

협업 필터링과 빈발 패턴을 이용한 개인화된 그룹 추천

김 정 우*, 박 광 현^o

Personalized Group Recommendation Using Collaborative Filtering and Frequent Pattern

Jung Woo Kim*, Kwang-Hyun Park^o

요 약

본 논문에서는 개인화 서비스를 제공하기 위해 책, 음악, 영화 등과 같이 단일 항목을 추천하는 기존 방법의 한계를 극복하고, 패션, 요리 등과 같이 연관성에 따른 항목의 조합, 즉 그룹을 추천하는 방법을 다룬다. 협업 필터링은 사용자 간의 유사도를 측정하여 비슷한 성향의 사용자들이 선택한 항목을 추천하는 방법이며, 사용자의 성향을 예측할 수 있다는 장점이 있다. 본 논문에서는 이러한 협업 필터링과 연관 규칙을 바탕으로 빈발 항목 집합을 생성하고, 그룹 간의 유사도에 따라 그룹을 추천하는 알고리즘을 제안한다. 제안하는 방법의 타당성을 검증하기 위하여 의류 전자상거래에서 4개월 동안 소비자가 구매한 목록 데이터로 실험을 수행하였다.

Key Words : Collaborative, filtering, association rule, frequent pattern, group recommendation, similarity

ABSTRACT

This paper deals with a method to recommend the combination of items as a group according to similarity to handle application area such as fashion and cooking, while the previous methods recommend single item such as a book, music or movie. Collaborative filtering is a method to recommend an item selected by users with similar tendency based on similarity between users. In this paper, the proposed method generates a set of frequent items based on collaborative filtering and association rules and recommends a group by similarity between groups. To show the validity of the proposed method, experiments are performed with purchase data collected from e-commerce for four months.

I. 서 론

최근 인터넷과 스마트폰, 사회 관계망 서비스(SNS)의 발전으로 사용자가 접하는 정보의 양이 급격하게 증가하고 있으며, 필요한 정보를 획득하기 위한 시간과 노력 또한 증가하고 있다. 이에 따라 원하는 정보를 쉽고 빠르게 찾을 수 있도록 지원하는 개인화된 추천 시스템에 대한 관심이 높아지고 있다^{1,2)}. 최근에는 다양한 산업에서 사용자의 행동과 패턴을 이

해하고^{3,4)} 이를 활용한 자동화된 개인화 서비스를 적극적으로 도입하고 있는데, 사용자의 선호 내용 및 평점, 후기 등과 같은 다양한 선호도 정보를 수집하여 새로운 상품을 추천하는 데 활용한다⁵⁾.

추천 시스템은 사용자의 상품 구매 정보를 분석하여 비슷한 성향의 다른 사용자들이 선택한 상품을 추천하거나 예측하는 시스템을 말한다. 협업 필터링(Collaborative Filtering)은 추천 시스템에 가장 많이 사용되는 알고리즘으로서 다양한 기업의 온라인 사이

* First Author : Mapssi, Co., Ltd., kjw1801@nate.com, 정희원

^o Corresponding Author : Kwangwoon University School of Robotics, akaii@kw.ac.kr, 정희원

논문번호: KICS2016-06-135, Received June 29, 2016; Revised July 5, 2016; Accepted July 6, 2016

트에 적용되고 있다. 이러한 기존의 방법은 단일 항목을 추천하는 방법이기 때문에 패션이나 요리와 같이 항목의 조합, 즉 그룹을 추천해야 하는 경우에는 한계가 있다. 그룹을 추천하기 위해서는 다음과 같은 사항이 고려되어야 한다. 첫째, 항목 간의 연관성을 찾아야 한다. 둘째, 연관성만으로는 개인의 성향이나 유행에 따른 변동을 능동적으로 적용하기 어렵기 때문에 기존의 전문적인 콘텐츠 그룹을 연관 규칙을 통해 유사도를 판별하여야 한다.

