

레스토랑 카테고리화 온라인 소비자 리뷰를 이용한 딥러닝 기반 레스토랑 추천 시스템 개발

Developing a Deep Learning-based Restaurant Recommender System Using Restaurant Categories and Online Consumer Review

구 하 은 (Haeun Koo) 경희대학교 빅데이터응용학과 석사과정
이 청 용 (Qinglong Li) 경희대학교 빅데이터응용학과 박사과정
김 재 경 (Jaekyeong Kim) 경희대학교 경영대학 & 빅데이터응용학과 교수, 교신저자

요 약

최근에는 외식 산업의 발달과 레스토랑 수요의 증가로 인해 레스토랑 추천 시스템 연구가 활발하게 제안되고 있다. 기존 레스토랑 추천 시스템 연구는 정량적인 평점 정보 또는 온라인 리뷰의 감성분석을 통해 소비자의 선호도 정보를 추출하였는데 이는 소비자의 의미론적 선호도 정보는 반영하지 못한다는 한계가 존재한다. 또한, 레스토랑이 포함하는 세부적인 속성을 반영한 추천 시스템 연구는 부족한 실정이다. 이를 해결하기 위해 본 연구에서는 소비자의 선호도와 레스토랑 속성 간의 상호작용을 효과적으로 학습할 수 있는 딥러닝 기반 모델을 제안하였다. 먼저, 합성곱 신경망을 온라인 리뷰에 적용하여 소비자의 의미론적 선호도 정보를 추출했고, 레스토랑 정보에 임베딩 기법을 적용하여 레스토랑의 세부적인 속성을 추출했다. 최종적으로 요소별 연산을 통해 소비자 선호도와 레스토랑 속성 간의 상호작용을 학습하여 소비자의 선호도 평점을 예측했다. 본 연구에서 제안한 모델의 추천 성능을 평가하기 위해 Yelp.com의 온라인 리뷰를 사용한 실험 결과, 기존 연구의 다양한 모델과 비교했을 때 본 연구의 제안 모델이 우수한 추천 성능을 보이는 것을 확인하였다. 본 연구는 레스토랑 산업의 빅데이터를 활용한 맞춤형 레스토랑 추천 시스템을 제안함으로써 레스토랑 연구 분야와 온라인 서비스 제공자에게 학술적 및 실무적 측면에서 다양한 시사점을 제공할 수 있을 것으로 기대한다.

키워드 : 레스토랑 추천 시스템, 합성곱 신경망, 온라인 리뷰, 레스토랑 속성

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

I. 서 론

외식 산업이 급속도로 성장함에 따라 오프라인 레스토랑의 유형이 다양해지고 규모가 점차 커지면서 소비자의 외식 수요도 증가하고 있다(김윤진, 2014). 소비자는 레스토랑을 선택할 때 단순히 음식만을 고려하는 것이 아니라 직원 서비스, 주차 시설, 분위기 등 여러 옵션을 고려하여 선택한다(Nemade *et al.*, 2017). 최근에는 정보통신 기술의 발전과 함께 온라인 서비스 플랫폼에서는 소비자의 의사결정을 돕기 위해 다양한 옵션과 서비스에 대한 구체적인 정보를 제공하고 있다. 하지만 제공되는 정보가 증가함에 따라 소비자는 자신의 선호에 적합한 레스토랑을 선택하는데 많은 시간과 비용이 소요되는 정부 과부하 문제에 직면할 수 있다(Choi *et al.*, 2021; Nemade *et al.*, 2017). 선행연구에 따르면 소비자는 일반적으로 자신에게 필요한 여러 옵션을 추가로 탐색하여 구매 의사결정을 내리는 경향이 존재한다(Nemade *et al.*, 2017). 또한, 선행연구에서 소비자는 개인화 추천 서비스의 부족과 높은 정보 탐색 비용 등으로 인해 온라인에서 관광 제품이나 서비스의 구매를 꺼리는 것으로 나타났다(Wolfe *et al.* 2005).

추천 시스템은 소비자의 선호도 정보를 바탕으로 맞춤형 제품이나 서비스를 제공하기 때문에 소비자의 효과적인 의사결정을 지원할 수 있다(Choi *et al.*, 2016; Park *et al.*, 2012). 소비자는 추천 시스템을 통해 제품 및 서비스의 세부 정보와 여러 옵션을 바탕으로 효율적인 구매 의사결정을 내릴 수 있으며 온라인 서비스 제공자는 추천 시스템을 도입하여 기업의 경쟁력을 강화하고 있다(Cho *et al.*, 2002; Lu *et al.*, 2015). 대표적으로, 넷플릭스(Netflix)는 소비자가 시청한 동영상의 60%를 추천 서비스를 통해 제공하고 있으며, 아마존(Amazon)의 전체 매출 중 35%는 추천 서비스에 의해 제공된 제품에서 발생하고 있다(Lee and Hosanagar, 2019). 이러한 상황에서 외식 산업의 지속적인 성장으로 인하여 소비자의 선

호도에 적합한 레스토랑 추천의 필요성이 제기되어 여러 연구가 진행되고 있다. 예를 들어, 구민정 등(2018)은 소비자를 구매 의사결정 체계에 따라 유형화하고 다기준 평점을 기반으로 결합 함수 기반 접근법을 사용하는 협업 필터링(Collaborative Filtering, CF) 기반 레스토랑 추천 시스템을 제안했다. Asani *et al.*(2021)은 소비자 맞춤형 추천을 위해 온라인 리뷰에 감성분석을 적용하여 추출한 소비자의 음식 선호도와 레스토랑의 메뉴를 사용한 CF 기법을 제안했다. 홍민성 등(2022)은 소비자와 레스토랑 간의 선형 및 비선형 상호작용을 학습하는 딥러닝을 적용한 CF 기법 기반 스마트관광 추천 방법론을 제안했다. 기존 레스토랑 추천 시스템 연구는 추천 성능을 효과적으로 향상하였으나 여전히 한계점이 존재한다. 첫째, 기존 레스토랑 추천 시스템 연구는 정량적인 평점 정보 또는 온라인 리뷰 내 키워드의 반복적인 패턴에 기반하여 추천을 제공하기 때문에 소비자의 선호도 정보를 효과적으로 반영할 수 없다. 정량적인 정보만을 사용하면 소비자의 레스토랑 방문 동기 및 평가 후기 등과 같은 구체적인 선호도 정보를 반영하지 못하고 키워드의 반복적인 패턴에 기반한 소비자 선호도 정보의 추출 방식은 온라인 리뷰의 의미론적 맥락을 파악하지 못한다는 한계가 존재한다(조승연 등, 2015). 둘째, 선행연구는 레스토랑의 이름을 통해 레스토랑의 정보를 인식하는 방식을 활용했지만, 실제 소비자는 구매 의사결정 과정에서 레스토랑의 이름이 아닌 음식을 가장 중요한 요소로 고려하기 때문에 레스토랑의 정보를 효과적으로 반영하지 못하는 한계가 존재한다.

이와 같은 연구의 한계점을 개선하기 위해 본 연구에서는 딥러닝 기법을 적용하여 소비자의 선호도와 레스토랑 속성 간의 상호작용을 효과적으로 학습할 수 있는 새로운 레스토랑 추천 방법론인 DRM-CRI(Deep Learning Recommendation Methodology based on Consumer and Restaurant

Interaction) 모델을 제안한다. 먼저, 온라인 리뷰에 존재하는 소비자의 구체적이고 신뢰할 수 있는 선호도 정보를 효과적으로 반영하기 위해 자연어 처리 분야에서 우수한 성능을 나타내는 합성곱 신경망(Convolutional Neural Network, CNN)을 적용하여 온라인 리뷰의 의미론적 표현(Semantic Representation)을 추출하고 이를 소비자 아이디 임베딩 특성과 결합하여 소비자 선호도 벡터를 생성하였다(Yoon, 2014). 다음으로, 레스토랑의 속성을 효과적으로 활용하기 위해 해당 레스토랑의 카테고리 정보를 다차원 임베딩 특성으로 변환하고, 이를 레스토랑 아이디 임베딩 특성과 결합하여 레스토랑 속성 벡터를 생성하였다. 마지막으로 생성된 소비자 선호도 벡터와 레스토랑 속성 벡터에 요소별(Element-wise) 연산을 수행하여 두 벡터 간의 상호작용을 학습하고, 이를 통해 소비자의 특정 레스토랑에 대한 선호도 평점을 정교하게 예측하였다. 본 연구에서 제안하는 DRM-CRI 모델의 추천 성능을 효과적으로 검증하기 위해 세계적인 레스토랑 커뮤니티인 Yelp.com의 데이터를 사용한 실험 결과, 본 연구에서 제안한 DRM-CRI 모델이 기존 정량적인 데이터를 사용하는 방법론 및 리뷰 내의 반복적인 패턴에 기반하여 소비자 선호도를 추출한 방법론에 비해 향상된 성능을 보였다. 본 연구는 레스토랑 산업의 빅데이터를 활용한 맞춤형 레스토랑 추천 시스템을 제안함으로써 레스토랑 연구 분야와 온라인 서비스 제공자에게 학술적 및 실무적 측면에서 다양한 시사점을 제공할 수 있을 것으로 기대한다.

본 연구의 나머지 구성은 다음과 같다. 제II장에서는 레스토랑 추천 시스템과 온라인 리뷰의 의미론적 표현에 관한 관련 연구를 서술한다. 제III장에서는 본 연구에서 제안하는 DRM-CRI 모델에 대해 설명한다. 제IV장에서는 실험 데이터, 평가 지표, 실험 설계 및 결과에 대해 서술한다. 마지막으로 제V장에서는 시사점 및 한계점과 향후 연구 계획에 대해 구체적으로 서술한다.

