

리뷰 데이터와 제품 정보를 이용한 멀티모달 감성분석

Multimodal Sentiment Analysis Using Review Data and Product Information

황호현(Hohyun Hwang)*, 이경찬(Kyeongchan Lee)**, 유진이(Jinyi Yu)***,
이영훈(Younghoon Lee)****

초 록

최근 의류 등의 특정 쇼핑물의 온라인 시장이 크게 확대되면서, 사용자의 리뷰를 활용하는 것이 주요한 마케팅 방안이 되었다. 이를 이용한 감성분석에 대한 연구들도 많이 진행되고 있다. 감성분석은 사용자의 리뷰를 긍정과 부정 그리고 필요에 따라서 중립으로 분류하는 방법이다. 이 방법은 크게 머신러닝 기반의 감성분석과 사전기반의 감성분석으로 나눌 수 있다. 머신러닝 기반의 감성분석은 사용자의 리뷰 데이터와 그에 대응하는 감성 라벨을 이용해서 분류 모델을 학습하는 방법이다. 감성분석 분야의 연구가 발전하면서 리뷰와 함께 제공되는 이미지나 영상 데이터 등을 함께 고려하여 학습하는 멀티모달 방식의 모델들이 연구되고 있다. 리뷰 데이터에서 제품의 카테고리나 사용자별로 사용되는 단어 등의 특징이 다르다. 따라서 본 논문에서는 리뷰데이터와 제품 정보를 동시에 고려하여 감성분석을 진행한다. 리뷰를 분류하는 모델로는 기본 순환신경망 구조에서 Gate 방식을 도입한 Gated Recurrent Unit(GRU), Long Short-Term Memory(LSTM) 그리고 Self Attention 기반의 Multi-head Attention 모델, Bidirectional Encoder Representation from Transformer(BERT)를 사용해서 각각 성능을 비교하였다. 제품 정보는 모두 동일한 Multi-Layer Perceptron(MLP) 모델을 이용하였다. 본 논문에서는 사용자 리뷰를 활용한 Baseline Classifier의 정보와 제품 정보를 활용한 MLP모델의 결과를 결합하는 방법을 제안하며 실제 데이터를 통해 성능의 우수함을 보인다.

ABSTRACT

Due to recent expansion of online market such as clothing, utilizing customer review has become a major marketing measure. User review has been used as a tool of analyzing sentiment of customers. Sentiment analysis can be largely classified with machine

* First Author, Master Course of Datascience, Seoul National University of Science and Technology (hhhwan94@ds.seoultech.ac.kr)

** Co-Author, Master Course of Datascience, Seoul National University of Science and Technology (nahcklee@gmail.com)

*** Co-Author, Master Course of Datascience, Seoul National University of Science and Technology (wlsdl2664@gmail.com)

**** Corresponding Author, Associate Professor, Department of Industrial & Systems Engineering, Seoul National University of Science and Technology(yhoon.lee@seoultech.ac.kr)

Received: 2021-09-07, Review completed: 2021-12-01, Accepted: 2021-12-21

learning-based and lexicon-based method. Machine learning-based method is a learning classification model referring review and labels. As research of sentiment analysis has been developed, multi-modal models learned by images and video data in reviews has been studied. Characteristics of words in reviews are differentiated depending on products' and customers' categories. In this paper, sentiment is analyzed via considering review data and metadata of products and users. Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM), Self Attention-based Multi-head Attention models and Bidirectional Encoder Representation from Transformer (BERT) are used in this study. Same Multi-Layer Perceptron (MLP) model is used upon every products information. This paper suggests a multi-modal sentiment analysis model that simultaneously considers user reviews and product meta-information.

키워드 : 감성분석, 멀티모달, 특성 추출, 인공 신경망


Sentiment Analysis, Multi-Modal, Feature Selection, Neural Network

1. 서 론

온라인 쇼핑물 시장은 시간이 지날수록 더욱 성장하고 있는 추세이다. 팬데믹 상황과 더불어 비대면 주문이 좀 더 각광 받으며 온라인 쇼핑물 시장은 점점 더 커져가고 있다. 최근 많은 온라인 의류 쇼핑물들은 직접 보고 살 수 없어 신뢰의 문제가 종종 발생하는 온라인 쇼핑물의 단점을 해결하기 위하여 제품에 대한 다양하고 다각적인 정보를 방문자에게 최대한으로 제공하고자 노력하고 있다. 특히 온라인 쇼핑물에서 제공하는 사용자들의 리뷰는 중요한 마케팅 요소로 작용한다. 쇼핑물은 구매자가 제품에 관련된 평가를 더욱 다각적인 측면에서 할 수 있도록 하기 위하여 리뷰뿐만이 아니라 제품에 대해 더욱 추가적인 정보를 입력받는 경우가 늘어나고 있다. 예를 들어, 리뷰와 함께 제품에 대한 사이즈와 색깔 등에 대한 평가 정보를 작성하도록 하여 다른 소비자들의 구매 결정에 도움을 준다. 또한 긍정적인 리뷰와 부정적인 리뷰의 비율을 통해서 구매를 결

