

# 온라인 쇼핑몰에서 상품 신뢰도를 고려한 개인화 추천 Personalized Recommendation Considering Item Confidence in E-Commerce

최도진\*, 박재열\*, 박수빈\*\*, 임종태\*, 송재오\*\*\*, 북경수\*, 유재수\*  
충북대학교 정보통신공학과\*, 충북대학교 빅데이터협동과정\*\*, (주) 제오시스 기업부설연구소\*\*\*

Do-Jin Choi(mydcj91@cbnu.ac.kr)\*, Jae-Yeol Park(yeols@cbnu.ac.kr)\*,  
Soo-Bin Park(vivapark530@cbnu.ac.kr)\*\*, Jong-Tae Lim(jtlim@cbnu.ac.kr)\*,  
Je-O Song(jos@zeosis.com)\*\*\*, Kyoung-Soo Bok(ksbok@cbnu.ac.kr)\*,  
Jae-Soo Yoo(yjs@cbnu.ac.kr)\*

## 요약

온라인 쇼핑몰의 대중화로 인해 소비자는 폭 넓은 소비의 기회를 제공받고 있다. 소비자들은 온라인 쇼핑몰에서 제공되는 실제 상품을 구매한 사용자의 리뷰, 상품의 자세한 정보와 같은 정보를 활용하여 상품의 구매 여부를 결정한다. 방대한 정보가 신뢰할 수 있는 정보인지는 소비자들이 스스로 판단해야만하기 때문에 객관적이며 신뢰할 수 있는 정보의 제공이 필요하다. 본 논문에서는 신뢰할 수 있는 상품의 추천을 위해서 상품의 신뢰도를 고려한 개인화된 추천 기법을 제안한다. 제안하는 추천 기법은 개인화 추천을 위해서 사용자의 다양한 행위를 기반으로 사용자의 선호도를 판별한다. 또한, 최신의 성향을 반영하기 위해서 시간 가중치를 고려한 사용자 선호도 계산 방법을 제안한다. 마지막으로 사용자가 사용하지 않았던 상품에 대한 선호 점수를 예측하고 예측 점수가 높은 상품 중 신뢰도가 높은 상품들을 추천한다.

■ 중심어 : | 온라인 쇼핑몰 | 상품 신뢰도 | 개인화 추천 | 협업 필터링 | 소셜 네트워크 서비스 |

## Abstract

As online shopping malls continue to grow in popularity, various chances of consumption are provided to customers. Customers decide the purchase by exploiting information provided by shopping malls such as the reviews of actual purchasing users, the detailed information of items, and so on. It is required to provide objective and reliable information because customers have to decide on their own whether the massive information is credible. In this paper, we propose a personalized recommendation method considering an item confidence to recommend reliable items. The proposed method determines user preferences based on various behaviors for personalized recommendation. We also propose an user preference measurement that considers time weights to apply the latest propensity to consume. Finally, we predict the preference score of items that have not been used or purchased before, and we recommend items that have highest scores in terms of both the predicted preference score and the item confidence score.

■ keyword : | Online Shopping Malls | Item Confidence | Personalized Recommendation | Collaborative Filtering | Social Network Service |

\* 본 연구는 2016년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. 2016R1A2B3007527), 2017년도 정부(과학기술정보통신부)의 재원으로 한국연구재단-차세대정보·컴퓨팅기술개발사업의 지원(No. NRF-2017M3C4A7069432), 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구 결과임 (No.NRF-2017S1A5B8059946)

접수일자 : 2019년 01월 11일

심사완료일 : 2019년 02월 18일

수정일자 : 2019년 02월 12일

교신저자 : 유재수, e-mail : yjs@cbnu.ac.kr

## I. 서론

온라인 쇼핑몰 활성화로 인해 소비자는 다양한 품목의 상품을 쉽게 구매하게 되었으며, 판매자 또한 온-오프라인을 통해 제품을 손쉽게 홍보하여 다양한 형태로 이익을 실현하고 있다[1][2]. 온라인 쇼핑몰에서 소비자가 원하는 상품을 구매하기 위해서는 상품 자체의 정보를 확인하거나 다른 소비자들의 구매 평가 정보를 활용한다. 폭 넓은 정보 제공을 통해 소비자들은 상품 구매에 다양한 선택을 할 수 있다. 하지만 반대로 방대한 정보가 신뢰성이 있는 정보인지는 소비자들이 스스로 판단해야만하기 때문에 선택에 대한 확실성을 제공하지 못한다[3-5]. 예를 들어, 상품 정보는 많지만, 구매 리뷰가 거의 없는 상품들은 실제 사용한 소비자들이 거의 없는 경우라고 생각하여 상품 선택에 있어서 구매를 확신하지 못하는 경우가 종종 생긴다. 반대로 어떤 쇼핑몰에서 특정 상품의 구매 리뷰가 많고 좋은 평가를 받은 상품이 실제로는 허위 구매 리뷰를 통해 소비자들이 좋은 상품인 것처럼 민게 만드는 악의적인 정보인 경우도 있다. 이러한 경우를 보면 알 수 있듯이 온라인 쇼핑몰에서 의미 있는 정보를 제공해주기 위해서는 좀 더 객관적이고 평가 가능한 형태의 상품 신뢰도 평가 방법이 필요하다[3][5][6].

온라인 쇼핑몰의 경우 사용자와 직접적인 상호작용이 없기 때문에 제품 광고 및 상품 판매 촉진을 위해 구매 내역, 댓글, 상품 유통 정보 분석을 통해 개인화된 상품 추천 서비스를 제공하고 있다[6-10]. CJ 오쇼핑은 조회한 제품 분류, 제품 정보 조회 수, 상품정보 공유 여부, 질문 등록 수, 최종 결제 가격, 실제 구매 여부 등 쇼핑 과정에서 발생하는 활동 정보와 사용 패턴을 실시간으로 분석해 연관 제품을 추천한다[11]. 아마존은 물건을 구매한 내역을 통해 사용자들의 소비 패턴을 분석하여 상품 추천에 활용한다[12]. 개인화된 상품 추천 방법으로 사용자들의 구매 행동 패턴을 분석하여 유사한 구매 패턴을 가지는 다른 사용자가 구매한 아이템을 해당 사용자에게 추천하는 패턴기반의 추천이 있다. 패턴기반의 추천은 패턴만으로 상품을 추천하기 때문에 실제로 구매할 생각이 없던 새로운 상품을 추천받는 경

우가 생길 수 있다. 또 다른 방법으로는 사용자가 구매한 상품과 사용자의 프로필을 분석하여 성향을 추출하여 성향 기반의 추출을 수행하는 성향 기반 추천이 있다. 성향 기반의 추천을 수행하기 때문에 실제로 좋아할 만한 상품들이 주로 추천되지만 평가하지 않은 상품은 추천 상품으로 생성될 확률이 매우 적어 사용자들은 고정된 상품 목록을 추천받는다고 생각할 수 있다. 기존 마케팅 분석 결과 사용자에게 상품할인 정보에 대해서 DM(Direct Mail)을 발송한 경우와 개인 맞춤형 상품 정보 DM을 발송한 경우를 비교하였을 때 구매 전환율이 10~20% 상승하였다고 한다[13]. 실제로 아마존에서는 상품 간의 유사성을 비교하여 이를 추천에 반영하는 '북 매치' 서비스가 제공되고 있다. 이러한 사례를 보면 알 수 있듯이 온라인 쇼핑몰에서 구매율을 향상하기 위해서는 개인 맞춤 추천 기능이 요구된다.

