

인플루언서를 위한 딥러닝 기반의 제품 추천모델 개발

송희석* · 김재경**

Deep Learning-based Product Recommendation Model for Influencer Marketing

Hee Seok Song* · Jae Kyung Kim**

Abstract

In this study, with the goal of developing a deep learning-based product recommendation model for effective matching of influencers and products, a deep learning model with a collaborative filtering model combined with generalized matrix decomposition(GMF), a collaborative filtering model based on multi-layer perceptron (MLP), and neural collaborative filtering and generalized matrix Factorization (NeuMF), a hybrid model combining GMP and MLP was developed and tested. In particular, we utilize one-class problem free boosting (OCF-B) method to solve the one-class problem that occurs when training is performed only on positive cases using implicit feedback in the deep learning-based collaborative filtering recommendation model. In relation to model selection based on overall experimental results, the MLP model showed highest performance with weighted average precision, weighted average recall, and f1 score were 0.85 in the model (n=3,000, term=15). This study is meaningful in practice as it attempted to commercialize a deep learning-based recommendation system where influencer's promotion data is being accumulated, practical personalized recommendation service is not yet commercially applied yet.

Keywords : Influencer Marketing, Product Recommendation, Deep Learning, Collaborative Filtering, One-class Problem

Received : 2022. 5. 17. Final Acceptance : 2022. 6. 14.

※ This research was supported by the National Research Foundation of Korea(NRF) grant (No.2021R1F1A1045815)

* First Author, Professor, Hannam University, Global IT Business, e-mail : hssong@hnu.kr

** Corresponding Author, Associate Professor, Hannam University, Global IT Business, 70 Hannam-ro, Daeduk-gu, Daejeon, 34430, Korea, Tel : +82-42-629-7684, e-mail : drj@hnu.kr

1. 서 론

산업 전반에 인공지능과 빅데이터 기술의 적용이 확산되면서 기존 분야의 스마트화와 디지털화를 가속화하고 있다. 예를 들어, 고객 관계 관리 영역에서 인공지능과 빅데이터의 활용은 고객 서비스 품질을 향상시킬 뿐만 아니라 축적된 고객 정보를 기반으로 맞춤형 서비스를 제공함으로써 기업 경쟁력을 강화하는 데 도움이 된다. 본 연구에서는 인플루언서와 제조사의 제품을 효과적으로 매칭시켜 제조사의 매출 증대는 물론이고 인플루언서의 광고수익을 극대화시킬 수 있는 인플루언서를 위한 딥러닝 기반의 홍보대상 제품 추천모델 개발을 목표로 하고 있다. 인플루언서에게 본인의 성향에 최적화된 홍보 제품을 추천할 수 있다면 제품 공급사 입장에서는 브랜드 핏에 적합한 인플루언서를 찾아줌으로써 지출대비 효과적인 광고 성과를 달성할 수 있으며 인플루언서를 섭외하기 위한 비용과 시간적 노력을 절약할 수 있다[Jung, 2019]. 또한, 인플루언서 측면에서는 자발적으로 제품 공급사의 제품을 선택하여 콘텐츠 광고를 진행할 수 있어 인플루언서의 광고수익을 극대화할 수 있다는 잇점이 있다.

기존에 시도된 상품 추천 방법은 분류나 예측 알고리즘을 사용하는 메모리 기반 협업 필터링이나 콘텐츠 기반 추천 시스템이 대부분이었다. 그러나 최근 딥러닝모델의 성공으로 추천분야에도 딥러닝모델을 적용하여 추천성능을 높이려는 시도가 증가하고 있다(Song, 2019). 본 연구에서는 인플루언서를 위한 마케팅 플랫폼에서 그 동안 수집된 인플루언서별 홍보제품 이력 데이터를 기반으로 각 인플루언서가 선호할 것으로 예상되는 홍보 제품을 추천하는 딥러닝 기반의 협업필터링 추천모델을 개발하고 성능평가를 통해 실무 적용가능성을 타진해 보고자 한다. 본 연구는 딥러닝 모델 중 기존 뷰티제품 추천에서 우수한 성능을 보인 것으로 보고된 행렬분해기반 신경망모델(GMF: Generalized Matrix Factorization)과 다층퍼셉트론 기반 협업 필터링 모델(MLP: CF based Multi-Layer Perceptron), 그리고 일반화 행렬분해와 뉴럴협업필터링의 결합모델(NeuMF: Neural Collaborative Filtering and Generalized Matrix Factorization)을 인플루언서를 위한 제품 추천에 적용하고 성능평가를 시행함으로써 상용화 가능성을 확인하기로 한다(Song,

2019].

한편 최근 협업필터링은 사용자가 아이টে에 대해 부여하는 평점과 같은 명시적인 피드백보다는 좋아요, 북마크, 클릭 등 사용자의 선호도를 추론하는 데 활용할 수 있는 묵시적 피드백 정보를 활용하는데 이는 묵시적 피드백이 명시적 피드백보다 더 풍부하고 편향이 적기 때문에 연구 커뮤니티에서 많은 관심을 받고 있다. 그러나 딥러닝 기반 협업필터링 추천모델을 구축하기 위해서는 사용자가 선호하는 아이টে에 대한 정보인 긍정사례와 사용자가 선호하지 않는 아이টে에 대한 정보인 부정사례가 함께 수집되어 훈련모델에 입력되어야 하는데 묵시적 피드백을 이용하는 경우 긍정사례로만 훈련이 이루어지기 때문에 모든 결측값에 대한 예측이 무조건 긍정값으로 주어지는(Trivial solution) 원클래스 문제가 발생한다. 원클래스 문제를 해결하기 위한 방법으로 그간 소개된 솔루션은 가중손실법과 데이터밸런싱 방법 등이 주류이다(Pan et al., 2008). 그러나 이들 방법 또한 사용자 선호가 확인되지 않은 경우를 싫어함으로 간주하기 때문에 높은 추천성능을 보장하기 어렵다. 원클래스 문제 해결을 위한 본 연구의 아이디어는 예측오차가 커서 손실함수에 대한 개선 기여도가 낮은 부정사례를 반복적으로 추출하여 다른 부정사례로 대체하는 방법을 사용하는 것이다. 즉 처음엔 부정사례를 임의로 생성 후 예측오차가 큰 부정사례를 제거하고 다른 부정사례로 대체하여 점진적으로 손실값을 줄여나가는 아이디어로 원클래스 문제를 해결할 수 있다.