정하는 소비자들도 많이 나타나고 있다. 그렇기 때문에 리뷰에 대한 감성분류는 중요 기술로 요구되고 있다. 최근에는 제품의 카테고리가 더욱 세분화되어 있으며 구매자는 단순 텍스트 리뷰뿐만 아니라 별점, 착용 시 느끼는 제품의 실착 크기, 두께감, 색깔 등 더욱 세부적인 정보를 선택 입력하도록 안내받는다. 따라서 리뷰에 대한 정교한 감성분석을 위해서는 리뷰 정보뿐만 아니라 이러한 카테고리 정보, 그리고 구매자가 남긴 제품 정보들을 함께 반영할 필요가 있다.

최근 리뷰에 대한 감성분석 연구가 점차 발전하면서 리뷰와 더불어 리뷰와 함께 입력받는 이미지 데이터 및 영상 데이터 등을 함께 학습시키는 멀티모달방식의 감성분석 방법이 많이 연구되고 있다. 멀티모달 방식이란 리뷰 데이터에서 얻을 수 없는 추가적인 정보를 다른 유형의 데이터에서 활용하여 모델을 학습하는 방법이다. 추가적인 데이터를 고려하여 결과를 예측하기 때문에 리뷰만을 이용해서 예측하는 기법보다 더욱 좋은 성능을 나타내고 있다.



〈Figure 1〉 Overview of Proposed Idea

본 논문에서는 대표적인 의류 온라인 쇼핑몰 플랫폼인 무신사(<https://store.musinsa.com/>)의 리뷰를 활용하여 감성분석 연구를 진행하였다. 온라인 쇼핑몰 중에서 의류 제품들은 카테고리 별로 제품의 특성이 다르고 이에 따른 사용자의 리뷰 역시 다른 특성을 갖는다. 그러므로 리뷰 및 제품 정보, 구매자가 남긴 제품 정보들을 함께 고려한다면 더욱 정확한 감성분석이 가능할 것으로 예상된다. 그러므로 <Figure 1>과 같이 본 연구에서는 리뷰뿐만 아니라 제품의 카테고리 정보와 구매자가 선택 입력하는 제품에 대한 메타 정보를 활용하여 시퀀스 분류 모델 및 Muti Layer Perceptron (MLP)을 통한 멀티모달 감성분석 모델을 제안한다. 또한 리뷰만을 이용한 모델과의 비교를 통하여 본 논문에서 제안한 방법이 성능면에서 우수함을 보인다.

본 논문은 제2장 관련 연구에 대한 설명, 제3장 제안하는 모델에 대한 설명, 제4장 실험에 대한 구성 및 실험 결과, 마지막 제5장 결론 순으로 구성된다.

2. 관련 연구

2.1 Sentiment Analysis

감성분석은 오래전부터 자연어처리 분야에서 주목받고 있는 분야 중 하나이다. 감성분석은 크게 머신러닝 기반의 감성분석과, 감성 사전기반의 감성분석으로 나눌 수 있다. 머신러닝 기반의 감성분석은 사용자가 작성한 리뷰 데이터와 그에 대응하는 감성 라벨 값을 같이 모델에 학습시키는 방법이다. Smeuruanu et al.[20]은 베이지안 방법론을 이용해서 텍스트 데이터에 대한 이진 분류를 진행했고, Wang et al.[24]에서는 트위터에 작성된 글을 이용해서 감성분석을 하는 연구를 진행했다. Pannal et al.[16]에서는 Support vector machine(SVM)을 이용하여 사용자 리뷰의 감성분석을 하는 연구를 진행했다. Severyn and Moschitti[19]는 트위터에 대한 감성분석을 인공 신경망을 이용해서 분석하고 기존에 이미지 분류 태스크에 주로 사용되던 Convolutional Neural Network(CNN)모델을

적용하면서 다른 머신러닝 기반의 감성분석 모델과 비교하면서 인공 신경망의 감성분석 성능을 검증 하였다. Huang et al.[9]은 텍스트의 local feature와 문맥 정보를 얻기 위하여 CNN과 Long short-term memory(LSTM) 레이어 2개를 이용해 감성 분석을 진행하였다. Yang[26]은 상품 리뷰의 감성분석을 위하여 sentiment lexicon에 기반한 CNN과 Bi-Gated Recurrent Unit(GRU)을 결합한 모델 SLCABG를 제안하였다. 분석 모델을 구축하는 연구 이외에도 감성 분석의 결과를 활용하는 연구들도 진행되고 있다. Kim et al.[14]은 감성분석의 결과와 주가 예측의 상관관계를 연구하여, SNS의 감성분석을 활용하여 주가의 방향성을 예측하는 연구를 진행했다. Jeon et al.[11]은 감성분석의 결과를 항공 서비스의 품질을 평가하는데 활용하는 연구를 진행했다. Oh and Hwang[15]은 키워드 기반으로 트위터의 감성분석을 통해 실시간으로 장소를 추천해주는 연구를 진행했다.