구매율 향상 및 정확성 개선을 위한 개인화된 상품 추천 기법에 대한 연구가 활발히 진행되고 있다[6-10]. 일부 연구들은 상품 기반의 추천기법으로 상품 간의 유사도 계산을 통해 유사한 사용자가 구매한 상품의 유사한 상품을 추천하는 기법이다. 그러나 상품 기반 추천에서는 한번 계산된 유사도가 변경될 일이 적어 고정된 추천 목록을 생성하는 문제점이 존재한다. 이러한 문제를 해결하기 위해서 평점을 내린 사용자 간의 유사도를 비교하여 다양한 추천 목록을 생성하는 사용자 기반의 추천 기법이 연구되고 있다[9]. 그러나 평점 이력이나 상품 수가 부족한 경우 추천을 할 수 없는 콜드스타트 문제(Cold Start Problem)를 내재하고 있다. 상품 부족의 현상을 해결하기 위해서 앞선 두 가지 추천 기법을 결합한 하이브리드 추천 기법들이 연구되고 있다. 데이터 부족 문제를 일부 해결하였으나 연산의 복잡도는 상대적으로 높아질 수밖에 없는 문제점을 가지고 있다.

본 논문에서는 온라인 쇼핑몰의 경쟁력 확보 및 매출액 증대를 위해 상품 신뢰도를 고려한 개인화 상품 추천 기법을 제안한다. 제안하는 기법은 맞춤형 추천을 위해서 사용자의 소비 패턴을 분석하여 성향을 추출하고 사용자 간의 유사성을 기반으로 사용자가 다음에 소비할 상품을 예측한다. 사용자의 성향은 사용자가 서비스 내에서 행하는 소비 패턴으로 대표되는 행위(평점,

클릭, 찜하기, 리뷰)를 기반으로 추출한다. 또한, 같은 상품에 대한 다중 리뷰 및 행위가 존재할 경우 시간에 따른 가중치를 고려하여 최신 성향에 맞는 상품에 가중치를 부여한다. 마지막으로 실제로 믿을 수 있는 상품 인지를 구별하기 위한 상품의 신뢰도를 SNS(Social Network Service)[6-8] 데이터를 수집하여 계산한다. 계산된 신뢰도는 개인화 추천에 반영한다.

본 논문의 구성은 다음과 같다. 2장에서는 배경 기술에 대해 설명한다. 3장에서는 제안하는 기법의 특징과 처리 방법에 대해 설명하고, 4장에서는 제안하는 기법의 우수성을 입증하기 위해 성능 평가를 수행한다. 마지막으로, 5장에서 본 논문의 결론과 향후 연구를 제시한다.

## II. 관련 연구

기존 추천 기법으로는 협업 필터링 추천과 내용 기반 필터링 추천 기법이 존재한다. 내용 기반 필터링에서는 각 콘텐츠의 메타 정보에서 특성을 추출하여 상품 프로필을 생성하고 사용자가 선호했던 상품에서 자주 나타나는 특성들을 기반으로 사용자 프로필을 생성한다. 생성된 사용자 프로필과 연관된 상품만을 추출하여 사용자에게 추천하는 기법이다[7]. 협업 필터링 추천 기법은 사용자와 유사한 소비 성향을 가진 사용자들을 판별하여, 사용자가 아직 소비하지 않았지만 유사 사용자 군에서 많이 선호하는 상품을 추천하는 기법이다[8-10].

협업 필터링 기법 중 상품의 유사도를 기반으로 추천하는 상품 기반 협업 필터링 추천 기법이 제안되었다[8]. 사용자들은 과거에 구매하였던 아이템과 유사한 상품들을 구매할 확률이 높을 것이라는 가정을 하고 있다. 유사 상품이란 두 개의 서로 다른 상품에 대해서 서로 다른 사용자들이 두 개의 상품을 모두 구매한 경우가 얼마나 많은지에 따라서 많으면 많을수록 유사도의 수치를 높여 유사 상품을 찾는다. 특정한 사용자가 유사도를 비교할 두 개의 상품에 대해 평점을 모두 부여한 경우에만 두 상품 간의 유사도를 계산하는데, 이때, 상품 평점을 바탕으로 코사인 유사도 수식을 통해 상품

의 유사도를 계산한다. 추천에서는 사용자가 해당 상품에 부여할 평점 예측 단계와 랭킹 단계를 거쳐서 랭킹이 높은 순서로 상품을 추천한다. 상품 기반의 추천은 상품 소비 이력에 따라 지속적인 추천이 가능하지만, 유사도 값은 사전에 계산되어서 거의 동일한 상품만을 추천하는 경우가 빈번히 발생한다.

동적인 추천 목록을 생성하기 위해서 사용자 기반 협업 필터링 추천 기법이 제안되었다[9]. 상품 기반 추천과 유사하게 사용자간의 행렬을 만들고 사용자와의 유사도를 계산하여 유사 사용자들이 선호하는 상품을 추천하는 방식이다. 상품 기반 추천과 같이 가중 합을 통해 상품의 점수를 예측하며 추가로 사용자의 평균 평점을 가중 합 결과에 합하여 예측 값을 계산한다. 사용자 기반의 추천은 사용자의 유사도만을 비교하기 때문에 다양한 추천 결과가 생성될 수 있다. 그러나 두 추천 기법 모두 데이터가 부족하거나 사용자의 평점 이력이 부족하면 추천 성능이 저하되는 문제점이 존재한다. 또한 행렬을 만들어서 계산을 수행하기 때문에 데이터가 증가할수록 계산 비용과 메모리 비용이 선형적으로 증가하는 문제점이 존재한다.

데이터의 부족 현상을 해결하기 위해서 아이템 기반과 사용자 기반의 협업 필터링을 결합한 하이브리드 협업 필터링 기법이 제안되었다[10]. 제안하는 기법은 유사 사용자 평점 행렬 SUR(Similar User Ratings)과 유사 상품 평점 행렬 SIR(Similar Item Ratings)를 통해 평점 예측을 수행하고 이를 결합한 SUIR(Similar User Item Ratings)을 생성하여 추가적인 평점 예측을 수행한다. 두 가지의 접근법을 결합하여 많은 수의 상품 평점을 예측할 수 있으며 데이터 부족에 따른 성능 저하 문제를 해결하고 있다.