2. 제품추천 관련 기존연구

여기서는 다양한 제품추천 연구 중 뷰티제품에 집중하여 제품추천 관련 국내의 연구들을 조사하고 추천시스템 개발 접근법을 검토하기로 한다. 이는 인플루언서용 홍보제품 중 뷰티제품이 다수를 차지하고 있기 때문이기도 하다. Kim et al.(2017)은 제품의 성분 데이터를 파싱 및 전처리하여 제품 성분의 유해도 점수(EWG Score)를 구하고, 소비자의 상품 후기 데이터에서 형태소를 분석하고, 감성극성에 따라 상품점수를 계산하여 퍼지 추론 과정을 통해 추천하였다. Lee et al.(2018)은 빅데이터 분석과 소셜네트워크 데이터를 활용해 소비자의 피부 유형과 유전정보에 따른 추천 방식을 제안하였으나, 유전자 정보의 제공이 불가능한 온

라인 제품 추천 측면에서 본 연구에서 제안하는 추천알고리즘과 다르다.

협업 필터링 추천 모델 자체가 가진 확장성 문제를 극복하기 위해 Lee et al.[2012]은 요인 분석과 군집 분석을 사용하여 데이터 차원을 축소한 협업필터링을 적용하여, 제품의 수를 줄였음에도 높은 성능을 보여 협업 필터링 방법의 확장성 문제에 대한 접근법을 제안하였다. Ha et al.[2016]은 사용자의 SNS 데이터와 피부 사진을 활용하여 피부에 대한 데이터를 수집하고 분석하여 사용자의 피부 상태를 진단한 후, 이를 기반으로 피부 개선에 적합하다고 추천된 각 제품 점수를 계산한 다음 피부 개선 순위와 제품 성분 간의 상관계수를 바탕으로 제품을 추천하였고, 모델의 성능 평가는 제품 회사에서 제공한 추천 리스트와 모델을 통한 추천 리스트를 비교하였다. 기존의 고객 구매 이력 데이터를 기반으로 한 추천 방식이 개인정보 이용에 따른 사생활 침해 우려와 구매 이력 데이터 확보가 어렵고, 추천 과정에 전문가의 정보가 필요하고 SNS 데이터의 품질에 대한 담보가 어렵다는 단점이 있는 반면, 주름, 민감도, 유분 등 개인의 피부 특성에 맞는 제품을 추천하는 실용적인 접근법이라 볼 수 있다. Yim et al.[2016]은 제품 포장에 인쇄된 성분과 사용자가 선호하는 제품의 성분을 바탕으로 카카드 유사도를 적용한 k-최근접 이웃 알고리즘과 내용기반 필터링 기법을 이용하여 유사도가 높은 제품을 추천하는 시스템을 제안하였다. 제안된 추천 모델은 추천 과정에서 전문가의 개입이 요구되지 않고 제품의 성분표를 통해 사용자의 선호도와 비교하여 제품을 추천할 수 있다는 장점이 있으나 개인의 선호 외에는 피부 특성과 같은 제품과 밀접한 특성은 추천 모델에 반영되지 못한다는 단점이 있다.

Cho et al.[2012]은 고객 정보에서 속성 변수의 특성 벡터를 사용한 클러스터링 작업과 클러스터 내부의 항목 범주 선호도 계산을 위한 전처리 작업을 사용한 묵시적인 방법을 이용하여 RFM(recency, frequency, monetary)기법과 k-평균 기법을 이용하여 매우 효율적인 제품 제안이 가능한 개인화 추천시스템을 제안하였다. 성능평가를 위해 현장에서 활용되고 있는 온라인 쇼핑몰의 데이터를 기반으로 데이터 세트를 생성하고, 기존 모델과의 비교 실험을 통해 성능을 검증하여 효용성을 확립하였으나, 이 연구 또한 개인의 피부 특성을 고려하지 않은 군집화 기법을 사용하기 때문에 가장 엄

밀한 의미에서 개인화된 추천이라고 볼 수 없다. Choi et al.[2018]은 SNS에서 생성된 뷰티 관련 정보와 제품 정보를 수집하고 이를 Kafka, Storm, HBase 등의 NoSQL 데이터베이스를 활용하여 트렌드 분석, 핫토픽 분석, 사용자 맞춤형 개인 제안 분석에 활용할 수 있는 추천 시스템을 제안하였다. 이 접근 방식의 궁극적인 목적은 제품에 적합한 사용자의 식별이 아닌 제품을 구매할 사용자를 식별하여 기업이 신제품의 시장 가치 또는 크기에 대한 통계 데이터를 제공하는 것으로 빅데이터와 상황정보를 결합해 제품을 추천한다는 점에 서 독특하다.

제품 추천 관련 해외 연구도 활발하게 진행되어왔다 (Gholamian et al., 2011; Iwabuchi et al., 2017; Matsunami et al., 2017; Wang et al., 2004). Gholamian et al.[2011]의 연구에서는 시간적 맥락과 소비자 집단 정보를 활용하여 추천 성능을 향상시키기 위해 사용자가 최근에 선호한 제품에 더 높은 가중치와 성능을 부여하여 홍보하는 시간 종속적 접근 방식을 적용함으로써 시간적 상황을 고려한 협업 필터링 기반 추천 시스템 모델을 제안하였다.

