된 편성을 제공하는 것을 “감성 큐레이션”이라 정의하고, 이를 위한 감성기반 큐레이션 방법론을 기술하고 실험을 통해 추천 효과를 입증하였다. 큐레이션은 기존의 개인화 추천과 달리 고객 취향뿐만이 아닌, 신선함, 다양성을 제공할 수 있어야 하며, 상용 큐레이션 서비스에서는 실제 시청으로 연결되는 비율이 중요하다. 본 연구에서는 큐레이션 성능 평가를 위해 성향인지도, 신선도, 다양성에 기반한 만족도 설문조사 방법과 함께, 콘텐츠의 전체 시청률 대비 큐레이션을 통해 추천되어 증가된 시청률의 확대 비율인 Lift score 라는 새로운 평가 방법을 제안하여 그 효용성을 증명하였다.

주제어: 감성분류, 개인화추천, 큐레이션

1. 서론

감성은, 협의의 의미로는 ‘어떤 현상이나 사건을 접했을 때, 마음에서 일어나는 느낌이나 기분’으로 인간의 내적인 관점에서 발생하며, 감정과 유사한 의미로 사용한다. 그리고 광의의 의미로는 ‘인간의 인식 능력(= 사용자 감성)으로 외부로부터의 감각자극에 대한 반응’이며, 사물의 외적인 측면에서 상호작용을 통해 발생한다. 이러한 감성은 기술의 발전과 더불어 최근에는 구매의 결정적인 요소로 작용하고 있으며, 기업에서는 구매자의 감성에 영향을 미치는 감성 요소를 디자인, 컨셉, 색상, 사용편의성 등의 다양한 측면으로 구축하는 데 주력하고 있다.

영화 관련 검색의 질의어 유형별 비율을 비교하면, 대부분 콘텐츠명이나 인물명으로 검색을 하며, 그 외의 질의 중에서 62%는 장르/소재 등의 일반적인 질의어이며, 38%는 감정/감성/상황/트렌드 질의어이다. 예를 들면, ‘웃긴, 슬픈, 야한, 자극적인, 야릇한, 파격적인’ 등과 같은 (콘텐츠의) 감성 질의어, ‘초등학생이 볼만한 영화, 일요일 밤에 볼만한 영화, 여자친구와 볼만한 영화’ 와 같은 (사용자의) 상황 질의어, ‘외로울 때 볼만한 영화, 심심할 때 볼만한 영화’ 와 같은 (사용자의) 감정 질의어가 있다. 고객이 영화를 탐색 및 소비하는데 있어, 콘텐츠의 명시적인 메타 정보 뿐만 아니라, 콘텐츠 혹은 사용자의 감성이 중요한 요소임을 알 수 있다.

특히, “감성”은 미흡한 콘텐츠 서비스 차별화를 위한 재미 요소를 가미할 뿐만 아니라, 고객이 콘텐츠를 선택하는 새로운 기준으로 작용할 수 있다. 그러나 현재

는 장르/출연자 등과 같은 콘텐츠에 대한 명시적인 메타 정보를 바탕으로 추천 결과를 제공하는 것이 일반적인 서비스 형상이다. 그리고 감성분석결과는 평판분석 시스템(Opinion Mining)에서 주로 긍정/부정 의견을 판별하기 위해 사용되는 수준이며, 감성기반 추천을 제공하기 위한 감성 지식베이스를 구축한 경우는 없다.

“큐레이션(Curation)”은 여러 정보를 수집, 선별하고 이에 새로운 가치를 부여해 공유하는 것으로, 본래 미술 작품이나 예술 작품의 수집과 보존, 전시하는 일을 가리키는 말이었다. 그러나 최근에는 디지털 콘텐츠의 양이 기하급수적으로 증가한 상황에서, 선별된 양질의 정보에 대한 사용자 요구를 충족시키기 위해 “디지털 큐레이션”이라는 개념으로 확장하여 사용하고 있다.

추천 서비스는 개인의 취향을 파악하여 이에 맞는 콘텐츠를 추천하는 단계를 넘어서, 각 개인별로 관심이 있을 만한 테마들로 콘텐츠를 분류하여 매일 제공하는 큐레이션의 형태로 진화하고 있다. 기존의 개인화 추천에서는 개인의 성향에 얼마나 맞게 추천되었는지가 중요하였다면, 큐레이션 서비스에서는 얼마나 다양하고 신선한 편성을 매일 제공할 수 있는가의 여부가 중요하고, 단순히 좋아하는 종류가 아닌, 콘텐츠의 내용이나 감성이 제공되는 서비스의 만족도에 중요한 역할을 한다.

