

RFM 다차원 분석 기법을 활용한 암시적 사용자 피드백 기반 협업 필터링 개선 연구

이재성

과학기술연합대학원대학교
과학기술경영정책학과
(jslee@kisti.re.kr, jaeseong.lee@ust.ac.kr)

김재영

아주대학교 미디어학부
(jaykim8809@gmail.com)

강병욱

경기대학교 산업공학과
(sin7389@gmail.com)

전자상거래 시장의 이용이 보편화 되며 고객들에게 좋은 품질의 물건을 어디서, 얼마나 합리적으로 구매할 수 있는지가 중요해졌다. 이러한 구매 심리의 변화는 방대한 정보 속에서 오히려 고객들의 구매 의사결정을 어렵게 만드는 경향이 있다. 이때 추천 시스템은 고객의 구매 행동을 분석하여 정보 검색에 드는 비용을 줄이고 만족도를 높이는 효과가 있다. 하지만 대부분 추천 시스템은 책이나 영화 등 동종 상품 분류 내에서만 추천이 이뤄진다. 왜냐하면 추천 시스템은 특정 상품에 매긴 구매 평점 데이터를 기반으로 해당 상품 분류 내 유사한 상품에 대한 구매 만족도를 추정하기 때문이다. 그밖에 추천 시스템에서 사용하는 구매 평점의 신뢰성에 대한 문제도 제시되고 있으며 오프라인에선 평점 확보 자체가 어렵다. 이에 본 연구에서는 일련의 문제를 개선하기 위해 RFM 다차원 분석 기법을 활용하여 기존에 사용하던 고객의 구매 평점을 객관적으로 대체할 수 있는 새로운 지표의 활용 가능성을 제안하는 바이다. 실제 기업의 구매 이력 데이터에 해당 지표를 적용해서 검증해본 결과 높게는 약 55%에 해당하는 정확도를 기록했다. 이는 총 4,386종에 달하는 이종 상품들 중 한번도 이용해본 적 없는 상품을 추천한 결과이기 때문에 검증 결과는 상대적으로 높은 정확도와 활용가치를 의미한다. 그리고 본 연구는 오프라인의 다양한 상품데이터에서도 적용할 수 있는 범용적인 추천 시스템의 가능성을 시사한다. 향후 추가적인 데이터를 확보한다면 제안하는 추천 시스템의 정확도 향상도 기대할 수 있다.

주제어 : 협업 필터링, 개인화상품추천, 추천시스템, 기계학습, 수요예측

논문접수일 : 2018년 6월 2일 논문수정일 : 2018년 12월 14일 게재확정일 : 2019년 1월 26일
원고유형 : 학술대회(급행) 교신저자 : 이재성

1. Introduction

온라인 채널을 통한 쇼핑은 모바일과 인터넷 산업의 성장 등에 힘입어 2001년 약 3.3조 원이었던 거래 액이 2015년에 약 53.9조 원으로 16.1배 커졌고, 15년간 연평균 22.0%의 성장세를 보인다(Department of Statistics Korea, 2016). 이러한 현상은 비단 우리나라에 국한된 것이 아니라 전세계적인 이슈로써, 전세계 전자상거래 시장

의 규모는 연평균 39% 이상씩 성장할 것으로 예상된다(Forrester Research, 2011). 전자상거래 시장이 급성장함에 따라 지난 10년 동안 개인화에 대한 관심이 커지고 있으며 추천 시스템의 발전은 더욱 가속화되고 있다(Potomniee, 2002).

전자상거래 시장의 발전은 고객들의 소비채널 뿐만 아니라 고객들의 구매 행동에도 많은 영향을 끼쳤다. 오늘날 ‘쇼루밍족(Showrooming)’이라는 개념의 대두가 바로 이러한 영향의 결과물

이다. 이제 고객들은 무엇을 살지 결정하는데 ‘어디서’, ‘어떻게’ 라는 문제가 상당한 고민거리다. 다시 말해 고객들에게 좋은 품질의 물건을 어디서, 얼마나 합리적인 가격으로 구매할 것인가라는 문제가 중요해졌다(Kotler, 2012).

주목할 점은 구매 후 새로이 나타난 행동양상이다. 이제 고객들의 구매 행동은 기존의 개인적 경험만이 아니라 고객들 간에 새로운 경험과 그 경험의 공유를 통해 획득한 정보를 바탕으로 최종 구매 결정이 이뤄진다. 실제로 사용자들 대부분은 다른 사람들의 후기나 추천에 의해 상품을 구매하는 양상을 보인다. 따라서 상품 구매 후 만들어지는 구매 평점은 기존에 사용되고 있는 추천 알고리즘에 있어서 굉장히 중요한 부분으로 작용한다(Kim et al., 2008; Park et al., 2012).

하지만 상당수의 구매 평점이 누락되고 있는 것이 현실이다. 기업에서는 포인트 적립 등의 방법으로 온라인 쇼핑 이용자에게 평점을 남기도록 유도하고 있지만 이러한 노력에도 불구하고 귀찮음과 같은 이유로 많은 사람들의 적극적인 참여 유도가 어렵다. 그나마 모인 평점 데이터들의 일부는 광고 등의 목적으로 작성되는 것이다. 또한 여전히 중요한 비중을 차지하는 오프라인 채널에서의 구매 평점은 수집 자체가 어렵다.

특히 광고 등의 목적으로 작성된 평점 데이터는 해당 점수의 신뢰성에 오류가 있을 여지가 크다. Herlocker et al.(2004)는 ‘Magic barrier’라는 개념을 들어 사용자의 생각을 정해진 척도로 환산 할 때 발생하는 노이즈의 문제를 지적한다. 이러한 노이즈는 불가피하며 사용자의 평점 데이터의 신뢰도나 내적 일관성을 떨어뜨리고 알고리즘의 정확도를 낮추기 때문에 어떤 조건에 따라 노이즈가 증가하거나 줄어드는지 알아보며 노이즈를 줄이기 위한 방안을 모색할 필요가 있

다고 강조한다. Nguyen et al.(2013)도 평가 행위에서의 노이즈를 없애면 추천 시스템의 정확도가 높아질 수 있다고 가정하고 있으며 이를 줄이기 위한 심도 깊은 고민을 했다.

그래서 본 연구에서는 이러한 문제점을 개선하기 위해 새로운 척도를 사용하는 추천 시스템을 제안한다. 이는 고객의 구매 특성과 기간을 가중치로 고려한 방법으로 주관적인 기존의 평점 대신에 객관적인 방법을 통해 새로운 지표를 사용하기 때문에 상품 추천을 보다 정량적으로 수행할 수 있다는 특징이 있다.

본 논문의 구성은 다음과 같다. 제 2장에서는 관련 연구에 대한 설명을 하며, 제 3장에서는 제안하는 기법에 대해 서술한다. 제 4장에서는 2014~2015년 2년치에 달하는 실제 구매 이력 데이터를 활용해 진행한 실험 내용과 모델의 성능을 검증한다. 그리고 마지막 제 5장에서는 본 연구에 대한 결론을 기술한다.

2. Theoretical Background and Research Model

2.1 구매 이력 데이터를 이용한 개인화 추천 시스템 연구와 한계점

오늘날 방대해진 정보의 양 때문에 고객 마케팅을 위한 수단으로 개인화된 추천 시스템이 각광받고 있다. 이와 관련해서 가장 널리 알려진 사례는 아마존(Amazon)과 넷플릭스(Netflix)가 있다. 아마존의 경우 추천의 60%가 상품구입으로 이루어지고 있으며, 35%의 매출 증진 효과를 기록하였다. 한편 넷플릭스의 경우는 영화 추천의 75%가 서비스 이용으로 이루어지고 있는 것

으로 나타났다(McKinsey, 2013).

이처럼 개인화 기법은 영업사원이 존재하지 않는 온라인 시장에서 유용하게 사용될 수 있는 일대일 마케팅의 핵심 전략으로 꼽히고 있다. 왜냐하면 고객의 취향을 분석하여 선호하는 상품을 추천함으로써 구매를 유도하고 교차판매를 위한 추가적인 상품구입을 권유할 수도 있기 때문이다. 따라서 기업은 개인화 기법을 통해 고객의 특성 집합에 따른 차별화된 맞춤형 서비스를 제공할 수 있고, 고객의 니즈(Needs)를 충족시킬 뿐만 아니라 고객이 정보를 검색하는데 소요되는 비용을 감소시킴으로써 고객의 만족도를 제고시키기 때문에 궁극적으로 기업의 매출 증대를 유도할 수 있다(Yun and Yoon, 2005).

이렇게 고객에게 개인화된 서비스를 제공하는 기법을 일컬어 개인화 추천 기법이라 한다. 또한 이러한 추천 기법을 적용한 시스템을 일컬어 추천 시스템이라고 부른다. 이러한 추천 시스템은 기업이 제공하는 서비스의 성격과 특징에 따라 다양한 추천 기법과 혼합적으로 사용되기도 한다. 오늘날 추천 시스템에 주로 활용되고 있는 추천 기법으로는 협업(Collaborative) 필터링과, 내용 기반(Contents-based) 필터링 등이 있다(Choi and Kim, 2013). 더욱이 이러한 기법들을 혼합하여 사용하는 하이브리드 기법이나 연관 규칙(Association rule) 등도 여러 분야에서 활용되고 있는 추세이다(Kim et al., 2004; Kim and Moon, 2006; Ahn et al., 2012).

