

앙상블 기법을 활용한 온라인 음식 상품 리뷰 감성 분석

김한민*, 박경보
성균관대 경영대학 박사과정

Sentiment analysis of online food product review using ensemble technique

Han-Min Kim*, Kyungbo Park
Doctoral Student, Business School, Sungkyunkwan University

요 약 온라인 시장에서 소비자는 다양한 상품을 접하고 이에 대한 의견을 자유롭게 기술한다. 소비자의 상품 리뷰가 다른 소비자와 온라인 시장의 성공에 큰 영향을 주는 만큼 온라인 시장은 판매 상품에 대한 소비자의 감성을 정확하게 분석할 필요가 있다. 데이터 분석 기법 중 하나인 텍스트 마이닝은 상품에 대한 소비자 리뷰를 분석하여 상품을 효율적으로 관리할 수 있게 해준다. 선행 연구들은 데이터 도메인과 사이즈에 따라 분석 결과의 정확도가 다르게 나타남에도 불구하고 특정 도메인과 2만개 미만의 데이터를 분석해왔다. 또한, 분석의 정확도를 향상시킬 수 있는 추가 요인에 대한 연구는 거의 수행하지 않았다. 본 연구는 앙상블 기법을 활용하여 기존 연구에서 주로 다루지 않은 음식 상품 도메인의 72,530개 리뷰 데이터를 분석하였다. 또한, 분석 정확도 향상과 관련하여 요약 리뷰의 영향력을 살펴보았다. 연구 결과, 본 연구는 기존 연구와 다르게 부스팅 앙상블 기법이 가장 높은 분석 정확도를 보인다는 사실을 발견하였다. 또한, 요약 리뷰는 분석의 정확도 향상에 기여하는 것으로 나타났다.

주제어 : 텍스트 마이닝, 감성 분석, 앙상블 기법, 온라인 시장, 머신러닝

Abstract In the online marketplace, consumers are exposed to various products and freely express opinions. As consumer product reviews have a important effect on the success of online markets and other consumers, online market needs to accurately analyze the consumers' emotions about their products. Text mining, which is one of the data analysis techniques, can analyze the consumer's reviews on the products and efficiently manage the products. Previous studies have analyzed specific domains and less than 20,000 data, despite the different accuracy of the analysis results depending on the data domain and size. Further, there are few studies on additional factors that can improve the accuracy of analysis. This study analyzed 72,530 review data of food product domain that was not mainly covered in previous studies by using ensemble technique. We also examined the influence of summary review on improving accuracy of analysis. As a result of the study, this study found that Boosting ensemble technique has the highest accuracy of analysis. In addition, the summary review contributed to improving accuracy of the analysis.

Key Words : Text mining, Sentiment analysis, Ensemble technique, Online market, Machine learning

1. 서론

온라인 시장이 경쟁에서 살아남고 지속적으로 성장하기 위해서는 소비자를 만족시킬 수 있는 상품을 제공하

고 판매하는 것이 중요하다[1]. 다시 말해서, 온라인 시장은 소비자가 신뢰 할 수 있는 상품을 제공하고 관리하는 능력이 필요하다고 볼 수 있다. 온라인 시장의 성공은 소비자가 만족하고 믿을 수 있는 상품을 제공하여 자사의

*Corresponding Author : Han-Min Kim(hanmin8809@gmail.com)

Received February 8, 2019
Accepted April 20, 2019

Revised March 9, 2019
Published April 28, 2019

마켓에 대한 신뢰를 쌓는 것이라고 해도 과언이 아니다 [2]. 따라서 온라인 마켓은 판매 상품에 대한 소비자의 평가를 이해할 필요가 있다. 온라인 마켓에서 상품을 구매한 소비자는 상품에 대한 사용 경험과 개선 사항, 전반적인 평가 등을 상품 리뷰로 표현한다.

텍스트 마이닝(Text mining)은 자연어 처리 기술을 활용하여 텍스트 데이터로부터 정보를 찾아내는 기술로써 분석방법으로는 감성분석, 정보추출, 텍스트분류 등이 존재한다[3]. 이러한 텍스트 분석은 소셜 네트워크에서 선거와 같은 특정 이벤트에 대한 개인들의 감성을 분석하거나 온라인마켓의 상품 의견을 분석하는 등 다양한 분야에서 적용되어 왔다[4-8].