Iwabuchi et al.[2017]은 협업 필터링 기반 방식은 추천 이유를 설명하기 어렵고, 제품 리뷰에 상반되는 내용이 많아 고객들이 제품 선택에 어려움을 겪는다는 점을 지적하고, Bihada-Mania 웹사이트에서 제품 성분을 수집한 후, 소비자의 피부 고민에 대응하는 15개의 효능을 구분하고 사용자 평가를 통해 적절한 성분을 도출하고 이러한 성분이 많이 함유된 제품을 추천하는 추천 방식을 제시했다.

부적절한 성분으로 인한 피부 자극의 위험도가 높기 때문에 화장품 리뷰는 구매 결정에 큰 영향을 미친다. Matsunami et al.[2017]은 사용자가 작성한 상품평을 기반으로 제품에 효능별 별점을 자동으로 부여하는 것으로 추천을 위해 필요한 중간 단계 데이터를 제공하는 상품평 언어 기반 자동 채점 시스템을 제안하고, 실제 온라인 리뷰의 관용구로 구성된 평가 어휘를 기반으로 사용자 유사도 평가 방법을 적용한 추천 시스템을 제시하였다.

Patty et al.[2018]은 콘텐츠 기반 필터링에 사용된 키워드는 7종의 화장품과 5개의 가격대, 4종류의 피부유형 등의 키워드를 직접 입력하도록 하고 TF-IDF 방식의 프로파일을 활용하여 키워드 간 코사인 유사도를 사용하

〈Table 1〉 Approaches for Developing Beauty Recommender

Development Approaches	Applied Techniques	References
Review text-based	Text mining, Deep learning	Matsunami et al.(2017), Patty et al.(2018), Song(2019)
Harmful ingredient-based	Fuzzy inference	Kim et al.(2017)
Skin type-based	OCR Recognition, CF, Content-based filtering	Lee et al.(2018), Lee et al.(2012)
Skin trouble-based	Content-based filtering	Ha et al.(2016), Iwabuchi et al.(2017)
Ingredient preference-based	k-nn, Content-based filtering	Yim et al.(2016)
Context-based	RFM, k-means, Association analysis	Cho et al.(2012)
Time dependent	CF	Choi et al.(2018), Gholamian et al.(2011)

여 추천도를 계산하는 콘텐츠 기반 필터링 방식 기반의 제품 추천 시스템을 제안했다. 한편, Song(2019)은 세 개의 심층신경망 모형(행렬분해기반 신경망 모형, 뉴럴협업필터링 모형, 일반화 행렬분해와 결합된 뉴럴협업필터링 모형)을 적용하고 성능평가하여 뷰티제품 추천에 가장 적합한 심층신경망 모형을 제안하였다. 이상의 제품 추천 모델 개발과 관련된 연구는 〈Table 1〉에 정리되었다.

3. 인플루언서를 위한 제품 추천시스템

본 연구에서는 딥러닝 모델에 기반한 홍보제품 추천 시스템 개발을 위해 다음의 설계 목표를 제시한다. 첫째, 제품 추천시스템은 인플루언서 개인의 선호성향을 고려한 맞춤형 추천이 이루어져야 한다. 둘째, 인플루언서의 선호제품 패턴을 고려하여 해당 인플루언서가 홍보를 꺼리는 제품(부정사례) 목록을 별도로 생성하여 훈련데이터 셋을 균형있게 구성함으로써 추천시스템 성능을 개선하여야 한다. 셋째, 인플루언서가 판매한 과거 데이터가 자동으로 추천에 전달되는 진화적 추천시스템으로 구성하여야 한다.

한편, 제품 추천을 위한 방법으로는 협업필터링(collaborative filtering, CF) 방식, 내용기반(content-based)추천방식, 그리고 이 둘을 결합한 하이브리드 추천방식이 있다. 협업 필터링 방법은 모든 영역에서 사용할 수 있으며, 무작위 추천을 제공할 수 있다는 이점이 있다. 무엇보다 CF 방식은 최근 부각되고 있는 다양한 딥러닝 기법과 연계된 모델이 많기 때문에 추천 성능을 높일 수 있다. 본 연구에서는 CF 방식의

딥러닝 추천모델을 적용하여 인플루언서를 위한 제품 추천 시스템을 개발한다(Herlocker et al., 2002; Song, 2019).

협업 필터링 방식은 사용자의 구매 이력을 집계하여 성향이 유사한 개인들이 선택한 제품을 추천하며, 유사도 측정 목적에 따라 협업 필터링 방법은 사용자 기반 CF와 항목 기반 CF의 두 가지 유형으로 나눌 수 있다. 사용자 기반 CF 방식은 먼저 인플루언서가 홍보했던 제품 이력을 읽어 들인 후, 사용자(인플루언서)-아이템(제품) 선호행렬을 생성한다. 그 후, 제품에 대한 선호를 기준으로 사용자 그룹 별로 유사도 행렬을 만든 후 제품 k가 사용자 그룹 I에 얼마나 선호될 것인지를 예측한다.

$$\hat{r}_{ik} = \bar{r}_i + \frac{1}{\sum_{j \in N_i} sim(i,j)} \sum_{j \in N_i} sim(i,j) \times (r_{jk} - \bar{r}_j)$$

\bar{r}_i : 사용자그룹*i*의 평균선호점수

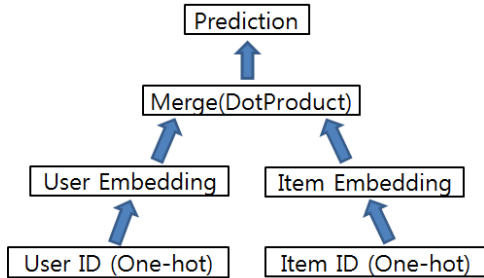
r_{jk} : 사용자그룹*j*가 제품k에 대해 평가한(평균)점수

N_i : 사용자그룹*i*와 선호패턴이 유사한 이웃사용자 그룹들

$sim(i,j)$: 사용자그룹*i*와 *j*의 선호패턴 유사도

본 연구에서 검토하는 딥러닝 모델은 CF 기반 딥러닝 모델 중 우수한 성능을 보인 것으로 보고된 행렬분해기반 신경망모델(GMF: Generalized Matrix Factorization)과 다층퍼셉트론기반 CF 모델(MLP: CF based Multi-Layer Perceptron), 그리고 일반화 행렬분해와 결합된 뉴럴협업필터링 모델(NeuMF:

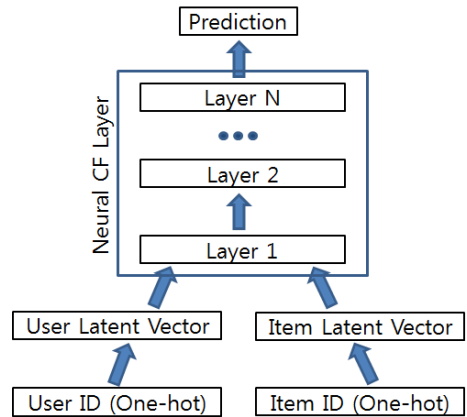
Neural Collaborative Filtering and Generalized Matrix Factorization)을 인플루언서를 위한 제품 추천에 적용하여 그 성능을 평가하기로 한다. 행렬 분해(GMF) 방식 CF 추천[Bokde et al., 2015; Koren et al., 2009] 방식은 유사 선호성향을 가진 인플루언서들을 그룹으로 형성하여 인플루언서-제품 선호행렬을 두 개의 부분 행렬 P와 Q로 분할 한 다음, 잠재요인(Latent Factor) 모델을 통해 재결합 한다. 사용자나 제품의 특성 벡터의 크기는 매우 크며, 잠재요인모델은 이렇게 긴 사용자와 제품 특성을 요인 벡터로 축소할 수 있다. 본 연구에서는 입력층과 사용자 또는 제품 유형 데이터를 잠재요인벡터로 변환하는 임베딩 층, 그리고 이 잠재요인벡터의 내적을 계산하는 출력층을 가진 신경망을 이용하여 행렬분해기반의 CF모델을 구현하고자 한다. 충분한 학습이 완료되면 임베딩 레이어의 출력 벡터는 유사한 제품 또는 유사한 사용자 간의 거리가 가까운 벡터를 갖게 된다. 아래 <Figure 1>은 신경망을 이용하여 행렬분해기반의 CF모델의 구조이다.



<Figure 1> Generalized Matrix Factorization based neural network model(GMF; Adapted from Bokde et al., 2015; Koren et al., 2009)

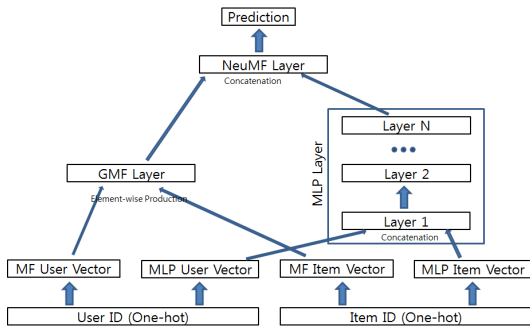
두 번째 적용모델은 딥러닝을 추천에 적용한 다층퍼셉트론 기반 CF(MLP; CF based Multi-Layer Perceptron)모델로서 YouTube 비디오 추천 [Covington et al., 2016], 안드로이드 앱 추천 [Cheng et al., 2016], 야후 뉴스 추천[Shumpei et al., 2017]에 적용되어 전통적인 추천 모델 대비 현저한 성능 향상을 나타내고 있다. 추천분야에서 딥러닝 모델을 적용한 추천 방식의 장점은 다음과 같다. 먼저, 딥러닝은 비선형 모델로 행렬분해와 같은 선형 모델과 비교하면 복잡한 상호 작용을 더 잘 처리하고 사용자

선호도를 더 정확하게 학습할 수 있다. 또한, 딥러닝은 대용량의 사용자-제품 간 선호도 정보에 내재된 특징을 학습할 수 있고, 문자, 그림, 소리, 동영상 등의 이질적인 정보를 포함한 유연한 모델의 구성이 가능하다. 또, 딥러닝 모델은 시간에 따른 사용자 선호도의 변화와 객체에 대한 선호 체계의 진화를 모델에 반영할 수 있으며, 다른 구조의 신경망 모델과 병합된 하이브리드 모델을 구축할 수 있으므로 다양한 특성과 기능을 가진 입력 데이터를 통합하는 모델을 구성할 수 있다. <Figure 2>에 보이는 본 연구에서 전통적인 추천 방법과 비교할 다층퍼셉트론 기반 CF 모델(He et al., 2017; He and Chua, 2017)은 잠재벡터에서 사용자-제품 간 복잡한 상호 작용을 예측할 수 있으므로 행렬분해 기반 모델 대비 높은 성능을 나타낸다.



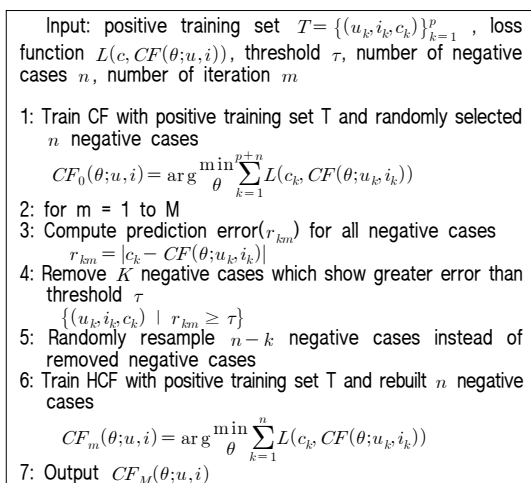
<Figure 2> CF based Multi-Layer Perceptron model (MLP; He et al., 2017; He and Chua, 2017)

한편 He et al.[2017]은 행렬분해 기법(Generalized matrix factorization)과 MLP를 결합한 하이브리드 모델 (NeuMF)을 제안하여 추천성능을 개선할 수 있음을 제안한 바 있다. 본 연구에서도 NeuMF 기반의 추천모델의 성능을 확인한다. MLP와 GMF가 결합된 모델은 각 공유 임베딩 레이어에서 출력 값을 가져와서 각각 학습이 이루어진 뒤 최종 은닉 레이어에서 연결(concatenation)하는 방식으로 구축된다. <Figure 3>에서 보는 것처럼, MF 사용자 벡터와 MF 제품 벡터를 일차원 벡터로 변환한 후 각 원소의 곱으로 GMF Layer를 계산한다.