2.2 Multi-modal for Sentiment Analysis

멀티모달 데이터란 문서, 이미지, 평점 등의 싱글모달 데이터와는 달리 영화 평점과 부가정보, 태그가 있는 이미지 등의 다중 관계형 데이터를 말한다. 멀티모달 딥 네트워크 연구는 멀티모달 데이터를 입력받아 주어진 과제에 맞는 출력 값을 제공하는 방향으로 많은 연구가 진행되어왔다. 기존의 단일 양식 감정 분석과 달리 다중 모드 감정 분석은 최근 몇 년 동안 점점 더 주목을 받고 있다. 멀티 모달 감정 분석을 위한 심층 시맨틱 네트워크인 MultiSentiNet 등 이미지와 텍스트 간의 상관관계를 이용한 감성

분석 연구가 진행되었다[25]. 또한 Recurrent Neural Network(RNN) 및 LSTM을 사용하여 시간적 멀티모달 정보를 융합하는데 사용하기도 하였다. 이러한 초기 애플리케이션 중 하나는 Jin et al.[12]로써, 마이크로 블로그에서의 루머를 탐지하기 위하여 text, image, social context 정보를 RNN구조를 거친 후 결합하여 활용하였다. Baltrušaitis et al.[4]에 따르면, Poria et al.[17]은 데이터의 다른 modality에 따라 다른 kernel을 사용하는 Multiple kernel learning을 사용하였으며, text, visual, audio feature를 이용하여 분류기를 학습시켰다. Agarwal et al.[1]은 감성분석을 위하여 RNN에 기초한 4가지 multi-modal 분류기를 비교하였다.

2.3 Sequence Models

리뷰데이터에 대한 머신러닝 기반의 감성분석에는 RNN기반의 딥러닝 모델이 많이 사용된다. RNN은 모든 hidden node가 연결되어있는 신경망으로 시퀀스의 길이가 길어질수록 기울기 소실 문제가 발생한다. 그렇기 때문에 hidden node안에 게이트 메커니즘을 적용하여 기울기 소실 문제를 해결하고자 하는 LSTM과 GRU가 제안되었다. 본 연구에서는 LSTM과 GPU를 리뷰의 감성분석에 활용하여 다른 baseline과 비교할 것이다.

2.3.1 Long Short-Term Memory (LSTM)

LSTM은 RNN의 한 종류로, 시퀀스가 길어질수록 RNN이 장기 기억에 취약한 점을 보완하기 위하여 게이트 메커니즘을 이용한 알고리즘이다. LSTM의 핵심은 cell state로서, gate라는 구조에 의한 linear 연산을 수행하여 기억해야 할 정보와 지워져도 될 정보를 구분하여 학

습을 진행하는 방법이다[8]. LSTM 셀은 이전 셀에서 cell state와 hidden state를 전달받고, 다음 데이터가 인풋으로 입력된다. hidden state와 입력 데이터는 forget gate와 input gate를 생성한다. forget gate를 통과한 값은 0에서 1사이의 값을 갖는데, 0에 가까울수록 cell state의 이전 정보는 잊혀져서 다음 셀로 보내진다. input gate를 통과한 정보는 현재 정보를 기억하기 위한 값으로, cell state에 더해져서 다음 셀로 보내진다. 마지막으로 인풋 데이터의 정보에 cell state의 tanh변환 값을 곱해주어 hidden state, 즉 output을 생성한다. 이를 통해 LSTM은 RNN의 기울기 소실문제를 완화하고 오래된 정보를 전달하는데 용이하다[19].

2.3.2 Gated Recurrent Unit (GRU)


GRU도 게이트 메커니즘이 적용된 RNN의 일종으로 LSTM에서 영감을 받아서 만들어졌다[4]. GRU는 LSTM보다 가중치의 수와 연산을 간단히 함으로써 구조는 더 간략하지만 LSTM과 대등한 성능을 보여준다. LSTM에서 cell state라는 존재를 없애고 hidden state와 인풋 정보를 활용해 reset gate와 update gate를 만든다. 그리고 난 후 현재 시점의 인풋 정보의 후보군을 만들기 위하여 이전 hidden state에 reset gate를 곱한 값과 현재 인풋을 더해준다. 마지막으로, 후보 정보와 update gate결과를 연산하여 현재 셀의 hidden state를 산출한다. GRU는 LSTM보다 학습할 매개변수가 적으므로 연산이 빠르다는 장점이 있다. Gruber et al.[7] 등의 여러 연구에서 LSTM과 GRU의 차이를 보이려고 했으나 현재는 두 방법 모두 비슷한 성능을 나타낸다고 알려져 있다.