본 논문에서는 그룹을 추천할 때 발생하는 기존 방법의 문제점들을 보완하고, 성능을 향상시키기 위한 대안으로 유사도 기반의 그룹 추천 알고리즘을 제안한다. 연관 규칙(Association Rule)을 통해 사용자들의 빈발 항목 집합을 찾고 사용자와 빈발 항목 집합 간의 유사도를 계산한다. 유사한 빈발 항목 집합과 협업 필터링 예측 값을 바탕으로 추천 목록을 생성한다.

본 논문의 구성은 다음과 같다. 제 II장에서는 기존의 추천 방법을 소개하고 한계와 문제점을 고찰한다. 제 III장에서는 기존 방법들의 한계를 극복하기 위하여 그룹 추천 방법을 제안한다. 제 IV장에서는 추천 평가 지표에 따른 실험을 통해 제안한 그룹 추천 방법의 타당성을 검증하고, 제 V장에서 결론을 맺는다.

II. 기존의 연구 방법

2.1 협업 필터링

협업 필터링(Collaborative Filtering)은 제록스(Xerox)의 팔로알토 연구소에서 개발한 태피스트리(Tapestry) 시스템에서 처음 사용되었으며⁶⁾, 각 항목에 대한 사용자의 선호도가 시간에 따라 변하지 않는다는 가정을 바탕으로 유사도를 측정하여 항목을 추천하는 방법이다. 예를 들어 영화를 추천하는 경우, 사용자가 과거에 관람한 영화들에 대해 입력한 선호도를 바탕으로 새로 출시되는 영화들에 대한 사용자의 선호도를 예측한다.

협업 필터링은 사용자 기반의 협업 필터링과 항목 기반의 협업 필터링, 크게 두 가지 방법으로 나눌 수 있다. 사용자 기반의 협업 필터링은 각 항목에 대해 사용자들이 입력한 선호도를 바탕으로 사용자들 간의 유사도를 측정한다. 선호도가 유사한 다른 사용자들이 입력한 항목별 선호도를 기반으로 특정 사용자가 선호할 만한 항목을 추천하는 방법이다. 비슷한 취향을 가진 사용자들에게 아직 구매하지 않은 상품들을 교차 추천하거나 사용자의 취향 및 생활 형태에 따라 관련 상품을 추천하는 서비스에 사용된다⁷⁾. 사용자들이

입력한 선호도 데이터가 많은 경우에는 다른 방법에 비해 상대적으로 정확한 예측을 한다는 장점이 있다.

항목 기반의 협업 필터링은 사용자가 선호도를 입력한 항목들과 추천 대상이 되는 항목 간의 유사도를 계산하여 사용자가 어떤 항목을 더 선호할지를 예측하여 추천하는 방법이다. 항목들 간의 유사도를 계산하기 위해 두 항목 모두 선호도를 입력한 사용자들의 선호도를 사용한다. 이 때, 사용자들 간의 유사도를 고려하지 않기 때문에 두 항목 모두 선호도를 입력한 사용자들이 특정 사용자와 항목별 선호도가 다른 경우에는 상관관계의 정확도가 떨어진다는 한계가 있다⁸⁾.

협업 필터링은 사용자들의 항목 별 선호도를 조사하고 수치화하여 입력 데이터를 구성하고, 다른 사용자들과의 유사도를 계산하며, 유사한 사용자를 바탕으로 예측 값을 계산하여 추천 목록을 생성하는 단계로 이루어진다. 협업 필터링의 주요 단계는 다음과 같다.

- 1) 데이터 구성 : 사용자가 입력한 선호도를 사용하여 사용자-항목 선호도 행렬을 만든다.
- 2) 유사도 계산 : 1 단계에서 만들어진 행렬을 사용하여 사용자들 간의 유사도를 계산한다.
- 3) 예측 값 계산 및 추천 목록 생성 : 사용자들 간의 유사도를 바탕으로 모든 항목에 대해 예측 값을 계산하고 높은 예측 값을 갖는 상위 N개의 추천 목록을 생성한다.

