

임베딩 자질을 이용한 대화의 감정 분류

신동원^{0†,††}, 이연수^{††}, 장정선^{††}, 임해창[†]
고려대학교[†], ㈜엔씨소프트^{††}

dwshin@nlp.korea.ac.kr, {yeonsoo, jsjang}@ncsoft.com, rim@nlp.korea.ac.kr

Emotion Classification in Dialogues Using Embedding Features

Dong-Won Shin^{0†,††}, Yeon-Soo Lee^{††}, Jung-Sun Jang^{††}, Hae-Chang Lim[†]
Korea University[†], NCSOFT Corp.^{††}

요 약

대화 시스템에서 사용자 발화에 대한 감정 분석은 적절한 시스템 응답과 서비스를 제공하는데 있어 매우 중요한 정보이다. 본 연구에서는 단순한 긍, 부정이 아닌 분노, 슬픔, 공포, 기쁨 등 Plutchick의 8 분류 체계에 해당하는 상세한 감정을 분석하는 데 있어, 임베딩 모델을 사용하여 기존의 어휘 자질을 효과적으로 사용할 수 있는 새로운 방법을 제안한다. 또한 대화 속에서 발생한 감정의 지속성을 반영하기 위하여 문장 임베딩 벡터와 문맥 임베딩 벡터를 자질로서 이용하는 방법에 대해 제안한다. 실험 결과 제안하는 임베딩 자질은 특히 내용어에 대해 기존의 어휘 자질을 대체할 수 있으며, 데이터 부족 문제를 다소 해소하여 성능 향상에 도움이 되는 것으로 나타났다.

주제어: 감정 분류, 워드 임베딩, 임베딩 벡터

1. 서론

대화 시스템에서 감정 분석은 발화를 통해 나타나는 특정 화자의 내재된 감정을 분석하는 것이다. 이러한 감정 분석은 로봇의 표정을 변화시키고 적절한 음악이나 영화를 추천하는 등 적절한 시스템 응답을 결정하는 데 있어 매우 중요하다. 예를 들어, 사용자가 “아 정말 졸리고 지루하다.” 라고 했을 때, 시스템이 사용자의 감정을 인식한다면 이를 해소할 수 있는 즐거운 음악이나 영상 등의 콘텐츠를 제공할 수 있을 것이고, “내일 시험 때문에 걱정 되서 잠이 안 오네.” 라는 걱정의 감정을 인식한다면 명상이나 차분한 음악 등을 들려 줄 수 있을 것이다.

위와 같이 대화 속에서 단순한 긍, 부정이 아닌 기쁨, 슬픔, 기대, 공포 등 사용자의 다양한 감정에 대해 인식하는 감정 분석(emotion analysis)에 관한 연구들은 비교적 많지 않다. 또한 감정에 대한 분류 체계는 적용하는 응용 시스템에 따라 제각각인 경우가 많다. 본 연구에서는 기존 [1] [2] 에서와 같이 Plutchick의 8 분류 체계[3] - ‘기쁨’, ‘신뢰’, ‘두려움’, ‘놀람’, ‘슬픔’, ‘혐오’, ‘화남’, ‘기대’ - 에 ‘감정 없음’을 더한 9가지의 분류 체계에 기반을 두어 감정 분석을 하고자 한다.

최근의 연구들은 감정 분석을 다중 분류 문제로 보고 지도 학습 기반의 분류기를 제안한다. 이를 위해 현재 발화나 이전 발화에 나타난 N-gram 자질, 이모티콘, 감성 사전, 관용어 사전 등을 주요 자질로 제안하였다. 그러나 각 세분화된 감정들에 대해 지도 학습(supervised learning)을 위한 충분한 학습 데이터를 구축하는 것이 매우 어려울 뿐 아니라 어휘 자질의 과도한 사용은 데이터 부족문제를 유발한다. 예를 들면, 나 정말 속상해.