내용 기반 필터링은 고정된 상품 추천 결과를 주로 생성하고 사용자가 예상치 못한 추천 결과를 생성해 주기 어렵다. 따라서 제안하는 기법은 사용자 기반의 협업 필터링 기법을 수행한다. 사용자 기반의 협업 필터링은 사용자 행위에 대한 유사 사용자 군 기반의 추천을 수행하기 때문에 다양한 추천 결과를 생성해줄 수 있다. 본 논문에서는 Cold Start 문제를 다루지 않지만, 기존 사용자 기반 협업 필터링에서 고려되지 않던 다양

한 사용자 행위와 다중 리뷰에 대한 시간 가중치를 고려한다. 또한, SNS 데이터 기반의 상품 신뢰도를 평가하여 추천 단계에서 신뢰할 수 있는 상품을 추천하는 새로운 접근 방법이다.

### III. 제안하는 개인화 추천 기법

#### 1. 특징

기존 추천에서 추천된 상품이 실제로 신뢰할 수 있는 상품인지 확인하는 단계가 없다. 만약, 특정 집단이 무분별하게 상품 리뷰 점수를 높게 준다면 해당 상품이 추천될 확률이 상승한다. 이러한 문제점을 해결하기 위해서는 상품이 추천의 후보 집합으로 선택할 때 신뢰할 수 있는 상품인지 알 수 있는 신뢰도 값을 추천 단계에 반영한다면 신뢰도가 낮은 상품들은 추천 목록에서 제거될 수 있다. 본 논문에서는 온라인 쇼핑몰에서 상품의 신뢰도를 고려한 개인화 상품 추천 기법을 제안한다. 제안하는 기법은 사용자의 소비 패턴을 분석하여 사용자의 성향을 판별하고 이를 기반으로 추천을 수행한다. 추천은 사용자 기반의 협업 필터링 기법을 활용하고 최종 추천에서는 사용자가 사용하지 않았던 상품을 추천한다. 제안하는 기법은 신뢰성 있는 상품을 추천에 반영하기 위해서 상품별 신뢰도를 측정하는 기법을 제안한다. 상품별 신뢰도는 시간대별로 SNS의 사용자들이 언급한 횟수와 서비스 내의 인기도를 기반으로 계산한다.

[그림 1]은 제안하는 기법의 전체 처리 과정을 나타낸다. 서비스 내에서 사용자의 소비 패턴으로 대표되는 사용자 행위(평점, 클릭, 찜하기, 리뷰)를 기반으로 사용자의 성향을 분석하여 사용자의 행위 가중치를 분석한다. 또한, 단일 상품에 대한 다중 리뷰 상황을 고려하기 위해서 시간 가중치를 고려한다. 분석된 행위 가중치를 바탕으로 사용자 기반의 협업 필터링을 수행하여 상품별 예측 선호도를 생성할 수 있다. 최종 추천에는 SNS의 상품 언급량과 서비스 내의 상품 인기도를 기반으로 측정된 상품 신뢰도 값을 예측 선호도 점수에 반영하여 점수가 높은  $k$ 개를 사용자에게 추천한다. 이때, 만약  $k$

개가 만족하지 않는다면 대중적으로 선호하는 상품들을 추천에 추가하여 추천의 결과를 생성한다.

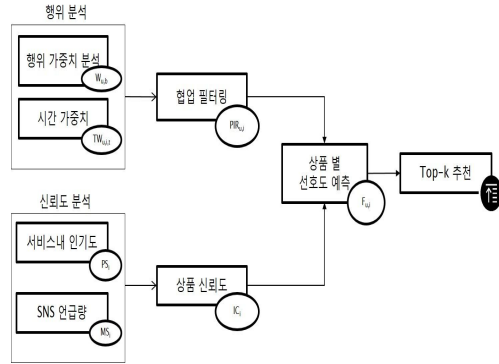


그림 1. 제안하는 기법의 구조도

#### 2. 행위 가중치 분석 및 시간 가중치

사용자 맞춤형 추천을 수행하기 위해서는 먼저 사용자의 성향을 판별하여 성향에 맞는 상품을 알아야 한다. 사용자들은 주로 하는 행위가 서로 다르기 때문에 자신이 주로 한 행위에 대해서는 높은 가중치를 주어야 한다. 예를 들어, 상품에 대한 선호를 평점을 통해 표현하는 사용자도 있는 반면에 클릭을 주로 하는 사용자는 클릭 수에 따라서 상품에 선호도를 표현한다고 볼 수 있다. 제안하는 기법은 사용자의 상품 선호도를 사용자 행위를 기반으로 선호도 값을 계산한다. 상품 선호도를 계산하기 위해서 사용자별로 어떤 행위가 중요한지를 가능하는 행위 가중치를 계산한 후 가중치를 기반으로 상품별 단일 선호도 값으로 계산한다. 제안하는 기법에서는 단일 상품에 대한 다중 리뷰에 대한 행위가 가능하다. 즉, 동일한 상품에 대해서 시간에 따라 다른 선호도 값이 반영될 수 있음을 의미한다. 시간에 따라 변화하는 선호도 값을 반영하기 위해서 시간 가중치를 계산하고 계산된 시간 가중치를 사용하여 상품에 대한 선호도 값을 재계산한다.

행위 가중치를 이용한 상품별 선호도 계산 절차는 [그림 2]와 같다. 사용자들은 서비스 내에서 다양한 행위를 수행한다. 사용자와 상품별로 여러 행위에 대한 값을 테이블 형태로 기록한다. 행위 값은 행위마다 값

의 범위가 다르기 때문에 행위 값을 정규화하고 어떠한 행위를 주로 했는지를 계산하기 위해서 행위별 비율 값을 계산한다. 마지막으로 계산된 비율을 이용하여 행위에 대한 가중치 계산을 수행한다. 계산된 행위 가중치를 바탕으로 최종적인 상품별 선호도 값을 도출한다.



그림 2. 상품 별 선호도 계산 절차

사용자가 상품에 대한 행위를 수행하게 되면 [표 1]과 같이 행위별로 값을 기록한다. USER\_ID, ITEM\_ID, RATING, CLICK\_NUM, IS\_LIKE, STAY\_TIME은 사용자 식별 번호, 상품 식별 번호, 리뷰 점수, 클릭 횟수, 찜하기 여부, 클릭 후 머무른 시간을 나타낸다. 행위를 값으로 변환했을 때 각 행위는 값의 범위가 다르며 심지어 값의 유형마저 다른 경우가 존재한다. 예를 들어, 평점은 0~5점 사이로 표현되고 클릭 수는 최소값이 0이며 최대값은 사용자마다 다르게 정해진다. 찜하기는 찜을 했는지 여부를 기록하기 때문에 다른 행위와 같이 값의 범위가 존재하지는 않는다.

