

Automatic Classification and Vocabulary Analysis of Political Bias in News Articles by Using Subword Tokenization

Dan Bi Cho[†] · Hyun Young Lee^{††} · Won Sup Jung^{†††} · Seung Shik Kang^{††††}

ABSTRACT

In the political field of news articles, there are polarized and biased characteristics such as conservative and liberal, which is called political bias. We constructed keyword-based dataset to classify bias of news articles. Most embedding researches represent a sentence with sequence of morphemes. In our work, we expect that the number of unknown tokens will be reduced if the sentences are constituted by subwords that are segmented by the language model. We propose a document embedding model with subword tokenization and apply this model to SVM and feedforward neural network structure to classify the political bias. As a result of comparing the performance of the document embedding model with morphological analysis, the document embedding model with subwords showed the highest accuracy at 78.22%. It was confirmed that the number of unknown tokens was reduced by subword tokenization. Using the best performance embedding model in our bias classification task, we extract the keywords based on politicians. The bias of keywords was verified by the average similarity with the vector of politicians from each political tendency.

Keywords : Political Bias, AI Bias, Lexical Bias, Document Embedding, Subword Tokenizer

부분 단어 토큰화 기법을 이용한 뉴스 기사 정치적 편향성 자동 분류 및 어휘 분석

조 단 비[†] · 이 현 영^{††} · 정 원 섭^{†††} · 강 승 식^{††††}

요 약

뉴스 기사의 정치 분야는 보수, 진보와 같이 양극화된 편향적 특성이 존재하며 이를 정치적 편향성이라고 한다. 뉴스 기사로부터 편향성 문제를 분류하기 위해 키워드 기반의 학습 데이터를 구축하였다. 대부분의 임베딩 연구에서는 미등록어인 문제를 완화시키기 위해 형태소 단위로 문장을 구성한다. 본 논문에서는 문장을 언어 모델에 의해 세부적으로 분할하는 부분 단어로 문장을 구성할 경우 미등록어 수가 감소할 것이라 예상하였다. 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델을 제안하며 이를 SVM과 전방향 뉴럴 네트워크 구조에 적용하여 정치적 편향성 분류 실험을 진행하였다. 형태소 토큰화 기법을 이용한 문서 임베딩 모델과 비교 실험한 결과, 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델이 78.22%로 가장 높은 정확도를 보였으며 부분 단어 토큰화를 통해 미등록어 수가 감소되는 것을 확인하였다. 분류 실험에서 가장 성능이 좋은 임베딩 모델을 이용하여 정치적 인물을 기반한 어휘를 추출하였으며 각 성향의 정치적 인물 벡터와의 평균 유사도를 통해 어휘의 편향성을 검증하였다.

키워드 : 정치 편향성, 인공지능 편향성, 어휘 편향성, 문서 임베딩, 부분단어 토큰화 기법

1. 서 론

언어를 구사하는 어휘의 표현과 문맥은 발화자의 의도를 전달하는 힘을 가지며 발화자의 주관적 편견이 개입되는 경

향이 있다[1]. 자연어처리 시스템에서는 언어의 표현에서 나타나는 편향성 문제인 어휘 편향성(lexical bias) 문제를 중점으로 연구가 진행되고 있다[2, 3]. 전 세계적으로 정보를 공유하는 위키피디아는 정보의 중립화를 위해 편향적 어휘를 정제하는 작업을 수행하고 있으며 Recasens(2013)와 Hube(2018)는 위키피디아의 특성과 편향적 어휘를 분석하였다. 정보 공유의 매체로 사용되는 위키피디아와 같이 뉴스 기사는 중립의 위치에서 공적인 정보를 전달하는 매체로 사용된다. 이에 따라 뉴스 기사는 주관적 개입을 최소화하여 중립의 표현으로 정보를 전달할 의무가 존재한다. 하지만 정치 분야의 경우, 보수와 진보 성향에 따른 양극화된 관점이 명백하게 나타난다. 이처럼 정치 분야의 뉴스 기사에서는 언론사의 정치적 성향에 따라 동일한 사건이 서로 다른 관점에서 기술되는 편향

* 이 논문은 2019년 대한민국 교육부와 한국연구재단의 지원을 받아 수행된 연구임(NRF-2019S1A5A2A03046571).

