

# 딥러닝 기반 온라인 리뷰의 언어학적 특성을 활용한 추천 시스템 성능 향상에 관한 연구\*

장동수

경희대학교 대학원 빅데이터응용학과  
(zsd21@khu.ac.kr)

이청용

경희대학교 대학원 빅데이터응용학과  
(leecy@khu.ac.kr)

김재경

경희대학교 경영대학&빅데이터응용학과  
(jaek@khu.ac.kr)

전자상거래 시장의 꾸준한 성장으로 인해 추천 시스템의 필요성은 점차 강조되고 있으며, 최근에는 추천 성능의 향상을 목적으로 리뷰 텍스트를 사용하는 연구가 활발히 진행되고 있다. 특히 많은 연구들은 리뷰 텍스트의 감성 점수를 활용하여 제안되고 있는데, 감성 점수만을 사용하는 방법론은 리뷰 텍스트에 존재하는 구체적인 선호도 정보의 활용 측면에 한계를 가지며 이는 결과적으로 성능 향상에 제약으로 작용하게 된다. 이를 개선하기 위해 본 연구는 딥러닝 기반 추천 모델에 온라인 리뷰 내 다양한 언어학적 요소들을 활용하여 고객의 선호도를 정교하게 학습할 수 있는 새로운 추천 방법론을 제안하였다. 이를 위해 먼저 고객과 상품 간 복잡한 상호작용을 고려할 수 있도록 딥러닝 모델을 통해 상호작용 관계를 비선형으로 학습하였다. 그리고 리뷰 텍스트를 효과적으로 활용할 수 있도록 언어학적 요소 중 고객의 구매 의사결정에 중요한 영향을 미치는 인지적 요인, 정서적 요인 그리고 언어 스타일 매칭을 사용하였다. 실험은 Amazon.com에서 수집한 온라인 리뷰 데이터를 사용하여 진행하였고, 실험 결과 제안 모델의 우수함을 검증할 수 있었다. 본 연구는 추천 시스템에서 리뷰 텍스트 내 고객 선호도에 대한 정보를 효과적으로 활용하는 방법론을 제안하여 연구의 이론적 및 방법론 측면에 기여하였다.

**주제어** : 딥러닝, 온라인 리뷰, 언어학적 요소, 추천 시스템, 텍스트 마이닝

논문접수일 : 2022년 10월 18일    논문수정일 : 2022년 12월 6일    게재확정일 : 2022년 12월 7일  
원고유형 : 학술대회 Fast Track    교신저자 : 김재경

## 1. 서론

정보통신기술의 발전으로 인해 온라인 전자상거래 시장은 꾸준히 성장하고 있으며 다양한 유형의 상품과 서비스는 지속적으로 출시되고 있다. 이로 인해 고객은 편의성과 다양한 선택지를 제공받을 수 있지만 자신에게 필요한 상품과 서비스를 선택하는데 많은 시간과 비용이 소요되는 정보 과부하 문제에 직면하고 있으며, 그 결과 고객의 선호도에 적합한 상품을 제공할 수 있는 추천 시스템이 주

목받고 있다(Haucap & Heimeshoff, 2014; Su & Khoshgoftaar, 2009). 예를 들어, Amazon(Rendle, 2012a), Google(Das et al., 2007), Netflix(Bennett & Lanning, 2007)와 같은 세계적인 전자상거래 기업들은 추천 시스템을 도입하여 고객의 구매 의사결정을 지원하고 있으며 이를 통해 기업의 지속 가능한 경쟁력을 확보하고 있다(김동연 등, 2022; 이청용 등, 2021). 실제, 전자 상거래 기업 아마존(Amazon)은 매출의 35%가 추천 서비스를 통해 발생하고 있으며 스트리밍 서비스를 제공

\* 본 논문은 교육부 및 한국연구재단 4단계 두뇌한국21 사업(4단계 BK21 사업)으로부터 지원받은 연구임.

하는 넷플릭스(Netflix)는 고객이 시청한 동영상의 75%가 개인화 추천 서비스를 통해 제공됨을 밝혔다(Nguyen et al., 2014). 이처럼 추천 시스템은 고객의 구매 의사결정을 효과적으로 지원하고 기업의 수익 창출에도 기여하여 학계와 산업계에서 많은 관심을 받고 있다(Kim & Park, 2018).

기존의 추천 시스템 연구는 고객의 구매 여부와 같은 암묵적 데이터 혹은 평점과 같은 명시적 데이터를 사용하여 고객의 선호도를 예측하였다(Acilar & Arslan, 2009; Li et al., 2014). 이러한 정량적인 정보는 추천 시스템을 구축할 때 효율적으로 활용할 수 있고 분석 시 편리하며 처리하기 쉽다는 장점이 존재한다. 하지만 정량적인 정보만을 활용하는 경우 고객의 선호도를 효과적으로 반영하지 못해 추천 성능이 저하될 수 있다는 문제점이 제기되고 있다(Cao et al., 2019; Zhang et al., 2014). 한편, 최근에는 정량적인 정보만을 사용한 기존 연구의 한계를 개선하기 위해 고객의 선호도에 대한 정성적인 정보를 담고 있는 온라인 리뷰를 추천 시스템에 반영하는 다양한 연구들이 제안되고 있다(Cheng et al., 2018; Lee et al., 2019). 온라인 리뷰는 제품에 대한 상세하고 신뢰할 수 있는 정보를 포함하기 때문에 이를 통해 고객의 선호도와 관련한 정보를 효과적으로 추출할 수 있다(이흥철 등, 2022; 전병국 등, 2015). 예를 들어, García-Cumbreras et al. (2013)는 협업 필터링(Collaborative Filtering, CF) 모델을 기반으로 하여 온라인 리뷰의 감성 점수를 고려한 방법론과 정량적 데이터만을 사용한 방법론 간 비교를 통해 감성 점수의 활용이 추천 시스템에 유효하게 작용함을 밝혔다. 현지연 등(2019)은 정량적 데이터만을 활용한 추천 시스템 성능의 한계를 개선하기 위해 고객의 리뷰에서 추출한 감성 점수를 평점에 결합한 CF 기반 방법론을 제안

하였으며, Ma et al. (2017)은 온라인 리뷰에서 세부적인 고객의 선호도를 추출하는 것을 목적으로 텍스트 내 다양한 측면에 대한 고객의 감성 점수를 활용하였고 그 결과 기존 정량적인 정보를 활용한 CF 모델보다 향상된 성능을 보이는 것을 확인하였다. 이처럼 온라인 리뷰를 활용한 기존의 추천 시스템 연구들은 감성 점수를 사용하는 데 집중하였다. 하지만, 리뷰 텍스트에는 감성 뿐만 아니라 여러 언어학적(Linguistic) 요소들이 존재한다(Asani et al., 2021; Preethi et al., 2017; Wang et al., 2018). 다시 말해, 온라인 리뷰를 구성하는 언어학적 요소는 감성, 가독성, 언어 스타일 등 다양하게 존재하는데 기존의 감성 점수만을 고려하는 방법론으로는 온라인 리뷰에서 고객의 구체적인 선호도 정보를 활용할 수 없어 추천 성능을 개선하는데 한계점이 존재한다.

이러한 기존 연구의 한계점을 개선하기 위해 본 연구는 딥러닝 모델을 적용하고 온라인 리뷰 텍스트 내 다양한 언어학적 요소를 활용하여 고객의 선호도를 정교하게 예측하는 DRM-IRA(Deep learning Recommendation Methodology based on Interaction and Review Attribute) 모델을 제안한다. 먼저, 고객과 상품 간 복잡한 상호작용을 정교하게 추출하기 위해 다층 퍼셉트론(Multi-Layer Perceptron, MLP)을 활용해 비선형으로 이들 간의 관계를 학습하였다. 또한, 리뷰 텍스트 내 존재하는 고객의 선호도 정보를 효과적으로 반영하기 위해 고객의 구매 의사결정에 중요한 영향을 미치는 인지적 요인(Cognitive Contents), 정서적 요인(Affective Contents) 그리고 언어 스타일 매칭(Linguistic Style Matching, LSM) 등 3가지 언어학적 요소를 활용하였다(Gundecha & Liu, 2012; Ludwig et al., 2013). 이와 관련하여 온라인 리뷰 관련 연구에서 널리 사용되는

Linguistic Inquiry and Word Count(LIWC) 프로그램을 통해 관련 언어학적 요소의 수치를 계산하였다(Hayati et al., 2019; Huang & Chen, 2020; Salsabila & Setiawan, 2021). 이를 기반으로 본 연구는 고객과 상품 간 상호작용 정보와 온라인 리뷰에서 추출한 사용자의 선호도 정보를 통합하여 고객이 특정 상품에 대해 가질 선호도를 정교하게 예측하고자 한다. 본 연구에서 제안한 DRM-IRA 모델의 성능을 효과적으로 검증하기 위해 세계 최대의 전자 상거래 플랫폼인 Amazon.com에서 수집된 온라인 리뷰 데이터를 사용하였다. 실험 결과, 제안한 DRM-IRA 모델은 우수함이 입증된 여러 벤치마크 모델과 비교하여 보다 높은 성능을 나타내는 것을 확인하였다. 본 연구는 온라인 리뷰에서 고객의 선호도 정보를 효과적으로 추출하고 이를 활용하는 추천 방법론을 제안하여 추천 시스템 연구의 이론적 및 방법론 측면에서 기여할 것을 기대한다.

본 연구의 구성은 다음과 같다. 제 2장에서는 CF를 활용한 추천 시스템과 감성 점수를 활용한 관련 연구를 서술한다. 제 3장에서는 본 연구에서 제안하는 DRM-IRA 모델을 설명한다. 제 4장에서는 실험 데이터, 평가지표, 실험 설계 및 결과에 관한 내용을 서술한다. 마지막 제 5장에서는 연구 결과 토의, 한계점과 향후 연구 계획 및 시사점에 대해 구체적으로 서술한다.