이중에서도 협업 필터링 추천 기법이 오늘날 가장 많이 사용되고 있다. 협업 필터링은 과거에 상품을 구매하거나 평가하는데 있어서 유사한 성향을 보였던 사용자들은 다른 상품에 대해서도 유사한 성향을 보일 것이라는 가정을 바탕으로, 선호도 또는 구매 행동이 유사한 이웃 고객

군이 선호하는 상품을 추천하는 방법이다(Kim et al., 2016).

협업 필터링 기법을 기반으로 하는 추천 시스템에 대한 주요 연구로는 Minnesota대학의 Grouplens Project(Konstan et al., 1997), MovieLens(Good et al., 1999), Tapestry(Shardanand and Maes, 1995) 및 BroadVision의 Bell core video 추천 시스템(Chen, 2000), 그리고 버클리 대학의 Jester(Goldberg et al., 1999), MIT대학의 음악 추천 시스템인 RINDO(Claypool et al., 1999), PHOAKS(Parthasarathy et al., 1999) 등이 있다.

일련의 주요 연구는 오늘날 아마존과 넷플릭스 사례를 통해 밝혀진 협업 필터링의 우수성을 설명하는 기초가 되었다. 한편 협업 필터링의 단점으로는 데이터의 희소성(sparsity)과 데이터의 확장성(scalability) 문제가 있다. 그로 인해 충분한 평점이 쌓이기 전까지는 새로운 상품을 추천할 수 없는 Cold-start문제를 야기한다. 때문에 최근에는 협업 필터링의 가장 큰 문제점인 희소성과 확장성을 해결하기 위한 연구가 주로 수행되어 왔다(Kim et al., 2004; Yun and Yoon, 2005; Oh and Moon, 2010; Ahmed et al., 2011; Kwon and Hong, 2013; Lee et al., 2014; Yu, 2016). 하지만 조사된 선행연구들은 모두 온라인 채널에서 발생하는 희소성과 확장성 문제를 다루고 있다는 한계가 있다. 본 연구는 오프라인 채널에서도 기능할 수 있도록 확장성 문제를 개선한 추천 시스템을 제안하는데 차별성을 갖는다.

2.2 구매 평점의 객관적 타당성에 관한 연구

앞서 살펴보았듯이 추천 시스템은 사용자 기반, 아이템 기반, 그리고 하이브리드의 다양한 종류를 갖는다. 그러나 상이한 작동 방식에 관계

없이 각각의 추천 시스템들은 모두 하나의 공통된 관심사를 공유하고 있다. 이들의 관심사는 사용자의 취향을 모델링 하는데 목적을 두고 있기 때문에 사용자의 취향을 추론하기 위해서 어떻게든 사용자로부터 긍정과 부정의 지표를 얻어내야만 한다(Amatrion et al., 2009).

이때 사용자의 선호를 나타내는 지표로는 크게 암시적(Implicit) 피드백과, 명시적(Explicit) 피드백으로 구분한다. 암시적 피드백은 보다 간접적으로 사용자의 선호를 다른 정보로부터 추론하는 방법을 일컫는다. 반면 명시적 피드백은 보다 직접적인 방법으로 사용자의 선호를 파악하는 방법을 말한다. 특히 암시적 피드백을 위한 접근에서 사용자 선호는 과거의 구매 행동을 관찰함으로써 추론된다(Oard and Kim, 1998).

반면 명시적 피드백을 이용하는 접근 방식은 사용자에게 상품에 대한 자신의 선호를 기록하게 하는 부담을 부여하는 특징이 있고, 일부 사용자가 자신의 선호에 대한 기록을 남김으로써 얻는 인센티브(Harper et al., 2005)에 의해 본래 의도와 다르게 반응할 수도 있음에도 불구하고 대부분의 상황에서 명시적인 데이터가 더 안정적이라고 일반적으로 인정되고 있다(Amatrion et al., 2009).

하지만 이러한 인식은 어디까지나 고객들이 특정 상품을 이용한 만족도에 따라 구매 평점을 충실히 남긴다는 가정에 기초하고 있다. 더욱이 '보상형 리뷰'의 등장으로 할인된 가격이나 무료로 상품을 제공 받고 좋은 평점과 리뷰를 남기는 등 인센티브에 대한 약용이 발생하고 있다.

실제로 아마존의 경우 지난 16년부터 이러한

'보상형 리뷰'에 대해 엄격하게 제재를 가하며 거짓 정보를 줄이고 신뢰성을 높이기 위한 강경책을 냈다.¹⁾ 관련 조사결과 '보상형 리뷰'가 있는 상품에 대한 평균 평점은 '보상형 리뷰'가 없는 상품들보다 높은 수치를 기록했다. 그리고 '보상형 리뷰'가 가장 낮은 평점을 줄 가능성을 약 12배, 비판적인 의견을 남길 확률을 약 4배 가량 낮추는 것으로 밝혀졌다.²⁾

이렇듯 고객 평점에는 다양한 노이즈(Noise)가 가득하다. 이러한 문제는 대부분의 전자 상거래에서 고(高)만족 고객들을 유치함으로써 이윤을 극대화시키는 기능을 목적으로 하는 추천 시스템의 성능과 직결된다(Said et al., 2012). 이에 대해 Herlocker et al.(2004)는 고객이 남긴 평점의 심각한 내적 일관성의 불일치 문제를 'Magic barrier'라는 개념을 통해 역설했다. 이 개념은 추천 시스템에서 평점의 예측에 대한 정확도에 한계를 규정하며, 그 이상의 정확도 개선을 무의미하게 만드는 특징을 갖는 심각한 문제를 발생시키는 것으로 밝혀졌다(Bellogin et al., 2014).

이러한 문제와 관련해서 암시적인 방법들을 이용하여 고객에게 제품에 대한 평가의 요구로 인한 번거로움과 이로 인한 평가 정보의 부족을 줄이는 방향으로 연구가 된 바 있다(Park and Chang, 2005). 이에 본 연구에서도 암시적 피드백 접근을 통해 기존 명시적 피드백을 이용할 때 발생하던 'Magic barrier' 이슈를 극복하고 온라인 채널과 더불어, 사용자가 구매 평점을 남기기 힘든 오프라인 채널에서 구입한 제품의 추천까지 확장할 수 있는 새로운 지표를 적용한 시스템을 제안한다.

1) Techcrunch, "Amazon bans incentivized reviews tied to free or discounted products," 4th Oct, 2016.

2) Reviewmeta, "Analysis of 7 million Amazon reviews: customers who receive free or discounted item much more likely to write positive review," 29th June, 2016

2.3 RFM 고객 다차원 분석 기법에 대한 연구

고객을 세분화하는 방법으로 CRM에서 주로 사용되고 있는 RFM 분석 기법은 Hughes(1994)에 의해 고안되었다. 이 기법은 데이터베이스에 축적된 고객 데이터를 활용하여 고객들의 상품 구매의 최근성(Recency)과, 구매 빈도(Frequency), 구매금액(Monetary)등 기업의 이윤 창출에 대한 기여도를 점수로 부여한다. 그리고 다양한 기준으로 고객의 등급을 세분화하고 이를 기반으로 개인화된 맞춤형 마케팅 전략을 수립하는데 사용되는 모델이다(Newell, 1997; Hsieh, 2004; Wu and Lin, 2005; Chan, 2005; Cheng et al., 2009; Wei et al 2013).

RFM 분석 기법이 주목받고 있는 이유는 오늘날 고객의 니즈(Needs)가 다양해 지면서 고객 가치에 기반을 두고 있는 고객 세분화의 필요성이 증가했기 때문이다. 이는 상위 20%의 고객이 기업 매출의 80%를 창출한다는 기존의 파레토 법칙(Pareto principle)을 따르며 가능한 많은 고객을 상위 고객으로 끌어올리기 위한 집중적인 마케팅 전략을 위해 지난 30년 동안 발전했다.

이 모델을 사용하기 전에 기업은 일반적으로 고객을 대상으로 인구통계학적인 분류를 통한 마케팅을 실시했다. 그러나 RFM 분석 기법을 통해 소비자의 과거 구매 이력 정보가 단순 인구 통계 정보보다 미래의 구매 행동을 예측하는데 더 나은 정확도를 보인다는 것이 밝혀졌다(Li and Ha, 2011).

일반적으로 RFM을 나타내는 구성요소로써 구매의 최근성(R)은 고객의 마지막 구매가 일어난 시점을 측정 기준일에서 차감한 날짜로 측정한다. 또한 구매 빈도(F)는 특정 기간 동안 구매가 몇 번이나 일어났는지를 나타내는 변수를 말

한다. 그리고 구매금액(M)은 특정 기간 동안 고객이 소비한 총 구매액을 나타낸다(Jeong et al., 2015).

이때 RFM 모형을 구성하는 각 변수의 점수를 정하고, 이를 다시 합산하는 여러가지 방법이 개발되어 있다. 가장 일반적인 방법으로는 각각의 구성 요소들을 동일하게 20%씩 나누는 5점 체계를 사용하기도 하며, 10%씩 나누는 10점 체계 등 다양하게 계산하고 있다. 그리고 Rogers(1962)가 신제품을 수용하는 집단을 통계적 분포를 이용하여 ‘혁신층’, ‘조기수용층’, ‘조기 다수층’, ‘후기 다수층’, ‘후발 수용층’으로 각각의 집단을 정의한 것처럼 군집분석을 통해 각각의 분포를 고려한 점수 체계를 설계할 수도 있다.