(슬픔) 라던가 “진짜 재밌다.(기쁨)” 등에 대해서는 학습 데이터에 나타난 고빈도 감정 어휘를 사용하였기 때문에 잘 동작하지만, 학습 데이터에 나타나지 않은 “드디어 성공했어.(기쁨)” 등의 표현에 대해서는 적절한 감정을 결정할 수 없게 된다. 또한 대화 속에서의 감정은 단순히 발화 하나를 통해 나타나기도 하지만 일반적으로 지속성을 갖고 있다. 따라서 “화자A:어제 혼났다며” / “화자B: 담임 선생님한테 지각했다고 혼났지” / “화자A: 많이 혼났니?” / “화자B: 응” 과 같은 이어지는 대화 예제에서 화자 B의 “응”에 나타난 감정은 “감정 없음”이 아니라 이전 발화에서 이어지는 “슬픔”의 감정이 더 적절하다고 할 수 있다.

본 연구는 이러한 어휘 자질의 데이터 부족 문제, 대량의 학습 데이터 확보에 대한 어려움, 문맥을 통한 감정의 지속성 등의 문제를 풀기 위해 최근 많이 사용되는 워드 임베딩(word embedding) 모델에서 쓰이는 임베딩 벡터(embedding vector)를 감정 분류 모델의 자질로서 사용하는 새로운 방법에 대해 제안한다.

2. 관련 연구

2.1 감정 분류

사용자의 감정 인식, 전달 연구에 관한 연구는 주로 affective computing 분야에서 활발하게 이루어져 왔다. 전통적으로 감정에 대한 분류 체계로는 주로 행복, 슬픔, 화남, 혐오, 놀람, 공포로 이루어진 Ekman의 6 가지 분류 체계[4]가 사용되어 왔으며, 이미지나 영상 등에서 표정을 나타내는 facial landmark point 등을 추출하거나, head pose, eye gaze, prosody, nonlinguistic vocalization (laugh, cry) 등을 이용하여 사용자의 현재 감정 상태를 분류한다[5].

이와는 별개로 텍스트 영역으로 한정된 감정 분석 연구들은 주로 사용자가 발화를 통해 표현한 어휘를 통해 감정을 인식하고자 한다. [6]의 경우 Ekman의 6가지 감정 카테고리에 대해 감정 단어 사전 및 감정 이모티콘 사전을 구축하여 이들 자질을 기반으로 SVM(Support Vector Machine) 분류기를 이용하여 블로그에서 감정을 인식하고자 하였다. [7]의 경우는 트윗 데이터를 대상으로 하였으며, 감정 사전을 구축하는 대신 광범위한 uni-gram 자질을 사용하였다. [1]의 경우 음식, 사랑, 음악과 관련된 대화 시스템에서 사용자 발화의 감정을 분석하고자 하였다. 이 연구에서는 대상이 구어체 대화라는 점을 고려하여 광범위한 n-gram 뿐 아니라 마지막 어미, 관용 현 사전, 이전 발화에서의 분석된 감정 정보 등을 자질로서 사용하였다. [2]의 연구 역시 이와 유사하게 현재 발화, 전 발화, 전전 발화에 대해 광범위한 n-gram을 자질로서 사용하였다.

그러나 위와 같은 n-gram 어휘 자질을 사용한 지도 학습 방식에서 가장 문제가 되는 것은 데이터 부족 문제이다. 특히 각 세부 감정별로 사용되는 어휘 자질이 다양하게 나타나기 때문에 이를 자질로 이용하여 학습할 만한 충분한 데이터를 구축하는 것이 매우 어려운 문제이다. 또한 사용자가 대화에서 감정을 표현하기 위해 감정 사전에 등재될 만한 구체적인 어휘를 사용할 수 있지만, 간접적이고 상황적인 표현을 통해 감정을 드러낼 수도 있기 때문에 데이터 부족 문제는 더 심각해진다.