II. 관련 연구

2.1 레스토랑 추천 시스템

정보통신 기술의 발전으로 소비자 간 생활 정보의 공유 및 재생산이 확대되고 있다. 이는 소비자의 외식 문화를 빠르게 변화시키고 있으며, 이러한 변화에 맞춰 레스토랑의 수가 증가하고 있다(김운진, 2014). 하지만, 레스토랑이 증가함에 따라 소비자는 선호하는 레스토랑의 선택에 어려움을 겪고 있다. 이러한 소비자의 구매 의사결정의 어려움을 해소하기 위해 레스토랑 추천 시스템 관련 연구가 다양하게 제안되고 있다(Shi *et al.*, 2018; Sun *et al.*, 2019; 홍민성 등, 2022). 기존 레스토랑 추천 시스템 연구는 CF 기법을 기반으로 소비자간의 선호도 평점 및 구매내역과 같은 정량적인 정보를 추천 시스템에 반영하는 방법론을 제안했다. 예를 들어, Li *et al.*(2017)은 3 유사도 계산 방법을 적용한 소비자 기반 CF 기법을 제안하였다. 소비자의 선호도 평점 및 속성 등을 기반으로 유사도를 계산하여 실험한 결과, 기존의 전통적인 소비자 기반 CF 기법보다 우수한 성능을 보임을 확인했다. Shi *et al.*(2018)은 개인화된 레스토랑 추천을 위해 소비자의 다중 특성을 기반으로 CF 기반 레스토랑 추천 알고리즘을 제안하였다. 소비자 간 선호도의 유사성, 소비자의 영향 및 팔로우 관계를 고려하여 실험한 결과, 소비자 선호도의 유사도가 소비자 간 영향에 가장 중요한 역할을 한다는 것으로 나타났다. Rajendran and Sundarraj(2021)은 소비자나 제품 간 유사도를 측정할 데이터가 부족할 때 발생하는 CF의 cold-start 문제를 해결하기 위해 개선된 CF 방식을 제안했다. 해당 연구는 위키피디아 문서에 토픽 모델링을 적용하여 주제를 도출하고 이를 소비자의 검색 기록과 결합한 CF 방식을 제안하여 소비자 간의 유사성 도출에 있어서 높은 성능을 보였다. 위와 같이 기존의 정량적인 정보를 이용한 CF 기법은 기존의 연구들보다 향상된 추천 성능을 보였지만 여전히 소비자의 구체적인 선호

도 정보를 반영하지 못한다는 한계점이 존재한다.

이를 개선하기 위하여 소비자의 구매 의사결정에 영향을 미치는 온라인 리뷰를 활용한 다양한 연구들이 제안되고 있다. 구체적으로, 이 룬경 등(2019)은 평점에서 확인할 수 없는 레스토랑의 속성별 소비자 선호도를 추출하기 위해 온라인 리뷰에 토픽 모델링을 적용하여 다속성별 레스토랑 추천을 수행하였다. 해당 연구는 소비자의 선호도를 세분화한 추천 시스템을 제안하여 소비자의 선호도 평점만을 사용하여 레스토랑을 추천하는 시스템보다 추천 성능을 향상했다. Sun *et al.*(2019)은 감성의 극성과 감성 강도를 결합하여 유사한 소비자의 선호를 감지하는 거리 기반 접근 방식을 이용한 레스토랑 추천 기법을 제안했다. 해당 연구의 실험 결과, 온라인 리뷰가 소비자 선호도에 관한 다양한 정보를 갖고 있다는 것을 확인했다. 홍민성 등(2022)은 OTA(Online Travel Agency) 플랫폼 소비자에게 맞춤형 추천을 제공하기 위해 소비자 피드백의 순차성을 고려하여 소비자와 아이템 간 선형 및 비선형 상호작용을 학습하는 추천 시스템을 제안했다. 실험 결과에 따르면 해당 연구에서 제안한 추천 시스템이 OTA 레스토랑 데이터에서 기존 행렬 인수분해 기반의 CF 기법을 사용한 추천 시스템보다 높은 추천 성능을 보이는 것을 확인하였다. 위와 같이 소비자의 온라인 리뷰를 활용한 추천 시스템은 정량적인 정보를 활용한 CF 기법들보다 개선된 성능을 보였다. 하지만 기존 연구는 레스토랑의 이름을 통해 레스토랑 정보를 인식하기에 레스토랑의 세부적인 속성을 반영하지 못한다는 한계점이 존재한다.

따라서 본 연구에서는 온라인 리뷰를 사용하여 레스토랑 방문 이유와 같은 소비자의 구체적인 선호도 정보를 추출하고 레스토랑의 카테고리를 통해 표현되는 음식 정보 등의 효과적인 반영을 통해 기존의 추천 시스템의 한계를 극복하여 추천 성능을 향상하고자 한다.

2.2 온라인 리뷰의 의미론적 표현

기존의 정량적인 데이터를 사용하는 추천 시스템의 한계를 개선하기 위해 온라인 리뷰를 사용하여 소비자의 선호도를 추출하는 연구가 활발히 진행되고 있다(Hegde *et al.*, 2018). 기존 연구에서는 소비자의 선호도를 추출하기 위해 자연어 처리 분야에서 널리 사용되는 감성분석 및 TF-IDF(Term Frequency-Inverse Document Frequency) 기법 등을 온라인 리뷰에 적용하였다. 예를 들어, 온라인 리뷰에서 제품에 대한 긍정 또는 부정의 감성을 나타내는 단어의 빈도수를 사용하거나 온라인 리뷰 내 단어의 빈도수와 평점 정보를 TF-IDF 기법에 적용하여 소비자의 선호도를 추출하였다(Gamon *et al.*, 2005; Scaffidi *et al.*, 2007). 하지만 이러한 방식은 온라인 리뷰 내 키워드의 반복적인 패턴만을 기반으로 하므로 소비자의 의미론적 선호도 정보를 추출하지 못한다는 문제점을 지니고 있다. 이를 해결하기 위해 최근 자연어 처리 분야에서는 CNN을 적용하여 온라인 리뷰의 의미론적 표현을 추출하고 있다(Majumder *et al.*, 2017; Yoon, 2014). CNN은 이미지 처리를 위해 고안된 딥러닝 구조로, 다차원 데이터의 기능을 유지하면서 네트워크의 차원을 효과적으로 감소시키기에 이미지 처리, 영상분류와 같은 컴퓨터 비전 분야에서 좋은 성능을 보이고 있다(Amari, 2003). 이미지의 지역적인 정보를 추출하는 CNN을 자연어 처리에서 사용하면 단어의 등장 순서, 문맥 정보와 같은 텍스트의 지역적인 정보 보존이 가능하다는 특징이 존재한다(Raj *et al.*, 2017; She and Zhang, 2018).

이러한 CNN의 특징은 온라인 리뷰 텍스트에서 소비자의 의미론적 맥락을 효과적으로 추출하기 위해 활용되고 있다. 구체적으로, Yoon(2014)은 CNN과 사전 훈련된 단어 벡터를 결합하여 문장 수준의 텍스트를 분류하는 방법을 제안하였다. 영화의 평점과 리뷰에 감성분석을 수행한 결과를 이용해 실험을 진행한 결과, 해당 연구에서 제안한 방법론이 기존의 기계학습 방식을 사용한 모델보

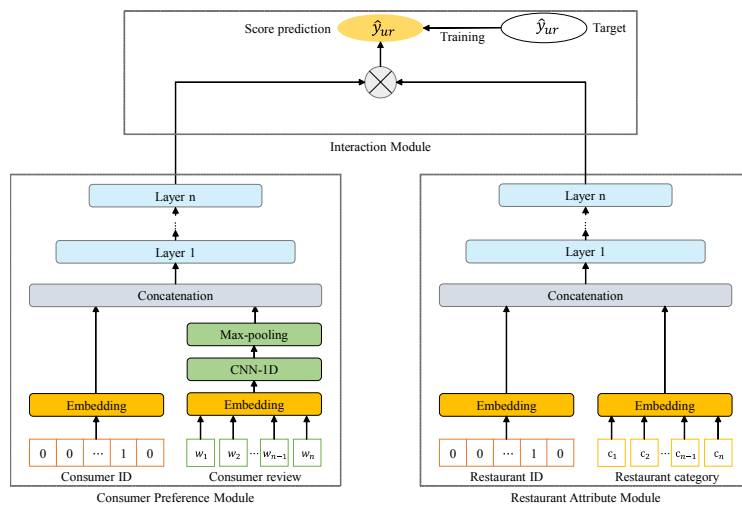
다 우수한 문장 분류 성능을 나타냈다. Majumder *et al.*(2017)은 CNN을 이용하여 텍스트 내 소비자의 개인적인 특징을 추출하여 소비자의 성격 유형을 결정하는 연구를 제안했다. 해당 연구는 텍스트에서 감성이 중립으로 분류되는 문장을 제거하여 성격 특성 분류에 관해 기존 연구보다 높은 성능을 보였다. 박호연 등(2019)은 기존 기계학습 기반 감성분석의 분류 정확도를 향상하기 위해 CNN-LSTM 모델을 제안하여 영화 리뷰 데이터를 분석하였다. 해당 연구의 실험 결과에 따르면 CNN이 텍스트 내 지역적 특징의 자동 추출을 가능하게 하여 감성분석에서 기계학습 방식보다 높은 분류 정확도를 보였다. 이흥철 등(2022)은 리뷰 텍스트와 평점 간의 상호작용을 효과적으로 학습하여 온라인 리뷰의 유용성을 예측하는 모델을 제안하였다. 해당 연구는 CNN을 활용하여 리뷰 텍스트에 포함된 연속적인 단어 특성의 학습을 통해 온라인 리뷰 내의 의미론적 특성을 추출하였다. 실험 결과에 따르면 해당 연구에서 제안한 모델이 기존 연구에 비해 온라인 리뷰 유용성 예측에 높은 성능을 보인다는 것을 확인하였다.

