

# 시각 정보를 활용한 딥러닝 기반 추천 시스템

## A Deep Learning Based Recommender System Using Visual Information

문현실 (Moon, Hyunsil) 국민대학교 경영대학원<sup>1)</sup>

임진혁 (Lim, Jinhyuk) 국민대학교 경영학부 빅데이터경영통계전공<sup>2)</sup>

김도연 (Kim, Doyeon) 국민대학교 경영학부 빅데이터경영통계전공<sup>3)</sup>

조윤희 (Cho Yoonho) 국민대학교 빅데이터경영통계전공<sup>4)</sup>

### 〈 국문초록 〉

사용자의 정보 과부하 문제의 해결을 목표로 하는 추천 시스템은 개인의 선호를 추론하여 이에 부합하는 아이템을 필터링하여 제공한다. 추천 시스템 관련 기법 중 가장 성공적으로 알려져 있는 협업 필터링은 최근까지 다양한 성능 개선 시도가 이루어지고 있으며 여러 분야에 적용되고 있다. 본 연구에서는 이와 같은 협업 필터링의 성공에 기반하여 소비자의 구매 의사결정에 영향을 미칠 수 있는 시각 정보를 추천 시스템에 반영할 수 있는 VizNCS를 제안한다. 이를 위하여 먼저, 비정형 데이터인 시각 정보에서 특징을 추출하기 위해 합성곱 신경망을 사용하였다. 다음으로, 합성곱 신경망으로부터 도출된 이미지 특성 정보를 추천 시스템에 반영하기 위하여 기존의 딥러닝 기반의 추천 시스템 중 다른 정보로 확장이 용이한 NCF 기법을 응용하였다. 본 연구에서 제안한 VizNCS의 성능 비교 실험 결과 기본 NCF보다 더 높은 성능을 보였으며 카테고리별 성능 비교 실험을 통해 시각 정보에 영향을 받는 카테고리 및 그렇지 않은 카테고리를 발견하였다. 결론적으로 본 연구에서 제안한 VizNCS는 시각정보를 개인화된 추천에 직접 활용함에 따라 시각 정보에 영향을 받는 소비자들의 구매의사결정 행태를 반영할 수 있어 추천 시스템 성능 향상에 기여하였다. 또한, 지금까지 활용이 미미했던 이미지 데이터로 추천 시스템의 원천 데이터 영역을 확장함에 따라 다양한 원천 데이터의 활용 방안을 제시하였다.

**주제어:** 추천시스템, 딥러닝, 협업필터링, 시각정보, 합성곱신경망

1) 제1저자, hsmoon@kookmin.ac.kr

2) 제2저자, kidjim2@naver.com

3) 제3저자, kdydo981203@gmail.com

4) 교신저자, www4u@kookmin.ac.kr

## 1. 서론

인터넷의 발달과 대중화로 인해 온라인 쇼핑 시장의 규모와 정보량은 매우 빠르게 성장하고 있으며 그에 따라 거래되는 상품 및 아이템(item)의 종류가 매우 다양해지고 있다. 예를 들어, 도서 시장의 경우 2019년 주요 온라인 전문 서점 3사의 매출(1,057,613백만원)이 오프라인, 온라인을 병행하는 3사의 매출(824,134백만원)을 넘어서는 정도로 온라인 시장이 매우 활성화 되어 있어 큰 규모를 형성하고 있을 뿐만 아니라 거래되는 도서의 종류도 방대하다(대한출판문화협회 2020). 이로 인해 소비자들의 접근성과 편의성은 높아졌지만 반대로 구매 의사 결정에 필요한 정보 탐색의 비용이 증가하는 또 다른 문제를 발생시키고 있다. 즉, 수많은 상품 중에서 자신의 선호에 부합하는 상품을 탐색하기 어려운 정보 과부하(information overload) 문제가 발생하는 것이다(Haucap and Heimeshoff 2014; Herlocker et al. 2004; Persson 2018). 특히, 온라인 서점 등의 온라인 쇼핑몰은 소비자가 직접적으로 상품을 자세히 물리적으로 살펴볼 수 없다는 한계를 가지고 있어 이러한 정보 과부하 문제가 더 크게 인식되고 있다. 또한, 기업 입장에서조차 자신의 상품을 실제로 구매할 가능성이 높은 고객에게 상품을 노출할 기회가 감소되어 이익 창출에 어려움을 겪을 수 있다.

추천 시스템은 이러한 문제의 해결을 목표로 하는 정보 필터링 알고리즘으로 추천의 형태로 사용자의 선호에 부합하는 아이템을 반환함으로써 손쉽게 빠르게 적절한 아이템에 접근할 수 있게 하는 시스템이다(김민정·조윤호 2015; 손지은 등 2015; 심재문 등 2010; Lathia et al. 2010). 초기 추천 시스템은 단순한 형태로서 가장 많이 판매되는 상품을 추천하는 베스트 셀러 기반의 추천 방식이었지만 최근의 주요한 추천 시스템은 개인의 선호를 추론하여 이에 부합하는 아

이템을 필터링하는 개인화된 추천을 기본으로 하고 있다(손지은 등 2015; 최영제 등; Sarwar et al. 2001; Schafer et al., 2007). 1990년대 후반부터 등장하기 시작한 개인화된 추천 시스템은 이후 다양한 기법과의 결합으로 발전하고 있다. 대표적인 접근 방식은 크게 내용 기반 필터링(Content based Filtering; CBF)와 협업 필터링(Collaborative Filtering; CF)으로 구분되고 있으며, 이 중 협업 필터링은 가장 성공적인 접근 방식으로 알려져 있어 다양한 분야의 추천 시스템에서 응용되고 있다(손지은 등 2015; Herlocker 2004; Resnick et al. 1994). 예를 들어, 도서 분야에서는 협업 필터링에 기반하여 연관성 규칙을 적용하여 성능을 높이려는 시도가 있었으며(김영준 등 2015; 이석원 등 2016), 내용 기반 필터링(CBF)과의 혼합을 제안한 하이브리드 모델(Sase et al. 2015) 등 다양한 시도가 이루어져 왔다. 또한, 기존 협업 필터링 기반 모델들이 과거 구매 이력 데이터만을 활용하여 개인화된 추천을 제공하였다면, 최근의 연구들은 가격, 제목, 후기 같은 아이템의 정보 또는 사용자의 인구 통계학 정보 등 다양한 데이터를 활용하기 위한 시도를 진행하고 있다(조승연 등 2015; 정영진·조윤호 2017). 하지만, 추가적으로 활용되고 있는 데이터가 데이터베이스에 수집 및 저장되고 있는 정형 데이터(가격, 제조사, 스펙 등)를 중심으로 하고 있으며 비정형 데이터의 활용은 초기 단계이다. 또한, 비정형 데이터 활용의 시도도 상품에 대한 리뷰, 상품 소개 등의 텍스트 데이터에 치중되어 있다.

따라서, 본 연구에서는 최근 비정형 데이터 활용의 중요성에 맞추어 소비자의 구매 의사결정에 영향을 미칠 수 있는 시각 정보를 추천 시스템에 반영할 수 있는 새로운 추천 시스템인 VizNCS를 제안하고자 한다. 예를 들어, 고건과 김보연(2015) 연구에 따르면 온라인 서점에서 소비자의 구매 의사결정에 표지 디자

인이라는 시각 정보가 중요한 역할을 담당하고 있다. 표지 디자인은 타이포그래피, 레이아웃, 이미지, 색채로 구성되어 있어 도서가 가지는 내용 구성 요소를 효과적으로 외부에 표출시킨 결과이다 (고건·김보연 2015). <그림 1>은 표지 디자인의 예시를 나타낸다.



<그림 1> 표지 디자인 예시

해당 연구에 따르면 표지 디자인이 구매에 영향을 미친다고 밝힌 조사 대상자가 68%에 달하며, 표지 디자인에 사용된 이미지가 가장 큰 영향을 미친다고 응답하였다. 즉, 표지 이미지가 다른 요소들만큼이나 도서 구매 의사결정에 중요한 역할을 담당하며 소비자 선호에 영향을 미친다고 할 수 있다.

