

심층신경망 기반의 뷰티제품 추천시스템

송 희 석*

Deep Neural Network-Based Beauty Product Recommender

Hee Seok Song*

Abstract

Many researchers have been focused on designing beauty product recommendation system for a long time because of increased need of customers for personalized and customized recommendation in beauty product domain. In addition, as the application of the deep neural network technique becomes active recently, various collaborative filtering techniques based on the deep neural network have been introduced. In this context, this study proposes a deep neural network model suitable for beauty product recommendation by applying Neural Collaborative Filtering and Generalized Matrix Factorization (NCF + GMF) to beauty product recommendation. This study also provides an implementation of web API system to commercialize the proposed recommendation model. The overall performance of the NCF + GMF model was the best when the beauty product recommendation problem was defined as the estimation rating score problem and the binary classification problem. The NCF + GMF model showed also high performance in the top N recommendation.

Keywords : Recommender, Deep Neural Network, Beauty Product, Neural Collaborative Filtering, Collaborative Filtering, Matrix Factorization

Received : 2019. 09. 20. Revised : 2019. 12. 18. Final Acceptance : 2019. 12. 20.

※ This work (Grants No. S2660157) was supported by project for Cooperative R&D between Industry, Academy, and Research Institute funded by Korea Ministry of SMEs and Startups in 2018.

* Professor, Department of Global IT Business in Hannam University, 133, Ojungdong, Daedukgu, Daejeon City, 34430, Korea, Tel : +82-42-629-8344, e-mail : hssong@hnu.kr

1. 서 론

4차 산업혁명의 핵심기술인 인공지능과 빅데이터 기술은 특정 산업분야만이 아닌 산업전반에 걸쳐 적용이 확대되면서 기존산업의 스마트화와 디지털전환을 촉진하고 있다. 특히 고객관계관리 분야에서 인공지능과 빅데이터의 적용은 축적된 고객의 과거기록을 토대로 개인화 및 맞춤형서비스를 가능케 함으로써 고객서비스의 질을 향상할 뿐 아니라 비즈니스 경쟁력 강화에 기여한다. 뷰티 산업에서도 소비자 기호의 변화와 개인 피부타입에 따른 제품 차별화 등으로 시중에 유통되는 뷰티제품의 종류가 급증하고 있으며 소비자 입장에서 정보과잉과 선택의 복잡성에 직면하여 개인화와 맞춤형 서비스에 대한 필요가 급증하고 있다. 동일한 편익을 제공하는 뷰티제품이라 하더라도 사용자의 속성이나 피부상태에 따라 특정 성분에 민감한 사용자가 있는 등 사용자 마다 선호도가 판이하기 때문에 뷰티제품은 어떤 상품보다 개인 특성에 맞춰화된 추천이 요구되는 분야이다. 이러한 이유로 뷰티제품 추천에 대한 연구는 기계학습 분야에서 오랜 기간 국내외 연구자들로부터 관심의 대상이 되어왔다. 뷰티제품 추천과 관련하여 기존에 시도된 방법들은 주로 메모리 기반의 협업필터링이나 분류모형 또는 예측모형을 이용한 내용기반추천 방법이었다. 그러나 최근 심층신경망모형의 성공으로 추천분야에도 심층신경망 모형을 적용하여 추천성능을 향상시키고자하는 시도가 늘어나고 있다. 한편 뷰티제품 추천 기술과 관련하여 국내의 상용화 현황을 살펴보면 대부분이 고객을 피부타입별로 구분하거나 화장품에 대한 사용 후기 리뷰를 공유하는 수준에 머물러 있으며(화해, 언니의 파우치 등) 피부타입이나 개인의 피부고민에 적합한 화장품을 직접 추천해주는 시스템은 아직 찾아보기 어렵다. 본 연구에서는 사용자리뷰 데이터가 축적되고 있지만 아직 개인화된 추천서비스로 연결되지 못하는 지금 상황이 뷰티제품 추천서비스 상용화의 적기라 판단하여 최근 높은 추천성능을 자랑하는 심층신경망기반 모형을 적용한 뷰티제품 추천시스템을 제안하기로 한다.

본 연구는 심층신경망 모형 중 우수한 추천 성능을 보인 것으로 보고된 행렬분해기반 신경망 모형(MF: Matrix Factorization)과 뉴럴협업필터링 모형(NCF: Neural Collaborative Filtering), 그리고

일반화 행렬분해와 결합된 뉴럴협업필터링 모형(NCF+GMF: Neural Collaborative Filtering and Generalized Matrix Factorization)을 뷰티제품 추천에 적용하고 성능평가를 시행함으로써 뷰티제품 추천에 적합한 심층신경망 모형을 제안할 뿐 아니라 이를 상용화하기 위한 웹API를 설계하여 제시하는 것을 최종 목표로 한다. 본 연구의 구성은 다음과 같다. 먼저 제2장에서는 뷰티제품 추천 분야의 추천시스템에 대한 국내외 문헌들을 조사한다. 제3장에서는 뷰티제품 추천을 위한 심층신경망 모형들을 소개하고, 제4장에서는 실험에 사용한 데이터 셋과 성능평가 방법을 제5장에서는 성능평가 결과를 요약한다. 마지막으로 제6장에서는 결론과 향후 연구방향을 제시한다.

2. 기존 뷰티제품 추천 연구

여기서는 뷰티제품 추천과 관련된 국내외 연구들을 조사하고 뷰티제품 추천시스템 개발 접근법을 검토하기로 한다. 먼저 뷰티제품 추천 관련 국내 연구로서 Kim et al.(2017)은 화장품에 사용되는 성분의 위험도에 대한 정보와 제품에 대한 소비자의 상품평을 이용하여 퍼지추론에 기반한 화장품 추천 시스템을 제안하였다. 이 연구에서는 제품별 성분정보와 사용자리뷰 정보를 파싱(Parsing)하고 전처리하여 제품 성분을 추출한 후 각 성분의 유해도 점수(EWG Score)를 이용하여 제품의 유해도를 평가한다. 또한 소비자 상품평 정보에서 형태소를 분석하고, 극성을 분류하여 감성사전을 구축하고 이를 근거로 상품평 점수를 산출한다. 최종적으로 제품 성분 점수와 상품평 점수는 퍼지 추론 과정을 거쳐 추천점수를 산출한다. 이 연구에서 제안한 방법은 소비자의 피부타입에 맞춰화된 상품 추천 방식이 아니라는 점에서 본 연구에서 지향하는 추천시스템과 다르다. 피부타입에 맞춤형된 추천 방식을 제안한 연구로는 Lee et al.(2018)의 연구가 있다. 이 연구에서는 개인마다 피부 상태에 따라 피부고민도 다르기 때문에 일반 소비자들의 화장품 사용에 대한 선호도는 나만의 것, 내 피부에 맞는 화장품, 자세한 카운슬링 순으로 선호도가 나타나고 있다고 주장하며 유전자 검사를 접목하여 피부타입을 판단하고 개인의 피부유형과 유전자 정보를 고려할 뿐 아니라 소셜 네트워크 데이터를 수집하여 빅데이터 분석을 활용

한 맞춤형 추천 서비스를 제안하였다. 이 연구에서는 유전자 검사 정보를 활용하기 때문에 유전자 정보의 제공이 어려운 온라인 추천시스템 관점에서는 오히려 이용의 장애가 될 수 있다.

