

# Multi-channel CNN 기반 온라인 리뷰 유용성 예측 모델 개발에 관한 연구\*

이흥철

경희대학교 빅데이터응용학과  
(lixz@khu.ac.kr)

윤효림

경희대학교 호텔관광대학 Hospitality 경영학부  
(hyorimyun@khu.ac.kr)

이청용

경희대학교 빅데이터응용학과  
(leecy@khu.ac.kr)

김재경

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

.....

온라인 리뷰는 소비자의 구매 의사결정 과정에서 중요한 역할을 담당하고 있으므로 소비자에게 유용하고 신뢰성이 있는 리뷰를 제공하는 것이 중요하다. 기존의 온라인 리뷰 유용성 예측 관련 연구는 주로 온라인 리뷰의 텍스트와 평점 정보 간의 일관성을 바탕으로 리뷰 유용성을 예측하였다. 그러나 기존 연구는 평점 정보를 스칼라로 표현했기 때문에 표현 수용력이 제한적이거나 평점 정보와 리뷰 텍스트 정보와의 상호작용을 제한적으로 학습하는 한계가 존재한다. 본 연구에서는 기존 연구의 한계점을 보완하기 위해 리뷰 텍스트와 평점 정보 간의 상호작용을 효과적으로 학습할 수 있는 CNN-RHP(CNN based Review Helpfulness Prediction) 모델을 제안하였다. 먼저, 리뷰 텍스트의 의미론적 특성을 추출하기 위해 multi-channel CNN을 적용하였다. 다음으로, 평점 정보는 텍스트 특성과 동일한 차원을 나타내는 독립된 고차원 임베딩 특성 벡터로 변환하였다. 최종적으로 요소별(Element-wise) 연산을 통해 리뷰 텍스트와 평점 정보 간의 일관성을 학습하였다. 본 연구에서는 제안된 CNN-RHP 모델의 성능을 평가하기 위해 Amazon.com에서 수집된 온라인 소비자 리뷰를 사용하였다. 실험 결과, 본 연구에서 제안한 CNN-RHP 모델이 기존 연구에서 제안된 여러 모델과 비교했을 때 우수한 예측 성능을 나타내는 것을 확인하였다. 본 연구의 결과는 온라인 전자상거래 플랫폼에서 소비자들에게 리뷰 유용성 예측 서비스를 제공할 때 유의미한 시사점을 제공할 수 있다.

**주제어** : 온라인 리뷰, 리뷰 유용성, 리뷰 텍스트, multi-channel CNN

.....

논문접수일 : 2022년 6월 1일

논문수정일 : 2022년 6월 17일

게재확정일 : 2022년 6월 18일

원고유형 : Regular Track

교신저자 : 이청용

## 1. 서론

온라인 리뷰는 전자상거래 생태계에서 기업의 지속 가능한 발전을 위한 효과적인 마케팅 수단으로 활용되고 있다(이선영 등, 2019; 이승우 등, 2022). Liu et al. (2007)에 따르면 온라인에서 제

품을 구매할 때 소비자 10명 중 8명은 다른 소비자가 작성한 온라인 리뷰를 통해 구매 의사결정에 필요한 정보를 탐색하는 것으로 나타났다. 이러한 온라인 소비자 리뷰는 기업 측면에서는 제품에 대한 소비자들의 평가 정보를 제공할 수 있으며, 이를 제품의 품질 개선이나 마케팅 전략에

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

반영할 수 있다(Li et al., 2021). 그러나 소비자가 작성한 리뷰는 소비자 경험, 제품 결함 등 다양한 요인의 영향을 받을 수 있으므로 온라인 리뷰의 품질은 상이할 수 있다. 온라인 소비자 리뷰 수가 기하급수적으로 증가하기 시작하면서 정보량이 방대해지자 소비자는 구매 의사결정에 필요한 정보를 탐색하는 데 어려움을 겪고 있다(Jones et al., 2004; Yin et al., 2014). 최근에 대부분의 전자상거래 기업은 온라인 소비자 리뷰의 품질을 평가하기 위해 리뷰 유용성 투표 시스템을 도입하고 있다(이청용 등, 2021). 그러나 이러한 투표 시스템을 사용하게 될 경우, 오래전에 작성된 리뷰는 많은 투표수를 받을 수 있지만, 최근에 작성된 소비자 리뷰는 투표수를 받을 기회가 제한적이고 실제로 최근에 작성된 많은 리뷰에서 투표 정보가 누락되는 현상을 보인다.

온라인 리뷰 유용성 예측은 소비자의 구매 의사결정 과정에 도움이 되는 맞춤형 리뷰를 자동적으로 탐색하여 소비자에게 추천하는 것을 목표로 한다. 기존의 관련 연구는 주로 온라인 리뷰의 텍스트와 평점 정보를 사용하여 리뷰의 유용성을 예측하였다(Charrada, 2016; Diaz & Ng, 2018; Hoffait et al., 2018). 리뷰 텍스트는 제품에 대한 소비자의 평가를 정성적으로 나타낼 수 있을 뿐만 아니라, 리뷰 유용성 정보를 학습할 때 필요한 구체적이고 풍부한 정보를 포함하고 있다. 평점은 제품에 대한 소비자의 평가를 정량적으로 나타내고, 평점의 방향성과 극단성은 소비자들의 리뷰 유용성의 평가에 영향을 미치는 것으로 나타났다(Fang et al., 2016; Yin et al., 2016). Quaschnig et al. (2015)에 따르면 리뷰 텍스트와 평점 간의 일관성이 소비자가 온라인 리뷰 유용성을 평가할 때 영향을 미치는 것으로 나타났다. 온라인 리뷰의 텍스트와 평점은 소비자

가 구매한 제품에 대하여 각각 정성적 및 정량적 측면에서 평가를 진행한 것이다. 온라인 구매 환경에서 소비자는 구매 의사결정에 필요한 리뷰를 탐색할 때 리뷰 텍스트와 평점이 일관된 정보를 나타내기를 기대하는 경향이 있다(Huang et al., 2015). 그러나 소비자는 주관적 측면에서 리뷰를 작성하기 때문에 리뷰 텍스트 내용이 리뷰 평점에 반드시 완벽하게 반영되는 것은 아니다. 즉, 온라인 리뷰의 텍스트 내용과 평점 정보가 일치하지 않으면 소비자들의 정보 탐색 과정의 효율성을 저해할 수 있으며 이들이 리뷰에 대해 인지하는 신뢰성과 유용성을 감소시킬 수 있다.

기존 연구에서는 리뷰 텍스트와 평점 간의 일관성을 고려하여 리뷰 유용성을 예측하기 위해 리뷰 텍스트와 평점 정보를 결합하였다. 그러나 평점 정보는 표현 수용력(Representation Capacity)이 제한적이거나 리뷰 텍스트와 상호작용을 제한적으로 학습하는 한계가 존재한다. 대부분의 연구에서는 리뷰 텍스트는 고차원 특성 벡터로 표현하지만, 평점 정보는 스칼라(Scalar)로 표현하고 있다(Ghose & Ipeirotis, 2010; Salehan & Kim, 2016; Siering et al., 2018). 이러한 스칼라 표현은 평점 정보의 표현 수용력과 리뷰 텍스트에 대한 평점의 영향을 제한할 수 있다. Qu et al. (2018)는 인코딩(Encoding) 수용력을 확장하기 위해 평점을 리뷰 텍스트의 마지막 단어로 인식시켜 학습하였다. 또한, CNN(Convolution Neural Network)을 인코더(Encoder)로 사용하여 평점 정보를 리뷰 텍스트 단어와 동일한 차원의 임베딩(Embedding) 벡터로 변환하여 리뷰의 행렬 표현(Matrix Representation)에 연결하였다. CNN은 텍스트에 포함된 연속적인 단어 특성을 학습하기 위해 슬라이딩 윈도우를 통해 연산을 수행한다. 그러나 평점 정보는 텍스트 말미의 일부 단어와

지역적으로 상호작용을 학습되기 때문에 리뷰 텍스트와 평점 간의 상호작용이 제한되는 한계가 존재한다. 또한, 맥스 풀링 특성으로 인해 평점 정보가 부분적으로 손실되는 문제가 발생할 수 있다. 다시 말해, 기존 연구에서 제안한 리뷰 유용성 모델들은 평점 정보를 충분히 활용하는 데 한계가 존재한다.