이러한 RFM 분석 기법은 스포츠(Choi, 2012), 병원(Lee et al., 2005; Ahn, 2010), 백화점(Ha and Beak, 2004), 미용 산업(Wei et al., 2013) 등 다양한 산업분야에서 폭넓게 응용되고 있다. 예컨대, Hong and Kim(2010)은 RFM 모형을 이용하여 고객을 등급화하여 나눈 뒤, 각 등급별 고객들의 구매액을 예측하는 SVR(Support Vector Regression) 모형을 연구한 바 있다. 특히 Park et al.(2005)는 주로 고객 정보를 기준으로 마케팅에 활용하던 기존 RFM 모델을 확장시켜 기준을 상품에 적용하여 상품구성을 분석하는데 해당 분석 기법을 사용하였다.

특히 본 연구에서는 Park et al.(2005)가 상품을 평가하는데 사용한 RFM 분석 기법에 주목하였다. 기존 고객 평점 역시 구매자의 만족도를 의미하며 고객의 재구매 가능성을 의미하는 지표이기 때문에 RFM의 본래 사용 취지와 크게 이질적이지 않다고 판단했다. 그래서 새로운 지표로써 RFM을 응용한 암시적 피드백의 활용성을 실험을 통해 평가했다.

3. Research Design

3.1 실험 데이터 및 연구 방법론

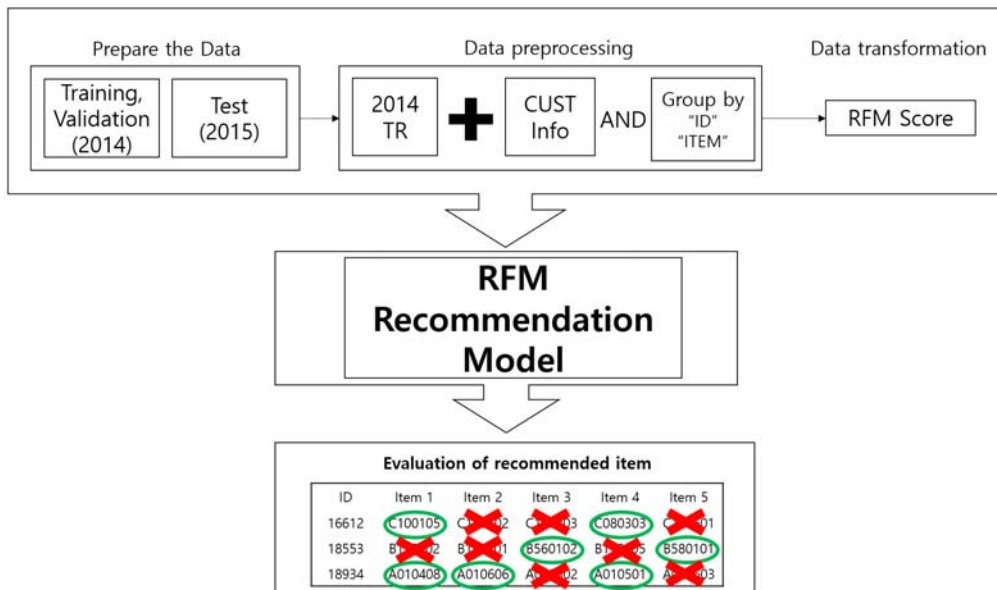
본 연구에서 사용된 데이터는 다음과 같은 특징을 갖는다. 본 연구는 기존의 RFM을 구성하고 있는 각각의 요소들인 거래의 최신성(Recency) 과 거래의 빈도성(Frequency), 그리고 거래의 규모성(Monetary)으로 이루어진 변수들에 대한 조작적 정의를 통해 추천 시스템에서 사용될 고객의 평가 지표로 제안한다. 본 연구에서는 데이터 필드의 한계로 인해서 고객의 구매 행동을 예측하는데 영향을 줄 만한 소비자 물가, 소득수준, 기준금리 등의 외부환경 요인에 대해서는 외생 변수로 고려했다. 따라서 본 연구에서 제안하는 추천 시스템을 구축하는데 일련의 외생변수들은 사용되지 않았다.

연구 방법론에 대한 약술은 다음과 같다. 본

연구에서 제안하는 RFM 점수를 고객평점으로 대체하여 고객과 상품으로 이루어진 매트릭스를 구축했다. 이후 14년도에 해당하는 고객-상품 매트릭스 데이터 세트를 이용하여 사용자 기반 협업 필터링(User Based Collaborative Filtering)의 알고리즘을 k겹 교차검증(K-fold cross validation)으로 모델을 학습시킨 후, 15년도 구매 이력 데이터와 비교 및 검증을 수행했다. 모든 과정은 Windows OS, R version 3. 3. 1 환경에서 진행했다.

3.2 사용 데이터

본 연구에서 사용한 데이터는 롯데멤버스, L.POINT|L.pay, 제3회 L.POINT Big Data Competition에서 제공받았다. 2017년에 들어 4회제를 맞이하는 L.POINT Big Data Competition은 롯데그룹의 통합멤버십 서비스 L.POINT에서 제



〈Figure 1〉 Research model Design

공하는 실제 구매 데이터를 바탕으로 빅데이터를 분석하고 주제에 맞는 콘텐츠를 개발하는 국내 대표 빅데이터 공모전이다.

L.POINT Big Data Competition은 다양한 소비 영역에서의 고객 행동 빅데이터를 통해 L.POINT만의 차별화된 가치를 창출할 수 있는 빅데이터 분석 전문가를 발굴하는데 목적을 두고 있다.³⁾ L.POINT는 롯데멤버스에서 40여 개 롯데그룹 계열사 및 외부 제휴사를 결합한 통합 멤버십 브랜드로써, 3,600만 회원들을 보유하고 있기 때문에 대한민국 국민의 60% 이상에 달하는 광범위한 생활 데이터를 가지고 있다. 그 중에서도 본 연구에서 사용된 데이터는 기업뿐만 아니라 학교에서도 실제 현장 데이터를 활용할 수 있도록 비상업적 용도와 연구목적으로 사용할 수 있도록 배포된 데이터로써⁴⁾, 하이마트, 더영, 룩스, 롯데마트 다동이 멤버십을 이용하고 있는 19,383명의 고객의 구매내역 중 14년도와 15년도에 해당되는 부분을 실험에 사용했다. 구매 상품은 총 717개의 중분류를 가지고 있으며, 총 4,386종의 상품에 대한 정보를 담고 있다. 따라서 추천 시스템에 사용된 데이터는 19,383명의 고객 행과 4,386개의 상품 열로 이루어진 총 28,593,030개의 구매 이력 정보를 사용했다.

메타데이터는 아래 <Table 1>과 같이 고객정보 데이터에는 고객번호, 성별, 연령대, 거주지역으로 이루어져 있고 구매내역 데이터에는 영수증번호, 대분류코드, 중분류코드, 소분류코드(상품코드), 고객번호, 점포코드, 구매일자, 구매시간, 구매금액으로 구성되어있다. 하지만 본 연구에서는 고객번호와 성별, 연령대, 소분류코드, 구매일자, 그리고 구매금액 변수만을 사용했다.

3.3 데이터 전처리

3.3.1 고객 집단 세분화 방법

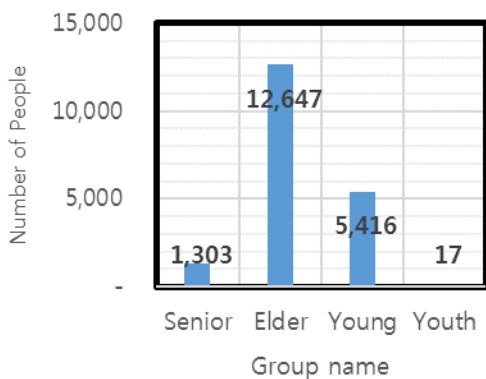
본 연구에서 사용한 데이터는 식·음료품부터 의류, 화장품 또는 가전제품 등 다양한 종류의 제품군을 다루고 있다. 따라서 이렇게 다양한 종류의 상품들의 구매 예측을 하기 위해서는 고객의 상품 구매에 영향을 미칠 수 있는 통제변수에 대한 고려가 필요했다. 하지만 본 연구에서 사용한 고객 정보 데이터에는 아래 <Table 1>과 같이 성별, 연령, 지역에 대한 정보만 존재했다. 그래서 본 연구에서는 연령과 성별 정보를 사용한 인구통계학적 통제만 수행했다. 구체적으로 고객의 분류를 위해 연령에 해당하는 변수를 20세 미만(Youth), 20~30대(Young), 40~50대(Elder), 60대 이상(Senior)로 4개로 조작성 정의를 내렸다. 그 결과 집단의 크기는 아래 <Figure 2>과 같이 Youth 집단은 17명, Young 집단은 5,416명, Elder 집단은 1,2647명, Senior 집단은 1,303명으로 구분됐다. 이후 이를 마찬가지로의 방법을 통해 성별(M : Male, F : Female)로 다시 한번 분류했고, 전체 구매내역을 14년도와 15년도로 나누며 총 16개의 데이터 셋을 준비했다. 하지만 앞서 살펴본 집단 별 크기에서 youth집단의 경우 데이터의 표본의 수가 다른 집단에 비해 현저하게 낮았기 때문에 본 연구에서는 해당 집단을 제외한 나머지 3개 집단만을 실험에 이용했다. 따라서 총 19,383명의 고객 정보에서 17명의 정보가 누락되었고 전체 비율로는 0.09%를 제외한 99.01%의 고객 정보가 실험에 사용됐다.