소비자의 구매 의사결정에 중요한 영향을 미치는 시각 정보를 추천 시스템에 반영하기 위하여 본 연구에서는 다음과 같은 방법을 제안한다. 먼저, 비정형 데이터인 이미지 정보를 추천 시스템에 효과적으로 반영하기 위해 기존의 이미지 처리 분야에서 성공적으로 적용되고 있는 합성곱 신경망(Convolution Neural Network; CNN)을 사용한다 (Zhang et al. 2019). 다음으

로, 추천 시스템 연구에서 가장 성공적으로 알려진 협업 필터링을 기반으로 방법을 구성한다. 특히, 본 연구에서는 합성곱 신경망으로부터 도출된 이미지 특성 정보를 추천 시스템에 반영하여 시각 정보의 활용이 가능한 추천 시스템을 제안하기 위하여 기존의 딥러닝 기반의 추천 시스템 중 다른 정보로 확장이 용이한 (Gao et al. 2018; He et al. 2017) Neural Collaborative Filtering(이하 NCF) 기반의 추천 시스템을 제안한다. 본 연구에서 제안하는 추천 시스템인 VizNCS는 표지 이미지 등의 시각 정보를 개인화된 추천에 직접 활용함에 따라 시각 정보에 영향을 받는 소비자들의 구매 의사결정 행태를 반영할 수 있어 추천 시스템 성능 향상에 기여할 수 있으리라 기대된다. 또한, 지금까지 활용이 미미했던 비정형 데이터인 이미지 데이터로 추천 시스템의 원천 데이터 영역을 확장함에 따라 다양한 원천 데이터의 활용 방안을 제시할 수 있으리라 기대된다.

## 2. 관련 연구

### 2.1. 협업 필터링과 딥러닝

개인화된 추천 시스템은 정보 과부하 문제에 대한 효과적인 해결책으로서 과거 데이터에서 사용자(소비자), 아이템(상품, 서비스) 등의 엔티티(Entity)들에 대한 관계를 파악하여 사용자가 선호할 아이템만을 선택적으로 제공하는 필터링 시스템이다 (최영제 등 2020; Herlocker et al. 2004; Resnick et al. 1994; Sarwar et al. 2001; Lathia et al., 2010). 이 중 협업 필터링(CF)은 다양한 기업과 분야에서 성공적으로 활용되고 있다 (손지은 등 2015; Herlocker 2004; Resnick et al. 1994). 협업 필터링은 특정 아이템에 대한 선호도가 유사한 고

객들이 그 외 다른 아이템에 대해서도 비슷한 선호도를 가질 것이라는 가정하에 사용자와 사용자 또는 아이템간 유사도를 통해 아이템을 추천한다. 특히, 내용 기반 필터링과 비교하여 구매 이력을 바탕으로 추천을 제공함에 따라 사용자의 프로파일 정보나 아이템의 특성 정보 없이 구현이 가능하며 다양한 아이템의 추천이 가능하다는 장점을 지닌다 (김경재·안현철 2009; 손지은 등 2015; Herlocker et al. 2004). 초기 협업 필터링은 최근접 이웃 방식(Nearest Neighbor)을 중심으로 연구가 진행되어 왔으며 이후 행렬 분해법(Matrix Factorization)에 기반한 협업 필터링 기법이 높은 성능을 나타내며 주목받아 왔다(Koren et al. 2009). 행렬 분해법에 기반한 협업 필터링은 사용자-아이템의 평점 행렬  $R$ 을 사용한다.  $N$ 명의 사용자와  $M$ 개의 아이템에 대한 평점 행렬  $R$ 은  $N \times M$ 으로 구성되며 이때 원소  $R_{ij}$ 는  $i$ 번째 유저가  $j$ 번째 아이템에 매긴 평점을 의미한다. 행렬 분해법은 해당 행렬  $R$ 을 사용자 잠재 벡터  $U$ 와 아이템 잠재 벡터  $V$ 로 분해하고 손실함수를 통해 최적화함으로써 복원되는  $R'$ 을 통해 아이템을 추천한다 (Koren et al. 2009).

최근에는 딥러닝 기법의 발전과 더불어 딥러닝의 실용적 활용 측면에서 추천 시스템에 적용하려는 시도가 활발히 이루어지고 있다. 특히, 협업 필터링의 높은 성능에 따라 이를 인공지능망으로 구현하여 성능을 개선하고자 하는 연구가 주를 이루고 있다. 딥러닝을 협업 필터링에 적용한 초기 시도는 Restricted Boltzmann Machine(RBM)을 협업 필터링에 적용한 RBM-CF이다(Salakhutdinov et al. 2007). 또한, 오토 인코더(Auto Encoder)에 기반하여 RBM-CF와 유사하게 작동되는 모델도 제안되었으며 (Ouyang et al. 2014) AutoRec와 같이 협업 필터링 알고리즘의 작동 방식을 오토 인코더로 구현한 모델도 제안되었다 (Sedhain et al. 2015). 이후 합성곱 신경망(Convolutional Neural Network;

CNN)에 기반한 Attention-based CNN (Chen et al. 2015), 순환 신경망(Recurrent Neural Network; RNN)에 기반한 GRU4REC (Hidasi et al. 2015) 등 비정형 데이터 기반의 문제 해결에 높은 성능을 발휘한 딥러닝 모델들을 추천 시스템에 적용하려는 연구가 최근 활발히 진행되고 있다. 또한, 인공 신경망의 임베딩 연산과 이를 내적하는 방식이 행렬 분해법의 잠재 벡터를 탐색하는 방식과 유사함에 따라 행렬 분해 과정을 인공 신경망으로 구현하여 기존의 행렬 분해법 기반의 협업 필터링의 성능을 개선하고자 하는 Wide & Deep 모델 등의 연구가 진행되고 있다 (Cheng et al. 2016).

하지만, 이러한 최근의 연구 성과에도 불구하고 추천 시스템에서 활용되고 있는 데이터는 여전히 평점 또는 구매 이력 데이터가 중심이다. 앞서 언급한 바와 같이 표지 이미지 등의 시각 정보는 소비자의 구매 의사 결정에 중요한 역할을 담당한다. 따라서, 시각 정보를 나타내는 비정형 이미지 데이터의 활용을 통해 구매 의사 결정 프로세스에 영향을 미치는 요소를 반영하여 추천 시스템의 성능을 높이려는 시도가 필요하다. 이를 위하여 최근의 연구에서는 이미지 데이터로부터 특성을 추출하여 추천 시스템의 성능을 높이려는 시도가 이루어 지고 있다. 해당 연구들에서는 합성곱 신경망(CNN)에 기반하여 이미지로부터 특성(Features)을 추출하고 이를 추천 시스템에 결합하는 방식을 도입하고 있다. 예를 들어 Lei et al. (2016)은 이미지 특징 학습에 사용되는 CNN모델과 사용자 선호를 모델링하는 CNN 모델을 하이브리드 방식으로 결합하는 방식을 제안하여 이미지 추천에 활용하였다. 이미지 추천 뿐만 아니라 다양한 도메인에서도 이미지 데이터를 활용하려는 시도가 이루어 졌는데 Wang et al. (2017)은 POI(Point-of-Interest)를 추천 하는데 있어 CNN을 통해 이미지의 특성을 추출하고 행렬 분해법에 기반하여 이미지와 사용자/아이템 잠재 벡

터간의 상호작용을 탐색하는 모델을 제안하였다. 또한, Rawat and Kankanhalli(2016)은 CNN을 기반으로 추출한 이미지 특성을 인공지능망과 결합하는 모델을 제안하여 태그(tag) 추천에 사용하였다. 하지만 현재 까지 제안된 모델들은 시각 정보인 이미지를 추천에 있어 추가적인 정보 원천으로만 활용하여 CNN을 통해 추출한 특성 정보를 단순히 기존의 추천 시스템의 입력데이터로만 사용하고 있다는 한계가 있다. 즉, 기존 모델의 개선보다는 잘 알려진 모델에 추가적인 데이터로 시각 정보를 사용하고 있다. 따라서, 단순히 시각 정보를 기존 모델의 추가적인 정보 원천으로 다루는 것이 아니라 사용자 선호 모델링 관점에서 시각 정보를 반영할 수 있도록 모델을 개선하는 방법에 대한 탐색이 필요하다.