** 이 논문은 2020년 한국정보처리학회 춘계학술발표대회에서 "형태소 임베딩과 SVM을 이용한 뉴스 기사 정치적 편향성의 자동 분류"의 제목으로 발표된 논문을 확장한 것임.

† 준 회 원 : 국민대학교 컴퓨터공학과 석사과정

†† 준 회 원 : 국민대학교 컴퓨터공학과 박사과정

††† 비 회 원 : 경남대학교 자유전공학부 교수

†††† 종신회원 : 국민대학교 소프트웨어학부 교수

Manuscript Received : July 22, 2020

Accepted : August 25, 2020

* Corresponding Author : Seung Shik Kang(sskang@kookmin.ac.kr)

성 문제가 제기된다. 이를 정치적 편향성이라고 하며 기자의 소속과 기자가 작성하는 의도적인 문맥에서부터 편향적 요소가 나타나기도 한다[4].

정치적 편향성 문제에 접근하기 위해 학습 데이터를 구축하였으며 뉴스 기사에서 나타나는 보수와 진보의 각 성향을 분류하는 실험을 진행하였다. 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델을 설계하고 SVM(Support Vector Machine)과 전방향 뉴럴 네트워크 구조(feedforward neural network)를 이용하여 뉴스 기사의 정치적 성향을 분류하였다. 정치적 편향성은 동일한 사건에 대하여 특정 인물을 옹호하거나 공격하는 방식과 같이 문맥 정보를 통해 간접적으로 드러난다. 이러한 특성을 고려하여 분류 실험에서 가장 높은 성능의 임베딩 모델을 이용하여 각 성향에 따라 편향된 어휘를 분석하였다. 편향성 어휘는 각 성향에 속하는 정치인들의 이름과 평균 유사도를 이용하여 추출하였다. 벡터의 평균 유사도를 통해 추출된 어휘를 보수와 진보, 중립의 정치적 성향에 따라 구분하여 편향성 어휘의 특성을 분석하였다.

2. 관련 연구

인공지능에서의 편향성 문제는 데이터의 형태, 편향성의 접근 방향에 따라 다르게 나타나며 그 유형으로는 대표성 편향성(representation bias), 측정 편향성(measurement bias), 알고리즘 편향성(algorithmic bias), 그리고 평가 편향성(evaluation bias) 등이 있다[5]. 이러한 편향성 문제는 데이터의 오류뿐만 아니라 학습 모델과 평가 모델에서 나타나는 측정 지표의 오류를 포함한다.

자연어처리 시스템에서는 단어 임베딩, 언어 모델, 기계 번역 등의 연구에서 편향성 문제가 나타난다[6-8]. 언어를 처리하는 과정에서 발생하는 편향성 문제는 대표적으로 어휘 편향성(lexical bias)이 있으며, 언어의 형태와 특성에 따라 성별 편향성(gender bias)과 정치 편향성(political bias) 등으로 나타난다.

어휘 편향성(lexical bias). 언어는 발화자가 서술하는 어휘, 문맥과 같이 주관적인 관점이 포함되어 편향적 요소로 나타난다. 언어의 편향적 요소에 따라 언어가 전달하는 의미가 다르게 표현되는 경향이 있으며 이러한 편향성 문제를 어휘 편향성이라고 한다. 전 세계적으로 정보와 지식을 공유하는 위키피디아는 자유로운 형식으로 작성과 수정이 이루어지며 다양한 정보를 습득하기 위해 보편적으로 사용된다. 동일한 주제에 대하여 다양한 관점의 작성자들이 정보를 작성하기 때문에 편향된 정보를 중립화시키는 작업이 필수적이다. 이에 따라 위키피디아는 편향된 정보를 수정하는 중립화 검증 절차를 거치며 이를 위한 정책 지침으로 NPOV(Neutral Point Of View)를 제시하였다. NPOV의 예시는 다음과 같다[1].