〈Figure 3〉 Neural Collaborative Filtering and Generalized Matrix Factorization model (NeuMF: Adapted from He et al., 2017)

한편 본 연구에서는 원클래스 문제 해결을 위한 대안으로 OCF-B(One-Class problem Free Boosting)를 적용하였다(Song and Song, 2022). OCF-B는 원클래스 문제 해결을 위해 부스팅 방법을 응용한 프레임워크이다. 원래 부스팅은 앙상블의 한 유형으로 틀린 케이스에 가중치를 높이 부여하여 보다 정확한 모델을 구현해 나가는 방식으로, 잘못 분류된 경우 더 높은 가중치를 두어 더 잘 해결할 수 있도록 모델을 수정해 나가는 방식이다. 여기서는 부스팅 개념을 변형하여 더 높은 손실 (또는 예측오차)을 유발하는 부정사례를 다른 부정사례로 교체하는 방법을 반복적으로 사용하여 손실함수를 최소화하는 부정사례를 발견해 나가는 것이 주요 아이디어이다. 원클래스문제를 해결하기 위해



〈Figure 4〉 OCF-B Algorithm

PAN et al.[2008]의 가중치기반 저순위근사법에서는 긍정사례를 제외한 모든 가능한 사례(관측되지 않은 사례)를 부정사례로 간주하고 긍정사례와 부정사례에 다른 가중치를 부여하여 손실함수를 계산하고 있는데 반해 OCF-B에서는 손실함수를 최소로 하는 부정사례의 집합을 리샘플링을 반복적으로 시행하면서 찾아 나간다는 점에서 차이가 있다고 볼 수 있다. OCF-B의 훈련 알고리즘을 구성하면 〈Figure 4〉와 같다.

OCF-B에서는 기본적인 훈련모델로 사용자프로파일(u)과 아이템프로파일(i)을 입력하고 긍정($c=1$) 또는 부정($c=0$)을 출력하는 CF모델($CF(\theta; u, i)$)을 사용한다. OCF-B 알고리즘은 먼저 p 개의 긍정사례로 구성된 실제 훈련데이터 T 에 임의의 부정사례 n 개를 샘플링하여 훈련데이터를 구성한 후 최초의 CF모델($CF_0(\theta; u, i)$)을 훈련하게 된다(Line 1). 학습된 CF모델은 실제 타겟클래스 c 와 모델에서 산출한 $CF(\theta; u, i)$ 간 오차를 최소화하는 파라미터 θ 를 갖게 된다. 최초 CF모델에 대한 학습이 끝나면 훈련에 사용된 각 케이스에 대한 오차를 구하게 된다. 이 때 오차는 예측오차를 이용할 수도 있고, pseudo-residual이라고 알려져 있는 negative gradient를 구하는 방법으로 계산할 수도 있다(Line 3). 계산된 예측오차가 경계값 τ 이상으로 큰 부정사례들을 추출하여 훈련데이터에서 제거하고 제거된 사례 수만큼 새로 부정사례를 샘플링하여 훈련 데이터에 추가한다(Line 4, 5). 새로 추출된 부정사례를 포함한 훈련데이터를 이용하여 다시 CF모델($CF_m(\theta; u, i)$)을 훈련하게 된다(Line 6). 이러한 방식으로 수차례 반복을 통해 손실함수를 최소화 하는 부정사례 집합을 결정한 후 최적의 CF모델을 훈련하는 것이 알고리즘의 최종 목표이다.

4. 성능평가 방법

여기서는 인플루언서를 위한 홍보제품 추천모델의 성능평가 방법을 소개하기로 한다. 본 연구 문제는 특정 인플루언서가 특정 제품을 홍보하고 싶을지 여부를 예측하는 것으로 이진 분류문제로 정의하며, 사용된 성능 지표는 정밀도(precision), 재현율(recall), f1이며, ROC 그래프를 통해 모델의 성능을 시각화하였고, 성능 평가를 위해 ROC 그래프의 AUC값을 사용하였다. 본 연구에서 정밀도는 “추천모델에서 만족이라고 예측

된 사용자-제품 쌍 중 실제 후기에서도 만족했던 사용자-제품 쌍의 비율"로 계산된다. 재현율은 "실제 후기에서 만족했던 사용자-아이템 쌍 중 추천모델에서도 만족으로 예측된 사용자-아이템 쌍의 비율"로 계산된다. 다음은 정밀도, 재현율, f1-score의 계산 공식이다.

5. 실험결과

5.1 데이터

본 연구는 국내 인플루언서용 마케팅 플랫폼인 M 플랫폼에서 수집된 인플루언서별 제품 홍보 이력데이터를 사용하여 제안된 추천모델의 성능을 평가하기로 한다. 인플루언서 데이터셋은 2021년 4월26일부터 2022년 1월19일까지 M플랫폼에 회원으로 가입한 인플루언서가 제품 홍보를 위해 제품 링크를 생성한 2,000건의 데이터로 구성되어 있으며 총 407명의 인플루언서가 462개의 제품에 대해 홍보한 이력이 담겨져 있다. 이 데이터 셋은 가능한 모든 사용자-아이템 상호작용 셀 (407×462) 중 2,000개의 상호작용만으로 구성되어 있기 때문에 희박도는 98.94%로 다소 높은 편이다.