2.4 Attention based Models

RNN기반의 모델들은 자연어 처리 분야에서 좋은 성능을 보여 왔지만 기울기 소실 등의 문제를 안고 있었다. 그래서 Self-Attention 기반의 모델들이 등장하여 RNN의 기울기 소실 문제와 장기 의존성 문제를 해결하는데 공헌하였다[3]. 본 논문에서는 Self-Attention 기반의 Multi-head Attention 모델과 사전 학습된 모델을 활용한 트랜스포머[23] 기반의 Bidirectional Encoder Representations from Transformers(BERT)모델을 사용했다.

2.4.1 Multi-head Attention

Multi-head Attention의 구조는 <Figure 2>



<Figure 2> Framework of Multi-head Attention Model


과 같다. 토큰임베딩 정보와 Positional encoding 정보를 고려한 입력 데이터에 대해서 self-attention 작업을 통해 주요 토큰에 집중된 단어별 임베딩 정보를 추출하는 Multi-head Attention 모델이다. Multi-head Attention은 Scaled Dot-Product Attention을 여러 개 만들어 다양한 특징에 대한 attention을 볼 수 있게 한 방법이다. 즉, 입력받은 query, key, value를 헤드 수만큼 나누어 병렬적으로 계산해주는 것이다. 감성 분석 등의 분류모델에 적용하기 위해서는 연산된 attention 결과를 Global Max Pooling과 Fully connected layer(FCN)를 이용해서 분류를 진행한다[2].

2.4.2 Bidirectional Encoder Representations from Transformers (BERT)

BERT는 트랜스포머의 인코더 부분을 여러 개 중첩한 모델로, 사전 학습된 양방향 언어표현 모델이다[6]. Multi-head Attention 정보와 Positional 인코딩과 세그먼트 임베딩정보까지 고려하여, 발표된 언어 모델 중 자연어처리 분야에서 좋은 성능을 보이는 모델로 평가받고 있다. 임의로 입력된 단어를 제거하여 그 단어를 예측하는 방식과 입력 값으로 사용되는 [CLS] 토큰을 사용해서 입력된 두 문장의 순서 여부를 학습하는 방식으로 사전학습과정이 진행된다. <Figure 3>과 같은 사전 학습된 BERT 모델은 분류를 위한 완전 연결 계층을 미세 조정하여 시퀀스 태깅, 질문 대답, 감성분석 등 넓은 범위의 자연어처리 과제에 적용될 수 있다. Sun et al.[21]의 연구에서는 BERT를 미세 조정하여 Aspect-based sentiment analysis 과제를 수행하였다.

BERT를 통해서 입력된 문장의 임베딩 벡

터는 여러 층으로 이루어진 트랜스포머를 통해서 산출된다. 구체적으로 미세조정과정은 위와 같이 사전 학습된 BERT 모델에서 산출된 벡터에서 [CLS] 토큰에 해당되는 출력의 결과를 이용해서 분류기를 학습한다. [CLS] 토큰의 출력에 해당되는 768차원의 임베딩 벡터를 완전 연결계층과 과적합 방지를 위한 드롭아웃을 거쳐서 긍정과 부정의 결과를 예측하도록 한다.



<Figure 3> Framework of Ko-BERT Model

영문으로 사전학습된 BERT 모델 외에 다른 언어들을 이용해서 학습된 모델도 개발되어 다양한 언어에 적용하여 연구가 진행될 수 있게 했다[17]. SK TBrain에서 공개한 한국어 BERT 모델(<https://github.com/SKTBrain/KoBERT>) 버트 모델도 개발되었다. S. Hwang et al.[10]에서는 한국어 BERT 모델을 활용해서 기술문서 분류모델을 학습하는 연구를 진행했다.

3. 제안 모델

본 연구에서는 일반적인 머신러닝 기반의 감성분석 baseline 모델에 제품 카테고리 정보 및 구매자가 리뷰와 함께 남긴 제품 메타 데이터를 입력한 MLP 모델을 멀티모달 방식으로 학습시켜 감성을 예측하는 모델을 제안한다. 리뷰 데이터를 입력받는 Text encoder 모델로는 4가지 모델을 사용하였다. 그리고 메타데이터를 입력받는 MLP 모델의 결과와 Text encoder 모델의 결과를 결합하여 감성분석에 이용하였다.

$$f_i^c = \text{Text Encoder}(x_i^r) \quad (1)$$

$$f_i^m = W_2(W_1x_i^m + b_1) + b_2 \quad (2)$$

$$f_i = [f_i^c; f_i^m] \quad (3)$$

x_i^r , x_i^m 은 각각 리뷰데이터와 one-hot 인코딩된 메타데이터이며 Text encoder는 RNN 기반의 GRU, LSTM, Self-attention 기반의 Multi-head Attention과 BERT를 나타낸다. $W_1 \in \mathbb{R}^{i \times h}$, $W_2 \in \mathbb{R}^{h \times i}$ 와 $b_1 \in \mathbb{R}^h$, $b_2 \in \mathbb{R}^i$ 는 각각 가중치와 편향 매개변수를 의미한다. $f^c \in \mathbb{R}^d$, $f^m \in \mathbb{R}^i$ 는 각각 리뷰 데이터에 대한 임베딩과