기존의 자연어 처리에서 사용하는 감성분석이나 TF-IDF 기법은 온라인 리뷰 내 키워드의 빈도

및 반복 패턴을 이용하기 때문에 소비자의 선호도 정보를 제대로 추출하지 못한다는 문제점을 지니고 있다. 이러한 문제를 해결하기 위해 여러 연구에서 텍스트 데이터의 단어 등장 순서를 학습하고 지역적인 특징의 추출이 가능한 CNN을 활용하여 텍스트 내의 의미론적 표현을 효과적으로 추출하였다(Majumder *et al.*, 2017; 박호연 등, 2019; 이흥철 등, 2022). 따라서 본 연구에서는 CNN을 통해 온라인 리뷰에서 의미론적 표현을 추출하여 소비자 선호도 평점의 정교한 예측을 통해 추천 시스템의 성능을 향상하고자 한다.

III. DRM-CRI 모델

본 연구에서는 기존 레스토랑 추천 시스템에서 소비자의 구체적인 선호도 정보 및 레스토랑의 속성을 효과적으로 반영하지 못하는 한계를 개선할 수 있는 DRM-CRI 모델을 제안한다. DRM-CRI 모델은 딥러닝 기법을 활용하여 소비자의 선호도와 레스토랑 속성 간 상호작용의 효과적인 학습을 통한 소비자 선호도 평점의 정교한 예측에 사용되며 <그림 1>과 같이 3개의 모듈로 이루어진다. 첫째, 소비자 선호도 모듈(Consumer Preference Module)



<그림 1> DRM-CRI 프레임워크

에서는 온라인 리뷰에 CNN을 적용하여 리뷰 텍스트의 의미론적 표현 특성을 추출하고, 이를 소비자 아이디 임베딩 특성과 결합하여 소비자 선호도 벡터를 생성한다. 둘째, 레스토랑 속성 모듈(Restaurant Attribute Module)에서는 레스토랑 카테고리 정보를 다차원 임베딩 특성으로 변환하여 레스토랑 속성을 추출하고, 이를 레스토랑 아이디 임베딩 특성과 결합하여 레스토랑 속성 벡터를 생성한다. 셋째, 상호작용 모듈(Interaction Module)에서는 소비자 선호도 벡터와 레스토랑 속성 벡터 간 상호작용의 학습을 위한 요소별 연산을 수행하여 소비자의 특정 레스토랑에 대한 최종 선호도 평점을 예측한다. 각 모듈의 구체적인 내용은 아래와 같다.

3.1 소비자 선호도 모듈

소비자 선호도 모듈은 온라인 리뷰에 CNN을 적용해 리뷰 텍스트 내 의미론적 표현의 특성을 추출하고, 이를 소비자 아이디 임베딩 특성과 결합하여 소비자 선호도 벡터를 생성한다. 먼저, 소비자 아이디 임베딩 특성을 추출하기 위해 희소 벡터(Sparse Vector)로 표현된 소비자 아이디에 임베딩 기법을 적용하여 밀집 벡터(Dense Vector)로 변환한다. 이는 소비자 잠재 요인(Latent Factor) 벡터가 되며 식 (1)과 같이 표현된다(He *et al.*, 2017).

$$p_u = P^T v_u^U \quad (1)$$

위의 식에서 v_u^U 및 P^T 는 각각 소비자 희소 벡터 및 임베딩 과정에서 적용되는 가중치 행렬을 의미하며 p_u 는 소비자 잠재 요인 벡터를 의미한다. 다음으로, 온라인 리뷰의 의미론적 표현을 효과적으로 추출하기 위해 자연어 처리 분야에서 우수한 성능을 보이는 CNN을 적용하였다. 기존 텍스트 마이닝 연구에서는 원-핫 인코딩(One-Hot Encoding) 기법을 사용하여 각 단어를 벡터로 변환하였지만, 이는 행렬의 차원이 지나치게 커지고 벡터의

대부분이 0으로 채워지는 데이터 희소성 문제가 발생한다(He and Chua, 2017). 본 연구에서는 이와 같은 문제점을 개선하기 위해 온라인 리뷰에 임베딩 기법을 적용하였다. 온라인 리뷰는 $w \in R^{V \times D}$ 로 표현되며, V 는 온라인 리뷰에 포함된 단어의 개수를 의미하고 D 는 임베딩 벡터 차원을 의미한다. 이에 필터를 적용하여 온라인 리뷰의 슬라이딩 윈도우(Sliding Window)에서 식 (2)와 같이 컨볼루션 연산을 수행한다.

$$c_i = f(w * x_{i+j-1} + b_c) \quad (2)$$

식 (2)에서 $*$ 는 컨볼루션 연산자를 의미하며 x_{i+j-1} 와 b_c 는 각각 필터 커널과 편향을 의미한다. f 는 ReLU(Rectified Linear Unit) 활성화 함수를 의미하며 식 (3)과 같이 정의할 수 있다.

$$f(x) = \max(0, x) \quad (3)$$

ReLU 활성화 함수는 Sigmoid와 Tanh 활성화 함수에 비해 기울기 소실(Gradient Vanishing) 문제와 계산 복잡도에서 높은 성능을 보이기에 널리 사용되고 있다(Liu *et al.*, 2022). 또한, 필터는 각 온라인 리뷰에 포함된 모든 단어의 슬라이딩 윈도우에 적용되어 식 (4)와 같이 특성 맵(Feature Map)을 생성한다.

$$c = [c_1, c_2, \dots, c_{N-j+1}] \quad (4)$$

컨볼루션 연산을 통해 추출한 특성 맵에서 중요한 특징만 유지하기 위해 맥스 풀링(Max Pooling)을 사용하여 최댓값을 추출한다. 필터마다 하나의 특성 맵이 추출되므로 m 개의 필터를 이용할 때는 m 개의 최댓값을 계산할 수 있다. 따라서 온라인 리뷰에 포함된 특성은 식 (5)와 같이 특정 길이의 벡터로 정의할 수 있다.

$$O = [o_1, o_2, \dots, o_m] \quad (5)$$

본 연구는 소비자 선호도 벡터를 생성하기 위해 식 (6)과 같이 소비자 잠재 요인 벡터와 온라인 리뷰의 특성 벡터를 결합(Concatenation)하고 이를 통해 소비자 선호도 벡터를 추출하기 위하여 식 (7)과 같이 은닉 레이어를 추가한다.

$$Z_u = \phi(p_u, O) = \begin{bmatrix} P_u \\ O \end{bmatrix} \quad (6)$$

$$\phi_1(Z_u) = f(w_{Z_u}^T Z_u + b_1) \quad (7)$$

.....

$$U = \phi_{Z_{u_L}}(Z_{u_{L-1}}) = f(W_{Z_{u_L}}^T Z_{u_{L-1}} + b_L)$$

식 (7)의 $\phi_{Z_{u_L}}$ 는 소비자 선호도 벡터 추출 과정에서 L 번째 레이어에 대한 매핑 함수를 의미한다. $W_{Z_{u_L}}^T$, b_L 와 f 는 각각 L 번째 레이어에 대한 가중치, 편향, 활성화 함수를 의미한다. 최종적으로 소비자 선호도 벡터는 U 로 표현할 수 있다.

3.2 레스토랑 속성 모듈

레스토랑 속성 모듈은 레스토랑의 카테고리 정보를 다차원 임베딩 특성으로 변환하여 레스토랑의 속성을 추출하고, 이를 레스토랑 아이디 임베딩 특성과 결합하여 레스토랑 속성 벡터를 생성한다. 레스토랑 아이디 임베딩 특성을 추출하기 위해 희소 벡터로 표현된 레스토랑 아이디에 임베딩 기법을 적용하여 밀집 벡터로 변환한다. 이는 레스토랑 잠재 요인 벡터가 되며 식 (8)과 같이 표현된다.

$$q_r = Q^T v_r^R \quad (8)$$

위의 식에서 v_r^R 및 Q^T 는 각각 레스토랑 아이디 희소 벡터 및 임베딩 과정에서 적용되는 가중치 행렬을 의미하며 q_r 는 레스토랑 잠재 요인 벡터를 의미한다. 다음으로 레스토랑 카테고리 정보에 담겨있는 특성을 고차원의 임베딩 특성 벡터로 변환

하여 추출한다. 각 레스토랑의 카테고리 정보는 $e_{rc} \in E_{rc} = \{a_1, a_2, \dots, a_k\}$ 로 표현한다. 레스토랑의 카테고리 정보를 모두 같은 차원의 벡터로 표현하기 위해 임베딩 레이어에서는 레스토랑의 카테고리 벡터 m 차원의 벡터로 매핑하여 레스토랑 카테고리 벡터 E_{rc}^m 으로 변환한다. 레스토랑 속성 벡터를 생성하기 위해 식 (9)와 같이 레스토랑 잠재 요인 벡터와 레스토랑 카테고리 벡터를 결합하고 레스토랑 속성 벡터를 추출하기 위해 식 (10)과 같이 은닉 레이어를 추가한다.

$$Z_r = \phi(q_r, E_{rc}^m) = \begin{bmatrix} q_r \\ E_{rc}^m \end{bmatrix} \quad (9)$$

$$\phi_1(Z_r) = f(W_{Z_r}^T Z_r + b_1) \quad (10)$$

.....

$$R = \phi_{Z_{r_L}}(Z_{r_{L-1}}) = f(W_{Z_{r_L}}^T Z_{r_{L-1}} + b_L)$$

식 (10)에서 $\phi_{Z_{r_L}}$ 는 레스토랑 속성 벡터 추출 과정에서 L 번째 레이어에 대한 매핑 함수를 의미한다. $W_{Z_{r_L}}^T$, b_L 와 f 는 각각 L 번째 레이어에 대한 가중치, 편향, 활성화 함수를 의미한다. 따라서 최종적으로 레스토랑 속성 벡터는 R 로 표현할 수 있다.

