

# XAI 기법을 이용한 리뷰 유용성 예측 결과 설명에 관한 연구\*

류동엽

경희대학교 빅데이터 응용학과  
(spes040@khu.ac.kr)

이희철

경희대학교 빅데이터 응용학과  
(lixz@khu.ac.kr)

김재경

경희대학교 경영대학 & 빅데이터 응용학과  
(jaek@khu.ac.kr)

정보통신 기술의 발전에 따라 웹 사이트에는 수많은 리뷰가 지속적으로 게시되고 있다. 이로 인해 정보 과부하 문제가 발생하여 사용자들은 본인이 원하는 리뷰를 탐색하는데 어려움을 겪고 있다. 따라서, 이러한 문제를 해결하여 사용자에게 유용하고 신뢰성 있는 리뷰를 제공하기 위해 리뷰 유용성 예측에 관한 연구가 활발히 진행되고 있다. 기존 연구는 주로 리뷰에 포함된 특성을 기반으로 리뷰 유용성을 예측하였다. 그러나, 예측한 리뷰가 왜 유용한지 근거를 제시할 수 없다는 한계점이 존재한다. 따라서 본 연구는 이러한 한계점을 해결하기 위해 리뷰 유용성 예측 모델에 eXplainable Artificial Intelligence(XAI) 기법을 적용하는 방법론을 제안하였다. 본 연구는 Yelp.com에서 수집한 레스토랑 리뷰를 사용하여 리뷰 유용성 예측에 관한 연구에서 널리 사용되는 6개의 모델을 통해 예측 성능을 비교하였다. 그 다음, 예측 성능이 가장 우수한 모델에 XAI 기법을 적용하여 설명 가능한 리뷰 유용성 예측 모델을 제안하였다. 따라서 본 연구에서 제안한 방법론은 사용자의 구매 의사결정 과정에서 유용한 리뷰를 추천할 수 있는 동시에 해당 리뷰가 왜 유용한지에 대한 해석을 제공할 수 있다.

**주제어** : 리뷰 유용성, 머신러닝, 온라인 구전, 온라인 리뷰, eXplainable Artificial Intelligence(XAI)

논문접수일 : 2022년 11월 10일    논문수정일 : 2022년 12월 9일    게재확정일 : 2022년 12월 14일  
원고유형 : 학술대회 Fast Track    교신저자 : 김재경

## 1. 서론

최근 정보통신 기술의 발전과 소셜 미디어의 등장은 온라인 구전의 개념을 탄생시켰다(Fader & Winer, 2012; Zhu et al., 2014). 그 중 온라인 리뷰는 온라인 구전의 대표적인 형태이며, 사용자 행동에 큰 변화를 불러일으켰다(Cantallops & Salvi, 2014). 제품 및 서비스를 사용하기 전 사용자는 다른 사용자가 작성한 온라인 리뷰에서 이전 구매에 대한 정보를 탐색한다(Choi & Leon, 2020). 또한, 온라인 리뷰는 사용자의 경험을 반영

하고 제품이나 서비스 제공자가 제공하는 정보와 비교했을 때 더 신뢰할 수 있으므로 사용자의 구매 의사결정에 도움을 준다(Sun et al., 2019; Zhou et al., 2022). Fullerton (2017)에 따르면 사용자의 82%는 제품 및 서비스에 대한 구매 의사 결정 전에 온라인 리뷰를 탐색하는 것으로 나타났다. 그러나, 웹 사이트에서 제공하는 수많은 리뷰는 정보 과부하 문제를 일으켜 사용자들이 원하는 리뷰 탐색을 어렵게 한다(Jones et al., 2004; Yin et al., 2014). 이러한 문제를 해결하기 위해 아마존(Amazon.com)과 같은 웹 사이트는 리뷰 유용성

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

투표 시스템을 도입하였다(이청용 등, 2021; 이병현 등, 2022). 예를 들어, 아마존은 사용자에게 “Was this review helpful?”이라는 질문에 예/아니오의 두 가지 반응 중 하나를 선택하게 하여 리뷰에 대한 유용성 투표를 누적한다(Krishnamoorthy, 2015). 그 다음으로, 유용성 투표를 많이 받은 리뷰를 사용자에게 추천한다(Kaushik et al., 2018; Ngo-Ye & Sinha, 2014). 그러나, 이러한 시스템은 리뷰 유용성 투표 수가 누적되기에는 많은 시간을 필요로 할 수 있으므로 최근에 작성된 리뷰는 오래 전에 작성된 리뷰에 비해 투표를 받을 기회가 제한적이라는 한계점이 존재한다(이흥철 등, 2022). 따라서 이러한 문제를 해결하기 위해 리뷰 유용성 예측에 관한 연구가 최근에 많이 진행되고 있다.

리뷰 유용성 예측은 사용자에게 유용하고 신뢰성 있는 리뷰를 제공하여 사용자의 구매 의사 결정에 도움이 되는 것을 목표로 한다. 기존의 리뷰 유용성 예측과 관련된 연구는 주로 리뷰의 언어적 특성, 사용자 정보 등의 리뷰 유용성에 영향을 미치는 특성을 탐색하고 이를 바탕으로 리뷰 유용성을 예측하였다(Malik, 2020; Zhang & Lin, 2018). 이러한 연구는 리뷰 유용성을 예측하기 위해 머신러닝 기법을 활용하였다. 머신러닝 기법은 온라인 리뷰의 유용성을 예측하고 추출하는데 사용되고 있으며, 전통적인 수동 콘텐츠 분석(Manual Content Analysis)과 비교했을 때 더 많은 정보를 탐색할 수 있고 예측 성능을 향상시킬 수 있다는 장점이 있다(Luo & Xu, 2019). 그러나, 머신러닝 모델이 예측한 개별 결과에 대해 각 특성이 미치는 영향력을 기반으로 해석하기 어렵다는 한계점이 존재한다(Muhamedyev et al., 2020). 이러한 한계점을 해결하기 위해 설명 가능한 인공지능(eXplainable Artificial Intelligence,

XAI)을 머신러닝 모델에 도입하는 연구가 활발히 진행되고 있다(Singh et al., 2022).

XAI 기법은 인간이 이해할 수 있는 영역 내에서 모델의 결과를 설명하는 것을 목표로 하는 기법이다(Jain et al., 2022). 일반적으로 머신러닝 모델의 결정이나 예측을 이해하기는 매우 어렵다(Rai, 2020). XAI 기법은 머신러닝 모델과 결합하여 의학, 보안, 금융 등의 여러 분야에 적용되고 있다. 그러나 리뷰 유용성 분석에 XAI 기법을 활용한 연구는 존재하지 않는다. 리뷰 텍스트는 사용자의 특정 제품이나 서비스에 대한 감성을 포함하며, 감성은 리뷰 유용성에 영향을 미칠 수 있다(Lu & Wu, 2019; Yang et al., 2020). 따라서, XAI 기법은 최근 머신러닝 모델에 적용되어 감성 분석 분야에서 많이 활용되고 있다(Fiok et al., 2021; Yang et al., 2020). 감성 분석은 제품, 브랜드 및 뉴스 등에 대한 사용자의 의견을 분석한다(Maks & Vossen, 2012). Kang et al. (2012)은 감성 단어 사전을 만들어 레스토랑 리뷰에 대해 감성 분석을 수행하였다. 또한, Fang and Zhan (2015)은 Amazon의 온라인 리뷰를 긍정/부정으로 분류하는 감성 분석을 진행하였다. 리뷰 텍스트에 포함된 사용자의 감성은 제품 및 서비스에 대한 특성을 반영할 수 있으므로 리뷰 유용성 평가 시 중요한 역할을 담당할 수 있다(Chua & Banerjee, 2016; Salehan & Kim, 2016). 따라서 본 연구는 리뷰 유용성 예측에 대한 해석을 제공하기 위해 XAI 기법을 리뷰 유용성 예측에 도입하였다.

XAI 기법을 활용한 기존 연구는 주로 전통적인 머신러닝 기법을 기반으로 진행되었다. 그러나 최근 딥러닝 기술 및 컴퓨팅 자원의 발전과 더불어 리뷰 유용성 예측에 관한 연구는 Convolutional Neural Network(CNN), Long Short-Term Memory(LSTM)과 같은 딥러닝 기법을 사용하였다(Mitra

& Jenamani, 2021). 딥러닝 기법은 인간의 생물학적 뇌가 문제를 해결하는 방식을 모방하여 컴퓨터가 계층적으로 특성을 학습하는 기법이다 (Jain et al., 1996). 딥러닝 기법은 전통적인 머신러닝 기법에 비해 더 복잡한 개념이나 특성을 추출할 수 있으며, 다양한 비선형(Non-Linear)문제를 해결할 수 있다(Ma et al., 2018).

따라서 리뷰 유용성에 대한 예측 성능을 향상시키고 예측 결과에 대한 해석을 제공하기 위해 본 연구는 리뷰 유용성 예측 모델에 XAI 기법을 적용하는 방법론을 제안한다. 우선 리뷰 유용성 예측에 적합한 모델을 선정하기 위해 리뷰 유용성 예측에 관한 연구에서 널리 사용되는 6개의 전통적인 머신러닝과 딥러닝 모델을 통한 예측 성능을 비교하였다. 그 다음, 예측 성능이 가장 우수한 모델에 XAI 기법을 적용하여 모델 예측 결과에 영향을 미친 단어들을 카테고리별로 분류하였다. 실험 단계에서는 예측 성능을 측정하기 위해 레스토랑 리뷰 웹사이트인 옐프(Yelp.com)에서 제공하는 58만 개의 사용자 리뷰를 사용하였다. 본 연구의 시사점은 다음과 같이 요약할 수 있다.