표 1. 상품에 대한 행위 저장 테이블

USER_ID	ITEM_ID	RATING	CLICK_NUM	IS_LIKE	STAY_TIME
234	108	4	10	Y	3600
234	108	3	3	N	600
234	741	1	20	N	400

행위의 가중치를 계산하기 위해서는 동일한 값의 범위로 변환하기 위해서 행위의 값을 정규화 할 필요가 있다. 값의 정규화는 수식 (1)을 통해 계산된다. 정규화 값  $N_{u,i,b}$ 에서 u는 사용자의 식별 번호, i는 상품 식별 번호, b는 사용자가 수행한 행위의 형태이다. 사용자 u가 상품 i에 대한 행위 b에 대한 정규화 값을 의미한다.  $\max_{u,b}$ 와  $\min_{u,b}$ 는 사용자 u가 수행한 행위 b에 대해 최대값과 최소값을 나타낸다. 이는 사용자마다 행위 값의 범위가 다르기 때문에 이를 0~1로 정규화하기 위한 작업이다. 예를 들어, 리뷰 점수에 3~4점만을 주는 사용

자가 있다고 하면 해당 사용자 입장에서는 4점이 가장 만족한 값이라고 보아야 되기 때문에 사용자별 행위 최대, 최소값을 사용한다.  $val_{u,i,b}$ 는 사용자의 행위를 정규화하기 위한 실제 행위 값을 나타낸다. 즉, 사용자 u가 상품 i에 대해 수행한 행위 b에 실제 값이다. 리뷰를 4점을 줬다면 4점이  $val_{u,i,b}$ 에 대입된다. 정규화를 수행하면 모든 행위 값은 [0, 1]로 표현된다.

$$N_{u,i,b} = \frac{val_{u,i,b} - \min_{u,b}}{\max_{u,b} - \min_{u,b}} \quad (1)$$

정규화에 대한 예제는 다음 [표 2]와 같다. [표 1]의 3개의 상품에 대한 행위의 값을 정규화한 값이다. \_ID는 고유 식별 번호로 사용한다. N(r)은 사용자가 상품에 부여한 평점을 정규화한 값으로 [표 1]에서 사용자 234는 상품 108에 대해 4점을 부여하여 이를 정규화한 값  $(4-0)/(5-0) = 4/5$ 인 0.8로 변환되고 이와 같은 방식으로 나머지 값들도 [0, 1]로 표현된다. N(c)와 N(s)는 상품에 대한 클릭 횟수와 클릭 후 머무른 시간을 정규화한 값이다. 두 값은 사용자마다 최대값이 다르기 때문에 사용자별로 별도 최대, 최소값으로 정규화한다.

표 2. 행위 값 정규화 테이블

_ID	N(r)	N(c)	N(s)
1	0.8	0.5	1.0
2	0.6	0.15	0.16
3	0.2	1.0	0.11

행위의 값을 정규화한 후 어떠한 행위를 많이 수행했는지를 계산하기 위해서 행위별 수행 비율을 계산한다. 행위 비율 값은 수식 (2)을 통해 계산 된다. 분모에서 사용되는 n은 행위의 개수이다. 즉, 어떠한 상품 i에 대해서 수행한 행위 b에 대한 정규화 값을 동일 상품 i에 대한 모든 행위 값을 모두 더한 값으로 나누어서 해당 행위 b가 얼마만큼의 가중치를 가지는지를 계산하는 수식이다.

$$P_{u,i,b} = \frac{N_{u,i,b}}{\sum_{j=1}^n N_{u,i,j}} \quad (2)$$

[표 2]의 정규화 값을 비율로 계산하게 되면 [표 3]과 같은 행위 비율 값을 얻을 수 있다.  $\_ID$ 는 고유 식별 번호이며, P(r), P(c), P(s)는 각각 리뷰 점수, 클릭 수, 클릭 후 머무른 수에 대한 행위 비율 값이다. 예를 들어, 1번 P(r)은 1번 N(r) 정규화 값인 0.8을 모든 행위의 정규화 값을 더한(0.8+0.5+1.0) = 2.3으로 나누어 0.34라는 결과 값을 얻게 된다. 나머지 값들도 수식 (2)를 통하여 모든 행위에 대한 비율 값을 계산한다.

표 3. 행위 비율 테이블

$\_ID$	P(r)	P(c)	P(s)
1	0.34	0.21	0.43
2	0.65	0.16	0.17
3	0.15	0.76	0.08

마지막 단계에서는 사용자별로 어떤 행위가 중요한지를 나타내는 행위 가중치를 계산한다. 해당 가중치 값을 통해 상품별 선호도 값을 단일 값으로 계산할 수 있게 된다. 행위 가중치 계산 수식은 수식 (3)과 같다. k는 사용자 u가 평가한 총 상품 개수이다. 행위 b에 대한 비율 값을 평균화한 값이 행위 b에 대한 가중치 값이다. [표 1]에서 총 상품이 3개이기 때문에 k는 3이 된다. 하나의 행위에 대한 비율 값을 평균화한 값이다.

$$W_{u,b} = \frac{1}{k} \sum_{i=1}^k P_{u,i,b} \quad (3)$$

[표 4]는 행위 비율 값을 사용하여 계산한 행위 가중치 값을 나타낸다. U는 사용자의 고유 식별 번호이며 W(r)은 평점 행위에 대한 가중치 값이다. 비율 값인 P(r)의 총합을 계산하고(0.34+0.65+0.15) 이 값을 k인 3으로 나누어 최종적인 평점 행위에 대한 가중치 값을 얻을 수 있다. W(c), W(s), W(l)은 각각 클릭, 클릭 후 머무른 시간, 찜하기의 가중치이다. 찜하기는 불리언 값으로 값을 정규화 및 비율 값을 계산하기 어렵기 때문

에 점한 비율 값을 그대로 사용한다.

표 4. 행위 가중치 테이블

U	W(r)	W(c)	W(s)	W(l)
234	0.38	0.37	0.22	0.33

계산된 행위 가중치를 통해 최종적인 상품별 선호도 값을 계산한다. 상품별 선호도 값은 각 행위에 대한 실제 값과 위의 계산 과정을 통해 얻은 행위 가중치 값을 곱한 모든 값의 합으로 최종적인 상품에 대한 선호도 값이 계산한다. 그러나 여기서 주의할 점은 클릭 횟수나 상품 선호도는 값의 범위가 넓기 때문에 해당 값에 의해 많은 변동이 일어날 수 있어서 값의 영향력을 조절하기 위해서 log 값을 취한다. 상품 선호도 계산의 예제는 [표 5]와 같다. 사용자 234가 상품 108에 대한 선호도 값을 얻기 위해 먼저 기존 행위 (평점, 클릭 수, 머무른 시간, 찜하기)에 대한 값(4, 10, 3600, 1)을 구하고 각 행위별 가중치 값(0.38, 0.37, 0.22, 0.33)을 기존 값에 곱한 후 합(4\*0.38 + log(10)\*0.37 +log(3600)\* 0.22 + 1\*0.33) = 5.37을 하여 최종적인 상품에 대한 선호도 값을 계산한다.