3) 롯데멤버스, “제4회 L.POINT Big Data Competition 개최,” 스포츠조선, 13th Nov, 2017.

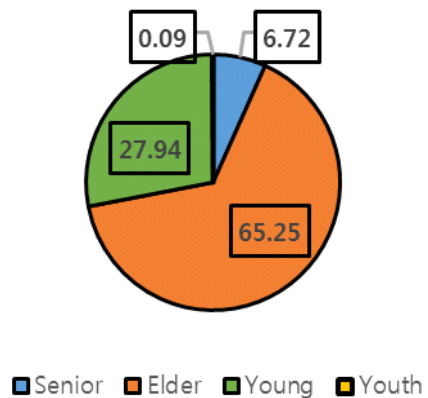
4) 롯데멤버스 “제3회 엘포인트 빅데이터 컴퍼티션 시상식 개최,” 중앙일보, 2th March, 2017.

〈Table 1〉 Usage Data and Variable Description

Data	Column	Description	Notation
고객정보	고객번호	고객의 고유 식별번호	1~19383
	성별	고객의 성별	F, M
	연령대	고객의 연령대	19세이하, 20~24세, 25~29세, 30~34세, 35~39세, 40~44세, 45~49세 50~54세, 55~59세, 60세이상
	거주지역	거주지역 신(新)우편번호 앞 3자리	60, 100, 33, 16 등
구매내역	채휴사	롯데 그룹 4개 계열사	A, B, C, D
	영수증번호	구매내역의 고유 식별번호	8664000, 8664001 등
	대분류코드	상품 대분류 카테고리 코드성 정보	15, 16, 18 등
	중분류코드	상품 중분류 카테고리 코드성 정보	1504, 1601, 1803 등
	소분류코드	상품 소분류 카테고리 코드성 정보	A010101, A010102 등
	고객번호	고객의 고유 식별번호	1~19383
	점포코드	구매가 발생한 점포 코드성 정보	44, 45, 11 등
	구매일자	구매가 발생한 일자	20140101~20151231
	구매시간	구매가 발생한 시간대	20, 21, 22 등
	구매금액	구매한 상품의 금액	2420, 1070, 8060 등



〈Figure 2〉 Number of customers by age



〈Figure 3〉 Percentage of customers by age

3.3.2 평점 대체할 RFM 지표 산출 방법

기존 경영학 분야에서 주로 쓰이는 다차원 분석 중 하나인 RFM 분석을 본 실험 데이터에 적용하기 위해서 기존의 RFM 분석 기법을 연구 성격에 알맞게 변형했다. 본 연구에서 사용된 RFM의 조작적 정의는 <Table 2>와 같다. R은 고객의 상품에 대한 최근 관심도를 의미한다고 정의했고, 최근 구매한 상품일수록 관심도가 높음을 의미한다. F는 고객의 관심의 정도로, M은 고객의 상품에 대한 가치를 표현 한다고 정의했다.

이후 이렇게 정의한 각각의 지표를 계산하는 과정을 수행했다. R점수는 2014년 12월 31일을 기준으로 최근 구매일 계산을 하기 위해서 우선, 차감 일수를 구했다. 그리고 이 차감 일수의 최대값과 최소값을 뺀 후 10%씩 상대구간으로 나누는 뒤, 각 구간에 1점부터 10점까지 차례대로 점수를 부여했다. 그리고 F점수는 전체 데이터에서 고객의 상품별 구매 횟수를 계산하였고, M점수를 구하기 위해 고객의 상품별 총 구매 금액을 점수분포에서 10개의 구간 등급(rank)으로 나누고, 마찬가지로 각 구간에 1점부터 10점까지 차례대로 점수를 부여했다. 이후 각각의 세 점수를 기존 RFM 기법에서 적용하는 것과 마찬가지로 합산하여 하나의 지표로 표현했다.

위와 같은 방법을 통해 정량화한 지표는 4,386종에 달하는 각각의 상품에 대하여 고객의 구매 가능성이 어느 정도인가를 나타낸다. 따라서 이후 실험에서는 RFM 지표를 구매 가능성이 높은 고객집단끼리 유사도 계산을 통해 새로운 상품을 추천해주는 사용자 기반 협업 필터링에 적용해보고 추천의 정확도를 검증했다.

4. Research Result

4.1 결과 해석

고객이 직접 상품에 대해 매긴 구매 평점으로 대표되는 명시적 사용자 피드백 기반의 본래 추천 시스템과 비교해 본 연구에서 제안하는 RFM 암시적 사용자 피드백 점수 산출 결과가 과연 얼마나 활용가능한지에 대한 판단이 필요했다. 그래서 우선 특정 고객의 구매 이력 정보를 토대로 특정 고객이 구매한 상품에 대한 각각의 RFM 점수를 도출했다.

아래 <Table 3>는 집단 F_elder에 속한 798명의 고객에 대한 RFM 점수 산출 결과의 일부를 나타낸다. 예컨대 798번의 고객이 구매한 제품들은 총 38종에 달하며 구매 빈도와 거래규모, 그

<Table 2> Operational definition of RFM

Index Term	Definition of RFM	Operational definition of RFM
Recency	고객이 얼마나 최근에 구입했는가?	고객이 해당 상품을 얼마나 최근에 구입했는가?
Frequency	고객이 얼마나 빈번하게 자사 상품을 구입했는가?	고객이 해당 상품을 얼마나 빈번하게 구입했는가?
Monetary	고객이 구입했던 상품들의 총 금액은 어느 정도인가?	고객이 해당 상품을 구입한 총 금액은 어느 정도인가?

〈Table 3〉 Example of RFM score(ID 798 in F_elder Group)


ID	Item code	RFM	Group	ID	Item code	RFM	Group
798	B100601	6	F_elder	798	C070103	30	F_elder
798	B120301	6	F_elder	798	C080101	15	F_elder
798	B120603	6	F_elder	798	C080102	8	F_elder
798	C010106	15	F_elder	798	C080103	29	F_elder
798	C020201	15	F_elder	798	C110203	28	F_elder
798	C030109	6	F_elder	798	C120501	30	F_elder
798	C030202	8	F_elder	798	C130206	8	F_elder
798	C030204	28	F_elder	798	C130501	28	F_elder
798	C030205	15	F_elder	798	C130504	15	F_elder
798	C030206	28	F_elder	798	C130708	7	F_elder
798	C030401	28	F_elder	798	C130803	16	F_elder
798	C030403	17	F_elder	798	C140305	17	F_elder
798	C030404	29	F_elder	798	C140405	8	F_elder
798	C030901	29	F_elder	798	C150202	6	F_elder
798	C040120	28	F_elder	798	C150205	7	F_elder
798	C050209	8	F_elder	798	C150401	15	F_elder
798	C050304	29	F_elder	798	C160504	8	F_elder
798	C060503	6	F_elder	798	C160915	16	F_elder
798	C070101	29	F_elder	798	C170152	17	F_elder

리고 거래의 최신성을 고려한 RFM 점수는 6에서 30까지 다양하게 분포하고 있음을 알 수 있다. 그 중 C070103(가공우유), C120501(막걸리), C080103(냉장 드레싱) 제품이 각각 30, 30, 29의 순으로 높은 RFM 점수를 기록했다. 반면 B100601(치즈), B120301(국수면), B120603(통조림)에 해당하는 제품에는 각각 6의 낮은 RFM 점수를 나타낸다.

그리고 아래 <Figure 4>는 이를 다시 파레토 차트(Pareto chart)로 도식화한 것으로, 798번 고

객의 구매 내역의 RFM 점수 분포와 누적 비율을 히스토그램에 동시에 표현했다. 그 결과, 798번 고객은 각각 ‘고만족 제품군(28-30)’, ‘중만족 제품군(15-17)’, ‘저만족 제품군(6-8)’으로 나뉘는 구매 이력 정보를 가지고 있는 것으로 나타났다. 이러한 구매 이력 정보는 고객들을 유사집단으로 군집을 나누는데 사용된다.

즉 해당 사례를 통해 기존 구매 평점을 사용하는 명시적 사용자 피드백 기반의 추천시스템의 메커니즘과 본 연구에서 제안하는 RFM 암시적



〈Figure 4〉 Example of RFM score by product (ID 798 in F_elder Group)

사용자 피드백 기반의 추천 시스템 메커니즘에 큰 차이가 없음을 알 수 있었다. 왜냐하면 앞서 살펴보았듯이 RFM을 통한 점수 체계 역시 기존의 구매 평점과 같이 각각의 구매 상품에 대한 특정 고객의 만족도의 차이를 ‘고만족 제품군’, ‘중만족 제품군’, ‘저만족 제품군’으로 충분히 잘 설명하고 있기 때문이다.