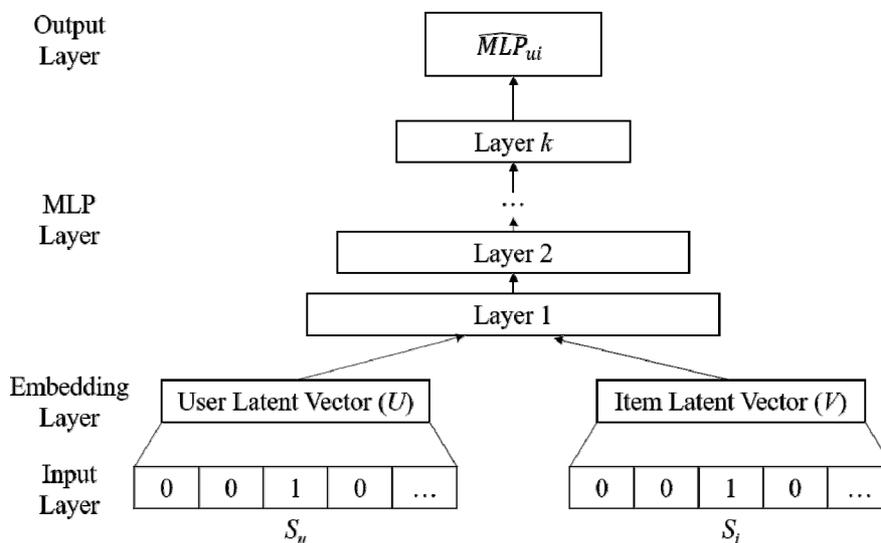
이를 위하여 본 연구에서는 추천 시스템 분야에서 성공적으로 활용되고 있는 딥러닝 기반의 협업 필터링을 활용함과 동시에 시각 정보를 반영하여 모델을 개선할 수 있는 방법을 다각화하여 시각 정보를 효과적으로 활용할 수 있는 추천 시스템을 제안하고자 한다.

## 2.2. NCF(Neural Collaborative Filtering)

NCF는 행렬 분해법이 협업 필터링 기반의 추천 시스템에서 갖는 강점을 인공지능망 형태로 구현한 대표적인 모델이다 (Gao et al. 2018; He et al. 2017; He et al. 2018). 먼저, <그림 2>는 NCF의 전체 프레임워크 중 사용자 잠재 벡터와 아이템 잠재 벡터의 상관관계를 인공지능망으로 표현한 MLP의 구조를 나타낸다.

<그림 2>에서 입력데이터인  $S_u$ 와  $S_i$ 는 각각 사용자와 아이템을 원핫인코딩(One-hot Encoding)으로 표현한 것이다. 이러한 입력데이터는 입력 차원의 크기는 사용자 수 또는 아이템 수만큼 커지지만 대부분의 값이 0으로 채워져 있는 희소(sparse) 행렬의 형태를 나타내게 된다. 그에 따라, 임베딩(Embedding)을 통해 사용자 잠재 벡터  $U$ 와 아이템 잠재 벡터  $V$ 로 표현한다. 이렇게 표현된 잠재 벡터를 인공지능망에 통과시켜 스코어를 예측하는 구조가 MLP이며 다음과 같은 수식으로 표현할 수 있다.

$$\widehat{MLP}_{ui} = p_u \odot p_i$$



Source: Neural collaborative filtering (He et al. 2017)

<그림 2> NCF(Neural Collaborative Filtering)의 MLP영역

여기에서  $f(\cdot)$ 는 다층신경망(Multi-Layer Perceptron)을 의미하며  $\theta$ 는 신경망의 파라미터인 가중치 및 편향을 의미한다. 따라서, NCF의 MLP는 사용자 잠재 벡터  $U$ 와 아이템 잠재 벡터  $V$ 의 상관관계를 표현하는 역할을 담당한다. NCF는 단순 점곱(dot-product)로 예측하는 MLP뿐만 아니라 행렬곱의 일반화 버전으로 요소별 곱(element-wise product)를 수행하는 GMF(Generalized Matrix Factorization)도 가지고 있다. GMF구조는 비선형 활성화 함수를 사용해서 모델이 사용자와 아이템 간의 상관관계를 더 풍부하게 표현할 수 있도록 하는 역할을 수행하며 다음과 같은 수식(1)로 표현된다.

$$\widehat{GMF}_{ui} = p_u \odot p_i \quad (1)$$

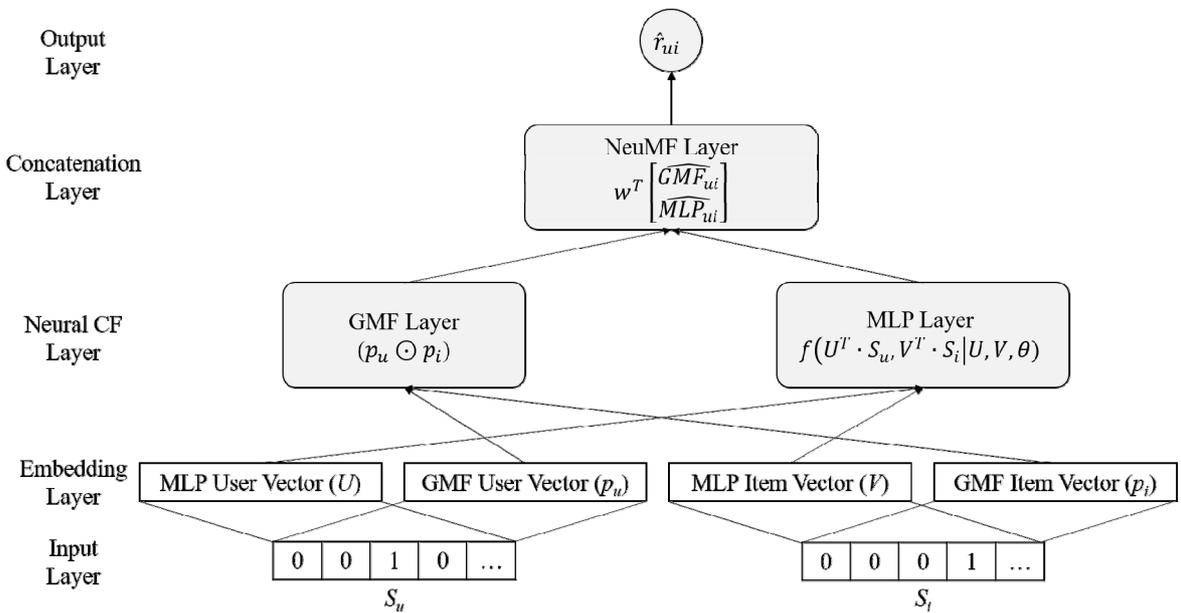
여기에서  $p_u$ 와  $p_i$ 는 MLP구조와 동일한 입력데이터인  $S_u$ 와  $S_i$ 를 사용하지만 사용자 잠재 벡터  $U$ , 아이템 잠재 벡터  $V$ 와 구분되어 학습된 GMF의 벡터이다. 즉, GMF에서는 두 임베딩 벡터  $p_u$ 와  $p_i$ 의 요소별 곱셈 연산  $\odot$ 을 하고 가중치를 곱함에 따라 MLP보다 사용자와 아이템의 상관관계를 학습하는 데 더 유연

한 구조를 가지게 된다. NCF에서는 이렇게 각자 다른 특성을 가진 MLP와 GMF의 결합을 통해 다음 <그림 3>과 같은 프레임워크를 가지게 된다.

즉, 학습된 GMF와 MLP를 최종 예측 스코어는 다음과 같이 표현될 수 있다.

$$\hat{r}_{ui} = \sigma \left( w^T \begin{bmatrix} \widehat{GMF}_{ui} \\ \widehat{MLP}_{ui} \end{bmatrix} \right) \quad (2)$$

NCF는 마지막에 GMF와 MLP의 앙상블을 통해 최종 스코어를 예측하는 모델을 구성함에 따라 기존의 행렬 분해법 기반의 협업 필터링 보다 사용자와 아이템의 상관 관계의 다각적인 반응을 통한 추천이 가능하다. 이러한 장점과 더불어 NCF는 추가적인 데이터의 활용에 있어 유연한 특징을 가진다 (Gao et al. 2018). 기본적으로 NCF는 앞서 언급한 바와 같이 GMF와 MLP의 결과를 앙상블하는 NeuMF Layer를 가지고 있다. 따라서, NeuMF층에 추가적인 특성 또는 모델의 결과를 앙상블하는 것이 가능하다. 또한, MLP에서는 사용자와 아이템 벡터 간의 결합을 입력으로