이 데이터 셋은 특정 인플루언서가 특정 제품을 홍보했다는 데이터로만 구성되어 있기 때문에 긍정사례로만 구성되어 있으며 학습을 위해서는 부정사례를 생성하여 추가할 필요가 있다. 부정사례 생성방법은 본문에서 제시된 OCF-B 알고리즘에 의해 생성한 후 성능평가를 시행하였다.


5.2 실험결과

실험에 사용된 모델은 GMF, MLP, NeuMF 모델이다. GMF모델은 잠재요인(Latent factor)의 수를 2에서 5까지로 달리하며 예측을 수행하였으나 학습모델의 수렴이 이루어지지 않아 성능평가에서 제외하였다. MLP모델의 경우 사용자 잠재요인과 제품 잠재요인의 수를 다르게 하여 성능평가를 하였으며 NeuMF 모델 또한 사용자 잠재요인, 제품 잠재요인, MF 잠재요인의 수를 다르게 한 후 평가치를 계산하여 가장 좋은 성능을 나타내는 잠재요인 수를 결정하였다. 전체 데이터의 70%를 훈련에 사용하고 30%는 시험용 데이터로 사용하여 성능지표를 측정하였다. 하이퍼파라미터 중

훈련의 반복횟수(epoch)는 손실 값이 최소화되는 값을 정하였다. 본 연구에서는 인플루언서를 위한 제품추천문제를 특정 인플루언서가 특정 제품을 선호할지의 이진분류로 정의하고 각 모델별로 성능을 비교하였다. 이진분류 문제에서 분류성능은 AUC, 정밀도, 재현율, F1값 등으로 측정한다.

먼저 MLP모델의 추천성능은 <Figure 5>와 같이 나타났다. <Figure 5>의 (a)는 OCF-B알고리즘의 진행단계(Term)별 AUC값의 변화를 나타내고 있다. MLP모델에 대한 학습결과 사용자잠재요인의 수가 4개, 아이템잠재요인의 수가 4개일 때 최고의 성능을 나타내어 이 모델을 사용하여 성능평가를 진행하였다. 그림에서 빨간색 점선은 부정사례 수를 긍정사례와 동일한 2,000개 만큼, 파란색 실선은 부정사례 수를 긍정사례보다 1.5배 많은 3,000개만큼 각각 생성하여 총 4,000개와 5,000개의 훈련데이터 셋을 마련하여 MLP모델을 학습한 후 모델성능을 AUC 값으로 나타낸 것이다. 실험결과 OCF-B알고리즘의 진행단계(Term)가 거듭될수록 AUC값은 점차 1에 가까워져서 더 높은 성능을 나타내는 학습모델이 구축되고 있음을 알 수 있다. OCF-B알고리즘의 마지막 진행단계인 Term 15에서의 AUC값은 부정사례의 수가 2,000개일 때 0.8868, 부정사례의 수가 3,000개일 때 0.9127로 나타나 부정사례의 수가 3,000개일 때 AUC측면에서 최고의 성능을 나타내는 것을 확인하였다.

<Figure 5>의 (b1)은 OCF-B알고리즘의 진행단계(Term)별 Positive precision값의 변화를 나타내고 있다. Positive precision은 긍정사례 관점에서의 정밀도를 나타내는 지표이다. OCF-B알고리즘의 Term 1에서의 Positive precision보다 Term 15에서의 Positive precision이 높고 알고리즘의 단계가 진행되면서 Positive precision이 우상향하는 경향을 보이고 있어서 좋은 부정사례를 훈련데이터에 추가하는 것만으로도 학습모델의 긍정사례 관점의 정밀도가 개선될 수 있음을 보여주고 있다. <Figure 5>의 (b2)에는 OCF-B알고리즘의 진행단계(Term)별 Negative precision값의 변화를 나타내고 있으며 이 또한 우상향 경향을 나타내고 있어서 알고리즘의 단계가 진행되면서 부정사례에 대한 정밀도도 한층 높아지고 있는 것을 확인할 수 있다. <Figure 5>의 (c1)과 (c2)는 OCF-B알고리즘의 진행단계(Term)별 Positive recall과



〈Figure 5〉 Performance Evaluation Results of MLP Models

Negative recall 값의 변화를 보여주고 있다. 재현을 측면에서 Positive recall은 뚜렷한 우상향의 경향을 확인할 수 있다.

〈Table 2〉는 OCF-B알고리즘의 마지막 진행단계인 Term 15에서의 Precision, Recall, f1스코어를 나타내고 있다. 그림에서 부정사례의 수가 2,000개일 때 average precision, average recall, f1스코어는 각각 0.83을 각각 나타내었으며 부정사례의 수가 3,000개일 때 average precision, average recall, f1스코어는 각각 0.85을 나타내어 부정사례의 수가 3,000개일 때 보다 우수한 성능을 보여주었다.

〈Table 2〉 Classification Report of MLP Models at the Final Term


(a) negative cases=2,000

	pre	rec	f1	sup
negative(0)	0.84	0.81	0.82	592
positive(1)	0.82	0.85	0.83	608
accuracy			0.83	
average	0.83	0.83	0.83	1200

(b) negative cases=3,000

	pre	rec	f1	sup
negative(0)	0.88	0.88	0.88	903
positive(1)	0.82	0.81	0.82	597
accuracy			0.85	
average	0.85	0.85	0.85	1500

NeuMF모델의 추천성능은 〈Figure 6〉과 같이 나타났다. 〈Figure 6〉의 (a)는 OCF-B알고리즘의 진행단계(Term)별 AUC값의 변화를 나타내고 있다. NeuMF모델의 사용자잠재요인의 수, 아이템잠재요인의 수, MF잠재요인의 수는 각각 4개일 때 최고의 성능을 나타내어 이 모델을 사용하여 성능평가를 진행하였다. 그림에서 빨간색 점선은 부정사례 수를 긍정사례와 동일한 2,000개 만큼, 파란색 실선은 부정사례 수를 긍정사례보다 1.5배 많은 3,000개 만큼 각각 생성하여 총 4,000개와 5,000개의 훈련데이터 셋을 마련하여 NeuMF모델을 학습한 후 모델성능을 AUC 값으로 나타낸 것이다. 실험결과 OCF-B알고리즘의 진행단계(Term)가 거듭될수록 AUC값은 점차 1에 가까워져서 더 높은 성능을 나타내는 학습모델이 구축되고 있음을 알 수 있다. 〈Figure 6〉의 (b1)은 OCF-B알고리즘의 진행단계(Term)별 Positive precision값의 변화를 나타내고