1. 본 연구는 리뷰 유용성에 대한 예측 성능을 향상시키기 위해 전통적인 머신러닝 모델 대신 딥러닝 모델을 활용하였다.
2. 본 연구는 XAI 기법을 적용하여 리뷰 유용성을 예측하는 동시에 리뷰 유용성에 대한 해석을 제공할 수 있다.
3. 본 연구는 정보 과부하 문제를 해결할 수 있으며, 다양한 웹 사이트에 적용되어 리뷰 유용성 예측 서비스를 제공할 수 있다.

본 연구의 나머지 구성은 다음과 같다. 제 2장에서는 리뷰 유용성 및 XAI 기법 관련 연구를

설명한다. 제 3장에서는 제안하는 설명 가능한 리뷰 유용성 예측 모델 프레임워크와 실험데이터, 그리고 평가 지표에 대해 설명한다. 제 4장에서는 실험 결과에 대해 자세하게 설명한다. 마지막으로 제 5장에서는 결론, 시사점 그리고 한계점 및 추후 연구 계획에 대해 설명한다.

## 2. 관련 연구

### 2.1. 리뷰 유용성 예측

리뷰 유용성은 제품의 판매와 밀접한 관계를 갖기 때문에 사용자의 온라인 리뷰와 관련된 특성 중 가장 중요하다(Malik & Hussain, 2018). 특히나, 제품 페이지에 게시된 유용한 리뷰는 제품 판매에 긍정적인 영향을 미칠 수 있다(Kaushik et al., 2018). 온라인 리뷰 유용성을 예측하기 위해 리뷰의 양적 및 질적 특징, 사용자 정보 등 리뷰에 포함된 다양한 특성을 활용한 방법론이 제안되었다(Malik, 2020; Qazi et al., 2016). 이러한 연구는 주로 리뷰에 포함된 다양한 특성을 기반으로 리뷰 유용성을 예측할 수 있는 전통적인 머신러닝 기법을 활용하였다. Malik (2020)은 리뷰의 언어적 특성, 가독성, 제품 정보 등의 특성을 활용하여 리뷰에 대한 유용성을 예측할 수 있는 방법론을 제안하였다. 이러한 방법론은 리뷰 유용성 예측 성능을 측정하기 위해 Multivariate Adaptive Regression(Musto et al.), Random Forest, Classification And Regression Tree(CART) 등 다양한 전통적 머신러닝 모델을 사용하였다. 실험 결과, 제품 정보 특성은 다른 특성에 비해 예측 성능에 가장 큰 영향을 미치는 것으로 나타났다. 또한, Singh et al. (2017)은 리뷰의 감성, 문장의 독해 난이도,

가독성과 같은 언어적 특성을 사용하여 Gradient Boosting 모델 기반 방법론을 제안하였다. 여기서 리뷰의 감성은 SentiWordNet을 이용하여 도출한 긍정 점수와 부정 점수의 차이를 사용하였으며, 문장의 독해 난이도는 Dale-Chall 공식을 사용하여 집계하였다. 또한, 가독성은 Flesch Reading Ease 공식을 활용하여 도출하였다. 실험 결과, 문장 내 어려운 단어 개수와 리뷰의 감성은 리뷰 유용성 예측에 가장 큰 영향을 미침을 확인할 수 있다. Lee et al. (2021)은 환대 산업군(Hospitality Industry)에서 리뷰 유용성에 영향을 미치는 요인을 탐색하기 위해 연구를 진행하였다. 여기서 레스토랑 리뷰 데이터를 활용하여 Linear Regression, Random Forest, Support Vector Machine(SVM), eXtreme Gradient Boosting(XGBoost)의 4가지 예측 모델을 기반으로 리뷰 유용성을 예측하였다. 실험 결과 사용자의 친구 수, 사용자가 게시한 리뷰 수, 계정 생성 후 경과된 기간과 같은 사용자 정보 특성이 리뷰 유용성 예측에 큰 영향을 미칠 수 있음을 확인하였다. 이러한 연구는 리뷰 사용자 정보, 리뷰에 포함된 특성, 그리고 제품 정보 특성과 같은 다양한 특성을 기반으로 리뷰 유용성을 예측하였다. 그러나 이러한 연구는 특성 간 높은 상관관계로 인해 다중 공선성 문제가 발생할 수 있다(Chan et al., 2022). 또한 사용할 특성의 수가 증가함에 따라 노이즈가 특성 공간(Feature Space)에 도입되는 문제가 존재하기 때문에 모델의 예측 성능이 제한될 수 있다. 따라서, 최근에는 리뷰 유용성을 더 효과적으로 예측하기 위해 리뷰 텍스트 정보를 기반으로 한 딥러닝 기법이 활발히 제안되고 있다.

CNN과 같은 딥러닝 기법은 리뷰 텍스트에 속한 잠재적 특성을 추출할 수 있다. 이러한 딥러닝 기법은 단어 임베딩(Word Embedding)을 사용하여

전통적인 머신러닝 기법에 비해 안정적인 예측 성능을 제공할 수 있다(Sadiq et al., 2021). Olmedilla et al. (2022)은 CNN 모델을 활용하여 온라인 리뷰를 유용한 리뷰, 중립적인 리뷰, 유용하지 않은 리뷰의 3가지 형태로 분류하였다. CNN은 텍스트 정보를 사용하여 온라인 리뷰의 복잡한 의미론적 특성을 효과적으로 추출할 수 있어 전통적인 머신러닝 기법에 비해 리뷰 유용성 예측 성능을 향상시킬 수 있다. Saumya et al. (2020)은 다양한 필터(Filter) 크기를 가진 Multi-channel CNN 모델을 통해 리뷰 유용성 점수를 예측하였다. 해당 연구에서 제안된 모델은 2개의 합성곱(Convolution Layer) 층으로 구성되어 있다. 해당 모델은 다양한 크기의 필터를 사용하여 리뷰 텍스트의 문맥적 위치(N-Gram) 정보를 효과적으로 학습할 수 있다. Mitra and Jenamani (2021)는 CNN과 LSTM 모델을 결합하여 리뷰 유용성을 예측할 수 있는 방법론을 제안하였다. CNN 층을 통해 리뷰 텍스트의 의미론적 관계를 추출하였고, LSTM 층으로 리뷰 내 단어의 순차적 관계를 학습하였다. LSTM 모델은 텍스트 문장 내 단어들 간의 순차적 연결 관계를 포착하여 리뷰 텍스트에 포함된 정보를 효과적으로 학습할 수 있다(Ma et al., 2018; Ren & Ji, 2017). 실험 결과, 해당 연구에서 제안된 방법론은 우수한 리뷰 유용성 예측 성능을 제공할 수 있다. 따라서 본 연구는 리뷰 유용성을 예측하기 위해 기존 연구에서 널리 사용되는 CNN, LSTM, CNN-LSTM 모델을 활용하여 예측 성능을 비교하였다.

## 2.2. 설명 가능한 인공지능(eXplainable Artificial Intelligence, XAI)

XAI 기법은 인공지능 모델의 의사결정 방식을

인간이 이해할 수 있게 설명하는 기법이다. 머신러닝은 높은 예측 성능을 제공할 수 있지만 예측 과정이나 방식에 대한 설명을 제공할 수 없는 블랙박스 모델이다(Handelman et al., 2019). 최근 머신러닝 모델이 다양한 분야에서 활용됨에 따라 의학, 보안, 금융 등의 분야에서는 머신러닝 모델의 의사 결정 방식을 이해하는 것에 대한 중요성이 커지고 있다(Arrieta et al., 2020). XAI 기법은 모델의 높은 예측 성능 유지와 동시에 인간이 이해할 수 있는 영역 내에서 모델의 예측 결과를 설명할 수 있다(Arrieta et al., 2020; Jain et al., 2022).

이러한 기법을 활용한 연구는 SHapley Additive exPlanations(SHAP)와 Local Interpretable Model-Agnostic Explanations(LIME)을 통해 머신러닝 모델의 예측 결과를 해석하는 데 중점을 두고 있다(Li, 2022). SHAP는 게임 이론에 기반하여 제안된 기법으로, 머신러닝 모델이 특정 결과를 얻었을 때 개별 특성의 기여도를 Shapley Value를 통해 정량화 할 수 있다(Štrumbelj & Kononenko, 2014). SHAP는 Shapley Value를 통해 특성 간 상호작용을 도출하여 특성의 기여도를 추출할 수 있어 예측 결과에 대한 해석을 제공할 수 있다(Dikshit & Pradhan, 2021). LIME은 머신러닝 모델의 개별 예측을 설명하는데 사용되는 기법이다(Aslam et al., 2022). LIME은 실험 데이터에 무작위로 특성을 제거하는 샘플링(Sampling) 작업을 수행하여 예측 모델을 통해 다시 예측한다. 이를 바탕으로 예측한 결과를 기존 예측 결과와의 차이를 통해 가중치를 부여한다(Linardatos et al., 2020). 따라서 LIME은 이러한 방식으로 데이터 내 특성들의 영향력을 간단하고 빠르게 확인할 수 있다.

