

오프라인 쇼핑몰에서 고객 행위에 기반을 둔 맞춤형 브랜드 추천에 관한 연구

김남기* · 정석봉**

A Study on Customized Brand Recommendation based on Customer Behavior for Off-line Shopping Malls

Namki Kim* · Seok Bong Jeong**

Abstract

Recently, development of indoor positioning system and IoT such as beacon makes it possible to collect and analyze each customer's shopping behavior in off-line shopping malls. In this study, we propose a realtime brand recommendation scheme based on each customer's brand visiting history for off-line shopping mall with indoor positioning system. The proposed scheme, which apply collaborative filtering to off-line shopping mall, is composed of training and apply process. The training process is designed to make the base brand network (*BBN*) using historical transaction data. Then, the scheme yields recommended brands for shopping customers based on their behaviors and *BBN* in the apply process. In order to verify the performance of the proposed scheme, simulation was conducted using purchase history data from a department store in Korea. Then, the results was compared to the previous scheme. Experimental results showd that the proposed scheme performs brand recommendation effectively in off-line shopping mall.

Keywords : Ecommendation System, Collaborative Filtering, Off-line Shopping, Customer Behavior, Social Network

Received : 2016. 10. 18. Revised : 2016. 11. 21. Final Acceptance : 2016. 11. 30.

※ This work was supported by the Ministry of Education of the Republic of Korea and the National Research Foundation of Korea (NRF-2015S1A5A8012533).

* Ph.D. Candidate, School of Business, Kyungil University, e-mail : yoy8741@naver.com

** Corresponding Author, Professor, School of Business, Kyungil University, 50 Gamasil-gil, Buho-ri, Hayang-eup, Gyeongsan-si, Gyeongsangbuk-do, 38428, Korea, Tel : +82-53-600-5071, e-mail : sbjung@kiu.ac.kr

1. 서 론

약 400조 원 규모의 국내 소매유통시장에서 기업들은 온·오프라인의 다양한 유통채널을 활용하여 치열한 경쟁을 지속하고 있다. 이러한 상황 속에 각 소매유통 기업들은 새로운 Merchandising (MD) 외에 신규고객 유치 및 기존 고객 유지를 위한 다양한 노력을 수행하고 있다[Kwak, 2014].

한편, 과거 소매유통업은 오프라인 중심인 백화점, 대형마트, 쇼핑센터 등이 주축을 이루었지만 최근에는 온라인 쇼핑 시장이 급부상하고 있다. 2015년의 경우 홈 쇼핑, 인터넷 쇼핑, 모바일 쇼핑을 포함한 온라인 쇼핑업계 전체의 시장 성장률은 약 9%에 달했고, 매출은 60조 원에 육박하는 등 오프라인 쇼핑 시장을 잠식해 가고 있다[Kim, 2016].

이러한 온라인 쇼핑 시장의 급속한 성장의 원인 중 하나로는 고객 정보를 활용한 맞춤형 마케팅 활동이 중요한 역할을 하고 있다[Kim, 2016; Jeong and Kim, 2014]. 온라인 쇼핑물은 일반적으로 회원가입 절차를 통한 고객의 인구통계학 정보의 파악이 가능하고, 개별 고객의 과거 구매 내역 및 상품 사용후기나 평가 등의 방대한 자료 축적이 용이하며, 이를 활용한 다양한 마케팅 기법의 적용이 가능하다는 특징을 갖고 있다[Jeong, 2014; Lee, 2015].

이러한 고객 맞춤형 마케팅 활동의 사례로, 아마존과 같은 대형 온라인 쇼핑물들은 협업필터링(collaborative filtering)으로 알려진 자동화된 정보 필터링 기술을 이용하여 고객의 구매성향을 파악하고, 그들의 기호에 맞는 상품을 추천하고 있다. 협업필터링은 온라인 쇼핑에서 가장 널리 사용되며, 성공적인 추천기법으로 알려져 있다[Park, 2012; Park et al., 2009].

이에 반해 오프라인 쇼핑물의 경우 우편물 발송(DM), 텔레마케팅 등의 전통적인 마케팅 활동

을 수행하고는 있지만, 온라인 대비 가용한 고객 정보 및 정보전달 매체의 한계로 인해 마케팅 활동이 제한적이었다[Cho and Kim, 2004]. 이러한 이유로 오프라인 쇼핑 시장에서 상품 추천과 관련된 연구는 주로 상품간의 연관성 파악에 의한 진열 및 배치, 세트 상품 구성 등에 국한되었으며[Kim et al., 2014; Radeder and Chawla, 2009; Song et al., 2014], 고객의 행위정보를 활용한 맞춤형 추천 연구는 상대적으로 빈약한 것으로 파악된다.

한편, 최근에는 블루투스 기반의 비콘(Beacon), 와이파이 기반의 기술 등 실내측위 및 IoT 기술의 발전으로[Yoo and Cho, 2014], 각종 멤버십과 마일리지 관련 서비스들이 오프라인 쇼핑시장에 시험적이거나 적용되고 있다[Choi, 2016]. 현재 SK플래닛의 시럽은 고객의 현 위치를 기반으로 쿠폰 전송, 이벤트 정보 제공 등과 같은 서비스를 제공하고 있으며, Yap 컴퍼니 역시 쿠폰 전송, 스탬프, 할인 및 제휴 카드 정보 제공 등의 서비스를 수행하고 있다. 또한 롯데백화점의 경우 ‘스마트 비콘서비스’를 운영하며, 백화점 내 개별 브랜드의 길안내 서비스를 고객 스마트폰을 이용하여 제공하고 있다[Lee, 2014].

이러한 실내측위 및 IoT 기술의 발전으로 인해 오프라인 쇼핑 시장에서도 고객의 구매 행위를 제한적이거나 파악하는 것이 가능해졌다. 즉, 쇼핑물 내의 고객 현 위치 정보나 방문한 브랜드 및 매장 정보, 각 브랜드 및 매장에 체류한 시간 등 고객의 쇼핑 행위 관련된 일부 정보의 파악이 가능해진 것이다[Choi, 2016].

이에 본 연구에서는 고객의 쇼핑 행위와 관련하여 일부 정보가 이용 가능한 오프라인 쇼핑물을 대상으로 협업필터링을 응용한 실시간 맞춤형 브랜드 추천기법을 구현하는 방안을 모색하고자 한다. 즉, 쇼핑물 내 위치한 개별 고객의 브랜드 방문 이력, 체류 시간 등의 정보를 활용할

수 있는 상황에서 백화점 등의 오프라인쇼핑물에 활용 가능한 브랜드 추천기법을 제안한다.

본 연구의 구성은 다음과 같다. 제 2장에서는 추천 시스템에 관한 기존 연구를 살펴보고, 제 3장에서는 오프라인 쇼핑물에서의 브랜드 추천기법을 제안한다. 제 4장에서는 국내 대형 백화점인 A백화점 거래내역을 통해 제안된 기법의 성능을 평가하며 그 결과를 해석한다. 마지막 제 5장에서는 본 연구에 관한 결론 및 시사점을 논의한다.

2. 관련 연구

현재까지 온라인 쇼핑시장에서 적용되고 있는 추천기법은 여러 가지가 있는데, 크게 내용 기반(contents-based) 기술과 협업필터링, 그리고 두 개 이상의 기술을 함께 사용하는 하이브리드 기술로 구분할 수 있다[Im, 2016; Nam et al., 2008; Ricci et al., 2011].