표 5. 성향을 고려한 상품 선호도 테이블

U	I	Preference
234	108	5.37
234	108	3.47
234	741	3.36

제안하는 기법은 시간에 따라 상품에 대한 선호도 변화를 반영하기 위해 시간 가중치를 고려한다. [표 5]에 상품 선호도 값을 보면 동일 상품 108에 대하여 다른 상품 선호도 값을 나타내게 된다. 실제로 해당 상품에 대한 행위는 처음에는 중간 정도의 평점을 부여하였지만, 나중에는 더 높은 평점을 부여한 것을 알 수 있다. 이는 해당 상품이 사용자에게 시간이 지나면서 더욱 더 좋은 느낌을 받게 되어 높은 평점을 부여한 것으로 볼 수 있다. 시간 가중치를 고려한 상품 선호도를 계산하기 위한 수식은 수식 (4)와 같다.

$PR_{u,i,t}$ 은 사용자 u가 상품 i에 대한 행위 가중치를 고

려하여 계산한 선호도 값이며  $t$ 는 시간 값이다.  $t$ 는 시간에 대한 값을 계산하기 위해서 사용되는데 가장 최근의 선호도 값을 계산하기 위해서는 가장 오래된 선호도 값  $PR_{u,i,t-n}$  부터 그 다음 시간의 선호도 값  $PR_{u,i,t-n+1}$  을 고려하여  $TW_{u,i-n+1}$  를 계산하고 이를 최근 시간  $t$ 까지 재귀적으로 계산하게 된다. 계산 방법은 현재 시간  $t$ 의 선호도 값에서 이전 시간  $t-1$ 의 선호도 값과의 차이에 대한 비율 값을 곱하여 최종적인 선호도 값을 계산한다. 예로 들어, 이전 상품 선호도 값이 1.92이고 현재 상품 선호도 값이 3.00이라면  $3.00 * (3.00 / 1.92) = 4.68$  이라는 시간 가중치가 고려된 상품 선호도 값으로 변환된다. 반대로  $1.92 * (1.92 / 3.00) = 1.22$  라는 상품 선호도 값으로 변환된다. 앞서 기술한 것과 같이 동일 상품에 대한 다중 선호도 평가는 해당 상품에 대해 사용자의 성향이 많이 반영되었다는 의미가 내포하기 때문에 선호도 값을 더욱 증폭 시키거나 감소시켜서 사용자의 성향을 뚜렷하게 만든다. 이는 추천에서 사용할 비교 상품을 선택하는 데 많은 도움이 된다.

$$TW_{u,i,t} = PR_{u,i,t} * \frac{PR_{u,i,t}}{PR_{u,i,t-1}} \quad (4)$$

### 3. 상품 신뢰도

추천 후보 집합에 포함되는 상품들은 상품 자체에 대한 신뢰도가 반영되지 않았다. 신뢰도는 실제로 그 상품이 믿을만한 상품인지에 대한 값으로 상품의 만족도에 영향을 받는다. SNS에서 자주 언급되는 상품들은 실제로 사용자들이 선호하는 확률이 높고 이는 믿을만한 상품임을 의미한다고 볼 수 있다. 제안하는 기법에서는 상품의 신뢰도를 측정하기 위해 SNS 데이터를 수집하여 해당 상품이 자주 언급되는 상품인지를 판단하여 신뢰도 계산에 반영한다. 또한, 서비스 내에서도 찜을 많이 한 상품, 클릭하고 머무른 횟수가 많거나, 평균적으로 평점이 높은 상품이라면 해당 상품 또한 높은 관심을 가지며 신뢰할만한 증거를 가진다고 볼 수 있는 상품이라고 판단하여 신뢰도 점수에 이를 반영한다.

[그림 3]은 상품에 대한 신뢰도 판별 과정을 나타낸

다. 먼저, SNS 데이터를 수집하고 수집된 데이터에서 저장되어있는 상품 정보와 관련된 정보들만을 추출하고, 상품과 관련된 문서들만을 이용하여 상품별 TF-IDF[14]를 계산한다. TF-IDF 계산에서는 상품명 을 기반으로 단어 사전을 구축하고 해당 단어들만을 계산한다. 계산된 TF-IDF를  $MS_i$  라고 지칭하며 이는 SNS의 언급량이다. 서비스 내의 인기도를 계산하기 위해서 각 상품마다 찜하기 수, 머무른 횟수, 평균 평점 값을 가지고 서비스 내의 인기도 값인  $PS_i$  값을 계산한다. 마지막으로 SNS 언급량인  $MS_i$ 와 서비스내의 인기도를 나타내는  $PS_i$  값을 합산하여 최종적인 상품에 대한 신뢰도 점수  $IC_i$ 를 계산하게 된다. 상품 신뢰도 점수가 높은 상품일수록 추천 상품의 상위 결과에 포함될 확률이 높아진다.

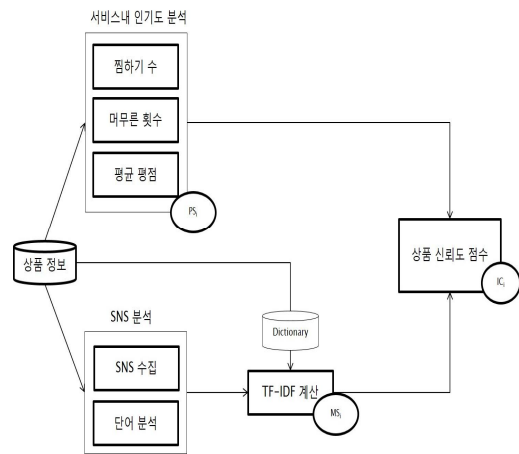


그림 3. 상품 신뢰도 판별 과정

상품 신뢰도는 앞서 기술한 것과 같이 서비스 내의 인기도와 SNS에서의 언급량을 가지고 계산한다. 먼저 서비스 내의 인기도는 수식 (5)을 통해 계산한다.  $LIKE_i$ 는 상품  $i$ 에 대한 사용자들의 찜하기 총 횟수이며  $STAY_i$ 는 상품  $i$ 에 대한 클릭 후 일정시간 머무른 총 횟수이다. 본 논문에서는 시간을 10초 이상에서 5분까지를 횟수에 반영하였다.  $AR_i$ 은 상품  $i$ 에 대한 평균 평점이다. SNS에서의 언급량은 수식 (6)을 통해 계산한다. 이때,  $i$ 는 특정 상품을 나타내며 TF-IDF는 불리언 기