- 이 벌레 사진은 징그럽다: 주관
- 이 벌레 사진은 징그럽지 않다: 주관

- 이 벌레 사진이 징그럽다는 의견과 그렇지 않다는 의견이 모두 나타나고 있다: 중립

벌레라는 대상을 '징그럽다'라고 표현하는 것은 개인적인 관점에서부터 나타난 표현이다. 대상을 보는 관점에 따라 대상에 대한 표현력이 다르게 나타나기 때문에 '징그럽다' 혹은 '징그럽지 않다'와 같이 특정 대상을 평가하는 표현은 편향적 어휘로 취급된다. 이러한 편향적 어휘를 추출하고 편향된 표현을 감소시키기 위해 Recasens(2013)와 Hube(2018)는 NPOV 데이터를 이용하여 위키피디아에서 나타나는 편향성 어휘를 분석하였다. Recasens(2013)는 언어적 특성에 기반하여 주관적인 언어를 다루는 framing bias와 사실에 대한 의문점을 통해 언어의 신뢰성을 다루는 epistemological bias로 편향성 문제에 접근하였다[2]. Hube(2018)는 편향적 어휘를 추출한 Conservapedia 데이터를 포함하여 Recasens(2013)의 실험을 확장하였으며 실험을 통해 위키피디아의 편향적 어휘를 추출하였다. 또한, 추출된 어휘를 이용하여 어휘 편향성 문제를 감소시키는 방법론을 제안하였다[3].

성별 편향성(gender bias). 성별 편향성은 성별을 구분하는 언어로부터 나타나는 편향성 문제이다. 예를 들어, '교사'는 학생을 가르치는 사람을 지칭하는 단어이지만 여성의 교사를 지칭하는 '여교사'라는 단어가 개별적으로 존재한다. 이와 달리, 남성의 교사를 지칭하는 '남교사'라는 단어는 존재하지 않는다. '여교사'라는 단어를 사용함으로써 '교사'는 남성의 성별을 가진 교사를 의미하게 되며 동일한 직업에 대하여 성별이 구분된다.

'여성'은 '베이비시터', '남성'은 '컴퓨터 프로그래머'와 같이 특정 성별에 따라 회상되는 특정 직업이 존재한다는 것은 사회적 문제로 인해 나타나는 단어 간 연관성에서 초래된다. Bolukbasi(2016)는 직업을 분류하는 실험에서 성별이 편향적 요소로 나타난다는 것을 확인하였다. 학습을 위한 말뭉치에서 '남성'은 '컴퓨터 프로그래머', '여성'은 '베이비시터'의 단어와 동시에 발생하는 빈도가 높은 경우, 벡터를 학습하는 과정에서 '남성'은 '컴퓨터 프로그래머', '여성'은 '베이비시터'와 유사한 벡터 값을 갖게 된다. 이러한 성별 편향성 문제를 감소시키기 위해 Bolukbasi(2016)는 벡터 학습 시 특정 성별 어휘와의 학습을 줄이고 중립된 단어를 추가하여 임베딩하였다[6]. Sheng(2019)은 성별 편향성 문제를 생성 실험에 적용하였다. GPT-2와 BERT 등의 언어 모델을 비교 분석하여 성별에 따라 생성되는 단어들의 긍정과 부정, 중립을 분석하였다[9].

정치적 편향성(political bias). 정치는 보수와 진보에 따른 양극화된 성향이 두드러지기 때문에 언론사마다 지지하는 성향의 특성에 따라 기사의 의도가 변형되는 문제가 발생한다. Fan (2019)은 뉴스 기사 데이터를 이용하여 편향성 문제를 다루기 위한 데이터를 구축하였다. 동일한 사건에 대하여 각 언론사가 취급하는 뉴스 기사를 수집하였으며 주요 키워드와 객체, 글의 주체 등을 추출하였다. 구축한 데이터를 이용하여 각각의 뉴스 기사에 속하는 정보 편향성과 어휘 편향성 정보를 분석하였다[4].

1) <https://namu.wiki/w/NPOV>

3. 정치적 편향성 분류 시스템

임베딩 기법은 단어의 좌우 문맥 정보를 이용하여 단어 또는 문장을 벡터 공간에 표현한다[10]. 이는 딥러닝 언어처리 모델에서 텍스트를 처리하기 위한 가장 근본적인 방식이며 많은 임베딩 연구에서는 텍스트의 기본 구성 토큰을 단어(또는 어절)로 취급한다[11, 12]. 하지만 학습 데이터에 출현한 단어(또는 어절)를 이용한 벡터 표현 기법인 워드 임베딩은 학습 말뭉치에 출현하지 않은 미등록어 토큰으로 인한 OOV (Out Of Vocabulary) 문제가 발생한다. 본 논문에서는 미등록어를 감소시키고 OOV 문제를 완화시키기 위해 부분 단어 토큰화 기법을 이용하였다. 부분 단어 토큰화 기법을 이용하여 정치적 편향성 문제에 접근하였으며 뉴스 기사로부터 보수와 진보의 문서를 분류하기 위한 문서 임베딩 모델을 (3.1)에서 제안하였다. 또한, 문서 분류에서 사용된 임베딩 모델을 이용하여 (3.2)와 같이 정치적 성향에 편향된 어휘를 추출하였으며 편향성 어휘들의 특성을 분석하였다.