그러므로 본 연구에서는 사용자의 취향과 감성에 기반하여 콘텐츠를 분류/추천하여 개인화된 편성을 제공하는 것을 “감성 큐레이션”이라 정의하고, 개인화 큐레이션 서비스에서 개인의 취향 외에 콘텐츠의 내용과 감성을 반영하기 위한 분류체계를 제안하고, 큐레이션 서비스의 성능 평가 방법을 제안한다.

2장에서는 추천과 큐레이션에 대한 기존 연구를 간략

히 정리하고, 3장에서는 감성분류체계에 대한 정의와 구축방법에 대해 소개한다. 그리고 4장에서는 감성 큐레이션을 위한 추천 방법들을 소개한 다음, 5장에서는 각 추천방식에 대한 평가를 위해 도입한 평가 함수를 소개하고 각 추천 방법에 대해 비교분석한 결과를 보인다

2. 관련 연구

추천 시스템은 사용자가 원하는 정보를 효율적으로 제공하는 시스템으로서, 이를 위한 추천 방법에는 사용자가 선택한 콘텐츠의 속성에 기반한 content-based Filtering 방법, 사용자의 관계 정보에 기반한 collaborative filtering 방법, 인구 통계학적 기법을 근간으로 하여, 사용자의 군집을 형성하고 동일 군집 내의 공통 속성을 추출하여 사용자의 선호정보로 이용하는 demographic filtering 방법, 사용자의 명시적인 입력에 의하여 추천하는 knowledge based 방법으로 나뉜다. 일반적으로 추천시스템은 cold start, data sparseness의 문제 극복과 성능 향상을 위해 여러 추천 기술을 결합하여 적용하고 있다[1][2][3][4].

하지만 이러한 기존 연구들은 개인의 취향에 적합한 콘텐츠를 추천하지만, 다양하고 신선한 추천 결과를 제공하지 못하는 단점이 있다.

반면 디지털 큐레이션은 인터넷에 널린 정보 등을 주제별로, 혹은 관련된 연계성, 연관성을 지닌 무엇인가를 기준으로 분류하여 제공함으로써 개인의 성향 뿐만 아니라 다양하고 신선한 추천결과를 제공할 수 있다. 최근 pinterest라는 소셜 큐레이션 서비스가 미국에서 각광을 받기 시작하면서 전세계로 확산되고 있다[5].

하지만 감성을 기반으로 콘텐츠에 새로운 가치를 부여하고 자동으로 제공하는 큐레이션에 관련된 연구는 아직까지 미비하다.

3. 감성분류체계

감성과 고객의 취향에 기반으로 감성메뉴를 자동으로 편성하여 제공하는 감성기반 맞춤형 큐레이션을 위해, 본 연구에서는 감성분류체계를 정의하고 구축하는 방법에 대해 기술한다.

3.1 감성분류체계 분류기준

본 연구에서는 감성을 관점에 따라 사용자 관점의 감성과 콘텐츠 관점의 감성으로 구분하였다. 사용자 관점의 감성은 콘텐츠와 무관하게 외부적인 요인으로 인해 사용자의 마음에서 일어나는 사용자 감정으로 협의의 “감성”과 유사하다. 콘텐츠 관점의 감성(=콘텐츠 감성)은 영화 시청과 같은 콘텐츠와의 상호작용을 통해 발생하는 사용자 감성으로 광의의 “감성”과 유사하다.

감성분류체계는 생성방법에 따라 고유감성과 사회감성, 테마감성으로 세분화하여 정의하고, 콘텐츠에 감성태그를 부착하고 감성 기반 큐레이션을 위한 기본 재료로 사용한다.

고유 감성은 콘텐츠가 기본적으로 가지는 장르, 카테

고리 등의 메타정보에 의해 생성되고, 사회감성은 콘텐츠가 사용자의 시청 및 구매 등의 상호작용을 통해 생성된다. 마지막으로 테마감성은 사람(사용자/관리자)이 수작업으로 콘텐츠에 새로운 가치를 부여함으로써 인해 생성된다. 사회감성과 테마감성은 콘텐츠와 사용자간의 상호작용으로 인해 생성된다는 공통점이 있으나, 자동/수동의 생성방법에 있어서 차이가 있다. 사회감성은 상품평, 영화평 등의 리뷰문서에서 감성분석을 통해 자동으로 생성되는 반면, 테마감성은 테마명과 관련 콘텐츠 목록 생성과 관련한 일련의 작업이 수동으로 이루어진다.