따라서 본 연구에서는 리뷰 텍스트와 평점 간의 상호작용을 효과적으로 학습하는 CNN-RHP(CNN based Review Helpfulness Prediction) 모델을 제안한다. CNN-RHP는 리뷰 텍스트와 평점 정보를 같은 차원의 특성 벡터로 매핑하여 표현 수용력을 동등하게 나타내도록 설계하였다. 리뷰 텍스트와 평점 간의 상호작용을 효과적으로 학습하기 위해 텍스트 및 평점은 별도의 임베딩 벡터로 변환되었다. 리뷰 텍스트에 포함된 의미론적 특성을 효과적으로 추출하기 위해 여러 개의 필터를 사용하는 multi-channel CNN을 적용하였다. 또한, 리뷰 텍스트의 마지막 단어로 결합하여 평점 정보를 학습하는 기존 연구와 달리 텍스트 인코딩과 평점 정보 인코딩은 독립적으로 구성하였다. 즉, CNN-RHP 모델에서는 평점 정보가 리뷰 텍스트에 포함된 모든 단어와 효과적으로 상호작용이 가능하다. 이를 통해 리뷰 텍스트와 평점 정보 간의 일관성은 리뷰 내용과 평점 벡터 간의 요소별(Element-wise) 연산을 통해 추출된다. 본 연구에서 제안된 CNN-RHP 모델의 성능을 평가하기 위해 아마존(Amazon.com)에서 수집된 온라인 소비자 리뷰를 사용하였다. 실험 결과, 본 연구에서 제안한 CNN-RHP 모델이 기존 연구에서 제안된 여러 모델과 비교했을 때 우수한 예측 성능을 나타내는 것을 확인하였다. 본 연구의 결과는 온라인 전자상거래 플랫폼에서 리뷰 유용성 관련 서비스를 제공할 때 유의미한

시사점을 제공할 수 있다.

본 연구의 나머지 구성은 다음과 같다. 제2장에서는 리뷰 텍스트와 평점을 고려한 리뷰 유용성 예측 관련 연구를 설명한다. 제3장에서는 본 연구에서 제안하는 CNN-RHP 프레임워크에 관해 설명한다. 제4장에서는 실험 데이터 및 평가 지표, 실험 설계와 실험 결과에 관해 구체적으로 설명한다. 마지막으로 제5장에서는 결과 토의, 시사점, 연구 한계점 및 추후 연구 계획에 관해 설명한다.

## 2. 관련 연구

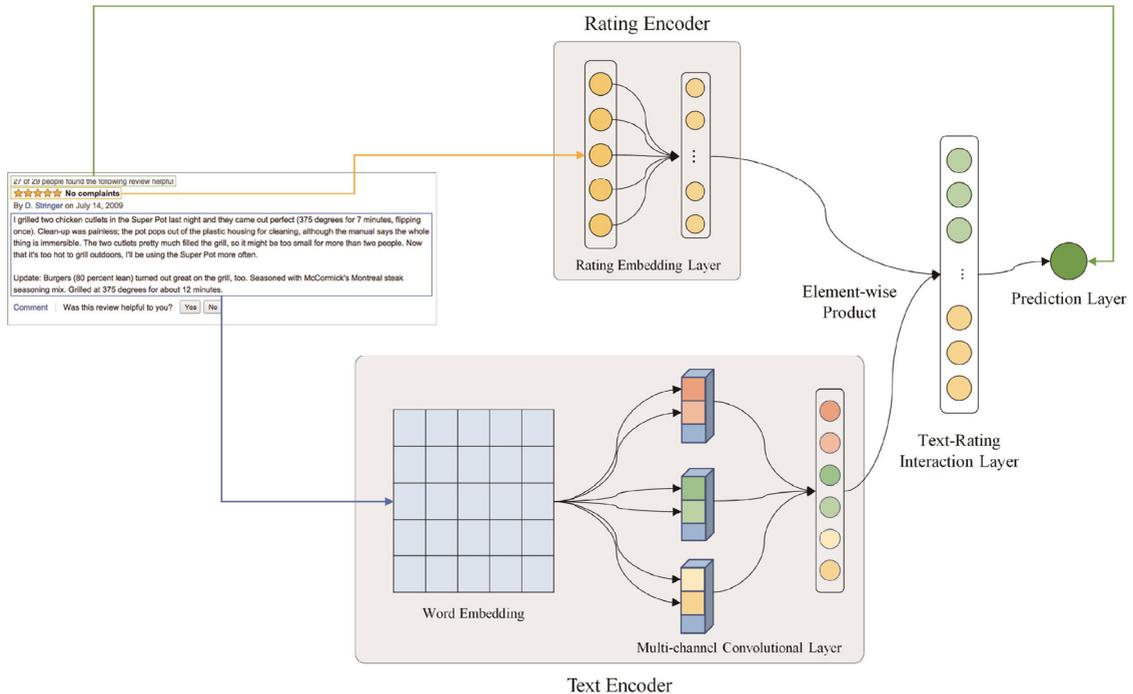
온라인 리뷰 유용성을 예측하기 위해 리뷰에 포함된 텍스트, 평점, 리뷰어 정보 등 특성 패턴을 바탕으로 구축된 다양한 모델이 제안되었다(Ghose & Ipeirotis, 2010; Yang et al., 2015). 이와 같은 모델은 효과적으로 리뷰 유용성을 예측할 수 있지만, 제품이나 도메인에 따라 특성 패턴이 이질적인 것에 대해 효과적으로 대응하기 어렵다. 또한, 모델 구축에 필요한 특성을 추출하는 과정은 많은 사전 지식과 연산 비용이 필요하다. 특히, 추출된 특성에서 중복된 정보로 인해 다중공선성 문제점이 발생할 수 있으며, 이는 모델을 구축할 때 편향을 발생시켜 성능을 저하시킬 수 있다. 최근에는 다양한 딥러닝 모델이 개발되기 시작하면서 리뷰 유용성 예측에 대한 새로운 방법들이 제안되고 있다(Yoon Kim, 2014; Kim et al., 2016). CNN은 텍스트에 포함된 의미론적 특성을 효과적으로 추출할 수 있으므로 온라인 리뷰의 유용성을 예측하는데 적절하게 적용할 수 있다. Y Kim (2014)는 여러 크기의 커널을 적용한 CNN 모델을 제안하여 영화 리뷰에 대한 감

성 분석을 수행하여 우수한 분류 성능을 보여주면서 많은 주목을 받았다. 이러한 multi-channel CNN은 다양한 크기의 커널을 적용하기 때문에 텍스트에 포함된 다양한 형태의 의미론적 특성을 효과적으로 추출할 수 있다(Han et al., 2019). Saumya et al. (2020)는 리뷰 텍스트에 포함된 의미론적 특성을 자동으로 추출하여 리뷰 유용성을 예측하기 위해 다양한 크기의 필터를 적용한 multi-channel CNN을 제안하였다. 제안한 방법론의 성능을 측정하기 위해 아마존과 스냅딜(Snapdeal.com)에서 수집한 온라인 리뷰 데이터를 실험에 사용하였다. 실험 결과, 필터 크기를 다양하게 설정한 multi-channel CNN의 예측 성능이 특정 필터 크기를 적용하는 CNN 모델보다 우수함을 확인하였다.