3.3 상호작용 모듈

상호작용 모듈에서는 소비자 선호도 모듈에서 추출한 소비자 선호도 벡터와 레스토랑 속성 모듈에서 추출한 레스토랑 속성 벡터 간의 상호작용을 학습하여 최종적으로 소비자의 선호도 평점을 예측한다. 먼저, 소비자 선호도 벡터와 레스토랑 속성 벡터 간의 상호작용을 효과적으로 학습하기 위하여 요소별 연산을 수행한다. 요소별 연산은 모델 학습에 사용되는 파라미터 수를 최소화하고 학습 시간을 효과적으로 단축하기 때문에 특성 벡터 간의 상호작용을 정교하게 학습할 때 사용한다 (He et al., 2017). 소비자 선호도 벡터와 레스토랑

속성 벡터 간의 상호작용은 식 (11)과 같이 정의할 수 있다.

$$H = U \odot R \quad (11)$$

여기서 H 와 \odot 는 각각 상호작용 특성 벡터와 요소별 연산자를 의미하며 U 와 R 은 각각 식 (7)에서 추출한 소비자 선호도 벡터와 식 (10)에서 추출한 레스토랑 속성 벡터를 의미한다. 최종적으로 상호작용 특성 벡터 H 를 통해 식(12)과 같이 소비자 선호도 평점을 예측한다.

$$\hat{y}_{ur} = \sigma(W_H \cdot H + b_H) \quad (12)$$

위 식에서 W_H 와 b_H 는 소비자 선호도 평점을 예측하는 과정에서 특성 벡터에 사용되는 가중치와 편향을 의미한다. σ 는 식 (13)으로 표현되는 Sigmoid 활성화 함수를 의미하며, 소비자 선호도 평점을 0과 1 사이로 예측하기 위해 사용된다 (Kiran *et al.*, 2020).

$$\sigma(\theta) = \frac{1}{1 + e^{-\theta}} \quad (13)$$

즉, \hat{y}_{ur} 는 소비자 선호도 평점을 0과 1 사이의 값으로 예측한다. 예측한 소비자의 평점을 $4((\hat{y}_{ur} - \min(\hat{y}_{ur})) + (\max(\hat{y}_{ur}) - \min(\hat{y}_{ur}))) + 1$ 을 통해 기존 평점의 범위인 1과 5 사이의 값으로 변환한 후 추천 성능을 평가한다(Kiran *et al.*, 2020).

IV. 실험

4.1 실험 데이터 및 평가지표

본 연구에서 제안한 모델의 추천 성능을 평가하기 위해 Yelp.com에서 제공하는 온라인 리뷰 데이터 세트를 사용하였다(Iwendi *et al.*, 2022; Wu *et al.*, 2016). Yelp.com은 세계적인 레스토랑 커뮤니

티로 비즈니스, 온라인 리뷰, 소비자 데이터 세트 등을 제공하고 있어 이를 이용한 연구가 다양하게 진행되고 있다(Margaris *et al.*, 2020; Singh *et al.*, 2019; Zhao *et al.*, 2014). 본 연구의 실험에서는 Yelp.com에서 제공하는 데이터를 정제하여 <표 1>과 같이 소비자 ID, 레스토랑 ID, 레스토랑 카테고리, 온라인 리뷰 등을 사용하였다. 본 연구에서는 가장 많은 비즈니스 데이터가 존재하는 미국 펜실베이니아의 7,851개의 레스토랑에 5,196명의 소비자가 남긴 240,040개의 평점 및 리뷰를 사용하였다. 본 연구에서 제안한 모델을 효율적으로 학습하기 위해 최소 20개 이상의 평점을 부여한 소비자만을 선택하여 실험에 사용했다(이청용 등, 2021). 또한, 모델 학습 과정에서 편향을 방지하기 위해 전체 데이터에서 80%는 학습 데이터로 사용하고 20%는 평가 데이터로 사용한다(Rendle, 2012).

<표 1> Yelp.com 데이터 세트 예시

속성	값
리뷰 ID	lpohaRlrXJG3pGL9qrynSw
소비자 ID	5CfRj0dIV1EPlarQ8oeh4w
레스토랑 ID	MTSW4McQd7CbVtyjqoe9mw
레스토랑 카테고리	Restaurants, Food, Bubble Tea, Coffee & Tea, Bakeries
평점	5
리뷰 작성일	2019-07-28
리뷰 텍스트	My favorite chinese bakery. I love their buns. And their egg tart is best in whole Chinatown

본 연구에서 제안한 모델의 성능을 평가하기 위해 기존 연구에서 널리 사용되는 MAE(Mean Absolute Error)와 RMSE(Root Mean Squared Error)를 사용하여 모델의 예측 성능을 평가하였다(Silveira *et al.*, 2019). 두 평가지표 모두 실제 평점과 예측 평점의 차이를 측정하여 예측 성능을 평가하며, 값이 작을수록 예측 정확도가 높음을 의미한다(Park *et al.*, 2012; Su and Khoshgoftaar, 2009). MAE는 절댓값을 취한 실제 평점과 예측

평점 간 차이의 합을 데이터 개수로 나눈 값을 의미한다. 즉, MAE는 오차 절댓값의 평균으로, 오차의 크기에 상관없이 모두 같은 가중치를 가지며 식 (14) 을 통해 계산할 수 있다(Goldberg *et al.*, 2001; Herlocker *et al.*, 1999). 아래 식에서 $p_{i,j}$ 는 소비자 i 의 아이템 j 에 대한 예측 평점, $r_{i,j}$ 는 소비자 i 의 아이템 j 에 대한 실제 평점, n 은 데이터 개수를 의미한다.

$$MAE = \frac{\sum |p_{i,j} - r_{i,j}|}{n} \quad (14)$$

RMSE는 실제 평점과 예측 평점 간의 오차를 제곱한 값을 합하여 데이터 개수로 나눈 값의 제곱근을 의미한다. RMSE는 오차가 큰 값에 대하여 높은 가중치를 부여하며 식 (15) 를 통해 계산할 수 있다.

$$RMSE = \sqrt{\frac{1}{n} \sum (P_{i,j} - r_{i,j})^2} \quad (15)$$

<표 2> 벤치마크 모델 설명

모델	내용	선행연구
ItemKNN	특정 아이템과 평점이 유사한 아이템을 이웃 아이템으로 선정하여 이웃 아이템의 평점을 기반으로 특정 아이템에 대한 타겟 소비자의 선호도를 예측한다.	Ning and Karypis (2011), Sarwar <i>et al.</i> (2001)
SVD (Singular Value Decomposition)	대표적인 잠재 요인 모델로 소비자와 아이템 간 잠재 요인 개수를 지정하고 잠재 요인 간의 내적을 통해 상호작용을 모델링하여 소비자의 아이템에 대한 선호도를 예측한다.	Billsus and Pazzani (1998), Zhou <i>et al.</i> (2015)
GMF (Generalized Matrix Factorization)	MF(Matrix Factorization)를 일반화한 모델로, 소비자 원-핫 인코딩 벡터와 아이템 원-핫 인코딩 벡터에 각각 가중치 행렬을 곱하고 두 벡터 간의 요소별 연산을 통해 학습하는 과정을 거친다.	He <i>et al.</i> (2017), Muhammad <i>et al.</i> (2020)
MLP (Multi-Layer Perceptron)	GMF 모델에 다층 신경망을 적용한 알고리즘으로, 소비자 원-핫 인코딩 벡터와 아이템 원-핫 인코딩 벡터에 각각 가중치 행렬을 곱하고 두 벡터를 연결하여 다층 신경망을 통과하면서 학습하는 과정을 거친다.	Alashkar <i>et al.</i> (2017), Chen <i>et al.</i> (2017)
NeuMF (Neural Matrix Factorization)	GMF 모델과 MLP 모델을 결합하여 소비자와 아이템의 잠재 요인 간 선형 및 비선형 관계를 계산하는 모델이다.	Kang <i>et al.</i> (2020), Wang <i>et al.</i> (2019)
CPAM (Consumer Preference-Aware Model)	딥러닝 기반 모델로 소비자-레스토랑 상호작용 벡터에 소비자의 의미론적 선호도를 추가로 학습하여 추천 성능을 예측하는 모델이다.	-

위 식에서 $p_{i,j}$ 는 소비자 i 의 아이템 j 에 대한 예측 평점, $r_{i,j}$ 는 소비자 i 의 아이템 j 에 대한 실제 평점, n 은 데이터 개수를 의미한다.

4.2 실험 설계

본 연구에서 제안한 DRM-CRI 모델의 성능을 효과적으로 평가하기 위해 <표 2>와 같이 기존 연구에서 우수한 추천 성능을 내는 모델들과 비교하였다.