2.2 워드 임베딩

워드 임베딩은 하나의 단어를 일반적으로 수백 개 정도의 저차원의 실수 벡터로 표현하는 것이다. 이러한 단어에 대한 분산화 되고(distributed), 연속적인(continuous) 표현 방식은 단어에 대해 유사도 관점의 분석을 가능하게 하고 다양한 벡터 연산을 통해 관계를 유추할 수 있도록 해준다. 전통적으로 LSA[8] 나 LDA[9] 방법이 제안되어왔으나 최근 들어 neural network 기반의 언어 모델 학습을 통한 벡터 학습 방법이 좋은 성능을 보여주고 있다[10][11]. 본 연구에서는 [12]에서 제안한 Word2Vec 방법을 사용하였다. Word2Vec은 기존의 neural network 모델에서 hidden layer를 제거함으로써 기존 방식에 비해 성능의 하락 없이 대략 1000배 이상의 빠른 학습 속도를 보여주고 있다. 또한 다른 의미 분석과 관련된 지도 학습에 대한 입력으로 최근 좋은 성능을 보여주고 있다[13].

Word2Vec에서 워드 임베딩은 대량의 코퍼스를 통해 문장 별로 문맥에 나타난 단어들에 주어졌을 때 언어 모델과 유사하게 단어의 발생 확률을 예측함으로써 학습된다. 따라서 유사한 용례를 가진 단어들에 유사한 위치로 학습된다. 예를 들어 의미적으로 유의어인 “아빠”, “아버지”의 경우 코사인 유사도(cosine similarity) 값이 매우 높게 나타난다. 혹은 문법적으로 쓰임새가 유사한 단어들에 가깝게 학습되기도 한다. 더불어 벡터 연산을 통해 단어 간 관계를 유추할 수도 있다.

이러한 특징을 이용하여 최근에는 임베딩 벡터를 자연

어처리의 의미 분석 태스크에 활용하는 연구들이 나타나고 있다. [14]의 경우에는, 분류 문제에서 대개 발생하는 일부 클래스들에 대한 학습 데이터 부족 문제를 워드 임베딩을 활용한 오버샘플링(over-sampling)을 적용하여 해결을 시도했다. 즉, 학습에 사용될 수 있는 새로운 데이터를 임베딩 벡터의 조합으로 생성함으로써 희소 클래스의 분류 성능을 향상시킬 수 있음을 보였다.

본 연구에서도 이러한 임베딩 벡터의 특징을 이용하여 앞에서 언급한 어휘 자질 부족 문제를 해소하고자 하되, 학습 데이터를 늘리기 보다는 임베딩 벡터의 자질로서의 활용에 대한 새로운 방법을 제시하여 해결하고자 한다. 또한 연속적인 대화 속에서 이어지는 감정의 지속을 반영하기 위해 문맥 임베딩 자질을 고려하였다. 임베딩 벡터를 사용하기 위한 본 연구에서 사용한 자질 함수 등에 대해서는 3장에서 자세히 설명하도록 한다.

3. 제안하는 방법

3.1 개요

본 연구에서는 대량의 태깅 되지 않은 코퍼스를 이용하여 임베딩 모델을 학습하고 적은 양의 태깅 된 학습 데이터로 어휘 자질을 선별한 후 자질 값으로 임베딩 공간에서의 유사도를 사용하였다. 또 문맥을 통한 지속 감정을 자질로서 반영하기 위해 문장과 문맥을 하나의 임베딩 벡터로 표현하고 이를 자질로 이용한다.

본 연구에서는 대화 속에서 새롭게 발생한 사용자의 발화에 대해 9 가지 중 하나의 감정을 선택하는 것을 분류 모델을 이용한 다중 분류 문제로 접근한다. 이를 위해 학습 데이터는 두 가지가 필요하다. 임베딩을 위한 1) 대량의 원시 말뭉치와 2) 9가지 중 하나의 감정 태그가 정답으로 부착된 소량의 대화 말뭉치이다. 우선 1)을 사용하여 워드 임베딩 모델을 학습시켜 생성한다. 그리고 2)를 사용하여 감정 분류기를 학습한다. 학습 방법은 다음과 같다. 각 감정이 부착된 학습 데이터에서 이전 연구에서 제안된 현재 발화 및 전 발화, 전전 발화에서 어휘 자질을 비롯하여 기존 연구들에서 제시되었던 다양한 자질들을 광범위하게 추출한다. 그리고 각 자질과 태깅된 감정 카테고리와의 information gain을 측정하여 뒤 자질을 선택한다. 대부분의 자질은 그대로 사용되되, 선택된 어휘 자질들 중 uni-gram 자질에 대해서는 제안하는 3 가지 임베딩 자질 함수를 적용하여 자질 값을 계산하거나 새로운 자질을 추가한다.