최근에는 이와 같은 multi-channel CNN 기반으로 리뷰 유용성의 예측 성능을 개선하기 위해 리뷰 텍스트와 평점 간의 상호작용을 고려한 다양한 연구들이 제안되고 있다. Qu et al. (2018)은 온라인 리뷰의 유용성을 예측하기 위한 모델의 성능을 향상시키기 위해 CNN을 적용한 CM(Combination Method) 모델을 제안하였다. CM 모델은 평점 정보를 리뷰 텍스트의 마지막 단어로 간주하고 리뷰 텍스트와 평점 정보를 결합하여 상호작용을 학습하였다. 실험 결과, 연구에서 제안한 리뷰 텍스트와 평점 정보를 결합하는 CM 모델은 기존 리뷰 텍스트만 사용하는 CNN에 비해 우수한 예측 성능을 보여주고 있음을 확인하였다. 하지만, 평점 정보가 리뷰 텍스트의 일부 단어와만 상호작용을 할 수 있으므로 리뷰 텍스트와 평점 정보 간의 상호작용이 제한적으로 학습되는 한계점이 존재한다. 또한, 모델의 학습 과정에서 맥스 풀링 레이어를 통해 추출된 평점 정보 특성 벡터에 부분적으로 손실이 발

생하여 평점 정보의 표현 수용력이 제한되는 한계점도 존재할 수 있다. Fan et al. (2018)는 리뷰 유용성 및 평점 정보를 예측하는 MTNL(Multi-Task Neural Learning) 모델을 제안하였다. 이 모델의 평점 정보 예측은 학습 과정에서 모델의 과적합(Overfitting) 문제를 개선하여 모델의 예측 성능을 향상시켰다. 이 때 리뷰 텍스트에 포함된 특성은 MTNL 모델을 통해 자동으로 추출되어 리뷰 유용성 및 평점을 예측할 수 있다. 제안한 모델의 예측 성능을 평가하기 위해 아마존에서 수집한 리뷰 데이터를 실험에 사용하였다. 실험 결과, MTNL 모델은 기존 연구에서 제안한 모델에 비해 예측 성능이 우수함을 확인하였다. 그러나 리뷰에 포함된 평점 정보를 고려하지 않고 리뷰 유용성을 평가한다는 가정을 바탕으로 유용성을 예측하였기 때문에 리뷰 텍스트와 평점의 상호작용을 고려하지 않았다는 한계점이 존재한다.

기존 리뷰 텍스트와 평점 간의 상호작용을 바탕으로 리뷰 유용성을 예측하는 선행연구는 다음과 같은 한계점이 존재한다. 첫째, 평점 정보를 스칼라 형태로 표현하기 때문에 정보 손실이 발생하여 추출된 평점 정보 특성 벡터의 표현 수용력이 제한적이라는 한계점이 존재한다. 둘째, 리뷰에 포함된 평점 정보를 텍스트의 마지막 단어로 간주하기 때문에 리뷰 텍스트와 평점 간의 상호작용이 제한적이라는 한계가 존재한다. 본 연구에서 제안하는 CNN-RHP 모델은 기존 연구에서 평점 정보의 표현 수용력이 손실되는 문제점을 개선하기 위해 리뷰 텍스트와 평점 정보를 개별적으로 임베딩 벡터로 변환하였다. 특히, 리뷰 텍스트에 포함된 의미론적 특성을 효과적으로 추출하기 위해 자연어 처리 분야에서 우수한 성능을 나타내고 있는 multi-channel CNN 모델을



(Figure 1) CNN-RHP Framework

적용하였다(Li et al., 2021). Multi-channel CNN 모델은 리뷰 텍스트에 포함된 다양한 길이의 특성을 효과적으로 추출하여 하나의 특성 벡터로 결합하여 출력한다. 또한, 평점 정보의 손실을 방지하고 표현 수용력을 확대하기 위해 평점 정보를 고차원 특성 벡터로 변환하였다. 본 연구에서 CNN-RHP 모델은 기존 연구에서 리뷰 텍스트와 평점 정보 간의 상호작용의 표현 수용력이 제한되는 한계점을 극복하기 위해 리뷰 텍스트와 평점 정보의 특성 벡터 간의 선형관계를 바탕으로 상호작용을 효율적으로 학습하였다.

### 3. CNN-RHP 프레임워크

본 연구는 기존 연구에서 리뷰 텍스트와 평점 정보를 사용하여 리뷰 유용성을 예측할 때 평점 정보의 표현 수용력이 제한되거나 상호작용을 효과적으로 학습할 수 없는 한계점을 개선하기 위해 <Figure 1>과 같이 CNN-RHP 모델을 제안하였다. CNN-RHP 모델은 평점 정보의 손실을 방지하기 위해 리뷰 텍스트와 평점 정보를 독립적인 특성 벡터로 변환하였다. 리뷰 텍스트에 포함된 의미론적 특성을 효과적으로 추출하기 위해 multi-channel CNN을 사용하였다. 또한, 평점 정보의 표현 수용력을 효과적으로 표현하기 위해 평점 정보의 특성을 고차원 벡터로 변환하여 텍스트 특성 정보와 매핑하였다. 최종적으로 출력된 리뷰 텍스트와 평점 정보의 특성 벡터에 요소별 연산을 수행하여 리뷰 텍스트와 평점 정보

간의 상호작용 학습을 바탕으로 리뷰 유용성을 예측할 수 있다. 본 연구에서 제안하는 CNN-RHP 모델은 크게 Text Encoder, Rating Encoder, Text-Rating Interaction Layer와 Prediction Layer로 구성되었으며 각 네트워크의 구체적인 내용은 아래와 같다.

### 3.1. Text Encoder

리뷰 텍스트에 포함된 의미론적 특성을 효과적으로 추출하기 위해 자연어 처리 관련 연구에서 우수한 성능으로 주목받고 있는 multi-channel CNN을 적용하였다(van Dinter et al., 2021). 본 연구에서 적용한 multi-channel CNN은 다양한 크기의 필터를 활용하므로 리뷰 텍스트에 포함된 다양한 형태의 의미론적 특성을 효과적으로 추출하고 연산 과정에서 리뷰 텍스트 특성에 대한 정보 손실을 최소화할 수 있다(Chen et al., 2018). 이를 위해 리뷰 텍스트에 포함된 각 단어를 벡터 형태로 변환하는 과정이 필요하다. 본 연구에서는 텍스트 정보의 손실을 최소화하기 위해 임베딩 기법을 적용하여 리뷰 텍스트에 포함된 각 단어를 밀집 형태의 벡터로 표현하였다. 따라서 리뷰 텍스트는  $w \in R^{V \times D}$  형태로 표현할 수 있으며,  $V$ 는 리뷰 텍스트에 포함된 단어 개수를 나타내고  $D$ 는 임베딩 벡터 차원을 나타내고 있다. 이를 통해 다양한 크기의 필터를 적용하여 아래 식 (1)과 같이 리뷰 텍스트의 슬라이딩 윈도우에서 컨볼루션 연산을 수행한다.

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

여기서  $*$ 는 컨볼루션 연산자를 나타내고,  $x_{i:i+j-1}$ 와  $b_c$ 는 각각 필터 커널과 편향을 나

타내고 있다.  $f$ 는 ReLU 활성화 함수를 나타내고 있으며, 이는 Sigmoid와 Tanh 활성화 함수에 비해 기울기 소실(Gradient Vanishing) 문제를 효과적으로 개선하고 계산 복잡도(Computational Complexity)가 낮은 장점을 가지고 있기 때문에 널리 사용되고 있다(Liu et al., 2021). 필터  $w$ 는 각 리뷰 텍스트에 포함된 단어의 슬라이딩 윈도우에 적용되며, 따라서 특정 채널에서 추출된 특성은 식 (2)와 같이 하나의 특성 맵(Map)으로 정의할 수 있다.

$$c = [c_1, c_2, \dots, c_{N-j+1}] \quad (2)$$

다음으로 추출된 특성 맵은 맥스 풀링 레이어를 통과하여 특성 맵에서 최대 값을 추출하였다. 따라서  $m$  개 필터를 사용하는 경우  $m$  개 특성 맵이 추출되어 맥스 풀링 레이어에서  $m$  개 최대 값을 계산할 수 있다. 따라서 리뷰 텍스트에 포함된 특성은 식 (3)과 같이 특정 길이의 특성 벡터로 출력된다.