메타데이터에 대한 임베딩을 나타내며 Text encoder, Multi-layer perceptron의 output이다. $f \in \mathbb{R}^{d+i}$ 는 리뷰 및 메타 데이터에 대한 임베딩으로써 f^c , f^m 을 concatenation한 것이다.

리뷰 데이터 및 메타 데이터에 대한 임베딩을 얻고 난 후, Fully connected layer(FCN)를 통과시킴으로써 후보 임베딩 $a_i \in \mathbb{R}^o$ 를 얻는다.

$$a_i = W_4(W_3f_i + b_3) + b_4 \quad (4)$$


$W_3 \in \mathbb{R}^{(d+i) \times h}$, $W_4 \in \mathbb{R}^{h \times o}$ 와 $b_3 \in \mathbb{R}^h$, $b_4 \in \mathbb{R}^o$ 는 FCN의 가중치 및 편향을 나타낸다. 그리고 나서 후보 임베딩에 Sigmoid 함수를 적용시켜 모델의 최종 결과인 $\hat{y}$ 를 얻는다.

$$\hat{y}_i = \text{sigmoid}(a_i) \quad (5)$$

시퀀스 데이터와 메타데이터를 고려한 모델의 구조는 <Figure 4>의 (c)와 같다.

3.1 Sequence Model

본 연구에서 텍스트 분류에 사용한 시퀀스



<Figure 4> Comparison of baseline and Proposed Method. (a) Baseline Model
(b) Add only category information (c) Proposed Model

모델은 GRU 모델과 LSTM을 적용했다. GRU는 기존 RNN에 기울기 소실 문제에 대한 해결책으로써 연구되었으며 같은 목적으로 개발된 LSTM은 비교적 복잡한 구조를 갖는다. 두 모델 모두 워드 임베딩 행렬로는 Word2Vec 모델을 학습 시켜서 사용했다. 모델에 대한 입력데이터에 대한 길이는 64로 맞추어 입력했다. 은닉층은 단층으로 설정했다. GRU와 LSTM에 대한 공정한 비교가 이루어질 수 있도록 활성화 함수와 최적화 기법을 동일하게 설정하였다. 두 모델에서의 하이퍼 파라미터 설정에 대한 정리는 <Table 1>과 같다.

<Table 1> Hyper Parameter Setting for Sequence Models

	GRU	LSTM
Input length	64	
Word embedding	Word2Vec	
Embedding dimension	200	
# of hidden layers	1	1
Hidden dimension	128	128
Activation function	Sigmoid	
Loss function	Binary Cross entropy	

3.2 Attention based Model

본 논문에서는 기울기 소실 문제가 발생하는 시퀀스 모델 대신 Attention을 적용한 다른 모델을 추가 적용한다. 본 연구에서 실험한 Attention 기반의 모델은 Multi-head Attention과 BERT이다. Multi-head Attention에 사용된 attention head의 개수는 8개를 사용했다. attention layer의 개수는 6개로 설정했고 입력데이터에 대한 길이는 시퀀스 모델과 동일하게 64로 설정했다. 모델에 대한 하이퍼 파라미터 설정은 <Table 2>와 같다.

본 연구에서는 구글에서 개발한 BERT 모델과 같은 구조를 가지고 있는 SKT Brain에서 공개한 한국어 BERT 모델을 이용하여 분류 모델을 학습하였다. 연구에 사용한 BERT 모델은 500만 개 이상의 문장으로 구성된 한국어 위키와 2천만 개 이상의 문장으로 구성된 한국어 뉴스 데이터로 학습되었다. 이 BERT 모델의 사전의 크기는 8,002이고 한국어 텍스트를 토큰화하기 위해 한글 위키와 뉴스 텍스트를 기반으로 문장 단위 토큰나이저(SentencePiece tokenizer)를 따로 학습하여 제공한다. 제공된 한국어 BERT 모델에서 출력된 768차원의 출력값을 활용하여 모델학습을 진행했다.

<Table 2> Hyper-parameter Setting for Multi-head Attention Model

Parameters	Values
Input length	64
num of attention layer	6
num of attention head	8
Embedding dimension	200
Hidden dimension	32
Activation function	Sigmoid
Loss function	Binary Cross entropy

3.3 Multi-layer Perceptron (MLP)

본 연구에서는 리뷰를 입력으로 받은 모델과 사용자 정보 및 제품 정보 등의 메타데이터를 입력으로 받은 모델을 멀티모달 방식으로 학습시키는 방법을 제안한다.