<그림 3> NCF Framework

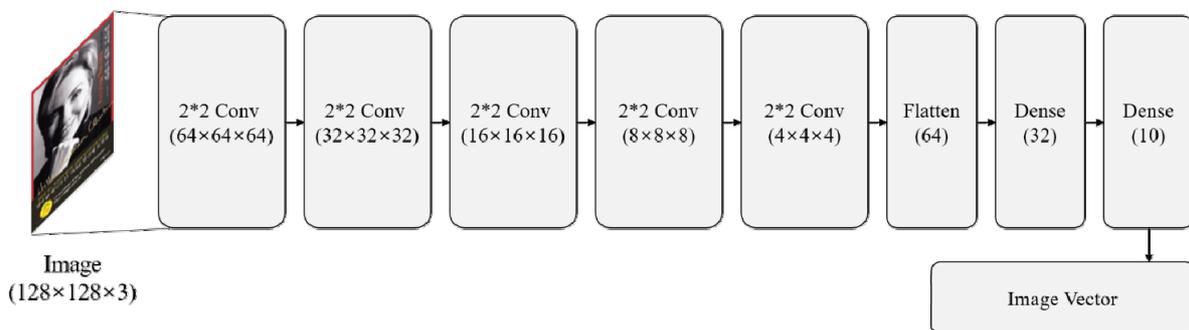
하여 은닉층을 통과시킴에 따라 MLP층에 추가적인 특성을 추가하여 결합하는 방식으로 사용도 가능하다. 마찬가지로 GMF의 요소별 곱셈 결과에 추가적인 특성을 추가한 결합도 가능하다. 결론적으로, NCF는 구조의 유연성으로 기본 모델에 다양한 추가 정보의 결합 방식을 수용할 수 있다. 따라서, 본 연구에서는 행렬 분해법을 인공 신경망으로 구현하여 성능에서 장점을 보이는 NCF모델의 또 다른 장점인 높은 유연성에 주목하여 이미지 처리 결과를 반영할 수 있는 NCF의 확장 모델을 제안하고자 한다.

### 3. 시각 정보를 반영한 추천 시스템

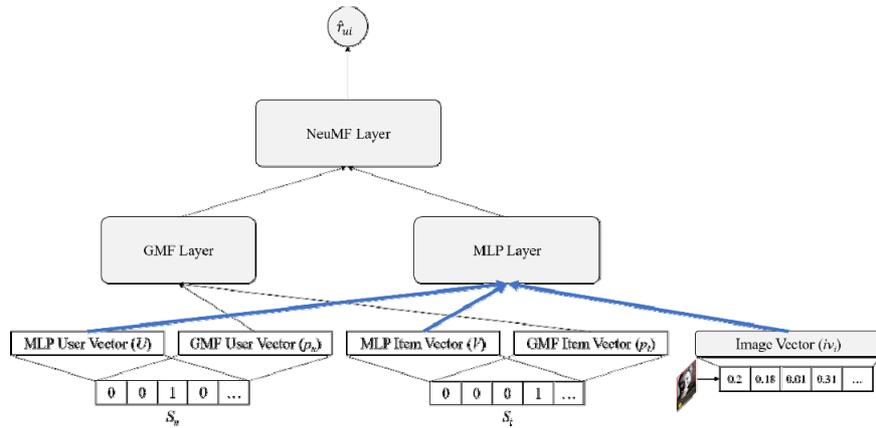
본 연구에서 제안하는 추천 시스템인 VizNCS는 기존의 NCF를 확장하여 시각 정보를 반영할 수 있도록 한 것이다. 이를 위하여 먼저, 이미지 원천 데이터를 NCF에 적용하기 위한 벡터화 과정을 거쳤다. 비정형 데이터를 추천 시스템을 비롯한 머신 러닝 문제에 활용하기 위해서는 벡터화 과정이 필수적이다. 특히, 최근의 연구에서는 벡터화를 위하여 원천 데이터의 지역적인 특성과 전체적인 특성을 잘 인식하는 것으로 알려져 있는 CNN을 주로 사용하고 있다 (He and McAuley 2016; He et al. 2018; Low et al. 2018; Kurt

and Özkan 2017). 예를 들어, He and McAuley(2016)의 연구에서는 합성곱 층 연산의 결과로 도출된 이미지 벡터를 아이템 벡터로 대체하여 추천 시스템에 활용했으며 Kurt and Özkan의 연구에서는 이러한 이미지 벡터를 아이템의 특성으로 대체하여 내용기반 필터링을 시도하였다. 하지만 He et al. (2018)은 합성곱 층의 연산으로 도출되는 이미지 벡터의 활용에 있어 기존의 이미지 분류 문제에 성공적으로 알려져 있는 VGG16 등 기존의 가중치 네트워크를 활용한 전이학습의 어려움을 지적하였다. 딥러닝 기반의 추천 시스템에서는 임베딩 층을 통해 아이템과 사용자에 대한 벡터를 형성하게 되는 데 기존의 가중치 네트워크로 도출되는 이미지 벡터는 이러한 벡터들에 비해 너무 큰 차원을 가지게 된다. 따라서, 다른 벡터들에 비해 큰 차원을 가지게 되는 이미지 벡터가 모델 학습을 방해하게 되어 성능을 저하시키게 되는 것이다. 따라서, 본 연구에서는 이미지 원천 데이터를 NCF에 적용하기 위한 이미지 벡터화 과정을 <그림 4>와 같이 제안한다.

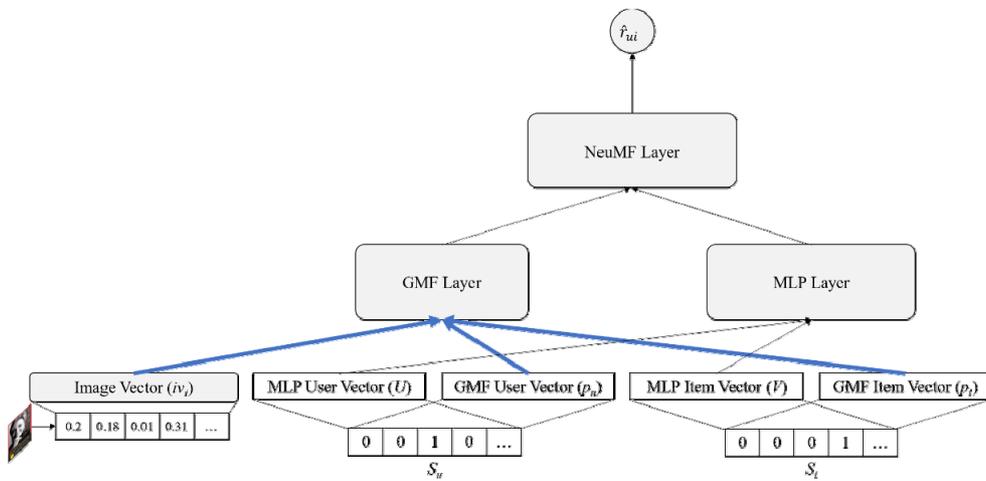
본 연구에서는 너무 큰 차원의 이미지 벡터로 발생되는 문제를 방지함과 동시에 원천 이미지로부터 충분한 특성 추출이 이루어질 수 있도록 <그림 4>와 같이 2\*2 크기의 작은 필터연산을 수행하는 합성곱 층을 다층으로 구성하였다. 또한, NCF와의 결합을 고려



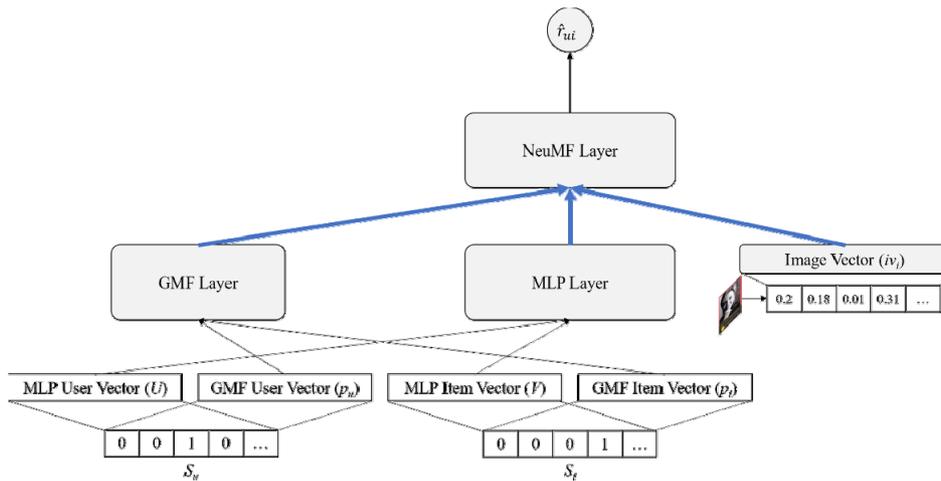
<그림 4> 이미지 원천 데이터의 벡터화 구조



〈그림 5〉 MLP-Concat 방식



〈그림 6〉 GMF-Product 방식



〈그림 7〉 NeuMF-Concat 방식

하여 결합하는 층에서의 다른 벡터들과 유사한 차원을 가질 수 있도록 마지막에 완전연결층(Dense)을 배치하여 이미지 벡터의 최종 크기를 조절할 수 있도록 하였다.