〈Figure 6〉 Performance Evaluation Results of NeuMF Models

있다. 그림에서 OCF-B알고리즘의 Term 1에서의 Positive precision보다 Term 15에서의 Positive precision이 높은 것을 알 수 있다. 〈Figure 7〉의 (b2)에는 OCF-B알고리즘의 진행단계(Term)별 Negative precision값의 변화를 나타내고 있으며 〈Figure 6〉의 (c1)과 (c2)는 OCF-B알고리즘의 진행단계(Term)별 Positive recall과 Negative recall 값의 변화를 보여주고 있다. Precision과 Recall그래프에서 뚜렷한 우상향의 경향은 나타나지 않았지만 Positive precision과 Negative recall 그래프에서 Term 1보다 Term 15에서 보다 높은 성능을 나타내는 것을 확인할 수 있다.

〈Table 3〉 Classification Report of MLP Models at the Final Term

(a) negative cases=2,000

	pre	rec	f1	sup
negative(0)	0.61	0.94	0.74	615
positive(1)	0.86	0.37	0.52	585
accuracy			0.66	
average	0.73	0.66	0.63	1200

(b) negative cases=3,000

	pre	rec	f1	sup
negative(0)	0.61	1.00	0.76	889
positive(1)	0.94	0.08	0.14	611
accuracy			0.62	
average	0.75	0.62	0.51	1500

〈Table 3〉은 OCF-B알고리즘의 마지막 진행단계인 Term 15에서의 Precision, Recall, f1스코어를 나타내고 있다. 그림에서 부정사례의 수가 2,000개일 때 average precision은 0.73, average recall은 0.66, f1스코어는 0.63을 나타내었으며 부정사례의 수가 3,000개일 때 average precision은 0.75, average recall은 0.62, f1스코어는 각각 0.51을 나타내어 MLP모델에 비해 저조한 성능을 보여주었다.

실험 결과를 요약해보면 인플루언서-제품 추천에 사용된 MLP모델과 NeuMF모델 모두 부정사례 추가를 통한 성능 향상을 위해 개발된 OCF-B알고리즘의 진행 단계별로 정밀도와 재현율의 우상향 경향을 나타내고 있어서 부정사례에 대한 모델 성능도 한층 높아지고 있는 것을 확인할 수 있었으며, MLP모델과 NeuMF모

델의 가중평균 정밀도, 가중평균 재현율, f1스코어의 비교 결과, MLP모델의 성능이 더 뛰어난 것으로 나타났다.

6. 결 론

인플루언서를 위한 제품 추천은 최신 비즈니스모델인 인플루언서를 위한 마케팅 플랫폼 구축의 필수 요소기술이다. 또한 최근 딥러닝 기법의 적용이 활발해지면서 딥러닝 기반의 다양한 협업필터링 기법이 소개되어 왔다. 이러한 상황에서 본 연구에서는 행렬분해기반 신경망 모델(GMF: Generalized Matrix Factorization)과 뉴럴협업필터링 모델(MLP: Neural Collaborative Filtering), 그리고 일반화 행렬분해와 결합된 뉴럴협업필터링 모델(NeuMF: Neural Collaborative Filtering and Generalized Matrix Factorization)을 인플루언서를 위한 제품 추천에 적용하고 성능평가를 시행함으로써 제품 추천에 적합한 딥러닝 모델을 제안하고, 상용화하기 위한 방안을 제시하였다. 모델 선정을 위해 실험결과를 종합해보면, MLP모델의 성능이 가장 우수했으며, 가장 높은 성능을 나타내는 모델($n=3,000$, $term=15$)에서 가중평균 정밀도, 가중평균 재현율, f1스코어는 각각 0.85로 나타났다.

본 연구에서는 인플루언서의 제품 홍보 이력을 활용하여 모델의 추천 성능을 평가하였지만 향후 추천 모델을 상용화하면 실제 회원들의 축적된 홍보이력을 토대로 추천 성능을 검증하는 후속 연구가 필요하다. 또한 홍보이력 데이터와 추천 성능의 관계를 분석하는 연구도 필요하겠다. 또한 향후 연구에서는 제품 설명 등의 텍스트 정보를 혼합한 하이브리드 CF시스템에 대한 추천 시스템으로의 확장도 필요할 것으로 보인다. 본 연구는 최근 뛰어난 성능으로 다방면에서 사용되고 있는 딥러닝모델을 인플루언서를 위한 제품 추천에 적용하여 그 가능성을 확인 했다는 점에서 의의가 있다. 또한 인플루언서의 제품 홍보 이력 데이터가 축적되고 있는 상황에서 이를 활용한 딥러닝 기반 개인화 추천시스템의 상용화를 시도함으로써 실무적 의의를 가진다.