내용기반 기술은 소비자가 소비하는 상품 중 이와 관련된 텍스트 정보 분석을 통하여 유사한 상품을 찾고 추천하는 방법으로, 주로 영화나 뉴스, 책 등의 콘텐츠 기반 상품을 대상으로 적용되어 왔다. 이 기술은 사용자의 정보나 평가 내역이 필요 없으며, 새로운 상품에 대한 추천이 가능하다는 장점을 가지고 있다. 하지만 텍스트와 같이 명시적으로 표현된 내용만 다룰 수 있고, 질적인 부분은 포착해 내지 못한다는 단점을 가지고 있어, 오픈마켓과 같은 온라인 쇼핑물에 적용하기에는 한계가 있다.

협업필터링은 각 상품에 대한 고객의 선호도를 이용하여, 추천 대상의 고객과 유사한 성향을 가진 고객 군을 찾고, 이 고객 군들의 구매 내역을 이용하여 추천 상품을 도출하는 방법이다. 협업필터링은 사용자를 기준으로 하는 user-based 협업필터링(UBCF)과 아이템(상품)을 기준으로 하는 item-based 협업필터링(BCF) 방법이 있다.

UBCF는 앞서 설명한 바와 같이 추천 대상 고객과 유사한 사용자 그룹을 찾고 이 그룹이 공통적으로 선호하는 아이템을 추천하는 방식으로, 매우 정확한 추천이 가능하다는 장점이 있다. 반면 IBCF는 고객들의 선호도를 바탕으로 아이템간의 유사도를 계산하고, 특정 사용자가 어떤 아이템을 구매하거나 좋다고 평가하면 그 아이템과 비슷한 아이템을 추천하는 방식이다. IBCF는 정확도는 다소 떨어지지만 계산 속도가 빨라 대용량 데이터에 적용이 가능하다는 장점을 가지고 있다.

하이브리드 기술은 두 가지 이상의 기술을 혼합해서 사용하는 형태로, 복수의 기술을 사용할 때 추천의 정확도가 향상된다는 기존 연구에 기반을 둔 방법이다[Nam et al., 2008]. 그러나 각 기술이 어떤 방식으로 결합할지에 대한 객관적이고 구체적인 가이드가 없어 각 쇼핑업체가 처한 환경에 따라 다양한 시도를 통해 최적의 방법을 찾는 것이 요구된다.

한편, 온라인 쇼핑 시장에서 사용되는 추천기법 중 가장 널리 그리고 성공적으로 활용되는 기술은 협업필터링이다[Kim et al., 2009; Lee and Park, 2009]. 앞서 언급한 아마존의 경우, 전체 매출의 30%를 협업필터링 추천을 통해 얻는다고 알려져 있다[Shmueli et al., 2006].

본 연구는 오프라인 쇼핑물에서 협업필터링 기술을 적용하는 방법에 대한 것으로, 실제 쇼핑물에 적용이 가능하도록 대량의 데이터 처리가 가능한 IBCF 기법을 활용하는 방안을 제안한다.

3. 오프라인 쇼핑물에서 브랜드 추천기법

온라인 시장에서 고객의 쇼핑 관련 행위는 특정 상품 검색 이력, 웹 페이지별 체류 시간, 상품 사용후기나 평가, 상품 구매이력 등과 같은 다양한 정보를 활용하여 파악이 가능하다[Koh et al., 2015].

반면 백화점과 같은 오프라인 쇼핑물의 경우, 고객별 구매이력 정보가 쇼핑행위와 관련된 거의 유일한 정보였으며, 따라서 이러한 구매이력 기반의 추천기법이 주로 연구되었다[Kim et al., 2012; Kim et al., 2014; Lu and Wu, 2009; Radeder and Chawla, 2009; Song et al., 2014].

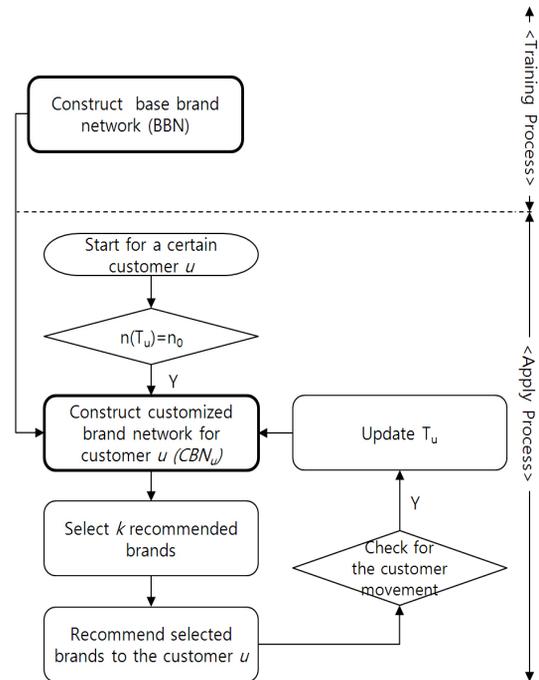
그러나 최근 비콘 등의 측위 기술을 이용하여 실내의 고객 위치 및 이동 동선 등에 대한 실시간 파악이 가능해졌고, 이를 활용한 실시간 마케팅 활동이 일부 쇼핑물에 이미 적용되고 있다[Choi, 2016, Kim and Youn, 2015].

본 연구에서 제안하는 브랜드 추천기법은 오프라인 쇼핑물 내에 비콘 등의 고객 측위 기술이 적용되어 개별 고객의 각 브랜드 방문 이력정보를 확인할 수 있는 상황을 가정한다. 본 연구에서 가정하는 오프라인 쇼핑물의 상황은 다음과 같다.

- ① 본 연구에서 언급하는 오프라인 쇼핑물은 백화점과 같이 최소 2개 이상의 브랜드가 입점된 물리적 쇼핑 공간을 의미한다.
- ② 쇼핑물은 해당 쇼핑물 전체를 관리·지원하는 마케팅 총괄실이 있으며, 당일 방문 고객들의 각 브랜드별 방문 내역 및 체류 시간(stay time)을 실시간 파악할 수 있다.
- ③ 쇼핑물은 입점 브랜드 간 교차판매 증대를 위한 마케팅 노력을 수행할 동기가 있다.
- ④ 쇼핑물은 방문 고객들을 대상으로 판매추진을 위한 실시간 광고·홍보 수단을 확보하고 있다.

위의 ①, ③번 가정들은 백화점과 같은 일반적인 오프라인 쇼핑물의 상황에 기본적으로 부합한다. 그러나 ③번 가정의 경우 쇼핑물이 단순히 입점 브랜드 협의회 형식으로 구성된 경우에는 맞지 않는 가정일 수 있다. 이는 쇼핑물 전체의 판매 증대를 위한 뚜렷한 동기가 없기 때문이다.

②번 가정은 앞서 설명한 것처럼 비콘 등의 실내 측위 기술이 적용된 쇼핑물을 대상으로 함을 의미한다. ④번 가정의 경우, 최근 일부 쇼핑물들은 쇼핑물 전용 앱 등을 구축하고 이를 활용한 실시간 쿠폰 전송 등의 광고를 수행하고 있으며 [Lee, 2016], 이외에도 쇼핑물 내부의 DID(Digital Information Display) 등 다수의 매체를 활용하고 있음을 고려할 때 현실적인 가정이라고 할 수 있다. 이러한 기본 가정 속에서 본 연구에서 제안하는 실시간 고객 맞춤형 브랜드 추천기법의 전체 프레임워크는 <Figure 1>과 같다.