$$O = [o_1, o_2, \dots, o_m] \quad (3)$$

여기서  $O$ 는 리뷰 텍스트에서 추출한 특성을 나타내고 있다. 본 연구는 리뷰 텍스트와 평점 정보 간의 상호작용을 학습하기 위해 요소별 연산을 수행한다. 이를 위해 리뷰 텍스트와 평점 정보의 특성 벡터를 동일한 차원으로 변환해야 한다. 이는 리뷰 텍스트와 평점 정보 간의 상호작용이 특정 정보에 대한 편향을 방지하고 리뷰 텍스트와 평점 정보가 같은 수준의 표현 수용력을 나타낼 수 있는 장점을 가지고 있다. 따라서 출력된 리뷰 텍스트 특성 벡터에 새로운 은닉 레

이어를 추가하여 식 (4)와 같이 리뷰 텍스트 특성 벡터의 차원을 축소하였다.

$$\begin{aligned} \phi_{O_1}(O) &= f(W_{O_1}^T O + b_{O_1}), \\ &\dots \\ O' &= \phi_{O_L}(O_{L-1}) = f(W_{O_L}^T O_{L-1} + b_{O_L}) \end{aligned} \quad (4)$$

식 (4)에서  $\phi_{O_x}$ 는 리뷰 텍스트 특성 벡터의 차원을 축소하는 과정에서  $x$ 번째 레이어에 대한 매핑 함수를 나타내며,  $W_{O_x}$ ,  $b_{O_x}$ 와  $f$ 는 각각  $x$ 번째 레이어에 대한 가중치, 편향과 ReLU 활성화 함수를 나타내고 있다. 이에 따라 차원이 축소된 리뷰 텍스트 정보의 특성 벡터는  $O'$ 로 표현할 수 있다.

### 3.2. Rating Encoder

본 연구에서는 평점 정보에 포함된 특성을 효과적으로 추출하기 위해 고차원 특성 임베딩 벡터로 변환한다. 각 리뷰에 포함된 평점 정보는  $r \in R = \{1, 2, \dots, K\}$ 로 표현하며, 각 평점 정보는  $r \in \mathbb{R}^{|K|}$ 로 표현한다. Amazon.com에서 제공하는 서비스는 평점 정보가 5점 척도로 되어있기 때문에 평점 정보는  $r \in R = \{1, 2, 3, 4, 5\}$ 로 나타낸다. 따라서 임베딩 레이어에서는 평점 정보가  $m$  차원의 벡터로 매핑하여 평점 특성 벡터  $r' \in \mathbb{R}^{K \times m}$ 로 변환한다. 또한,  $K \times m$ 차원으로 되어있는 평점 특성 벡터는 스칼라 형태로 표현되는 기존 평점 정보에 비해  $m$ 배의 표현 수용력을 갖고 있다. 또한, 기존 평점 정보에 포함된 노이즈는 각 차원에 분산되어 있기 때문에 평점 정보를 특성 벡터로 변환하는 방법은 더 높은 강건성을 갖고 있는 장점이 있다(Du et al., 2020).

평점 특성 벡터는 리뷰 텍스트 특성 벡터와 요소별 연산을 수행하기 위해 리뷰 텍스트 특성 벡터와 동일한 차원으로 변환할 필요가 있다. 따라서 출력된 평점 특성 벡터를 식 (5)를 통해 리뷰 텍스트 특성 벡터와 동일한 차원으로 변환한다.

$$R' = \phi_{r'}(r) = f(W_{r'}^T r + b_{r'}) \quad (5)$$

식 (5)에서  $R'$ 은 리뷰 텍스트 특성 벡터와 동일한 차원으로 변환된 평점 특성 벡터를 나타낸다. 그리고  $\phi_{r'}$ ,  $W_{r'}$ 와  $b_{r'}$ 는 각각 평점 특성 벡터의 차원을 변환하는 과정에서 사용되고 있는 매핑 함수, 가중치와 편향을 나타낸다.

### 3.3. Text-Rating Interaction Layer

다음으로 출력된 리뷰 텍스트와 평점 정보의 특성 벡터 간의 상호작용을 학습하여 최종적으로 온라인 리뷰에 대한 유용성을 예측한다. 리뷰 텍스트와 평점 정보 간의 상호작용을 효과적으로 학습하기 위해 요소별 연산을 수행한다. 요소별 연산은 모델 학습에 사용되는 파라미터 수를 최소화하고 모델 학습 시간을 효과적으로 단축시키는 장점을 가지고 있다. 이와 같은 요소별 연산은 특성 벡터 간의 상호작용을 정교하게 학습하는데 널리 사용되고 있다(He et al., 2017). 본 연구의 맥락에서 리뷰 텍스트와 평점 정보 간의 상호작용은 식 (6)과 같이 정의할 수 있다.

$$H = O' \otimes R' \quad (6)$$

여기서  $\otimes$ 와  $H$ 는 각각 요소별 연산자와 상호작용 특성 벡터를 나타낸다.  $O'$ 는 식(4)에서 추

〈Table 1〉 An example of Amazon.com Dataset

Attribute	Value
Reviewer ID	AVVEA5AVWWU7Y
Product ID	971024952
Total number of votes	29
Number of helpful votes	26
Star rating	4
Review time	03 27, 2003
Reviewer name	D. Sippel "Rocker"
Summary headline	Solid effort from Moore
Review text	I wanted to address some of the criticisms of other reviewers. First of all, while the reproduction isn't top notch, and doesn't match the quality of the majority of TPB's, it is acceptable, and didn't diminish my enjoyment of the story.....

출한 리뷰 텍스트의 특성 벡터를 나타내고,  $R'$ 은 식(5)에서 추출한 평점 정보의 특성을 나타낸다.

### 3.4. Helpfulness Score Prediction Layer

최종적으로 상호작용 특성 벡터  $H$ 를 통해 식(7)과 같이 리뷰 유용성을 예측한다.

$$\hat{y} = \sigma(W_H \bullet H + b_H) \quad (7)$$

여기서  $W_H$ 와  $b_H$ 는 각각 리뷰 유용성 예측 과정에서 특성 벡터  $H$ 에 대해 사용되고 있는 가중치와 편향을 나타낸다.  $\sigma$ 는 Sigmoid 활성화 함수를 나타내며, 이는 계산된 리뷰 유용성 점수를 방탕으로 리뷰 유용성 여부를 분류할 때 사용된다. 즉, 최종 출력 값  $\hat{y}$ 는 특정 리뷰가 유용한지 여부를 0과 1사이의 확률 값으로 예측한다.

## 4. 실험

### 4.1 실험 데이터 및 평가지표

본 연구에서 제안한 CNN-RHP 모델의 예측 성능을 평가하기 위해 아마존에서 1996년 5월부터 2014년 7월까지 수집된 리뷰 데이터를 사용한다(Mudambi & Schuff, 2010; J. Park et al., 2012). 아마존은 세계 최대 전자상거래 플랫폼으로 방대한 양의 온라인 리뷰 데이터를 포함하고 있으며, 이를 활용한 연구가 다양한 분야에서 진행되고 있다(Ghose & Ipeirotis, 2010; Kim et al., 2006; Malik & Hussain, 2018). 본 연구의 실험에 사용한 온라인 리뷰 데이터는 <Table 1>과 같이 소비자 정보, 제품 정보, 유용성 투표 수 등 다양한 정보가 포함되어 있다. 본 연구에서는 리뷰 데이터 크기가 가장 큰 아마존 도서 카테고리에서 603,668명의 소비자가 367,928개의 제품에 대한 남긴 8,898,041개의 리뷰를 실험에 사용하

였다.