References

- [1] Bokde, D., Girase, S., and Mukhopadhyay, D., "Matrix factorization model in collaborative filtering algorithms: A survey", *Procedia Computer Science*, Vol. 49, 2015, pp. 136-146.
- [2] Chee, S. H. S., Han, J., and Wang, K., "RecTree: An Efficient Collaborative Filtering Method", *Data Warehousing and Knowledge Discovery*, 2001, pp. 141-151.
- [3] Cheng, H., Koc, L., Harmsen, J., and Shaked, T., "Wide & deep learning for recommender systems", *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*, 2016, pp. 7-10.
- [4] Choi, D. J., Yoo, S. H., Seo, I. D., Jeong, J. Y., Song, H. S., Park, J. Y., Song, J. O., Bok, K. S. and Yoo, J. S., "Design of a trend analysis and recommendation system using beauty big data", *Proceedings of Symposium of the Korean Institute of communications and Information Sciences*, 2018, pp. 1520-1521.
- [4] Cho, Y. S., Gu, M. S., and Tyu, K. H., "Development of personalized recommendation system using RFM method and k-means clustering", *Journal of The Korea Society of Computer and Information*, Vol. 17, No. 6, 2012.
- [5] Gholamian, M., Fathian, J., M., and Mehrbod, A., "Improving electronic customers' profile in recommender systems using data mining techniques", *Management Science Letters*, Vol. 1, No. 4, 2011, pp. 449-456.
- [6] Covington, P., Adams, J., and Sargin, E., "Deep neural networks for youtube recommendations", *Proceedings of the 10th ACM Conference on Recommender Systems*, 2016, pp. 191-198.
- [7] Ha, E., Moon, J., and Hwang, E., "User's SNS data-based scoring scheme for per-

- sonalized cosmetics recommendation”, Preceeding of Korea Information Processing Society, Vol. 23, No. 2, 2016.
- [8] He, X. and Chua, T., “Neural factorization machines for sparse predictive analytics”, Proceedings of the 40th International ACM SIGIR conference on Research and Development in Information Retrieval. ACM, 2017.
- [9] He, X., Liao, L., Zhang., H., Nie, L., Hu, X., and Chua, T., “Neural collaborative filtering”, Proceedings of the 26th International Conference on World Wide Web, 2017, pp. 173-182.
- [10] Herlocker, J., Konstan, J. A., and Riedl, J., “An empirical analysis of design choices in neighborhood-based collaborative filtering algorithms”, Information Retrieval, Vol. 5, No. 4, 2002.
- [11] Iwabuchi, R., Nakajima, Y., Honma, H., Aoshima, H., Kobayashi, A., and Akiba, T., “Proposal of recommender system based on user evaluation and cosmetic ingredients”, 2017 International Conference on Advanced Informatics, Concepts, Theory, and Applications (ICAICTA), 2017, pp. 1-6.
- [12] Jung, A. Y., “Influencer marketing case analysis and marketing research proposal”, Service Marketing Journal, Vol. 12, No. 1, 2019, pp. 33-39.
- [13] Kim, S., Kim, E., and Ki, Y., “Cosmetic recommendation system using fuzzy inference and buildnig sentiment dictionary”, Journal of Korean Institute of Intelligent Systems, Vol. 27, No. 3, 2017, pp. 253-260.
- [14] Koren, Y., Bell, R., and Volinsky, C., “Matrix factorization techniques for recommender systems”, Computer, Vol. 42, No. 8, 2009, pp. 30-37.
- [15] Lee, E., Song, J., Kim, I., and Yoo, J., “Big-data analysis based mobile services using individual skin-type and genes for cosmetic recommendation”, Proceedings of Korea Contents Society, 2018, pp. 495-496.
- [16] Lee, Y., Yang, H., Choi, J., and Hur, J., “A study on comparison between association rule and collaborative filtering using the factor and k-means cluster analysis in the recommendation of cosmetics”, Journal of the Korean Data Analysis Society, Vol. 14, No. 2, 2012, pp. 689-705.
- [17] Matsunami, Y., Ueda, M., and Nakajima, S., “How to find similar users in order to develop a cosmetics recommender system”, Transactions on Engineering Technologies, 2018, pp. 337-350.
- [18] Okura, S., Tagami, Y., Ono, S., and Tajima, A., “Embedding-based news recommendation for millions of users”, In SIGKDD, 2017, pp. 1933-1942.
- [19] Patty, J. C., Kirana, E. T., and Giri, M. S. D. K., “Recommendations system for purchase of cosmetics using content-based filtering”, International Journal of Computer Engineering and Information Technology, Vol. 10, No. 1, 2018, pp. 1-5.
- [20] Song, H. S., “Deep neural network-based beauty product recommender”, Journal of Information Technology Application & Management, Vol. 26, No. 6, 2019, pp. 89-101.
- [21] Song, G. and Song, H., “Algorithm for generating negative cases for collaborative filtering recommender”, Expert Systems, <https://doi.org/10.1111/exsy.12986>, 2022.
- [22] Wang, Y., Chuang, Y., Hsu, M., and Keh, H., “A personalized recommender system for the cosmetic business”, Expert Systems

- with Applications, Vol. 26, 2004, pp. 427-434.
- [23] Yim, Y., Bae, H., Jeong, Y., Kim, M., Nasridinov, A., Yoo, K. H., and Hong, J., "A user driven cosmetic item recommendation system by character recognition", Proceeding of Korea Information Processing Society, 2016, pp. 722-725.

■ 저자소개



송 희 석

고려대학교 경영학과 학사, 한국과학기술원 경영과학과 석사 및 경영공학과 박사학위를 취득하였으며 대우전자, 대우정보시스템 기술연구소 근무를 거쳐 현재는 한남대학교 글로벌IT경영학과 교수로 재직

중이다. 관심분야는 CRM과 DataMining, 소셜네트워크, 유비쿼터스 비즈니스, 비즈니스모델 등이며 주요 연구 결과는 Knowledge-based systems, Expert systems with applications, Artificial Intelligence Review 등의 학술지에 발표하였다.



김 재 경

아주대학교 경영학과 학사, Miami University 경영학과 MBA 및 University of Nebraska-Lincoln 경영학과 박사학위를 취득하였으며 State University of New York College at Oneonta 근무

를 거쳐 현재는 한남대학교 경영정보학과 교수로 재직 중이다. 관심분야는 지식경영과 조직행동, 전자상거래, 인공지능 등이며 주요연구 결과는 International Journal of Knowledge Management, Omega, Expert systems with applications 및 다수의 국내 학술지에 발표하였다.