<Figure 1> The Whole Framework for the Proposed Scheme

본 연구에서 제안하는 기법은 온라인 쇼핑물의 추천 시스템에서 주로 활용하는 협업필터링을 응용한 것으로, 협업필터링은 기본적으로 사회 네트워크 분석을 기반으로 한다[Park, 2012]. 제안된 기법은 크게 두 부분으로 구성되는데, <Figure 1>과 같이 학습과정(Training Process)과 적용과정(Apply Process)으로 이루어져 있다. 학습과정

은 쇼핑몰의 과거 일정 기간 동안 각 일자별/고객별 브랜드 방문이력을 기반으로 이루어지며, 본 연구에서는 고객의 브랜드 방문이력을 고객의 방문 브랜드 리스트와 체류시간으로 정의한다.

<Table 1>은 특정 고객의 브랜드 방문이력을 표현한 예로써, 이 고객은 브랜드 1에서 3분을 체류한 후, 브랜드 17에서 5분, 브랜드 20에서 10분을 체류하는 쇼핑 행위를 보여주고 있다. 학습 과정은 과거 각 일자별 고객들의 브랜드 방문이력을 기반으로 브랜드 네트워크(BBN)를 구축하는 역할을 담당한다.

<Table 1> Customer's Brand Visiting History

Brand	Stay Time(mim)
brand 1	3
brand 17	5
brand 20	10

브랜드 네트워크가 구성되면 적용과정에서는 당일 방문 고객에 대한 실시간 맞춤형 추천 브랜드를 도출한다. 제안된 기법에서는 쇼핑몰의 당일 방문 고객이 최소 n_0 개의 브랜드를 방문한 이후부터 브랜드 추천을 수행한다. 즉 가장 최근 방문한 브랜드 정보 하나가 아닌, 쇼핑 중 방문한 n_0 개 이상의 브랜드 정보 모두를 활용하여 추천 브랜드를 도출하는데, 이는 당일 방문고객의 쇼핑 의도 및 구매 욕구를 보다 정확하게 파악하기 위함이다.

당일 방문한 특정 고객이 처음 n_0 개의 브랜드를 방문하면, 마케팅 총괄실에서는 해당 고객의 브랜드 방문이력 및 기 학습된 브랜드 네트워크를 활용하여 k 개의 맞춤형 추천 브랜드를 도출한다. 이후 마케팅 총괄실은 스마트폰 앱이나 SMS, 고객 근처의 DID 등을 통해 해당 고객에게 쿠폰 제공, 광고 등의 실시간 맞춤형 마케팅 활동을 수행할 수 있다.

각 과정에 대한 상세 설명은 다음절부터 제시되어 있다.

3.1 학습과정 : 사회 네트워크를 활용한 브랜드 네트워크 구성

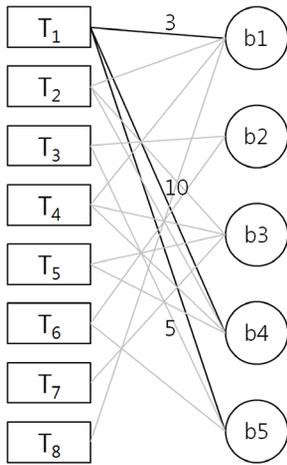
제안된 기법의 학습과정은 쇼핑몰의 과거 브랜드 방문이력을 기반으로 브랜드 네트워크를 구성하는 과정이다. 먼저, 쇼핑몰에 입점한 전체 브랜드의 집합을 B 라고 하고, 이 중 <Table 1>과 같이 특정 고객이 특정 일자에 방문한 브랜드 리스트 및 체류시간을 트랜잭션 데이터 T 라고 정의하자. 이는 동일 고객이라 하더라도 서로 다른 일자에 쇼핑몰을 방문했다면 각 브랜드 방문이력은 서로 다른 트랜잭션임 의미한다.

한편, 사회네트워크 분석을 응용하면 브랜드 네트워크 구성을 통해 쇼핑몰의 입점 브랜드 간의 관계 파악이 가능하다. 과거 트랜잭션을 이용하여 브랜드 네트워크를 구성하기 위해서는 먼저 일자별/고객별 트랜잭션과 브랜드로 구성된 2-Mode 매트릭스를 작성하고 이를 이용해 브랜드 네트워크를 구성한다.

<Figure 2>(a)의 예에서 첫 번째 트랜잭션 T_1 은 고객 1이 브랜드 b_1, b_4, b_5 를 방문하고 각 브랜드의 체류시간을 3분, 10분, 5분임을 의미한다. 이와 마찬가지로 다른 고객들도 브랜드 $b_1 \sim b_5$ 중 일부를 방문한 경우, 트랜잭션-브랜드(TB) 매트릭스는 <Figure 2>(b)와 같이 2-Mode 매트릭스로 표현된다.

TB 매트릭스는 각 행에 트랜잭션, 각 열에 브랜드가 배치된 형태로써, 셀(i, j) 값은 트랜잭션 i 에 브랜드 j 가 포함된 경우는 체류시간을, 그렇지 않은 경우 0의 값을 갖는다.

브랜드 간의 관계를 표현하기 위해서는 2-Mode의 TB 매트릭스를 1-Mode의 브랜드 매트릭스로 변환하여야 한다. 이때 TB 매트릭스에 기

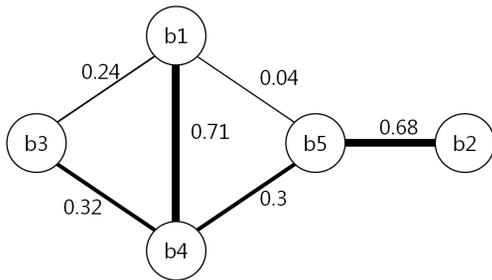


(a) Graph

	b1	b2	b3	b4	b5
T1	3	0	0	10	5
T2	5	0	20	4	0
T3	0	7	0	0	5
T4	30	0	4	12	0
T5	0	0	4	5	0
T6	0	2	0	0	7
T7	0	0	18	0	0
T8	15	0	0	0	0

(b) Matrix

〈Figure 2〉 Transaction-Brand Network



(a) Graph

	b1	b2	b3	b4	b5
b1	0	0	0.24	0.71	0.04
b2	0	0	0	0	0.68
b3	0.24	0	0	0.32	0
b4	0.71	0	0.32	0	0.3
b5	0.04	0.68	0	0.3	0

(b) Matrix

〈Figure 3〉 Brand Network

반하여 브랜드 간의 유사도를 계산해야 하는데, 쇼핑물의 협업필터링에서 많이 쓰이는 유사도로는 코사인계수, 자카드 계수 등이 있다[Kwak, 2014; Lee, 2012; Im, 2016].

예를 들어, 〈Figure 2〉의 TB 매트릭스를 코사인 계수 유사도를 통해 브랜드 네트워크로 변환한 결과는 〈Figure 3〉과 같다.

〈Figure 3〉에 따르면, 브랜드 $b1$ 과 $b4$ 의 경우 유사도가 0.71로 가장 강한 관계를 가지고 있다. 이는 브랜드 $b1$ (혹은 $b4$)을 방문한 고객에게 브랜드 $b4$ (혹은 $b1$)를 추천하는 것이 쇼핑물 전체에서 교차판매의 효과를 높일 수 있는 방법임을 의미한다[Im, 2016; Jeong, 2015].