## 2. 관련 연구

### 2.1. 추천 시스템

정보통신기술의 발전으로 온라인 전자 상거래 시장이 꾸준히 발달함에 따라 고객들의 구매 의

사결정 난이도는 점차 증가하고 있다(Haucap & Heimeshoff, 2014; Su & Khoshgoftaar, 2009). 추천 시스템의 목표는 고객의 과거 구매 내역이나 평점 정보를 바탕으로 고객의 선호도를 예측하여 맞춤형 상품이나 서비스를 추천하는 것이며, 이를 통해 고객의 구매 의사결정을 효과적으로 지원할 수 있기 때문에 그 중요성은 점차 커지고 있다(Xuequn Wang et al., 2019). 실제 추천 시스템은 학계뿐만 아니라 산업계에서도 기업 경쟁력 강화를 위해 활발히 사용되고 있으며 Amazon(Rendle, 2012a), Google(Das et al., 2007), Netflix(Bennett & Lanning, 2007) 등 세계적인 전자상거래 기업은 추천 시스템을 통해 이윤을 효과적으로 향상시키고 있다. 특히 사용자 기반 협업 필터링(User-based Collaborative Filtering, UBCF)과 아이템 기반 협업 필터링(Item-based Collaborative Filtering, IBCF)으로 구분되는 CF 모델은 Goldberg et al. (1992)에 의해 소개된 이후 우수한 성능으로 인해 다양한 분야에서 널리 사용되고 있다(Acilar & Arslan, 2009; Bhojne et al., 2017; Kim et al., 2010).

예를 들어, Li et al. (2005)는 기존 CF 모델의 예측 대상이 되는 상품이 이웃 고객의 관심사와 일치하지 않는 경우 정확한 추천이 불가능한 문제를 해결하기 위해 IBCF와 UBCF 모델을 결합한 하이브리드 CF를 제안했다. 실험을 위해 EachMovie의 평점 데이터를 영화의 개수 별로 다양하게 분류하여 사용했으며, 실험 결과 제안 모델이 기존의 CF 모델보다 나은 성능을 보이는 것을 확인하였다. CF 모델을 사용하기 위해서는 유사도 측정 과정이 필요하며 고객이나 상품의 수가 증가할 때 필요한 연산의 수는 기하급수적으로 증가하게 되는 문제점이 있다. 본 문제를 개선하기 위해 Kim and Ahn (2008)는 유전 알고리즘(Genetic Algorithms, GA)을 사용한 새로운 클러스터링 알고리즘을 제안

했다. 실험은 한국의 온라인 다이어트 포털 사이트에서 수집한 데이터를 사용했으며 클러스터링의 성능을 비교하기 위해 K-Means, 자기 조직화 지도(Self-Organizing Map, SOM)와 제안 모델인 GA K-Means를 사용했고, 집단의 관성(Intraclass Inertia)을 기준으로 측정한 성능 비교 결과 GA K-Means의 우수함을 확인하였다. 이를 활용한 추천 모델의 유용성을 검증하기 위해 무작위 추천 생성 모델과의 만족도 비교를 시행했으며 설문조사 결과를 통해 제안 모델이 통계적으로 유의한 만족도를 보이는 것을 확인하였다. Acilar and Arslan (2009)는 CF 모델의 한계점을 해결하기 위해 데이터의 희소성을 줄일 수 있는 Artificial Immune Network Algorithm(aiNet) 모델을 제안했다. MovieLens 데이터를 사용하여 실험을 진행했으며 제안 모델의 사용을 통해 데이터의 희소성을 개선한 경우 기존보다 성능이 향상되는 것을 확인하였다. 또한, Kim et al. (2010)은 CF 모델의 고질적인 문제점인 희소성 문제의 개선을 목표로 고객이 생성한 태그를 활용하였다. 소셜 북마크 서비스를 제공하는 del.icio.us의 데이터를 사용했으며 고객의 태그를 활용하여 고객의 선호도를 필터링하였다. 성능 비교 결과 제안 모델이 IBCF, UBCF 모델보다 높은 성능을 보였으며 동시에 데이터 희소성 문제도 개선했음을 확인하였다. CF 모델의 확장성 문제를 해결하기 위해 Park et al. (2015)은 유사도 순서로 N개의 고객이나 상품만을 선정하여 선호도를 예측하는 방법을 제안했다. 실험을 위해 MovieLens 데이터를 사용했으며, 실험 결과 제안 방법론은 정확도 수준을 해치지 않는 수준에서 더 빠른 연산 속도를 보임을 확인하였다.

CF 모델은 고객의 구매 내역, 평점 정보를 사용하여 추천 대상 고객과 유사한 이웃 고객을 기반으로 대상 고객의 선호도를 예측하며 높은 성

능 수준으로 최근까지 많은 연구에서 활용되고 있다. 하지만 전통적인 CF 모델은 구매 정보가 부족한 고객의 선호도를 효과적으로 예측하기 어려운 데이터 희소성 문제와 구매 내역 데이터가 증가할수록 연산 비용이 증가하는 확장성 문제가 존재한다. 또한, 고객의 구매 행동을 기반으로 연산을 진행할 때 CF 모델로는 선형적인 관계만을 고려할 수 있어 고객과 상품 간 복잡한 상호작용 관계가 존재할 경우 이를 고려할 수 없다는 문제점도 존재한다(He et al., 2017). 따라서 본 연구는 딥러닝을 적용한 추천 방법론을 제안하여 비선형 학습 방식을 통해 고객과 상품 간 존재할 수 있는 복잡한 상호작용 관계까지 충분히 고려하는 것을 목표로 한다.

## 2.2. 온라인 리뷰 기반 추천 시스템

정량적인 정보만을 사용한 방법론으로는 고객의 구체적인 선호도를 반영하지 못한다는 문제점이 제기된 이후 고객의 구매 의사결정에 주요한 영향을 미치는 온라인 리뷰를 활용한 추천 시스템 연구들이 다수 제안되고 있다(Cao et al., 2019; Cheng et al., 2018; Zhang et al., 2014). 그 중 자연어 처리 기법의 한 종류인 감성 분석(Sentiment Analysis)을 활용한 연구가 활발하게 진행되고 있다. 감성 분석은 긍정 혹은 부정 단어로 구성된 감성 사전을 기반으로 하는 사전 기반 방법(Lexicon-based Approach)과 감성 특성이나 맥락을 학습하는 기계 학습 기반(Machine Learning Approach)로 구분된다. 이는 정량적인 정보만을 사용하는 추천 시스템의 한계점을 개선하기 위해 온라인 리뷰 텍스트에서 정성적 정보를 추출하는 수단으로 사용되어 상품이나 서비스에 대한 선호도의 유사도를 계산할 때 활용되고 있다(Cheng

et al., 2018; Zheng et al., 2017).

예를 들어, Leung et al. (2006)은 최초로 추천 시스템에 온라인 리뷰를 고려한 연구를 제안하였다. 연구는 감성 분석을 통해 IMDb 내 고객의 영화 리뷰에서 긍정 혹은 부정에 해당하는 감성 방향 (Sentimental Orientation)과 의견의 강도(Intensity)를 추정하고 해당 값들을 CF 모델에 투입하여 추천 모델을 구축하였다. 해당 연구는 추천 시스템에서 정성적 선호도를 정량적으로 변환하여 활용한 첫 번째 연구라는 점에서 의의가 있지만 정량적 선호도는 고려하지 못한 한계점이 존재한다. García-Cumbreras et al. (2013)는 CF 모델의 성능 향상을 목적으로 리뷰의 감성 분석을 통해 고객을 낙관주의자 혹은 비관주의자로 분류하고 각 집단 별로 CF를 수행하는 방법론을 제안하였다. 제안 방법론의 검증을 위해 IMDb 데이터를 사용해 실험을 진행했으며 해당 방법론을 통해 CF 알고리즘의 성능 개선이 가능함을 입증했다. Bhojne et al. (2017)는 추천 시스템에 사용자의 속성을 추가로 고려하여 추천 결과의 품질 향상을 목표로 연구를 수행하였다. 해당 연구는 레스토랑 데이터를 사용하였으며 감성 분석 라이브러리를 통해 리뷰를 분석한 감성 점수와 고객의 속성을 활용하여 모델을 구축하였고 이를 통해 추천 성능의 향상을 가져올 수 있음을 확인하였다. 현지연 등 (2019)은 감성 분석 결과를 활용하여 고객 선호도를 보다 정교하게 추출하는 것을 목표로 연구를 진행하였다. 이를 위해 한글 형태소 분석에 사용되는 라이노(RHINO) 라이브러리를 사용하여 전처리를 진행한 이후 구축한 사전을 통해 감성 점수를 도출하였다. 실험은 네이버 영화에서 수집한 데이터를 사용했으며 감성 분석 결과와 평점을 결합하고 모델에 투입시킨 결과 제안 방법론이 추천 성능 개선을 가져옴을 확인하였다. 이승우 등

(2022)은 정량적인 정보만을 사용하는 기존 연구의 한계를 넘기 위해 사용자의 정량적 선호도(평점)과 정성적 선호도(리뷰의 감성 점수)의 가중합을 이용하는 방법론을 제안했다. TripAdvisor.com에서 수집한 데이터를 사용했으며 가중합 방식을 통해 생성한 새로운 평점 행렬을 CF 모델에 투입하여 실험을 진행하였고 정량적 선호도만 사용한 기존 방법론보다 우수함을 입증하였다.