본 연구에서는 제안한 모델을 효율적으로 학습하기 위해 기존 연구에 따라 리뷰 유용성 투표 수가 10개 이상인 리뷰만 사용하였다(Tay et al., 2020). 리뷰 유용성 여부는 기존 연구의 전략을 바탕으로 유용한 투표 수를 전체 투표 수에 나눈 백분율을 바탕으로 계산되었다. 즉, 유용성 점수가 0.6보다 크면 유용한 리뷰로 분류하고, 0.6보다 작으면 유용하지 않은 리뷰로 분류하였다(Mitra & Jenamani, 2021; Yang et al., 2020). 모델 학습 과정에서 편향을 방지하기 위해 실험 단계에서는 유용한 리뷰와 유용하지 않은 리뷰를 각각 180,000개를 랜덤으로 선택하여 실험에 사용하였다. 전체 데이터에서 80%는 학습 데이터로 사용하고 나머지 20%는 성능 평가를 위한 검증 데이터로 사용하였다. 본 연구에서 제안한 모델의 성능을 평가하기 위해 기존 연구에서 널리 사용되는 Accuracy, Precision, Recall과 F1-Score를 사용하여 모델의 분류 성능을 평가하였다(Li et al., 2021; D. H. Park et al., 2012).

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (8)$$

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

$$Recall = \frac{TP}{TP + FN} \quad (10)$$

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (11)$$

여기서 Accuracy는 분류 성능을 평가할 때 널리 사용하고 있으며, 전체 분류 결과 중에서 유용한 리뷰와 유용하지 않은 리뷰를 정확하게 분류를 비율을 나타낸다. Precision와 Recall는 각각

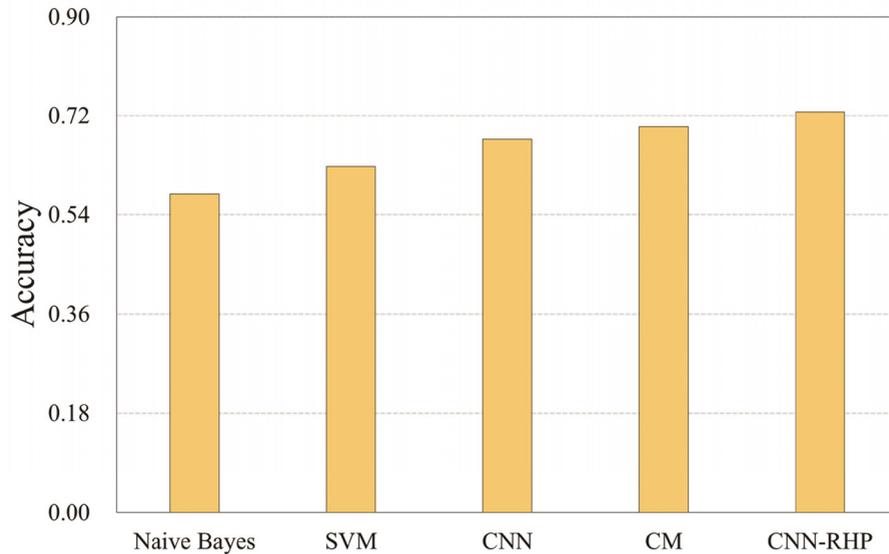
유용하다고 분류한 리뷰 중에서 실제 유용한 리뷰의 비율과 실제 유용한 리뷰 중에서 모델이 유용하다고 분류한 리뷰의 비율을 나타낸다. F1-Score는 Precision과 Recall의 조화 평균 값으로 계산된다.

## 4.2 실험 설계

본 연구에서는 실험에 사용되는 온라인 리뷰를 효율적으로 분석하기 위해 NLTK 패키지를 사용하여 리뷰 텍스트에 포함된 불용어, 특수 문자, 기호 및 숫자 등을 제거하였다. 또한, 제안한 CNN-RHP 모델이 성능을 효과적으로 평가하기 위해 기존 연구에서 우수한 성능을 나타내는 모델과 비교하였다. 리뷰 텍스트와 평점을 동시에 사용하여 우수한 성능을 보여준 CM 모델과 개별 리뷰 텍스트만을 사용하는 CNN 모델을 적용하여 성능을 비교하였다(Qu et al., 2018). 또한, 텍스트 분류 연구에서 널리 사용된 SVM(Support Vector Machine)과 Naive Bayes 모델을 적용하여 제안한 모델의 분류 성능을 다양한 측면에서 비교하였다(Mohammad et al., 2016). 모델 학습 과정에서 단어 임베딩 벡터를 300차원으로 설정하고, 필터 크기는 100으로 설정하였으며, 커널 사이즈는 각각 3, 4, 5로 설정하였다. 기존 연구의 전략에 따라 각 리뷰의 최대 길이의 90%로 고정하고 단어 크기는 40,000개로 설정하였다(Dong et al., 2020; Du et al., 2020). 모델 학습 과정에서 과적합 문제를 해결하기 위해 드롭아웃 레이어를 추가하였으며 비율은 0.4로 설정하였다. 최적화 알고리즘은 Adam을 적용하였으며 배치 크기는 256으로 설정하고 모델 학습을 수행하였다. 또한, 효율적으로 최적의 Epoch 횟수를 설정하기 위해 Early Stopping을 적용하였다(Du et al.,

〈Table 2〉 CNN-RHP Model Parameters

Parameters	Value
Dimension of the word vector	300
Number of words	40000
Size of the convolution kernel	3, 4, 5
Size of the feature map	100
Dropout	0.4
Optimizer	Adam
Early Stopping	10 epochs

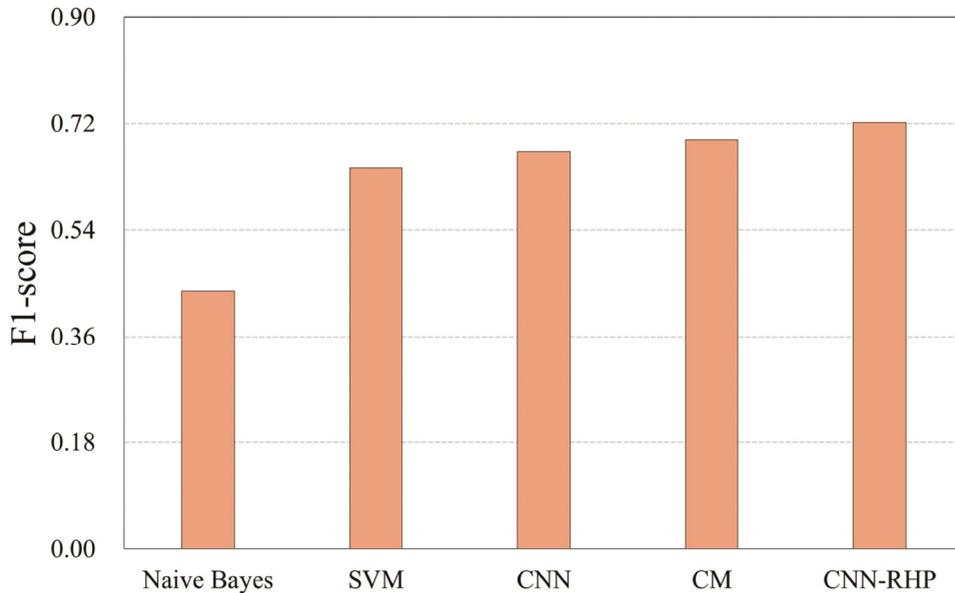


〈Figure 2〉 Accuracy of CNN-RHP and Benchmark Models

2021; Du et al., 2020). 본 연구의 실험에서 사용한 모델의 하이퍼파라미터는 <Table 2>와 같다. 본 연구에서는 TensorFlow 및 Keras 패키지를 사용하여 CPU Intel Core i9-900KF, 64GB RAM, GeForce RTX 2080 Ti 환경에서 실험을 수행하였다.