최근에는 XAI 기법을 머신러닝 기법에 적용하여 감성 분석을 수행한 연구가 활발하게 진행되었다. Fiok et al. (2021)은 SHAP를 딥러닝 모

델에 적용하여 특성들의 중요도를 확인하였다. 해당 연구는 텍스트 내에서 언어적 특징 및 감정과 관련된 특성을 추출하였고, SHAP 분석 결과 감성 요소, 부정적 형용사의 2가지 특성이 모델 예측에 큰 영향을 미칠 수 있음을 확인하였다. Adak et al. (2022)은 다양한 딥러닝 모델을 통해 감성 분석을 수행하고 SHAP 및 LIME을 적용하여 개별 리뷰의 감성 예측에 영향을 준 단어를 탐색하였다. 감성 분석에는 LSTM, Bidirectional LSTM(Bi-LSTM), Bidirectional GRU-LSTM-CNN(Bi-GRU-LSTM-CNN)의 3가지 모델을 사용하였으며, 실험 결과 LSTM 모델의 성능이 가장 우수한 것을 확인할 수 있다. 그 다음으로, LSTM 모델에 SHAP 및 LIME을 통해 개별 리뷰의 모델 예측에 긍정적 또는 부정적인 영향을 미칠 수 있는 단어들을 확인할 수 있다.

본 연구는 리뷰 유용성을 예측하는 동시에 예측 결과에 대한 해석을 제공하기 위해 XAI기법을 딥러닝 모델에 적용할 수 있는 방법론을 제안하였다. 본 연구에서는 우수한 리뷰 유용성 예측 모델을 제공하기 위해 기존 연구에서 널리 사용되는 6개의 전통적인 머신러닝과 딥러닝 기법을 통해 예측 성능을 비교하였다. 그 다음, 예측 성능이 가장 우수한 모델에 SHAP와 LIME 기법을 적용하여 예측 결과에 대한 해석을 제공할 수 있다. 이러한 해석을 더 구체적으로 살펴보기 위해 본 연구는 리뷰 유용성 여부에 영향을 미칠 수 있는 단어를 도출하여 카테고리별로 분류하였다.

### 3. 제안 방법론

본 연구에서 제안하는 방법론은 아래 <그림 1>과 같다. 본 연구는 엘프에서 제공하는 레스토랑 리뷰 데이터를 사용하여 실험을 진행하였다. 엘프는

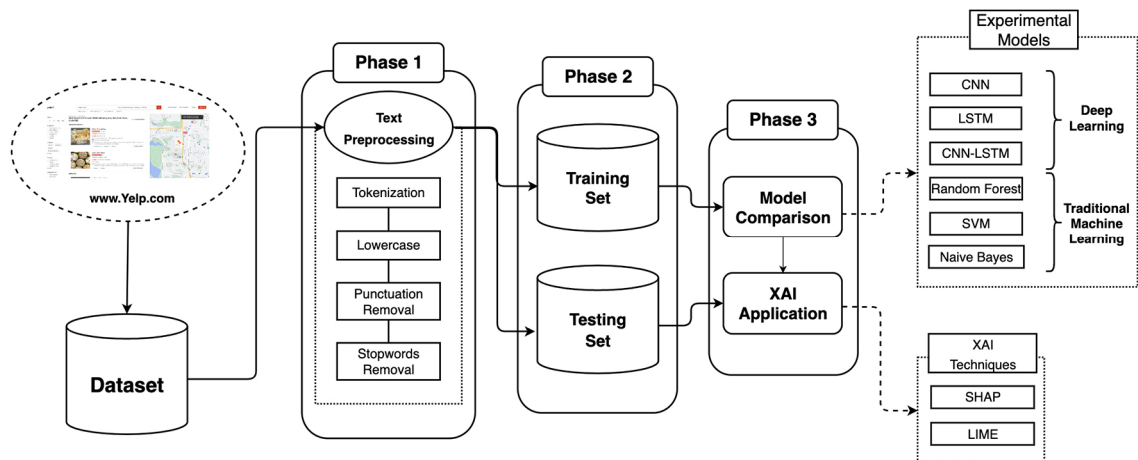
사용자들이 소셜 네트워크와 온라인 리뷰를 기반으로 지역 비즈니스 선택을 돕는 목적으로 2004년 설립되었다(Ariyasriwatana et al., 2014). 특히, 옐프에 게시된 수많은 레스토랑 리뷰는 사용자들의 식당 선택 의사결정에 큰 영향을 미치는 것으로 나타났다(Ariyasriwatana & Quiroga, 2016).

본 연구의 방법론은 3단계로 구성되어 있으며, 첫번째 단계에서는 실험 데이터에 포함된 리뷰 텍스트에 대해 단어 토큰화, 소문자 변환, 불용어 제거 등의 전처리 작업을 수행하였다. 다음으로 두번째 단계에서는 전처리된 실험 데이터를 8:2의 비율에 따라 훈련 및 검증 데이터로 분리하였다. 세번째 단계에서는 리뷰 유용성에 대한 예측 성능이 가장 우수한 모델을 설정하기 위해 기존 연구에서 널리 사용되는 Naive Bayes, SVM, Random Forest의 전통적인 머신러닝 모델과 CNN, LSTM, CNN-LSTM의 딥러닝 모델에 대해 예측 성능을 비교하였다. 마지막으로, 앞서 비교된 예측 성능이 가장 우수한 모델에 SHAP와 LIME 기법을 적용

하여 리뷰 유용성 예측 과정에서 영향을 미친 단어들을 별도로 추출하고 카테고리별로 분류하였다.

### 3.1. 실험 데이터

본 연구에서 제안된 방법론의 예측 성능 및 예측 결과에 대한 해석을 검증하기 위해 옐프에서 제공하는 옐프 오픈 데이터셋(Yelp Open Dataset)<sup>1)</sup>을 사용하였다. 해당 데이터셋은 미국 11개 대도시에서 수집한 약 700만개의 온라인 리뷰 데이터를 포함하고 있으며, 각 데이터는 <표 1>과 같이 리뷰 텍스트, 리뷰 평점, 그리고 리뷰 유용성 투표 수(Useful) 등의 다양한 정보가 포함되어 있다. 본 연구는 리뷰 유용성 예측 문제를 이진 분류 문제로 접근하였다. 즉, 리뷰에 포함된 정보를 기반으로 리뷰에 대한 유용성을 유용한 리뷰 및 유용하지 않은 리뷰로 분류하였다. 따라서 리뷰 유용성 여부를 분류하기 위해 리뷰 유용성 투표 수가 4 이상이면 유용한 리뷰로, 투표를 받지



〈그림 1〉 연구 방법론 프레임워크

1) <https://www.yelp.com/dataset>

못했으면 유용하지 않은 리뷰로 분류하였다(Bilal & Almazroi, 2022). 또한 유용한 리뷰와 유용하지 않은 리뷰 간 보다 명확한 구분을 위해 리뷰 유용성 투표 수가 1, 2, 3인 리뷰는 제외하였다. 그 다음으로, 리뷰 유용성에 대한 예측 편향을 방지하기 위해 유용한 리뷰와 유용하지 않은 리뷰를 각각 290,000개씩 무작위로 추출하였다.

〈표 1〉 옐프 데이터셋 예시

속성	데이터 값
User-ID	tCXElwhzekJEH6QJe3xs7Q
Business-ID	MTSW4McQd7CbVtyjqoe9mw
Categories	Restaurants, Food, Bubble Tea, Coffee & Tea, Bakeries
Useful	3
Review Text	This is the bakery I usually go to in Chinatown. They have a decent variety of buns and pastries. Red bean-filled buns, mung bean-filled buns, coconut stuff, egg tarts etc. If you buy a dozen, they will give you two more for free. The prices are standard for a Chinese bakery...

첫번째 단계에서는 실험 데이터에 포함된 리뷰 텍스트에 대해 NLTK 패키지를 사용하여 토큰화(Tokenization) 및 소문자 변환 작업을 수행하고 리뷰 텍스트에 포함된 특수문자, 기호, 그리고 불용어를 제거하였다. 두번째 단계에서는 전처리된 실험 데이터 중 80%를 훈련 데이터로 사용하고 나머지 20%는 리뷰 유용성 예측 성능 평가를 위한 검증 데이터로 사용하였다. 모델의 효과적인 학습을 위해 훈련 및 검증 데이터 내 유용한 리뷰와 유용하지 않은 리뷰의 비율은 1:1로 동일하게 설정하였다.

## 3.2. 모델 구축

### 3.2.1. 딥러닝 모델

본 연구에서는 리뷰 유용성을 예측하기 위해 CNN, LSTM, CNN-LSTM의 3가지 딥러닝 기법을 사용하였다. CNN 모델은 다양한 크기의 합성곱 필터(Convolutional Filter)를 활용하여 리뷰 텍스트의 의미론적 특성을 추출하고, 정보 손실을 최소화한다(Chen et al., 2018). 각 합성곱 필터는 단어 임베딩 형태로 표현된 개별 리뷰 텍스트에 대해 슬라이딩 윈도우(Sliding Window) 형식으로 아래 식 (1)과 같이 합성곱 연산을 수행한다.

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

위 식에서 \*는 합성곱 연산자를 나타내고,  $x_{i:i+j-1}$ 와  $b_c$ 는 각각 합성곱 필터와 편향(Bias)을 나타낸다.  $f$ 는 Rectified Linear Unit(ReLU) 활성화 함수(Activation Function)를 나타내며, 해당 함수는 Sigmoid 및 Hyperbolic Tangent(Tanh) 활성화 함수에 비해 기울기 소실(Gradient Vanishing) 문제를 효과적으로 해결한다(Ide & Kurita, 2017). 개별 합성곱 연산의 결과로 출력된 단일 특성 맵(Feature Map)은 식 (2)와 같이 정의할 수 있다.