협업 필터링에서 사용자들 간의 유사도를 측정하는 방법은 추천 성능을 좌우하는 중요한 요소이다. 유사도를 계산하기 위한 측정 지수로는 코사인(Cosine), 유클리드 거리(Euclidean Distance), 피어슨 상관 계수(Pearson Correlation Coefficient), 자카드 계수(Jaccard Coefficient) 등이 있는데, 본 논문에서는 자카드 계수를 사용하였다.

자카드 계수는 범주 속성을 갖는 두 객체 간의 유사성을 파악하기 위해 많이 사용되며 식 (1)과 같이 계산할 수 있다.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (1)$$

여기서 $|A \cap B|$ 는 사용자 A와 사용자 B가 모두 선호도를 입력한 항목의 개수를 나타내며, $|A \cup B|$ 는 사용자 A와 사용자 B 중 한 명이라도 선호도를 입력한 항목의 개수를 나타낸다.

사용자들 간의 유사도를 바탕으로 식 (2)와 같이 사

용자 a 의 항목 i 에 대한 선호도 예측 값 $p_{a,i}$ 를 계산하고⁹⁾ 추천 목록을 생성한다.

$$p_{a,i} = \bar{r}_a + \frac{\sum_{j=1}^n (r_{j,i} - \bar{r}_j) w_{a,j}}{\sum_{j=1}^n w_{a,j}} \quad (2)$$

여기서 \bar{r}_a 는 사용자 a 가 입력한 선호도의 평균값, \bar{r}_j 는 사용자 j 가 입력한 선호도의 평균값이다. $r_{j,i}$ 는 사용자 j 가 항목 i 에 대해 입력한 실제 선호도 값이며, $w_{a,j}$ 는 사용자 a 와 사용자 j 간의 유사도를 나타낸다.

협업 필터링을 사용하여 추천한 후에는 추천 성능을 평가하는 과정이 중요하는데, 본 논문에서는 추천 평가 지표를 사용하여 성능을 측정하였다¹⁰⁾. 상위 N 개를 추천하는 형태로 만들어진 추천 목록을 평가하기 위한 지표로는 정밀도(Precision)와 재현율(Recall), F-measure 등이 있다. 정밀도는 추천 시스템이 생성한 추천 목록의 항목 중에서 대상 사용자가 선호하는 항목의 비율로서, 식 (3)과 같이 계산할 수 있다.

$$\frac{TP}{TP+FP} \quad (3)$$

여기서 TP(True Positive)는 추천된 항목이 사용자가 선호하는 항목인 개수를 나타내고, FP(False Positive)는 추천된 항목이 사용자가 선호하지 않는 항목인 개수를 나타낸다. FN(False Negative)은 추천되지 않았지만 사용자가 선호하는 항목인 개수를 나타내며 TN(True Negative)은 추천되지 않은 아이템이 사용자가 선호하지 않는 항목인 개수를 나타낸다.

재현율은 사용자의 선호도와 추천 시스템의 추천이 일치하는 항목이 추천 목록에 속하는 비율로서, 식 (4)와 같이 계산할 수 있다.

$$\frac{TP}{TP+FN} \quad (4)$$

일반적으로 정밀도와 재현율은 추천 목록의 개수에 따라 달라지며 서로 반비례하는 경향이 있다. 따라서 본 논문에서는 정밀도와 재현율을 동시에 고려하는 F-measure를 계산하여 추천 성능 지표로 사용하였다. F-measure는 식 (5)와 같이 계산된다.

$$F\text{-measure} = \frac{TP + TP}{TP+FP+TP+FN} = \frac{2 \times TP}{2 \times TP+FN+FP} \quad (5)$$

2.2 연관 규칙

협업 필터링은 추천 시스템에서 가장 많이 사용되는 기법이며 연구가 활발히 진행되고 있지만 몇 가지 단점이 있다. 책, 음악, 영화 등과 같이 단일 아이템을 추천하는 경우와는 달리 패션, 요리 등과 같이 항목의 조합, 즉 그룹을 추천해야 하는 경우에는 다양한 속성을 체계적으로 분류하기 어렵고 둘 이상의 항목 간의 상호 관련성을 찾기에는 어려움이 있다. 이를 보완하기 위해 데이터 마이닝(Data Mining)의 하나인 연관 규칙을 사용한다.