텍스트 마이닝의 감성 분석을 통해 온라인 마켓은 소비자를 만족시키는 상품에 대한 장점을 발견할 수 있을 뿐만 아니라 부정적인 상품을 효율적으로 관리 할 수 있다. 감성 분석을 위한 분류 기법에는 단일 분류 기법과 앙상블 기법이 존재한다. 앙상블 기법은 여러 단일 분류 기법을 조합해서 분석하는 기법으로 여러 단일 분류기법들의 알고리즘을 조합해서 분석을 실시하기 때문에 최적의 분석결과 값을 단일 분류 기법보다 쉽게 도출해낼 수 있다는 장점을 가지고 있다[9]. 감성분석에 앙상블 기법을 적용한 선행 연구들은 앙상블 기법이 단일 분류 기법보다 우수한 분류 정확도를 제공한다는 사실을 확인해왔다[10,11].

한편, 앙상블 기법을 기반으로 한 감성 분석 연구에서는 데이터의 도메인에 따라 최적의 분류 정확도를 제공하는 분석 기법이 다르게 나타나고 있다[10]. 또한, 데이터 크기에 따라 분석 정확도가 다르게 나타나기 때문에 데이터 크기에 따른 적절한 분석방법의 발견이 이루어져야 한다고 언급하고 있다[11]. 하지만, 선행 연구들은 주로 2 만 개 미만의 데이터를 사용하여 감성 분석을 실시하였으며, 가전·제품·서적·DVD 등과 같은 데이터 도메인을 대상으로 앙상블 기법의 성능을 검증해왔다[10-17]. 반면에, 본 연구에서 분석하고자 하는 음식 상품 도메인과 2만개 이상의 데이터를 활용하였을 때 나타나는 분석 기법의 정확도 차이는 거의 연구되지 않은 상황이다.

한편, 앙상블 기법을 활용한 선행연구들은 감성 분석의 정확도를 향상시키기 위해 텍스트에 첨부된 이모티콘 요인을 고려하였으며 결과적으로 이모티콘이 분류 정확도를 향상 시킨다는 사실을 발견하였다[11]. 하지만 이모티콘 이외에 분석의 정확도를 향상시킬 수 있는 추가 요

인 발견에 대한 연구는 거의 진행되고 있지 않다. 본 연구는 상품 리뷰에 대한 요약 리뷰가 상품 평가에 대한 핵심 단어들을 포함하고 있기 때문에 감성분석에서 소비자의 감성을 분류하는데 큰 기여를 할 수 있다고 판단한다. 하지만 아직까지 상품의 요약 리뷰에 대한 영향력을 검토한 연구는 거의 진행되지 않았다.

이러한 인식을 기반으로 본 연구는 다음과 같은 연구 목표를 설정하였다. 첫 번째, Bayes Net, Naive Bayes, Logistic, Artificial Neural Network (ANN), Support Vector Machine (SVM), Decision Tree (DT) 와 같은 단일 분류 기법들과 Boosting, Bagging, Random Subspace, Random Forest의 앙상블 기법들의 분류 정확도 차이를 비교하고자 한다. 이를 통해 앙상블 기법이 단일 분류 기법을 활용하였을 때 보다 분석의 정확도를 향상시킬 수 있는지 확인하고자 한다. 두 번째, 음식 상품 리뷰 도메인과 72,530개의 데이터를 활용하여 도메인과 데이터 크기에서 올 수 있는 분류 기법의 정확도 차이를 선행 연구 결과와 비교하고자 한다. 세 번째, 상품 요약 리뷰를 포함한 데이터가 소비자의 감성을 정확히 분류하는데 기여하는 영향력을 검증하고자 한다. 이를 통해 감성분석의 정확도를 향상시킬 수 있는 방안을 강구하고자 한다.

본 연구의 구성은 다음과 같다. 2장에서 앙상블 기법을 활용한 기존 감성 분석 연구들을 살펴보고자한다. 3장에서는 본 연구의 연구방법을 기술하며, 4장에서는 분석 결과를 제시한다. 5장에서는 연구 결과를 토대로 본 연구의 기여사항, 한계점 및 향후 연구방향에 대해 논의하고자 한다.