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

다음으로, 각각의 특성 맵은 맥스 풀링 층(Max Pooling Layer)를 거쳐 특성 맵 요소 내 최대값을 추출하였고, 이를 연결 층(Concatenate Layer)을 통해 단일 리뷰 텍스트 특성 행렬  $H$ 로 통합하였다. 마지막으로, 리뷰 텍스트 특성 행렬을 사용하여 아래 식 (3)과 같이 리뷰 유용성을 예측하였다.

$$\hat{y} = \sigma(W_H \odot H + b_H) \quad (3)$$

$W_H$  및  $b_H$ 는 각각 리뷰 텍스트 특성 행렬  $H$ 에 대해 연산되는 가중치와 편향을 나타내며,  $\odot$ 는 성분별 곱(Element-Wise Product)을 의미한다.  $\sigma$ 는 Sigmoid 활성화 함수로써 계산된 리뷰 유용성 예측 확률에 대해 리뷰 유용성 여부를 최종적으로 분류할 때 사용한다. 따라서, 식 (3)의 결과로 출력되는 값  $\hat{y}$ 는 개별 리뷰가 유용한지 아닌지를 0 또는 1의 값으로 예측한다(주명길 등, 2019). 여기서 0은 유용하지 않은 리뷰를 나타내고 1은 유용한 리뷰를 나타낸다.

LSTM은 Recurrent Neural Network(RNN)의 장기 의존성 문제(Long-Term Dependency)를 해결하기 위해 고안된 모델로, 리뷰 텍스트 내 단어들 간의 긴 순차적 관계를 효율적으로 학습한다(박호연 등, 2019). LSTM 층은 입력 게이트(Input Gate), 망각 게이트(Forget Gate), 출력 게이트(Output Gate)의 3가지 게이트 및 셀 상태(Cell State)로 구성되어 있다. 각각의 게이트와 셀 상태는 단어 임베딩 표현을 시점별로 입력 받아 중요한 정보를 기억하고 불필요한 정보를 제거한다. 입력 게이트는  $x$ 를 입력 받아 현재 시점의 중요한 정보를 기억하는 역할을 한다. 다음으로, 망각 게이트는 입력 게이트와 동일하게  $x$ 를 입력 받아 불필요한 정보를 제거하며, 출력값이 0에 가까울수록 정보를 많이 제거한 것을 의미한다(Sherstinsky, 2020). 셀 상태는 이전 시점의 정보와 현재 시점의 정보를 얼마나 기억에 반영할지를 결정한다. 출력 게이트는 현재 시점의 셀 상태와 입력값을 입력 받아 현재 시점의 은닉 상태를 출력해 출력층으로 전달한다. LSTM 층이 단어 임베딩 표현  $x = (x_1, x_2, \dots, x_t)$ 를 입력 받아  $y = (y_1, y_2, \dots, y_t)$ 를 출력하는 식은 다음

과 같다(Sak et al., 2014).

$$\begin{aligned} i_t &= \sigma(x_t + W_{hi}h_{t-1} + b_i) \\ g_t &= \tanh(W_{xg}x_t + W_{hg}h_{t-1} + b_g) \\ f_t &= \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \\ C_t &= f_t \odot C_{t-1} + i_t \odot g_t \\ o_t &= \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \\ h_t &= o_t \odot \tanh(C_t) \\ y_t &= W_{ym}h_t + b_y \end{aligned} \quad (4)$$

$W$ 와  $b$ 는 가중치 행렬과 편향을 의미하며,  $\odot$ 는 성분별 곱을 의미한다.  $i_t$ 와  $g_t$ 는 입력 게이트,  $f_t$ 와  $o_t$ 는 각각 망각 게이트와 출력 게이트를 거쳐 도출된 확률값을 의미하며  $C_t$ 와  $h_t$ 는 각각 셀 상태와 은닉 상태를 의미한다. 마지막으로, LSTM 층을 거친 출력값  $y_t$ 는 식 (5)를 거쳐 각 리뷰의 유용성을 예측한다.

$$\hat{y} = \sigma(W_y \odot y_t + b_y) \quad (5)$$

CNN-LSTM은 위 CNN에서 연결층까지의 부분과 LSTM 층을 결합한 모델이다. 해당 모델은 리뷰 유용성 예측 과정에서 CNN의 리뷰 텍스트 내 의미론적 특성 추출과 동시에 LSTM의 리뷰 내 긴 순차적 관계를 학습할 수 있다(Wang et al., 2016). 본 연구에서는 CNN의 연결층까지의 연산을 통해 리뷰 텍스트 내 단어들의 지역적인 정보를 포착하였고, 이후 LSTM 층을 거쳐 리뷰 내 단어들의 긴 순차적 관계를 학습하였다. 마지막으로, LSTM 층에서 추출된 리뷰 텍스트 시퀀스는 식 (5)를 거쳐 개별 리뷰가 유용한지 아닌지를 0 또는 1의 값으로 예측한다.



### 3.2.2. 전통적인 머신러닝 모델

본 연구에서는 위에서 설명한 딥러닝 모델과의 리뷰 유용성 예측 성능 비교를 위해 기존 리뷰 유용성 예측에 널리 사용되는 Naive Bayes, SVM, Random Forest의 세 가지 전통적인 머신러닝 모델을 사용하였다. Naive Bayes는 베이즈 정리를 기반으로 텍스트 데이터를 분류하는 확률론적 기법이다. 리뷰 텍스트 내 각 단어는 서로 독립적이라고 가정하며, 각 리뷰의 유용성 여부에 대한 사전 확률과 관찰 정보, 리뷰 전체의 유용성 여부 분포 확률을 통해 도출된 사후 확률로 개별 리뷰의 유용성을 예측한다(Zhang & Gao, 2011).

SVM은 고차원 데이터에 대한 효과적인 모델 중 하나로 분류 예측에 널리 사용되는 기법이다(Vapnik, 1999). SVM은 각 리뷰 텍스트 입력을 선형적으로 분리하여 유용한 리뷰와 유용하지 않은 리뷰를 분리하며, 차원을 증가시키면서 두 클래스 간 효과적 분리를 위한 최적의 초평면(Hyperplane)을 찾는 작업을 수행한다(Kang et al., 2012).

Random Forest는 여러 개의 의사결정나무(Decision Tree)로 구성된 앙상블(Ensemble) 기법이며, 리뷰 텍스트 데이터를 부트스트랩(Bootstrap) 방식으로 여러 개의 하위 데이터셋을 생성한다(Lee et al., 2018). 다음으로, 개별 하위 데이터셋에 각 의사결정나무 모델을 학습시킨 후 모든 의사결정나무의 예측 결과를 결합하여 리뷰 유용성을 예측한다.

### 3.3. SHAP/LIME

본 연구에서는 위에서 제안한 딥러닝과 전통적인 머신러닝 모델의 리뷰 유용성 분류 성능을 비교한 다음, 가장 우수한 모델에 SHAP와 LIME 기법을 적용하여 개별 리뷰 예측에 영향을 미치는 단어들을 확인하였다. SHAP는 머신러닝 모델이

개별 리뷰의 유용성 예측에 대한 결과를 얻었을 때 각 단어들의 기여도를 정량화한 Shapley Value를 계산한다. 리뷰 내 특정 단어  $i$ 의 Shapley Value를 구하는 과정  $R(i)$ 는 아래 식 (6)과 같다.

$$R(i) = \sum_{S \subseteq P(i)} \frac{|S|!(P-|S|-1)!}{|P|!} [\hat{f}(S \cup \{i\}) - \hat{f}(S)] \quad (6)$$

$P$ 는 전체 단어 집합이며,  $S$ 는  $i$ 를 포함하는 단어 집합, 그리고  $\hat{f}(S)$ 는  $S$ 에 대한 모델의 예측을 의미한다. 또한,  $\hat{f}(S \cup \{i\})$ 는  $S$ 와  $i$ 를 모두 포함하는 집합에 대한 모델의 예측을 의미한다. SHAP를 통해 개별 리뷰 내 단어가 모델의 리뷰 유용성 예측에 기여하는 정도를 확인할 수 있다.

LIME은 로컬 대리 접근(Local Surrogate Approach) 방식으로 개별 리뷰 내 단어가 리뷰 유용성 예측에 미치는 영향력을 확인하는 기법이다(Kumar et al., 2021). LIME은 테스트 데이터에 대해 훈련 데이터로 학습된 모델의 예측 근사값을 구하고, 동일한 데이터에 무작위 샘플링 작업을 수행한다. 새로 생성된 데이터는 원본 데이터에서 단어가 무작위로 제거된 형태이며, 해당 데이터에 대한 모델의 새로운 예측 값과 기존 예측과의 차이를 통해 개별 단어에 가중치를 부여한다. LIME을 사용하여 모델을 설명하는 방식  $\xi(x)$ 는 아래 식 (7)과 같다.

$$\xi(x) = \underset{g \in G}{\operatorname{argmin}} L(f, g, \pi_x) + \Omega(g) \quad (7)$$

$f$ 와  $g$ 는 각각 데이터  $x$ 가 특정 범주에 위치할 확률과 해석 가능한 모델을 의미한다. 또한,  $\pi_x$ 와  $\pi(g)$ 는 데이터  $x$  주변의 지역성과 모델의 복잡도를 나타낸다. 따라서, LIME은 모델의 복잡도가 인간이 해석할 수 있을 만큼 충분히 낮으면서

$L(f, g, \pi_x)$ 를 최소화하는 설명을 제공하는 것을 목적으로 한다.