연관 규칙(Association Rule)은 하나의 거래나 사건에 포함된 서비스 간의 관계를 살펴보고 이로부터 유용한 규칙을 찾아내고자 할 때 이용할 수 있는 데이터 마이닝 기법이다. 주로 함께 구매하는 항목의 조합이나 서비스 패턴을 발견하거나 특정 제품 또는 사건들이 동시에 발생하는 패턴을 파악하는 데 이용된다. 또한, 동시에 구매될 가능성이 큰 상품들을 찾아냄으로써 장바구니 분석(Market Basket Analysis)에서 다루는 문제들에 적용된다.

데이터를 통해 얻어지는 모든 연관성이 의미 있다고 말하기가 곤란하기 때문에 결과 해석에 앞서 연관성의 내용이 일반화할 수 있는 내용인가를 판단할 수 있도록 각 연관성 규칙을 비교할 수 있는 기준이 필요하다. 연관성 규칙을 측정하는 방법으로는 지지도(Support), 신뢰도(Confidence), 리프트(Lift)가 있다. 본 논문에서는 사용자가 선호하는 항목 간의 연관성을 찾기 위해 지지도를 사용하였다.

지지도는 의미 있는 연관성의 여부를 판단하기 위해 관련이 있다고 판단되는 항목들을 포함하는 거래를 살펴봐야 한다. 전체 거래 중에서 항목 X와 항목 Y를 동시에 포함하는 거래가 어느 정도인지를 측정하며 식 (6)과 같이 계산할 수 있다.

$$P(X \cap Y) = \frac{\text{항목 X와 항목 Y를 동시에 포함하는 거래수}}{\text{전체 거래수}(N)} \quad (6)$$

사용자의 항목 구매 명세를 바탕으로 전체 거래 데이터에서 2개 이상의 항목이 얼마나 같이 빈발하게 발생하는지의 확률 값을 사용자와 빈발 항목 집합 간의 유사도 계산에 사용한다.

III. 그룹 추천 시스템

본 논문에서는 기존의 협업 필터링을 확장하여 그룹을 추천하는 방법을 제안한다. 단일 항목을 추천하는 방법보다 좀 더 개인에게 적합한 그룹을 추천하기 위해 빈발 패턴과 그룹 간의 유사도를 고려한 추천 방법을 제안한다.

제안하는 방법은 전체 사용자에게 대한 각 항목별 선호도 행렬에서 빈발 패턴을 생성하는 단계, 빈발 패턴과 협업 필터링 예측 값을 바탕으로 사용자와 패턴, 그룹 유사도를 계산하는 단계, 유사도를 바탕으로 예측 값을 계산하고 그룹 추천 목록을 생성하는 단계로 구성된다. 빈발 패턴을 생성하는 단계에서는 기존의 선형적(Apriori) 알고리즘을 사용하여 최소 지지도를 만족하는 빈발 항목을 추출한다. 유사도를 계산하는 단계에서는 기존의 협업 필터링에서 사용자의 항목별 선호도만 이용한 것과는 달리 협업 필터링 방법을 확장하여 사용자와 그룹 간의 유사도를 계산하는 방법을 제안한다. 그룹 추천 목록을 생성하는 단계에서는 계산된 유사도를 바탕으로 그룹에 대한 사용자의 선호도를 계산하는 방법을 제안한다.

3.1 빈발 패턴 생성

사용자의 항목 선호도를 고려하여 연관성을 찾기 위해 선형적 알고리즘을 이용하여 빈발하게 발생하는 항목 집합으로 패턴을 찾는다. 생성된 항목 집합만으로는 정확한 패턴이 생성되지 않기 때문에 중복되는 속성을 제거한다.