반의 TF를 사용하여 단어 출현 빈도가 높더라도 1 값을 가짐으로써 높은 값이 나오지 않게 조절하였다. SNS는 네이버[15]의 블로그, 카페, 지식인을 통해 수집하였으며 추후 연구를 통해 트위터[16], 페이스북[17]으로 확장할 예정이다. 최종적으로 계산되는 상품 신뢰도  $IC_i$ 는 수식 (7)의 가중치  $\alpha$ 를 통해 서비스 내의 인기도와 SNS 언급량의 기여도를 조절한다.

$$PS_i = (LIKE_i + STAY_i) * AR_i \quad (5)$$

$$MS_i = TFIDF_i \quad (6)$$

$$IC_i = \alpha PS_i + (1-\alpha)MS_i \quad (7)$$

#### 4. 상품 추천

추천을 수행하기 위해서는 추천 목록 후보를 생성하고 추천 목록 내에서 어느 것을 먼저 추천할 것인지에 대한 랭킹을 수행해야 한다. [그림 4]는 상품 추천의 전체 동작 과정을 나타낸다. 사용자 행위 가중치 및 시간 가중치를 고려한 상품의 선호도 값을 이용하여 사용자와 상품 간의 선호도 값을 이용하여 행렬을 생성한다. 생성된 행렬을 이용하여 추천 대상의 사용자와 유사한 상품 선호도를 가진 사용자들을 코사인 유사도를 통해 추출한다. 유사 사용자군의 상품 선호도 값을 기반으로 선호도 값이 없는 상품에 대한 예측 값을 생성하고 예측 값이 높은 순으로 k의 두 배수만큼 추출한다. 생성된 상품 목록에 앞서 계산한 상품 신뢰도 값을 반영하여 값이 높은 Top-k개를 추출하여 최종적인 추천 목록을 생성하여 해당 사용자에게 제공한다.

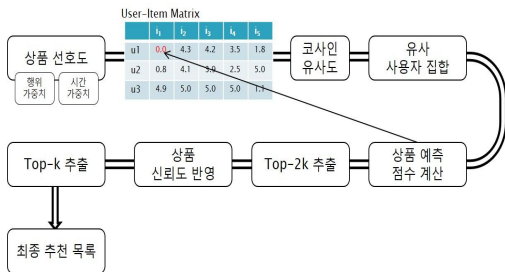


그림 4. 상품 추천 과정

선호도 예측을 수행하기 전에 유사 사용자 군을 도출

하기 위한 기준 상품들이 필요하다. 모든 상품의 선호도를 바탕으로 사용자 간의 유사도를 계산하는 것은 많은 비용이 소모된다. 따라서 제안하는 기법은 사용자 간의 유사도를 계산하기 위해서 사용자의 가장 높은 선호도 상품 n개와 가장 낮은 선호도 상품 m개와 최근 성향을 반영하기 위해서 최근에 평점을 부여한 상품 o개를 기준 상품으로 선택한다. 예를 들어, n, m, o가 각각 3이라면 최소 3개에서 최대 9개까지의 기준 상품을 기반으로 사용자 간의 유사도를 계산한다. 유사도 계산은 코사인 유사도 수식을 통해 유사도 값을 계산한다.

사용자가 선호할만한 상품을 추천하기 위해서는 상품별 예측 선호도 값을 계산해야 한다. 본 논문에서는 도출된 유사 사용자 군을 기반으로 수식 (8)을 통해 상품 선호도를 예측한다. 예측된 선호도 값이 클수록 해당 사용자에게 추천될 확률이 높아진다.  $PIR_{u,i}$ 는 사용자 u가 상품 i에 대해 어느 정도 선호할지를 예측한 값이다. 수식에서  $\bar{r}_u$ 는 사용자 u의 평균 선호도를 나타내며  $SIM_{u,u'}$ 은 사용자 u와 u'간의 유사도 수치이다. 즉, 사용자의 평균 선호도 값에서 유사 사용자들의 평균 선호도를 뺀 후 해당 사용자와의 유사도를 곱하고 모든 유사도 수치를 합하여 나눈 값이 상품의 선호도 예측 값이 된다.

$$PIR_{u,i} = \bar{r}_u + \frac{\sum_{u' \in N} (SIM_{u,u'}) (TW_{u',i} - \bar{r}_{u'})}{\sum_{u' \in N} |SIM_{u,u'}|} \quad (8)$$

[그림 5]는 유사도를 기반으로 상품 예측 선호도를 계산하는 예제를 나타낸다. 사용자 U1이 상품 Item2에 대해 예측 선호도를 계산하기 위해 유사 사용자 그룹을 추출한다. 예제에서는 유사 사용자 그룹을 U2 단일 사용자로 가정하였으며, 이때, U1과 U2의 유사도는 0.84이다. Item2의 예측 점수를 계산하기 위해서 U1의 평균 선호도 값을 계산하고(2.74) U2의 평균 선호도 값을 (2.6) 계산한다. 마지막으로 수식 (8)을 통해 U2가 Item2에 대한 선호도(0.1)에 U2의 평균 선호도(2.6)를 뺀 값에서 U2와의 유사도 값(0.84)을 곱한 값이 분자가 된다(0.84\*(0.1-2.6)) = -2.1. 분모는 유사 사용자 군의



유사도 합인데 유사 사용자는 U2 한 명이므로 0.84 값을 사용한다. 수식을 통해  $-2.1/0.84 = -2.5$ 라는 값이 나오게 되고 U1의 평균 선호도(2.74)에 값을 더하게 되면 Item2에 대해 0.24라는 최종 예측 값이 도출된다. 유사 사용자 U2가 Item2에 대해 계산된 선호도는 0.1로 낮은 수치이며 예측 값 또한 0.24로 이와 유사하게 낮은 수치로 나오는 것을 알 수 있다.