2. 이론적 배경

2.1 앙상블 기법을 활용한 감성분석 연구

앙상블 기법은 텍스트 분석에서 분석의 정확도를 높일 수 있는 방안으로 여겨져 왔다. Su et al. (2013)은 12,000개의 책, 호텔, 노트북 데이터 도메인 데이터를 활용하여 Stacking 앙상블 기법이 단일 분류 기법들 보다 높은 정확도를 보인다는 것을 발견하였으며, Rodriguez et al. (2013)는 트위터와 SMSs 4,435개의 데이터를 활용하여 앙상블 기법의 분류 정확도가 다른 단일 분류 기법보다 향상된 정확도를 제공한다는 사실을 발견하였다. Hassan et al. (2013)은 트위터의 14,000개 데이터를 활용

하여 단일 분류기법들을 조합한 앙상블 기법이 높은 분류 정확도를 가진다는 것을 확인하였으며, Da Silva et al. (2014)는 트위터의 3,785개 데이터와 이모티콘을 활용한 앙상블 기법이 단일 분류 기법보다 향상된 분석 결과를 제공한다는 사실을 발견하였다. 또한, 데이터 크기에 따라서 최적의 분석정확도를 제공하는 분석 방법의 차이가 존재한다는 사실을 발견하였다. Wang et al. (2014)은 카메라, 캠프, 약물, 라디오, TV 등 8개의 다양한 데이터 도메인을 감성 분석하여 앙상블 기법이 높은 분석 정확도를 보여준다는 것을 확인하였으며, 데이터 도메인에 따라서 최적의 분석 정확도를 갖는 분석 방법이 다르게 나타난다는 사실을 발견하였다. 구체적으로 의료, 라디오, 영화 등의 도메인에서 대부분 SVM 기반 Random Subspace 앙상블기법이 가장 높은 분석 정확도를 나타낸 반면 카메라, 노트북의 도메인은 Bagging 앙상블 기법이 가장 높은 분석 정확도를 보이는 것으로 나타났다.

Fersini et al. (2014)은 17,818개의 영화, 도서, 음악, 트위터 도메인 데이터를 분석하여 앙상블 기법이 우수하다는 것을 확인하였으며, Chalothom and Ellman (2015)의 연구에서도 Stacking 앙상블 기법이 단일 분류 기법보다 향상된 분석 결과를 보여준다는 것을 확인하였다. Catal and Nangir (2017)의 연구 또한 9,052개의 도서, 영화, 쇼핑 도메인 데이터를 활용하여 앙상블기법이 정확도를 향상시킨다는 사실을 확인하였다.

요약하면 선행 연구들은 음식상품 이외의 도메인들을 대상으로 2만개 미만의 데이터를 분석하였으며, Da Silva et al. (2014)의 연구를 제외하고 분석의 정확성을 향상시킬 수 있는 추가적인 방법에 대한 연구는 거의 수행하지 않았다. 다시 말해서, 음식 상품에 대한 소비자의 리뷰를 보다 정확하게 분석할 수 방안에 대한 연구는 아직 해소해야할 학문적 과제라고 볼 수 있다. 따라서 본 연구는 아직까지 크게 고려되지 않았던 음식 상품 도메인을 대상으로 72,530 개의 리뷰 데이터를 분석하고자 한다. 추가적으로, 소비자의 요약리뷰가 분석 정확도 향상에 미치는 영향력을 발견하고자 한다. 앙상블 기법을 활용한 감성 분석 연구의 흐름을 아래 Table 1에 기술하였다.

3. 연구 방법

3.1 데이터 수집 및 데이터 특성

본 연구에서 활용한 음식상품 리뷰 Raw 데이터는 <https://www.kaggle.com/> 사이트에서 제공 받았으며, 제공받은 데이터는 아마존에서 음식 상품을 구매하고 작성한 텍스트 리뷰, 평점, 작성자의 정보 등이 포함되어 있다. 분석에 앞서 본 연구는 아마존 사이트의 음식 상품 리뷰 데이터 568,455개를 전 처리하였다. 전 처리는 엑셀을 활용하여 중복 리뷰 데이터, 일부 항목이 누락된 결측