이처럼 기존의 온라인 리뷰를 사용한 추천 시스템 연구는 주로 리뷰 텍스트에서 감성 점수를 추출하여 추천 시스템에 반영하였다. 그러나 온라인 리뷰는 다양한 언어학적 요소로 구성되어 있기 때문에 감성 점수만을 고려하는 방식은 고객의 구체적인 선호도 특성을 반영하는 데 한계점으로 작용한다. 즉, 기존의 방식으로는 온라인 리뷰에 담겨있는 고객의 구체적인 선호도 정보를 효과적으로 활용할 수 없어 추천 성능 향상 측면에 제약으로 작용하게 된다. 따라서 본 연구는 온라인 리뷰 내 인지적 요인, 정서적 요인 그리고 LSM을 활용하여 추천 시스템을 구축한다. 여러 연구를 통해 인지적 요인, 정서적 요인 그리고 LSM은 온라인 리뷰를 구성하는 중요한 언어학적 요소라는 것이 입증되었다(Xi Wang et al., 2019; Yang et al., 2021). 온라인 리뷰의 주요 구성 요소 중 인지적 요인은 텍스트 내 필요, 결과, 원인 등의 요소로 이루어진 맥락적 측면을 의미하고, 정서적 요인은 텍스트 내 긍정 혹은 부정 요소로 이루어진 감정적인 측면을 의미한다(Ludwig et al., 2013). LSM은 관사, 접속사, 전치사와 같은 기능어 사용의 유사도를 계산하여 측정하며 온라인 리뷰 텍스트를 통해 전자상거래 고객의 수렴 행동을 평가할 때 사용된다(Gonzales et al., 2010). 이러한 요소들은 온라인 리뷰의 구체적인 선호도 특성을 추출할 때 널리 사용되고 있으며,

여러 연구를 통해 온라인 쇼핑 환경에서 고객의 구매 행동에 중요한 영향을 미친다는 것이 검증되었다(Ludwig et al., 2013; Topaloglu & Dass, 2021; Yang et al., 2021). 즉, 온라인 리뷰의 언어학적 요소들은 실제 고객의 구매 의사결정과 행동에 영향을 미치는 것이 입증되었음에도 불구하고 고객의 선호도를 예측하여 맞춤형 제품이나 서비스를 제공하는 추천 시스템 분야에서 이를 적용한 연구는 부족한 실정이다. 따라서 본 연구에서는 온라인 리뷰 내 구매 의사결정에 영향을 미치는 다양한 언어학적 요소를 활용하여 고객의 선호도를 정교하게 예측하는 DRM-IRA 모델을 제안한다.

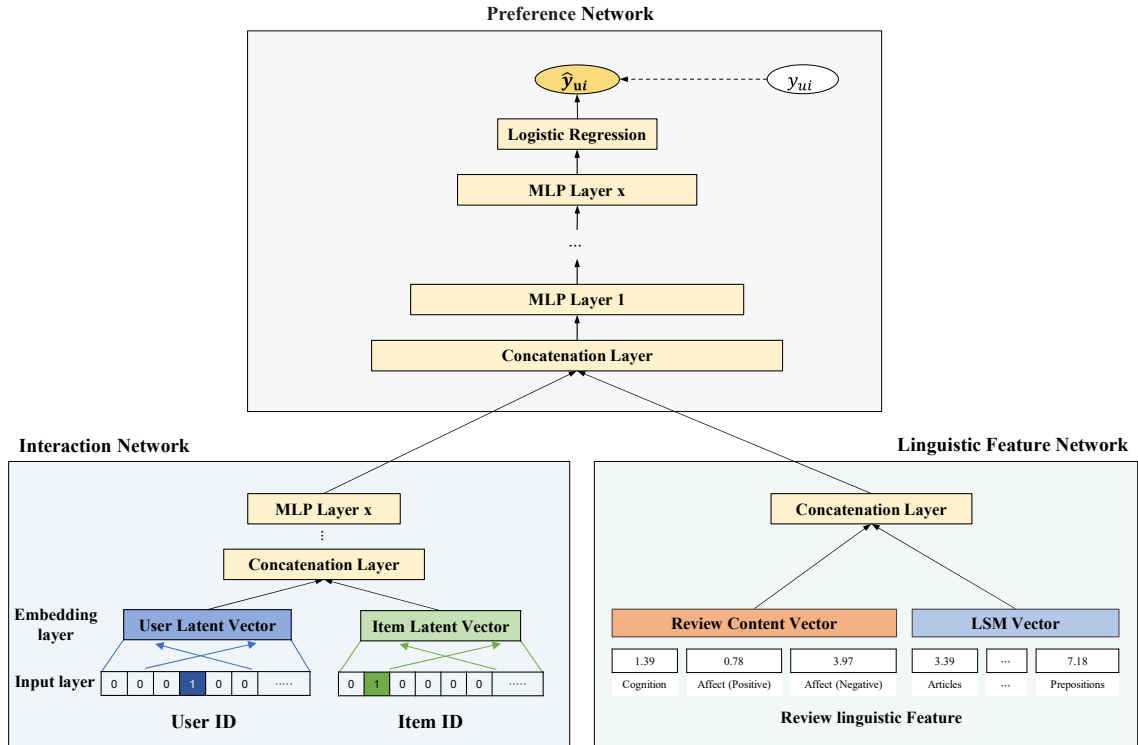
### 3. DRM-IRA 프레임워크

온라인 리뷰에는 여러 언어학적 요소가 존재하지만 기존 추천 시스템 연구들은 리뷰 텍스트 내 감성 요소를 활용하는 데 집중하였다. 본 연구는 기존 온라인 리뷰를 활용한 추천 시스템의 한계점을 개선하기 위해 딥러닝 기반 추천 시스템에 온라인 리뷰를 구성하는 주요 요소이자 구매 의사결정에 영향을 미치는 언어학적 요소(인지적 요인, 정서적 요인, LSM)를 반영하는 DRM-IRA 모델을 제안한다. 본 연구에서 제안한 모델은 <Figure 1>과 같이 총 3가지 네트워크로 구성된다. 첫 번째 상호작용 네트워크(Interaction Network)는 고객과 상품 간 상호작용을 비선형으로 학습하고 상호작용 벡터를 출력한다. 두 번째 언어학적 요소 네트워크(Linguistic Feature

Network)는 고객의 온라인 리뷰에 내재된 언어학적 요소들을 추출하는 것을 목적으로 하며 각 리뷰를 대상으로 인지적 요인, 정서적 요인 그리고 LSM 요인을 산출한다. 마지막 선호도 예측 네트워크(Preference Prediction Network)는 상호작용 네트워크와 언어학적 요소 네트워크를 통해 출력된 벡터를 결합하여 연산을 수행하며 고객의 선호도 평점을 예측하는 역할을 한다. 각 네트워크의 구체적인 내용은 다음과 같다.

#### 3.1. 상호작용 네트워크

첫 번째 상호작용 네트워크는 MLP를 적용하여 고객과 상품 간 복잡한 상호작용을 학습하는 것을 목표로 한다. 이를 위해 먼저 딥러닝 기반 모델에서 상호작용을 효과적으로 학습할 수 있도록 고객과 상품의 희소 벡터(Sparse Vector)를 밀집 벡터(Dense Vector)로 변환하여 표현한다(He et al., 2017). 이 과정은 고객과 상품 정보에 각각 임베딩 기법을 적용하여 벡터를 생성하는 과정을 통해 구현되며 산출된 임베딩 벡터는 잠재 요인 모델(Latent Factor Model)에서의 고객과 상품의 잠재 벡터로 활용된다. 위 과정의 결과로 생성된 두 잠재 벡터를 단순히 연결하는 방식으로는 잠재 요인 간 상호작용을 반영시키지 못해 추천 시스템에 활용되기에 불충분하다. 따라서 생성된 잠재 벡터들은 상호작용을 학습하기 위해 수식 (1)과 같이 결합 과정을 거친 이후 MLP에 순차적으로 투입되며 레이어들의 비선형 학습 과정을 통해 고객-상품 간 상호작용을 나타내는 특정 패턴을 반영한 벡터를 출력한다.



〈Figure 1〉 DRM-IRA Framework

$$\begin{aligned}
 i_0 &= \phi(p_u, q_i) = \begin{bmatrix} p_u \\ q_i \end{bmatrix} \\
 i_1 &= a_1(W_1^T i_0 + b_1) \\
 &\dots \\
 V^I &= a_L(W_L^T i_{L-1} + b_L)
 \end{aligned} \tag{1}$$

여기서  $p_u$ 와  $q_i$  는 각각 고객과 상품 임베딩이며,  $\phi$  는 요소 간 결합(Concatenate)을 수행하는 함수를 나타낸다. 그리고  $W_L^T$ ,  $b_L$  및  $a_L$  는 각각 L번째 레이어에 대한 가중치, 편향 그리고 활성화 함수인 ReLU(Rectified Linear Unit)이며 수식의 결과로 출력되는  $V^I$  는 상호작용이 학습된 벡터를 의미한다.