한편, 학습과정에서 구성된 브랜드 네트워크는 이후 적용과정에서 각 고객의 추천 브랜드를 도출하는데 활용되므로 본 연구에서는 이를 BBN (Base Brand Network)이라고 지칭한다.

3.2 적용과정 : 고객 맞춤형 브랜드 네트워크 구성 및 추천 브랜드 도출

적용과정은 학습과정의 결과인 BBN 과 당일 고객의 브랜드 방문이력을 기반으로 해당 고객에게 맞는 추천 브랜드를 실시간으로 도출하는 과정이다. 본 연구에서는 추천 브랜드 도출 시 고객이 현재까지 방문한 n_0 개 이상의 브랜드 방문이력을 활용하는데 이는 해당 정보가 고객의 쇼핑 의도를 내재하고 있다는 가정에 기반한다. 이러한 가정의 타당성은 실험 결과를 통해서 간접적으로 확인할 수 있다.

당일 방문한 특정 고객 u 가 처음 n_0 개의 브랜드를 방문한 시점에서의 트랜잭션을 T_u 라고 하자. 고객 u 가 n_0 번째의 브랜드를 방문한 이후부터($n(T_u) \geq n_0$) 제안된 기법은 작동하기 시작한다. 예를 들어 n_0 가 2일 경우, 고객은 2번째 브랜드의 방문을 마친 이후부터 제안된 기법에 의해

실시간 브랜드 추천을 받게 된다.

이를 위해서는 해당 고객의 현재까지의 브랜드 방문이력을 참조하여 고객 u 만의 맞춤형 브랜드 네트워크(Customized Brand Network; CBN)를 구성할 필요가 있다. 만일 고객의 현재까지 브랜드 방문이력을 감안하지 않고, 가장 최근(latest)의 방문 브랜드 정보만을 기반으로 추천 브랜드를 도출할 경우에는 학습과정에서 구축한 BBN 을 수정 없이 그대로 활용할 수 있다.

예를 들어, <Figure 3>과 같이 BBN 이 구성된 상황에서, 당일 방문한 임의의 고객 u 의 최근 방문 브랜드가 b_5 라고 하면 b_2 를 추천받게 된다. 그러나 고객이 방문한 다수개의 브랜드 이력정보를 활용할 경우, 고객의 쇼핑 의도 및 욕구를 보다 정확히 판단할 수 있고 이로 인해 추천의 정확도가 높아질 수 있다고 가정할 수 있다(이러한 가정의 타당성은 4장의 실험 결과를 통해 확인할 수 있다). 따라서 고객의 방문이력을 감안한 맞춤형 브랜드 네트워크, CBN 을 구성할 필요가 있다.

본 연구에서 제안하는 CBN 의 구성 방법은 다음과 같다. 트랜잭션 T_u 를 구성하는 각각의 브랜드 $i(i \in T_u)$ 에서 해당 고객이 머문 시간을 d_i 라고 하자. 고객 u 의 CBN_u 를 구성하는 방법은 다음과 같이 2 step으로 이루어진다.

[step 1] T_u 내의 모든 노드를 하나의 노드 c 로 통합한다.

[step 2] 노드 c 와 다른 브랜드 노드 $j(j \in B - T_u)$ 간의 링크 가중치 w_{cj} 를 식 (1)과 같이 부여한다.

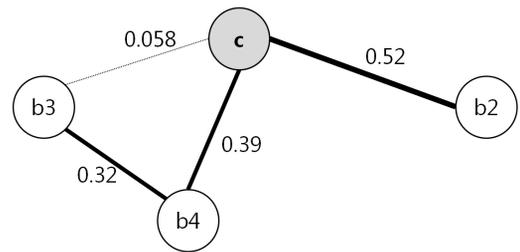
$$w_{cj} = \frac{\sum_{i \in T_u} w_{ij} \times d_i}{\sum_{i \in T_u} d_i} \quad (1)$$

예를 들어 설명하면, <Figure 3>과 같이 학습 과정을 통해 BBN 이 구성된 상황에서, 고객 u 가 당일 첫 방문을 수행한 두 개의 브랜드를 b_1 및

b_5 라고 하고($n_0 = 2$ 를 가정) 각 브랜드에서 3분 및 10분을 체류하였다고 하자. 이 경우 고객 u 의 CBN_u 는 <Figure 4>와 같이 구성된다.

<Figure 4>의 CBN_u 에서는 <Figure 3>의 BBN 의 b_1 과 b_5 가 통합되어 하나의 노드 c 로 표현되며, 통합 노드인 c 와 다른 노드들 간 링크의 강도는 고객 u 가 b_1 과 b_5 에 체류한 시간을 감안하여 결정된다. 즉, 노드 c 와 b_4 와의 연결강도는 b_1 과 b_4 간의 강도인 0.71과, b_5 와 b_4 간의 강도 0.3을 대상으로 고객 u 가 b_1 과 b_5 에 머문 시간인 3분과 10분을 감안하여 가중평균으로 계산한다($w_{c,b_4} = 0.71 \times 3 / (3 + 10) + 0.3 \times 10 / (10 + 3) = 0.39$).

식 (1)에서 통합 노드 c 와 다른 노드 j 간의 연결강도 계산 시, c 를 구성하는 각 노드에서 해당 고객이 체류한 시간을 가중치로 반영하는 이유는 다음과 같다. 이는 특정 브랜드에서의 고객 체류 시간은 해당 브랜드에 대한 고객의 관심도에 비례한다는 일반적인 상식에 근거하여, 고객이 오래 체류한 브랜드의 이웃 브랜드들이 추천될 가능성을 보다 높게 부여하기 위함이다.



(a) Graph

	b2	b3	b4	c
b2	-	0	0	0.52
b3	0	-	0.32	0.06
b4	0	0.32	-	0.39
c	0.52	0.06	0.39	-

(b) Matrix

<Figure 4> Customized Brand Network

CBN_u 가 구성된 이후에는 통합 노드 c 의 이웃 노드 중에서 연결강도가 높은 노드 순으로 고객 u 를 위한 추천 브랜드를 추출한다. 즉, 추천 브랜드의 수 k 를 미리 설정하고 통합 노드 c 의 이웃 노드 중에서 c 와의 연결강도가 높은 순으로 k 개 만큼의 추천 브랜드를 추출한다. 물론 이웃 노드의 수가 k 보다 작을 경우에는 이웃 노드의 수만큼의 추천 브랜드를 생성한다.

이렇게 선택된 추천 브랜드는 스마트폰의 앱, SMS, DID 등의 다양한 광고 수단을 통하여 실시간으로 방문고객에게 전달된다.

한편, 해당 고객이 다른 브랜드로 이동하게 될 경우 고객 방문 브랜드 리스트 T_u 를 업데이트하고 업데이트된 T_u 를 기준으로 다시 추천 브랜드를 생성한다. 이러한 과정은 고객이 당일 쇼핑을 마치고 쇼핑물을 이탈할 때까지 반복된다.

4. 실험

본 연구에서는 제안된 기법의 성능 및 적용가능성을 검증하기 위하여 국내의 유명 백화점 중 하나인 A백화점의 실제 데이터를 대상으로 실험을 진행하였다.