선형적 알고리즘은 빈발 항목 집합을 찾는 대표적인 알고리즘이다. 후보 항목 집합을 생성할 때 모든 데이터 항목을 대상으로 생성하는 것이 아니라, 전 단계의 빈발 항목 집합을 대상으로 후보 항목을 구성한다. 여기서 빈발 항목 집합은 항목 집합 X의 지지도가 사용자가 지정한 최소 지지도 이상인 모든 X의 집합이며, 빈발 항목은 빈발 항목 집합의 원소이다. k-빈발 항목 집합은 k개의 원소로 구성된 빈발 항목 집합이며 L_k 로 표시한다. 후보 항목 집합은 빈발 항목 집합의 원소가 될 가능성이 있는 항목들로 구성된 집합으로, 빈발 항목 집합을 구성하기 위해 사용되는 집합이다. k-후보 항목 집합은 k개의 원소로 구성된 후보 항목 집합을 말하며 C_k 로 표시한다.

선형적 알고리즘은 단계마다 후보 항목을 생성하고, 생성된 후보 항목에 대해 최소 지지도를 만족하는 빈발 항목을 추출하는 방법이라고 할 수 있다. 우선, 항목 집합 전체에 대해 지지도를 계산하고 빈발 항목

집합을 찾는다. L_{k-1} 로부터 후보 집합 C_k 를 생성하고, C_k 의 각 부분 집합에 대해 모든 거래를 조사하여 지지도를 계산하고 최소지지도를 넘지 못하는 후보를 제거한다. 더 이상 L_k 를 생성할 수 없을 때까지 이러한 과정을 반복한다^[11].

3.2 유사도 측정

기존의 협업 필터링에서는 사용자들 간의 유사도를 계산할 때 사용자의 항목별 선호도만 이용하는 경우가 많았다. 본 논문에서는 그룹을 추천하기 위해 빈발 패턴을 바탕으로 사용자와 패턴 간의 유사도를 계산하고, 패턴의 유사도를 바탕으로 사용자와 그룹 간의 유사도를 계산하였다. 그림 1은 패턴의 유사도를 계산하기 위한 알고리즘을 나타낸 것이다.

빈발 패턴 항목을 사용자가 선호도를 입력하였으면

<p>Algorithm 1 CalcPatternSimilarity(F, s, R, U)</p> <p>Input: F: A set of frequent pattern items s: Support of F R: A set of predictive values of collaborative filtering U: A set of items evaluated by a user</p> <p>Output: pattern similarity</p> <pre> 1: sim ← 0 2: for all i ∈ F do 3: if i ∈ U then 4: sim ← sim + 1 5: else 6: sim ← sim + R_i 7: end if 8: end for 9: return s × (sim / F)</pre>

그림 1. 패턴 유사도를 계산하기 위한 알고리즘
 Fig. 1. Algorithm for pattern similarity

<p>Algorithm 2 CalcGroupSimilarity(G, F, s)</p> <p>Input: G: A set of group items F: A set of frequent pattern items s: Pattern similarity of F</p> <p>Output: group similarity</p> <pre> 1: sim ← 0 2: for all i ∈ G do 3: if i ∈ F then 4: sim ← sim + (s / G) 5: end if 6: end for 7: return sim</pre>
--

그림 2. 그룹 유사도를 계산하기 위한 알고리즘
 Fig. 2. Algorithm for group similarity

1을 더하고, 그렇지 않으면 협업 필터링 예측 값을 더한 후 전체 패턴의 개수로 나누어서 패턴 유사도를 계산한다.

패턴 유사도를 계산한 후에는 그룹 유사도를 계산한다. 그림 2는 그룹 유사도를 계산하는 알고리즘이다.

그룹 항목 집합의 항목이 패턴 항목 집합에 있으면 패턴 유사도 값을 그룹 항목 집합의 크기만큼 나누어서 더한다.

3.3 그룹 예측 값 계산 및 추천 목록 생성

대상 사용자의 패턴 유사도와 그룹 유사도를 계산한 후 그룹 추천 목록을 생성한다. 그림 3은 그룹 예측 값을 계산하는 알고리즘이다.