또한, 실험에 사용되는 온라인 리뷰를 효율적으로 분석하기 위해 NLTK 패키지를 사용했다(Dalvi *et al.*, 2020; Ramachandran, Parvathi, 2019). 리뷰 텍스트에 포함된 불용어를 제거하고 표제어를 추출한 다음 길이가 3 이하인 단어를 제거하였고 모든 온라인 리뷰에서 나오는 횟수가 3회 미만인 희귀 단어를 삭제하였다(Denny, Spirling, 2018; Sohrabi, Hemmatian, 2019). 본 연구에서는 제안 모델과 벤치마크 모델의 성능을 비교하기 위해 모델의 파라미터를 <표 3>과 같이 동일하게 설정했다.

구체적으로, DRM-CRI 모델 내의 소비자 리뷰에 대한 CNN 모델 학습 과정에서 단어 임베딩 벡터를 100차원으로 설정하였고, 커널 크기는 3으로, 커널 개수는 256개로 설정하였다(Kaur *et al.*, 2020). 또한, 리뷰 길이를 기존 연구에 따라 최대 리뷰 길이의 90%로 고정하고 단어 수는 33,274개로 설정하였다(Dong *et al.*, 2020; Du *et al.*, 2020). 그리고 레스토랑과 소비자에 대한 특성을 추출하기 위한 모델 학습 과정에서 임베딩 벡터를 32차원으로, 레스토랑 카테고리에 대한 임베딩 벡터는 50차원으로 설정하였다(Wu *et al.*, 2022). 최적화 알고리즘은 Adam(Adaptive Moment Estimation)을 적용하였고, 학습률은 0.01, 배치 크기는 1024로 설정하여 모델 학습을 수행하였으며, 최적의 Epoch 횟수를 설정하기 위해 Early Stopping을 적용하였다(Kiran *et al.*, 2020). 또한, 일관된 추천 성능을 나타내는지 확인하기 위해 각 실험은 5회씩 수행되어 평균과 표준편차를 통해 최종 성능 수준을 제시하였다(Liu *et al.*, 2013). 본 연구에서는 TensorFlow 및 Keras 패키지를 사용하였으며 실험은 CPU Intel Core i9-10900K, 64GB RAM, GeForce RTX 3090 환경에서 진행되었다.

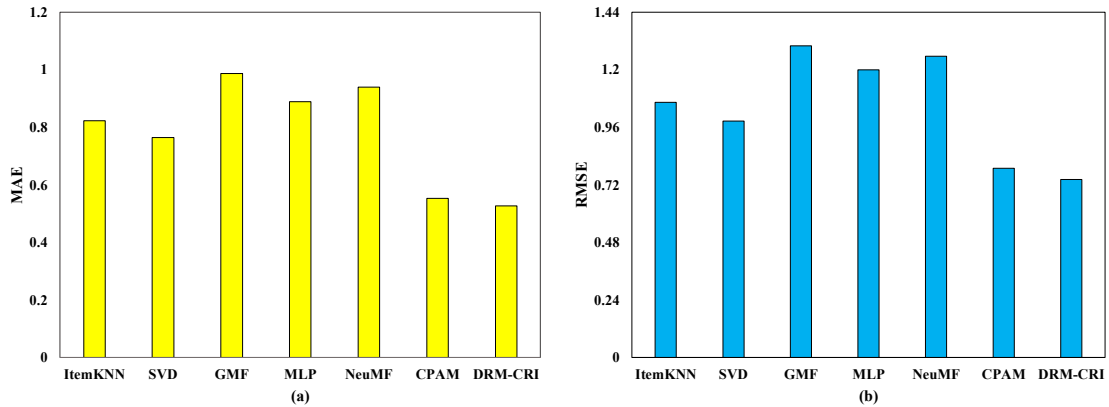
〈표 3〉 DRM-CRI 모델 파라미터

파라미터	설정값
단어 임베딩 벡터 차원	100
레스토랑 카테고리 임베딩 벡터 차원	50
단어 수	33274
CNN 커널 크기	3
CNN 커널 개수	256
CNN 드롭아웃	0.2
소비자 및 레스토랑 아이디 임베딩 벡터 차원	32
학습률	0.01
배치 크기	1024
최적화 알고리즘	Adam
Early Stopping	10

4.3 실험 결과

4.3.1 벤치마크 모델과의 추천 성능 비교

본 연구에서 제안한 DRM-CRI 모델의 성능을 평가하기 위해 글로벌 리뷰 플랫폼인 Yelp.com의 데이터 세트를 사용하여 기존 연구에서 제안된 다양한 벤치마크 모델과 추천 성능을 비교했다. 실험 결과는 <그림 2>와 같이 나타나며, 이를 통해 본 연구에서 제안한 DRM-CRI 모델이 모든 벤치마크 모델에 비해 우수한 추천 성능을 보여주고 있음을 확인했다. 실험 결과, <표 4>와 <표 5>의 MAE 및 RMSE 평가지표에서 평균적으로 각각 30.8% 및 35.2%만큼 우수한 추천 성능을 확인할 수 있었다. 이러한 결과는 제안된 DRM-CRI 모델의 소비자 선호도 및 레스토랑 속성을 활용하는 방법론이 소비자의 레스토랑 선호도 평점을 정교하게 예측할 수 있음을 시사한다. 먼저, 제안 모델의 추천 성능을 ItemKNN, SVD 및 GMF 모델과 비교했을 때 우수한 추천 성능을 나타내는 것을 확인할 수 있다. 구체적으로, DRM-CRI 모델은 ItemKNN, SVD 및 GMF 모델과 비교했을 때 MAE 평가지표에서 각각 35%, 30% 및 46%만큼 개선되었고 RMSE 평가지표에서 각각 29%, 24% 및 42%만큼 성능이 개선되었다. 해당 결과는 소비자와 레스토랑 간의 상호작용을 학습할 때, 전통적인 선형 학습 방법론보다 제안 모델의 학습 방법론이 효과적이라는 것을 나타낸다. 또한, 제안 모델의 추천 성능을 딥러닝 기반의 MLP 및 NeuMF 모델과 비교했을 때, MAE 평가지표는 40% 및 43%만큼 개선되었고, RMSE 평가지표는 37% 및 40%만큼 개선되었다. 이와 같은 결과를 통해, 단순히 소비자와 레스토랑의 아이디만을 가지고 이들 간의 상호작용을 학습하는 모델들보다 DRM-CRI 모델이 소비자 선호도와 레스토랑 속성을 사용하여 소비자와 레스토랑 간의 상호작용을 정교하게 학습하기 때문에 소비자의 레스토랑 선호도 평점을 효과적으로 예측하는 것을 확인할 수 있다.



〈그림 2〉 DRM-CRI 모델과 벤치마크 모델의 MAE (a) 와 RMSE (b) 성능 비교

〈표 4〉 DRM-CRI 모델과 벤치마크 모델의 MAE 평가지표

모델		MAE	Percentage Change
Proposed	DRM-CRI	0.534	-
	CPAM	0.553	+3%
Benchmark	ItemKNN	0.822	+35%
	SVD	0.764	+30%
	GMF	0.985	+46%
	MLP	0.889	+40%
	NeuMF	0.939	+43%

〈표 5〉 DRM-CRI 모델과 벤치마크 모델의 RMSE 평가지표

모델		RMSE	Percentage Change
Proposed	DRM-CRI	0.754	-
	CPAM	0.789	+4%
Benchmark	ItemKNN	1.064	+29%
	SVD	0.986	+24%
	GMF	1.301	+42%
	MLP	1.199	+37%
	NeuMF	1.256	+40%

또한, 레스토랑의 속성이 소비자의 선호도 평점 예측에 미치는 영향을 파악하기 위해 소비자 선호도만을 사용한 CPAM과 비교하였을 때,

DRM-CRI 모델이 MAE 및 RMSE 평가지표에서 3% 및 4%만큼 개선된 성능을 보였다. 이를 통해, 소비자의 선호도 평점을 예측할 때 레스토랑의 속성이 중요한 역할을 하는 것을 확인할 수 있고 이는 레스토랑 속성이 소비자 선호도에 영향을 미친다는 것을 나타낸다.

4.3.2 파라미터에 따른 추천 성능 비교


본 연구에서는 다양한 파라미터가 모델 성능에 미치는 영향을 확인하기 위해 추가로 다양한 실험을 수행했다. 먼저, 임베딩 크기가 모델 성능에 미치는 영향을 확인하기 위해 소비자 및 레스토랑 벡터의 임베딩 크기를 8, 16, 32 및 64로 변경하여 실험을 수행하였다. <그림 3>은 서로 다른 임베딩 크기에서 DRM-CRI 모델의 MAE 및 RMSE 평가지표의 값을 나타낸다. 두 평가지표에서 임베딩 크기가 64일 때 제안 모델이 가장 우수한 성능을 나타내고 있음을 확인할 수 있다. 이러한 결과를 통해 임베딩 크기가 작으면 소비자 및 레스토랑 벡터의 잠재 요소를 효과적으로 반영하지 못하는 문제점이 존재하는 것을 확인할 수 있다(Behera, Nain, 2022).