### 4.3 실험 결과

실험 결과에 따르면 본 연구에서 제안한 CNN-RHP 모델이 기존 연구에서 제안된 다양한 모델과 비교했을 때 우수한 예측 성능을 보여주고 있음을 확인했다(<Figure 2>와 <Figure 3> 참고). 구체적으로 <Table 3>과 같이 Accuracy 평가지표에서는



〈Figure 3〉 F1-score of CNN-RHP and Benchmark Models

〈Table 3〉 An Accuracy Percentage Change between CNN-RHP Model and Benchmark Models

Model		Accuracy	Percentage Change
Proposed	CNN-RHP	0.727	-
Benchmark	Naive Bayes	0.577	+26%
	SVM	0.629	+16%
	CNN	0.681	+6%
	CM	0.700	+3%

〈Table 4〉 An F1-score Percentage Change between CNN-RHP Model and Benchmark Models

Model		F1-score	Percentage Change
Proposed	CNN-RHP	0.722	-
Benchmark	Naive Bayes	0.436	+65%
	SVM	0.644	+12%
	CNN	0.672	+7%
	CM	0.692	+4%

예측 성능이 각각 3%(CM), 6%(CNN), 16%(SVM), 26%(Naive Bayes)만큼 개선되었다. F1-Score 평가지표에서는 <Table 4>와 같이 예측 성능이 각

각 4%(CM), 7%(CNN), 12%(SVM), 65%(Naive Bayes)만큼 개선되었다. 또한, CNN-RHP와 CM 모델처럼 리뷰 텍스트와 평점 정보를 모두 고려

하는 모델의 예측 성능은 리뷰 텍스트만 고려하는 CNN 모델에 비해 예측 성능이 더 우수함을 확인할 수 있다. 이는 리뷰 유용성을 예측할 때 리뷰 텍스트와 평점 정보를 결합하는 방법은 리뷰 유용성에 대한 예측 성능을 향상시킬 수 있음을 의미한다. 특히 리뷰 텍스트와 평점 정보 간의 상호작용은 리뷰 유용성 예측에 큰 영향을 미칠 수 있음을 확인할 수 있다. CM 모델은 평점 정보에 포함된 특성을 특성 벡터로 변화했기 때문에 리뷰 텍스트 정보와 암묵적 상호작용을 수행할 수 있다. 그러나 CM 모델은 본 연구에서 제안된 CNN-RHP 모델에 비해 예측 성능이 다소 감소되었음을 확인할 수 있다. 이는 평점을 리뷰 텍스트의 마지막 단어로 간주하였기 때문에 평점 정보가 손실되어 효과적으로 표현 수용력을 나타낼 수 없고 리뷰 텍스트와 평점 정보 간의 상호작용이 제한적으로 학습되는 한계점을 시사하고 있다. 또한 CNN 기반 모델의 예측 성능은 전통적인 머신러닝 모델에 비해 현저히 우수함을 확인할 수 있다. 이는 딥러닝 모델의 복잡한 신경망 구조는 리뷰에 포함된 특성을 효과적으로 추출할 수 있음을 의미한다.

따라서 본 연구의 결과는 리뷰 텍스트와 평점 정보 간의 상호작용 학습에 대한 중요성을 시사하고 있으며 이와 같은 상호작용은 리뷰 유용성의 예측 성능을 효과적으로 향상할 수 있다. 또한, 본 연구에서 제안한 CNN-RHP 모델은 기존 평점 정보에 대한 정보 손실 문제를 방지할 수 있고 리뷰 텍스트와 평점 정보 간의 상호작용을 효과적으로 학습하여 리뷰 유용성을 예측할 수 있는 장점을 가지고 있다. 이는 기존 리뷰 유용성 예측에 관한 연구에서 리뷰 텍스트와 평점 정보를 효과적으로 학습할 수 없었던 문제점을 개선하여 리뷰 유용성에 대한 예측 성능을 개선할

수 있음을 시사한다.

## 5. 결론

전자상거래의 발전에 따라 소비자의 구매 의사결정에 있어서 중요한 역할을 담당하고 있는 온라인 리뷰는 그 중요성이 더욱 커지고 있다. 하지만 온라인 소비자 수가 기하급수적으로 증가하고 이에 따라 제공되는 정보의 양이 방대해짐에 따라 소비자는 자신의 구매 의사결정에 필요한 정보를 탐색하는 데 어려움을 경험하고 있다. 이러한 문제를 개선하기 위해 온라인 전자상거래 기업은 소비자의 구매 의사결정을 돕기 위해 리뷰 유용성 투표 서비스를 제공하고 있다. 리뷰 유용성 정보는 소비자에게 구매 의사결정에 필요한 정보를 효과적으로 제공하고 있으나 오래전에 작성된 리뷰는 노출 횟수가 많아서 상대적으로 투표를 많이 받을 수 있는 반면, 최근에 작성된 리뷰는 소비자에게 노출 횟수가 적어서 대체로 투표수가 상대적으로 적거나 누락되는 문제점이 존재한다. 이러한 문제를 보완하기 위해서는 소비자의 구매 의사결정을 도움이 되는 맞춤형 온라인 리뷰를 자동적으로 예측하여 소비자에게 제공하는 것이 중요하다. 본 연구는 온라인 리뷰 텍스트와 평점 간의 상호작용을 효과적으로 학습하여 소비자 구매 의사결정에 필요한 리뷰를 자동으로 탐색하여 제공하는 CNN-RHP 모델을 제안하였다. 또한, 아마존에서 수집한 온라인 소비자 리뷰를 사용하여 제안한 모델을 평가한 결과 기존 연구에서 제안한 여러 모델에 비해 우수한 성능을 나타냄을 확인하였다. 본 연구의 결과를 요약하면 다음과 같다.

첫째, 기존 연구에서는 리뷰 평점을 텍스트의

마지막 단어로 간주하고 이를 결합한 벡터 특성을 통해 리뷰 유용성을 예측하였다. 이와 같은 방법은 평점 정보에 대한 표현 수용력이 제한적이기 때문에 리뷰 텍스트에 대한 평점의 영향력을 감소시킬 수 있다. 따라서 본 연구는 평점 정보의 표현 수용력을 효과적으로 나타내기 위해 리뷰 텍스트와 평점 정보를 독립적인 임베딩 벡터로 변환하여 리뷰 텍스트와 평점 간의 상호작용을 학습하여 우수한 예측 성능을 확인하였다. 이를 통해, 리뷰 평점 등과 같은 정량적인 정보에서 표현 수용력을 효과적으로 추출하기 위해서는 단순히 스칼라 표현보다 다차원의 벡터 특성 공간 형태로 표현하면 표현 수용력 측면에서 우수하다는 것 알 수 있다(Du et al., 2020; He et al., 2017). 둘째, 리뷰 텍스트와 평점 간의 상호작용을 학습할 때 기존 연구에서는 결합한 벡터 특성을 바탕으로 컨볼루션 연산을 수행하였다. 그러나 평점을 리뷰 텍스트의 마지막 단어로 간주하고 벡터 특성을 추출하기 때문에 평점 정보는 리뷰 텍스트에 포함된 모든 단어와 상호작용을 학습하는 데 한계가 존재한다. 따라서 본 연구는 리뷰 텍스트와 평점 정보를 개별적으로 임베딩 벡터로 변환하고 이를 바탕으로 요소별 연산을 수행하여 이들 간의 상호작용을 학습하였다. 이와 같은 방법은 평점 정보가 리뷰 텍스트에 포함된 모든 단어와 효과적으로 상호작용이 가능하다. 다시 말해, 리뷰 텍스트와 평점 정보의 일관성을 고려하여 리뷰 유용성을 판단하기 때문에 독립된 벡터 특성을 바탕으로 이들 간의 상호작용을 학습하는 것이 더욱 더 효과적이라는 것을 나타낸다(He et al., 2017).