이후 RFM 점수를 이용하여 협업 필터링 알고리즘에 기반한 추천 시스템의 추천 결과를 산출한 내용 중 일부가 아래 <Table 4>와 같다. 해당 결과는 연령대와 성별의 인구통계학 기반 정보를 토대로 앞서 총 6개로 나눈 각각의 집단에 속한 모든 고객에 대한 5개의 추천 결과를 의미한다. 예컨대 798번 고객에게는 C150302(쿠기), C150306(파이), C150403(옥수수스낵), C070203(떠먹는요구르트), C070202(마시는요구르트) 순서로 상품이 추천됐다. 이는 앞서 살펴본 <Table 3>과 비교해보면 주로 C 계열사를 이용하는 798번 고객에게 해당 계열사의 제품들로 알맞게 추천됨을 알 수 있다.

또한 C120501(막걸리), C070103(가공우유), C030901(일반계란), C030404(콩나물), C050304(닭가슴살), C070101(일반우유), C080103(냉장드레싱), C130501(식용유차), C110203(콜라), C040120(오징어)등 높은 RFM 점수를 보여줬던 ‘고만족 제품군(28-30)’으로 주로 가공우유, 유제품 등을 구매하는 구매 행동 등을 고려했을 때 해당 고객이 비록 C070203(떠먹는요구르트)나 C070202(마시는요구르트)를 구매한 적은 없지만, 충분히 구매를 고려할 법한 상품들이 적절히 추천된 것으로 볼 수 있다.

정확한 성능 평가를 위해서 RFM 점수를 기반으로 앞서 추천된 상품들에 대해 Validation 데이터 셋⁵⁾을 통해 k겹 교차검증(K-fold cross validation)을 수행했다. 그 결과 아래 <Table 5>와 같이 3번의 임의 추출한 Validation검증을 반복하여 평균을 구해놓은 정확도(이하 Precision)과 재현율(이하 Recall), 그리고 이 둘의 조화평균인 F1 Score 값을 도출할 수 있었다.

5) 본 연구에서는 2014년 구매 내역 데이터의 80%를 Training 데이터 셋으로, 20%를 Validation 데이터 셋으로 사용했으며, 2015년 실제 구매 내역 데이터 전체를 Test 데이터 셋으로 사용했다.

〈Table 4〉 Example of recommendation result (F_elder Group)

Id	Top1	Top2	Top3	Top4	Top5
795	A020302	A010202	A010644	A010607	A010104
796	B740101	B140202	B430302	B040101	B160101
798	C150302	C150306	C150403	C070203	C070202
799	A010202	A020302	A010644	A010207	A010613
800	A010201	A010603	A040214	A040215	A010501
801	A040222	A010613	A010710	A010644	A010407
802	B120201	B530401	B140103	B470104	A010404
805	C160201	C030404	C120201	C030202	C050209
806	A010608	A010202	A010405	A010653	A010509
808	A010603	A020701	A040229	A070608	A010614
809	B460101	B470104	B670402	B160201	B460501
810	A040224	A010302	A010101	A040601	A010103
811	A010501	A011004	A040223	A060114	A020306
812	A010101	A010608	A010902	A060166	A040229
813	C050205	C080304	C070203	C150306	C090101
814	A010302	A060114	A010501	A040224	A010404
815	A010301	A040222	A040229	A010613	A010707
816	A010602	A020306	A010301	A040214	A020109
818	B120201	B740101	B160201	B480202	B460203

〈Table 5〉 Validation data set evaluation result

Result \ Group	M_Young	M_Elder	M_Senior	F_Young	F_Elder	F_Senior
Precision	0.7540	0.7633	0.6886	0.7570	0.8010	0.7495
Recall	0.0514	0.0465	0.0546	0.0518	0.0453	0.0545
F1 score	0.0962	0.0877	0.1012	0.0970	0.0858	0.1016

F1 score를 구하는 이유는 다음과 같다. Precision은 전체 19,366명에 달하는 고객에게 추천한 5개의 상품 중 고객이 실제 구입한 상품의 개수를 추천된 모든 상품의 개수로 나눈 값을 의미한다. 그리고 Recall은 각각의 고객이 실제 구입한 모

든 상품 중 본 연구에서 제안하는 추천 시스템이 추천한 상품의 개수를 구한 값을 나타내기 때문에 Precision과 Recall은 필연적으로 상호 반비례의 관계를 가지게 되고, 이를 보완하기 위해 F1 score를 사용했다.

그 결과 Precision은 F_Elder(0.8010), M_Elder(0.7630), F_Young(0.7570), M_Young(0.7540), F_Senior(0.7495), M_Senior(0.6886)의 순서로 나타났다. Recall의 경우는 전술 한대로 Precision과 반대의 순서로 높은 값을 기록하였다. 한편 F1 Score는 F_Senior(0.1016), M_Senior(0.1012), F_Young(0.0970), M_Young(0.0962), M_Elder(0.0877), F_Elder(0.0858)의 순서로 높은 값으로 밝혀졌다.

이러한 값이 나타난 이유는 다음과 같이 생각해볼 수 있다. Elder에 해당하는 집단이 <Figure 3>과 같이 전체 고객의 약 65.2%나 차지해서 Precision을 구할 때 데이터 표본의 양이 많아 분류 정확도가 향상됐기 때문이다. 하지만 Recall을 구할 때는 데이터 표본의 양에 따라 고객이 실제 구입한 상품의 개수가 늘어나기 때문에 Recall의 값이 낮게 기록됐다. 왜냐하면 5개의 상품을 추천할 때 Precision의 표본 수는 19,366명에 대한 5개의 상품 추천 개수에 해당하기 때문이다. 하지만 Recall을 계산할 때의 표본 수는 19,366명의 고객이 각각 구입한 상품의 종류를 의미하며, 한사람의 고객이 적게는 수십 종에서 많게는 수백 종의 상품을 구입하기 때문이다. 그래서 Recall의 표본 수가 Precision의 표본 수보다 훨씬 높기 때문에 상대적으로 Recall의 값이 낮

게 기록됐다. 그래서 F1 Score를 살펴본 결과, 높은 Precision을 기록했던 집단 Elder보다 되려 집단 Senior의 추천이 더 정확한것으로 밝혀졌다.

본래 기계학습 기반의 모델링은 주어진 데이터를 기반으로 모델을 적합 시켜 분류 및 예측을 수행한다. 따라서 앞서 검증한 추천 시스템의 성능 또한 2014년에 해당하는 구매 이력 데이터를 통해 예측된 추천 결과를 반영한다. 하지만 오프라인 채널 데이터 특성 상 단순변심 및 할인행사 와 같은 단발적 구매 행위 등이 있을 수 있다. 따라서 보다 객관적인 성능 평가를 위해서 실제 구매 이력과 일치 정도를 분석했다.

그래서 본 연구에서는 특별히 2015년에 해당하는 구매 이력 데이터를 Test 데이터로 설정하여 2014년에 해당하는 구매 이력 데이터를 학습하여 얻어낸 추천 상품의 리스트 중 실제 구매 여부를 따졌다. 이때의 정확도는 추천된 상품이 2015년에 구매로 이어졌을 경우를 1로 아니면 0으로 두고 집단 별 고객의 추천 상품 개수와 실제 구매로 이어진 상품의 개수로 계산했다.

이때의 정확도는 각각의 집단을 추천의 정도가 높은 상품으로 상위 5개씩 구분하여 살펴보았는데 그 결과는 아래 <Table 6>과 같다. 실제 다음 년도 구매여부를 가지고 본 연구에서 제안하는 추천 시스템을 Test 데이터로 검증

<Table 6> Test data set evaluation result

Result \ Group	M_Young	M_Elder	M_Senior	F_Young	F_Elder	F_Senior
1st Item	0.5403	0.5059	0.4472	0.5493	0.5434	0.4705
2nd Item	0.5273	0.4505	0.3699	0.4798	0.4912	0.4057
3rd Item	0.5273	0.4505	0.3699	0.4328	0.4609	0.3886
4th Item	0.5273	0.4505	0.3699	0.4137	0.4264	0.3362
5th Item	0.4302	0.4250	0.3821	0.4001	0.4050	0.3352

한 결과는 F_Young(0.5493), F_Elder(0.5434), M_Young(0.5403), M_Elder(0.5059), F_Senior(0.4705), M_Senior(0.4472) 순서로 높은 정확도를 기록했다. 집단 F_Young의 정확도는 약 55%로 가장 높았으며 집단 Senior는 40%대로 다소 정확도가 떨어졌다. 이는 앞서 k겹 교차검증의 Precision 결과와 비교하면 적게는 약 14%에서 크게는 약 35% 가량 정확도가 떨어진 수치다.