마지막으로 SVM 기반의 분류 모델을 이용하여 감정 분류기를 학습한다. 그림 1은 제안하는 방법에 대한 시스템 구조이다.

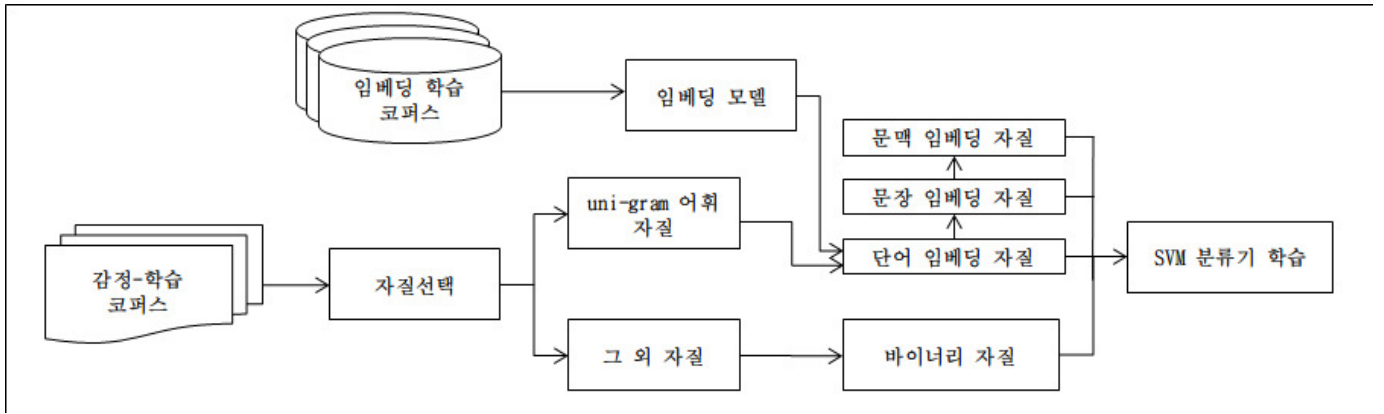


그림 1 분류기 학습을 위한 임베딩 자질의 사용

3.2 n-gram 자질

다음은 본 연구에서 기존 연구 및 기존 연구를 확장하여 사용한 자질이다. 자질 개수로 보면 형태소 n-gram 자질이 대부분을 차지하고, 그 외에 주요 문장 성분 및 품사 구성을 자질로 반영한다.

표 1은 현재 발화에서의 자질의 종류와 자질 표현 방법을 보여주고, 표 2는 전 발화들에서 추출되는 어휘 자질 및 표현에 대해 보여준다. 전 발화 및 전전 발화에 대해 표 1에서 나타난 현재 발화와 동일한 종류의 자질들이 추출된다.

표 1 현재 발화에 대한 자질 및 자질 표현

자질	자질 표현=값 예
형태소 n-gram	TriMorph_열_받_다=1
형태소-품사 쌍	MorphPos_습니다_EF=1
마지막 어절	LastEojeol_보겠습니다!=1
마지막 동사	LastVerb_만들=1
마지막 부사	LastAdverb_어서=1
마지막 보조용언	LastAux_보=1
마지막 어미	LastEomi_습니다=1
주어	Subject_나=1
품사 n-gram	PosTrigram_VX_EP_EF=1
형식 형태소 열	FunMorphSeq_이_어_이_아_보_겠_습니 다=1
형식 형태소 집합	FunMorphSet_겠_보_습니다_아_어_이=1
형식 품사 열	FunPosSeq_JKS_EC_VX_EC_VX_EP_EF=1
형식 품사 집합 길이	FunPosSet_EC_EF_EP_JKS_VX=1 Length_Midum=1
욕설, 이모티콘	ExistExp=JOY, NumExp=JOY:1, ExpWord=JOY_^_^