### 3.2. 언어학적 요소 네트워크

두 번째는 온라인 리뷰에서 언어학적 요소를 추출하는 과정이다. 기존 감성 요소를 활용한 방법보다 다양한 정보의 추출을 통해 온라인 리뷰의 고도화된 활용을 구현하기 위하여 온라인 리뷰의 주요 요소이자 고객의 구매 행동에도 주요한 영향을 미치는 것이 입증된 인지적 요인, 정서적 요인 그리고 LSM을 활용한다(Ludwig et al., 2013; Topaloglu & Dass, 2021). 본 연구에서는 온라인 리뷰에 담긴 위 특성들을 효과적으로 추출하기 위하여 LIWC를 사용한다(Yang et al., 2021). LIWC는 텍스트 내 존재하는 여러 특성들을 추출할 때 사용되며 다양한 분야의 연구에서

활용되어 우수한 성능을 입증받고 있다(Gottschalk, 2020; Roberts, 2020). 본 연구에서 활용하는 리뷰 콘텐츠의 구성 요소로 먼저 인지적 요인은 텍스트 내의 필요, 결과, 원인 등의 요소로 이루어진 맥락적인 측면을 나타내며, 다음으로 정서적 요인은 텍스트 내 긍정 요소와 부정 요소로 구성된 두 가지 감정적인 측면을 나타낸다(Ludwig et al., 2013; Topaloglu & Dass, 2021). 이러한 두 요인은 LIWC를 통해 텍스트를 구성하는 전체 단어 중 해당 측면을 나타내는 단어의 비율로 계산된다. 즉, 이 과정을 통해 특정 리뷰가 전체 내용 중 인지적 내용의 비율이 얼마나 큰지 혹은 정서적 내용 중 긍정적 내용의 비율 및 부정적 내용의 비율은 얼마나 큰지를 계산하여 리뷰 텍스트 내 요인들을 계량화하게 된다. 추출된 인지적 요인과 정서적 요인 내 긍·부정 감정 요소는 수식 (2)와 같이 결합 과정을 통해 리뷰 콘텐츠 (Review Contents) 요인으로 활용된다.

$$O^{rc} = [O_{cognition}, O_{positive}, O_{negative}] \quad (2)$$

수식 (2)의  $O_{cognition}$ 는 인지적 요인을 추출한 벡터를 의미하고,  $O_{positive}$ 와  $O_{negative}$ 는 각각 정서적 요인을 구성하는 긍정적 요소 벡터와 부정적 요소 벡터를 의미한다.

다음으로 LSM은 온라인 리뷰 내 기능어의 사용에 따라 정의되며 기능어는 <Table 1>과 같이 총 9가지 주요 범주로 구성된다(Tausczik & Pennebaker, 2010).

<Table 1> Example of 9 categories of functional words within the LIWC

Category	Example
Personal pronouns	I, you, we, he, she, they...
Impersonal pronouns	another, anything, everyone, it, that...
Articles	a, an, the...
Conjunctions	also, and, but, because, if, until...
Prepositions	about, as, by, for, in, with...
Auxiliary verbs	be, do, have, must, shall, should...
High-frequency adverbs	rather, just, only, often, really, very...
Negations	cannot, never, no, nothing, not, none...
Quantifiers	all, both, much, multiple, few...

기능어는 개인이 사용하는 전체 단어 중 절반 이상을 차지하며, 각각의 고객이 작성한 리뷰에 유사한 기능어가 많다는 것은 고객 간에 인지적 동시성을 가지게 되는 요소로 작용한다(Ireland & Pennebaker, 2010). 또한, 유사한 기능어의 사용은 커뮤니티 내 의사소통 과정에서 사회적 거리를 줄일 수 있도록 자극하기도 하며, 다른 고객의 리뷰와의 커뮤니케이션 스타일이 유사하면 행동까지 수렴하게 만드는 커뮤니케이션 수렴 이론을 발생시키기도 한다(Chung & Pennebaker, 2007; Gonzales et al., 2010). 이렇듯 고객의 구매 의사결정에 중요한 입력으로 작용하게 되는 LSM은 선행 연구에 따라 수식 (3)으로 표현한 방식과 같이 9개의 개별 요소들을 계량화하고 계산된 개별 요소들의 평균 값을 LSM 요인으로 활용하게 된다(Chung & Pennebaker, 2007; Ireland & Pennebaker, 2010).



$$LSM_{perp} = 1 - \frac{|perp_1 - perp_2|}{perp_1 + perp_2 + 0.0001} \quad (3)$$

수식 (3)의  $LSM_{perp}$ 는 LSM 내 9가지 범주 중 Personal pronouns 범주에 해당하는 LSM 점수를 나타내며  $Perp_1$ 는 특정 고객이 사용한 해당 범주의 기능어,  $perp_2$ 는 전체 고객 집단이 사용한 해당 범주의 기능어를 의미한다.

즉, 3.2장에서 추출된 온라인 리뷰의 주요 요인들은 크게 리뷰 콘텐츠 벡터, LSM 벡터로 정리되며 리뷰 콘텐츠 벡터는 인지적 요인과 정서적 요인(긍정 및 부정)으로 구성되고 LSM 벡터는 9개 범주들의 평균 값을 도출하여 구성된다. 마지막으로 두 벡터는 제안 모델 내 리뷰 언어학적 요소로 투입하기 위해 수식 (4)와 같이 벡터간 결합을 수행한다.

$$V^{rlf} = \phi(O^{rc}, O^{lsm}) = \begin{bmatrix} O^{rc} \\ O^{lsm} \end{bmatrix} \quad (4)$$

위 수식의  $V^{rlf}$ 는 언어학적 요소 네트워크의 결과이며,  $O^{rc}$ 와  $O^{lsm}$ 는 각각 리뷰 콘텐츠 벡터와 LSM 벡터를 의미한다.

### 3.3. 선호도 예측 네트워크

마지막 과정에서는 상호작용 네트워크와 언어학적 요소 네트워크에서 추출한 벡터를 바탕으로 고객의 선호도를 나타내는 평점을 최종 예측한다. 선행 과정에서 추출된 상호작용 벡터와 언어학적 요소 벡터를 예측을 위한 요인으로 활용하기 위해 수식 (5)의 과정을 통해 요소간 결합을 수행한다. 아래 수식 (5)의  $V$ 는 상호작용을 학습한 벡터를 의미하고,  $V^{rlf}$ 는 언어학적 요소

를 통합한 벡터를 의미한다.

$$z_0 = \phi(V_I, V_{rlf}) = \begin{bmatrix} V_I \\ V_{rlf} \end{bmatrix} \quad (5)$$

수식 (5)를 통해 고객과 상품의 정보를 바탕으로 생성한 상호작용 벡터에 고객의 온라인 리뷰 내 언어학적 요소 정보를 반영한 벡터가 생성된다. 생성된 벡터는 평점 예측을 위해 수식 (6)와 같이 MLP 레이어에 투입되는데 다음 레이어로 연산 결과를 전달하기 위한 활성화 함수는 ReLU를 사용한다. 최종 평점 예측을 위해 위 과정을 반복 진행되며 파라미터들도 튜닝하는 과정을 반복한다. 해당 과정에서 최소 및 최대 범위가 지정된 평점을 대상으로 한 예측을 수행하기 위해 1~5 범위를 나타내는 기존 평점을 선형 변환을 통해 0~1 범위의 값으로 조정된 이후 학습에 투입한다(Kiran et al., 2020). 따라서, 최종 레이어는 로지스틱 회귀를 사용하며 이를 위해 출력 함수로 Sigmoid를 사용한다(Li & Kim, 2021).

$$\begin{aligned} \sigma_1 &= a_1(W_1^T z_0 + b_1) \\ &\dots \\ \sigma_{output} &= a_L(W_L^T \sigma_{L-1} + b_L) \end{aligned} \quad (6)$$

여기서  $W^T$ ,  $b$  그리고  $a$ 는 각 레이어에 대한 가중치, 편향 그리고 활성화 함수로 사용된 ReLU이며 앞서 서술한 바와 같이 최종 출력 함수인  $a_L$ 는 Sigmoid를 의미한다.

위 수식을 통해 출력된 예측 값은 기존 평점의 최소 및 최대 범위에 위치할 수 있도록 최종 출력 함수에 선형 변환을 적용하는 과정을 거친다. 이를 통해 예측 평점은 실제 평점의 범위 내 위치할 수

있게 되며 최종 성능 평가 또한 기존 평점 범위를 기준으로 수행할 수 있다(Rama et al., 2021). 따라서 Sigmoid 연산을 통해 산출된 0~1 범위의 예측 값을  $min_{rating} + \sigma_{output} \times (max_{rating} - min_{rating})$  수식을 통해 1~5 범위를 가진 기존 평점 범위로 선형 변환시킨 이후 성능 수준을 측정한다(Kiran et al., 2020). 위 수식의  $min_{rating}$ 과  $max_{rating}$ 은 각각 평점 내 최소 값과 최대 값을 의미한다.

## 4. 실험

### 4.1. 데이터 및 평가지표

본 연구에서 제안한 DRM-IRA 모델의 성능을 검증하기 위해 Amazon.com에서 1996년 5월부터 2018년 10월까지 수집된 리뷰 데이터를 사용하였다(Ni et al., 2019). 세계 최대 전자 상거래 플랫폼인 Amazon.com에는 방대한 양의 구매 기록과 온라인 리뷰를 포함한 데이터가 존재하여 이를 활용한 연구는 다양한 분야에서 진행되고 있다(Huang et al., 2020; Huang et al., 2004; Schafer et al., 2001). 본 연구에서 사용된 Amazon.com 데이터는 <Table 2>와 같이 고객, 상품, 리뷰, 평점 등 다양한 정보를 포함하고 있다. 본 연구에서는 약 153만 명의 고객이 7만여 개의 상품에 대해 남긴 2,563,542개의 리뷰 데이터를 담은 Video Games 카테고리를 사용했다. 그 중 제안 모델의 성능을 효과적으로 측정하기 위해 5개 이상의 구매 이력을 남긴 고객 데이터를 사용하며 전체 데이터 중 70%는 학습 데이터, 10%는 검증 데이터 그리고 20%는 테스트 데이터로 사용했다(Rendle, 2012b).