구체적인 실험의 방법 및 결과에 대한 설명에 앞서, 본 실험의 한계에 대해서 먼저 살펴보고자 한다. 본 연구에서는 고객의 브랜드 방문이력을 활용하는 상황을 가정하고 추천기법을 제안하였지만, 아직 국내에서 실내 측위정보에 기반한 고객의 브랜드 방문이력을 수집·제공하는 쇼핑물을 찾을 수 없었다. 따라서 본 실험에서는 부득이하게 고객의 브랜드 방문이력 대신에 백화점의 구매 데이터를 활용한 브랜드 구매이력을 사용하였다. 또한, 브랜드 구매이력에는 고객의 브랜드별 체류시간이 포함되지 않아, 본 실험에서는 각 고객의 브랜드 체류시간을 모두 동일하다고 가정하였다.

이러한 실험의 한계점에도 불구하고 뒤에서

살펴보게 될 본 실험결과의 우수한 성능은 본 연구에서 제안된 기법이 고객 위치의 실시간 측정 기술이 적용되지 않은 현재의 대다수 쇼핑물에서도 충분히 적용될 수 있음을 의미한다. 더불어 측위기술의 보편화로 향후 고객의 브랜드 방문 이력 정보를 추가로 활용할 경우 보다 우수한 추천 성능을 보일 것으로 기대된다.

4.1 실험 데이터

본 실험에서는 년 매출 약 5천억 원에 12만 여명의 회원을 보유한 국내 중형의 A백화점의 구매내역 데이터를 사용하였다. 실험에 포함된 고객은 전체 방문 고객 중에서 브랜드별 구매 이력의 추적이 가능한 A백화점의 회원으로 한정하였다.

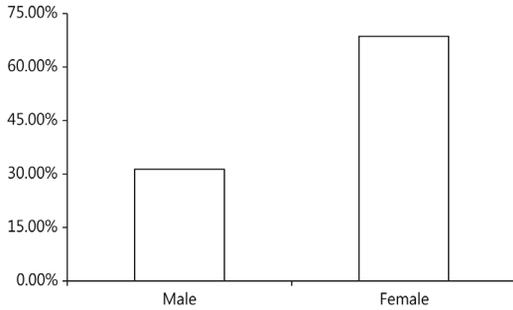
<Table 2>는 실험에 사용한 데이터의 상세내역을 보여준다.

<Table 2> Customers' Purchasing Data

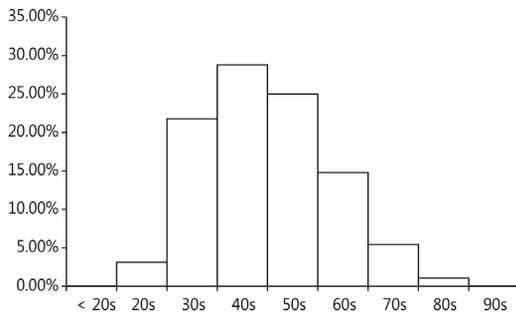
	before preprocessing	after preprocessing
period	2015. 5~2015. 8 (4months)	2015. 5~2015. 8 (4months)
no. of transactions	302,758	233,550
no. of customers	60,078	57,075
no. of brands	485	430

실험에 앞서 브랜드의 구분이 애매한 백화점 내 푸드코트 및 실험 기간 동안에 신규 입점 혹은 철수한 브랜드를 제외하는 등의 전처리 작업을 거쳤다. <Table 2>에서 보듯이 본 실험의 기간인 4개월 동안 총 57,075명의 고객 및 430개의 브랜드를 대상으로 제안된 기법의 성능을 평가하였다.

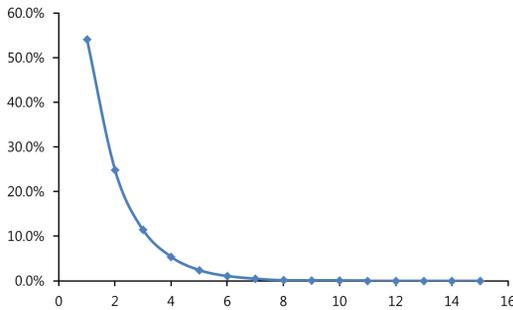
전처리 이후 전체 고객의 인구통계학적 특성은 <Figure 5> 및 <Figure 6>에 표시되어 있다. 여



〈Figure 5〉 Gender Ratio



〈Figure 6〉 Age Distribution



〈Figure 7〉 Transaction Distribution According to the Number of Brands

성이 68.6%, 30에서 60세 까지의 고객이 전체 고객의 75%로 다수를 차지하고 있음을 알 수 있다.

〈Figure 7〉은 하나의 트랜잭션에 포함된 브랜드 개수의 분포를 보여주고 있다. 〈Figure 7〉에 따르면 전체 트랜잭션의 54.1%가 오직 하나의 브랜드만 포함하고 있어, 방문 고객 중 절반 정도는 하나의 브랜드에서만 구매를 수행하는 것으로 파악되었다. 3회 이상의 브랜드를 포함하

는 트랜잭션의 비중은 21.1%이다.

한편, 일반적인 머신러닝 기법의 성능평가 방법에 따라 제안된 기법의 성능을 검증하기 위하여 전체 트랜잭션 데이터를 〈Table 3〉과 같이 학습 집단(training set)과 테스트 집단(test set)으로 구분하였다.

〈Table 3〉에서 보듯이, 2015년 5월부터 7월까지 3개월의 트랜잭션 데이터(약 77%)를 제안된 기법의 학습을 위해 사용하였으며, 이 결과를 2015년 8월 트랜잭션 데이터(약 23%)에 적용함으로써 제안된 기법의 성능을 평가하였다.

〈Table 3〉 Training set vs. TEST set

	training set	test set
period	2015. 5~2015. 7 (3 months)	2015. 8 (1 months)
no. of transactions	179,342 (76.8%)	54,208 (23.2%)

4.2 분석 방법

기존의 많은 연구들이 추천 시스템의 성능을 평가하는 방법으로 정확도(Precision), 재현율(Recall) 및 F1 값을 사용해 왔다[Ahn, 2008; Sarwar et al., 2000; Schonberger and Cukier, 2013]. 정확도는 추천 시스템이 추천한 아이템 중 실제 고객이 구매하는 아이템의 비율이며, 재현율은 고객이 구매한 아이템 중에서 추천 시스템의 추천이 적중시킨 비율이다.