특히 낮은 정확도를 기록한 집단 Senior는 앞서 k겹 교차검증의 Precision을 설명할 때와 같이 <Figure 3>에서 나타나듯 데이터 표본의 수가 낮아 학습에 필요한 충분한 데이터가 부족했던 것으로 생각된다. 게다가 실제 구매행위에 영향을 미칠 수 있는 고객의 단순변심, 단기 프로모션 이벤트 등의 다양한 외생변수에 대한 가능성을 감안했을 때 4,386종의 이종 상품 분류에 대한 본 추천 시스템의 Test 결과는 비교적 상당한 정확도로 이해할 수 있다. 또한 본 추천 시스템의 결과는 Training으로 사용된 2014년 구매 이력 정보 데이터에서 특정 고객이 일년 내내 한번도 구매한 이력이 없던 상품의 이용을 유인하여 실제 2015년에 매출을 발생시킨 것으로써, 비록 추천 정확도가 Test 단계에서 다소 떨어졌어도 기업의 입장에서 매출액 증진 효과로 봤을 때 상당한 유용성을 제공하는 것으로 생각된다.

4.2 토의

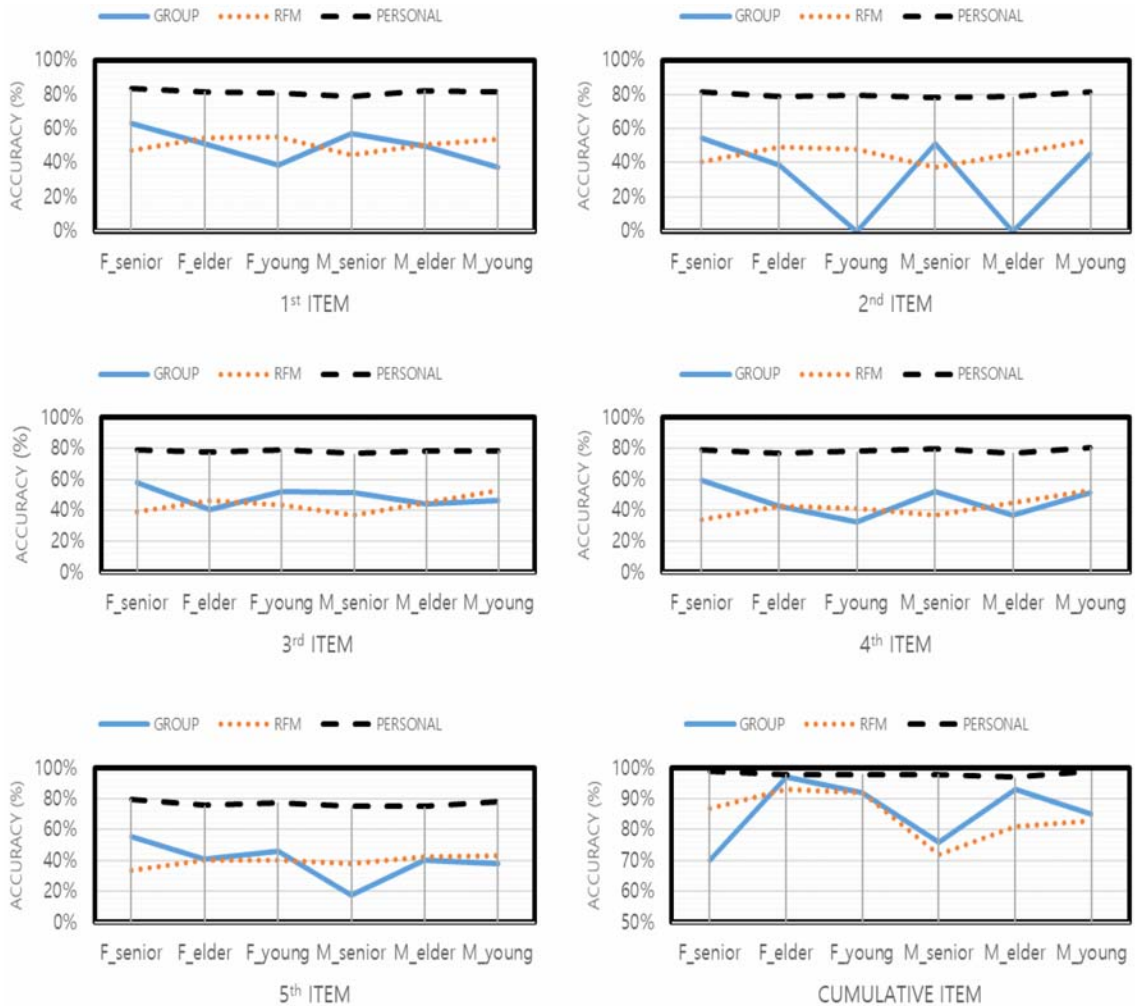
아래 <Figure 5>은 본 시스템의 추천 정확도를 비교 검증하기 위한 다양한 지표들을 포함하고 있다. 범례 GROUP은 연구에서 사용한 6개 그룹 내에서 가장 많은 구매를 이룬 상품 순으로 그룹 내 모든 고객에게 동일하게 추천을 했을 때의 정확도를 의미한다. 그리고 범례 RFM은 본 연구가

제안하는 RFM 변형식을 이용한 추천의 정확도를 나타낸다. 그리고 마지막 범례 PERSONAL은 총 19,366명에 해당하는 전체 고객들이 각각 2014년 동안 가장 많이 구매하였던 상품을 빈도가 높은 순으로 2015년에 다시 추천했을 경우의 정확도를 말한다.

이렇게 다양한 평가 지표를 설정하여 본 시스템의 추천 정확도의 타당성과 적합성을 비교한 결과 개인 별로 가장 많이 구매 한 상품을 추천할 때 고객이 2015년에도 구매 할 확률이 가장 높다. 하지만 추천의 목적을 생각 할 때 고객이 항상 구매 하던 상품을 추천하는 것은 추천의 본래 취지와는 맞지 않다. 왜냐하면 해당 고객에게 자주 사는 상품을 추천하지 않더라도 개인 기준의 구매 이력 정보에는 변화를 주지 못하며 굳이 추천을 하지 않더라도 자주 사던 상품들을 다시 구매할 여지가 다분하기 때문이다. 또한 새로운 상품이 계속해서 출시되는 시장의 특성을 고려한다면 오히려 새롭게 출시된 상품들이 고객들과 가까워지는 기회를 차단하는 것이 될 수 있으므로 진정한 의미의 추천이라고 볼 수 없다.

그리고 각 집단 별 가장 많이 구매한 Top 5 상품을 그룹에 속한 모든 고객에게 동일하게 추천하는 방식을 생각하면 개인별 선호도를 활용한 추천이 아닌 고객 집단 별로 이루어지는 추천이므로 개인화된 맞춤형 추천이라는 의미가 부족하다. 하지만 본 연구에서 제안하는 RFM 추천 시스템은 고객의 구매 이력을 바탕으로 상품에 대한 고객들의 성향을 최대한 객관화해 적합한 추천이 가능하다. 이로 인해 고객 개개인의 특성을 반영한 다양한 상품을 추천을 하기때문에 집단 내 가장 많이 구매한 상품의 추천보다 훨씬 개인화 추천의 성격이 훨씬 강화됐다.

나아가 우리의 RFM 추천 시스템의 정확도 역



〈Figure 5〉 Compare result of the Model test

시 집단 별로 최다 구매 상품을 추천하였을 때와 비교한 결과 본 연구에서 제안하고자 하는 추천 시스템의 정확성이 크게 떨어지지 않는다는 사실을 알 수 있다. 이를 증명하기 위해 5개의 추천 상품들 중 한 개 이상 실제로 샀을 경우를 고려하는 Top-N Accuracy(이 경우는 N=5)를 개인별 최다 구매 상품 추천, 집단 별 최다 구매 상품 추

천, RFM 점수를 활용한 추천 시스템 이렇게 각각 계산했다.

개인별 최다 구매 상품의 추천이 당연히 Top5 Accuracy가 높지만 집단 별 최다 구매 상품 추천의 Top5 Accuracy와 RFM 점수를 활용한 추천 시스템의 Top5 Accuracy를 비교해본다면 오히려 F_senior, F_young의 집단은 RFM 활용한 추천

시스템의 정확도가 더 높았다.

이를 통해 본 연구에서 제안하는 RFM 점수를 적용한 추천 시스템이 집단 별 최다 구매 상품 추천보다 개인화 추천 성향을 많이 가지고 있으면서도 준수한 성능을 보이는 것으로 이해할 수 있다. 본 연구에서는 Recency와 Frequency, 그리고 Monetary를 각각 10점 척도로 평가하여 단순히 이를 합산한 지표를 사용했지만 각각의 점수에 가중치를 정교하게 설정하면 개인화 상품 추천의 정확도가 보다 높아질 것으로 보인다.

5. Conclusion

오늘날 다양해진 고객의 개성에 따라 상품에 대한 개인화된 맞춤형 마케팅 전략의 중요성이 높다. 이때 고객의 상품에 대한 선호를 파악할 수 있는 데이터의 확보가 선행된다. 따라서 기업은 고객에게 상품 구매 평점 및 짧은 리뷰의 작성을 다양한 인센티브 제도로 유인하고 있다. 하지만 고객은 이런 유인 정책의 인센티브만을 목적으로 내적 일관성이 낮은 구매 평점을 남기는 경향을 보인다. 그리고 고객의 상품에 대한 구매 만족도는 굉장히 주관적인 것으로 타당성 오류를 갖기 쉽다. 이렇게 노이즈가 많은 저품질의 고객 선호도 데이터는 개인화된 맞춤형 마케팅을 위한 추천 시스템의 심각한 성능저하 문제를 초래한다.