한편 Lee et al.[2012]의 연구에서는 화장품 추천 분야에서 협업 필터링 추천 모형과 연관성 규칙 기법의 성능을 비교하고 있다. 이 연구에서는 협업필터링 추천모형의 확장성문제를 해결하기 위해 요인분석과 군집분석을 이용하여 데이터 차원을 축소한 후 협업필터링을 적용하는 방법을 제안하였으며 실험결과 제안한 방법이 확장성 문제를 해결하는데 기여하는 것으로 주장하고 있다. 이 방법에서 사용한 화장품의 상품수는 51개로 비교적 적은 상품수를 사용하였고, 협업필터링 기법 자체의 확장성문제가 존재한다는 점에서 연구의 한계를 찾을 수 있다. Ha et al.[2016]은 스마트폰용 휴대용 카메라를 이용하여 고객의 피부 상태를 진단한 후, 고객의 피부 개선에 적합한 화장품을 자동으로 추천하는 기법을 제안하였다. 먼저, 화장품 추천을 위해 사용자의 SNS 데이터와 피부 데이터를 수집 및 분석하여 추천 리스트를 생성하고 이를 기반으로, 추천된 각 화장품의 스코어를 계산한 다음 피부 개선 순위와 스코어 기반의 화장품 특성 순위 간의 상관계수를 이용하여 가장 높은 상관계수를 나타내는 화장품을 추천하는 방식을 사용하였다. 성능 평가를 위해 실제 화장품 회사에서 제시한 화장품 추천 리스트와 제안한 방법을 적용한 화장품 추천 리스트를 비교함으로써 효용성을 보여주고 있다. 개별 고객의 구매이력 정보를 이용하는 기존 추천 방식이 개인정보의 사용으로 인한 프라이버시 침해 우려와 구매이력 정보 수집의 어려움과 같은 한계를 가지고 있는데 비해, 이 연구의 추천방식은 개인의 피부타입에 맞춤형된 화장품을 추천한다는 점과 주름, 거칠기, 민감성, 미백, 유분 등 피부고민에 초점을 두고 이를 개선할 수 있는 화장품을 추천한다는 점에서 실무적으로 유용한 접근법이라 볼 수 있다. 그러나 추천과정에서 전문가의 정보가 많이 요구되고 SNS수집정보의 품질보장이 어렵다는 단점이 존재한다. Yim et al.[2016]은 자신의 피부 상태에 맞는 화장품을 추천하는 것을 목표로 사용자가 선호하는 화장품에 들어 있는 성분을 프로파일링하여 이와 유사도가 높은 화장품을 추천하는 시스템을 제안하였다. 즉 화장품을 구입하기 전에 상자 표면에 적힌

성분을 사진으로 찍어 이미지로부터 성분단어를 추출한 후 k-최근접 이웃 알고리즘과 내용 기반 기법을 이용하여 사용자에게 적합한 화장품을 추천한다. 이때 k-최근접 이웃 알고리즘의 유사도는 자카드 유사도를 사용한다. 이 연구는 화장품의 성분표를 통해 DB에 없는 화장품이라도 즉석에서 사용자의 정보와 비교하여 적정도를 분석할 수 있다는 장점이 있으나 선호성분 외에 개인의 취향이나 선호도는 반영하지 못한다는 단점이 있다.

Cho et al.[2012]는 실시간성과 민첩성이 요구되는 유비쿼터스 상거래에서 고객에게 번거로운 질의응답 과정이 없이 묵시적인(Implicit) 방법을 이용하여 RFM(Recency, Frequency, Monetary)기법과 k-means 기법을 이용한 개인화 추천시스템을 제안하였다. 이를 위해 효율성이 높은 아이템 추천이 가능하도록 고객정보의 속성 변수의 특징 벡터가 적용된 클러스터링 작업과 군집내의 아이템 카테고리 선호도 계산 작업의 전처리를 수행한다. 성능평가를 위해 협업에서 사용하는 인터넷 화장품 아이템 소평몰의 데이터를 기반으로 데이터 셋을 구성하여 기존 시스템과 비교 실험을 통해 성능을 평가하여 유용성을 입증하였다. 이 연구 또한 피부타입을 고려하지 않은 추천방법이며, 클러스터링 기법을 사용하기 때문에 엄격한 의미에서 개인화 추천이라고 보기는 어렵다. Choi et al.[2018]은 뷰티 빅데이터를 활용한 트렌드 분석 및 추천 시스템을 제안하였다. 제안하는 기법에서는 빅데이터 처리를 위해 Kafka, Storm 그리고 HBase와 같은 NoSQL 데이터베이스를 사용하여 화장품 관련 정보뿐만 아니라 SNS에서 발생하는 뷰티 관련 정보들을 수집하여 분석에 활용한다. 수집된 데이터는 핫-토픽 분석과 트렌드 분석, 사용자 맞춤형 개인 추천을 위한 분석에 사용된다. 이 시스템은 사용자에게 맞는 제품이 아니라 제품을 구매할만한 사용자를 역으로 찾아내서 화장품 제조 회사에게 새로운 제품의 시장 가치 혹은 규모에 대한 통계정보를 제공하는 것을 최종 목표로 하고 있다. 이 연구는 빅데이터와 상황정보를 통합하여 뷰티제품 추천에 활용한다는 점에서 차별화된 연구라 할 수 있다.

뷰티제품 추천과 관련된 해외 연구로는 Gholamian et al.[2011], Iwabuchi et al.[2017], Matsunami et al.[2017], Wang et al.[2004] 등의 연구가 있다.