메타데이터를 입력으로 받는 모델은 Multi-layer Perceptron(MLP)이다. 메타데이터의 범주형 변수들을 순서정보가 없는 변수들은 원핫 인코딩(One-hot encoding) 형식으로, 순서

정보가 있는 변수들은 Ordinal Encoding 형식으로 입력을 받아서 메타데이터의 정보가 요약된 벡터를 출력하게 된다. 이 결과와 리뷰 데이터를 입력으로 받은 모델의 출력 값을 합쳐서 예측에 사용한다. 사용한 MLP모델에 대한 정보는 <Table 3>과 같다.

<Table 3> Hyper-parameter Setting for MLP

Parameters	Values
Input length	15
# of hidden layers	2
Hidden dimension	64 / 32
Activation function	relu

4. 실험 결과

4.1 실험 구성

본 연구의 실험에는 온라인 패션 플랫폼인 ‘무신사’의 리뷰 데이터를 사용했다. 무신사의 경우에는 제품에 대한 상세한 리뷰뿐만 아니라, 리뷰를 작성한 사용자가 제품을 직접 보거나 착용한 후 평가하여 자신이 생각하는 제품정보를 선택 입력하도록 함으로써 다각적인 제품 정보를 수집한다. 이로써 리뷰 정보를 이용하려는 소비자들에게 더 자세한 정보를 제공하고 있다.

데이터는 인기 카테고리에 속하는 6개의 카테고리를 선정하였고 카테고리 내에서 인기순 정렬하여 수집 기간(2021년 6월) 기준 상위에 노출되는 인기 아이템 위주로 수집하였다. 총 6개의 제품카테고리에 대하여 50,000개의 리뷰 데이터를 수집하였고, 그 중 긍정 리뷰의 수는

35,000개, 부정 리뷰 수는 15,000개이다. 데이터셋은 웹 크롤링을 통해서 구축했다.

제품 메타 데이터는 카테고리, 리뷰의 종류, 구매자 성별, 사용자가 제품을 직접 보고 판단한 의류의 밝기, 색깔, 사이즈, 두께감 등 총 7개를 이용했다. 카테고리는 반팔티셔츠, 데님팬츠, 셔츠/블라우스 등 상/하의 구분 없이 다양한 종류의 의류를 포함하였다. 리뷰의 종류는 실제 착용하여 스타일링한 사진과 함께 작성된 스타일 후기, 의류를 촬영한 사진과 함께 작성된 상품 사진 후기, 사진 없이 리뷰만 작성된 일반 후기 총 3가지로 나뉜다. 이 외의 밝기, 색깔, 사이즈, 두께감은 세 가지 정보 중 선택하게 된다. 데이터에 대한 정리는 <Table 4>와 같다.

<Table 4> Summary for Dataset

Variable	num of Classes	Class
Category	6	short-sleeved shirt/ denim pants/suit pants/slacks, shirt/blouse/sweatsuit/ jogger pants/shorts
Review type	3	style review, product photo review, general review
sex	2	male, female
Brightness	3	Darkness, normal, brightness
Color-tone	3	blurry, normal, clearly
Thickness	3	thin, average, thick.
Size	3	small, normal, big

위와 같은 데이터를 이용해서 8:2의 비율로 훈련데이터와 평가데이터를 분류했다. 평가데

〈Table 5〉 Performance for Each Model

Models	Baseline		Baseline + category		Proposed model	
	Accuracy	F1 score	Accuracy	F1 score	Accuracy	F1 score
GRU	88.54	83.21	89.86	85.53	90.57	86.68
LSTM	86.67	81.33	87.13	82.17	88.89	84.34
Multi-head Attention	90.18	84.27	91.37	85.36	92.86	87.03
Ko-BERT	92.86	87.65	92.98	86.81	94.12	88.29

이터는 긍정/부정의 비율을 6:4로 설정해서 실험한 모델에 대한 평가를 진행했다. 감성라벨에 대한 정보는 리뷰에서 별점 데이터를 이용했다. 별점 5점은 긍정 데이터로 분류하고, 1,2,3점 데이터를 부정 데이터로 분류하여 학습했다. 모델을 학습할 때 Adam optimizer를 사용했고 [13], Learning rate는 0.001이며, 64의 배치사이드로 7 에폭만큼 학습을 진행했다. 하이퍼 파라미터는 학습데이터에서 0.1의 비율로 검증데이터를 구축하여 하이퍼 파라미터 최적화 작업을 진행했다.