Table 1. The study of sentiment analysis using ensemble technique

Study	Data Domain	Data Size	Base learner	Ensemble Method	Study Result
Su et al., 2013	Book, Hotel, Notebook	12,000	NB, CB, KNN, ME, SVM	Voting, Stacking	Stacking shows best performance.
Rodriguez et al., 2013	Tweet, SMSs	4,435	CRF, SVM and heuristic method	Majority vote, upper bound, ensemble vote	Ensemble method provides good performance
Hassan et al., 2013	Tweet	14,000	RBF Neural Network, Random Tree, REP Tree, Naive Bayes, Bayes Net, Logistic Regression and SVM	bootstrap model (combining dataset, feature and classifier parameters)	Bootstrap (combining dataset, feature and classifier parameters) model shows good performance
Da Silva et al., 2014	Tweet	3,785 (emoticon: 1,600,000)	Random Forest, SVM, Multinomial Naive Bayes, Logistic Regression	Base learner ensemble (RF+SVM+NB+LR)	Ensemble with Lexicon shows best performance
Wang et al., 2014	Camera, Camp, Doctor, Drug, Laptop, Lawyer, Movie, Music, Radio, TV	8,034	NB, ME, DT, KNN, SVM	Bagging, Boosting, Random Subspace	Random Subspace with SVM shows best accuracy in 8 data set
Fersini et al., 2014	Movie, Book, Music, Tweet	17,818	NB, SVM, ME, CRF, DIC	Bagging, SV, Bayes Model Average (BMA)	BMA provides better performance
Chalothom and Ellman, 2015	Tweet	Not mentioned	SVM, Naive Bayes, Senti Strength	Stacking	Stacking has better performance
Catal and Nangir, 2017	Book, Movie, Shopping	9,052	Naive Bayes, SVM, Bagging	Voting, Bagging	Voting shows best accuracy

데이터 및 !,@,~ 등의 특수 문자를 제거하였다. 데이터 전처리 이후 본 연구는 분석에 사용할 72,530개의 데이터를 확보하였으며, 목표 변수는 음식상품에 대한 평가 1점을 부정적 감성(36,265개)으로 5점을 긍정적 감성(36,265개)으로 설정하였다. 아래에 음식 상품에 대한 실제 리뷰와 요약 리뷰를 예시로 기술 하였다.

음식 상품 리뷰에 대한 요약문:

“Very Low quality”

음식 상품에 대한 리뷰 본문:

“I don't know how long these sat on the back of a shelf somewhere but they were so old that they wouldn't cook I had to throw half of them out because the skins were damaged a clear sign of dried beans past their prime I can't even return these or ask for a refund because food is not returnable Will find a different brand to use For now I have about fifty servings of beans to throw away”

3.2 분석 방법

본 연구는 감성 분석을 위한 단일 분류 기법으로 Bayes Net, Naive Bayes, Logistic, Artificial Neural Network (ANN), Support Vector Machine (SVM), Decision Tree (DT)을 사용하였으며, 앙상블 기법으로는 Boosting, Bagging, Random Subspace, Random Forest를 사용하였다. 분석 프로그램은 무료 소프트웨어인 WEKA 3.722를 활용하였으며, 변수 선택 방법(Feature selection)으로 Info gain-ranker 와 Term Frequency-Inverse Document Frequency(TF-IDF)을 적용하였다. 또한, 10-fold 교차 검증(10-fold cross validation)을 기반으로 분석 결과의 신뢰성을 확보하고 단일 분류 기법과 앙상블 기법 분석을 실시하였다. 본 연구는 총 2번의 분석을 실시하였다. 첫 번째 단계에서는 음식 상품 리뷰 본문만을 텍스트 분석하여 소비자의 감성을 분류 하였다. 두 번째 단계에서는 음식 상품 리뷰 본문에 리뷰 요약문을 추가하여 텍스트 분석하였다.