다음으로, 이와 같이 벡터화된 이미지 원천 데이터를 NCF에 적용하여 이미지 정보를 반영한 도서 추천 시스템으로 확장하기 위해 <그림 5, 6, 7>과 같은 세가지 방식을 제안한다.

먼저, MLP-Concat방식은 기존 NCF구조 중 MLP에 이미지 벡터를 결합하는 방식이다. 즉, 기본 NCF의 MLP에서 사용자와 아이템 벡터 간의 결합을 통해 사용자와 아이템 간의 상관관계를 학습하도록 유도한 것에 이미지 벡터를 추가하여 사용자-아이템-이미지 간의 다각적인 상관관계를 학습할 수 있도록 확장한 것이다. 이러한 결합 방식은 수식(3)과 같이 표현된다.

$$\widehat{MLP}_{ui} = \sigma \left( w^t \begin{bmatrix} \widehat{mlp}_{ui} \\ iv_{ui} \end{bmatrix} \right)$$

$$\widehat{mlp}_{ui} = f(U^T \cdot S_u, V^T \cdot S_i | U, V, \theta) \quad (3)$$

수식(3)에서  $iv_i$ 는 이미지 벡터를 의미하며,  $\widehat{mlp}_{ui}$ 는 NCF구조 중 MLP구조를 의미한다. 다음으로, GMF-Product 방식은 GMF 구조에 이미지 벡터를 반영하기 위한 시도이다. 이를 위하여 GMF 사용자 벡터  $p_u$ 와 GMF 아이템 벡터  $p_i$ 의 요소별 곱에 앞서 GMF 아이템 벡터와 이미지 벡터의 요소별 곱을 먼저 수행한다. 이를 수식으로 나타내면 수식(4)와 같다.

$$\widehat{GMF}_{ui} = p_u \odot (p_i \odot iv_i) \quad (4)$$

즉, GMF-Product 방식은 GMF의 아이템 벡터에 이미지 특성을 반영하여 모델을 구성한 것이다. 마지막으로, NeuMF-Concat 방식은 최종적으로 GMF와 MLP가 결합되어 앙상블하는 효과를 나타내는 NeuMF층에 이미지 벡터를 추가한 것이다.

$$\hat{r}_{ui} = \sigma \left( w^T \begin{bmatrix} \widehat{GMF}_{ui} \\ \widehat{MLP}_{ui} \\ iv_i \end{bmatrix} \right) \quad (5)$$

GMF-Product 방식은 NCF의 기본 행렬 분해 방식은 유지하면서 이미지 벡터를 부가적인 정보(side information)으로 활용하여 추천 시스템의 성능을 높이고자 하는 시도이다. 세 가지 방식 모두에서 이미지 벡터의 차원은 결합되는 층의 다른 벡터의 차원을 고려하여 결정된다. 또한, 최종적으로는 비선형 활성화함수를 통해 각 아이템에 대한 사용자의 스코어를 예측한다.

## 4. 실험 및 결과

### 4.1. 실험 데이터 및 방법

본 연구에서 제안한 시각 정보를 반영한 추천 시스템인 VizNCS의 성능을 측정하기 위한 실험은 다음과 같이 진행되었다. 실험을 위한 원천 데이터는 온라인 서점의 고객 구매 트랜잭션 데이터 11,0533건으로 실험의 신뢰도와 정확도를 높이기 위하여 먼저 구매 횟수가 다른 카테고리에 비해 지극히 적은 잡지 등의 카테고리를 제외하였다. 또한, 신규 사용자 또는 신규 아이템에 대한 추천을 배제하기 위해 최소 2번 이상 구매한 사용자, 2번 이상 판매된 아이템만을 대상으로 실험을 진행하였다. 그에 따라 최종적으로 19,210명의 사용자와 12,036개의 아이템이 실험에 사용되었다. 이미지 데이터는 최종적으로 실험에 사용된 아이템에 대한 표지 이미지를 사용하였으며 일괄적으로 일정한 크기로 조정하여 128×128 크기의 컬러 이미지(RGB 3개 채널)를 사용하였다.

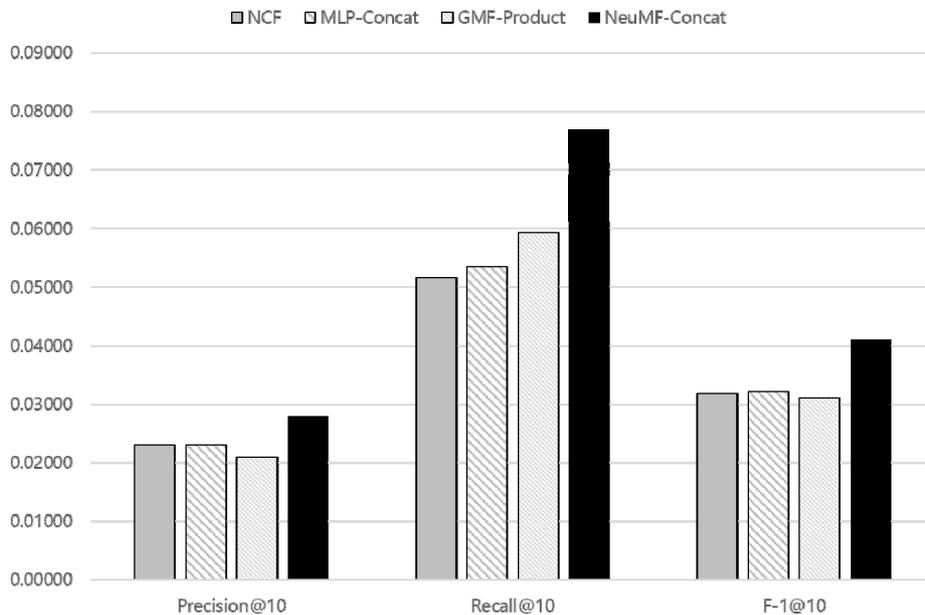
다음으로, 이와 같은 구매 데이터를 딥러닝 기반의 추천 시스템에 학습시키기 위해서는 구매하지 않은 아

이템의 일부를 샘플링하여 학습에 사용하는 네거티브 샘플링(Negative Sampling)이 필수적이다 (Caselles-Dupré et al. 2018; Xu et al. 2016). 암시적 선호(Implicit Preference)를 나타내는 대표적인 데이터인 구매 데이터의 경우 구매한 아이템만 데이터로 기록되어 있다. 그에 따라 구매 데이터 자체로는 구매 여부를 목표 변수로 하는 모델의 학습이 불가능하다. 또한, 일반적으로 구매 아이템(Positive)이 구매하지 않은 아이템(Negative)보다 훨씬 많기 때문에 구매하지 않은 아이템을 모두 학습할 경우 편향된 모델 학습이 이루어질 수 밖에 없다. 따라서, 본 연구에서는 이러한 편향을 제거하기 위해 각 사용자가 구매한 아이템 개수만큼 구매하지 않은 아이템을 무작위 샘플링하여 네거티브 샘플(Negative Sample)을 생성하여 실험에 사용하였다. 또한, 기본 NCF의 성능을 측정된 He et al. (2017)의 연구에서 네거티브 샘플(구매하지 않은 아이템)과 포지티브 샘플(구매 아이템) 간의 비율을 3대 1로 하였을 때 가장 높은 성능이 나타났다. 그에 따라, 본 연구에서도 구매

한 아이템의 개수의 3배로 네거티브 샘플을 추출하여 실험에 사용하였다.