또한, 배치 크기를 128, 256, 512 및 1024로 설정하여 배치 크기가 DRM-CRI 모델에 미치는 영향을 확인했다. <그림 4>는 서로 다른 배치 크기에서 DRM-CRI 모델의 MAE 및 RMSE 평가지표의 값을

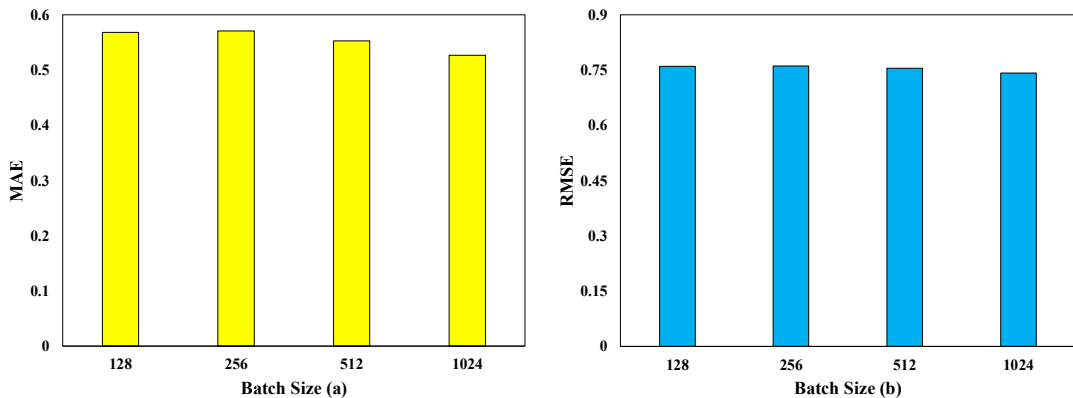
나타낸다. 두 평가지표에서 배치 크기가 1024일 때 제안 모델이 가장 우수한 성능을 나타내고 있음을 확인할 수 있다. 선행연구는 배치 크기가 클수록 네트워크의 정확도가 높아질 수 있다는 것을 검증하였는데, 본 실험에서도 선행연구에서와 같이 가장 큰 배치 크기인 1024를 사용하였을 때 가장 높은 성능 수준을 나타내는 것을 확인할 수 있었다 (Radiuk, 2017).

제안된 DRM-CRI 모델은 온라인 리뷰에서 소비자의 선호도를 추출하기 때문에 전체 리뷰 텍스트에 포함된 단어 수에 따라 추천 성능이 상이할 수 있다. 리뷰 텍스트에 포함된 모든 단어를 사용하면 학습 속도 및 예측 성능에 있어서 효율적이지 않

므로 적절한 단어 수를 설정하는 것이 중요하다 (Yang *et al.*, 2020). 따라서 본 연구에서는 <표 6>과 같이 여러 단어 수를 설정하여 DRM-CRI 모델의 추천 성능에 미치는 영향을 확인하였다. MAE 평가지표는 빈도가 가장 높은 25,000개의 단어를 사용할 때 가장 우수한 추천 성능을 나타내지만, RMSE 평가지표는 빈도가 가장 높은 15,000개의 단어를 사용할 때 가장 좋은 추천 성능을 나타냄을 확인할 수 있었다. 이러한 결과는 온라인 리뷰에서 의미론적 표현을 추출할 때 빈도가 낮은 단어는 상대적으로 낮은 중요도를 나타내므로 적절한 단어 수를 사용하는 것이 성능 측면에서 효과적이라는 것을 보여준다(Yang *et al.*, 2020).



〈그림 3〉 임베딩 크기에 따른 MAE (a) 와 RMSE (b) 성능 비교



〈그림 4〉 배치 크기에 따른 MAE (a) 와 RMSE (b) 성능 비교

<표 6> 단어 수에 따른 MAE와 RMSE 성능 비교

단어 수	MAE	RMSE
33,274(Max)	0.527 ± 0.013	0.742 ± 0.023
30,000	0.552 ± 0.025	0.751 ± 0.027
25,000	0.523 ± 0.018	0.729 ± 0.021
20,000	0.600 ± 0.036	0.808 ± 0.032
15,000	0.525 ± 0.010	0.725 ± 0.012

본 연구의 결과는 소비자의 의미론적 선호도와 레스토랑 속성 간 상호작용의 학습이 추천 성능에 미치는 영향을 나타내고 있다. 이와 같은 상호작용의 학습은 소비자 선호도 평점의 예측 성능을 효과적으로 향상할 수 있다. 또한, 기존 연구에서 사용한 정량적인 선호도 정보보다 소비자의 의미론적 선호도와 레스토랑의 특성이 소비자의 선호도 평점을 예측할 때 중요한 영향을 미친다는 것을 확인할 수 있다.

V. 결 론

외식 산업이 급속도로 성장함에 따라 레스토랑의 유형은 다양해지고 규모는 점차 커지고 있다. 또한, 온라인 서비스 플랫폼은 소비자가 레스토랑을 선택할 때 필요한 정보와 옵션을 제공하지만, 소비자는 여전히 레스토랑 구매 의사결정에 어려움을 겪고 있다. 이를 개선하기 위해서 온라인 서비스 제공자는 추천 서비스를 도입하여 소비자의 구매 의사결정을 지원하고 기업의 경쟁력을 강화하고 있다. 그러나 기존 추천 서비스는 평점 정보 또는 온라인 리뷰 내 키워드의 반복 패턴을 통해 추출한 정보를 사용하여 소비자의 구체적인 선호도 추적이 어렵다는 문제점이 존재한다. 또한, 레스토랑 이름을 통해 레스토랑 정보를 인식하는 방법론은 레스토랑 정보의 효과적인 반영이 어렵다는 문제점이 존재한다. 본 연구는 위와 같은 문제점을 해결하기 위해 소비자 선호도와 레스토랑 속성 간의 상호작용을 효과적으로 학습하여 소비자에게 맞춤형 레스토랑의 추천을 제공하는

DRM-CRI 모델을 제안하였다. Yelp.com에서 제공하는 데이터를 사용하여 제안 모델을 평가한 결과 기존 연구에서 제안된 여러 모델에 비해 우수한 성능을 보이는 것을 확인하였다.

본 연구의 학술적 시사점은 다음과 같다. 첫째, 본 연구는 온라인 리뷰를 통해 소비자의 의미론적 선호도 정보를 추출하였고, 이를 추천 시스템에 적용하여 추천 성능의 향상을 확인하였다. 기존 추천 시스템 연구에서는 정량적인 평점 정보 또는 감성분석을 통해 소비자의 선호도 정보를 추출하였다. 하지만 기존 방식은 온라인 리뷰에 포함된 레스토랑 방문 동기, 평가 후기 등 소비자의 구체적인 선호도 정보를 추출하지 못한다. 따라서 본 연구에서는 텍스트 내의 의미론적 표현을 추출한다고 입증된 CNN을 활용하여 소비자의 의미론적 선호도 정보를 추천 시스템에 반영하였고 실험 결과, 성능 향상을 가져옴을 확인하였다. 이는 리뷰 텍스트 내에 담긴 소비자의 의미론적 선호도 정보가 실제 소비자의 구체적인 선호도를 반영한다는 것을 나타낸다. 둘째, 본 연구는 레스토랑의 세부 정보를 활용한 방법론을 제시하여 레스토랑 추천 시스템 연구의 확장에 기여하였다. 특히, 추천 성능을 비교 분석하기 위해 소비자 선호도 정보만을 투입한 결과와 소비자 선호도와 레스토랑 속성을 함께 투입한 결과를 확인했고, 레스토랑 카테고리 추출된 레스토랑 속성을 사용한 추천 시스템의 성능이 비교적 높음을 알 수 있었다. 이를 통해 레스토랑 추천 시스템에서 레스토랑의 속성이 중요한 역할을 한다는 것을 알 수 있었고, 본 연구는 다양한 레스토랑의 정보를 활용하는 후속 연구의 발판을 마련했다는 점에서 의의가 존재한다. 셋째, 본 연구는 소비자의 의미론적 선호도 정보와 레스토랑 속성을 동시에 사용한 새로운 추천 시스템 모델인 DRM-CRI를 제안하였다. 기존 딥러닝 기법을 적용한 추천 시스템은 단순히 소비자 아이디와 레스토랑 아이디 간의 잠재 요인을 추출하여 추천 성능을 예측하였다. 하지만 본 연구에서는 소비자의 의미론적 선호도 정보와 레스토랑 속성

을 모델에 적용하여 기존 추천 시스템보다 우수한 예측 성능을 보였다. 이는 추천 시스템에서 여러 정보를 결합하는 것이 상호작용의 학습 및 추천 성능 향상에 도움이 된다는 것을 나타낸다. 또한, 소비자 혹은 레스토랑 측면의 정보만을 활용하지 않고 양측의 정보를 모두 활용하였다는 점에서 레스토랑 추천 시스템 연구의 확장에 기여하였다는 의의가 존재한다.

본 연구의 실무적 시사점은 다음과 같다. 첫째, TripAdvisor.com, Yelp.com 등 레스토랑의 세부적인 정보와 소비자의 리뷰를 포함하는 플랫폼에서 활용할 수 있는 추천 방법론을 제안했다. 기존의 레스토랑 추천 시스템은 정량적인 정보만을 활용하여 소비자 행동의 결과만을 고려하였고, 레스토랑의 세부적인 정보를 활용하지 않아 정교한 레스토랑 추천에 한계가 있었다. 본 연구에서 제안한 방법론은 온라인 리뷰와 레스토랑의 세부 정보인 카테고리 정보를 이용하기에 실제 온라인 플랫폼에 적용하면 더 정확한 추천 시스템의 구축을 가능하게 할 수 있다. 이를 통해, 소비자 선택의 질을 높이고 소비자에게 맞춤형 정보를 제공함으로써 소비자 만족도의 향상을 통해 레스토랑 산업의 유의미한 성장을 불러올 수 있을 것이다. 둘째, 레스토랑의 카테고리 정보로 나타나는 정보가 추천 성능에 미치는 영향을 분석하여 레스토랑 경영자가 레스토랑의 카테고리를 결정할 때 적용 가능한 경영 전략을 제공할 수 있다. 본 연구의 결과, 레스토랑의 카테고리 정보의 활용이 추천 시스템 성능에 긍정적인 영향을 미치는 것을 확인하였다. 이는 레스토랑의 카테고리 정보가 소비자 구매 의사결정에 영향을 미친다는 것을 나타내며 본 연구의 결과를 통해 레스토랑 경영자가 소비자가 중요하다고 여기는 정보를 레스토랑의 카테고리 설정하게 할 수 있다. 셋째, 온라인 리뷰를 통해 소비자의 의미론적 선호도를 파악하여 소비자가 선호하는 서비스를 레스토랑 경영자가 제공하게 할 수 있다. 본 연구의 결과, 소비자의 의미론적 선호도의 활용이 추천 시스템의 성능을 향상하는 것을 확인하였다.