### 3.4. 평가 지표

본 연구에서 언급한 모델들의 리뷰 유용성 예측 성능 비교를 위해, 아래와 같은 4가지 평가 지표를 적용하였다. 해당 평가 지표를 계산하기 위해 <표 2>의 혼동 행렬(Confusion Matrix)이 사용되었다. Accuracy는 전체 분류 결과 중 유용한 리뷰와 유용하지 않은 리뷰를 정확하게 분류한 개수의 비율을 나타낸다. 또한, Precision은 모델이 유용하다고 예측한 리뷰 중 실제 유용한 리뷰에 속하는 비율이며, Recall은 실제 유용한 리뷰 중 모델이 유용하다고 예측한 리뷰의 비율을 나타낸다. 마지막으로, F1-Score는 Precision과 Recall의 결과를 조화 평균하여 모델의 성능을 평가한다. 아래 식 (8) ~ 식 (11)은 각각의 평가 지표를 구하는 수식을 나타낸다.

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

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

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

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

## 4. 실험 결과

### 4.1. 리뷰 유용성 예측 성능 비교

본 연구는 앞서 분리한 훈련 데이터로 모델을 학습시킨 다음, 검증 데이터에 대해 리뷰 유용성 예측 성능을 비교하였다. 본 연구에서는 리뷰 유용성 예측 성능을 비교하기 위해 6개의 전통적인 머신러닝 모델과 딥러닝 모델을 사용하였다. 실험에는 전통적인 머신러닝 모델 중 Random Forest, SVM, Naive Bayes의 3가지 모델을 사용하였고, 딥러닝 모델은 CNN, LSTM, CNN-LSTM을 사용하였다. 실험 결과, LSTM 모델의 리뷰 유용성 예측 성능이 다른 모델과 비교했을 때 가장 우수한 것을 확인하였다. 구체적으로는 Accuracy

<표 2> 혼동 행렬

		모델 예측 값	
		유용하다	유용하지 않다
실제 값	유용하다	TP	FN
	유용하지 않다	FP	TN

<표 3> 리뷰 유용성 예측 성능 비교

모델		Accuracy	Accuracy 증감율	F1-Score	F1-Score 증감율
딥러닝	LSTM	0.774	-	0.770	-
	CNN-LSTM	0.769	+ 0.7%	0.762	+ 1.1%
	CNN	0.762	+ 1.6%	0.762	+ 1.1%
전통적인 머신러닝	Random Forest	0.736	+ 5.2%	0.723	+ 6.5%
	Naive Bayes	0.592	+ 30.7%	0.346	+ 123.5%
	SVM	0.501	+ 54.5%	0.667	+ 15.4%

평가 지표에서는 LSTM 모델의 예측 성능이 각각 0.7%(CNN-LSTM), 1.6%(CNN), 5.2%(Random Forest), 30.7%(Naïve Bayes), 54.5%(SVM)만큼 더 우수한 것으로 나타났다. F1-Score 평가 지표에서는 LSTM 모델의 예측 성능이 각각 1.1%(CNN-LSTM, CNN), 6.5%(Random Forest), 123.5%(Naïve Bayes), 15.4%(SVM)만큼 더 우수한 것으로 나타났다.

이는 LSTM이 리뷰 텍스트의 단어 임베딩 표현 간 긴 순차적 관계를 잘 포착하고 장기 의존성 문제를 해결했기 때문이다(Behera et al., 2021). 또한, LSTM은 CNN 및 CNN-LSTM에 비해 우수한 예측 성능을 보이는 것을 확인하였다. 이는 CNN 기반 딥러닝 모델은 리뷰 내 모든 단어 표현을 Sliding Window 방식으로 학습하지만, LSTM은 선택적으로 중요한 정보와 불필요한 정보를 구분하기 때문이다. 즉, LSTM이 CNN 구조를 포함하는 모델에 비해 중요한 정보만을 선택적으로 기억하므로 예측 성능 및 시간 복잡도 측면에서 우수함을 의미한다. 또한, 딥러닝 모델의 예측 성능은 전통적인 머신러닝 모델과 비교했을 때 현저히 우수한 성능을 보이는 것을 확인하였다. 이는 딥러닝 모델이 전통적인 머신러닝 모델에 비해 리뷰 텍스트 내 잠재된 특성을 안정적으로 추출할 수 있음을 의미한다. 따라서 딥러닝 모델은

전통적인 머신러닝 모델에 비해 리뷰 유용성 예측 성능을 향상시킬 수 있음을 제시할 수 있다.

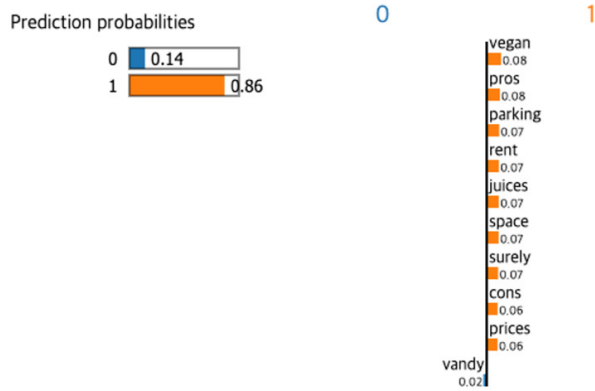
#### 4.2. SHAP/LIME을 적용한 리뷰 내 단어 카테고리별 분류

다음으로, 리뷰 유용성 예측 성능이 가장 우수한 LSTM에 SHAP와 LIME 기법을 적용하여 모델 예측에 영향을 미친 단어들을 확인하였다. 아래 <그림 2>는 LSTM 모델이 유용하다고 예측한 리뷰와 리뷰 내 단어 별 영향력에 대한 SHAP의 설명을 나타낸다. 빨간색과 파란색으로 표시된 단어는 각각 모델이 해당 리뷰가 유용하다 또는 유용하지 않다고 예측하는데 영향을 미친다. SHAP는 ‘prices’, ‘space’, 그리고 ‘parking’와 같은 단어가 해당 리뷰를 유용하다고 판단하는데 큰 영향을 미쳤음을 설명하였다. 또한, <그림 3>은 동일한 리뷰에 대한 LIME의 설명을 나타내며, ‘vegan’, ‘parking’, ‘juices’와 같은 단어는 모델이 해당 리뷰를 유용하다고 판단할 확률을 높였음을 나타낸다. 실험 결과, SHAP와 LIME은 동일한 리뷰에 대해 LSTM 모델의 리뷰 유용성 예측에 영향을 미치는 단어들을 비슷하게 제시함을 확인할 수 있다. 따라서, 본 연구는 SHAP와 LIME이 리뷰 유용성 예측에 영향을 미칠 수 있는 단어를 사용자에게 효과적으로 설명할 수 있음을 제시할 수 있다.

model prediction : 84.82%  
actual class : 1



<그림 2> LSTM 모델이 예측한 리뷰에 대한 SHAP의 설명



**Text with highlighted words**

place cute house made chai keep coming back **prices** food drink items pretty high good quality mind paying little extra good stuff tons **vegan** options **vegan** love seeing creative **space** hope around long time **pros** good coffee drinks fruit **juices** smoothies free **parking** available front back good wifi **cons** unless want sit bean bag 4 tables general seating area rooms pay **rent** hour **surely** changing shortly especially **vandy** back session

〈그림 3〉 LSTM 모델이 예측한 리뷰에 대한 LIME의 설명

마지막으로, 리뷰 유용성에 긍정적인 영향을 미칠 수 있는 단어를 더 구체적으로 판별하기 위해 LSTM이 유용하다고 예측한 리뷰 내 단어와 유용하지 않다고 예측한 리뷰 내 단어를 추출하였다. 이러한 단어는 XAI 기법 중 직관적인 시각적 접근 방식을 제공하는 LIME을 사용하여 검증 데이터의 리뷰 내 단어를 추출하였다(Jeyakumar et al., 2020). LSTM이 유용하다고 예측한 리뷰 내 리뷰 유용성에 긍정적인 영향을 미치는 단어는 기존 레스토랑 관련 선행 연구를 참고하여 <표 4>와 같이 식당 내부시설 및 분위기, 식당 위치 및 운영 정보, 감각과 연관된 음식 정보, 식당 가격 및 서비스 정보, 식당 방문 목적, 사용자 감정 표현의 6가지 카테고리별로 분류하였다. 카테고리별 주요 키워드는 카테고리 내 등장 빈도수가 높은 단어로 결정하였고, 카테고리별로 등장 빈도수가 많은 단어부터 적은 단어 순으로 정렬하였다. 첫번째 카테고리는 식당 내부시설 및 분위기와 관련된 단어(예 : ‘Space’, ‘Décor’, ‘Romantic,

‘Classy’)로 구성되어 있으며, 식당의 내부 구조와 느껴지는 분위기에 대한 정보를 의미한다. 두번째 카테고리는 식당 운영 정보와 관련된 단어(예 : ‘Lunch’, ‘Reservations’, ‘Deliver’, ‘Sundays’)로 구성되어 있으며, 식당의 위치,영업시간, 예약 및 배달여부 등 전반적인 운영 정보를 의미한다. 세번째 카테고리는 감각과 연관된 음식 정보와 관련된 단어로 구성되어 있으며, 이는 사용자가 식당 메뉴를 경험하고 느낀 오감과 관련된 정보를 의미한다. 네번째 카테고리는 식당 가격 및 서비스 정보와 관련된 단어로 구성되어 있으며 전반적인 식당 메뉴의 가격, 서비스 품질 및 직원 태도 관련 정보를 의미한다. 다섯 번째 카테고리는 식당 방문 목적과 관련된 단어로 구성되어 있으며, 사용자의 방문 목적과 동행인에 대한 정보를 의미한다. 여섯 번째 카테고리는 사용자 감정 표현과 관련된 단어로 구성되어 있으며, 사용자의 식당 사용 경험 도중 느낀 감정 정보를 의미한다.