<Table 2> Example of Amazon.com online review dataset

Attribute	Example
Reviewer ID	0439381673
Product ID	A21ROB4YDOZA5P
Vote	0
Star rating	1
Review time	06 9, 2014
Review name	Mary M. Clark
Review Text	'I used to play this game years ago and loved it. I found this did not work on my computer even though it said it would work with Windows 7.'
Summary	'Did not like this'

모델의 성능을 측정하는 평가지표는 평점 예측 분야에서 널리 사용되는 MAE(Mean Absolute Error)와 RMSE(Root Mean Square Error)를 사용했다(Silveira et al., 2019). MAE는 수식 (7)과 같이 예측 점수와 실제 점수 간 오차의 절대값을 합하여 전체 평가 대상의 개수로 나눠주는 방식으로 오차의 크기에 상관없이 모두 같은 가중치를 가진다. RMSE는 수식 (8)과 같이 오차를 제곱한 값의 평균으로 계산되는 MSE(Mean Squared Error)의 제곱근으로 MAE에 비해 예측 오차가 큰 관측치에 대해 상대적으로 큰 가중치를 가진다.

$$MAE = \frac{\sum_{i=1}^N |\hat{y}_{u,i} - y_{u,i}|}{N} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (\hat{y}_{u,i} - y_{u,i})^2}{N}} \quad (8)$$


공통적으로 수식 (7)과 수식 (8)의  $N$ 은 예측 평점의 개수를 나타내며,  $\hat{y}_{u,i}$ 는 고객  $u$ 의 상품  $i$ 에 대한 예측 평점,  $y_{u,i}$ 는 고객  $u$ 가 상품  $i$ 에 남긴 실제 평점을 나타낸다.

#### 4.2. 실험 설계


제안한 DRM-IRA 모델의 추천 성능을 효과적으로 검증하기 위해 <Table 3>과 같이 정량적 정보를 활용한 모델 중 우수함이 입증된 Generalized Matrix Factorization(GMF), Multi-Layer Perceptron (MLP) 및 Neural Matrix Factorization(NeuMF) 모델을 구축하였다. 이를 통해, 정량적 정보를 고려한 모델과 언어학적 요소들을 추가로 고려한 모델 간 성능을 비교하였다. 다음으로, 리뷰 콘텐츠 요인 (예: 감성 점수)을 상황 정보로 고려한 Review Content-Aware Model(RCAM)과 LSM 요인을 상황 정보로 고려한 Linguistic Style Matching-Aware Model(LSMAM)을 각각 구축하여 언어학적 요소가 추천 성능에 미치는 영향을 확인하였다.

본 연구에서는 실험에 사용하는 온라인 리뷰를

효율적으로 분석하기 위해 NLTK 패키지를 통해 텍스트 전처리를 진행했으며 리뷰 텍스트에 포함되어 있지만 의미를 갖지 않는 특수문자, 숫자, 기호 등을 제거했다(Hickman et al., 2022). 이후 정제된 리뷰 데이터는 LIWC 프로그램을 통해 분석을 시행했으며, 이를 통해 도출된 수치들은 각각의 요인들에 부합하도록 가공하는 과정을 거쳐 모델의 언어학적 요소로 투입되었다(Gundecha & Liu, 2012; Ludwig et al., 2013; Topaloglu & Dass, 2021). 모델의 학습 과정에서 사용한 파라미터로 ItemKNN 모델은 이웃 수를 32로 설정했으며, 제안 모델과 딥러닝을 활용한 벤치마크 모델은 동일한 파라미터들을 사용했다. 구체적인 파라미터로 고객과 상품의 잠재 요인 크기를 32, 학습에 투입되는 배치의 크기를 1024로 사용했다 (Yang et al., 2020). 또한, 기존 연구에 따라 학습률은 0.001, 최적화 함수는 Adam을 사용하여 모델 학습을 수행했다(He et al., 2017). 그리고 모델의 반복 학습 과정에서 최적의 Epoch 수를 설정하기 위해 Early Stopping을 10 Epochs로 설정



<Figure 2> Performance Comparison with Benchmark Models Based on MAE



〈Figure 3〉 Performance Comparison with Benchmark Models Based on RMSE

했다(Rendle & Schmidt-Thieme, 2008). 본 연구의 실험은 총 5회씩 수행되었고 성능 결과로는 평균과 표준편차를 계산했다. 실험은 Tensorflow 패키지를 사용하며 CPU Intel Core i9-11900F, 128GB RAM, GeForce RTX 3080 Ti GPU 환경에서 수행되었다.

### 4.3. 실험 결과

#### 4.3.1. 모델 성능 비교

본 연구에서 제안한 DRM-IRA 모델의 성능을 평가하기 위해 세계 최대의 전자 상거래 플랫폼인 Amazon.com의 온라인 리뷰 데이터를 사용했으며 여러 벤치마크 모델과 추천 성능을 비교했다. 실험 결과는 <Figure 2>와 <Figure 3>과 같이 나타나며, 해당 실험 결과를 통해 다음과 같은 결론을 도출할 수 있다. 먼저, 본 연구에서 제안한 DRM-IRA 모델은 모든 벤치마크 모델보다 향상된 성능을 보여주고 있으며, 전체 벤치마크 모델과 비교하여 MAE 및 RMSE를 기준으로 평균

13.98%, 9.39% 만큼 개선된 추천 성능을 보여 우수함을 나타냈다. 이러한 결과는 DRM-IRA 모델의 주요 언어학적 요소를 활용하는 방법론은 정교한 고객 선호도 학습을 가능하게 함을 시사한다.

또한, <Table 4>와 <Table 5>에서 확인할 수 있듯 상호작용을 선형으로 학습하는 전통적인 추천 원리를 기반으로 하는 ItemKNN 및 GMF 모델과 제안 모델 간 비교를 수행했을 때 MAE 기준 각각 17%와 38%, RMSE 기준 각각 19% 수준으로 성능이 개선됨을 보였다. 이러한 성능 향상은 제안 모델이 언어학적 요소와 고객과 상품 간 상호작용을 비선형 방식으로 학습한 데서 기인한 것을 알 수 있다. 동시에, DRM-IRA 모델은 딥러닝 기반 비선형 학습을 진행하는 MLP 및 NeuMF보다 우수한 성능 수준을 나타낸다. 특히 추천 시스템의 대표적인 벤치마크 모델인 NeuMF와 비교했을 때 MAE 기준 10%, RMSE 기준 6% 만큼의 성능 개선을 보였다. 해당 결과는 고객의 선호도 정보를 추출할 때 온라인 리뷰 내 주요 언어학적 요소의 활용이 상호작용을 계산하는

데 매우 효과적이었음을 알 수 있다. 즉, 리뷰 내 언어학적 요소를 활용하는 제안 방법론은 고객과 상품 간 상호작용을 정교하게 학습할 수 있게 만들어 고객의 선호도를 효과적으로 예측할 수 있는 것이다. 또한, 리뷰 콘텐츠 요인을 상황 정보로 고려한 RCAM 모델과 LSM 요인을 상황 정보로 고려한 LSMAM 모델과의 비교 결과 제안 모델의 성능은 MAE 기준 각각 2%와 8%만큼 개선되었고 RMSE 기준 1%와 5%만큼 개선됨을 보였다. 이를 통해 온라인 리뷰의 여러 언어학적 요소는 동시에 반영되었을 때 추천 성능을 가장 효과적으로 향상시킬 수 있음을 확인할 수 있다.

<Table 4> Performance Comparison with Benchmark Models Based on Percentage Change of MAE

Model		MAE	Percentage Change
Proposed	DRM-IRA	0.689	-
Benchmark	RCAM	0.705	+2%
	LSMAM	0.743	+8%
	NeuMF	0.754	+10%
	MLP	0.754	+10%
	GMF	0.950	+38%
	ItemKNN	0.805	+17%

<Table 5> Performance Comparison with Benchmark Models Based on Percentage Change of RMSE

Model		RMSE	Percentage Change
Proposed	DRM-IRA	1.000	-
Benchmark	RCAM	1.009	+1%
	LSMAM	1.051	+5%
	NeuMF	1.062	+6%
	MLP	1.062	+6%
	GMF	1.190	+19%
	ItemKNN	1.192	+19%

### 4.3.2. 파라미터에 따른 제안 모델 성능 비교

제안 모델은 딥러닝 모델을 기반으로 하기 때문에 고객과 상품을 표현하는 잠재 요인의 크기를 할당하기 위해 임베딩 크기를 지정해야 한다. 임베딩 크기가 성능에 미치는 영향을 확인하기 위해 고객과 상품의 임베딩 크기를 다양하게 변경하여 제안 모델의 성능에 미치는 영향을 확인하였다. <Table 6>은 서로 다른 임베딩 크기에서 제안 모델의 MAE와 RMSE 수준을 나타낸다. 두 평가지표에서 임베딩 크기는 각각 16과 32일 때 가장 우수한 성능을 나타내고 있음을 알 수 있다. 이와 같은 결과로 임베딩 크기가 작으면 고객과 상품 벡터의 잠재 요인을 완전하게 표현하지 못하는 반면 지나치게 클 경우 과적합을 유발할 수 있음을 확인할 수 있다(Liu et al., 2021).

<Table 6> The impact of Embedding Size on Recommendation Performance

Embedding Size	MAE	RMSE
8	0.712 ± 0.010	1.015 ± 0.008
16	0.709 ± 0.016	<b>0.949 ± 0.141</b>
32	<b>0.689 ± 0.005</b>	1.000 ± 0.004
64	0.694 ± 0.018	1.003 ± 0.006
128	0.710 ± 0.027	1.002 ± 0.007

본 연구에서는 배치 크기가 모델 성능에 미치는 영향을 확인하기 위한 실험을 진행했다. 배치 크기는 128, 256, 512, 1024로 설정하고 각각이 제안 모델에 미치는 영향을 확인했다. <Table 7>은 각 배치 크기에서의 MAE와 RMSE 결과를 보여준다. 성능의 차이는 크지 않으나 두 평가지표에서 상이한 결과가 도출되었는데 MAE를 기준으로 배치 크기가 1024일 때, RMSE를 기준으로

배치 크기가 128일 때 우수함을 보여주고 있다. 선행 연구는 배치 크기가 지나치게 크고 작은 경우 노이즈의 영향으로 인해 상호작용을 효과적으로 포착하지 못해 모델 성능의 제약이 된다고 주장했다(Janke et al., 2019). 하지만 본 연구의 제안 모델에서는 128부터 1024사이의 배치 크기가 모델의 성능 수준에 큰 차이를 가져올 만큼 유효하지는 않았음을 알 수 있다.