Gholamian et al.[2011]은 협업필터링을 기반으로 시간적 상황을 고려한 추천 시스템 모형을 제안하였다. 이 연구에서는 추천성능 향상을 위해 시간 컨텍스트 및 고객 그룹정보를 이용하여 추천을 수행하였으며 성능평가 실험 결과도 제시하고 있다. 이 연구는 사용자가 최근에 선호했던 아이템에 보다 높은 가중치를 부여하여 추천을 하는 시간의존적인 방법이라는 점에서 의의를 찾을 수 있다. Iwabuchi et al.[2017]은 화장품 제품 리뷰가 서로 상반되는 내용이 많아 소비자가 제품 선택에 어려움이 있음을 파악하고 화장품 리뷰 정보로부터 소비자의 피부고민을 해결해 줄 수 있는 화장품을 추천해주는 시스템을 제안하였다. 이 연구에서는 일본의 대형 화장품 사이트인 @cosme 웹사이트에 추천 기능이 있기는 하지만 협업필터링 추천 방식을 채택하고 있어서 추천이유에 대한 설명이 어렵다고 지적하고 소비자의 피부고민 별로 이를 해결할 수 있는 적합한 성분을 사용자 리뷰로부터 도출하고, 이러한 성분이 많이 함유된 화장품을 추천하는 방식으로 추천시스템을 제안하였다. 이들은 화장품 개수가 가장 많은 스킨로션 카테고리를 선정하여 추천시스템을 개발하였으며, 스킨로션의 효능(소비자 측면에서는 피부고민)을 수분공급, 모공, 여드름, 미백, 저자극, 항노화, 자외선차단, 피부탄력, 사용감, 각질치료, 지방공급, 타이팅, 클린징, 가성비, 유기농제품의 15가지 효능으로 구분하였고, 화장품에 대한 성분정보는 Bihada-Mania 웹사이트에서 수집하여 추천에 활용하였다.

Matsunami et al.[2017]은 화장품 제품에 대한 리뷰는 부정적일 제품으로 인한 피부 자극의 가능성 때문에 구매 결정에 중요한 영향을 미친다고 주장

하고 사용자 리뷰에 기반한 뷰티제품 추천시스템과 사용자 유사성 계산 방법을 제안하였다. 즉 실제 온라인 리뷰의 관용구로 구성된 평가 사전을 기반으로 화장품 아이템 리뷰 텍스트 기반의 자동 스코어링 방법을 제안하고 사용자 유사성을 계산하는 방법을 제시하였다. 이 방법은 리뷰 텍스트를 분석하여 효능별 별점을 자동으로 부여하는 것으로 화장품 추천을 위해 필요한 중간단계의 데이터를 제공한다는 점에서 기존연구와 차별화된 시도라 볼 수 있다. Patty et al.[2018]은 TF-IDF 방식으로 계산된 프로파일을 이용한 내용기반 필터링 방법을 사용하여 화장품에 대한 추천시스템을 제안하였다. 이 연구에서는 내용기반 필터링에 사용되는 키워드를 7가지 화장품 타입(페이셜워시, 토너, 모이스처, 자외선차단제, 파우더, 마스크, 세럼)과 2가지 사용시기(낮, 밤), 4가지 피부타입(건성, 표준, 지성, 혼합), 5가지 가격대를 사용한 키워드로 사용자 프로파일을 구성하였으며, 신규회원에게는 상기 키워드를 직접 입력하도록 하는 방식으로 추천을 진행하고 있다. 유사도 척도는 코사인척도를 사용하였다. Wang et al.[2004]은 맞춤형 화장품 추천을 위한 컨텐츠 및 협업필터링 기술을 통합한 추천 시스템을 제안하며 새로운 제품에 대한 고객의 관심도 점수를 결정하기 위한 점수 부여 방식을 소개하였다. 이 연구에서는 클러스터링 알고리즘을 사용하여 유사한 구매 행동을 보이는 고객을 여러 그룹으로 나눈 후 연관성 규칙을 생성하여 화장품에 대한 추천점수를 계산하는 방식을 제안한 바 있다. 이상 기존 뷰티제품 추천과 관련된 연구를 요약하면 <Table 1>과 같이 추천시스템 개발 접근법에 따라 구분할 수 있다.

<Table 1> Approaches for Developing Beauty Recommender

Development Approaches	Applied Techniques	References
Review text-based	Text mining	Matsunami et al.[2017], Patty et al.[2018]
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], Wang et al.[2004]
Time dependent	CF	Choi et al.[2018], Gholamian et al.[2011]

3. 뷰티 제품 추천시스템

본 연구에서는 심층신경망 모형에 기반한 뷰티제품 추천시스템을 제안한다. 이를 위해 다음과 같은 설계 목표를 제시한다. 첫째, 뷰티 추천시스템은 사용자 개인의 성별, 연령, 피부타입 뿐 아니라 피부고민까지 고려한 맞춤형 뷰티제품 추천이 가능해야 한다. 둘째, 피부타입에 대한 적합도와 동시에 개인의 선호도를 동시에 반영한 추천이 이루어져야 한다. 셋째, 새로운 사용자가 추천을 요청할 때, 사용자-아이템 선호 매트릭스가 존재하지 않아 추천이 곤란한 문제(Cold start 문제라고 함)를 해결하여 처음 사용자에게도 적절한 추천이 이루어질 수 있어야 한다. 넷째, 사용자가 등록한 후기가 자동으로 추천에 피드백되는 진화적 추천시스템으로 구성하여야 한다.

한편, 뷰티제품 추천을 위한 방법으로 협업필터링방식과 내용기반 추천방식, 이들을 결합한 하이브리드 추천방식이 적용될 수 있다. 이 중 협업필터링 방식은 모든 도메인에 동일하게 적용 가능한 범용성을 갖추고 있으며, 가끔 우연에 의한 추천이 가능하다는 장점이 있다. 무엇보다도 협업필터링 방법은 최근 우수한 성능을 나타내어 각광받고 있는 다양한 심층신경망 기법과 연계한 설계모형이 다량 출현하고 있어 추천 성능을 향상시킬 수 있는 높은 잠재력을 보유하고 있다. 그러나 협업필터링기법이 가진 치명적인 단점은 새로운 사용자가 시스템에 등록했거나 새로운 아이템이 등장했을 때, 사용자-아이템 선호 매트릭스 정보가 존재하지 않기 때문에 추천을 하지 못하는 콜드스타트(Cold start) 문제가 존재한다는 점이다. 본 연구에서는 이를 해소하기 위해 사용자를 개인단위로 분석하기 보다는 동일한 사용자특성과 피부고민을 가지고 있는 사용자들을 그룹으로 형성하여 신규사용자 일지라도 해당 사용자 그룹을 발견하여 해당그룹의 선호제품 정보를 토대로 추천이 가능하도록 설계한다. 결국 본 연구에서는 협업필터링 방식의 심층신경망 추천모형을 적용하여 뷰티제품 추천 시스템을 개발한다[Chee et al., 2001; Herlocker et al., 2002]. 협업필터링 방식은 기존 사용자의 구매후기를 집약하여 해당 사용자와 비슷한 성향의 사용자들이 선호한 아이템을 추천하는 방식이다. 협업필터링 방식은 유사도 측정 대상에 따라 사용자 기반(User-based CF)과 아이템 기반