게다가 L.POINT의 구매 이력 정보 데이터와 같이 고객의 선호도와 관련된 구매 평점 데이터 필드가 아예 없는 경우가 굉장히 많다. 예컨대 오프라인에서 이뤄지는 모든 형태의 거래 데이터는 모두 구매 평점 데이터가 없다고 볼 수 있다. 따라서 본 연구에서는 RFM 점수를 암시적

피드백으로 활용하여 모든 고객이 각각의 상품에 대해 가지는 객관적인 선호도로 사용했다. 이를 통해 오프라인 채널 데이터를 가지고 고객이 기존에 구매해 본 적 없는 새로운 상품에 대한 추천을 했다. 기존 명시적 접근을 통한 고객 평점의 노이즈 문제와 같은 상품 군 내에 있는 동종 유사 상품에 대해서만 제한되어 있던 추천 시스템의 확장성을 암시적 피드백을 통해 개선할 수 있었다.

본 연구에서 제안하는 RFM 점수를 통한 상품 추천의 정확도는 개인이 속한 인구통계학적 집단에서 가장 많이 구매하던 상품을 다시 추천하는 정확도와 비교해 큰 차이가 없었다. 하지만 추천 시스템의 의미를 고려하면 본 연구에서 제안하는 시스템의 정확도는 고객이 구매하지 않았던 새로운 제품을 추천하는 것이기 때문에 효과적으로 잠재고객을 추려내고 있음을 알 수 있다. 종합하자면 본 연구는 사용자 평점이 존재하지 않는 오프라인 채널 데이터나 이종 상품 시장에서도 충분히 객관적이고 효과적인 추천 시스템을 구축할 수 있다는 가능성을 시사한다.

하지만 본 연구에서 사용한 구매 이력 정보 데이터에는 기존의 추천 시스템에서 일반적으로 사용하고 있던 고객 평점의 명시적 지표가 없었기 때문에 본 연구에서 제안하는 암시적 지표의 추천 결과 정확도와 직접적인 비교를 수행하지 못한 한계가 있다. 이는 본 연구에서 사용된 데이터의 한계에 기인한다. 따라서 향후 사용자의 명시적 지표로 대표되는 상품 구매 평점과 본 연구에서 제안하는 RFM 점수를 직접 비교할 수 있는 데이터를 확보하여 직접적인 성능 평가를 수행하고자 한다.

참고문헌(References)

- Ahmed, S., J. Kim, and S. Kang, "Enhanced Recommendation Algorithm using Semantic Collaborative Filtering - E-commerce Portal," *Journal of Intelligence and Information Systems*, Vol.17, No.3(2011), 79~98.
- Ahn, K. C., C. B. Moon, B. M. Kim, S. S. Yoon, and H. S. Kim, "POS Data Analysis System based on Association Rule Analysis," *Journal of the Korea industrial information systems society*, Vol.17, (2012), 9~17.
- Ahn, Y. C., "Implemental Model of Customer Relationship Management System for Oriental Hospital Using Customer Segmentation," *Korea Society of Industrial Information Systems*, Vol.15, No.5(2010), 79~87.
- Amatriain, Xavier, J. M. Pujol, and N. Oliver, "I like it... i like it not: Evaluating user ratings noise in recommender systems," *International Conference on User Modeling, Adaptation, and Personalization*, (2009), 247~258.
- Bellogin, A., A. Said, and A. P. de Vries, "The magic barrier of recommender systems-no magic, just ratings," *International Conference on User Modeling, Adaptation, and Personalization*, (2014), 25~36.
- Chan, C. C. H., "Online auction customer segmentation using a neural network model," *International Journal of Applied Science and Engineering*, Vol.3, No.2(2005), 101~109.
- Chen, P., "Broadvision delivers new frontier for e-commerce." *M-commerce*. October 25, (2000).
- Cheng, C. H. and Y. S. Chen, "Classifying the segmentation of customer value via RFM model and RS theory," *Expert systems with applications*, Vol.36, No. 3(2009), 4176~4184.
- Choi, Y. H., "RFM analysis of Korean professional baseball spectators," *Journal of Sport and Leisure Studies*, Vol.50, No.1 (2012), 289~299.
- Choi, Y. K., and S. K. Kim, "Recommendation Algorithms for Online Shopping Malls with Periodically Purchasing Users," *Journal of KIISE: Software and Applications*, Vol.40, No.8(2013), 453~462.
- Claypool, M., A. Gokhale, T. Miranda, P. Murnikov, D. Netes, and M. Sartin, "Combining contents-based and collaborative filters in an online news paper," *ACM SIGIR '99 Workshop on Recommender Systems*, (1999).
- Department of Statistics Korea, "Online shopping 20 years by statistics", 2016. Available at http://kostat.go.kr/portal/korea/kor_nw/2/1/index.board?bmode=read&aSeq=354647/ (Downloaded 15 March, 2018).
- Forrester Research, "Forrester Research 2011 Annual Report", 2011. Available at <http://phx.corporate-ir.net/phoenix.zhtml?c=60569&p=irol-reportsannual/> (Downloaded 13 March, 2018)
- Goldberg, K., D. Gupta, M. Digiovanni, and H. Narita, "Jester 2.0: Evaluation of a new linear time collaborative filtering algorithm," *Intl. ACM SIGIR Conf. on Research and Development in Information Retrieval*, (1999)
- Good, N., J. B. Schafer, J. A. Konstan, A. Borchers, B. Sarwa, J. Herlocker, and J. Ridel, "Combining collaborative filtering with personal agents for better recommendations," *Proceedings of the Sixteenth National Conference on Artificial Intelligence*, (1999), 439~446.
- Ha, S. H. and K. H. Baek, "Analyzing Customer

- Purchase Behavior of a Department Store and Applying Customer Relationship Management Strategies,” *Korean Management Science Review*, Vol.21, No.3(2004), 55~69.
- Harper, F. M., X. Li, Y. Chen, and J. A. Konstan, “An economic model of user rating in an online recommender system,” *International Conference on User Modeling*, (2005), 307~316.
- Herlocker, J. L., J. A. Konstan, L. G. Terveen, and J. T. Riedl, “Evaluating collaborative filtering recommender systems,” *ACM Transactions on Information Systems (TOIS)*, Vol.22, No.1 (2004), 5~53.
- Hsieh, N. C., “An integrated data mining and behavioral scoring model for analyzing bank customers,” *Expert Systems with Applications*, Vol.27, No.4(2004), 623-633.
- Hughes, A. M., *Strategic database marketing*, Probus Publishing Company, 1994.
- Jeong, Y. J., I. Y., Choi, J. K. Kim, and J. C. Choi, “Strategy for Store Management Using SOM Based on RFM,” *Journal of Intelligence and Information Systems*, Vol.21, No.2(2015), 93~112.
- Kim, J. H., K. H. Lee, H. J. Lee, and D. S. Park, “Development of Recommendation System based on Data Mining Technique for E-Commerce,” *Journal of Korean Institute of Information Technology*, Vol.2, No.1(2004), 47~57.
- Kim, J. H., K. C. Nam, and S. J. Lee, “Forecasting of Customer’s Purchasing Intention Using Support Vector Machine,” *Information Systems Review*, Vol.10, No.2(2008), 137~158.
- Kim, J. H., B. H. Ahn, and D. Jeong, “A Recommender System using Mixed Filtering for Health Products,” *The Journal of Internet Electronic Commerce Research*, Vol.12, No.2 (2016), 109-124.
- Kim, J. W., S. J. Bae, and H. J. Lee, “Sparsity Effect on Collaborative Filtering-based Personalized Recommendation,” *Asia Pacific Journal of Information Systems*, Vol.14, No.2 (2004), 131~149.
- Kim, Y., and S. B. Moon, “A Study on Hybrid Recommendation System Based on Usage Frequency for Multimedia Contents,” *Journal of the Korean Society for Information Management*, Vol.23, No.3(2006), 91-125.
- Konstan, J. A., B. N. Miller, D. Maltz, J. L. Herlocker, L. R. Gordon, and J. Riedl, “GroupLens: Applying Collaborative Filtering to Usenet News,” *Communication of the ACM*, Vol.40, No.3(1997), 77~87.
- Kotler, P., *Principles of Marketing (15th Edition)*, Prentice Hall., p.411.
- Kwon, H. J., and K. S. Hong, “Method to Improve Data Sparsity Problem of Collaborative Filtering Using Latent Attribute Preference,” *Journal of Internet Computing and Services*, Vol.14, No.5(2013), 59~67.
- Lee, O. J., M. S. Hong, W. J. Lee, and J. D. Lee, “Scalable Collaborative Filtering Technique based on Adaptive Clustering,” *Journal of Intelligence and Information Systems*, Vol.20, No.2(2014), 73~92.
- Lee, Y. H., U. G. Kang, and H. J. Hwang, “Hospital Customer Segmentation Strategies based on RFM Model,” *Journal of KIISE*, Vol.2, No.1(2005), 25~33.
- Li, D. K., and B. K. Ha, “Posting RFM Model for Evaluating the Member Loyalty in Social Network Sites,” *The Society of service*