표 2 이전 발화에 대한 자질 및 자질 표현

자질	자질 표현 예
자신 전 발화의 자질	PrevMyXXXXXX
자신 전전 발화의 자질	BeforeLastMyXXXXXX
상대 전 발화의 자질	PrevOppXXXXXX
상대 전전 발화의 자질	BeforeLastOppXXXXXX

3.3 단어 임베딩 자질

기존의 BOW(Bag-of-Word) 자질을 사용하는 분류 시스템에서는 단순히 해당 자질의 출현 여부만으로 자질 값이 결정되는 이진 자질 공간(binary feature space)을 형성한다. 따라서 자질로 선택된 어휘와 동일한 어휘가 사용되지 않을 경우 감정 분석에 있어 유용한 자질들이 충분히 활용되지 못한다고 볼 수 있다. 이러한 문제를 해결하기 위해 본 연구에서는 워드 임베딩 공간상의 임베딩 벡터를 이용한 자질들을 제안한다.

우선 학습 데이터로부터 자질 선택에 의해 어휘 자질이 선택된다. 우리는 이 선택된 어휘 자질 중 uni-gram 자질에 대해 기존의 바이너리 자질 값 대신, 다음과 같이 각 uni-gram 자질과 학습 데이터의 문장을 구성하는 단어들 간의 코사인 유사도를 계산하여 최대 유사도를 해당 uni-gram 자질의 값으로 사용한다.

즉, 발화 U_j 의 uni-gram 자질 f_k 의 자질 값, $p(f_k, U_j)$ 를 수식으로 나타내면 다음과 같다.

$$p(f_k, U_j) = \max\{\tau(v_{f_k}, v_{w_i}) | w_i \in U_j, i = 1, 2, \dots, m\}$$

단,

U_j = 사용자의 j 번째 발화

f_k : k 번째 어휘 자질

$U_j = \langle w_1, w_2, \dots, w_m \rangle$

w_i = 발화에 속한 i 번째 단어

v_{f_k} : f_k 의 임베딩 벡터

$$\tau(v_{f_k}, v_{w_i}) = \cos(v_{f_k}, v_{w_i})$$

이다.

이는 감정 분석에 있어 중요한 어휘 자질이 해당 문장에서 나타나지 않았다고 하더라도, 그와 유사한 의미를 갖는 문장 내 어휘들이 감정 분석에 활용될 수 있도록 하기 위해서이다.

3.4 문장 임베딩 자질

bi-gram 이상의 형태소 n-gram 자질들은 각 단어 간의 비 독립성을 표현하기 위해 사용한다. 이와 유사하게 우리는 문장 내 나타난 단어들의 집합을 자질로 표현하기 위해 문장 임베딩 자질을 사용한다. 문장 임베딩 벡터는 문장을 구성하는 단어들의 임베딩 벡터의 합으로 나타낸다. 그리고 해당 문장 벡터와 감정 클래스를 나타내는 단어(기쁨, 슬픔 등)의 용언에 대한 벡터들과의 코사인 유사도를 계산하여, 가장 높은 유사도를 자질 값으로 사용한다. 발화 U_j 의 문장 임베딩 자질 f_u 의 자질 값 $p(f_u, U_j)$ 는 다음과 같이 계산한다.