표 1. 감성분류체계 예제

고유감성
(1) 장르/카테고리 기반 * 웃긴 / 유쾌한 / 즐거운 / 코믹한 ... * 스틸있는 / 긴장감있는 / 박진감 넘치는 ...
(2) 사용자 상황 기반 * 가족이 볼만한 / 아이들과 볼만한 ... * 크리스마스에 볼만한 / 연말에 볼만한 ...
(3)주제어 기반 * 로봇이 나오는 / 싸이코패스가 나오는 * 좀비가 나오는 / 재난을 소재로 한 ...
사회감성
* 스토리라인이 탄탄한 영화 * 교훈적인 내용의 영화 * 잊을 수 없는 음악 영화 * 잔잔한 영상미의 영화 * 소름끼치는 연기력의 영화 * 섬세한 연출이 돋보인 영화
테마감성
* 거친 남자의 감성액션 * 남자를 위한 예능 * 노회경 바람이 분다 * 대결, 명탐정 시리즈 * 만우절 생각나는 영화 * 블록버스터 재난 영화

본 연구에서는 확장 메타 정보에 의해 시스템이 자동으로 생성하는 고유감성, 사회감성 뿐만 아니라, 사람이 수동으로 생성한 누적된 테마감성을 복합적으로 적용한다.

3.2 감성분류체계 구축방법

영화나 다큐멘터리, TV영상 등의 주제나 소재로 많이 사용되어, 영상 콘텐츠를 찾기 위해 많이 사용되는 어휘를 주제어라고 정의하고, 각 콘텐츠의 줄거리 정보에서 해당 콘텐츠의 주제어를 개체명 인식기술을 적용하여 자동 추출하였다. 이와 같이 추출한 주제어와 카테고리/장르 및 규칙을 기반으로 콘텐츠에 고유감성을 태깅하였다.

사회 감성어휘를 추출하기 위해, 20여개의 속성(예: 영상)과 100여개의 각 속성별 표현 어휘(예: 아름다운, 잔잔한, ...)를 정의하였다. 이는 영화의 내용을 표현하기 위해 리뷰 등에서 많이 나오는 어휘를 1차로 수작업

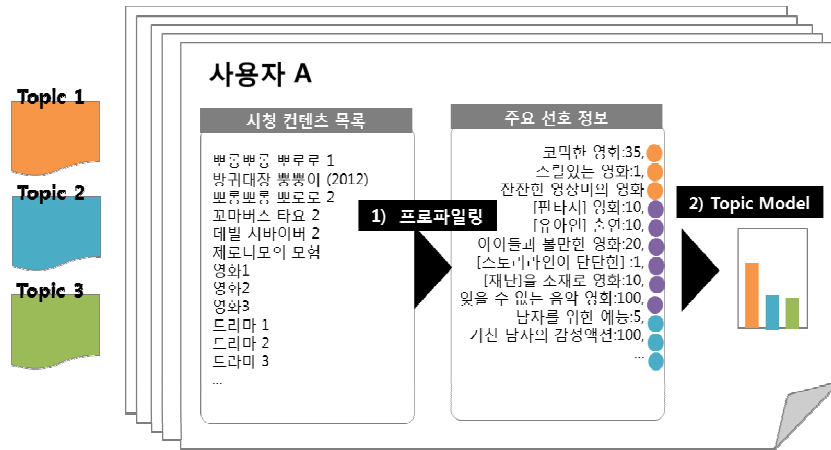


그림 1. LDA 알고리즘을 적용한 선호감성 예측

정의하고, 실제 콘텐츠별 리뷰문장에서 사용되는 어휘 확률(Term frequency)와 이들 어휘가 사용되는 콘텐츠의 수(Document frequency)가 일정치가 넘는 속성-표현 집합을 추출하여 최종 선정하여, 사회감성태그를 각 콘텐츠에 부착하였다.