〈Table 7〉 The impact of Batch Size on Recommendation Performance

Batch Size	MAE	RMSE
128	0.712 ± 0.011	<b>0.996 ± 0.003</b>
256	0.708 ± 0.026	0.998 ± 0.007
512	0.714 ± 0.029	1.004 ± 0.008
1024	<b>0.689 ± 0.005</b>	1.000 ± 0.004

딥러닝 학습 과정에서 발생할 수 있는 과적합 문제를 해결하기 위해 사용되는 드롭아웃은 제안 모델의 각 레이어에 0.2부터 0.8사이의 비율로 추가하여 영향 정도를 파악했다. 〈Table 8〉은 드롭아웃 비율에 따른 MAE와 RMSE 결과를 보여준다. 실험 결과는 선행 연구에서 밝혀진 바와 마찬가지로 드롭아웃 비율이 0.2 일 때 가장 높은 성능 수준을 기록하여 적절한 수준임을 보였고, 비율이 점차 올라갈수록 성능 수준을 떨어뜨리는 요인으로 작용함을 알 수 있다(Srivastava, 2013). 하지만 해당 실험의 모든 경우에서 드롭아웃을 쓰지 않은 모델보다 성능 수준이 떨어지는 것을 통해 제안 모델에서는 드롭아웃을 통한 정보의 손실이 과적합 방지로 인한 이득보다 더 크게 작용함을 확인할 수 있다.

〈Table 8〉 Impact of Dropout Rate on Recommendation Performance

Dropout Rate	MAE	RMSE
0.2	<b>0.757 ± 0.026</b>	<b>1.038 ± 0.017</b>
0.4	0.791 ± 0.019	1.069 ± 0.016
0.6	1.129 ± 0.251	1.422 ± 0.327
0.8	1.304 ± 0.492	1.587 ± 0.548

제안된 딥러닝 기반 모델은 학습과 검증의 반복 과정을 통해 파라미터를 튜닝하며 파라미터별 최적화된 값을 찾아간다. 이 과정에서 학습률은 튜닝 수준의 크기로 사용된다. 본 실험에서는 〈Table 9〉과 같이 학습률에 따라 제안된 모델의 성능에 미치는 영향을 확인했다. 실험 결과 학습률은 0.001일 때 두 평가지표에서 공통적으로 우수한 추천 성능을 나타내는 것을 알 수 있다. 이는 학습률이 지나치게 높은 경우 파라미터들이 최적값에 수렴하지 못하고 발산하게 되는 한계점과 학습률이 지나치게 낮은 경우 학습이 끝날 때까지 최적화된 값으로 수렴하지 못하는 문제를 보여주며, 적절한 수준의 학습률을 사용하는 것이 모델 튜닝에 효과적이라는 것을 나타낸다(Zeiler, 2012).

〈Table 9〉 The impact of Learning Rate on Recommendation Performance

Learning Rate	MAE	RMSE
0.0001	0.734 ± 0.017	1.034 ± 0.005
0.0005	0.712 ± 0.009	1.016 ± 0.004
0.001	<b>0.689 ± 0.005</b>	<b>1.000 ± 0.004</b>
0.005	0.718 ± 0.018	1.002 ± 0.011

## 5. 결론 및 시사점

온라인 전자상거래 시장이 발전함에 따라 고객의 구매 의사결정 난이도는 점차 높아지고 있다. 이 문제를 개선하기 위해 선호도와 관련된 많은 정보를 포함한 온라인 리뷰를 활용한 추천 시스템 연구가 활발하게 진행되고 있다. 실제 추천 시스템은 구매 의사결정을 도와 고객과 기업에게 효과적으로 작용하고 있지만, 기존의 온라인 리뷰 내 감성 점수만을 사용하는 방법론은 리뷰 텍스트에 존재하는 다양한 정보를 반영하지 못한다는 한계점이 존재한다. 본 연구는 온라인 리뷰에서 고객의 구매 의사결정에 주요한 입력으로 작용하는 언어학적 요소들을 추출하여 딥러닝 기반 추천 시스템에 적용하는 DRM-IRA 모델을 제안하였다. Amazon.com에서 수집한 온라인 리뷰 데이터를 사용하여 수행한 실험의 결과 다양한 모델과의 성능 비교를 통해 제안 모델의 우수함을 확인할 수 있었다. 본 연구의 시사점은 다음과 같다.

본 연구는 대표적인 정성적 데이터인 온라인 리뷰에서 주요 언어학적 요소들을 추출하여 추천 시스템에 적용하였고 성능 향상을 입증하였다. 본 연구의 학술적 시사점을 살펴보면 다음과 같다. 첫째, 평점 예측을 목표로 하는 추천 시스템의 경우 고객과 상품 간 상호작용을 비선형으로 학습하는 방식이 선형 학습 방식보다 우수할 수 있음을 밝혔다. 벤치마크 모델 중 ItemKNN, GMF 모델은 내부적으로 선형 학습 방식을 사용하여 최종 평점을 예측한다. 두 모델의 성능 수준은 MAE, RMSE 모두에서 비선형 학습 방식을 사용한 다른 모델들에 미치지 못함을 알 수 있었다. 이는 명시적 데이터를 예측 대상으로 사용한 추천 시스템에서 비선형 학습 방식이 상호작용

학습과 예측에 유리할 수 있다는 것을 나타낸다. 둘째, 대표적인 정성적 데이터인 온라인 리뷰를 활용한 방법론을 통해 기존 추천 시스템 연구의 확장에 기여하였다. 특히 추천 성능 검증 단계에서 LSM 요인만을 투입한 모델과 리뷰 콘텐츠 요인만을 투입한 모델과의 성능 비교를 수행하였고, 실험 결과 인지적 요인과 정서적 요인으로 구성된 리뷰 콘텐츠 요인을 사용한 추천 시스템의 성능이 비교적 높음을 확인하였다. 이를 통해 추천 시스템에서는 LSM 요인보다 리뷰 콘텐츠 요인이 상대적으로 중요한 역할을 한다는 것을 알 수 있었다. 그럼에도 두 요인을 함께 사용한 경우 가장 우수한 성능을 나타내는 것은 각각의 언어학적 요소들은 독립적으로 적용하는 것보다 함께 적용했을 때 선호도를 반영하는 효과적인 요인이 되는 것을 시사한다. 셋째, 본 연구는 추천 시스템에서 온라인 리뷰의 다각도적 활용 방안에 대한 방법론을 제시하였다. 기존 추천 시스템 연구에서는 주로 감성 분석을 통해 온라인 리뷰에 담긴 고객의 선호도 정보를 추출하였다. 하지만 온라인 리뷰는 감성 외에도 고객의 선호도 정보를 반영하는 다양한 언어학적 요소들을 담고 있다. 따라서 본 연구에서는 온라인 리뷰에서 고객의 구매 의사결정에 영향을 미치는 것이 입증된 여러 언어학적 요소를 추출하여 추천 시스템에 반영하였고 성능 향상을 가져옴을 검증하였다. 이는 향후 추천 시스템 연구에 있어 온라인 리뷰의 다양한 활용 방안에 대한 가능성을 열어주는 선행적 연구라 할 수 있다.

본 연구의 실무적 시사점은 다음과 같다. 첫째, Amazon.com 뿐만 아니라 고객이 리뷰를 작성할 수 있는 다양한 전자상거래 플랫폼에도 활용 가능한 추천 방법론을 제안했다. 기존 온라인 리뷰를 활용한 추천 시스템은 리뷰에 내재된 다

양한 정보를 활용하는데 한계점이 있고 이는 성능의 제약으로 작용한다. 하지만 본 연구에서 제안한 언어학적 요소를 고려한 방법론은 기존보다 정확한 추천 시스템의 구축을 가능하게 하여 추천 시스템을 통해 발생 가능한 효과를 향상시킬 수 있을 것이다. 둘째, 제안 방법론은 기업들이 각 상품과 관련하여 온라인 리뷰의 정량적 정보인 개수뿐만 아니라 상품별 리뷰의 질적 요소 또한 파악해야 할 필요성을 보여주며 이를 기반으로 상품과 관련하여 기존에는 발견하지 못한 통찰을 획득할 수 있다. 현재까지 전자 상거래 플랫폼과 플랫폼 내 기업은 주로 리뷰의 정량적인 개수 정보에 집중하였다. 그러나 온라인 리뷰에는 고객의 선호도와 관련한 여러가지 요소들이 존재하며 이것이 다른 고객의 구매 의사결정에도 영향을 미치는 중요한 요소임을 알 수 있다. 제안 방법론의 활용은 각 상품별 리뷰의 질적 요소를 파악 가능하게 하여 상품 관리 전략 등 상품과 관련된 다양한 정보들을 활용할 수 있게 한다. 셋째, 제안 방법론을 활용하면 개별 고객들이 상품에 대하여 어떠한 특성을 가진 리뷰들을 생성하는지 확인할 수 있다. 이를 기반으로 플랫폼 관리자와 상품 생산자는 고도화된 마케팅 전략 수립, 고객 관리 및 서비스 편의성 향상 등을 가능하게 하고 결과적으로 매출과 이윤에 긍정적인 영향을 미치는 것을 기대할 수 있다.