(Item-based CF)으로 구분할 수 있다. 이 중 사용자 기반 추천은 다음과 같은 절차로 이루어진다. 첫째, 뷰티제품에 대한 사용자리뷰를 읽어 들인 후, 연령대 피부타입 등 같은 사용자 특성과 피부고민을 가진 사용자그룹을 형성하여 사용자그룹-아이템 선호행렬을 생성한다. 둘째, 아이템에 대한 선호패턴을 기준으로 사용자그룹 간 유사도 행렬을 생성한다. 셋째, 사용자그룹 i 가 뷰티제품 k 를 얼마나 좋아할지를 다음 식으로 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

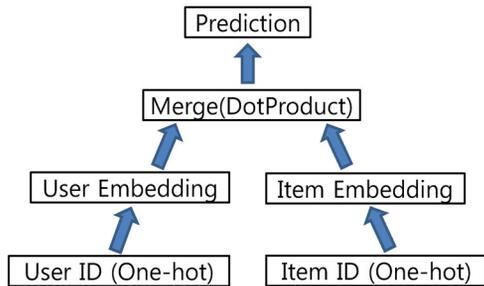
r_{jk} : 사용자그룹 j 가 뷰티제품 k 에 대해 평가한 (평균)점수

N_i : 사용자그룹 i 와 선호패턴이 유사한 이웃사용자 그룹들

$sim(i,j)$: 사용자그룹 i 와 j 의 선호패턴 유사도

본 연구에서 검토하는 심층신경망 모형들은 모두 이러한 협업필터링 방법에 기반을 두고 있다. 여기서는 우수한 추천 성능을 보인 것으로 보고된 행렬분해기반 신경망 모형(MF: Matrix Factorization)과 뉴럴협업필터링 모형(NCF: Neural Collaborative Filtering), 그리고 일반화 행렬분해와 결합된 뉴럴협업필터링 모형(NCF+GMF: Neural Collaborative Filtering and Generalized Matrix Factorization)을 뷰티제품 추천에 적용하여 그 성능을 평가하기로 한다. 첫째 뷰티제품 추천모형은 전통적인 모형기반 추천방식 중 하나인 행렬분해(Matrix Factorization) 방식의 협업필터링 추천이다[Bokde et al., 2015; Koren et al., 2009]. 이 방법 또한 연령대, 피부타입 등 같은 사용자 특성과 피부고민을 가진 사용자들을 그룹으로 형성하여 사용자그룹-아이템 선호행렬을 생성한다는 점에서는 기존의 메모리기반 협업필터링 방식과 동일하다. 그러나 행렬분해 방법에서는 사용자그룹-아이템 선호행렬을 P와 Q 두 개의 소행렬로 분해한 후 재조합하는 방식을 사용하며 이 때 주로 사용되는 방법이 잠재요인(Latent Factor) 모형이다. 사용자의 특성 벡터나 상품의 특성 벡터의 길이는 수천에서 수십억에 달하는 긴

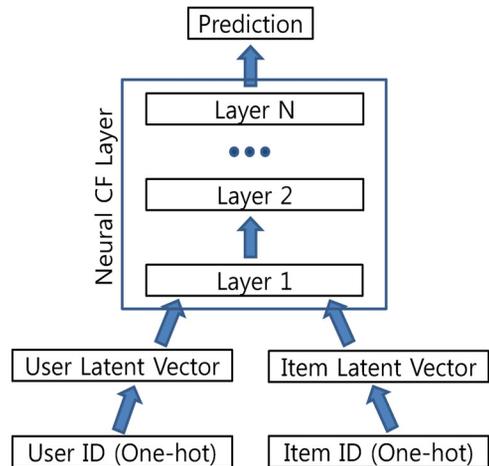
크기가 될 수도 있다. 잠재요인모형은 이렇게 긴 사용자 특성이나 상품 특성을 몇 개의 요인 벡터로 간략화 할 수 있다는 가정에서 출발한다. 여기서는 인공신경망을 이용하여 행렬분해기반의 협업필터링모형을 구현하고자 한다. 신경망을 이용한 행렬분해기반의 협업필터링모형은 입력층과 임베딩층, 그리고 임베딩층에서 산출된 벡터의 내적을 계산하는 출력층으로 구성된다. 여기서 임베딩층은 잠재요인벡터라고도 불리어지며, 사용자 또는 아이템과 같은 카테고리 데이터를 저차원의 고밀도 벡터로 변환하는 층이다. 충분한 학습이 이루어지면 임베딩층의 출력벡터는 유사한 아이템 또는 유사한 사용자 간에는 거리가 가까운 벡터로 출력이 이루어짐을 알 수 있다. 아래 <Figure 1>은 행렬분해기반의 협업필터링 모형에 대한 인공신경망 구조를 나타내고 있다.