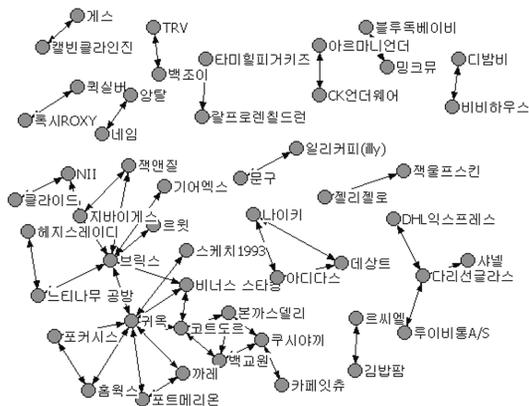
한편, 정확도와 재현율은 시스템이 추천하는 아이템의 개수에 영향을 받는다. 즉, 시스템이 추천하는 아이템의 개수가 많아지면 재현율은 올라가고 정확도는 떨어지게 된다. 따라서 최근의 추천 시스템 연구에서는 주로 식 (2)와 같이 정확도와 재현율을 가중 평균한 F1 값을 추천 정확도의 평가방법으로 사용한다[Cho et al., 2004; Choi et al., 2011; Park et al., 2009].

$$F1 = \frac{Recall \times Precision}{(Recall + Precision)/2} \quad (2)$$

본 실험에서는 제안된 기법을 대상으로 정확도, 재현율 및 F1 값을 산출하여 그 성능을 살펴볼 것이며, 또한 성능의 비교평가를 위하여 기존의 베스트셀러 기반 추천기법과 그 값을 비교해 본다. 한편, 본 실험은 실제 환경에서 진행하지 못하는 한계로 인해 제안된 알고리즘을 그대로 적용하지 못하고, 테스트 집단 내에 속한 트랜잭션 중에서 브랜드의 개수가 n_0 를 초과하는 트랜잭션만을 대상으로 추천을 수행하였다. 즉 테스트 집단 내의 각 고객을 대상으로, 방문한 브랜드의 수가 n_0 가 되는 순간 추천을 수행하고, 추천된 브랜드와 고객이 실제 방문한 브랜드를 비교하여 정확도, 재현율 및 F1 값을 산출한다.

4.3 실험 결과

<Figure 8>은 A백화점 트랜잭션 데이터의 학습과정 결과로 생성된 BBN의 일부를 나타낸 것으로, 가독성을 위하여 브랜드 간 연결강도가 0.02 이상인 브랜드만 표기한 것이다. 총 430개의 브랜드 중, 50개의 브랜드만 표현되어 있다.



<Figure 8> Base Brand Network

<Figure 8>의 중앙에는 나이키, 아디다스, 데상트가 연결되어 있어 동일 종류(스포츠)의 브랜드 간 연결을 확인할 수 있으며, 좌측 하단에 있는 브릭스와 귀족은 여성의류 및 생활용품 브랜드로서 다른 종류의 브랜드 간 연결도 존재함을 확인할 수 있다.

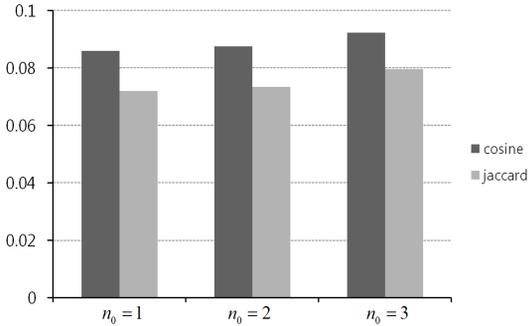
이렇게 생성된 BBN의 결과는 테스트 집단 내 각 트랜잭션의 구매이력과 결합하여 CBN의 구성 및 고객 맞춤형 추천 브랜드를 생성하는데 활용된다.

4.3.1 n_0 및 유사도에 따른 추천 성능 비교

제안된 기법의 성능 평가의 첫 번째로, 우선 추천 시스템이 동작하기 위한 n_0 값의 변화가 추천 성능에 어떠한 영향을 미치는지 확인해 본다. 이는 추천 시스템이 활용하는 고객의 브랜드 이력 정보의 양과 추천 성능 간의 관계를 확인해 보기 위함이다. 더불어 학습과정에서 BBN을 구성할 때, 브랜드 간의 유사도 계산 방식이 추천 성능에 미치는 영향을 함께 살펴본다.

<Figure 7>에서 보듯이 백화점 방문 고객의 일일 구매 브랜드 수는 1~4회가 95.8%를 차지하고 있다. 따라서 본 실험에서는 n_0 의 값을 1부터 3까지 변화해 가면서 추천 시스템의 성능을 확인해 보았다. 브랜드 간 유사도 계산 방식으로는 온라인 쇼핑몰의 추천 시스템 구현에 주로 활용되는 코사인 및 자카드 계수를 적용해보고[Im, 2016; Chung and Lee, 2002; Kim, 2008], 그 성능을 비교해 보았다. 이 실험에서는 추천 시스템이 도출하는 추천 브랜드의 개수를 4개로 고정하였다($k=4$).

<Figure 9>에 따르면 유사도 계산 방식에 상관없이 n_0 가 증가할수록 F1 값이 증가하는 것을 확인할 수 있다. n_0 가 3일 경우에 F1 값은 코사인 및 자카드 계수를 적용한 경우 각각 0.093 및 0.080으로, n_0 가 1인 경우의 0.086 및 0.072 대비 각각 7.3% 및 10.7% 상승했다.



<Figure 9> F1 Measure for Various n_0 and Similarity Measures

이는 추천 시스템에서 사용하는 개별 고객의 브랜드 이력정보의 양이 증가할수록 해당 고객의 구매 의도 및 욕구에 대한 보다 정확한 판단이 가능해 지며, 이로 인해 추천 정확도가 증가함을 의미한다고 할 수 있다.

한편, 유사도 계산 방식에 따른 추천 정확도의 차이를 살펴보면, 제안된 기법에 코사인 계수를 적용한 경우가 자카드 계수를 적용할 때 보다 n_0 값의 변화에 따라 각각 19.5%, 19.2%, 15.9% 높은 것을 확인할 수 있다. 이는 오프라인 쇼핑몰의 추천 시스템 구현 시 각 브랜드 간 유사도 계산 방식으로 자카드 계수보다 코사인 계수가 적절함을 의미한다.

4.3.2 추천 브랜드의 개수에 따른 성능 비교

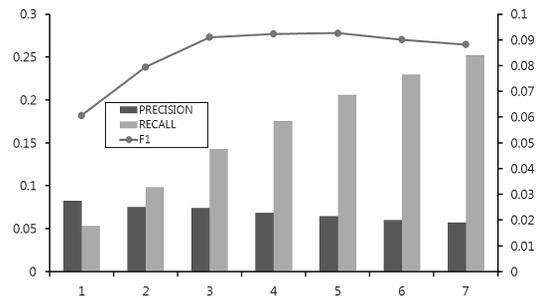
다음으로는 제안된 기법이 도출하는 추천 브랜드의 개수를 변화시키면서 성능을 평가하였다. 이 실험에서 브랜드 간 유사도 계산 방식은 코사인계수를, n_0 는 3을 사용하였다.

<Figure 10>에서 보듯이, F1 값은 추천 브랜드의 개수 k 가 4일 경우에 0.093으로 가장 높음을 알 수 있다. 또한 예상대로 k 가 커질수록 재현율을 키지고 정확도는 감소하는 것을 확인할 수 있었다. 즉, 쇼핑 중인 고객에게 4개의 브랜드를 추천할 경우 그 추천 성능이 가장 뛰어남을 알 수 있다.

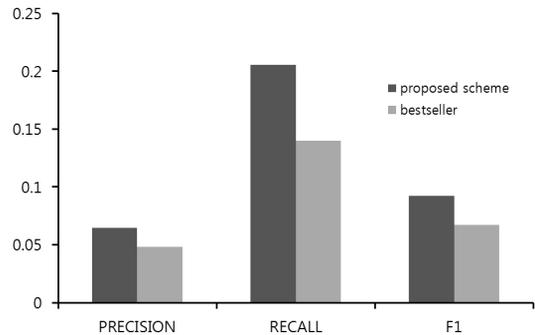
4.3.3 베스트셀러 기반 기법과의 성능 비교

마지막으로, 제안된 기법의 추천 성능의 우수성을 확인하기 위해 기존의 베스트셀러 기반 추천기법과 그 성능을 비교해 보았다. 베스트셀러 기반 추천기법은 개별 고객의 브랜드 방문이력에 대한 고려 없이, 학습기간 동안 가장 방문 빈도가 높은 브랜드를 모든 고객에게 동일하게 추천하는 방식이다[Park et al., 2009]. 한편, 실험에 사용된 제안된 기법의 파라미터로는 $n_0 = 3$, $k = 4$ 를 사용하였고, 베스트셀러 기반 추천기법에서도 가장 방문 빈도가 높은 4개의 브랜드를 추출하였다.