$$p(f_u, U_j) = \max\{\tau(v_{u_j}, v_e) | e \in E\}$$

$$v_{u_j} = \sum_{i=1}^m v_{w_i}$$

$$E = \{ '기쁘', '놀랍', '하나', '두렵', '싫어하', '죄송하', '슬프', '민' \}$$

3.5 문맥 임베딩 자질

기존 연구에서는 대화에서 화자의 감정이 지속되는 것을 반영하기 위하여 사용자의 전 발화, 전전 발화 자질을 사용하였다. 이와 유사하게 제안하는 방법에서도 문맥 자질을 반영한다. 그러나 단순히 전 발화만을 고려하는 것이 아니다. 대화가 진행될 때 마다, 문맥 벡터에 이전 발화 문장의 문장 벡터를 가중치를 부여해 더해나감으로써 보다 오래전의 감정을 모두 누적하여 반영하되, 시간에 따라 비율을 낮추도록 하였다. 발화 U_j 의 문맥 임베딩 자질 f_c 의 자질 값 $p(f_c, U_j)$ 는 다음과 같이 계산한다.

$$p(f_c, U_j) = \max\{\tau(c_{u_j}, v_e) | e \in E\}$$

$$c_{u_j} = \alpha v_{u_j} + (1 - \alpha) c_{u_{j-1}}$$

$$c_{u_1} = v_{u_1}$$

이때 α 값은 0.5~0.9 까지를 대상으로 실험적으로 결정하였다. 본 연구에서 실험을 위해 사용된 α 값은 0.7이다.

4. 실험 및 평가

4.1 임베딩 학습

실험에서는 임베딩 모델에 사용된 일반 코퍼스와 발화

감정 분류기의 학습 및 테스트에 쓰인 대화 코퍼스, 두 종류의 코퍼스가 사용된다. 임베딩 모델에 사용된 코퍼스는 대량의 뉴스 기사와, 구어체 반영을 위해 수집한 해외 드라마의 한국어 자막 데이터로 구성되어 있다. 임베딩 학습을 위해 한국어 형태소 분석[15]을 수행하였으며, 모든 숫자에 대해 0으로 정규화하고 형태소 단위의 토큰나이징을 수행 하였다. 임베딩 학습 데이터에 대한 구성은 표 3과 같다.

표 3 임베딩 코퍼스 데이터

코퍼스	크기	문장 수
한국어 뉴스 기사 코퍼스	2.069 GB	11,835,341
해외 드라마 자막 한국어 번역 코퍼스	18.3 MB	361,480
전체	2.087GB	12,196,821

임베딩 학습 방법인 Word2Vec의 주요 파라미터들은 표 4와 같다. 각 파라미터 값은 실험적으로 결정하였다.

표 4 Word2Vec의 주요 파라미터 설정

파라미터	설명	값
Architecture	임베딩 학습 구조	cbow
Window size	단어 확률값 예측을 위한 Context 크기	7
Dimensionality	임베딩 벡터 크기	200
Training Algorithm	훈련 알고리즘	hierarchical softmax
Min-count	빈도 threshold	5

4.2 대화 코퍼스 구축 및 감정 정답 집합 구축

실제 대화를 수집하는 것은 보안과 프라이버시 문제로 매우 어렵다. 따라서 우리는 영어 회화 코퍼스와 영어 드라마의 한국어 자막 코퍼스를 재가공하여 구어체 대화 코퍼스를 구축하였다. 먼저 자막에서 1:1 대화 부분을 추출한 다음 화자 간 관계 설정을 한 뒤, 자연스러운 구어체 대화가 되도록 변환하고 감정을 부착하였다.

대화 코퍼스의 감정 태깅은 총 3명의 작업자가 태깅한 결과를 다수결을 통해 1차 감정과 2차 감정을 결정하고, 3자의 결과가 불일치한 5.9%의 발화들에 대해서만 재작업을 수행하였다. 1등 감정에 대해 작업자 3명의 동의율은 48.3%로 매우 낮았다. 그러나 최소 2명까지의 동의율은 92.1%로 매우 높았으며 2등까지에 대한 2명까지의 동의율은 94.1%였다. 대부분의 경우 부정적인 감정 '슬픔' 과 '분노', '싫어함' 등이 모호성이 있는 것으로 드러났다. 예를 들어 "아 오늘도 시험이라니"의 경우 한 작업자라도 '슬픔', '분노', '싫어함'에 대해 모호성이 있다고 판단하였으며, 각 작업자 간 2차 감정까지의 선택이 서로 달랐다. 이렇게 구축한 전체 감정 부착 코퍼스는 2,307 개의 대화 세션, 13,329 개의 발화로 구성된다. 이 중 2차 감정을 가진 발화의

수는 전체 4460 개이며 33.46 %를 차지한다. 1차 감정에 대한 감정 카테고리 별 발화 개수 분포는 표 5와 같다.