4. 분석결과

본 연구는 분석 결과를 검증하기 위해 Accuracy, Precision, Recall, F-measure, Area Under Curve (AUC)를 활용하였다. 여러 측정 기준을 통해 보다 정확한 최적의 분석 결과를 판단하고자 하였다. 첫 번째 음식 상품에 대한 일반 리뷰 감성 분석결과, 단일 분류기법을 적용했을 때보다 앙상블 기법을 적용했을 때 상대적으로 감성 분석의 정확도가 향상된 것을 볼 수 있었다. 또한, 앙상블 기법 중 Boosting with DT (LMT)이 소비자의 음식 상품 리뷰를 가장 잘 정확하게 분류하는 것을 확인 할 수 있었다(Accuracy: 0.827, Precision: 0.827, Recall: 0.827, F-measure: 0.827, AUC: 0.923). 두 번째 분석에서는 일반 상품리뷰에 요약 리뷰를 추가한 분석을 진행하였다. 분석 결과, 일반적인 리뷰만을 분석하는 것보다 요약 리뷰를 추가하여 분석하는 것이 소비자의 감성을 보다 정확하게 분류하는 것으로 나타났다. 또한, 단일 분류기법을 적용하였을 때 보다 Boosting, Bagging, Random Subspace, Random Forest의 앙상블 기법이 향상된 분류 정확도를 제공한다는 사실을 확인하였다. 앙상블 기법에서는 Boosting with DT (LMT)이 상품에 대한 감성을 가장 정확하게 분류하는 것으로 나타났다(Accuracy: 0.856, Precision: 0.856, Recall: 0.856, F-measure: 0.856, AUC: 0.945). 본 연구의 결과를 아래 Table 2와 Table 3에 구체적으로 기술 하였다.

5. 논의

5.1 기여 사항

본 연구의 기여 사항은 다음과 같다. 첫째, 본 연구는 단일 분류기법보다 앙상블기법을 적용했을 때 감성분석 정확도가 향상된다는 사실을 확인하였다. 선행 연구에서 앙상블 기법이 단일 분류 기법들의 다양한 알고리즘을 활용하기 때문에 최적의 값을 쉽게 도출 할 수 있다는 관점을 지지하는 결과이다[10-17]. 텍스트를 기반으로 한 감성분석 시 보다 높은 분석 정확도를 얻고자 한다면 앙상블 기법을 적극적으로 활용할 가치가 있다고 할 수 있다. 하지만 앙상블 기법은 분석에 있어 단일 분석 기법보다 높은 컴퓨터 분석능력을 필요로 하고 많은 시간을 소모하기 때문에 이에 대한 손익을 고려하여 실무에서 적용되어야 할 것이다. 예를 들어 컴퓨터 분석 능력이 충분히 확보한 기업에서는 앙상블 기법을 적극 활용하여 상

Table 2. Analysis result of Normal review

	Accuracy	Precision	Recall	F-measure	AUC
Bayes Net	0.772	0.775	0.772	0.772	0.862
Naive Bayes	0.772	0.775	0.772	0.772	0.862
Logistic	0.785	0.785	0.785	0.785	0.872
ANN	0.779	0.780	0.778	0.778	0.866
SVM	0.784	0.784	0.784	0.784	0.784
DT (Hoeffding Tree)	0.770	0.770	0.770	0.770	0.854
DT (J48)	0.778	0.778	0.777	0.777	0.848
DT (LMT)	0.784	0.785	0.784	0.784	0.872
DT (Random Tree)	0.757	0.757	0.757	0.757	0.811
DT (REP Tree)	0.770	0.770	0.770	0.770	0.849
Boosting with Bayes Net	0.774	0.779	0.774	0.773	0.856
Boosting with Naive Bayes	0.774	0.779	0.774	0.773	0.856
Boosting with Logistic	0.785	0.785	0.785	0.784	0.854
Boosting with NN	0.777	0.778	0.777	0.777	0.862
Boosting with SVM	0.784	0.784	0.784	0.784	0.859
Boosting with DT (Hoeffding Tree)	0.776	0.776	0.776	0.776	0.860
Boosting with DT(J48)	0.773	0.773	0.773	0.773	0.856
Boosting with DT (LMT)	0.827	0.827	0.827	0.827	0.923
Boosting with DT (Random Tree)	0.768	0.767	0.767	0.767	0.842
Boosting with DT (REP Tree)	0.775	0.775	0.775	0.775	0.860
Bagging with Bayes Net	0.772	0.775	0.772	0.772	0.862
Bagging with Naive Bayes	0.772	0.775	0.772	0.772	0.862
Bagging with Logistic	0.785	0.785	0.785	0.785	0.872
Bagging with NN	0.785	0.785	0.785	0.785	0.875
Bagging with SVM	0.785	0.785	0.785	0.785	0.803
Bagging with DT (Hoeffding Tree)	0.781	0.781	0.781	0.781	0.867
Bagging with DT(J48)	0.780	0.780	0.780	0.779	0.861
Bagging with DT (LMT)	0.821	0.822	0.821	0.821	0.915
Bagging with DT (Random Tree)	0.769	0.769	0.769	0.769	0.852
Bagging with DT (REP Tree)	0.776	0.776	0.776	0.776	0.863
Random Subspace with Bayes Net	0.763	0.766	0.763	0.762	0.854
Random Subspace with Naive Bayes	0.763	0.766	0.763	0.762	0.854
Random Subspace with Logistic	0.773	0.775	0.773	0.773	0.863
Random Subspace with NN	0.772	0.772	0.772	0.772	0.859
Random Subspace with SVM	0.763	0.763	0.763	0.763	0.839
Random Subspace with DT (Hoeffding Tree)	0.774	0.774	0.774	0.774	0.862
Random Subspace with DT (J48)	0.777	0.777	0.777	0.777	0.862
Random Subspace with DT (LMT)	0.774	0.775	0.774	0.774	0.863
Random Subspace with DT (Random Tree)	0.773	0.774	0.773	0.773	0.862
Random Subspace with DT (REP Tree)	0.773	0.773	0.773	0.773	0.861
Random Forest	0.773	0.773	0.773	0.772	0.857