그룹을 추천하기 위해 먼저 예측 값을 계산한다. 그룹 항목 집합에 있는 항목을 사용자가 선호도를 입력하였으면 그룹 유사도 값을 더하고, 아니면 협업 필터링 예측 값과 그룹 유사도 값을 곱하여 더한다. 이러한 과정을 통해 대상 사용자의 그룹에 대한 선호도 예측 값을 계산할 수 있고, 예측 값이 높은 그룹으로 추천 그룹 목록을 생성한다.

Algorithm 3 CalcPredictiveValue(G, s, R, U)
Input: G: A set of group items s: Group similarity of G R: A set of predictive values of collaborative filtering U: A set of items evaluated by a user
Output: predictive value of group recommendation
<pre> 1: t ← 0 2: for all i ∈ G do 3: if i ∈ U then 4: t ← t + s 5: else 6: t ← t + (R_i × s) 7: end if 8: end for 9: return t </pre>

그림 3. 그룹 추천 예측 값 계산을 위한 알고리즘
Fig. 3. Algorithm for predictive value of group recommendation

IV. 실험 결과

본 논문에서 제안한 그룹 추천 시스템의 성능을 측정하고, 항목 선호도만 이용한 기존 추천 방식과 비교하기 위해 실제 전자 상거래에서 수집된 상품 선호도 정보와 패션 전문가들이 선정한 그룹 항목 집합을 사용하여 실험하였다.

4.1 실험 데이터 수집

본 논문에서는 국내 의류 전자상거래를 서비스하는 스마트폰 애플리케이션을 통해 데이터를 수집하였다. 4개월 동안 사용자들이 선호하는 상품 항목을 수집하고, 총 248명의 사용자로부터 19,105개의 선호도 데이터를 수집하였다. 1명당 최소 35개 이상의 선호도를 입력하였으며 항목의 개수는 3,284개로 항목 속성별로 분류하여 수집하였다. 패션 전문가들이 선정한 항목 집합, 즉 그룹 데이터는 2,883개 수집하였다.

4.2 실험 결과

그룹 추천 시스템의 성능을 측정하기 위해 수집된 데이터를 학습 데이터와 평가 데이터로 나누어 실험하였다. 평가 데이터는 사용자가 선호도를 입력한 데이터 중에서 20%를 무작위로 추출하여 구성하였다. 평가 데이터를 제외한 나머지 80%를 학습 데이터로 사용하였다. 사용자들의 선호도 데이터를 이용하여 사용자와 패턴 간의 유사도를 계산하였다. 유사도를 가중치로 추천 목록을 생성하고, 추천 평가 지표를 사용하여 추천 결과를 비교하였다.

실험에서 사용된 패턴은 최소 지지도(Minimum Support) 10%로 데이터의 개수는 1,356개이다. F-measure는 추천 성능 평가지표로 값이 클수록 추천 성능이 좋다는 것을 의미한다. 전체 사용자 248명의 평균 F-measure 값을 측정하였고 표 1과 같이 빈발 패턴을 이용한 추천 성능이 기존 유사도만 이용한 협업 필터링의 성능보다 약 0.025 정도 향상되었음을 알 수 있다.

그룹 유사도를 계산한 후 유사도를 가중치로 추천 목록을 생성하고 테스트 데이터와 추천 평가 지표를 사용하여 추천 결과를 비교하였다. 전체 사용자 248명의 평균 F-measure 값을 측정하고 표 1과 같이 기존 방법과 빈발 패턴만 이용한 방법, 그룹 추천을 각각 비교하였다. 그룹 추천 성능이 협업 필터링의 성능보다 약 0.056 정도 향상되었고 빈발 패턴만을 이용한 추천 성능보다 약 0.03 정도 향상되었음을 알 수 있다.