표 5 감정 카테고리 별 발화 비율

감정 카테고리	발화 수	비율 (%)
감정 없음	6834	51.27
기쁨	1644	12.33
놀람	1463	10.98
화남	855	6.41
두려움	738	5.54
슬픔	725	5.44
싫어함	519	3.89
바람	504	3.78
신뢰	47	0.35
전체	13329	

4.3 실험 설계 및 평가 척도

본 연구에서는 대화 코퍼스를 대상으로 하여 기존 감정 분류 연구에서 좋은 성능을 보인 SVM을 사용해 분류기를 학습 시켰으며, 10-fold cross validation을 통해 평가하였다. 임베딩 자질을 적용하기 전에 어휘 자질에 대한 자질 선택 방법은 document frequency(=3)와 information gain(=0.001)을 사용하였다.

감정 분류에 대한 평가를 위해 시스템에 의한 분류 결과와 정답을 비교하여 분류의 정확도를 다음과 같은 평가 척도를 통해 평가한다. 앞에서 살펴본 바와 같이 일부 발화는 모호성이 있으며, 1,2위 감정 중 하나에 대한 3자까지의 동의율이 매우 높은 점을 반영하여 우리는 정답이 2차까지 있는 발화에 대해서는 시스템이 둘 중 하나를 맞추었을 때, 맞은 것으로 하는 평가 척도를 사용한다.

$$accuracy = \frac{\text{정답 중 하나와 시스템 1위가 일치한 수}}{\text{전체 발화 개수}}$$

4.4 실험 결과 및 분석

3장에서 제안한 임베딩 자질들이 성능에 얼마나 영향을 미치는지를 평가하기 위하여 기존 시스템에서 사용되었던 자질들만을 사용했을 때와, 제안한 자질을 추가하였을 때의 성능을 비교하였다.

표 7을 보면 기존의 감정 분석 시스템에서는 uni-gram에 bi-gram을 추가했을 때에는 성능이 상승했지만, tri-gram까지 추가했을 때에는 오히려 성능이 다시 감소하는 것을 알 수 있다. 그러나 uni-gram 자질 대신, 본 연구에서 제안한 단어 임베딩 자질과 문장 임베딩 자질을 추가한 경우 기존 자질을 사용한 경우들과 비교해 모두 accuracy 향상을 보였음을 알 수 있다.

표 7 현재 발화의 어휘 자질과 임베딩 자질 효과 실험

n-gram	accuracy (%)
uni-gram	71.51
uni ~ bi-gram	72.43
uni ~ tri-gram	72.27
bi-gram + 단어 임베딩 자질 (1)	72.63
bi-gram ~ tri-gram + 단어 임베딩 자질 (2)	72.28
(1) + 문장 임베딩 자질	72.68
(2) + 문장 임베딩 자질 (3)	72.30

다음은 문맥 임베딩 자질의 기여도를 평가하기 위해, 이전 발화들의 어휘 자질을 현재 발화의 감정 분석에 반영했을 때의 결과이다. 표 8을 보면, 전 발화와 전전 발화의 어휘 자질을 반영하는 것은 오히려 감정 분류 성능을 감소시킨다. 하지만 문맥 임베딩 자질의 반영은 현재 발화의 어휘 자질을 반영했을 때 보다 높은 성능을 보임으로서 문맥 임베딩 자질의 사용이 감정 분석 성능 향상에 도움이 되었음을 알 수 있다.