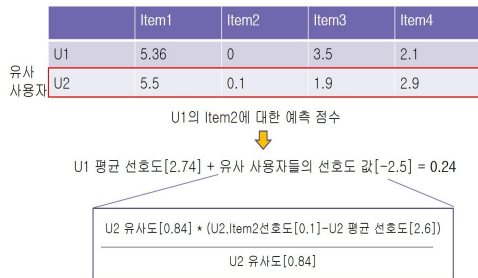


그림 5. 유사도 기반 상품 예측 점수 계산

추천 상품을 사용자에게 제공하기 위해서는 최종적인 랭킹이 필요하다. 본 논문에서는 앞서 계산한 예측된 상품 선호도 값에 상품의 신뢰도 값을 반영하여 높은 값부터 차례대로 사용자에게 정해진 개수인 k개를 추천한다. 랭킹 값을 계산하기 위해 수식 (9)와 같은 방법으로 계산한다.  $PIR_{u,i}$ 는 앞에서 계산한 사용자 u가 아직 접해보지 않은 상품 i에 대한 예측 값이며  $IC_i$ 는 상품 i에 대한 신뢰도 값이다. 즉, 상품 신뢰도 값과 예측 평점의 합으로 최종적인 랭킹을 위한 예측 값이다. 가중치  $\beta$ 의 조절을 통해 신뢰도 및 예측 선호도 점수의 반영 정도를 조절한다.

$$F_{u,i} = \beta PIR_{u,i} + (1 - \beta) IC_i \quad (9)$$

#### IV. 성능 평가

성능 평가에서는 실제 상품 1,237개에 대해 222명의 사용자의 행위 (찜하기, 클릭, 클릭 후 머무른 시간, 리뷰) 26,460개를 사용한다. 해당 데이터 셋은 모바일 온라인 쇼핑몰을 운영하는 A업체에서 제공받았으며, 개

인 정보 보호를 위해 추천 결과에서 사용자는 사용자  $1^n$ 으로 표현한다. 상품 신뢰도를 계산하기 위해서 서비스 내의 인기도와 SNS 언급량의 기여도인 가중치  $\alpha$ 는 0.5로 정하였으며, 최종 추천을 위해서 사용되는 신뢰도 및 예측 선호도 점수의 반영 비율인 가중치  $\beta$  또한 0.5로 설정하였다. 시간 가중치가 고려된 사용자 성향을 반영하기 위해서 사용자가 명시적으로 수행한 리뷰 행위를 기준으로 동일 상품에 대한 다음 리뷰 이전의 행위 (찜하기, 클릭, 클릭 후 머무른 시간)들은 이전 선호도에 영향을 주지 않는다. 즉 선호도가 부여되는 시점은 리뷰 행위를 한 시점, 마지막 리뷰가 존재하지 않는다면 선호도를 분석한 시점에 선호도가 부여된다. 성능 평가는 대중성만을 고려한 추천 기법과 코사인 유사도 기반의 협업 필터링 기법과 제안하는 기법과의 추천 결과를 비교한다. 성능 평가는 전체 행위 데이터에서 80%를 학습용으로 사용하고 나머지 행위 20%를 정답 데이터로 사용한다. 우수성을 평가하기 위해서 총 추천 개수에서 클릭한 상품의 개수를 계산하는 CTR(Click Through Rate)[18]을 계산한다. [표 6]은 성능 평가 환경을 나타낸다.

표 6. 성능 평가 환경

파라미터	값
사용자 행위	26,460개
사용자	222명
아이템	1,237개
가중치 ( $\alpha, \beta$ )	0.5, 0.5

[그림 6]은 추천 기법 및 사용자에 따른 추천 클릭 비율 결과이다. 성능 평가에서는 총 10명의 사용자를 선별하였고 적극적인 사용자 40%와 무작위 사용자 60%를 선별하였다. 적극적인 사용자는 사용자  $1^4$ 이며 그 외는 무작위로 선별된 사용자이다. 대중성을 고려한 추천 기법은 리뷰 점수를 기준으로 대중적으로 많은 사용자들이 사용했던 상품을 추천하는 기법이다. 단, 개인화 추천을 위해서 사용자가 사용했던 상품들은 추천 순위에서 제외된다. 유사 사용자 추천 기법은 제안하는 기법의 선호도 점수 계산 방법을 적용한 후 선호도 기반

의 코사인 유사도를 측정한다. 측정된 코사인 유사도 기반으로 식 (8)을 이용하여 상품의 예측 점수를 계산하여 예측 점수가 높은 순으로 추천하는 기법이다. 마지막으로 제안하는 기법은 유사성 기법에서 상품의 신뢰도 점수를 반영하여 추천하는 기법이다. 추천 결과 제안하는 기법은 적극적인 사용자와 무작위로 선별된 사용자 모두 가장 좋은 성능을 보이고 있다. 사용자 8은 다른 사용자 보다 행위 정보가 10% 가량 적은 사용자이다. 정답 데이터가 비교적 적은 사용자인기 때문에 CTR 값이 상대적으로 낮게 평가되었다.




그림 6. 추천 기법 및 사용자에 따른 CTR

[그림 7]은 추천 기법에 따른 평균 추천 클릭 비율 결과이다. 앞선 성능 평가 결과와 동일하게 제안하는 기법이 제일 우수한 결과를 보이며 평균 16% 정도의 성능을 보이고 있다. 대중성 결과는 10%, 유사 평가 결과는 약 6% 가량의 성능을 나타내고 있다. 제안하는 기법은 사용자의 특성에 상관없이 기존 기법 대비 60%~235% 가량의 뛰어난 성능을 보임으로써 제안하는 기법의 타당성을 입증하였다.




그림 7. 추천 기법에 따른 평균 CTR

## V. 결론 및 향후 연구

본 논문에서는 상품 신뢰도를 고려한 개인화 상품 추천 기법을 제안하였다. 제안하는 기법은 맞춤형 추천을 위해서 사용자의 행위를 분석하여 선호도를 계산하였고, 선호도 기반의 사용자 유사도를 바탕으로 사용자가 사용하지 않았던 상품의 예측 선호도를 계산하였다. 선호도를 분석하기 위해서 평점, 클릭, 찜하기, 리뷰와 같은 행위를 분석하였으며 동일한 상품에 대한 다중 리뷰 행위를 반영하기 위해서 시간 가중치가 고려된 선호도 계산 방법을 제안하였다. 신뢰성 있는 상품 추천을 수행하기 위해서 SNS 데이터와 서비스 내의 데이터를 활용하여 상품 신뢰도를 계산하는 방법을 제안하였다. 마지막으로, 사용자의 최근 선호도와 상품의 신뢰도 값을 반영한 개인화된 추천 결과를 생성하여 사용자에게 제공하였다. 성능 평가를 통해 제안하는 기법이 기존 기법보다 우수한 성능을 보임을 입증하였다. 본 연구의 한계점은 실제 응용 데이터의 부재에 따라 제안하는 기법의 유효성을 입증하기 어려움에 있다. 또한, 실제 응용에서 SNS 데이터 수집에 비용적인 문제로 인해서 바로 적용하기가 힘든 문제점이 있다. SNS에서의 단어 빈도만으로는 신뢰성을 입증하기가 어렵다는 문제점 또한 존재한다. 향후 연구로는 대중적으로 사용되는 평가 데이터 집합인 MovieLens 데이터 집합의 성능 평가를 통해 실제 응용 적용 가능성을 입증하고 다른 접근 방법을 통해 신뢰도를 조금 더 객관적으로 평가할 수 있는 방법을 제시할 예정이다. 또한, 기계 학습 기술을 적용하여 본 기법에서 사용되는 파라미터(유사 사용자 수,  $\alpha$ ,  $\beta$ , 행위, 시간 가중치)의 최적 값을 찾아 낼 예정이다.