4. 감성 큐레이션

본 연구에서는 감성 큐레이션을 위한 추천방법들을 비교 분석하였다. 추천방법 중에서 가장 일반적인 CF 기반 연관추천을 baseline으로 삼았으며, 선호하는 장르/인물/주제어 등의 사용자의 성향 분석을 통한 프로파일 기반 추천과 감성분류체계에 의해 태깅된 감성태깅정보를 이용하여 선호할 만한 감성 예측을 통한 추천 방법을 각각 비교하였다.

4.1 CF 기반 연관추천

전통적인 Item-based Collaborative Filtering 방법으로 사용자가 최근 시청했던 콘텐츠의 연관콘텐츠를 추천하는 방법을 baseline방법으로 삼았다. 이때, 콘텐츠 벡터는 해당 콘텐츠를 시청한 사용자 목록으로 구성된 다음, 콘텐츠 벡터 간의 코사인 유사도를 계산하여, 최근 사용자가 시청했던 N개의 콘텐츠의 유사도가 높은 M개의 연관 콘텐츠를 추출하여 추천하였다.

이 방법은 콘텐츠의 메타정보와 관계없이 콘텐츠와 사용자간의 표면적인 관계만을 통해 콘텐츠를 추천함으로써, 가장 간단한 방법인 반면 추천결과에 대한 설득력이 높은 방법이다.

4.2 프로파일 기반 추천

사용자 프로파일링은 설문지나 인터뷰 등을 통해 사용자의 선호정보를 습득한 후 사용자에게 대한 모델을 구축하는 방법과 사용자의 행위에서 유용한 패턴을 발견하여 모델을 구축하는 방법이 있다. 대부분의 추천 시스템은 행위 기반 프로파일링(behavior-based profiling) 기법을 사용하며, 본 연구에서도 시청/구매 등의 정보를 활용하여 행위 기반 프로파일링을 수행하였다.

콘텐츠가 보유한 여러 가지 종류의 정보 중에서 본 연구에서는 콘텐츠의 장르/인물/주제어/제작국가에 대한 정보를 프로파일링하며, 선호정보 i 에 대한 사용자 u 의 선호도 P 는 아래 식으로 계산한다. 이 때, tf 와 idf 는 선호정보의 빈도와 역가중치이며, α 는 선호 행위가 발생한 시간 가중치, β 는 선호정보의 타입별 가중치이다.

$$P_{ui} = \alpha * \beta * tf_i * idf_i \quad (1)$$

본 연구에서는 위 방법으로 구축한 사용자 프로파일을 기반으로 threshold이상의 프로파일을 기반으로 추천하였다.

4.3 감성 기반 예측 추천

LDA(latent Dirichlet Allocation)[7]는 주제가 명시되어 있지 않은 주어진 문서에 대하여 텍스트를 분석하여 각 문서에 어떤 주제들이 존재하는지, 주제를 자동으로 찾아주는 확률적인 모델을 디자인하는 토픽 모델링(Topic Modeling)의 한 방법으로, PSLA의 문제를 보완하면서 현재 가장 많이 사용하는 방법이다. LDA에서 문서 내의 단어들은 사람들이 관찰할 수 있는 변수이며, 이를 바탕으로 토픽의 개수, 문서별 토픽 분포도, 문서 내 단어들의 토픽 할당을 수행한다.

본 연구에서는 이러한 확률 모델을 적용하여 사용자가 선호할 만한 감성을 예측하여 추천한다. 즉, LDA의 개념을 확장하여 문서와 단어를 각각 사용자와 사용자의 감성태그라는 개념을 적용하고, 감성태그집합이라는 토픽을 생성하여 사용자별 토픽 분포도, 사용자의 감성태그별로 토픽 할당을 적용하였다.

그림 2는 이러한 LDA 알고리즘을 적용한 예제이다. 사용자가 시청한 콘텐츠로부터 감성태그에 대한 선호정보를 추출하고, 이 선호정보를 바탕으로 사용자의 감성태그집합에 대한 선호예측점수를 계산한다. 즉, 결과적으로 사용자별로 감성태그 클러스터에 대한 예측점수와 감성태그 클러스터 내의 개별 감성태그에 대한 예측점수를 도출하였다. 이 예측점수를 기반으로 감성메뉴를 추천한

였다. 또한 이러한 감성태그에 대한 예측은 CF (Collaborative Filtering) 방법을 적용하여 수행할 수도 있다.