이는 온라인 리뷰 내에 담긴 소비자의 의미론적 선호도가 기존 정량적인 선호도 평점보다 유의한 영향을 미친다는 것을 나타내며, 본 연구를 통해 레스토랑 경영자가 온라인 리뷰를 통해 소비자의 의미론적 선호도를 파악하고 그에 맞는 서비스를 제공하게 할 수 있다.

본 연구는 다음과 같은 한계점이 존재한다. 첫째, 본 연구는 Yelp.com에서 제공하는 미국의 펜실베이니아주의 데이터만 사용하여 제안한 모델의 성능을 검증하였다. 따라서 다양한 유형의 데이터에서도 동일한 결과가 나타나는지 검증할 필요성이 존재한다. 둘째, 본 연구에서는 소비자 선호도를 온라인 리뷰에서 CNN을 적용하여 추출하였지만, 현재 좋은 성능을 나타내고 있는 LSTM-CNN과 BERT-CNN을 사용하여 추후 모델의 성능을 향상할 필요성이 존재한다. 셋째, 본 연구는 레스토랑의 속성을 파악하기 위해 레스토랑 카테고리 정보만을 사용하였다. 하지만 Yelp.com에서 제공하는 비즈니스 데이터 세트에는 레스토랑의 카테고리 정보 외에 가격대, 주차 시설, 분위기 등의 정보들이 포함되어 있다. 따라서 이러한 레스토랑의 추가 정보들을 활용한 연구를 진행하여 추후 모델의 성능을 향상할 필요성이 존재한다. 넷째, 본 연구에서 제안한 DRM-CRI 모델은 소비자의 선호도 평점을 예측하는 연구로 MAE 및 RMSE 평가지표를 이용하여 성능을 평가했다. 하지만 추천 시스템의 궁극적인 목표는 소비자에게 알맞은 레스토랑을 추천하는 것이다. 따라서 향후 연구에서는 DRM-CRI 모델을 통해 추천한 레스토랑이 실제 소비자의 구매 의사결정에 유의한 영향을 미치는지 Precision, Recall, F1-score로 성능을 검증하여 연구를 고도화할 필요성이 존재한다.

참 고 문 헌

- [1] 구민정, 안현철, “종합 평점과 다기준 평점을 선택적으로 활용하는 협업필터링 기반 하이브리드 추천시스템”, *지능정보연구*, 제24권,

- 제2호, 2018, pp. 85-109.
- [2] 김윤진, “세계 외식산업 성장과 트렌드”, *세계 농업*, 제168권, 2014, pp. 115-128.
- [3] 나진성, 노용휘, “네트워크 텍스트 분석을 통한 외식경영 연구동향 분석: 최근 3개년(2012년도-2014년도) 논문을 중심으로”, *외식경영 연구*, 제18권, 제1호, 2015, pp. 117-136.
- [4] 박호연, 김경재, “CNN-LSTM 조합모델을 이용한 영화리뷰 감성분석”, *지능정보연구*, 제25권, 제4호, 2019, pp. 141-154.
- [5] 손지은, 김성범, 김현중, 조성준, “추천시스템 기법 연구동향 분석”, *대한산업공학회지*, 제41권, 제2호, 2015, pp. 185-208.
- [6] 이륜경, 정남호, 홍태호, “딥러닝을 이용한 온라인 리뷰 기반 다속성별 추천 모형 개발”, *정보시스템연구*, 제28권, 제1호, 2019, pp. 97-114.
- [7] 이청용, 이병현, 이흠철, 김재경, “CNN 기반 리뷰 유용성 점수 예측을 통한 개인화 추천 서비스 성능 향상에 관한 연구”, *지능정보연구*, 제27권, 제3호, 2021, pp. 29-56.
- [8] 이흠철, 윤효림, 이청용, 김재경, “Multi-channel CNN 기반 온라인 리뷰 유용성 예측 모델 개발에 관한 연구”, *지능정보연구*, 제28권, 제2호, 2022, pp. 171-189.
- [9] 조승연, 최지은, 이규현, 김희웅, “고객 온라인 구매후기를 활용한 추천 시스템 개발 및 적용”, *Information Systems Review*, 제17권, 제3호, 2015, pp. 95-111.
- [10] 홍민성, 정남호, 한석호, “딥러닝 기반 스마트 관광 추천 알고리즘 개발 연구: 새로운 OTA 레스토랑 추천 시스템의 제안”, *관광레저연구*, 제34권, 제3호, 2022, pp. 431-444.
- [11] Alashkar, T., S. Jiang, S. Wang, and Y. Fu, “Examples-rules guided deep neural network for makeup recommendation”, *Proceedings of the AAAI Conference on Artificial Intelligence*, 2017, pp. 941-947.
- [12] Amari, S., *The handbook of brain theory and neural networks*, MIT Press, Cambridge, Massachusetts, U.S., 2003.
- [13] Asani, E., H. Vahdat-Nejad, and J. Sadri, “Restaurant recommender system based on sentiment analysis”, *Machine Learning with Applications*, Vol. 6, 2021, pp. 100-114.
- [14] Behera, G. and N. Nain, “Handling data sparsity via item metadata embedding into deep collaborative recommender system”, *Journal of King Saud University-Computer and Information Sciences*, 2022, pp. 9953-9963.
- [15] Billsus, D. and M. J. Pazzani, “Learning collaborative information filters”, *International Conference on Machine Learning (ICML)*, Vol. 98, 1998, pp. 46-54.
- [16] Chen, C., P. Zhao, L. Li, J. Zhou, X. Li, and M. Qiu, “Locally connected deep learning framework for industrial-scale recommender systems”, *Proceedings of the 26th International Conference on World Wide Web Companion*, 2017, pp. 769-770.
- [17] Cho, Y. H., J. K. Kim, and S. H. Kim, “A personalized recommender system based on web usage mining and decision tree induction”, *Expert Systems with Applications*, Vol. 23, No. 3, 2002, pp. 329-342.
- [18] Dalvi, R. R., S. B. Chavan, and A. Halbe, “Detecting a Twitter cyberbullying using machine learning”, *4th International Conference on Intelligent Computing and Control Systems (ICICCS)*, 2020, pp. 297-301.
- [19] Denny, M. J. and A. Spirling, “Text preprocessing for unsupervised learning: Why it matters, when it misleads, and what to do about it”, *Political Analysis*, Vol. 26, No. 2, 2018, pp. 168-189.
- [20] Dong, J., F. He, Y. Guo, and H. Zhang, “A commodity review sentiment analysis based on

- BERT-CNN model”, *2020 5th International Conference on Computer and Communication Systems (ICCCS)*, 2020, pp. 143-147.
- [21] Du, J., L. Zheng, J. He, J. Rong, H. Wang, and Y. Zhang, “An interactive network for end-to-end review helpfulness modeling”, *Data Science and Engineering*, Vol. 5, No. 3, 2020, pp. 261-279.
- [22] Gamon, M., A. Aue, S. Corston-Oliver, and E. Ringger, “Pulse: Mining customer opinions from free text”, *Proceedings of 6th International Symposium on Intelligent Data Analysis*, 2005, pp. 121-132.
- [23] Goldberg, K., T. Roeder, D. Gupta, and C. Perkins, “Eigentaste: A constant time collaborative filtering algorithm”, *Information Retrieval*, Vol. 4, No. 2, 2001, pp. 133-151.
- [24] He, X. and T.-S. Chua, “Neural factorization machines for sparse predictive analytics”, *Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2017, pp. 355-364.
- [25] He, X., L. Liao, H. Zhang, L. Nie, X. Hu, and T.-S. Chua, “Neural collaborative filtering”, *Proceedings of the 26th International Conference on World Wide Web*, 2017, pp.173-182.
- [26] Hegde, S. B., S. Satyappanavar, and S. Setty, “Sentiment based food classification for restaurant business”, *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, 2018, pp. 1455-1462.
- [27] Herlocker, J. L., J. A. Konstan, A. Borchers, and J. Riedl, “An algorithmic framework for performing collaborative filtering”, *Proceedings of the 22nd Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, 1999, pp. 230-237.
- [28] Iwendi, C., E. Ibeke, H. Eggoni, S. Velagala, and G. Srivastava, “Pointer-based item-to-item collaborative filtering recommendation system using a machine learning model”, *International Journal of Information Technology & Decision Making*, Vol. 21, No. 01, 2022, pp. 463-484.
- [29] Kang, S., J. Hwang, W. Kweon, and H. Yu, “DE-RRD: A knowledge distillation framework for recommender system”, *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*, 2020, pp. 605-614.
- [30] Kaur, S., P. Kumar, and P. Kumaraguru, “Detecting clickbaits using two-phase hybrid CNN-LSTM biterm model”, *Expert Systems with Applications*, Vol. 151, 2020, pp. 113350.
- [31] Kiran, R., P. Kumar, and B. Bhasker, “DNNRec: A novel deep learning based hybrid recommender system”, *Expert Systems with Applications*, Vol. 144, 2020, pp. 113054.
- [32] Lee, D., Hosanagar, K., “How do recommender systems affect sales diversity? A cross-category investigation via randomized field experiment”, *Information Systems Research*, Vol. 30, No. 1, 2019, pp. 239-259.
- [33] Li, L., Y. Zhou, H. Xiong, Hu, C., Wei, X., “Collaborative filtering based on user attributes and user ratings for restaurant recommendation”, *2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)*, 2017, pp. 2592-2597.
- [34] Liu, J., C. Wu, and W. Liu, “Bayesian probabilistic matrix factorization with social relations and item contents for recommendation”, *Decision Support Systems*, Vol. 55, No. 3, 2013, pp. 838-850.
- [35] Liu, Z., B. Yuan, and Y. Ma, “A multi-task dual attention deep recommendation model using ratings and review helpfulness”, *Applied Intelligence*, Vol. 52, No. 5, 2022, pp. 5595-5607.
- [36] Lu, J., D. Wu, M. Mao, W. Wang, and G. Zhang,