<Figure 1> Matrix Factorization based neural network model
[Adapted from Bokde et al., 2015; Koren et al., 2009]

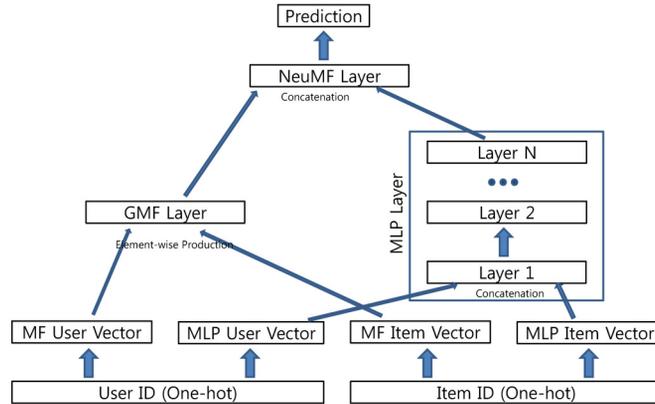
두 번째 적용모형은 뉴럴협업필터링 모형(NCF: Neural Collaborative Filtering)이다. Covington et al.[2016]은 비디오추천을 위한 심층신경망 기반의 추천알고리즘을 제안하여 Youtube에 적용한 결과 동영상 클릭의 60%가 알고리즘에 의해 추천된 동영상이라는 성과를 창출한 바 있다. Cheng et al.[2016]은 심층신경망 기반의 구글 플레이용 앱 추천시스템을 제안하였고, Shumpei et al.[2017]은 야후뉴스를 위한 순환신경망 기반의 뉴스추천시스템을 제안하여 그 유용성을 확인한 바 있다. 이들 심층신경망 기반의 추천 모형들은 전통적인 모형에 비해 현저한 성능향상을 나타내고 있어 심층신경망은 추천분야의 혁명을 이끌고 있다. 추천분야에서 심층신경망 모형 적용의 잇점은 다음과 같다. 첫째, 심층신경망 모형은 비선형모형으로 행렬

분해(Matrix Factorization)와 같은 선형모형에 비해 복잡한 상호 작용을 잘 처리하고 사용자의 선호도를 정확하게 학습하는 것이 가능하다. 둘째, 심층신경망은 대용량의 사용자-아이템 선호정보에 내재된 특징들을 자동으로 학습할 수 있으며 텍스트, 이미지, 오디오, 비디오 등 이질적인 정보를 포함한 추천모형 구성이 가능하다는 장점이 있다. 셋째, 심층신경망 모형은 시간에 따라 변화하는 사용자 선호패턴과 아이템에 대한 선호체계의 진화를 모형에 반영할 수 있다는 장점이 있다. 마지막으로 심층신경망은 다른 구조의 신경망 모형과 결합하여 하이브리드 모형을 만드는 것이 용이하여 다른 특성을 갖는 입력정보와 특징을 결합한 유연한 추천기 개발이 가능하다. 여기서는 추천분야에 적용된 He et al.[2017]과 He and Chua[2017]에 의해 제안된 뉴럴협업필터링(Neural CF: 이하 NCF)모형을 뷰티제품 추천에 적용하여 전통적인 추천기법과 비교하여 성능을 평가하고자 한다. <Figure 2>에 나타나 있듯이 NCF는 잠재공간에서 사용자-항목 간 복잡한 상호 작용을 적절히 예측 가능하기 때문에 전통적인 행렬분해기반 모형보다 높은 성능을 나타내는 것으로 알려져 있다.



<Figure 2> Neural collaborative filtering model (Adapted from He et al., 2017; He and Chua, 2017)

한편 He et al.[2017]은 행렬분해 기법(Generalized matrix factorization)과 NCF를 결합한 하이브리드 모형을 제안하여 추천성능을 개선할 수 있음을 제안한 바 있다. 본 연구에서도 NCF+GMF 기반의



〈Figure 3〉 Generalized Matrix Factorization with Neural Collaborative Filtering Mode[Adapted from He et al., 2017]

추천모형을 뷰티제품 추천에 적용하여 그 성능을 확인해 보기로 한다. NCF와 GMF를 결합하는 방식은 아래 〈Figure 3〉에서와 같이 각각 공유된 임베딩층으로 부터의 출력값을 입력 받아 학습을 별도로 진행한 후 마지막 은닉층에서 이들을 연결(Concatenation) 하는 방법으로 결합모형이 구성된다. 그림에서 GMF Layer는 MF user vector와 MF item vector간의 element-wise product로 계산하는데 이를 위해 MF user vector와 MF item vector를 일차원 벡터로 변환하는 작업을 수행한 후 각 원소를 곱하는 방식으로 GMF Layer를 계산한다.

4. 성능평가 방법

여기서는 뷰티제품 추천문제를 다양한 방식으로 정의하고 각기 다른 성능 평가지표를 활용하여 성능평가를 수행하기로 한다. 먼저 뷰티제품 추천문제를 사용자 선호도에 대한 예측문제로 정의할 수 있다. 즉 특정 사용자가 특정 아이템을 얼마나 좋아할지를 5점 척도의 연속형 값으로 예측하는 것이 목표이며 이 때 활용될 수 있는 성능지표로 평균제곱근오차(Root Mean Square Error: RMSE)가 있다. 평균제곱근오차(Root Mean Square Error: RMSE)는 추정 값 또는 모형이 예측한 값과 실제 환경에서 관찰되는 값의 차이를 다룰 때 흔히 사용하는 지표이다. 사용자의 취향이나 선호도에 기반하여 아이템을 추천하는 알고리즘의 경우 사용자의 평가치(선호도)와 예측된 평가치(선호도)의 차이의 제곱합을 이용하여 RMSE를 계산하는 것이 일반적이다.

RMSE 계산 공식은 다음과 같다.

$$\text{추천오류율(RMSE)} = \sqrt{\frac{\sum_i (p_i - a_i)^2}{n}}$$

p_i : i 번째 후기에 대한 예측 선호도

a_i : i 번째 후기의 실제 선호도

n : 후기 수(number of review)

추천문제를 정의하는 두 번째 방법은 특정사용자가 특정 뷰티제품을 좋아할지 여부를 예측하는 것으로 추천문제를 이진 분류문제로 정의하는 것이다. 이 때 사용될 수 있는 지표로는 정밀도(Precision)와 재현율(Recall), f1, AUC가 있다. 본 연구에서 정밀도는 “추천모형에서 만족이라고 예측된 사용자-아이템 쌍 중 실제 후기에서도 만족했던 사용자-아이템 쌍의 비율”로 계산한다. 또한 재현율은 “실제 후기에서 만족했던 사용자-아이템 쌍 중 추천모형에서도 만족으로 예측된 사용자-아이템 쌍의 비율”로 계산한다. 정밀도와 재현율, f1-score의 계산 공식은 다음과 같다.