5. 평가

5.1 평가 기준

기존 추천 시스템의 성능을 평가하기 위해 사용되어온 주요 기준치는 RMSE(Root Mean Squared Error)[8], Mean Absolute Error(MAE)[8], Prec@N[9] 등이 있다.

하지만, 본 연구에서 제안하는 다수의 콘텐츠를 감성에 기반하여 재구성하여, 최소 100여편의 콘텐츠를 한번에 편성하여 제공하는 큐레이션 서비스의 평가 기준으로서 적절하지 않은 부분이 있다. 첫 번째로, 일반적인 개인화 추천에 비하여 많은 수의 콘텐츠를 편성하여 제공하기 때문에, 이 편성된 모든 콘텐츠를 한번에 보기를 원하는 것이 아니므로, 추천된 콘텐츠를 일정 기간에 얼마나 보았는지를 기준으로 하는 평가수치가 적절하지 않다는 점이 있고, 두 번째로, 통상 개인화된 추천시스템이 한 사람의 성향에 얼마나 잘 맞는지를 평가하는 데 반해, 여러 사람이 보는 TV에서 큐레이션을 제공하는 방법은 이들 여러 사람에 대한 다양성을 반영하여야 한다는 점, 세 번째로 상용서비스에서 고객의 취향을 잘 반영하는 것도 중요하지만, 그보다는 고객의 만족도를 높이고 실제 매출로서 연결되는 정도가 더 중요하다는 점 등이다.

본 연구에서는 TV 큐레이션의 만족도를 실제 평가하기 위해 성향인지도, 신선도, 다양성에 기반한 만족도 설문조사[10]를 수행하였을 뿐만 아니라, 실제 매출로서의 반응을 평가하기 위해 Lift Score를 정의하고 이를 측정하였다.

우선 만족도 설문조사에 사용한 지표는 다음과 같다. 성향인지도는 추천 콘텐츠에 대해 개인별 성향을 얼마나 인지하고 있는지를 나타내는 지표이다. 신선도는 개인 성향에서 다소 벗어나지만 얼마나 신선한 자극을 줄 수 있는지를 나타내는 지표이다. 다양성은 추천 콘텐츠가 특정 장르나 소재에 치우침이 없이 얼마나 다양한지를 나타내는 지표이다. 만족도를 평가하기 위해 4명의 설문 대상자에게 100명의 테스트 사용자를 샘플링하여 이들의 시청목록을 관찰한 후 추천 결과에 대해 평가지표별로 1점에서 5점까지 점수를 부여하도록 하였다.

다음으로 큐레이션 결과가 실제 매출로의 연결정도를 측정하는 Lift Score에 대해 정의하고 측정하였다. Lift Score[11]는 연관성 분석에서 사용하는 개념으로, 품목 a가 주어지지 않았을 때의 품목 b의 확률과 대비하여, 품목 a가 주어졌을 때의 품목 b의 확률에 대한 확대 비율로서 향상도라고 한다. 이 값이 1인 경우 두 품목은 서로 독립적인 관계이고, 1이상인 경우 A,B 품목은 서로 양의 상관관계가 있다고 한다.

본 연구에서는 큐레이션과 시청을 각각 a,b라고 정의하면, Lift Score는 특정 콘텐츠가 큐레이션(a)을 하지 않았을 때 시청할(b) 확률과 대비하여, 큐레이션(a)을 하였을 때 시청(b)할 확률에 대한 확대비율이다. 즉 콘텐츠의 전체 시청률 대비 큐레이션을 통해 추천됨으로서 증가되는 시청률의 확대 비율이라고 정의한다. 예를 들

어 Lift Score가 1이상인 경우 큐레이션을 통해 시청률이 증가되었다고 해석할 수 있다.

Lift score는 수식3과 같이 정의한다. watchCount는 콘텐츠A가 추천된 가구에서 큐레이션을 통해 시청된 횟수이며, recomCount는 콘텐츠 A가 추천된 가구수, total WatchRating는 콘텐츠 A의 전체 시청률이다. 즉, Confidence는 콘텐츠를 추천받은 가구 중, 실제 추천을 통해 시청한 비율을 의미하며, Lift score는 Confidence를 전체 시청률로 나눈 수치이다.

$$Confidence_A = \frac{watchCount_A}{recomCount_A} \quad (2)$$

$$LiftScore_A = \frac{Confidence_A}{totalWatchRating_A} \quad (3)$$

5.2 추천 방식에 따른 평가 결과 분석

본 연구에서 감성기반 큐레이션의 방법론에 대해서 만족도 설문조사 결과와 실제 매출로의 반응을 평가하기 위한 Lift score를 비교하였다.