- “Recommender system application developments: A survey”, *Decision Support Systems*, Vol. 74, 2015, pp. 12-32.
- [37] Majumder, N., S. Poria, A. Gelbukh, and E. Cambria, “Deep learning-based document modeling for personality detection from text”, *IEEE Intelligent Systems*, Vol. 32, No. 2, 2017, pp. 74-79.
- [38] Margaris, D., C. Vassilakis, and D. Spiliotopoulos, “What makes a review a reliable rating in recommender systems?”, *Information Processing & Management*, Vol. 57, No. 6, 2020, pp. 102304.
- [39] Muhammad, K., Q. Wang, D. O’Reilly-Morgan, E. Tragos, B. Smyth, N. Hurley, J. Geraci, and A. Lawlor, “Fedfast: Going beyond average for faster training of federated recommender systems”, *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*, 2020, pp. 1234-1242.
- [40] Nemade, G., R. Deshmane, P. Thakare, M. Patil, and V. Thombre, “Smart tourism recommender system”, *International Research Journal of Engineering and Technology (IRJET)*, Vol. 4, No. 11, 2017, pp. 601-603.
- [41] Ning, X. and G. Karypis, “Slim: Sparse linear methods for top-n recommender systems”, *2011 IEEE 11th International Conference on Data Mining*, 2011, pp. 497-506.
- [42] Park, D. H., H. K. Kim, I. Y. Choi, and J. K. Kim, “A literature review and classification of recommender systems research”, *Expert Systems with Applications*, Vol. 39, No. 11, 2012, pp. 10059-10072.
- [43] Radiuk, P. M., “Impact of training set batch size on the performance of convolutional neural networks for diverse datasets”, *Information Technology and Management Science*, Vol. 20, No. 1, 2017, pp. 20-24.
- [44] Raj, D., S. Sahu, and A. Anand, “Learning local and global contexts using a convolutional recurrent network model for relation classification in biomedical text”, *Proceedings of the 21st Conference on Computational Natural Language Learning (CoNLL 2017)*, 2017, pp. 311-321.
- [45] Rajendran, D. P. D., and R. P. Sundarraj, “Using topic models with browsing history in hybrid collaborative filtering recommender system: Experiments with user ratings”, *International Journal of Information Management Data Insights*, Vol. 1, No. 2, 2021, pp. 100027.
- [46] Ramachandran, D., and R. Parvathi, “Analysis of twitter specific preprocessing technique for tweets”, *Procedia Computer Science*, Vol. 165, 2019, pp. 245-251.
- [47] Rendle, S., “Learning recommender systems with adaptive regularization”, *Proceedings of the 15th ACM International Conference on Web Search and Data Mining*, 2012, pp. 133-142.
- [48] Sarwar, B., G. Karypis, J. Konstan, and J. Riedl, “Item-based collaborative filtering recommendation algorithms”, *Proceedings of the 10th International Conference on World Wide Web*, 2001, pp. 285-295.
- [49] Scaffidi, C., K. Bierhoff, E. Chang, M. Felker, H. Ng, and C. Jin, “Red Opal: product-feature scoring from reviews”, *Proceedings of the 8th ACM Conference on Electronic Commerce*, 2007, pp. 182-191.
- [50] She, X. and D. Zhang, “Text classification based on hybrid CNN-LSTM hybrid model”, *2018 11th International Symposium on Computational Intelligence and Design (ISCID)*, 2018, pp. 184-189.
- [51] Shi, Y., Q. Zhao, Y. Wang, and J. Cao, “An Improved Restaurant Recommendation Algorithm Based on User’s Multiple Features”, *2018 IEEE 9th International Conference on Software Engin-*

- ering and Service Science (ICSESS), 2018, pp. 191-194.
- [52] Silveira, T., M. Zhang, X. Lin, Y. Liu, and S. Ma, “How good your recommender system is? A survey on evaluations in recommendation”, *International Journal of Machine Learning and Cybernetics*, Vol. 10, No. 5, 2019, pp. 813-831.
- [53] Singh, R., J. Woo, N. Khan, J. Kim, H. Lee, H. Rahman, J. Park, J. Suh, M. Eom, N. Gudigantala, “Applications of machine learning models on Yelp data”, *Asia Pacific Journal of Information Systems*, Vol. 29, No. 1, 2019, pp. 117-143.
- [54] Sohrabi, M. K. and F. Hemmatian, “An efficient preprocessing method for supervised sentiment analysis by converting sentences to numerical vectors: a twitter case study”, *Multimedia Tools and Applications*, Vol. 78, No. 17, 2019, pp. 24863-24882.
- [55] Su, X. and T. M. Khoshgoftaar, “A survey of collaborative filtering techniques”, *Advances in Artificial Intelligence*, 2009, pp. 1-19.
- [56] Sun, L., J. Guo, and Y. Zhu, “Applying uncertainty theory into the restaurant recommender system based on sentiment analysis of online Chinese reviews”, *World Wide Web*, Vol. 22, No. 1, 2019, pp. 83-100.
- [57] Wang, H., D. Amagata, T. Maekawa, T. Hara, H. Niu, K. Yonekawa, and M. Kurokawa, “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*, 2019, pp. 398-403.
- [58] Wolfe, K., C. H. Hsu, and S. K. Kang, “Buyer characteristics among users of various travel intermediaries”, *Journal of Travel & Tourism Marketing*, Vol. 17, No. 2-3, 2005, pp. 51-62.
- [59] Wu, B., L. Zhong, H. Li, and Y. Ye, “Efficient complementary graph convolutional network without negative sampling for item recommendation”, *Knowledge-Based Systems*, Vol. 256, 2022, pp. 109758.
- [60] Wu, Y., C. DuBois, A. X. Zheng, and M. Ester, “Collaborative denoising auto-encoders for top-n recommender systems”, *Proceedings of the 9th ACM International Conference on Web Search and Data Mining*, 2016, pp. 153-162.
- [61] Yang, L., Y. Li, J. Wang, and R. S. Sherratt, “Sentiment analysis for E-commerce product reviews in Chinese based on sentiment lexicon and deep learning”, *IEEE Access*, Vol. 8, 2020, pp. 23522-23530.
- [62] Yoon, K., “Convolutional Neural Networks for Sentence Classification”, *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014, pp. 1746-1751.
- [63] Zhao, G., X. Qian, and H. Feng, “Personalized recommendation by exploring social users’ behaviors”, *International Conference on Multimedia Modeling*, 2014, pp. 181-191.
- [64] Zhou, X., J. He, G. Huang, and Y. Zhang, “SVD-based incremental approaches for recommender systems”, *Journal of Computer and System Sciences*, Vol. 81, No. 4, 2015, pp. 717-733.

Information Systems Review

Volume 25 Number 1

February 2023

Developing a Deep Learning-based Restaurant Recommender System Using Restaurant Categories and Online Consumer Review

Haeun Koo* · Qinglong Li** · Jaekyeong Kim***

Abstract

Research on restaurant recommender systems has been proposed due to the development of the food service industry and the increasing demand for restaurants. Existing restaurant recommendation studies extracted consumer preference information through quantitative information or online review sensitivity analysis, but there is a limitation that it cannot reflect consumer semantic preference information. In addition, there is a lack of recommendation research that reflects the detailed attributes of restaurants. To solve this problem, this study proposed a model that can learn the interaction between consumer preferences and restaurant attributes by applying deep learning techniques. First, the convolutional neural network was applied to online reviews to extract semantic preference information from consumers, and embedded techniques were applied to restaurant information to extract detailed attributes of restaurants. Finally, the interaction between consumer preference and restaurant attributes was learned through the element-wise products to predict the consumer preference rating. Experiments using an online review of Yelp.com to evaluate the performance of the proposed model in this study confirmed that the proposed model in this study showed excellent recommendation performance. By proposing a customized restaurant recommendation system using big data from the restaurant industry, this study expects to provide various academic and practical implications.

Keywords: *Restaurant Recommender System, Convolutional Neural Network, Online Reviews, Restaurant Attribute*

* Master Student, Department of Big Data Analytics, Kyung Hee University

** Ph.D. Candidate, Department of Big Data Analytics, Kyung Hee University

*** Corresponding Author, Professor, School of Management & Department of Big Data Analytics, Kyung Hee University

◎ 저 자 소 개 ◎



구 하 은 (heni1325@khu.ac.kr)

경희대학교 대학원 빅데이터응용학과 석사과정에 재학 중이며, 주요 연구 관심 분야는 추천 시스템, 딥러닝, 자연어 처리, 빅데이터 분석 등이다.



이 청 용 (leecy@khu.ac.kr)

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, 지식경영 연구, Information Systems Review, Applied Sciences, Applied Artificial Intelligence, Data Technologies and Applications, Expert Systems 등 다수의 학술지에 논문을 게재하였다.



김 재 경 (jaek@khu.ac.kr)

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.

논문접수일 : 2022년 11월 01일

게재확정일 : 2022년 12월 08일