품 관리 및 판매 전략을 보다 명확하게 수립할 수 있을 것이다. 두 번째, 본 연구는 7만개 이상의 데이터 크기에 있어서 음식 상품 도메인의 감성 분석 결과를 제공하였다. 감성 분석에서 데이터 크기와 도메인에 따라 최적의 분석 결과를 도출하는 분석 방법이 달라질 수 있지만 대부분의 선행 연구들은 음식 상품 도메인을 크게 고려하지 않고 비교적 적은 2만개 미만의 데이터를 분석에 사용하였다[10-17]. 본 연구는 72,530 개의 음식 상품 리뷰 데이터를 사용하여 분석하였으며, 그 결과 Boosting with DT(LMT) 양상블 기법이 가장 높은 분류 정확도를 보인

다는 사실을 발견하였다. 한편, SVM 기반의 랜덤 서브스페이스(Random Subspace) 양상블 기법은 선행 연구에서 가장 우수한 성능을 보인 것[8]과는 다르게 본 연구에서 가장 낮은 정확도를 보였다. 이러한 결과는 데이터 크기와 도메인에 따라 감성분석을 정확하게 실시할 수 있는 분석방법이 다르게 나타날 수 있다는 시사점을 제공한다. 향후 연구에서는 데이터의 크기와 도메인에 따라서 분석방법에 대한 다양한 시도와 이론적 고찰이 이루어져야 할 것이다. 세 번째, 본 연구는 감성 분석에 있어 요약 리뷰가 분석의 정확도를 향상 시킨다는 사실을