본 연구는 다음과 같은 한계점이 존재한다. 첫째, 본 연구에서 제안한 방법론의 검증은 위해 Amazon.com의 Video Game 데이터 셋을 사용했다. 본 연구에서 제안한 방법론의 일반화된 성능 검증을 위해서는 다양한 분야의 데이터를 사용하여 실험을 진행할 필요가 있다. 둘째, 추천 시스템에서 LSM 요인을 활용한 최선의 방법론이 아닐 수 있다. 본 연구에서 LSM 요인을 산출한

방식은 선행연구에 따라 9개 지표에 대한 수치의 평균을 계산하였다. 평균을 계산하는 과정은 각 9개의 요소들이 가진 정보들을 모호하게 만들 수 있어 온라인 리뷰 내 언어 스타일과 관련하여 추출할 수 있는 모든 정보를 활용하는 데 한계점으로 작용할 수 있다. 따라서 향후 연구에서는 LSM 요인을 활용하는 최선의 방안에 대한 탐구가 필요하다. 셋째, 고객의 선호도와 관련한 정성적 정보는 리뷰뿐만 아니라 제품 설명, 제품 이미지 등 다양한 데이터에 존재할 수 있다. 이러한 정보들을 상호작용 모델링에 활용한다면 추천 모델의 성능 수준을 향상시킬 수 있을 것이다. 따라서 제품의 정보, 리뷰에 담긴 이미지 등의 요소를 고려하여 추천 시스템 연구를 확장시킬 필요가 있다.

## 참고문헌(References)

- 김동언, 김민지, 김재경. (2022). 소규모 전자상거래를 위한 추천 시스템의 시간 차이에 따른 추천 효과 측정에 관한 연구. *인터넷전자상거래연구*, 22(6), 185-202.
- 이승우, 강경모, 이병현, 이청용, 김재경. (2022). 사용자의 정성적 선호도와 정량적 선호도를 고려하는 추천 시스템 성능 향상에 관한 연구. *경영과학*, 39(1), 15-27.
- 이청용, 이병현, 이흥철, 김재경. (2021). CNN 기반 리뷰 유용성 점수 예측을 통한 개인화 추천 서비스 성능 향상에 관한 연구. *지능정보연구*, 27(3), 29-56.
- 이흥철, 윤효림, 이청용, 김재경. (2022). Multi-channel CNN 기반 온라인 리뷰 유용성 예측 모델 개발에 관한 연구. *지능정보연구*, 28(2), 171-189.
- 전병국, 안현철. (2015). 사용자 리뷰 마이닝을



- 결합한 협업 필터링 시스템: 스마트폰 앱 추천에의 응용. *지능정보연구*, 21(2), 1-18.
- 현지연, 유상이, 이상용. (2019). 평점과 리뷰 텍스트 감성분석을 결합한 추천시스템 향상 방안 연구. *지능정보연구*, 25(1), 219-239.
- Acilar, A. M., & Arslan, A. (2009). A collaborative filtering method based on artificial immune network. *Expert Systems with Applications*, 36(4), 8324-8332.
- Alashkar, T., Jiang, S., Wang, S., & Fu, Y. (2017). Examples-rules guided deep neural network for makeup recommendation. *Proceedings of the AAAI Conference on Artificial Intelligence*, 31(1).
- Asani, E., Vahdat-Nejad, H., & Sadri, J. (2021). Restaurant recommender system based on sentiment analysis. *Machine Learning with Applications*, 6, 100114.
- Bennett, J., & Lanning, S. (2007). The netflix prize. *Proceedings Of KDD Cup and Workshop*, 35.
- Bhojne, N., Deore, S., Jagtap, R., Jain, G., & Kalal, C. (2017). Collaborative approach based restaurant recommender system using naive bayes. *International Journal of Advanced Research in Computer and Communication Engineering*, 6(4), 6-13.
- Billsus, D., & Pazzani, M. J. (1998). Learning collaborative information filters. *Proceedings of the Fifteenth International Conference on Machine Learning*, 46-54.
- Cao, R., Zhang, X., & Wang, H. (2019). A review semantics based model for rating prediction. *IEEE Access*, 8, 4714-4723.
- Chen, C., Zhao, P., Li, L., Zhou, J., Li, X., & Qiu, M. (2017). Locally connected deep learning framework for industrial-scale recommender systems. *Proceedings of the 26th International Conference on World Wide Web Companion*, 769-770.
- Cheng, Z., Ding, Y., Zhu, L., & Kankanhalli, M. (2018). Aspect-aware latent factor model: rating prediction with ratings and reviews. *Proceedings of the 2018 World Wide Web Conference*, 23-27.
- Chung, C., & Pennebaker, J. W. (2007). The psychological functions of function words. *Social Communication*, 1, 343-359.
- Das, A. S., Datar, M., Garg, A., & Rajaram, S. (2007). Google news personalization: scalable online collaborative filtering. *Proceedings of the 16th International Conference on World Wide Web*, 271-280.
- García-Cumbreras, M. Á., Montejo-Ráez, A., & Díaz-Galiano, M. C. (2013). Pessimists and optimists: Improving collaborative filtering through sentiment analysis. *Expert Systems with Applications*, 40(17), 6758-6765.
- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, 35(12), 61-70.
- Gonzales, A. L., Hancock, J. T., & Pennebaker, J. W. (2010). Language style matching as a predictor of social dynamics in small groups. *Communication Research*, 37(1), 3-19.
- Gottschalk, L. A. (2020). *Text Analysis for The Social Sciences: The Unobtrusive Measurement of Psychological States and Traits*. New York, United States: Routledge.
- Gundecha, P., & Liu, H. (2012). Mining social media: a brief introduction. *New Directions in Informatics, Optimization, Logistics, and Production*, 1-17.

- 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.
- Hayati, H., Chanaa, A., Idrissi, M. K., & Bennani, S. (2019). Doc2Vec & Naïve bayes: learners' cognitive presence assessment through asynchronous online discussion TQ transcripts. *International Journal of Emerging Technologies in Learning*, 14(8), 70-81.
- He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. (2017). Neural collaborative filtering. *Proceedings of the 26th International Conference on World Wide Web*, 173-182.
- Hickman, L., Thapa, S., Tay, L., Cao, M., & Srinivasan, P. (2022). Text preprocessing for text mining in organizational research: Review and recommendations. *Organizational Research Methods*, 25(1), 114-146.
- Huang, Y.-F., & Chen, P.-H. (2020). Fake news detection using an ensemble learning model based on self-adaptive harmony search algorithms. *Expert Systems with Applications*, 159, 113584.
- Huang, Y., Liu, H., Li, W., Wang, Z., Hu, X., & Wang, W. (2020). Lifestyles in Amazon: Evidence from online reviews enhanced recommender system. *International Journal of Market Research*, 62(6), 689-706.
- Huang, Z., Chung, W., & Chen, H. (2004). A graph model for E-commerce recommender systems. *Journal of the American Society for Information Science and Technology*, 55(3), 259-274.
- Ireland, M. E., & Pennebaker, J. W. (2010). Language style matching in writing: synchrony in essays, correspondence, and poetry. *Journal of Personality and Social Psychology*, 99(3), 549.
- Janke, J., Castelli, M., & Popovič, A. (2019). Analysis of the proficiency of fully connected neural networks in the process of classifying digital images. Benchmark of different classification algorithms on high-level image features from convolutional layers. *Expert Systems with Applications*, 135, 12-38.
- Jeong, S.-Y., & Kim, Y.-K. (2021). Deep learning-based context-aware recommender system considering contextual features. *Applied Sciences*, 12(1), 45.
- Kang, S., Hwang, J., Kweon, W., & Yu, H. (2020). DE-RRD: A knowledge distillation framework for recommender system. *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*, 605-614.
- Kim, H.-N., Ji, A.-T., Ha, I., & Jo, G.-S. (2010). Collaborative filtering based on collaborative tagging for enhancing the quality of recommendation. *Electronic Commerce Research and Applications*, 9(1), 73-83.
- Kim, K.-j., & Ahn, H. (2008). A recommender system using GA K-means clustering in an online shopping market. *Expert Systems with Applications*, 34(2), 1200-1209.
- Kim, K.-W., & Park, D.-H. (2018). Individual thinking style leads its emotional perception: Development of web-style design evaluation model and recommendation algorithm depending on consumer regulatory focus. *Journal of Intelligence and Information Systems*, 24(4), 171-196.
- Kiran, R., Kumar, P., & Bhasker, B. (2020). DNNRec: A novel deep learning based hybrid recommender system. *Expert Systems with Applications*, 144, 113054.