신뢰도 있는 실험을 위해 모델 학습을 위한 훈련용 데이터와 성과 측정을 위한 테스트 데이터로 나누어 실험을 진행하였다. 테스트 데이터를 위하여 사용자 중 30%인 5,763명을 무작위로 선정하여 각 사용자별로 모든 아이템에 대해 선호도에 대한 예측을 진행하여 예측 값이 가장 높은 K개를 추천하여 성능을 측정하였다. 성능 확인을 위한 지표는 F-1 Measure를 사용하였다 (Herlocker et al. 2004; Sarwar et al. 2001). F-1 지표는 가장 잘 알려진 의사결정 기반 평가 지표인 Precision과 Recall의 결과를 모두 반영하여 동시에 하나의 값으로 나타낸 지표로서 두 지표의 조화평균으로 나타낸다. 이를 통해 추천 상품 수 K가 커질수록 Recall이 증가되고 Precision이 감소되는 트레이드 오프 관계를 고려할 수 있다.

$$Precision@K = \frac{\text{추천한 도서를 구매한 수}}{\text{사용자에게 추천한 도서 수}} \quad (6)$$



〈그림 8〉 모델별 비교 결과

$$Recall@K = \frac{\text{추천한 도서를 구매한 수}}{\text{사용자가 구매한 도서 수}} \quad (7)$$

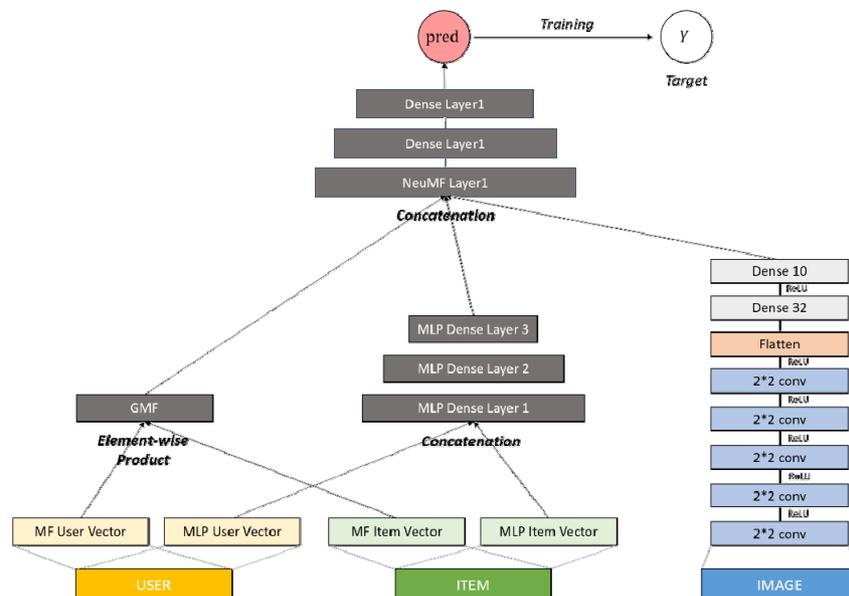
$$F-1@K = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

딥러닝 모델의 학습을 위한 하이퍼파라미터는 다음과 같이 설정하였다. 먼저, 옵티마이저는 사전 실험을 통해 결정하였으며 모든 모델에서 RMSProp(Mukkamala and Hein 2017)이 가장 높은 성능을 나타내었다. 다음으로, 본 실험의 목표 변수가 구매 여부로 나타남에 따라 이진 범주로 표현되어 손실 함수는 binary cross-entropy를 사용하다. 학습 횟수(epochs)는 각 모델별 실험에서 테스트 데이터에 대한 성능이 가장 높게 나온 횟수로 지정되었으며, 배치 크기는 256개로 설정하였다. 모든 실험은 CPU Intel Xeon® 4216 @2.1GHz, GPU GeForce Titan XP 12GB의 환경에서 진행되었으며 모델의 구현을 위해 Python 3.7언어와 Tensorflow 라이브러리를 사용하였다.

## 4.2. 실험 결과

기본 NCF와 본 연구에서 제안한 VizNCS의 세 가지 결합 방식인 MLP-Concat, GMF-Product, NeuMF-Concat의 성능을 비교한 결과는 <그림 8>과 같다.

실험 결과 F-1@10 측정지표 관점에서 시각 정보를 반영하지 않은 기본 NCF(0.03182)에 비해 시각 정보를 반영한 MLP-Concat, NeuMF-Concat 방식이 높은 성능을 보였다. 즉, 도서 도메인의 시각 정보인 표지 이미지로 추출된 이미지 벡터가 추천 시스템의 성능을 향상시키는 데 유의미한 기여를 했음을 알 수 있다. 다음으로, 이미지 벡터를 결합하는 방식에 있어서 GMF-Product(0.03102)는 기본 NCF보다 낮은 성능을 보여 다른 방식에 비해 낮은 성능을 나타내었다. 이는 NCF에서 추가적인 정보를 반영할 때 요소별 곱셈보다는 벡터간 결합을 통한 반영이 더 효과적임을 의미한다. 즉, 추가적인 정보 반영에 있어서는 NCF의 기본 모델이 담당하고 있는 역할과 학습 프로세스에 영향을 덜 주는 것이 더 나은 성능을 나타낸다. 이는



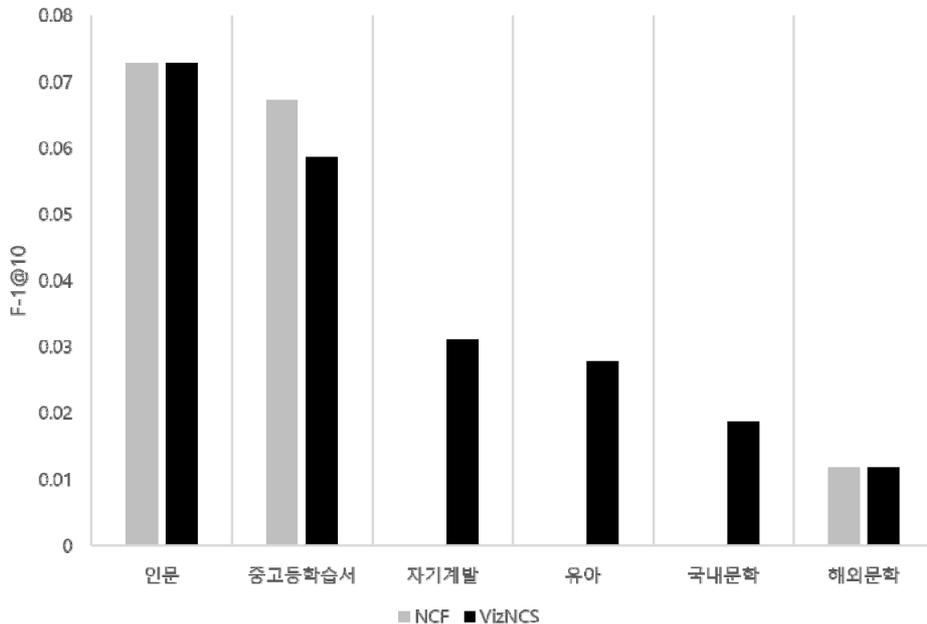
<그림 9> 최종 VizNCS 아키텍처

NeuMF-Conat 방식(0.04104)이 가장 우수한 성능을 보인 원인으로 된다. NeuMF-Concat 방식의 경우 이미지 벡터를 NCF의 행렬 분해를 담당하고 있는 층에 직접 반영하는 것이 아니라 사용자와 아이템의 상관 관계의 모델링이 완료된 GMF와 MLP의 앙상블에 반영하는 것이다. 즉, 기본 NCF의 구조와 학습은 그대로 두면서 최종 앙상블 단계에서 활용하는 방식이 가장 높은 성능을 보인 것이다. 따라서, NCF에 추가적인 정보의 반영을 고려할 때에는 NCF 구조 및 학습 방식을 해치지 않으면서 반영할 수 있는 적절한 방식의 탐색이 필요하다. 이와 같은 실험 결과를 반영하여 본 연구에서 제안하는 시각 정보를 반영한 VizNCS의 최종 모델은 <그림 9>와 같다.

앞선 실험 결과를 통해 추천 시스템에서 시각 정보의 반영은 성능 향상에 유의미한 영향이 있음을 확인하였다. 이는 전체 도서 아이템에 대한 실험 결과로 다수의 연구에 따르면 도서 소비자는 도서 장르 즉, 카테고리에 따라 표지 디자인에 반응하는 정도가 다

르다(고건·김보연 2015; 남미현·백진경 2004). 그에 따라 본 연구에서 제안한 VizNCS의 성능이 카테고리별로 다르게 나타나는지를 실험하였다. 이를 위해 총 25개의 카테고리 중에서 기본 NCF 기법이 가장 많이 추천을 한 장르인 국내문학, 해외문학, 유아, 자기계발, 인문, 중고등학습서 등 6개 카테고리에 대해 <그림 9>와 같이 본 연구에서 제안하는 최종 모델의 성능을 측정하여 비교하는 실험을 진행하였으며 그 결과는 <그림 10>과 같다.