Table 3. Analysis result of Normal review + Summary review

	Accuracy	Precision	Recall	F-measure	AUC
Bayes Net	0.806	0.807	0.806	0.806	0.898
Naive Bayes	0.806	0.807	0.806	0.806	0.898
Logistic	0.818	0.818	0.818	0.818	0.905
NN	0.813	0.814	0.813	0.812	0.899
SVM	0.809	0.818	0.809	0.808	0.809
DT (Hoeffding Tree)	0.805	0.806	0.805	0.805	0.888
DT (J48)	0.813	0.813	0.813	0.813	0.883
DT (LMT)	0.818	0.818	0.818	0.818	0.905
DT (Random Tree)	0.795	0.796	0.796	0.796	0.850
DT (REP Tree)	0.804	0.804	0.804	0.804	0.882
Boosting with Bayes Net	0.807	0.809	0.807	0.807	0.888
Boosting with Naive Bayes	0.807	0.809	0.807	0.807	0.888
Boosting with Logistic	0.818	0.818	0.818	0.818	0.889
Boosting with NN	0.825	0.825	0.825	0.825	0.907
Boosting with SVM	0.810	0.819	0.810	0.809	0.896
Boosting with DT (Hoeffding Tree)	0.812	0.812	0.812	0.812	0.892
Boosting with DT(J48)	0.810	0.810	0.810	0.810	0.890
Boosting with DT (LMT)	0.856	0.856	0.856	0.856	0.945
Boosting with DT (Random Tree)	0.805	0.805	0.805	0.805	0.878
Boosting with DT (REP Tree)	0.810	0.810	0.810	0.810	0.893
Bagging with Bayes Net	0.806	0.807	0.806	0.806	0.898
Bagging with Naive Bayes	0.806	0.807	0.806	0.806	0.898
Bagging with Logistic	0.818	0.818	0.818	0.818	0.905
Bagging with NN	0.829	0.829	0.829	0.829	0.916
Bagging with SVM	0.810	0.819	0.810	0.809	0.814
Bagging with DT (Hoeffding Tree)	0.816	0.816	0.816	0.816	0.901
Bagging with DT(J48)	0.814	0.814	0.814	0.814	0.895
Bagging with DT (LMT)	0.850	0.850	0.850	0.850	0.936
Bagging with DT (Random Tree)	0.806	0.806	0.806	0.806	0.886
Bagging with DT (REP Tree)	0.811	0.811	0.811	0.811	0.896
Random Subspace with Bayes Net	0.800	0.801	0.800	0.800	0.889
Random Subspace with Naive Bayes	0.800	0.801	0.800	0.800	0.889
Random Subspace with Logistic	0.811	0.812	0.812	0.812	0.896
Random Subspace with NN	0.825	0.825	0.825	0.825	0.907
Random Subspace with SVM	0.794	0.794	0.794	0.794	0.876
Random Subspace with DT (Hoeffding Tree)	0.808	0.808	0.808	0.808	0.893
Random Subspace with DT(J48)	0.808	0.809	0.808	0.808	0.893
Random Subspace with DT (LMT)	0.810	0.811	0.810	0.810	0.896
Random Subspace with DT (Random Tree)	0.810	0.810	0.810	0.810	0.896
Random Subspace with DT (REP Tree)	0.810	0.810	0.810	0.810	0.895
Random Forest	0.809	0.809	0.809	0.809	0.891

Bold: best value

발견하였다. 기존 연구에서는 개인의 일반적인 리뷰를 토대로 분류 분석을 실시해왔으며 추가적으로 분석의 정확도를 향상시킬 수 있는 방법으로 이모티콘의 활용을 제시하고 있었다[9]. 하지만 이모티콘 이외에 분석 결과를 향상시킬 수 있는 요약 리뷰의 역할에 대한 연구는 거의 이루어지지 않았다. 이에 본 연구는 소비자의 요약 리뷰가 상품에 대한 감성 분석의 정확도 향상에 기여할 수 있는지 분석하였다. 그 결과, 소비자의 요약 리뷰는 감성 분석의 분류 정확도를 향상 시킨다는 사실을 발견하였다. 이러한 결과는 소비자가 요약 리뷰에 자신의 생각을 보

다 명확하게 나타낼 수 있는 핵심단어를 포함시키기 때문에 발생하는 결과라고 할 수 있다. 향후 연구에서는 감성 분석을 진행할 때 의견을 보다 정확하게 분류할 수 있게 해주는 요약 리뷰에 주목해야 할 것이다. 실무적으로는 상품 리뷰 작성 시 요약 리뷰를 작성할 수 있게 하는 기능을 추가해야 할 것이다. 또한, 요약 리뷰 작성에 따른 할인 포인트나 베스트 상품리뷰 등록 자격을 제공하는 방안을 강구해야 할 것이다.

5.2 한계점 및 향후 연구방향

본 연구는 데이터 수집의 한계로 인해 온라인 마켓 한 곳의 리뷰만을 다루었으므로 다양한 온라인 마켓의 리뷰들을 활용하지 못했다. 온라인 마켓은 사이트마다 제공하는 상품, 가격, 이벤트, 사이트 디자인에 차이가 존재하므로 소비자의 리뷰도 사이트 별로 차이가 존재할 수 있다. 향후 연구에서는 다양한 온라인 마켓 사이트의 리뷰 데이터를 활용하여 감성분석을 실시해야 할 것이다. 예를 들어 이베이(eBay) 사이트의 리뷰를 분석하여 아마존의 리뷰 분석 결과와 차이점을 발견할 수 있을 것이다.

REFERENCES

[1] G. Kim & H. Koo. (2016). The causal relationship between risk and trust in the online marketplace: A bidirectional perspective. *Computers in Human Behavior*, 55, 1020-1029. DOI : 10.1016/j.chb.2015.11.005

[2] P. A. Pavlou & D. Gefen. (2004). Building effective online marketplaces with institution-based trust. *Information systems research*, 15(1), 37-59. DOI : 10.1287/isre.1040.0015

[3] W. Fan, L. Wallace, S. Rich & Z. Zhang. (2006). Tapping the power of text mining. *Communications of the ACM*, 49(9), 76-82. DOI : 10.1145/1151030.1151032

[4] D. Paranyushkin. (2011). *Identifying the pathways for meaning circulation using text network analysis*. Berlin: Nodus Labs.