- Lee, R.-K., Chung, N., & Hong, T. (2019). Developing the online reviews based recommender models for multi-attributes using deep learning. *The Journal of Information Systems*, 28(1), 97-114.
- Leung, C. W., Chan, S. C., & Chung, F.-I. (2006). Integrating collaborative filtering and sentiment analysis: A rating inference approach. *Proceedings of the ECAI 2006 Workshop on Recommender Systems*, 62-66.
- Li, Q., & Kim, J. (2021). A deep learning-based course recommender system for sustainable development in education. *Applied Sciences*, 11(19), 8993.
- Li, X., Wang, M., & Liang, T.-P. (2014). A multi-theoretical kernel-based approach to social network-based recommendation. *Decision Support Systems*, 65, 95-104.
- Li, Y., Lu, L., & Xuefeng, L. (2005). A hybrid collaborative filtering method for multiple-interests and multiple-content recommendation in E-Commerce. *Expert Systems with Applications*, 28(1), 67-77.
- Liu, S., Gao, C., Chen, Y., Jin, D., & Li, Y. (2021). Learnable embedding sizes for recommender systems. *Proceedings of the 9th International Conference on Learning Representations (ICLR 2021)*. <https://openreview.net/group?id=ICLR.cc/2021/Conference>
- Ludwig, S., De Ruyter, K., Friedman, M., Brüggem, E. C., Wetzels, M., & Pfann, G. (2013). More than words: The influence of affective content and linguistic style matches in online reviews on conversion rates. *Journal of Marketing*, 77(1), 87-103.
- Ma, Y., Chen, G., & Wei, Q. (2017). Finding users preferences from large-scale online reviews for personalized recommendation. *Electronic Commerce Research*, 17(1), 3-29.
- Nguyen, T. T., Hui, P.-M., Harper, F. M., Terveen, L., & Konstan, J. A. (2014). Exploring the filter bubble: the effect of using recommender systems on content diversity. *Proceedings of the 23rd International Conference on World Wide Web*, 677-686.
- Ni, J., Li, J., & McAuley, J. (2019). Justifying recommendations using distantly-labeled reviews and fine-grained aspects. *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, 188-197.
- Ning, X., & Karypis, G. (2011). Slim: Sparse linear methods for top-n recommender systems. *Proceedings of the 2011 IEEE 11th International Conference on Data Mining*, 497-506.
- Park, Y., Park, S., Jung, W., & Lee, S.-g. (2015). Reversed CF: A fast collaborative filtering algorithm using a k-nearest neighbor graph. *Expert Systems with Applications*, 42(8), 4022-4028.
- Preethi, G., Krishna, P. V., Obaidat, M. S., Saritha, V., & Yenduri, S. (2017). Application of deep learning to sentiment analysis for recommender system on cloud. *Proceedings of the 2017 International Conference on Computer*, 93-97.
- Rama, K., Kumar, P., & Bhasker, B. (2021). Deep autoencoders for feature learning with embeddings for recommendations: a novel recommender system solution. *Neural Computing and Applications*, 33(21), 14167-14177.
- Rendle, S. (2012a). Factorization machines with libfm. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 3(3), 1-22.
- Rendle, S. (2012b). Learning recommender systems

- with adaptive regularization. *Proceedings of the Fifth ACM International Conference on Web Search and Data Mining*, 133-142.
- Rendle, S., & Schmidt-Thieme, L. (2008). Online-updating regularized kernel matrix factorization models for large-scale recommender systems. *Proceedings of the 2008 ACM Conference on Recommender Systems*, 251-258.
- Roberts, C. W. (2020). *Text Analysis for the Social Sciences: Methods for Drawing Statistical Inferences from Texts and Transcripts*. New York, United States: Routledge.
- Salsabila, G. D., & Setiawan, E. B. (2021). Semantic Approach for Big Five Personality Prediction on Twitter. *Jurnal RESTI*, 5(4), 680-687.
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th international conference on World Wide Web*, 285-295.
- Schafer, J. B., Konstan, J. A., & Riedl, J. (2001). E-commerce recommendation applications. *Data Mining and Knowledge Discovery*, 5(1), 115-153.
- Silveira, T., Zhang, M., Lin, X., Liu, Y., & Ma, S. (2019). How good your recommender system is? A survey on evaluations in recommendation. *International Journal of Machine Learning and Cybernetics*, 10(5), 813-831.
- Srivastava, N. (2013). Improving neural networks with dropout. University of Toronto.
- Su, X., & Khoshgoftaar, T. M. (2009). A survey of collaborative filtering techniques. *Advances in Artificial Intelligence*, 4, 2.
- Tausczik, Y. R., & Pennebaker, J. W. (2010). The psychological meaning of words: LIWC and computerized text analysis methods. *Journal of Language and Social Psychology*, 29(1), 24-54.
- Topaloglu, O., & Dass, M. (2021). The impact of online review content and linguistic style matching on new product sales: The moderating role of review helpfulness. *Decision Sciences*, 52(3), 749-775.
- Unger, M., Tuzhilin, A., & Livne, A. (2020). Context-aware recommendations based on deep learning frameworks. *ACM Transactions on Management Information Systems (TMIS)*, 11(2), 1-15.
- Wang, H., Amagata, D., Maekawa, T., Hara, T., Niu, H., Yonekawa, K., & Kurokawa, M. (2019). Preliminary investigation of alleviating user cold-start problem in e-commerce with deep cross-domain recommender system. *Proceedings of the 2019 World Wide Web Conference*, 398-403
- Wang, X., Lin, X., & Spencer, M. K. (2019). Exploring the effects of extrinsic motivation on consumer behaviors in social commerce: Revealing consumers' perceptions of social commerce benefits. *International Journal of Information Management*, 45, 163-175.
- Wang, X., Tang, L. R., & Kim, E. (2019). More than words: Do emotional content and linguistic style matching matter on restaurant review helpfulness? *International Journal of Hospitality Management*, 77, 438-447.
- Wang, Y., Wang, M., & Xu, W. (2018). A sentiment-enhanced hybrid recommender system for movie recommendation: a big data analytics framework. *Wireless Communications and Mobile Computing*. <https://doi.org/10.1155/2018/8263704>
- Yang, J., Yi, X., Zhiyuan Cheng, D., Hong, L., Li,

- Y., Xiaoming Wang, S., Xu, T., & Chi, E. H. (2020). Mixed negative sampling for learning two-tower neural networks in recommendations. *Proceedings of the Web Conference 2020*, 441-447.
- Yang, S., Zhou, C., & Chen, Y. (2021). Do topic consistency and linguistic style similarity affect online review helpfulness? An elaboration likelihood model perspective. *Information Processing & Management*, 58(3), 102521.
- Zeiler, M. D. (2012). Adadelat: an adaptive learning rate method. *arXiv preprint arXiv:1212.5701*. <https://arxiv.org/abs/1212.5701>
- Zhang, Z., Zhang, D., & Lai, J. (2014). urCF: user review enhanced collaborative filtering, University of Maryland.
- Zheng, L., Noroozi, V., & Yu, P. S. (2017). Joint deep modeling of users and items using reviews for recommendation. *Proceedings of the Tenth ACM International Conference on Web Search and Data Mining*, 425-434.
- Zhou, X., He, J., Huang, G., & Zhang, Y. (2015). SVD-based incremental approaches for recommender systems. *Journal of Computer and System Sciences*, 81(4), 717-733.

Abstract

## A Study on the Enhancing Recommendation Performance Using the Linguistic Factor of Online Review based on Deep Learning Technique

\*

Dongsoo Jang\* · Qinglong Li\* · Jaekyeong Kim\*\*

As the online e-commerce market growing, the need for a recommender system that can provide suitable products or services to customer is emerging. Recently, many studies using the sentiment score of online review have been proposed to improve the limitations of study on recommender systems that utilize only quantitative information. However, this methodology has limitation in extracting specific preference information related to customer within online reviews, making it difficult to improve recommendation performance. To address the limitation of previous studies, this study proposes a novel recommendation methodology that applies deep learning technique and uses various linguistic factors within online reviews to elaborately learn customer preferences. First, the interaction was learned nonlinearly using deep learning technique for the purpose to extract complex interactions between customer and product. And to effectively utilize online review, cognitive contents, affective contents, and linguistic style matching that have an important influence on customer's purchasing decisions among linguistic factors were used. To verify the proposed methodology, an experiment was conducted using online review data in Amazon.com, and the experimental results confirmed the superiority of the proposed model. This study contributed to the theoretical and methodological aspects of recommender system study by proposing a methodology that effectively utilizes characteristics of customer's preferences in online reviews.

**Key Words** : Deep Learning, Recommender System, Online Review, Linguistic Factor, Text Mining

Received : October 18, 2022 Revised : December 6, 2022 Accepted : December 7, 2022

Corresponding Author : Jaekyeong Kim

---

\* Department of Big Data Analytics, Kyung Hee University

\*\* Corresponding author: Jaekyeong Kim

School of Management & Department of Big Data Analytics, Kyung Hee University

26, Kyungheedae-ro, Dongdaemun-gu, Seoul, Korea

Tel: +82-2-961-9355, Fax: +82-82-2-961-9355, E-mail: jaek@khu.ac.kr

## 저자 소개



**장동수**

부산대학교 경제학부에서 경제학 학사학위를 취득하고, 현재 경희대학교 대학원 빅데이터응용학과 석사과정에 재학중이다. 주요 관심 분야는 머신러닝 응용, 딥러닝 응용, 자연어 처리, 개인화 추천 시스템 등이며, 2022년 한국지능정보시스템학회에서 주최한 추계 학술대회에서 관련 논문을 발표하였다.



**이청용**

경희대학교 경영학과에서 경영학 학사학위를 취득하고, 동 대학원 빅데이터응용학과에서 공학 석사학위를 취득하였다. 현재 빅데이터응용학과 박사과정에 재학 중이며, 주요 관심 분야로는 개인화 추천 서비스, 자연어 처리, 머신러닝 응용, 빅데이터 응용 등이다. 경영과학, 한국 IT 서비스학회지, 지능정보연구, 지식경영연구, Information Systems Review, Applied Sciences, Data Technologies and Applications, Expert Systems 등 다수의 학술지에 논문을 게재하였다.



**김재경**

서울대학교에서 산업공학학사, 한국과학기술원에서 경영정보시스템 전공으로 석사 및 박사학위를 취득하였으며 현재 경희대학교 경영대학 및 빅데이터응용학과 교수로 재직하고 있다. 미국 미네소타 주립대학교 그리고 텍사스 주립대학교(달라스)에서 교환교수를 역임하였다. 주요 관심 분야로는 개인화 서비스, 추천 시스템, 빅데이터 및 딥러닝 등이다. IEEE Transaction on Services Computing, IEEE Transaction on SMC-A, International Journal of Human Computer Studies, International Journal of Information Management,

Information and Management, Expert Systems with Applications, Applied Artificial Intelligence 등 다수의 학술지에 논문을 게재하였다. 현재 4단계 BK21 사업 연구단장 (빅데이터 분야) 및 AI 비즈니스 연구센터 센터장을 맡고 있다.