본 연구의 학술적 의의는 다음과 같다. 첫째, 본 연구에서는 리뷰 텍스트와 평점 간의 일관성을 바탕으로 리뷰 유용성을 예측하는 CNN-RHP

모델을 제안했다. 기존 연구에서는 주로 리뷰 콘텐츠 정보를 사용하거나 리뷰 텍스트와 평점 정보를 단순히 결합하는 형태로 리뷰 유용성을 예측하였다. 이와 같은 방법은 도메인에 따라 사용하는 특성이 다르기 때문에 연산 비용이 높아지거나 평점 정보의 표현 수용력을 효과적으로 나타내지 못한다는 문제점이 존재한다. 온라인 소비자 리뷰에서 리뷰 텍스트와 평점 정보는 동일한 소비자가 자신의 구매 경험을 바탕으로 작성한 정성적, 정량적 정보이다. 따라서 소비자들은 온라인 리뷰의 유용성을 평가할 때 리뷰 텍스트와 평점 간의 정보가 일치하기를 바라며, 그렇지 않을 경우 해당 리뷰에 대한 유용성과 신뢰도가 감소할 수 있다. 따라서 본 연구는 이와 같은 리뷰 텍스트와 평점 간의 일관성을 고려하여 리뷰 유용성을 예측하는 새로운 모델을 제안하여 리뷰 유용성 예측 관련 연구를 확장하는데 기여하였다. 둘째, 리뷰 텍스트와 평점 정보 간의 상호작용을 효과적으로 학습하기 위해 요소별 연산을 바탕으로 이들 간의 선형관계를 확인하였다. 기존 연구에서는 평점을 리뷰 텍스트의 마지막 단어로 간주하고 벡터 형태로 결합하여 출력하였다. 이는 평점 정보가 리뷰 텍스트에 미치는 영향을 제한하기 때문에 이들 간의 상호작용을 효과적으로 학습하는데 한계가 존재한다. 본 연구에서는 리뷰 텍스트와 평점 정보를 개별적으로 임베딩 벡터로 변환하고 이들 간의 요소별 연산을 통해 상호작용을 효과적으로 학습하였다. 이는 리뷰 유용성 관련 연구에서 텍스트와 평점 정보 간의 상호작용을 학습할 수 있는 효과적인 접근법을 제시하였다.

본 연구의 실무적 시사점은 다음과 같다. 첫째, 전자상거래 사이트는 소비자가 온라인 리뷰를 평가할 수 있는 기존 유용성 투표 시스템을

대신하여 본 연구에서 제안한 모델을 바탕으로 소비자가 작성한 리뷰를 자동으로 평가하여 유용성을 예측할 수 있는 새로운 시스템을 도입할 필요성이 있다. 본 연구는 리뷰 텍스트와 평점 정보 간의 상호작용을 바탕으로 리뷰 유용성을 예측하였다. 실험 결과에 따르면 기존 연구에서 제안한 다양한 모델에 비해 예측 성능이 우수함을 확인할 수 있었다. 또한, 소비자가 작성한 리뷰의 유용성 점수가 높을 때 인센티브를 제공한다면 제품에 대한 리뷰의 가치를 높일 수 있다. 둘째, 본 연구에서 제안한 모델을 사용하여 온라인 리뷰와 평점 정보 간의 정교한 일관성을 바탕으로 이러한 문제점을 극복할 수 있다. 소비자가 작성한 온라인 리뷰에는 광고, 거짓 정보 등 소비자의 구매 의사결정에 영향을 미칠 수 있는 정보들이 포함되어 있다. 온라인 구매 환경에서 소비자는 이와 같은 리뷰를 참고하여 구매한 제품이 참고한 리뷰와 일치하지 않으면 제품 및 전자상거래 사이트에 대해 부정적인 인상을 받을 수 있다. 셋째, 기업은 단순히 온라인 리뷰의 개수를 늘리는데 집중하기보다 소비자들이 구매한 제품에 대하여 구체적으로 양질의 리뷰를 작성할 수 있도록 유도하는 전략을 고려할 필요성이 있다. 대부분의 전자상거래 기업은 온라인 리뷰 수를 증가시키는 데 중점을 두고 소비자들이 구매한 제품에 리뷰를 작성하도록 유도하기 위해 다양한 수단을 동원하였다. 그러나 소비자들이 임의적으로 작성한 최신 리뷰는 유용성 투표수가 적거나 누락되는 경우가 많기 때문에 구매 의사결정 과정에서 이를 참고하는 데 한계가 존재한다.

본 연구에서 제안한 CNN-RHP 모델은 기존 연구에서 제안한 여러 모델에 비해 우수한 성능을 나타내고 있지만 여전히 한계점들이 존재한

다. 첫째, 본 연구에서는 아마존에서 도서 리뷰 데이터를 사용하여 제안한 모델의 성능을 측정했지만 본 제안한 모델을 다른 분야에 적용하였을 때 동일한 결과가 나타나는지 검증할 필요성이 있다. 따라서 다른 분야의 온라인 리뷰 데이터를 추가하거나 여러 분야의 데이터를 하나로 통합시키는 방식으로 데이터를 추가하여 모델의 성능을 측정할 필요성이 있다. 둘째, 본 연구는 리뷰 텍스트와 평점의 선형 상호작용을 효과적으로 학습하기 위해 요소별 연산을 실행했다. 최근에는 어텐션 메커니즘(Attention Mechanism)을 활용하는 연구가 많이 발전되고 있다. 이는 특정 상호작용을 나타내는 것이 아니라 딥러닝 기반의 복합적인 구조로 되어있기 때문에 리뷰 텍스트와 평점의 상호작용을 추가로 탐색하여 학습할 수 있다. 이러한 어텐션 메커니즘을 도입한 추후 연구를 하여 모델의 성능을 향상할 수 있다. 셋째, 본 연구는 소비자에게 유용한 리뷰를 탐색하여 추천하는 것을 목적으로 연구했다. 본 연구에서 제안한 CNN-RHP 모델을 통해 탐색한 유용한 리뷰는 실제 온라인 구매 환경에서 리뷰 추천 성능을 향상할 수 있는지도 검증할 필요가 있다. 또한, 소비자에게 유용한 리뷰를 추천하는 기준을 투명하게 마련하면 소비자들이 의사결정 과정에서 해당 리뷰에 대한 신뢰성을 제고할 수 있다.

## 참고문헌(References)

- 이선영, 정남호, 양성병. (2019). 온라인 리뷰에서 이미지 효용성 결정요인에 관한 탐색적 연구: 음이항 모형 적용. *인터넷전자상거래연구*, 19(1), 93-113.

- 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, 이흠철, 김재경. (2021). CNN 기반 리뷰 유용성 점수 예측을 통한 개인화 추천 서비스 성능 향상에 관한 연구. *지능정보연구*, 27(3), 29-56.
- 박호연, 김경재. (2019). CNN-LSTM 조합모델을 이용한 영화리뷰 감성분석. *지능정보연구*, 25(4), 141-154.
- 전민진, 황지원, 김종우. (2021). CNN 보조 손실을 이용한 차원 기반 감성 분석. *지능정보연구*, 27(4), 1-22.
- Charrada, E. B. (2016). Which one to read? Factors influencing the usefulness of online reviews for RE. 2016 IEEE 24th International Requirements Engineering Conference Workshops, Beijing, China.
- Chen, H., Han, F. X., Niu, D., Liu, D., Lai, K., Wu, C., & Xu, Y. (2018). Mix: Multi-channel information crossing for text matching. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining (ACM 2018)*, 110-119.
- Diaz, G. O., & Ng, V. (2018). Modeling and prediction of online product review helpfulness: a survey. *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL 2018)*, 698-708.
- Dong, J., He, F., Guo, Y., & Zhang, H. (2020). A commodity review sentiment analysis based on BERT-CNN model. 2020 5th International Conference on Computer and Communication Systems, Coimbatore, India.
- Du, J., Rong, J., Wang, H., & Zhang, Y. (2021). Neighbor-aware review helpfulness prediction. *Decision Support Systems*, 148, 113581.
- Du, J., Zheng, L., He, J., Rong, J., Wang, H., & Zhang, Y. (2020). An interactive network for end-to-end review helpfulness modeling. *Data Science and Engineering*, 5(3), 261-279.
- Fan, M., Feng, Y., Sun, M., Li, P., Wang, H., & Wang, J. (2018). Multi-task neural learning architecture for end-to-end identification of helpful reviews. 2018 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, Barcelona, Spain.
- Fang, B., Ye, Q., Kucukusta, D., & Law, R. (2016). Analysis of the perceived value of online tourism reviews: Influence of readability and reviewer characteristics. *Tourism Management*, 52, 498-506.
- Ghose, A., & Ipeirotis, P. G. (2010). Estimating the helpfulness and economic impact of product reviews: Mining text and reviewer characteristics. *IEEE Transactions on Knowledge and Data Engineering*, 23(10), 1498-1512.
- Han, Q., Kou, Y., & Snaidauf, D. (2019). Experimental Evaluation of CNN Parameters for Text Categorization in Legal Document Review. 2019 IEEE International Conference on Big Data, Los Angeles, USA.
- 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 (WWW 2017)*, 173-182.
- Hoffait, A.-S., Ittoo, A., & Schyns, M. (2018). Assessing and predicting review helpfulness: Critical review. 29ème Conférence Européenne Sur La Recherche Opérationnelle, Valence,