〈표 4〉 리뷰 유용성에 긍정적인 영향을 끼친 단어

카테고리 번호	카테고리명	카테고리별 주요 키워드	참고 문헌
1	식당 내부시설 및 분위기	Space, Décor, Interior, Inside, Scene, Spacious, Romantic, Classy, Mood, Atmosphere	Liu et al. (2022) Park et al. (2020)
2	식당 운영 정보	Open, Located, Lunch, Course, Vegan, Event, Tip, Reservations, Deliver, Sundays	Luo and Xu (2021) Chen et al. (2020)
3	감각과 연관된 음식 정보	Solid, Crispy, Juicy, Frozen, Fluffy, Tender, Fresh, Refreshing, Smooth, Deliciousness	Lopez and Garza (2021) Chen et al. (2020)
4	식당 가격 및 서비스 정보	Service, Parking, Prices, Offer, Plenty, Overpriced, Cheap, Affordable, Complimentary, Attitude	Jia (2020) Liu et al. (2022)
5	식당 방문 목적	Business, Dining, Social, Community, School, Office, Meeting, Fave, Friends, Family	Liu et al. (2022) Jia (2021)
6	사용자 감정 표현	Really, Excited, Happy, Mediocre, Worst, Shame, Hate, Completely, Horrible, Shocked	Chen et al. (2020) Kwon et al. (2020)

또한, LSTM이 유용하지 않다고 예측한 리뷰 내 단어는 <표 5>와 같이 등장 빈도수가 가장 많은 단어를 추출하였다. 해당 단어는 특성이 존재하지 않는 단순 수식어와 관련된 단어(예 : ‘Great’, ‘Good’, ‘However’, ‘Always’)로 구성되어 있다(Wang et al., 2017). 이러한 단어는 사용자의 긍정적인 감성을 반영할 수 있지만 식당 및 음식 관련 특성이 존재하지 않기 때문에 사용자는 해당 키워드가 포함된 리뷰를 유용하지 않은 리뷰로 판단할 수 있다. 따라서, XAI 기법은 모델의 리뷰 유용성 예측에 영향을 미친 단어와 그 영향력을 인간이 이해할 수 있는 영역 내에서 확인할 수 있다는 장점이 존재한다.

〈표 5〉 리뷰 유용성에 부정적인 영향을 끼친 단어

카테고리명	주요 키워드
단순 수식어	Great, Good, However, Always, Nashville, Waiter, Thank, Gave, Orleans, Die

실험 결과를 통해 사용자가 특정 레스토랑에 대한 리뷰 유용성 평가 시 주로 이러한 요소들을 고려하여 리뷰 유용성 정보를 평가함을 제시할 수 있다. <표 5>와 같은 리뷰 유용성에 긍정적인 영향을 미치는 키워드는 음식의 맛, 가격 및 서비스와 같이 사용자가 식당에 관해 자주 탐색하는 정보를 포함하기 때문에 리뷰 유용성을 향상시킬 수 있다. 또한, 해당 키워드는 사용자의 식당 방문 목적과 식당에 대한 전체적인 만족도 정보를 포함하므로 리뷰 유용성을 향상시킬 수 있다. 그러나, <표 6>과 같은 키워드는 레스토랑과 관련된 특징적인 정보를 포함하지 않는 단순 수식어이므로 해당 단어가 많을 수록 유용하지 않은 리뷰로 평가될 수 있다.

## 5. 결론

정보통신 기술의 발전과 소셜미디어의 등장에 따라 온라인 리뷰는 사용자의 구매 의사결정 과

정에서 그 중요성이 대두되고 있다. 그러나, 웹 사이트에서 제공하는 리뷰 수가 기하급수적으로 증가함에 따라 사용자들은 원하는 리뷰를 탐색하는데 어려움을 겪는다. 이러한 문제를 해결하여 사용자의 구매 의사결정 과정을 돕기 위해 아마존과 같은 웹 사이트는 리뷰 유용성 투표 시스템을 도입하였다. 그러나, 리뷰 유용성 투표 수가 누적되기에는 많은 시간을 필요로 하므로 최근에 작성된 리뷰는 오래 전에 작성된 리뷰에 비해 투표를 받을 기회가 제한적이다. 이러한 문제를 개선하여 사용자 구매 의사결정에 도움을 주기 위해서는 자동적으로 유용한 리뷰를 예측하면서 해당 리뷰가 왜 중요한지에 대한 정보를 제공하는 것이 중요하다. 본 연구는 리뷰 유용성 예측 모델에 XAI 기법을 적용하여 효과적으로 리뷰 유용성을 예측함과 동시에 리뷰 유용성에 관해 설명할 수 있는 방법론을 제안하였다. 본 연구의 결과를 요약하면 다음과 같다. 첫째, 딥러닝 모델을 리뷰 유용성 예측에 활용하여 전통적인 머신러닝 기반 기존 연구보다 우수한 예측 성능을 나타냈다. 기존 연구는 전통적인 머신러닝 기법을 활용하여 리뷰에 포함된 다양한 특성을 기반으로 리뷰 유용성을 예측하였다. 이러한 방법은 사용할 특성의 수가 증가함에 따라 노이즈가 특성 공간에 포함되는 문제가 존재하므로 모델의 예측 성능이 제한적이다. 따라서 본 연구는 잠재된 리뷰 텍스트 특성을 추출하는 딥러닝 기법과 전통적인 머신러닝 기법 간 성능 비교를 통해 딥러닝 기법이 효과적으로 리뷰 유용성을 예측하는 것을 확인하였다. 이를 통해 단어 임베딩을 기반으로 잠재적인 정보를 포착하는 딥러닝 기법이 전통적인 머신러닝 기법에 비해 우수한 예측 성능을 보임을 확인할 수 있다. 두 번째, XAI 기법을 활용하여 모델의 리뷰 유용성

예측에 영향을 미칠 수 있는 단어를 확인하였다. 머신러닝 모델은 높은 예측 성능을 제공하지만 예측 과정 및 방식에 대한 설명을 제공할 수 없는 블랙박스 모델이다. 이를 해결하여 머신러닝 모델의 의사 결정 방식을 인간이 이해할 수 있게 설명하기 위해 XAI 기법이 다양한 분야에서 활용되고 있다. 본 연구에서는 XAI 기법 중 SHAP, LIME을 리뷰 유용성 예측 모델에 적용하여 개별 리뷰 예측에 영향을 준 단어를 확인한 다음 카테고리별로 분류하였다. 이를 통해, LSTM은 식당 및 음식 정보, 사용자 감정을 명확히 표현하는 단어가 많은 리뷰는 유용하다고 예측하는 반면 단순 수식어가 많은 리뷰는 유용하지 않다고 예측함을 확인할 수 있다.

본 연구의 학술적 의의는 다음과 같다. 첫째, 본 연구에서는 옐프에서 제공하는 레스토랑 데이터를 사용하여 딥러닝 모델 중 LSTM의 리뷰 유용성 예측 성능이 가장 우수함을 확인하였다. LSTM 모델은 리뷰 텍스트에 대해 중요한 정보를 기억하고 불필요한 정보를 제거할 수 있다. 따라서, 방대한 텍스트 정보 내에서 중요한 정보를 효율적으로 추출할 수 있고 리뷰 유용성에 대한 예측 성능을 향상시킬 수 있다. 둘째, 본 연구에서는 리뷰 유용성을 예측한 딥러닝 모델에 XAI 기법을 적용하여 개별 리뷰 내 단어의 중요도를 확인하였다. XAI 기법은 머신러닝 모델과 결합하여 의학, 보안, 금융 등의 여러 분야에서부터 온라인 리뷰의 감성 분석에 이르기까지 폭넓게 활용되고 있다. 그러나 리뷰 유용성 분석에 XAI 기법을 사용한 연구는 존재하지 않는다. 따라서, 본 연구는 리뷰 유용성 예측 모델에 XAI 기법을 적용하는 방법론을 제안하여 효과적인 예측 성능과 동시에 리뷰 유용성에 대한 해석을 제공하였다.

본 연구의 실무적 시사점은 다음과 같다. 첫째, 다양한 웹 사이트는 기존 리뷰 유용성 투표 시스템을 대신하여 본 연구에서 제안한 방법론을 기반으로 사용자가 작성한 리뷰를 자동으로 평가하는 새로운 시스템을 도입할 수 있다. 본 연구를 통해 우수한 리뷰 유용성 예측 서비스를 제공하는 동시에 유용성에 대한 해석을 제공할 수 있다. 따라서, 사용자에게 특정 리뷰를 추천하는 기준에 대한 설명을 제공하여 구매 의사결정 과정에 도움을 줄 수 있다. 두번째, 본 연구에서 제안하는 방법론의 우수한 예측 성능과 설명력을 바탕으로 다음과 같은 문제점을 극복할 수 있다. 사용자가 작성한 리뷰에는 광고, 거짓 정보 등 사용자의 구매 의사결정에 악영향을 미칠 수 있는 정보가 포함되어 있다. 이와 같은 리뷰를 참고하여 사용한 제품 또는 서비스가 리뷰 내용과 일치하지 않으면 사용자는 해당 웹 사이트에 부정적인 인식을 가질 수 있다. 본 연구에서 제안하는 방법론은 리뷰가 왜 유용한지에 대한 설명을 제공하므로 게시된 광고 또는 거짓 정보를 효과적으로 탐지할 수 있다. 세번째, 레스토랑 산업의 종사자는 본 연구에서 제안하는 방법론에서 제공하는 유용성에 대한 해석을 바탕으로 제품 및 서비스의 질을 개선시킬 수 있다. 본 연구는 유용한 리뷰 예측과 동시에 유용성 예측에 긍정적인 영향을 미치는 키워드를 제공할 수 있다. 특히, 해당 키워드는 음식의 맛, 가격, 서비스에 관한 정보와 사용자의 식당에 대한 전반적인 만족도를 포함한다. 따라서, 레스토랑 산업 종사자는 해당 키워드를 포함하는 리뷰를 참고하여 사용자에게 향상된 제품 및 서비스를 제공하는 전략을 고려할 필요성이 있다.