카테고리별 비교 실험 결과 자기계발(0.0312), 유아(0.0279), 국내문학(0.0188) 카테고리에서는 기본 NCF보다 시각 정보를 반영한 모델이 더 높은 성능을 보여 해당 카테고리에서는 시각 정보의 반영이 추천 시스템 성능 향상에 영향을 미쳤다. 성능 차이의 유의성 검증을 위한 t-검정 결과 p-value값이 자기계발 0.083, 국내문학 0.098, 유아 0.168로 유의수준 10%에서 자기계발과 국내문학 카테고리의 성능차이가 유의미한 것으로 판단되었다. 따라서, 해당 카테고리의 소비자는



<그림 10> 카테고리별 비교 결과

시각 정보에 영향을 받는다고 할 수 있다. 다음으로, 인문(0.0729), 해외문학(0.0119) 카테고리의 경우 기본 NCF와 본 연구에서 제안한 VizNCS가 동일한 추천 목록을 제공하여 동일한 성능이 나타났다. 이는 해당 카테고리의 경우 NCF의 MLP와 GMF의 앙상블만으로 추천이 이루어짐을 의미한다. 따라서, 해당 카테고리의 소비자는 시각 정보보다는 기존의 협업 필터링 모델이 가지는 장점인 유사한 사용자 또는 아이템의 추천만으로도 충분한 성능을 나타낼 수 있음을 의미한다. 또한, 이는 앞서 언급한 연구 결과와 유사한 결과로 표지 이미지가 도서 구매의사결정에 영향을 미치는 카테고리가 별도로 존재한다는 것을 의미한다. 마지막으로, 중고등학습서의 경우는 기본 NCF(0.0673)보다 오히려 시각 정보를 반영한 모델(0.0587)이 더 낮은 성능을 보였지만  $t$ -검정 결과  $p$ -value값이 0.552로 나타내어 유의한 성능차이가 나타나지 않았다. 그럼에도 불구하고 중고등학습서의 경우는 시각 정보가 오히려 모델 학습에 있어 잡음(noise)이 되어 추천 성능을 저하시키는 것으로 판단할 수 있다. 이는 중고등학습서의 구매의 경우 도서 자체가 가지는 콘텐츠가 중요하고 구매 습관 등의 다른 요인이 구매 의사결정에 더 많은 영향을 끼친다는 것을 의미한다. 즉, 시각 정보를 반영한 모델의 낮은 성능은 시각 정보 외의 다른 요인에 대한 반응을 통한 성능 향상이 필요함을 의미하며 그에 따라 도서 시장의 소비자 구매 의사결정 요인에 대한 논의를 통해 추천 시스템의 구조를 개선하는 추가적인 연구가 필요하다는 것을 시사한다.

## 5. 결론

온라인 쇼핑 시장의 성장으로 거래되는 아이템의 종류가 기하급수적으로 늘어나면서 소비자들은 정보

과부하라는 또다른 문제에 직면하게 되었다. 이는 소비자 관점에서의 어려움일 뿐만 아니라 기업 입장에서도 수익 창출에 어려움을 겪게 하는 원인이 되고 있다. 이를 해결하기 위한 시도인 개인화된 추천 시스템은 추천의 형태로 사용자의 선호에 부합하는 아이템만을 필터링하여 제공함에 따라 사용자의 만족도를 높이고 있다. 그에 따라 다양한 분야에서 추천 시스템의 성능을 개선하고자 하는 시도가 이루어져 왔으며 최근에는 딥러닝 기법의 발전과 더불어 이를 추천 시스템에 도입하고자 하는 연구가 활발히 진행되고 있다. 딥러닝 기법은 특히 비정형 데이터 처리에 높은 성능을 보이고 있어 추천 시스템에서 비정형 데이터의 직접적인 활용의 가능성을 높이고 있다. 하지만, 현재 추천 시스템 분야에서 비정형 데이터의 활용은 텍스트 데이터를 중심으로 논의되고 있다. 온라인 환경에서 사용자는 직접적으로 상품을 볼 수 없기 때문에 상품과 관련된 다양한 정보를 의사결정에 반영한다. 특히, 대표적인 시각 정보인 상품의 이미지는 소비자의 구매 의사결정에 큰 영향을 미친다. 따라서, 본 연구에서는 기존의 추천 시스템에서 높은 성능을 나타내고 있는 협업 필터링 기법을 기반으로 시각 정보를 반영할 수 있는 VizNCS를 제안하였다. 이를 통해 추천 시스템의 성능을 개선하였을 뿐만 아니라 추천 시스템에 활용되는 데이터의 영역을 넓혔다는 데 그 의의가 있다.

실험을 통해 본 연구에서 제안한 VizNCS는 기반 기법인 NCF보다 높은 성능을 보여 시각 정보의 반영이 추천 시스템 성능 향상에 유의미한 영향이 있음을 확인하였다. 즉, 소비자의 구매 의사결정 과정에 대한 이해를 통해 이에 영향을 미치는 정보를 추천 시스템에 반영하는 것이 추천 시스템 성능 향상에 도움이 된다는 것을 밝혀낸 것이다. 또한, 상품 카테고리별로 시각 정보의 반영 효과를 살펴보기 위해 각 카테고리

별로 VizNCS의 성능을 측정하였다. 실험 결과 일부 카테고리에서는 VizNCS의 성능이 NCF보다 높았지만 일부 카테고리에서는 비슷하거나 약간 낮은 성능을 보였다. 이러한 결과는 구매 의사결정에 있어 시각 정보가 영향을 주는 카테고리나 그렇지 않은 카테고리를 발견한 것이라 할 수 있다. 즉, VizNCS의 적용을 통해 소비자의 구매 의사결정에 시각 정보의 영향 정도를 발견할 수 있었다.

결론적으로 본 연구에서 제안한 VizNCS는 시각정보의 반영을 통해 기존의 추천 시스템의 성능을 개선하였을 뿐만 아니라 비정형 데이터의 활용 영역을 이미지로 확장하였다. 또한, 구매 의사결정에 시각 정보가 미치는 영향을 상품 분류 즉, 카테고리에 따라 확인하여 향후 추천 시스템 설계에 있어 소비자의 의사결정 프로세스에 대한 이해를 바탕으로 한 반영이 필요함을 시사하였다. 하지만 본 연구는 다음과 같은 한계를 지닌다. 먼저, 본 연구에서는 VizNCS의 성능을 측정하기 위하여 도서 도메인을 대상으로 실험을 진행하였다. 시각 정보는 도서 뿐만 아니라 일반적인 상품의 의사결정에도 큰 영향을 줄 수 있다. 따라서, 향후 연구에서는 도서 도메인에서 확장하여 다양한 상품군에 대한 실험을 진행할 예정이다. 다음으로, 본 연구에서 제안한 VizNCS는 시각 정보로의 확장을 고려하여 확장성이 높은 NCF에 기반하였다. 최근 딥러닝을 추천 시스템에 적용하려는 연구가 활발히 진행되고 있는 상황에서 VizNCS의 성능을 높이기 위해 향후 연구에서는 다른 딥러닝 기반의 추천 시스템의 확장을 고려할 예정이다.

## 〈참고문헌〉

### [국내 문헌]

1. 고건, 김보연 (2015). 베스트셀러 표지디자인과 소비자의 구매 결정에 관한연구—온라인 서점을 중심으로. **커뮤니케이션 디자인학연구**, (53), 84-93.
2. 김경재, 안현철 (2009). 개인화된 추천시스템을 위한 사용자-상품 매트릭스 축약기법. **Journal of Information Technology Applications & Management**, 16(1), 97-113.
3. 김민정, 조윤호 (2015). 빅데이터 기반 추천 시스템 구현을 위한 다중 프로파일 양상블 기법. **지능정보연구**, 21(4), 93-110.
4. 김영준, 김용희, 김응모 (2015). 협업필터링과 데이터마이닝을 통한 도서추천 시스템 제안. **2015 한국통신학회 추계종합학술발표회 논문집**, 58-60.
5. 이석원, 임세희, 양지훈 (2016). 협력적 필터링과 연관규칙 알고리즘을 활용한 도서추천시스템. **한국정보과학회 2016년 동계학술대회 논문집**, 1818-1820.
6. 대한출판문화협회 (2020). **2019년 출판시장 통계(주요 출판사와 서점의 매출액, 영업이익 현황)**. 서울: 대한출판문화협회.
7. 손지은, 김성범, 김현중, 조성준 (2015). 추천 시스템 기법 연구동향 분석. **대한산업공학회지**, 41(2), 185-208.
8. 심재문, 강지욱, 권오병 (2010). 상황인식 기술을 이용한 운전자 선호도 기반 교통상세정보 추천 시스템. **지식경영연구**, 11(2), 75-93.
9. 조승연, 최지은, 이규현, 김희웅 (2015). 고객 온라인 구매후기를 활용한 추천시스템 개발 및 적용. **Information Systems Review**, 17(3), 77-93.
10. 정영진, 조윤호 (2017). 온라인 구매 행태를 고려한 토픽 모델링 기반 도서 추천. **지식경영연구**, 18(4), 97-118.
11. 최영제, 문현실, 조윤호 (2020). 트랜잭션 기반 추천 시스템에서 워드 임베딩을 통한 도메인 지식 반영. **지식경영연구**, 21(1), 117-136.