- Science*, Vol.1, No.1(2011), 49~60.
- Mackenzie, I., C. Meyer, and S. Nobble, "How retailers can keep up with consumers," *McKinsey & Company*, 2013. Available at <http://www.mckinsey.com/industries/retail/our-insights/how-retailers-can-keep-up-with-consumers> (Downloaded 13 March, 2018)
- Newell, F., *The new rules of marketing: How to use one-to-one relationship marketing to be the leader in your industry*, New York: McGraw-Hills Companies Inc., 1997.
- Nguyen, T. T., D. Kluver, T.-Y. Wang, P.-M. Hui, M. D. Ekstrand, M. C. Willemsen, and J. Riedl, "Rating support interfaces to improve user experience and recommender accuracy," *Paper Presented at the Proceedings of the 7th ACM Conference on Recommender Systems*, (2013).
- Oard, D. W., and J. Kim, "Implicit feedback for recommender systems," *Proceedings of the AAAI workshop on recommender systems*, Vol. 83, (1998).
- Oh, J. M, and N. M. Moon, "Preference Element Changeable Recommender System based on Extended Collaborative Filtering," *Computer and Information-Journal of the Institute of Electronics Engineers of Korea*, Vol.47, No.4(2010), 18~24.
- Park, D. H., H. K. Kim, I. Y. Choi, and J. K. Kim, "A literature review and classification of recommender systems research," *Expert Systems with Applications*, Vol.39, No.11 (2012), 10059-10072.
- Park, K. H., D. H. Baek, H. C. Jeon, and J. Y. Seo, "Development of a Merchandising Evaluation Framework for Internet Shopping Malls," *The Korean Association of Small Business Studies*, Vol.27, No.1(2005), 89~114.
- Park, Y. J., and K. N. Chang, "A study on the customer behavior based customer profile model for personalized products recommendation," *Proceedings of Korean Academic Society Of Business Administration*, (2005), 315~322.
- Parthasarathy, S., M. J. Zaki, M. Ogihara and S. Dwarkadas, "Incremental and Interactive Sequence Mining," *Proceeding of the 8th International Counterenn Information and Knowledge Management (CIKM'99)*, (1999).
- Potoniee, O., "Ubiquitous Personalization: a Smart Card Based Approach," *Gemplus Developer Conference*, (2002).
- Rogers, E. M., *The diffusion of innovations*, The Tree Press, New York, 1962.
- Said, A., B. J. Jain, S. Narr, and T. Plumbaum, "Users and noise: The magic barrier of recommender systems," *International Conference on User Modeling, Adaptation, and Personalization*, (2012), 237~248.
- Shardanand, P, and P. Maes, "Social Information Filtering Algorithms for Automating Word of Month," *Proceedings of Conference on Human Factors in Computer Systems*, (1995), 210~217.
- Wei, J. T., M. C. Lee, H. K. Chen, and H. H. Wu, "Customer relationship management in the hairdressing industry: An application of data mining techniques," *Expert Systems with Application*, Vol.40, No.18(2013), 7513~7518.
- Wu, J., and Z. Lin, "Research on customer segmentation model by clustering," *Proceedings of the 7th international conference on Electronic commerce*, (2005), 316~318.

Yu, S. J., "A Study of Improvement of Individual Item Diversity in Collaborative Filtering-based Recommendation," *Journal of Korean Institute of Information Technology*, Vol.14, No.8(2016), 89~64.

Yun, S., and H. Yoon, "An Analysis of Performance Improvement Algorithm for Personalized Recommender System," *Proceedings of KFIS Spring Conference 2005*, Vol.15, No.1(2005), 181~184.

Abstract

A Study on Improvement of Collaborative Filtering Based on Implicit User Feedback Using RFM Multidimensional Analysis

Jae-Seong Lee* · Jaeyoung Kim** · Byeongwook Kang***

The utilization of the e-commerce market has become a common life style in today. It has become important part to know where and how to make reasonable purchases of good quality products for customers. This change in purchase psychology tends to make it difficult for customers to make purchasing decisions in vast amounts of information. In this case, the recommendation system has the effect of reducing the cost of information retrieval and improving the satisfaction by analyzing the purchasing behavior of the customer. Amazon and Netflix are considered to be the well-known examples of sales marketing using the recommendation system. In the case of Amazon, 60% of the recommendation is made by purchasing goods, and 35% of the sales increase was achieved. Netflix, on the other hand, found that 75% of movie recommendations were made using services.

This personalization technique is considered to be one of the key strategies for one-to-one marketing that can be useful in online markets where salespeople do not exist. Recommendation techniques that are mainly used in recommendation systems today include collaborative filtering and content-based filtering. Furthermore, hybrid techniques and association rules that use these techniques in combination are also being used in various fields. Of these, collaborative filtering recommendation techniques are the most popular today. Collaborative filtering is a method of recommending products preferred by neighbors who have similar preferences or purchasing behavior, based on the assumption that users who have exhibited similar tendencies in purchasing or evaluating products in the past will have a similar tendency to other products. However, most of the existed systems are recommended only within the same category of products such as books and movies. This is because the recommendation system estimates the purchase satisfaction about

* Corresponding Author: Jae-Seong Lee
University of Science & Technology
66 Hoegi-ro, Dongdaemun-gu, Seoul 02456, Korea
Tel: +82-2-3299-6122, Fax: +82-504-195-7656, E-mail: jslee@kisti.re.kr, jaeseong.lee@ust.ac.kr

** Ajou University

*** Kyonggi University

new item which have never been bought yet using customer's purchase rating points of a similar commodity based on the transaction data. In addition, there is a problem about the reliability of purchase ratings used in the recommendation system.

Reliability of customer purchase ratings is causing serious problems. In particular, 'Compensatory Review' refers to the intentional manipulation of a customer purchase rating by a company intervention. In fact, Amazon has been hard-pressed for these "compassionate reviews" since 2016 and has worked hard to reduce false information and increase credibility. The survey showed that the average rating for products with 'Compensated Review' was higher than those without 'Compensation Review'. And it turns out that 'Compensatory Review' is about 12 times less likely to give the lowest rating, and about 4 times less likely to leave a critical opinion. As such, customer purchase ratings are full of various noises. This problem is directly related to the performance of recommendation systems aimed at maximizing profits by attracting highly satisfied customers in most e-commerce transactions.

In this study, we propose the possibility of using new indicators that can objectively substitute existing customer 's purchase ratings by using RFM multi-dimensional analysis technique to solve a series of problems. RFM multi-dimensional analysis technique is the most widely used analytical method in customer relationship management marketing(CRM), and is a data analysis method for selecting customers who are likely to purchase goods.

As a result of verifying the actual purchase history data using the relevant index, the accuracy was as high as about 55%. This is a result of recommending a total of 4,386 different types of products that have never been bought before, thus the verification result means relatively high accuracy and utilization value. And this study suggests the possibility of general recommendation system that can be applied to various offline product data. If additional data is acquired in the future, the accuracy of the proposed recommendation system can be improved.

Key Words : Collaborative Filtering, Personalized Marketing, Recommendation System, Machine Learning, Demand forecast

Received : June 2, 2018 Revised : December 14, 2018 Accepted : January 26, 2019

Publication Type : Conference(Fast-track) Corresponding Author : Jae-Seong Lee

저자 소개



이재성

현재 과학기술연합대학원대학교 과학기술경영정책학과 석사과정을 수료하고 동 대학원 박사과정 진학 예정에 있으며, 한국과학기술정보연구원 데이터분석본부 데이터분석플랫폼센터에 학생연구원으로 근무하고 있다. 주요 관심 연구분야로는 기계학습, 또는 인공지능을 활용한 국가 연구개발과제 관리나 기술사업화와 관련된 ICT 중소기업 혁신을 위한 국가 주도 R&D 관련 정책 연구가 있다. 주요 연구로는 한국표준산업분류를 기준으로 한 문서의 자동 분류 모델에 관한 연구, 영과잉 회귀분석을 이용한 연구개발 인력 주요 특성에 관한 연구, PPDM기반 이중 DB 연계를 활용한 출연연 공동연구 지원 효율화 연구 등이 있다.



김재영

아주대학교 미디어학부를 졸업하고, 경기 빅데이터 전문가 과정, 핀테크 블록체인 Advanced Development Course, 서울대학교 4차 산업혁명 아카데미를 수료하였다. 주요 관심분야는 빅데이터, 머신러닝, 딥러닝이다. 주요 프로젝트로 불법 주정차 현황 분석 대시보드 개발, NHN Ent. 머신러닝랩팀에서 StarGAN을 활용한 Action Emoji 생성(Video Generation) Capstone pj가 있다. 현재는 kt에서 it 컨설턴트로서 it플랫폼팀에서 빅데이터, 인공지능 관련 다양한 공공사업에 참여하고 있다.



강병욱

경기대학교 산업경영공학과를 졸업하였으며, 경기 빅데이터 전문가 과정, Iot 아카데미, 서울대 4차 산업혁명 아카데미를 수료하였다. 주된 관심 분야는 빅데이터, 머신러닝이며 이를 활용하여 고객 및 CRM에서 수집되는 데이터를 분석하고 인사이트를 도출하는 것이다. 현재까지 불법 주정차 분석, 클릭스트림 데이터를 활용한 인구통계학적정보 예측, 식당 SNS 데이터를 활용한 위생 식당 예측, 보험사 내부 데이터와 공공데이터를 이용한 의료비 과다 지출 고객 예측 등의 프로젝트를 수행하였다.