$$\text{정밀도(Precision)} = \frac{\|P \cap A\|}{\|P\|}$$

$\|P \cap A\|$: 만족으로 예측된 사용자-아이템 쌍 중 실제 후기에서도 만족으로 나타난 사용자-아이템 쌍의 수

$\|P\|$: 만족으로 예측된 사용자-아이템 쌍의 수

$$\text{재현율(Recall)} = \frac{\|A \cap P\|}{\|A\|}$$

$\|A \cap P\|$: 실제후기에서 만족한 사용자-아이템 쌍 중 추천모형에서도 만족으로 예측된 사용자-아이템 쌍의 수

$\|A\|$: 실제후기에서 만족한 사용자-아이템 쌍의 수

$$f1\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

한편 모형의 성능을 나타내는 방법으로 ROC그래프가 있다. ROC 그래프는 가로축을 특이도(Specificity)로 하고 세로축을 재현율(Recall) 또는 민감도(Sensitive)로 하여 시각화 한 그래프이다. 일반적으로 ROC 그래프가 위로 향할수록 성능이 우수한 모형이라 할 수 있다. 이때 ROC는 그래프이기 때문에 모형의 정확도를 하나의 숫자로 나타내기 쉽도록 AUC(Area Under Curve) 라는 값을 사용하는데, AUC값은 ROC 그래프의 면적으로 계산하며 최대값은 1이 된다. 일반적으로 이진분류문제의 경우 분류임계값에 따라 예측정확도가 달라질 수 있다. 즉 분류 임계값을 낮추면 더 많은 항목이 양성으로 분류되므로 참양성율(TPR)과 거짓양성율(FPR)이 모두 증가하게 된다. 이 때 ROC커브나 AUC값을 사용하면 모든 가능한 분류 임계값을 고려한 예측 성능을 비교할 수 있다. AUC는 특정모형이 임의 양성 예제를 임의 음성 예제보다 더 높게 평가할 확률로 정의할 수 있다. 추천문제를 정의하는 세 번째 방법은 뷰티제품 추천 문제를 톱N 추천문제로 정의하는 방법이다. 이 방법은 사용자가 가장 좋아할 만한 톱 N개의 제품을 추천하고, 이 중 사용자가 실제 좋아하는 제품이 얼마나 포함되어 있는지 또는 사용자가 실제 좋아하는 제품이 추천결과에 얼마나 포함되었는지를 측정하여 성능을 평가하는 것으로 성능평가 지표로는 톱N정밀도(Precision@N)와 톱N재현율(Recall@N)이 있다. 본 연구에서는 각각의 계산공식을 다음과 같이 정의하여 사용하기로 한다.

$$\text{톱N정밀도(Precision@N)} = \frac{\|P^{\text{Q}} \cap A^{\text{Q}}\|}{\|P^{\text{Q}}\|}$$

$\|P^{\text{Q}} \cap A^{\text{Q}}\|$: 특정사용자에게 추천된 제품 중 실제 해당 사용자가 선호했던 제품의 수

$\|P^{\text{Q}}\|$: 특정 사용자에게 추천된 제품의 수

$$\text{톱N재현율(Recall@N)} = \frac{\|A^{\text{Q}} \cap P^{\text{Q}}\|}{\|A^{\text{Q}}\|}$$

$\|A^{\text{Q}} \cap P^{\text{Q}}\|$: 특정사용자가 실제 선호했던 제품 중 추천된 제품의 수

$\|A^{\text{Q}}\|$: 특정 사용자가 실제 선호했던 제품의 수

5. 실험결과

5.1 데이터셋

본 연구에서는 화장품과 관련된 인터넷 커뮤니티로부터 스킨케어 4종(클렌저, 토너, 모이스춰라이저, 썬스크린)에 대한 총 59개 뷰티제품을 대상으로 각 카테고리당 250개씩 총 1,000개의 사용자리뷰 데이터를 수집하여 추천성능을 실험하였다. 상기 네 개의 카테고리는 뷰티제품 사용자가 제품 선택에 있어서 가장 고민을 많이 하는 분야이기도 하다. 실험에 사용된 데이터의 사용자 특성과 피부타입은 다음과 같이 코드화 하여 사용하였다 (<Table 2>). 타겟변수는 5점 척도의 사용자후기 평점으로 이를 이진 변환하여 3점 초과이면 1(만족), 3점 미만이면 0(불만족)으로 표현하여 학습에 사용한다.

<Table 2> Attributes of Dataset and Code

Attribute	Value	Code
Sex	Female	U1
	Male	U2
Age	10~	10
	20~	20
	30~	30
	40~	40
	50~	50
Skin Type	Dry	DR
	Neutral	NE
	Oilly	OI
	Complex	CO
	Sensitive	SE

5.2 실험결과

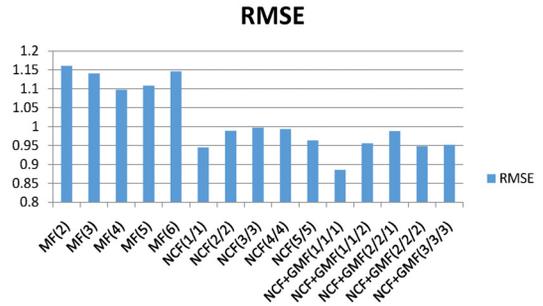
실험에 사용된 모형은 MF, NCF, NCF+GMF 모형이다. MF 모형은 잠재요인(Latent factor)의 수를 2에서 5까지로 달리하며 예측을 수행하였다. 또한 NCF

모형의 경우 사용자잠재요인과 아이템잠재요인의 수를 각각 달리하여 예측을 하였으며 NCF+GMF 모형 또한 사용자잠재요인, 아이템잠재요인, MF잠재요인의 수를 각각 달리하여 평가치를 예측하였다. 성능평가를 위해 전체 데이터셋의 70%는 훈련용으로 30%는 시험용으로 구분하고, 시험용 데이터에 대해 성능지표를 측정하였다. 이때 훈련용 데이터와 시험용 데이터의 무작위 구분에 따른 측정값의 편차를 통제하기 위해 10회에 걸친 시험용 데이터 추출과 시험을 수행하여 결과를 평균하는 방식으로 최종 성능지표를 계산하였다. 각 모형을 훈련하는 과정에서 다양한 파라미터의 설정이 필요하다. 이 중 최적의 성능을 나타낼 수 있도록 학습 반복횟수(epoch)를 결정하는 것이 무엇보다 중요하다. 훈련 시 반복횟수(epoch)는 시험용 데이터에서 손실 값이 최소화되는 지점을 선정하였다. MF추천기의 경우 반복횟수가 200일 때 손실 함수값이 최소였기 때문에 반복횟수를 200회로 설정하여 실험하였다. 검증용 데이터는 훈련데이터의 33%로 설정하였다. <Figure 1>은 각 모형별로 반복횟수별 손실함수 값의 변화를 나타내고 있으며 손실함수 값이 더 이상 낮아지지 않는 지점에서 반복횟수를 결정하여 훈련에 사용하였다.