- Spain.
- Huang, A. H., Chen, K., Yen, D. C., & Tran, T. P. (2015). A study of factors that contribute to online review helpfulness. *Computers in Human Behavior*, 48, 17-27.
- Jones, Q., Ravid, G., & Rafaeli, S. (2004). Information overload and the message dynamics of online interaction spaces: A theoretical model and empirical exploration. *Information Systems Research*, 15(2), 194-210.
- Kim, S.-M., Pantel, P., Chklovski, T., & Pennacchiotti, M. (2006). Automatically assessing review helpfulness. *Proceedings of the 2006 Conference on Empirical Methods in Natural Language Processing (EMNLP 2006)*, 423-430.
- Kim, Y. (2014). Convolutional Neural Networks for Sentence Classification. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP 2014)*, 1746-1751.
- Kim, Y., Jernite, Y., Sontag, D., & Rush, A. M. (2016). Character-aware neural language models. Thirtieth AAAI Conference on Artificial Intelligence, Phoenix, USA.
- Li, Q., Li, X., Lee, B., & Kim, J. (2021). A hybrid CNN-based review helpfulness filtering model for improving e-commerce recommendation Service. *Applied Sciences*, 11(18), 8613.
- Liu, J., Cao, Y., Lin, C.-Y., Huang, Y., & Zhou, M. (2007). Low-quality product review detection in opinion summarization. Proceedings of the 2007 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning (EMNLP-CoNLL 2007), 334-342.
- Liu, Z., Yuan, B., & Ma, Y. (2021). A multi-task dual attention deep recommendation model using ratings and review helpfulness. *Applied Intelligence*, 52(5), 1-13.
- Malik, M., & Hussain, A. (2018). An analysis of review content and reviewer variables that contribute to review helpfulness. *Information Processing & Management*, 54(1), 88-104.
- Mitra, S., & Jenamani, M. (2021). Helpfulness of online consumer reviews: A multi-perspective approach. *Information Processing & Management*, 58(3), 102538.
- Mohammad, A. H., Alwada'n, T., & Al-Momani, O. (2016). Arabic text categorization using support vector machine, Naive Bayes and neural network. *GSTF Journal on Computing*, 5(1), 1-8.
- Mudambi, S. M., & Schuff, D. (2010). Research note: What makes a helpful online review? A study of customer reviews on Amazon. com. *MIS Quarterly*, 34(1), 185-200.
- Park, D. H., Kim, H. K., Choi, I. Y., & Kim, J. K. (2012). A literature review and classification of recommender systems research. *Expert Systems with Applications*, 39(11), 10059-10072.
- Park, J., Gu, B., & Lee, H. (2012). The relationship between retailer-hosted and third-party hosted WOM sources and their influence on retailer sales. *Electronic Commerce Research and Applications*, 11(3), 253-261.
- Qu, X., Li, X., & Rose, J. R. (2018). Review helpfulness assessment based on convolutional neural network. *arXiv preprint arXiv:1808.09016*.
- Quaschnig, S., Pandelaere, M., & Vermeir, I. (2015). When consistency matters: The effect of valence consistency on review helpfulness. *Journal of Computer-Mediated Communication*,

- 20(2), 136-152.
- Salehan, M., & Kim, D. J. (2016). Predicting the performance of online consumer reviews: A sentiment mining approach to big data analytics. *Decision Support Systems, 81*, 30-40.
- Saumya, S., Singh, J. P., & Dwivedi, Y. K. (2020). Predicting the helpfulness score of online reviews using convolutional neural network. *Soft Computing, 24*(15), 10989-11005.
- Siering, M., Muntermann, J., & Rajagopalan, B. (2018). Explaining and predicting online review helpfulness: The role of content and reviewer-related signals. *Decision Support Systems, 108*, 1-12.
- Tay, W., Zhang, X., & Karimi, S. (2020). Beyond mean rating: Probabilistic aggregation of star ratings based on helpfulness. *Journal of the Association for Information Science and Technology, 71*(7), 784-799.
- van Dinter, R., Catal, C., & Tekinerdogan, B. (2021). A Multi-Channel Convolutional Neural Network approach to automate the citation screening process. *Applied Soft Computing, 112*, 107765.
- Yang, S., Yao, J., & Qazi, A. (2020). Does the review deserve more helpfulness when its title resembles the content? Locating helpful reviews by text mining. *Information Processing & Management, 57*(2), 102179.
- Yang, Y., Yan, Y., Qiu, M., & Bao, F. (2015). Semantic analysis and helpfulness prediction of text for online product reviews. *Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics (ACL 2015)*, 38-44
- Yin, D., Bond, S. D., & Zhang, H. (2014). Anxious or angry? Effects of discrete emotions on the perceived helpfulness of online reviews. *MIS Quarterly, 38*(2), 539-560.
- Yin, D., Mitra, S., & Zhang, H. (2016). Research note—When do consumers value positive vs. negative reviews? An empirical investigation of confirmation bias in online word of mouth. *Information Systems Research, 27*(1), 131-144.

Abstract

## A multi-channel CNN based online review helpfulness prediction model

Xinzhe Li\* · Hyorim Yun\*\* · Qinglong Li\*\*\* · Jaekyeong Kim\*\*\*\*

Online reviews play an essential role in the consumer's purchasing decision-making process, and thus, providing helpful and reliable reviews is essential to consumers. Previous online review helpfulness prediction studies mainly predicted review helpfulness based on the consistency of text and rating information of online reviews. However, there is a limitation in that representation capacity or review text and rating interaction. We propose a CNN-RHP model that effectively learns the interaction between review text and rating information to improve the limitations of previous studies. Multi-channel CNNs were applied to extract the semantic representation of the review text. We also converted rating into independent high-dimensional embedding vectors representing the same dimension as the text vector. The consistency between the review text and the rating information is learned based on element-wise operations between the review text and the star rating vector. To evaluate the performance of the proposed CNN-RHP model in this study, we used online reviews collected from Amazon.com. Experimental results show that the CNN-RHP model indicates excellent performance compared to several benchmark models. The results of this study can provide practical implications when providing services related to review helpfulness on online e-commerce platforms.

**Key Words** : Online Reviews, Review Helpfulness, Review Text, Multi-channel CNN

Received : June 1, 2022 Revised : June 17, 2022 Accepted : June 18, 2022

Corresponding Author : Qinglong Li

---

\* Department of Big Data Analytics, Kyung Hee University

\*\* College of Hotel and Tourism School of Hospitality Management, Kyung Hee University

\*\*\* Corresponding author: Qinglong Li

Department of Big Data Analytics, Kyung Hee University

26, Kyungheedaero Dongdaemun-gu, Seoul 02447, Korea

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

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

## 저자 소개



### 이 흠철

경희대학교 대학원 빅데이터응용학과 석사과정에 재학 중이며, 주요 연구 관심 분야는 추천시스템, 딥러닝, 자연어 처리 및 빅데이터에 분석 등이다.



### 윤 효림

경희대학교 호텔관광대학 Hospitality 경영학부에 재학 중이며, 주요 관심 분야로는 추천 시스템, 빅데이터 분석, 딥러닝, 데이터마이닝, 스마트 투어리즘 등이다.



### 이 청용

경희대학교 경영학과에서 경영학 학사학위를 취득하고, 동 대학원 빅데이터응용학과에서 공학 석사학위를 취득하였다. 현재 빅데이터응용학과 박사과정에 재학 중이며, 주요 관심 분야로는 개인화 추천 서비스, 자연어 처리, 데이터 마이닝, 빅데이터 분석, 딥러닝 등이다.



### 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, 추천시스템, 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.