## 참 고 문 헌


- [1] R. A. Lewis and D. H. Reiley, "Online ads and offline sales: measuring the effect of retail advertising via a controlled experiment on Yahoo!," Quantitative Marketing and

- Economics, Vol.12, No.3, pp.235-266, 2014.
- [2] I. M. Dinner, H. J. Van Heerde, and S. A. Neslin, "Driving online and offline sales: The cross-channel effects of traditional, online display, and paid search advertising," *Journal of Marketing Research*, Vol.51, No.5, pp.527-545, 2014.
- [3] B. J. Corbitt, T. Thanasankit, and H. Yi, "Trust and e-commerce: a study of consumer perceptions," *Electronic commerce research and applications*, Vol.2, No.3, pp.203-215, 2003.
- [4] A. Parasuraman, V. A. Zeithaml, and L. L. Berry, "Servqual: A multiple-item scale for measuring consumer perc," *Journal of retailing*, Vol.64, No.1, pp.12-31, 1988.
- [5] B. Palese and A. Usai, "The relative importance of service quality dimensions in e-commerce experiences," *International Journal of Information Management*, Vol.40, pp.132-140, 2018.
- [6] R. Abdelkhalak, I. Boukhris, and Z. Elouedi, "Assessing items reliability for collaborative filtering within the belief function framework," *Proc. International Conference on Digital Economy*, pp.208-217, 2017.
- [7] S. Huang, Y. Chen, H. Chen, L. Chen, and Y. Fan, "Personalized item-of-interest recommendation on storage constrained smartphone based on word embedding quantization," *Proc. Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pp.610-621, 2018.
- [8] Y. Jiang, J. Liu, M. Tang, and X. Liu, "An effective web service recommendation method based on personalized collaborative filtering," *Proc. International Conference on In Web Services*, pp.211-218, 2011.
- [9] T. Ha and S. Lee, "Item-network-based collaborative filtering: A personalized recommendation method based on a user's item network," *Information Processing and Management*, Vol.53, No.5, pp.1171-1184, 2017.
- [10] T. Ebesu and Y. Fang, "Neural Semantic Personalized Ranking for item cold-start recommendation," *Information Retrieval Journal*, Vol.20, No.2, pp.109-131, 2017.
- [11] <http://display.cjmall.com>, 2018. 2. 7.
- [12] <https://www.amazon.com>, 2018. 2. 7.
- [13] 이문철, 양정원, "리테일 마케팅 4.0: 더 오래 더 많이 팔리는 마케팅 실전 가이드," 21세기 북스, 2017.
- [14] R. Baeza-Yates and B. Ribeiro-Neto, *Modern information retrieval*, ACM press, 1999.
- [15] <https://www.naver.com>, 2018. 2. 7.
- [16] <https://twitter.com>, 2018. 2. 7.
- [17] <https://www.facebook.com>, 2018. 2. 7.
- [18] J. Beel, M. Genzmehr, S. Langer, A. Nürnberger, and B. Gipp, "A comparative analysis of offline and online evaluations and discussion of research paper recommender system evaluation," *Proc. International workshop on reproducibility and replication in recommender systems evaluation*, pp.7-14, 2013.

#### 저자 소개

최도진(Do-Jin Choi)

정회원



- 2014년 2월 : 한국교통대학교 컴퓨터공학과(공학사)
- 2016년 2월 : 한국교통대학교 컴퓨터공학과(공학석사)
- 2016년 3월 ~ 현재 : 충북대학교 정보통신공학과 박사과정

<관심분야> : 연속 질의 처리, 그래프 스트림

박 재 열(Jae-Yeol Park)

정회원



- 2014년 2월 : 충북대학교 정보통신공학과(공학사)
- 2016년 2월 : 충북대학교 정보통신공학과(공학석사)
- 2016년 3월 ~ 현재 : 충북대학교 정보통신공학과 박사과정

<관심분야> : 데이터베이스, RDF, 빅데이터

박 수 빈(Soo-Bin Park)

준회원



- 2018년 2월 : 한남대학교 산업경영공학과, 컴퓨터공학과(공학사)
- 2018년 3월 ~ 현재 : 충북대학교 빅데이터협동과정 석사과정

<관심분야> : 빅데이터, 분산 처리, 소셜 네트워크

임 중 태(Jong-Tae Lim)

정회원



- 2009년 2월 : 충북대학교 정보통신공학과(공학사)
- 2011년 2월 : 충북대학교 정보통신공학과(공학석사)
- 2015년 8월 : 충북대학교 정보통신공학과(공학박사)

▪ 2015년 9월 ~ 현재 : 충북대학교 정보통신공학과 박사후연구원 (Post.doc)

<관심분야> : 시공간 데이터베이스 시스템, 이동 객체 질의 처리, 위치기반 서비스, P2P 네트워크

송 재 오(Je-O Song)

종신회원



- 2005년 2월 : 서원대학교 정보통신공학과(공학사)
- 2015년 2월 : 한국교통대학교 컴퓨터정보학과(공학석사)
- 2015년 3월 ~ 현재 : 충북대학교 정보통신공학과 빅데이터협동과정 박사과정

<관심분야> : 빅데이터 기반 비즈니스 솔루션, 스마트 팩토리 플랫폼

북 경 수(Kyoung-Soo Bok)

종신회원



- 1998년 2월 : 충북대학교 수학과(이학사)
- 2000년 2월 : 충북대학교 정보통신공학과(공학석사)
- 2005년 8월 : 충북대학교 정보통신공학과(공학박사)

▪ 2005년 3월 ~ 2008년 2월 : 한국과학기술원 정보전자연구소 Postdoc

▪ 2008년 3월 ~ 2011년 2월 : 가인정보기술 연구소 연구원

▪ 2011년 3월 ~ 현재 : 충북대학교 전자정보대학 정보통신공학부 초빙교수

<관심분야> : 데이터베이스 시스템, 이동 객체 데이터베이스, 이동 P2P 네트워크, 소셜 네트워크 서비스, 빅데이터 처리

유 재 수(Jae-Soo Yoo)

종신회원



- 1989년 2월 : 전북대학교 컴퓨터공학과(공학사)
- 1991년 2월 : 한국과학기술원 전산학과(공학석사)
- 1995년 2월 : 한국과학기술원 전산학과(공학박사)

▪ 1995년 2월 ~ 1996년 8월 : 목포대학교 전산통계학과 전임강사

▪ 1996년 8월 ~ 현재 : 충북대학교 전자정보대학 정교수

<관심분야> : 데이터베이스 시스템, 멀티미디어 데이터베이스, 센서 네트워크, 바이오 인포메틱스, 빅데이터