4.2 실험 결과

실험은 총 4가지의 정확도와 f1-score를 비교하여 성능을 검증하는 방식으로 진행했다. 4가지 방식 모두 동일한 조건에서 실험을 진행하였다. 첫 번째로 사용한 baseline 모델은 리뷰 데이터만을 이용하여 예측한 감성분석 모델이다. 두 번째는 baseline 모델에 텍스트 인코더의 출력값에 제품에 대한 카테고리 정보를 합쳐서 학습하는 모델이다. 그리고 본 논문에서 제안하는 멀티모달 방식으로 메타데이터를 MLP를 사용해서 학습한 특징 벡터를 텍스트 인코더의 출력값과 합쳐서 학습하는 방법이다.

<Table 5>와 같이 메타 데이터의 정보를 멀

티모달 형식으로 학습 시킨 결과가 가장 정확도가 높음을 확인할 수 있다. 모델 중에서는 attention 기반의 방법이 시퀀스 기반 모델보다 성능이 좋음을 확인할 수 있었다.

5. 결 론

리뷰 데이터에 대한 감성분석은 자연어 처리 분야에서 오래전부터 주목받아온 분야이고, 사용자의 리뷰데이터를 이용한 마케팅 방법이 온라인 시장에서 활발하게 활용되고 있다. 감성분석은 크게 사전기반의 감성분석과 머신러닝 기반의 감성분석이 존재한다. 머신러닝 기반의 감성분석은 사용자가 작성한 리뷰데이터와 그에 맞는 감성 라벨 값을 이용해서 지도학습을 통한 모델 학습과정을 거친다.

그러나 여러 제품들이 공존하고 있는 사이트에서 리뷰 데이터는 카테고리 별로 또는 사용자 별로 다른 특징들을 지니고 있다. 따라서 본 연구에서는 제품에 대한 정보와 사용자에 대한 정보를 메타 데이터로 활용하여 감성분석에 이용하고자 했다. MLP를 이용하여 메타데이터를 학습하고, 리뷰데이터를 입력한 모델과 멀티모달 방식으로 학습한 감성분석 모델을 제안한다.

리뷰를 입력 값으로 받는 4가지 모델을 제안하는 방법을 포함한 3가지 방식에 대한 정확도를 비교하여 제안하는 모델의 성능을 검증했다. 검증 결과 제안한 방법의 정확도가 가장 높음을 확인 할 수 있었다. 이를 통해서 사용자의 정보를 MLP를 통해서 학습시킨 정보를 추가한다면 좀 더 명확한 감성분석의 결과를 얻을 수 있음을 확인하였다. 머신러닝을 통한 예측 알고리즘이 대부분의 도메인에서 많이 사용되고 있다. 그런데 주가 예측의 같은 경우에 대부분의 연구들이 특정 일자를 기준으로 예측을 진행하기 때문에 실시간으로 즉각적인 의사결정이 요구되는 자동매매 시스템이 직접적으로 응용하는 데에는 한계를 가지고 있다. 따라서 즉각적으로 이루어지는 매도/매수 의사결정을 고려했을 때, 보상과 행동을 모델링할 수 있는 강화학습이 효과적인 대안이 될 수 있다.

References

- [1] Agarwal, A., Yadav, A., and Vishwakarma, D. K., "Multimodal sentiment analysis via RNN variants," 2019 IEEE International Conference on Big Data, Cloud Computing, Data Science & Engineering (BCD), IEEE, 2019.
- [2] Ambartsoumian, A. and Popowich, F., "Self-attention: A better building block for sentiment analysis neural network classifiers," arXiv preprint arXiv:1812.07860, 2018.
- [3] Bahdanau, D., Cho, K., and Bengio, Y., "Neural machine translation by jointly learning to align and translate," arXiv preprint arXiv:1409.0473, 2014.
- [4] Baltrušaitis, T., Ahuja, C., and Morency, L., "Multimodal machine learning: A survey and taxonomy," IEEE transactions on pattern analysis and machine intelligence, Vol. 41, No. 2, pp. 423-443, 2018.
- [5] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., and Bengio, Y., "Learning phrase representations using RNN encoder-decoder for statistical machine translation," arXiv preprint arXiv:1406.1078, 2014.
- [6] Devlin, J., Chang, M., Lee, K., and Toutanova, K., "Bert: Pre-training of deep bidirectional transformers for language understanding," arXiv preprint arXiv:1810.04805, 2018.
- [7] Gruber, N. and Jockisch, A., "Are GRU cells more specific and LSTM cells more sensitive in motive classification of text?," Frontiers in Artificial Intelligence, Vol. 3, 2020.
- [8] Hochreiter, S. and Schmidhuber, J., "Long short-term memory," Neural Computation, Vol. 9, No. 8, pp. 1735-1780, 1997.
- [9] Huang, Q., Chen, R., Zheng, X., and Dong, Z., "Deep sentiment representation based on CNN and LSTM", 2017 International Conference on Green Informatics (ICGI), IEEE, 2017.
- [10] Hwang, S. and Kim, D., "BERT-based Classification Model for Korean Docu-