표 8 이전 발화들의 자질 반영과 문맥 임베딩 자질 효과 실험

자질	accuracy (%)
현재 발화의 기존 자질 (4)	72.73
(4) + 전 발화의 기존 자질 (5)	72.55
(5) + 전전 발화의 기존 자질	71.60
(3) + 문맥 임베딩 자질	72.89

5. 결론

본 연구에서는 대화 시스템에서 사용자 발화의 감정 분석에서 임베딩 모델을 사용하여 기존의 어휘 자질들을 좀 더 효과적으로 활용할 수 있는 단어, 문장 그리고 문맥의 임베딩 자질을 제안하였다.

실험 결과, 각 임베딩 자질의 사용이 모두 기존의 감정 분석 시스템에서의 성능 향상에 도움이 되었으며, 제안한 자질들이 감정 분석에 있어 효과적임을 보였다.

그러나 Word2Vec 학습 알고리즘의 한계로 인하여 일부 반의어의 유사도 값이 높게 나오거나 자질로 사용할 수 있는 품사를 한정시킬 수밖에 없는 문제가 있었다. 향후 연구에서는 임베딩 공간에서의 단어 유사성 및 활용에 대한 깊이 있는 연구와 더불어 uni-gram 이상의 n-gram에 대한 임베딩 자질 활용이 필요하고, 구어체 코퍼스 확장을 통해 신조어, 이모티콘 임베딩 자질 등을 반영해야 한다.

사사

이 논문은 2012년도 정부(미래창조과학부)의 재원으로 한국연구재단-차세대정보컴퓨팅기술개발사업의 지원을 받아 수행된 연구임(No. 2012M3C4A7033344)

참고문헌

- [1] 강상우, "대화 시스템을 위한 사용자 발화 문장의 감정 분류", *인지과학*, 제21권, 제4호, pp. 459-480, 2010.
- [2] Takayuki Hasegawa, Nobuhiro Kaji, Naoki Yoshinaga, and Masashi Toyoda, "Predicting and Eliciting Addressee's Emotion in Online Dialogue", In *Proceedings of ACL 2013*, 2013
- [3] Robert Plutchik, "A general psychoevolutionary theory of emotion", In *Emotion: Theory, Research, and Experience: Vol. 1. Theories of Emotion*, 1980
- [4] Paul Ekman, "An Argument for Basic Emotions", In *Cognition and Emotion*, 1992
- [5] Valstar, Michel F., et al., "The first facial expression recognition and analysis challenge." *Automatic Face & Gesture Recognition and Workshops 2011 IEEE International Conference on*, 2011
- [6] Saima Aman and Stan Szpakowicz, "Identifying Expressions of Emotion in Text", In *Proceedings of 10th International Conference on Text, Speech and Dialogue*, 2007
- [7] Matthew Purver and Stuart Battersby, "Experimenting with Distant Supervision for Emotion Classification", In *Proceedings of EACL 2012*, 2012
- [8] Dumais, Susan T. "Latent semantic analysis." *Annual review of information science and technology* 38.1, pp. 188-230, 2004
- [9] Blei, David M., Andrew Y. Ng, and Michael I. Jordan. "Latent dirichlet allocation." *the Journal of machine Learning research* 3, pp. 993-1022, 2003
- [10] Bengio, Yoshua, et al. "A neural probabilistic language model." *The Journal of Machine Learning Research* 3, pp. 1137-1155, 2003
- [11] Mikolov, Tomas, et al. "Recurrent neural network based language model." *INTERSPEECH 2010, 11th Annual Conference of the International Speech Communication Association*, 2010
- [12] Mikolov, Tomas, et al. "Efficient estimation of word representations in vector space." *arXiv preprint arXiv:1301.3781*, 2013
- [13] Baroni, Marco, Georgiana Dinu, and Germán Kruszewski, "Don't count, predict! a systematic comparison of context-counting vs. context-predicting semantic vectors.", *Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics. Vol.* 1, 2014
- [14] XU, Ruifeng, et al. Word Embedding Composition for Data Imbalances in Sentiment and Emotion Classification. *Cognitive Computation* 7.2, pp. 226-240, 2015
- [15] Lee, Do-Gil and Hae-Chang Rim, "Probabilistic modeling of korean morphology", *Audio, Speech, and Language Processing, IEEE Transactions on* 17.5, pp. 945-955, 2009