<표2>은 추천 방식에 따른 만족도 설문조사 결과이며, 성향인지도, 신선도, 다양성의 3가지 기준으로 평가하였다. 성향인지도 관점에서는 프로파일 기반 추천방식(PR)이 77.1%로 가장 높았으며, 신선도와 다양성 관점에서 감성 기반 예측 추천방식(ER) 각각 78.4%, 77.1%로 가장 높았다. 결과적으로 평균 점수가 74.7%로 감성기반 예측 추천 방식(ER)이 가장 높은 점수를 받았다.

<표3>은 추천방식에 따른 Lift Score이다. 감성 기반 예측 추천방식(ER)의 Lift Score가 6.20로 가장 높으며, CF기반 연관추천 방식(CR)이 4.27로 가장 낮았다. Lift Score가 6.2라는 말은 추천 받지 않은 사용자에 비해 추천 받은 사용자가 6.2배 더 많이 시청하였다는 의미로 해석할 수 있다.

표 2. 추천 방식에 따른 설문조사 결과

추천방식	성향인지도	신선도	다양성	평균
CR(baseline)	67.9%	72.1%	65.4%	68.4%
PR	77.1%	65.2%	66.2%	69.5%
ER	68.6%	78.4%	77.1%	74.7%

표 3. 추천 방식에 따른 Lift Score

추천방식	Lift Score (average)
CR(baseline)	4.27
PR	4.89
ER	6.20

6. 결론

본 연구에서는 큐레이션 서비스에서 중요한 콘텐츠 감성을 반영하기 위한 감성분류체계를 제안하고 큐레이션 서비스 성능 평가방법을 제안하였다.

사용자의 취향에 맞고 콘텐츠의 내용과 감성을 반영한

다양한 추천 방법을 제공하기 위해, CF기반 연관추천과 프로파일 기반 추천, 제안한 감성분류체계를 기반으로 한 감성기반 예측 추천의 3가지 방법을 비교 분석하였다. 실험 결과 감성 기반 예측 추천 방식이 설문조사 결과 평균 74.7%로 가장 높았으며, Lift Score도 6.20로 매출에 기여도가 가장 높았다.

본 연구를 통해, 감성 기반 예측 추천의 유용성을 증명하였고, 기존 연구가 없었던 큐레이션에 대한 새로운 평가 방법을 제안함으로써 향후 큐레이션 관련 연구에 도움을 줄 수 있을 것이다.

참고문헌

- [1] Hybrid web recommender systems, : Survey and Experiments. Burke, User Modeling and User-Adapted Interaction. 2002.
- [2] Recommender Systems Handbook, Ricci, F.; Rokach, L.; Shapira, B.; Kantor, P.B. (Eds.), Springer, 2011.
- [3] G. Adomavicius and A. Tuzhilin, "Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions", IEEE Trans. Knowl. Data Eng., vol. 17, no. 6, pp. 734-749, Jun. 2005.
- [4] Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. Adomavicius et al., IEEE Transactions on Knowledge and Data Engineering. 2005
- [5] <http://ko.wikipedia.org/wiki/>
- [6] 안영희, "대학도서관 서비스의 디지털 큐레이션 전략", 한국도서관 정보학회, 한국도서관 정보학회지 40(4), 2009.12, 311-326
- [7] David M.Blei, Andrew Y.Ng, Michael I.Jordan, "Latent Dirichlet Allocation," Journal of Machine Learning Research 3, p.93-102, 2003.
- [8] Bennett et al. "The Netflix Prize", KDD Cup and Workshop 2007
- [9] Cremonesi et al., "Performance of recommender algorithms on top-n recommendation tasks", Proceedings of the 4th ACM conference on recommender systems, 2010.
- [10] Pearl. Pu, Li Chen, Rong Hu, "A User-Centric Evaluation Framework for Recommender Systems", Proceedings of the 5th ACM conference on recommender systems, 2011.
- [11] W.-Y. Lin, M.-C. Tseng, and J.-H. Su, "A Confidence-Lift Support Specification for Interesting Associations Mining," Proc. Sixth Pacific-Asia Conf. Advances in Knowledge Discovery and Data Mining (PAKDD), pp. 148-158, 2002.