<Figure 10>은 각 기법의 성능 비교 결과를 보여주고 있다.



<Figure 10> Recommendation Performances for Various k



<Figure 11> Performance comparison

<Figure 11>에 따르면 제안된 기법의 정확도, 재현율 그리고 F1 값은 0.061, 0.206, 0.093으로 베스트셀러 기반 추천기법의 0.048, 0.140, 0.067 대

비 각각 34.1%, 46.8%, 38.0% 높음을 알 수 있다.

이는 오프라인 쇼핑몰에서 개별 고객의 쇼핑 의도에 대한 고민 없이 단순히 최대 방문 빈도의 브랜드들을 추천하는 것 보다, 각 고객의 쇼핑 행위를 감안한 맞춤형 추천 방식이 보다 윤택한 추천 성능을 보여줌을 의미한다.

5. 결론 및 시사점

본 연구에서는 오프라인 쇼핑몰에서 고객의 브랜드 방문이력 정보를 활용한 실시간 고객 맞춤형 브랜드 추천기법을 제안하였다. 이를 위하여 온라인 쇼핑몰에서 주로 활용되는 협업필터링 기법을 오프라인 쇼핑몰 상황에 맞게 응용하였으며, 특히 고객의 가장 최근의 방문 브랜드 정보가 아닌 해당일의 방문이력 정보를 활용하는 방안을 제안하였다.

제안된 기법은 크게 학습과정과 적용과정으로 구성된다. 학습과정에서는 과거 특정기간동안의 트랜잭션 데이터를 기반으로 브랜드 네트워크를 구성하게 된다. 적용과정에서는 학습과정에서 구성된 브랜드 네트워크를 고객의 브랜드 방문이력을 감안하여 고객 맞춤형 브랜드 네트워크로 변환하고, 이를 기반으로 추천 브랜드를 추출한다.

본 연구에서는 제안된 기법의 성능을 평가하기 위하여 국내 한 중형 백화점의 브랜드 구매이력 데이터를 확보하여 실험을 수행하였다. 실험 결과, 제안된 추천기법은 기존의 베스트셀러 기반 추천기법과 비교하여 높은 추천 정확도를 보였다.

한편, 본 연구의 결과는 오프라인 쇼핑몰에서 브랜드 추천과 관련하여 다음과 같은 시사점을 제공해준다. 첫째 본 연구의 결과는 온라인과 마찬가지로 오프라인 쇼핑몰에서도 고객의 쇼핑 행위를 감안한 맞춤형 추천 방법이 효과적으로 적용될 수 있음을 보여준다. 비록, 온라인 쇼핑

몰 대비 파악할 수 있는 고객의 쇼핑 행위 정보에는 한계가 있으나, 측위 기술을 비롯한 IoT 기술의 발달로 인해 과거보다 많은 정보가 가용해지고 있는 상황이다. 이러한 상황 속에서 본 연구는 브랜드 방문이력 정보를 감안한 실시간 맞춤형 브랜드 추천에 관한 초창기 연구로써 그 기여가 있다고 하겠다.

두 번째, 오프라인 쇼핑몰에서 맞춤형 브랜드 추천 시스템을 설계할 때 고려해야 할 여러 파라미터들에 대한 가이드라인을 제시하였다. 실험을 통해 브랜드 간 유사도 계산 방식 및 추천 브랜드의 개수에 따른 추천 정확도의 영향을 파악함으로써, 향후 시스템 구현 시 고려해야 할 정보를 제공하였다.

한편, 본 연구의 한계점 및 향후 연구과제는 다음과 같다. 첫째, 실험 환경에 관한 것으로 본 연구의 실험 환경은 실제 서비스 환경과 다음과 같은 차이가 존재한다. 우선 실제 서비스 환경 하에서는 각 개별 고객은 브랜드 방문 횟수가 증가함에 따라 단계적으로 추천을 받게 되지만 본 연구에서는 이러한 사항을 고려하지 못하고 있다. 또한 실제 서비스 환경에서 각 고객의 구매 패턴은 맞춤형 추천에 의해 영향을 받을 수 있으나, 이전의 다수의 연구에서와 마찬가지로 사후적인 고객 구매행위 데이터를 통한 실험만으로는 이러한 효과를 파악하는데 한계가 존재한다. 따라서 저자들은 현재 대형 오프라인 쇼핑몰에 제안된 서비스를 적용하여 그 효과를 직접적으로 측정하기 위한 준비를 하고 있다.

둘째, 본 연구에서 제안된 추천기법은 고객의 브랜드 방문이력 정보만을 쇼핑 행위정보로 활용하고 있다. 그러나 고객의 오프라인 쇼핑 행위에 영향을 미칠 수 있는 다양한 정보, 예를 들면 기온, 강수량 등의 날씨정보나 계절정보, 고객의 인구통계학적정보 등을 활용하면 보다 정확도가 높은 추천 시스템의 설계가 가능할 것이다. 이때

는 협업필터링의 직접적인 적용보다는 다른 머신러닝 기법의 활용이 추가로 필요할 것으로 판단된다. 향후 오프라인 쇼핑몰을 대상으로 다양한 정보를 활용하는 추천 시스템 관련 연구가 활발히 진행되기를 기대한다.

References

- [1] 광기영, 소셜네트워크분석, 제1판, 도서출판 청림, 2014.
(Kwak, K. Y., Social Network Analysis, 1st Edition, Book Publishing Coalition, 2014.)
- [2] 김운태, “소셜, 홈쇼핑, 역직구 모두 모바일에 집중”, Retail, 한국체인스토어협회, 2016, pp. 52-54.
(Kim, Y.-T., “Social, home shopping, Buy-back, All focused on mobile”, Retail, The Korea Chain stores’ Association, 2016, pp. 52-54.)
- [3] 송지혜, “급성장하는 모바일 커머스”, Retail, The Korea Chain stores’ Association, 2015, pp. 70-73.
(Song, J. H., “Burgeoning Mobile Commerce”, Retailers, Korea Chain Store Association, 2015, pp. 70-73.)
- [4] 이민하, “롯데백화점, 옴니채널 강화, 본점 스마트 비콘서비스”, 한국경제신문, 2014.
(Lee, M. H., “Lotte Department Store, Strengthening Omni Channel, The main store Smart Beacon Service”, Korea Economic Daily, 2014.)
- [5] 이수상, 네트워크 분석 방법론, 논형, 2012.
(Lee, S. S., Network Analysis Methodology, Lunheung, 2012.)
- [6] 임 일, R을 이용한 추천 시스템, 제2판, 카오스북, 2016.
(Im, I., Recommendation system using R, 2nd edition, Chaosbook, 2016.)
- [7] 최승진, “강남역 도착했나요? 80m앞 반짝세일”, 매일경제신문, 2016.
(Choi, S. J., “Have you arrived at Gang-nam Station? On flash sale, 80m in front of you”, Maeil Business Newspaper, 2016.)
- [8] Ahn, H. J., “A new similarity measure for collaborative filtering to alleviate the new user cold-starting problem”, *Information Sciences*, Vol. 1, No. 78, 2008, pp. 37-51.
- [9] Cho, Y. H. and Kim, J. K., “Application of Webusage mining and product taxonomy to collaborativer ecommendations in e-commerce”, *Expert Systems with Applications*, Vol. 26, No. 3, 2004, pp. 234-246.
- [10] Cho, Y. H., Park, S. K., Ahn, D. H., and Kim, J. K., “Collaborative Recommendations using Adjusted Product Hierarchy : Methodology and Evaluation”, *Journal of the Korean Operations Research and Management Science Society*, Vol. 29, No. 2, 2004, pp. 61-77.
- [11] Choi, J. S., Kim, D. Y., Han, I. S., and Kim, Y. C., “A Study on Data Analysis in on/off-line shopping mall”, *Electronic Commerce Research association*, Vol. 12, No. 2, 2011, pp. 71-88.
- [12] Chung, Y. M. and Lee, Y. G., “Developing a Book Recommendation System Using Filtering Techniques”, *Journal of Information Management*, Vol. 33, No. 1, 2002, pp. 1-17.
- [13] Jeong, S. B. and Kim, B. G., “The relationship between relation attributes among goods and sales performance of internet shopping mall based on social network analysis”, *Business Education Research*, Vol. 20, No.