표 1. 추천 성능 평가
Table 1. Recommended performance evaluation

method	F-measure
Collaborative filtering	0.0977
Frequent pattern	0.12366
Group recommendation	0.15435

V. 결 론

본 논문에서는 사용자와 그룹 간의 유사도를 분석하여 정확도를 높이기 위한 그룹 추천 시스템을 제안하였다. 사용자들 간의 선호도 데이터를 바탕으로 빈발 패턴을 생성하고, 사용자와 패턴 간의 유사도를 계산하였다. 사용자와 그룹 간의 유사도를 판별할 수 있었고, 유사도가 높은 그룹을 사용자에게 추천함으로써 전체 정확도를 높일 수 있었다.

추천의 정확도를 비교 분석하여 기존 성능보다는 그룹 추천 시스템이 우수하다는 결과를 보였지만, 그룹 데이터와 사용자 데이터의 양이 많아질수록 추천 성능이 좋아지기 때문에 좀 더 많은 사용자 데이터를 활용하여 실험한다면 기존보다 더 좋은 결과를 얻을 수 있을 것이다.

향후 연구로는 실제 전자상거래 시장에서 실제 데이터를 활용하여 그룹 추천 시스템의 성능을 평가하고, 검증을 통해 실제 효과와 개선 방향에 대한 연구가 필요하다.

References

[1] M. D. Ekstrand, J. T. Riedl, and J. A. Konstan, "Collaborative filtering recommender systems," *Foundations and Trends in Human-Computer Interaction*, vol. 4, no. 2, pp. 81-173, 2010.

[2] J. Moon, I. Jang, Y. C. Choe, J. G. Kim, and G. Bock, "Case study of big data-based agri-food recommendation system according to types of customers," *J. KICS*, vol. 40, no. 5, pp. 903-913, 2015.

[3] D.-J. Seo and T.-S. Kim, "Influence of personal information security vulnerabilities and perceived usefulness on bank customers' willingness to stay," *J. KICS*, vol. 40, no. 8, pp. 1577-1587, 2015.

[4] T.-N. Phan and M. Yoo, "Facebook fan page evaluation system based on user opinion mining," *J. KICS*, vol. 40, no. 12, pp. 2488-2490, 2015.

[5] P. Harrington, *Machine Learning in Action*, Manning, 2012.

[6] D. Goldberg, D. Nichols, B. M. Oki, and D. Terry, "Using collaborative filtering to weave

an information tapestry," *Commun. ACM*, vol. 35, no. 12, pp. 61-70, Dec. 1992.

[7] Y. Koren, R. Bell, and C. Volinsky, "Matrix factorization techniques for recommender systems," *IEEE Computer*, pp. 42-49, Aug. 2009.

[8] B. Sarwar, G. Karypis, J. Konstan, and J. Riedl, "Item-based collaborative filtering recommendation algorithms," in *Proc. 10th Int. Conf. World Wide Web*, pp. 285-295, 2001.

[9] X. Su and T. M. Khoshgoftaar, "A survey of collaborative filtering techniques," *Advances in Artificial Intelligence*, vol. 2009, no. 4, pp. 1-19, Jan. 2009.

[10] P. Cremonesi, R. Turrin, E. Lentini, and M. Matteucci, "An evaluation methodology for collaborative recommender systems," in *Proc. International Conf. Automated solutions for Cross Media Content and Multi-channel Distribution*, pp. 224-231, 2008.

[11] R. Agrawal and R. Srikant, "Fast algorithms for mining association rules," in *Proc. 20th Int. Conf. Very Large Data Bases*, pp. 487-499, 1994.

김 정 우 (Jung Woo Kim)



2015년 8월 : 광운대학교 제어
계측공학과 석사
2015년 9월~현재 : (주)맵씨닷
컴 CTO
<관심분야> 기계학습, 패턴인
식, 데이터 마이닝

박 광 현 (Kwang-Hyun Park)



1994년 2월 : KAIST 전기및전
자공학과 학사

1997년 2월 : KAIST 전기및전
자공학과 석사

2001년 2월 : KAIST 전기및전
자공학과 박사

2008년~2011년 : 광운대학교
로봇학부 조교수

2011년~현재 : 광운대학교 로봇학부 부교수

<관심분야> 서비스 로봇, 패턴인식, 로봇소프트웨어