[5] J. H. Ryu & Y. Y. You. (2018). The Fourth Industrial Revolution Core Technology Association Analysis Using Text Mining. *Journal of Digital Convergence*, 16(8), 129-136. DOI : 10.14400/JDC.2018.16.8.129

[6] J. H. Bae, J. E. Son & M. Song. (2013). Analysis of twitter for 2012 South Korea presidential election by text mining techniques. *Journal of Intelligence and Information Systems*, 19, 141-156. DOI : 10.13088/jiis.2013.19.3.141

[7] D. Y. Lee, J. C. Jo & H. S. Lim. (2017). User Sentiment Analysis on Amazon Fashion Product Review Using Word Embedding. *Journal of the Korea Convergence Society*, 8(1), 11. DOI : 10.15207/JKCS.2017.8.4.001

[8] E. Y. Kim & E. J. Ko. (2018). Monitoring Mood Trends of Twitter Users using Multi-modal Analysis method of Texts and Images. *Journal of the Korea Convergence Society*, 9(1), 419-431. DOI : 10.15207/JKCS.2018.9.1.419

[9] L. Rokach. (2010). *Pattern classification using ensemble methods*. World Scientific.

[10] G. Wang, J. Sun, J. Ma, K. Xu & J. Gu. (2014). Sentiment classification: The contribution of ensemble learning. *Decision support systems*, 57, 77-93. DOI : 10.1016/j.dss.2013.08.002

[11] N. F. F. Da Silva, E. R. Hruschkaa & E. R. Hruschka. (2014). Tweet sentiment analysis with classifier ensembles. *Decision Support Systems*, 66, 170-179. DOI : 10.1016/j.dss.2014.07.003

[12] C. Catal & M. Nangir. (2017). A sentiment classification model based on multiple classifiers. *Applied Soft Computing*, 50, 135-141. DOI : 10.1016/j.asoc.2016.11.022

[13] T. Chalothom & J. Ellman. (2015). Simple approaches of sentiment analysis via ensemble learning. *In information science and applications*. (pp. 631-639). Berlin, Heidelberg.

[14] E. Fersini, E. Messina & F. A. Pozzi. (2014). Sentiment analysis: Bayesian ensemble learning. *Decision support systems*, 68, 26-38. DOI : 10.1016/j.dss.2014.10.004

[15] A. Hassan, A. Abbasi & D. Zeng. (2013). Twitter sentiment analysis: A bootstrap ensemble framework. *In Social Computing*. (pp. 8-14). Alexandria, USA.

[16] C. Rodríguez-Penagos, J. A. Batalla, J. Codina-Filba, D. García-Narbona, J. Grivolla, P. Lambert & R. Saurí. (2013). FBM: Combining lexicon-based ML and heuristics for Social Media Polarities. In Second Joint Conference on Lexical and Computational Semantics (*SEM). *Proceedings of the Seventh International Workshop on Semantic Evaluation*. (pp. 483 - 489) Atlanta, Georgia.

[17] Y. Su, Y. Zhang, D. Ji, Y. Wang & H. Wu. (2012). Ensemble learning for sentiment classification. *In Workshop on Chinese Lexical Semantics*. (pp. 84-93). July, Berlin, Heidelberg.

김 한 민(Kim, Han Min)

[정회원]



- 2017년 2월 : 충남대학교 경영학과 경영정보시스템 (석사)
- 2017년 3월 ~ 현재 : 성균관대학교 경영대학 경영정보 (박사과정)
- 관심분야 : 악성댓글, 빅데이터, 데이터 마이닝, 블록체인

· E-Mail : hanmin8809@gmail.com

박 경 보(Park, Kyung Bo)

[정회원]



- 2015년 2월 : 경남대학교 경영학과 (경영학사)
- 2015년 3월 ~ 현재 : 성균관대학교 경영대학 경영정보 (석박사 통합과정)
- 관심분야 : 빅데이터, 데이터 마이닝, 헬스케어

· E-Mail : air_sword@naver.com