본 연구에서 제안하는 방법론은 우수한 예측 성능과 동시에 리뷰 유용성에 관한 설명을 효과적

으로 제공하지만 여전히 한계점이 존재한다. 첫째, 본 연구에서는 오픈에서 제공하는 레스토랑 리뷰를 사용하여 모델의 성능을 비교했지만 해당 모델을 다양한 분야에 적용시켰을 때 동일한 결과가 나타나는지에 대해 검증할 필요성이 있다. 따라서, 모델 성능 비교 시 다른 분야의 데이터를 추가하거나 다양한 분야의 데이터를 하나로 통합할 필요가 있다. 두번째, 본 연구는 XAI 기법을 사용하여 리뷰 유용성에 긍정적 또는 부정적인 영향을 미칠 수 있는 단어를 제시하였다. 또한 부정적인 영향을 미칠 수 있는 단어가 레스토랑 관련 특징 정보를 포함하지 않는 단순 수식어임을 명시하였다. 그러나, 향후 연구에서는 해당 단어에 대해 부정적인 영향을 미치는 요인을 포괄적으로 분석하여 보다 설득력 있는 설명을 제공할 필요가 있다. 세번째, 본 연구는 딥러닝 기법으로 LSTM, CNN, CNN-LSTM을 사용하여 리뷰 텍스트에 속한 잠재적 특성을 추출하였다. 최근에는 어텐션 메커니즘(Attention Mechanism) 기반의 트랜스포머(Transformer), BERT(Bidirectional Encoder Representations from Transformers)와 같은 기법들을 활용한 연구가 활발히 진행되고 있다. 따라서, 이러한 어텐션 메커니즘 기반의 기법들을 도입한 추후 연구를 통해 모델의 예측 성능을 향상시킬 수 있다.

## 참고문헌(References)

### [국내 문헌]

- 이청용, 이병현, 이흥철, & 김재경. (2021). CNN 기반 리뷰 유용성 점수 예측을 통한 개인화 추천 서비스 성능 향상에 관한 연구. *지능정보연구*, 27(3), 29-56.

- 이흠철, 윤희림, 이청용, & 김재경. (2022). Multi-channel CNN 기반 온라인 리뷰 유용성 예측 모델 개발에 관한 연구. *지능정보연구*, 28(2), 171-189.
- 이병현, 최일영 정재호, & 김재경. (2022). E-커머스 사용자의 평점과 리뷰 유용성이 상품 추천 시스템의 성능 향상에 미치는 영향 분석. *지능정보연구*, 28(1), 311-328.
- 박호연, & 김재경. (2019). CNN-LSTM 조합모델을 이용한 영화리뷰 감성분석. *지능정보연구*, 25(4), 141-154.
- 주명길, & 윤성욱. (2019). 워드 임베딩과 CNN을 사용하여 영화 리뷰에 대한 감성 분석. *디지털산업정보학회논문지*, 15(1), 87-97.
- challenges toward responsible AI. *Information fusion*, 58, 82-115.
- Aslam, N., Khan, I. U., Mirza, S., AlOwayed, A., Anis, F. M., Aljuaid, R. M., & Baageel, R. (2022). Interpretable Machine Learning Models for Malicious Domains Detection Using Explainable Artificial Intelligence (XAI). *Sustainability*, 14(12), 7375.
- Behera, R. K., Jena, M., Rath, S. K., & Misra, S. (2021). Co-LSTM: Convolutional LSTM model for sentiment analysis in social big data. *Information Processing & Management*, 58(1), 102435.
- Bilal, M., & Almazroi, A. A. (2022). Effectiveness of Fine-Tuned BERT Model in Classification of Helpful and Unhelpful Online Customer Reviews. *Electronic Commerce Research*, 1-21.
- Cantalops, A. S., & Salvi, F. (2014). New consumer behavior: A review of research on eWOM and hotels. *International Journal of Hospitality Management*, 36, 41-51.
- Chan, J. Y.-L., Leow, S. M. H., Bea, K. T., Cheng, W. K., Phoong, S. W., Hong, Z.-W., & Chen, Y.-L. (2022). Mitigating the Multicollinearity Problem and Its Machine Learning Approach: A Review. *Mathematics*, 10(8), 1283.
- 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,
- Chen, W.-K., Riantama, D., & Chen, L.-S. (2020). Using a text mining approach to hear voices of customers from social media toward the fast-food restaurant industry. *Sustainability*, 13(1), 268.

#### [국외 문헌]

- Adak, A., Pradhan, B., Shukla, N., & Alamri, A. (2022). Unboxing deep learning model of food delivery service reviews using explainable artificial intelligence (XAI) technique. *Foods*, 11(14), 2019.
- Ariyasriwatana, W., Buente, W., Oshiro, M., & Streveler, D. (2014). Categorizing health-related cues to action: using Yelp reviews of restaurants in Hawaii. *New Review of Hypermedia and Multimedia*, 20(4), 317-340.
- Ariyasriwatana, W., & Quiroga, L. M. (2016). A thousand ways to say 'Delicious!'—Categorizing expressions of deliciousness from restaurant reviews on the social network site Yelp. *Appetite*, 104, 18-32.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., García, S., Gil-López, S., Molina, D., & Benjamins, R. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and



- Choi, H. S., & Leon, S. (2020). An empirical investigation of online review helpfulness: A big data perspective. *Decision Support Systems*, 139, 113403.
- Chua, A. Y., & Banerjee, S. (2016). Helpfulness of user-generated reviews as a function of review sentiment, product type and information quality. *Computers in Human Behavior*, 54, 547-554.
- Dikshit, A., & Pradhan, B. (2021). Interpretable and explainable AI (XAI) model for spatial drought prediction. *Science of the Total Environment*, 801, 149797.
- Fader, P. S., & Winer, R. S. (2012). Introduction to the special issue on the emergence and impact of user-generated content. *Marketing Science*, 31(3), 369-371.
- Fang, X., & Zhan, J. (2015). Sentiment analysis using product review data. *Journal of Big Data*, 2(1), 1-14.
- Fiok, K., Karwowski, W., Gutierrez, E., & Wilamowski, M. (2021). Analysis of sentiment in tweets addressed to a single domain-specific Twitter account: Comparison of model performance and explainability of predictions. *Expert Systems with Applications*, 186, 115771.
- Fullerton, L. (2017). Online reviews impact purchasing decisions for over 93% of consumers, report suggests. *The Drum*.
- Handelman, G. S., Kok, H. K., Chandra, R. V., Razavi, A. H., Huang, S., Brooks, M., Lee, M. J., & Asadi, H. (2019). Peering into the black box of artificial intelligence: evaluation metrics of machine learning methods. *American Journal of Roentgenology*, 212(1), 38-43.
- Ide, H., & Kurita, T. (2017). Improvement of learning CNN with ReLU activation by sparse regularization. 2017 International Joint Conference on Neural Networks (IJCNN), Anchorage, AK, USA
- Jain, A. K., Mao, J., & Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Jain, D. K., Rahate, A., Joshi, G., Walambe, R., & Kotecha, K. (2022). Employing Co-Learning to Evaluate the Explainability of Multimodal Sentiment Analysis. *IEEE Transactions on Computational Social Systems*.
- Jeyakumar, J. V., Noor, J., Cheng, Y.-H., Garcia, L., & Srivastava, M. (2020). How can i explain this to you? an empirical study of deep neural network explanation methods. *Advances in Neural Information Processing Systems*, 33, 4211-4222.
- Jia, S. (2021). Analyzing restaurant customers' evolution of dining patterns and satisfaction during COVID-19 for sustainable business insights. *Sustainability*, 13(9), 4981.
- Jia, S. S. (2020). Motivation and satisfaction of Chinese and US tourists in restaurants: A cross-cultural text mining of online reviews. *Tourism Management*, 78, 104071.
- 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.
- Kang, H., Yoo, S. J., & Han, D. (2012). Senti-lexicon and improved Naïve Bayes algorithms for sentiment analysis of restaurant reviews. *Expert Systems with Applications*, 39(5), 6000-6010.
- Kaushik, K., Mishra, R., Rana, N. P., & Dwivedi, Y. K. (2018). Exploring reviews and review sequences on e-commerce platform: A study