### [국외 문헌]

12. Caselles-Dupré, H., Lesaint, F., & Royo-Letelier, J. (2018). Word2vec applied to recommendation: Hyperparameters matter. *In Proceedings of the 12th ACM*

- Conference on Recommender Systems*, 352–356.
13. Cheng, H. T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., Anderson, G., Corrado, G., Chai, W., Ispir, M., Anil, R., Haque, Z., Hong, L., Jain, V., Liu, X., & Shah, H. (2016). Wide & deep learning for recommender systems. *In Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*, 7–10.
  14. Chen, K., Wang, J., Chen, L. C., Gao, H., Xu, W., & Nevatia, R. (2015). *Abs-cnn: An attention based convolutional neural network for visual question answering*. arXiv preprint arXiv: 1511.05960.
  15. Gao, C., He, X., Gan, D., Chen, X., Feng, F., Li, Y., Chua, T. S., Yao, L., Song, Y., & Jin, D. (2018). *Learning recommender systems from multi-behavior data*. arXiv preprint arXiv:1809.08161.
  16. Haucap, J., & Heimeshoff, U. (2014). Google, Facebook, Amazon, eBay: Is the Internet driving competition or market monopolization? *International Economics and Economic Policy*, *11*(1), 49–61.
  17. Herlocker, J. L., Konstan, J. A., Terveen, L. G., & Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, *22*(1), 5–53.
  18. He, R., & McAuley, J. (2016). VBPR: Visual bayesian personalized ranking from implicit feedback. *In Thirtieth AAAI Conference on Artificial Intelligence*, 144–150.
  19. He, X., Du, X., Wang, X., Tian, F., Tang, J., & Chua, T. S. (2018). *Outer product-based neural collaborative filtering*. arXiv preprint arXiv:1808.03912.
  20. He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T. S. (2017). Neural collaborative filtering. *In Proceedings of the 26th International Conference on World Wide Web*, 173–182.
  21. Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2015). *Session-based recommendations with recurrent neural networks*. arXiv preprint arXiv:1511.06939.
  22. Koren, Y., Bell, R., & Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, *42*(8), 30–37.
  23. Kurt, Z., & Özkan, K. (2017). An image-based recommender system based on feature extraction techniques. *In 2017 International Conference on Computer Science and Engineering (UBMK)*, 769–774.
  24. Lathia, N., Hailes, S., Capra, L., & Amatriain, X. (2010). Temporal diversity in recommender systems. *In Proceedings of the 33rd International Acm Sigir Conference on Research and Development in Information Retrieval*, 210–217.
  25. Lei, C., Liu, D., Li, W., Zha, Z. J., & Li, H. (2016). Comparative deep learning of hybrid representations for image recommendations. *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2545–2553.
  26. Low, Y. H., Yap, W. S., & Tee, Y. K. (2018). Convolutional neural network-based collaborative filtering for recommendation systems. *In International Conference on Robot Intelligence Technology and Applications*, 117–131.
  27. Ouyang, Y., Liu, W., Rong, W., & Xiong, Z. (2014). Autoencoder-based collaborative filtering. *In International Conference on Neural Information Processing*, 284–291.
  28. Rawat, Y. S., & Kankanhalli, M. S. (2016). ConTagNet: Exploiting user context for image tag recommendation. *In Proceedings of the 24th ACM International Conference on Multimedia*, 1102–1106.
  29. Persson, P. (2018). Attention manipulation & information overload. *Behavioural Public Policy*, *2*(1), 78–106.
  30. Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., & Riedl, J. (1994). GroupLens: An open architecture for collaborative filtering of netnews. *In Proceedings of the 1994 ACM Conference on Computer Supported Cooperative Work*, 175–186.
  31. Salakhutdinov, R., Mnih, A., & Hinton, G. (2007). Restricted Boltzmann machines for collaborative filtering. *In Proceedings of the 24th International Conference on Machine Learning*, 791–798.
  32. Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *In Proceedings of the 10th International Conference on World Wide Web*, 285–295.
  33. Sase, A., Varun, K., Rathod, S., & Patil, D. (2015).

- A proposed book recommender system. *International Journal of Advanced Research in Computer and Communication Engineering*, 4(2), 481-483.
34. Schafer, J. B., Frankowski, D., Herlocker, J., & Sen, S. (2007). Collaborative filtering recommender systems. In *The adaptive web* (pp. 291-324). Berlin: Springer.
35. Sedhain, S., Menon, A. K., Sanner, S., & Xie, L. (2015). Autorec: Autoencoders meet collaborative filtering. In *Proceedings of the 24th International Conference on World Wide Web*, 111-112.
36. Wang, S., Wang, Y., Tang, J., Shu, K., Ranganath, S., & Liu, H. (2017). What your images reveal: Exploiting visual contents for point-of-interest recommendation. In *Proceedings of the 26th International Conference on World Wide Web*, 391-400.
37. Xu, Z., Chen, C., Lukasiewicz, T., Miao, Y., & Meng, X. (2016). Tag-aware personalized recommendation using a deep-semantic similarity model with negative sampling. In *Proceedings of the 25th ACM International Conference on Information and Knowledge Management*, 1921-1924.
38. Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys (CSUR)*, 52(1), 1-38.

## 저 자 소 개



### 문 현 실 (Hyun Sil Moon)

현재 국민대학교 경영대학원 AI빅데이터MBA 조교수로 재직 중이다. 경희대학교 경영학부를 졸업하고 동 대학원 경영학과에서 MIS전공으로 석사, 박사학위를 취득하였다. 주 연구 분야는 빅데이터 분석, 머신러닝 및 딥러닝 기반 추천 시스템, 텍스트 분석, 소셜네트워크 분석 등이다.



### 임 진 혁 (Jinhyuk Lim)

국민대학교 경영학부 빅데이터통계전공을 졸업하였다. 주요 연구 관심분야는 추천시스템, Knowledge Transfer, 모델경량화이다.



### 김 도 연 (Doyeon Kim)

현재 국민대학교 경영학부 빅데이터경영통계전공에 재학중이다. 주요 연구 관심분야는 딥러닝, 머신러닝, 추천시스템이다.



### 조 윤 호 (Yoonho Cho)

현재 국민대학교 경영학부 빅데이터경영통계전공 교수로 재직 중이다. 서울대학교 계산통계학과를 졸업하고, KAIST 경영정보공학과에서 석사, KAIST 경영공학과에서 박사학위를 취득하였으며, LG전자(주)에서 6년간 주임연구원으로 재직하였다. 주 연구분야는 머신러닝, 딥러닝, 비즈니스애널리틱스, 추천시스템, 소셜네트워크분석, 고객관계관리 등이다.

〈 Abstract 〉

# A Deep Learning Based Recommender System Using Visual Information

Moon, Hyunsil<sup>\*</sup>, Lim, Jinhyuk<sup>\*\*</sup>, Kim, Doyeon<sup>\*\*\*</sup>, Cho Yoonho<sup>\*\*\*\*</sup>

In order to solve the user's information overload problem, recommender systems infer users' preferences and suggest items that match them. The collaborative filtering (CF), the most successful recommendation algorithm, has been improving performance until recently and applied to various business domains. Visual information, such as book covers, could influence consumers' purchase decision making. However, CF-based recommender systems have rarely considered for visual information. In this study, we propose VizNCS, a CF-based deep learning model that uses visual information as additional information. VizNCS consists of two phases. In the first phase, we build convolutional neural networks (CNN) to extract visual features from image data. In the second phase, we supply the visual features to the NCF model that is known to easy to extend to other information among the deep learning-based recommendation systems. As the results of the performance comparison experiments, VizNCS showed higher performance than the vanilla NCF. We also conducted an additional experiment to see if the visual information affects differently depending on the product category. The result enables us to identify which categories were affected and which were not. We expect VizNCS to improve the recommender system performance and expand the recommender system's data source to visual information.

Key Words: Recommender Systems, Deep learning, Collaborative Filtering, Visual Information, Convolutional Neural Networks

---

\* Graduate School of Business Administration, Kookmin University

\*\* School of Business Administration, Kookmin University

\*\*\* School of Business Administration, Kookmin University

\*\*\*\* School of Business Administration, Kookmin University