- ments,” *The Journal of Society for e-Business Studies*, Vol. 25, No. 1, 2020.
- [11] Jeon, W., Lee, Y., and Geum, Y., “Airline Service Quality Evaluation Based on Customer Review Using Machine Learning Approach and Sentiment Analysis,” *The Journal of Society for e-Business Studies*, Vol. 26, No. 4, pp. 15–36, 2021.
- [12] Jin, Z., Cao, J., Guo, H., Zhang, Y., and Luo, J., “Multimodal fusion with recurrent neural networks for rumor detection on microblogs,” *Proceedings of the 25th ACM international conference on Multimedia*, 2017.
- [13] Kingma, D. P. and Ba, J., “Adam: A method for stochastic optimization,” *arXiv preprint arXiv:1412.6980*, 2014.
- [14] Mohan, S., Mullapudi, S., Sammeta, S., Vijayvergia, P., and Anastasiu, D. C., “Stock price prediction using news sentiment analysis,” *2019 IEEE Fifth International Conference on Big Data Computing Service and Applications (BigDataService)*, IEEE, 2019.
- [15] Oh, P. and Hwang, B., “Real-time Spatial Recommendation System based on Sentiment Analysis of Twitter,” *The Journal of Society for e-Business Studies*, Vol. 21, No. 3, pp. 15–28, 2016.
- [16] Pannala, N. U., Nawarathna, C. P., Jayakody, J. T. K., Rupasinghe, L., and Krishnadeva, K., “Supervised learning based approach to aspect based sentiment analysis,” *2016 IEEE International Conference on Computer and Information Technology (CIT)*, IEEE, 2016.
- [17] Pires, T., Schlinger, E., and Garrette, D., “How Multilingual is Multilingual BERT?,” *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*, pp. 4996–5001, 2019.
- [18] Poria, S., Cambria, E., and Gelbukh, A., “Deep convolutional neural network textual features and multiple kernel learning for utterance-level multimodal sentiment analysis,” *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*, 2015.
- [19] Severyn, A. and Moschitti, A., “Twitter sentiment analysis with deep convolutional neural networks,” *Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2015.
- [20] Smeureanu, I. and Zurini, M., “Spam Filtering for Optimization in Internet Promotions using Bayesian Analysis,” *Journal of Applied Quantitative Methods*, Vol. 5, No. 2, pp. 198–211, 2010.
- [21] Sun, C., Huang, L., and Qiu, X., “Utilizing BERT for aspect-based sentiment analysis via constructing auxiliary sentence,” *arXiv preprint arXiv:1903.09588*, 2019.
- [22] Sutskever, I., Vinyals, O., and Le, Q. V., “Sequence to sequence learning with neural networks,” *Advances in Neural Information Processing Systems*, 2014.
- [23] Vaswani, A., Shazeer, N., Parmar, N.,

- Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., and Polosukhin, I., "Attention is all you need," In Advances in Neural Information Processing Systems, pp. 6000–6010, 2017.
- [24] Wang, H., Can, D., Kazemzadeh, A., Bar, F., and Narayanan, S., "A system for real-time twitter sentiment analysis of 2012 us presidential election cycle," Proceedings of the ACL 2012 System Demonstrations, 2012.
- [25] Xu, N. and Mao, W., "Multisentinet: A deep semantic network for multimodal sentiment analysis," Proceedings of the 2017 ACM on Conference on Information and Knowledge Management, 2017.
- [26] Yang, L., Li, Y., Wang, J., and Sherratt, R. S., "Sentiment analysis for E-commerce product reviews in Chinese based on sentiment lexicon and deep learning," IEEE Access, Vol. 8, pp. 23522–23530, 2020.

저 자 소 개



황호현
2020년
2020년~현재
관심분야

(E-mail: hhhwang94@ds.seoultech.ac.kr)
서울과학기술대학교 산업정보시스템전공 (학사)
서울과학기술대학교 데이터사이언스학과 (석사과정)
자연어처리, 인공지능망, 텍스트마이닝, XAI



이경찬
2018년
2020년~현재
관심분야

(E-mail: nahcklee@gmail.com)
충남대학교 메카트로닉스공학과 (학사)
서울과학기술대학교 데이터사이언스학과 (석사과정)
추천시스템, 머신러닝, 자연어 처리



유진이
2021년
2021년~현재
관심분야

(E-mail: wlsdl2664@gmail.com)
서울과학기술대학교 산업정보시스템전공 (학사)
서울과학기술대학교 데이터사이언스학과 (석사과정)
빅데이터, 텍스트 마이닝, 자연어 처리, AI



이영훈
2007년
2009년
2009년~2016년
2019년
2019년~현재
관심분야

(E-mail: yhoon.lee@seoultech.ac.kr)
서울대학교 산업공학과(학사)
서울대학교 산업공학과(석사)
LG전자 UX연구소
서울대학교 산업공학과 (박사)
현대자동차 빅데이터실
서울과학기술대학교 산업공학과 조교수
텍스트 분석, 사용자 데이터 분석