5.2.1 예측 오류율 비교

여기서는 뷰티추천문제를 사용자별 뷰티제품에 대한 평가치를 예측하는 문제로 정의하여 시험용 데이터에 대해 평가치를 예측한 후 RMSE를 계산하였다. 실험결과 모형별 RMSE는 <Figure 5>와 같다. 그림에서 모형이름의 괄호에 나타난 숫자는 실험에 사용된 모수값으로 MF 모형의 경우 임베딩벡터의 차원을 의미하며, NCF와 NCF+GMF 모형의 경우 잠재요인

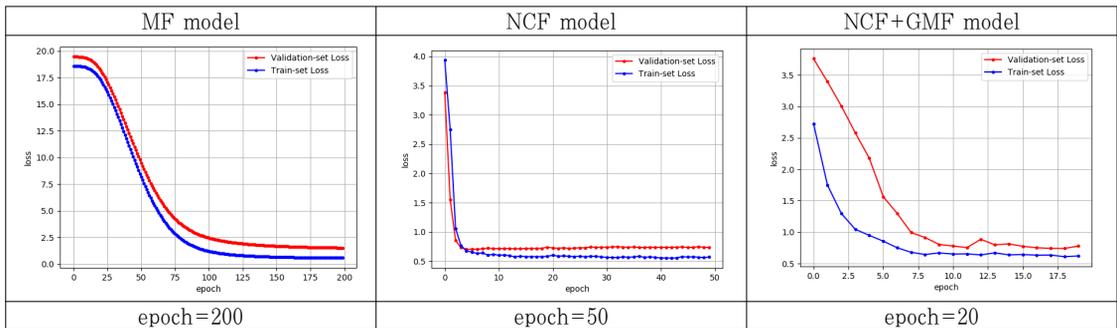
의 수를 각각 나타내고 있다. 수집된 데이터가 많지 않았음에도 불구하고 RMSE측면에서 NCF+GMF 모형이 전반적으로 낮은 오류율을 보여주었다. 특히 NCF+GMF(1/1/1)모형의 경우 RMSE가 0.8852로 가장 낮은 값을 보여주었다.



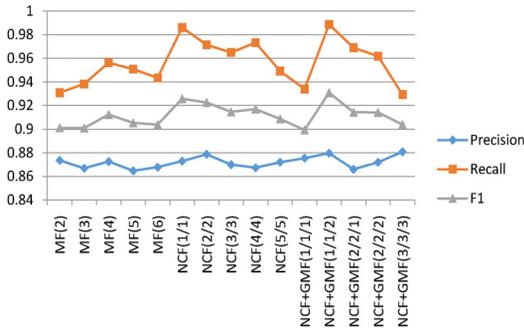
<Figure 5> RMSE by Models

5.2.2 이진분류 문제에서의 성능비교

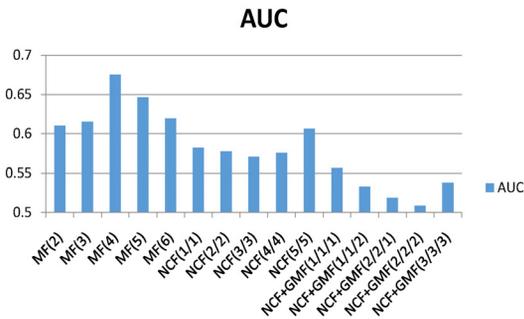
여기서는 추천문제를 사용자가 특정 뷰티제품을 좋아할지 여부의 이진분류문제로 정의하고 각 모형별로 분류 성능을 비교하였다. 이진분류 문제에서 분류성능은 정밀도, 재현율, F1값으로 측정하였다. 이진 분류성능 측면에서는 NCF+GMF(1/1/2) 모형이 정밀도는 0.8796, 재현율은 0.9887, F1값은 0.9309로 가장 높게 나타났으며, 모형별로 재현율의 차이는 상대적으로 많았지만 정밀도의 차이는 미미하였다. <Figure 6>은 모형별 이진분류 성능을 보여주고 있다. AUC측면에서는 MF 모형이 우수한 것으로 나타났다. 특히 MF(4)모형의 경우 AUC값이 0.6753으로 나타나 가장 우수한 성능을 보여주었다(<Figure 7> 참고).



<Figure 4> Determination of Epoch



〈Figure 6〉 Precision, Recall, and F1-Score by Models



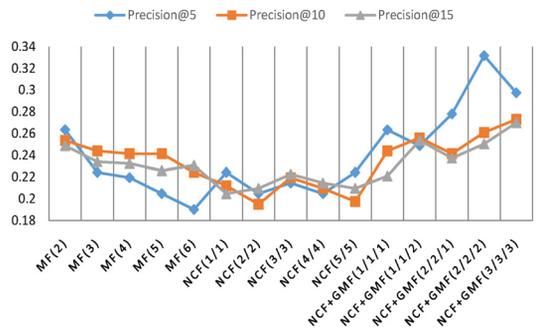
〈Figure 7〉 AUC by Models

결과적으로 뷰티제품 추천문제를 평가치 예측 문제로 정의했을 때는 NCF+GMF 모형의 성능이 가장 우수했으나, 이진분류 문제로 정의했을 때는 성능은 정밀도 측면에서는 MF 모형의 성능이 다른 모형에 비해 상대적으로 낮았으나 AUC측면에서는 높은 성능을 보여주었다. 이러한 결과는 평가치 예측과 달리 상대적으로 간단한 이진분류에서는 고차함수로 표현되는 NCF+GMF 모형을 굳이 사용하지 않고 MF 모형을 적용하더라도 의미있는 분류가 가능함을 보여준 것으로 판단된다. 따라서 뷰티제품 추천문제를 이진분류 문제로 정의할 경우 MF 모형을 적용하는 것도 나쁘지 않은 선택임을 알 수 있다.