- 2, 2014, pp. 394-409.
- [14] Jeong, S. B., "A Novel Approach to Customer Classification and Preference Goods Extraction based on Social Network Analysis for Internet Shopping Malls", *Entrue Journal of Information Technology*, Vol. 13, No. 1, 2014, pp. 57-68.
- [15] Jeong, S. B., "The Relationship between Structure Attributes of Product Networks and Sales Performance of integrated Internet Shopping Malls", *Association of Business Education*, Vol. 30, No. 3, 2015, pp. 97-106.
- [16] Kim, D. H. and Youn, S. J., "Efficient customer management system design using the Beacon", *Korea Society Computer Information*, Vol. 23, No. 2, 2015, pp. 29-30.
- [17] Kim, H. K., Kim, J. K., and Chen, Q. Y., "A Network Approach to Derive Product Relations and Analyze Topological Characteristics", *The Journal of Intelligence and Information Systems*, Vol. 15, No. 4, 2009, pp. 159-182.
- [18] Kim, H. K., Kim, J. K., and Chen, Q. Y., "A Product Network Analysis for Extending the Market Basket Analysis", *Expert Systems with Applications*, Vol. 39, No. 8, 2012, pp. 7403-7410.
- [19] Kim, K. M., Kim, D. Y., and Lee, J. H., "Measuring Similarity Between Movies Based on Polarity of Tweets", *Journal of Korean Institute of Intelligent Systems*, Vol. 24, No. 3, 2014, pp. 292-297.
- [20] Kim, K. S., "A Hybrid Collaborative Filtering Algorithm for Personalized Recommendations and its Application to the Internet Electronic Commerce", *Internet Electronic Commerce Research*, Vol. 8, No. 4, 2008, pp. 1-20.
- [21] Koh, J., Choi, S. J., and An, B. C., "Determinants of Customer Loyalty in the Context of Online Shopping : A Comparative Analysis of Internet Shopping and Mobile Shopping", *Journal of Korea Contents Association*, Vol. 15, No. 11, 2015, pp. 486-500.
- [22] Lee, J. S. and Park, S. D., "Performance Improvement of Movie Recommendation System using Genre-wise Collaborative Filtering", *Journal of Korea Intelligent Information System*. Vol. 13, No. 4, 2009, pp. 65-78.
- [23] Lee, S. Y., "A Study on Omni Channel Case and Strategy in Domestic Large-scale Distributors", *Journal of the Korean Society of Design Culture*, Vol. 21, No. 4, 2015, pp. 477-488.
- [24] Lee, S. Y., "A Study on the State and Brand Differentiation Strategies of Korean-style Drug Stores", *Journal of the Korean Society of Design Culture*, Vol. 22, No. 2, 2016, p. 443.
- [25] Lu, T. and Wu, K., "A transaction pattern analysis system based on neural network", *Expert System with Applications*, Vol. 36, No. 3, 2009, pp. 6097-2099.
- [26] Nam, K. W., Park, S. S., Shin, Y. K., and Jang, D. S., "An Analytical Study on Research trends of Web-based Recommendation System", *The Korean Operations Research and Management Science Society Spring Joint Meeting*, 2008.
- [27] Park, J. H., "The Effect of Perceived Customer

- mer Orientation to Emotional Presence, Commitment and Customer Satisfaction in E-Learning”, *Journal of Digital Convergence*, Vol. 10, No. 10, 2012, pp. 139-146.
- [28] Park, J. H., Cho, Y. H., and Kim, J. K., “Social Network : A Novel Approach to New Customer Recommendations”, *Journal of Intelligent Information Systems*, Vol. 15, No. 1, 2009, pp. 123-140.
- [29] Park, W. B., Cho, Y. S., and Ko, H. H., “Clustering Method of Weighted Preference Using K-means Algorithm and Bayesian Network for Recommender System”, *Journal of Information Technology Applications and Management Special Section*, 2013, pp. 219-230.
- [30] Radeder, T. and Chawla, N. V., “Modeling a store’s product space as a social network”, *Proceeding of the international conference on advances in social network analysis and mining*, Athens Greece, 2009, pp. 164-169.
- [31] Ricci, F., Rokach, L., Shapira, B., and Kantor, P. B., *Recommender Systems Handbook*, 2011.
- [32] Sarwar, B., Karypis, G., Konstan, J., and RIEDL, J., “Analysis of Recommendation Algorithm for E-Commerce”, Proceedings of ACME-commerce conference, 2000, pp. 158-167.
- [33] Schonberger, V. M. and Cukier, K., *Big data : a revolution that will transform how we live work and think*, John Murray, 2013.
- [34] Shmueli, G., Nitin, R. P., and Perter, C. B., *Data Mining for Business Intelligence : Concept, Techniques, and Applications in Microsoft Office Excel with XLMiner*, John Wiley and Sons, 2006.
- [35] Song, H. S., Joo, S. J., and Lee, J. H., “The Effect of Social Information on Recommendation Performance According to the Product Involvement Level”, *Journal of Information Technology Applications and Management*, Vol. 21, No. 4, 2014, pp. 361-379.
- [36] Yoo, J. J. and Cho, Y. S., “Trends in Technical Development and Standardization of Indoor Location Based Services”, *ETRI Journal*, Vol. 20, No. 5, 2014, pp. 51-61.

■ 저자소개



Nam Ki Kim

Nam Ki Kim is currently in the doctoral program in Kyungil University Business School. He had worked in Daegu Department Store for 24 years. He

received Master's degree in Yeongnam University Business School and bachelor's degree in Keimyung University. He interested in Social network analysis, recommendation system, and e-CRM for his research.



Seok Bong Jeong

Seok Bong Jeong is currently a Professor of school of Business, Kyungil University. He received the B.S. degree in Industrial Management and the

M.S. and Ph.D. degree in Industrial Engineering from KAIST. He worked for SAMSUNG SDS and Ernst & Young as a IT consultant and participated in several IT Projects. His research interests are in the areas of Big Data Analysis, Business Intelligence, and Machine Learning.