- of helpful reviews on Amazon. in *Journal of retailing and Consumer Services*, 45, 21-32.
- Krishnamoorthy, S. (2015). Linguistic features for review helpfulness prediction. *Expert Systems with Applications*, 42(7), 3751-3759.
- Kumar, A., Dikshit, S., & Albuquerque, V. H. C. (2021). Explainable artificial intelligence for sarcasm detection in dialogues. *Wireless Communications and Mobile Computing*, 2021.
- Kwon, W., Lee, M., & Back, K.-J. (2020). Exploring the underlying factors of customer value in restaurants: A machine learning approach. *International Journal of Hospitality Management*, 91, 102643.
- Lee, M., Kwon, W., & Back, K.-J. (2021). Artificial intelligence for hospitality big data analytics: developing a prediction model of restaurant review helpfulness for customer decision-making. *International Journal of Contemporary Hospitality Management*.
- Lee, P.-J., Hu, Y.-H., & Lu, K.-T. (2018). Assessing the helpfulness of online hotel reviews: A classification-based approach. *Telematics and Informatics*, 35(2), 436-445.
- Li, Z. (2022). Extracting spatial effects from machine learning model using local interpretation method: An example of SHAP and XGBoost. *Computers, Environment and Urban Systems*, 96, 101845.
- Linardatos, P., Papastefanopoulos, V., & Kotsiantis, S. (2020). Explainable ai: A review of machine learning interpretability methods. *Entropy*, 23(1), 18.
- Liu, J., Yu, Y., Mehraliyev, F., Hu, S., & Chen, J. (2022). What affects the online ratings of restaurant consumers: a research perspective on text-mining big data analysis. *International Journal of Contemporary Hospitality Management* (ahead-of-print).
- Lopez, A., & Garza, R. (2021). Do sensory reviews make more sense? The mediation of objective perception in online review helpfulness. *Journal of Research in Interactive Marketing*.
- Lu, K., & Wu, J. (2019). Sentiment analysis of film review texts based on sentiment dictionary and SVM. Proceedings of the 2019 3rd international conference on innovation in artificial intelligence.
- Luo, Y., & Xu, X. (2019). Predicting the helpfulness of online restaurant reviews using different machine learning algorithms: A case study of yelp. *Sustainability*, 11(19), 5254.
- Luo, Y., & Xu, X. (2021). Comparative study of deep learning models for analyzing online restaurant reviews in the era of the COVID-19 pandemic. *International Journal of Hospitality Management*, 94, 102849.
- Ma, Y., Xiang, Z., Du, Q., & Fan, W. (2018). Effects of user-provided photos on hotel review helpfulness: An analytical approach with deep learning. *International Journal of Hospitality Management*, 71, 120-131.
- Maks, I., & Vossen, P. (2012). A lexicon model for deep sentiment analysis and opinion mining applications. *Decision Support Systems*, 53(4), 680-688.
- 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.
- Malik, M. S. I. (2020). Predicting users' review helpfulness: the role of significant review and reviewer characteristics. *Soft Computing*, 24(18), 13913-13928.

- Mitra, S., & Jenamani, M. (2021). Helpfulness of online consumer reviews: A multi-perspective approach. *Information Processing & Management*, 58(3), 102538.
- Muhamedyev, R., Yakunin, K., Kuchin, Y., Symagulov, A., Buldybayev, T., Murzakhmetov, S., & Abdurazakov, A. (2020). The use of machine learning “black boxes” explanation systems to improve the quality of school education. *Cogent Engineering*, 7(1), 1769349.
- Musto, C., Lops, P., de Gemmis, M., & Semeraro, G. (2021). Context-aware graph-based recommendations exploiting Personalized PageRank. *Knowledge-Based Systems*, 216, 106806.
- Ngo-Ye, T. L., & Sinha, A. P. (2014). The influence of reviewer engagement characteristics on online review helpfulness: A text regression model. *Decision Support Systems*, 61, 47-58.
- Olmedilla, M., Martínez-Torres, M. R., & Toral, S. (2022). Prediction and modelling online reviews helpfulness using 1D Convolutional Neural Networks. *Expert Systems with Applications*, 198, 116787.
- Park, E., Chae, B., Kwon, J., & Kim, W.-H. (2020). The effects of green restaurant attributes on customer satisfaction using the structural topic model on online customer reviews. *Sustainability*, 12(7), 2843.
- Qazi, A., Syed, K. B. S., Raj, R. G., Cambria, E., Tahir, M., & Alghazzawi, D. (2016). A concept-level approach to the analysis of online review helpfulness. *Computers in Human Behavior*, 58, 75-81.
- Rai, A. (2020). Explainable AI: From black box to glass box. *Journal of the Academy of Marketing Science*, 48(1), 137-141.
- Ren, Y., & Ji, D. (2017). Neural networks for deceptive opinion spam detection: An empirical study. *Information Sciences*, 385, 213-224.
- Sadiq, S., Umer, M., Ullah, S., Mirjalili, S., Rupapara, V., & Nappi, M. (2021). Discrepancy detection between actual user reviews and numeric ratings of Google App store using deep learning. *Expert Systems with Applications*, 181, 115111.
- Sak, H., Senior, A., & Beaufays, F. (2014). Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition. *arXiv preprint arXiv:1402.1128*.
- 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.
- Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306.
- Singh, H., Roy, A., Setia, R., & Pateriya, B. (2022). Estimation of nitrogen content in wheat from proximal hyperspectral data using machine learning and explainable artificial intelligence (XAI) approach. *Modeling Earth Systems and Environment*, 8(2), 2505-2511.
- Singh, J. P., Irani, S., Rana, N. P., Dwivedi, Y. K., Saumya, S., & Roy, P. K. (2017). Predicting the “helpfulness” of online consumer reviews. *Journal of Business Research*, 70, 346-355.
- Štrumbelj, E., & Kononenko, I. (2014). Explaining prediction models and individual predictions with feature contributions. *Knowledge and information systems*, 41(3), 647-665.

- Sun, X., Han, M., & Feng, J. (2019). Helpfulness of online reviews: Examining review informativeness and classification thresholds by search products and experience products. *Decision Support Systems*, 124, 113099.
- Vapnik, V. (1999). *The nature of statistical learning theory*. Springer science & business media.
- Wang, J., Yu, L.-C., Lai, K. R., & Zhang, X. (2016). Dimensional sentiment analysis using a regional CNN-LSTM model. Proceedings of the 54th annual meeting of the association for computational linguistics (volume 2: Short papers),
- Wang, W., Wang, H., & Song, Y. (2017). Ranking product aspects through sentiment analysis of online reviews. *Journal of Experimental & Theoretical Artificial Intelligence*, 29(2), 227-246.
- 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.
- 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.
- Zhang, W., & Gao, F. (2011). An improvement to naive bayes for text classification. *Procedia Engineering*, 15, 2160-2164.
- Zhang, Y., & Lin, Z. (2018). Predicting the helpfulness of online product reviews: A multilingual approach. *Electronic Commerce Research and Applications*, 27, 1-10.
- Zhou, C., Yang, S., Chen, Y., Zhou, S., Li, Y., & Qazi, A. (2022). How does topic consistency affect online review helpfulness? The role of review emotional intensity. *Electronic Commerce Research*, 1-36.
- Zhu, L., Yin, G., & He, W. (2014). Is this opinion leader's review useful? Peripheral cues for online review helpfulness. *Journal of Electronic Commerce Research*, 15(4), 267.

Abstract

## Explainable Artificial Intelligence Applied in Deep Learning for Review Helpfulness Prediction

Dongyeop Ryu\* · Xinzhe Li\* · Jaekyeong Kim\*\*

With the development of information and communication technology, numerous reviews are continuously posted on websites, which causes information overload problems. Therefore, users face difficulty in exploring reviews for their decision-making. To solve such a problem, many studies on review helpfulness prediction have been actively conducted to provide users with helpful and reliable reviews. Existing studies predict review helpfulness mainly based on the features included in the review. However, such studies disable providing the reason why predicted reviews are helpful. Therefore, this study aims to propose a methodology for applying eXplainable Artificial Intelligence (XAI) techniques in review helpfulness prediction to address such a limitation. This study uses restaurant reviews collected from Yelp.com to compare the prediction performance of six models widely used in previous studies. Next, we propose an explainable review helpfulness prediction model by applying the XAI technique to the model with the best prediction performance. Therefore, the methodology proposed in this study can recommend helpful reviews in the user's purchasing decision-making process and provide the interpretation of why such predicted reviews are helpful.

**Key Words** : Review helpfulness, Machine Learning, eWOM, Online review, eXplainable Artificial Intelligence(XAI)

Received : November 10, 2022 Revised : December 9, 2022 Accepted : December 14, 2022

Corresponding Author : Jaekyeong Kim

---

\* Department of Big Data Analysis, Kyung Hee University  
\*\* Corresponding Author: JaeKyeong Kim  
School Management & Department of Big Data Analysis, Kyung Hee University  
26, Kyungheedae-ro, Dongdaemun-gu, Seoul 02447, Korea  
Tel: +82-2-961-9355, Fax: +82-2-961-9355, E-mail: jaek@khu.ac.kr

## 저자 소개



### 류동엽

국민대학교 경영학과에서 경영학 학사학위를 취득하고, 현재 경희대학교 대학원 빅데이터응용학과 석사과정에 재학 중이다. 주요 관심 분야는 추천시스템, 자연어 처리, 딥러닝 및 머신러닝 응용 등이다.



### 이흠철

경희대학교 대학원 빅데이터응용학과 박사과정에 재학 중이며, 동 대학원 학과에서 공학 석사학위를 취득하였다. 주요 관심 분야는 추천시스템, 자연어 처리, 딥러닝 및 빅데이터 분석 등이다. 지능정보연구, Applied Sciences, Data Technologies and Applications 등의 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, 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.