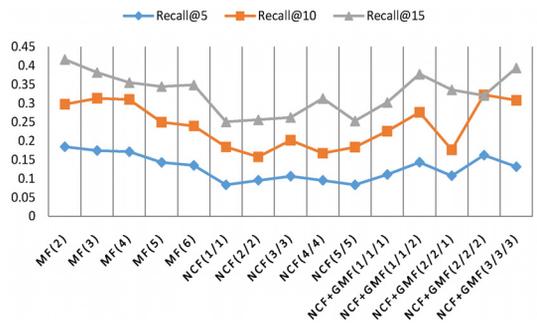
5.2.3 톱N추천 성능 비교

여기서는 실제로 사용자에게 해당 사용자가 좋아할 만한 제품 N개를 추천하고 추천결과에 대한 성능을 평가한다. 이를 위해 사용자리뷰 파일로부터 각 사용자별 선호상품 리스트를 만들고 추천된 N개의 상품 중 선호상

품이 몇 개나 포함되었는지(Precision@N)와 각 사용자의 선호상품 중 추천리스트에 포함된 상품이 얼마나 있는지(Recall@N)를 계산하여 추천성능을 비교하고자 한다. 본 실험에서는 추천제품 수를 5개, 10개, 15개로 변화시키면서 정밀도와 재현율을 측정하였다. Precision@5의 경우, NCF+GMF(2/2/2)모형이 0.3317로 가장 높게 나타났으며, Recall@5는 MF(2)모형이 0.1847로 가장 높게 나타났다. Precision@10의 경우, NCF+GMF(3/3/3)모형이 0.2731로 가장 높게 나타났으며, Recall@10은 NCF+GMF(2/2/2)모형이 0.3229로 가장 높게 나타났다. Precision@15의 경우, NCF+GMF(3/3/3)모형이 0.2699로 가장 높게 나타났으며, Recall@15는 MF(2)모형이 0.4165로 가장 높게 나타났다. 정밀도 측면에서 보면 NCF+GMF 모형의 정밀도가 모든 톱N추천에서 전반적으로 높게 나타났다. 재현율 측면에서 보면 MF 모형과 NCF+GMF 모형의 재현율이 모든 톱N추천에서 전반적으로 높게 나타났다(〈Figure 8〉, 〈Figure 9〉).



〈Figure 8〉 Precision@N by Models



〈Figure 9〉 Recall@N by Models

6. 결 론

뷰티제품 추천 분야는 개인화 및 맞춤형 추천의 필요성이 매우 높은 분야로 오랫동안 관련 연구자들의 관심이 집중되어 왔다. 또한 최근 심층신경망 기법의 적용이 활발해지면서 심층신경망 기반의 다양한 협업 필터링 기법이 소개되어 왔다. 이러한 상황에서 본 연구에서는 심층신경망 모형 중 우수한 추천 성능을 보인 것으로 보고된 행렬분해기반 신경망 모형(MF: Matrix Factorization)과 뉴럴협업필터링 모형(NCF: Neural Collaborative Filtering), 그리고 일반화 행렬분해와 결합된 뉴럴협업필터링 모형(NCF+GMF: Neural Collaborative Filtering and Generalized Matrix Factorization)을 뷰티제품 추천에 적용하고 성능평가를 시행함으로써 뷰티제품 추천에 적합한 심층신경망 모형을 제안할 뿐 아니라 이를 상용화하기 위한 웹API를 설계하여 제시하였다. 모형 선정과 관련하여 전체적인 실험결과를 종합하면 뷰티제품 추천문제를 평가치 예측 문제로 정의했을 때는 NCF+GMF 모형의 성능이 가장 우수했으며, 이진분류 문제로 정의했을 때는 정밀도 측면에서는 MF 모형의 성능이 다른 모형에 비해 상대적으로 낮았으나 AUC 측면에서는 높은 성능을 보여주었다. 마지막으로 톱N추천 성능에서는 정밀도는 NCF+GMF 모형이 재현율은 NCF+GMF 모형과 MF 모형이 전반적으로 높은 성능을 나타내었다.

본 연구에서는 사용자 후기를 활용하여 추천성능을 평가하였지만 향후 추천시스템이 상용화 되면 실제 사용자의 사용 만족도를 토대로 추천 성능을 확인하는 추가적인 연구가 필요할 것이다. 또한 사용자 후기 데이터가 증가하면서 추천성능이 어떻게 변화하는지를 동시에 분석하는 연구도 필요할 것이다. 또한 향후 연구에서는 가용 예산, 브랜드 선호도 등을 함께 사용하여 추천이 가능한 시스템으로의 확장도 필요할 것으로 보인다. 그럼에도 불구하고 본 연구는 최근 각광받고 있는 심층신경망모형을 뷰티제품 추천에 적용하여 모형의 성능과 실제 상용화 가능성을 확인했다는 점에서 의의가 있다. 또한 사용자리뷰 데이터가 축적되고 있지만 아직 개인화된 추천서비스로 연결되지 못하는 국내 상황에서 이를 활용한 심층신경망 기반 추천시스템의 상용화를 시도했다는 점에서 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. T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., Anderson, G., Corrado, G., Chai, W., Ispir, M., and others, *Wide & deep learning for recommender systems*, In Recsys, 2016, pp.7-10.
- [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] 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.
- [6] Covington, P., Adams, J., and Sargin, E., *Deep neural networks for youtube recommendations*, In Recsys, 2016, pp.191-198.
- [7] 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.
- [8] Ha, E., Moon, J., and Hwang, E., "User's SNS Data-Based Scoring Scheme For Personalized Cosmetics Recommendation," *Preceeding of Korea Information Pro-*

- cessing Society, Vol. 23, No. 2, 2016.
- [9] He, X. and Chua, T. S., *Neural Factorization Machines for Sparse Predictive Analytics*, 2017.
- [10] He, X., Liao, L., Zhang, H., Nie, L., Hu, X., and Chua, T. S., *Neural collaborative filtering*, In WWW, 2017, pp. 173-182.
- [11] 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.
- [12] Iwabuchi, R., 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.
- [13] Kim, S. E., Kim, E. K., and Ki, Y. G., "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.
- [15] Lee, E. J., Song, J. O., Kim, I., and Yoo, J. S., "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.
- [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.
- [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] Wang, Y. F., Chuang, Y. L., Hsu, M. H., and Keh, H. C., "A personalized recommender system for the cosmetic business," *Expert Systems with Applications*, Vol. 26, 2004, pp. 427-434.
- [21] Yim, Y. J., Bae, H. S., Jeong, Y. J., Kim, M. Y., Nasridinov, A., Yoo, K. H., and Hong, J. E., "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 Data Mining, 소셜네트워크, 유비쿼터스 비즈니스, 비즈니스모델 등이며 주요 연구 결과는 Knowledge-based systems, Expert systems with applications, Artificial Intelligence Review 등의 학술지에 발표하였다.