3.1 부분 단어 토큰화 기법을 이용한 문서 임베딩

영어를 이용한 임베딩 연구에서는 벡터 학습을 위한 기본 토큰 단위를 단어(또는 어절)로 구성한다. 반면, 교착어인 한국어는 이용한 임베딩 연구에서는 의미를 표현하는 가장 작은 단위가 형태소라는 특성을 이용하였으며 임베딩을 위한 토큰을 형태소 단위로 구성하는 형태소 임베딩 연구가 진행되고 있다[13, 14]. 한국어의 어절은 형태소뿐만 아니라 음절로 분할이 가능하다. 이 때 텍스트를 구성하는 음절 간 언어 모델을 통해 음절 쌍 형태의 부분 단어를 구성할 수 있다. 예를 들어, “학교에”라는 단어는 ‘학’, ‘교’, ‘에’와 같이 음절로 분할되며 음절 간 언어 모델을 통해 “학교”, “에” 혹은 “학”, “교에”와 같이 음절 쌍 형태의 부분 단어를 구성할 수 있다. 부분 단어로 구성된 단어 집합은 단어(또는 어절)로 구성된 단어 집합보다 학습되는 토큰의 수가 증가하고 미등록어 수가 감소할 것이라 예상할 수 있다[15].

부분 단어 토큰화 기법인 SentencePiece2)는 문장 단위의 토큰 분할 및 합성 알고리즘이며 언어 모델을 기반으로 음절 쌍의 부분 단어를 생성한다. 이 때 띄어쓰기의 공백 문자를 음절 토큰에 포함하기 위해 ‘_’로 대체하여 부분 단어로 토큰화한다[16]. 하지만 띄어쓰기를 포함하기 위해 대체되는 ‘_’는 기계번역이나 생성을 위한 연구에서 토큰화된 데이터를 복원하기 위해 사용되는 방식이다[17]. 본 논문에서는 문서 분류 실험을 위해 SentencePiece 토큰화 기법을 사용하는 것이 때문에 공백 문자를 대체한 ‘_’를 벡터 학습 시 다시 공백 문자로 변경하였다. 예를 들어, “나는 학교에 갔다.”의 문장을 SentencePiece 토큰화 기법을 이용하여 분할할 경우 [나는, _학교, 에, _갔다.]와 같이 생성될 수 있지만, 본 논문에서는 ‘_’를 다시 공백 문자로 대체하여 [나는, 학교, 에, 갔다.]의 형태로 벡터를 학습하였다.

SentencePiece 토큰화 기법은 문장 단위의 분할로 이루어지며 하나의 문장 S 에 대하여 여러 개의 부분 단어 토큰열

후보 집합 $\{C_1, C_2, \dots, C_M\}$ 을 생성한다. 이 때 문장 S 를 표현하는 부분 단어 토큰열은 Equation (1)과 같이 부분 단어 토큰열 $C_m = t_1, t_2, \dots, t_n$ 의 문장 생성 확률 $P(C_m)$ 을 최대화하는 토큰열 C 로 선택하여 문장을 구성하였다.

$$P(C_m) = \prod_{i=1}^n p(t_i) \tag{1}$$

$$S = \operatorname{argmax}_C (P(C_m))$$

부분 단어 토큰열을 구성하기 위한 부분 단어 집합은 문장 내의 음절 토큰으로 생성할 수 있는 모든 경우의 음절 쌍으로부터 추출되며 vocab size를 지정하여 부분 단어 집합의 크기를 제한할 수 있다. 본 논문에서는 문장 단위의 부분 단어 분할 알고리즘인 SentencePiece 토큰화 기법을 문서 수준으로 확장하여 문서를 부분 단어 토큰열로 구성하였다.

문서를 단어(또는 어절)이 아닌 연속된 부분 단어 토큰열로 구성하였으며 각 부분 단어 토큰들의 입력으로 토큰 벡터를 구성하였다. 문서 내의 토큰 벡터는 Fig. 1과 같이 Skip-gram을 확장한 모델로 설계하였다. Skip-gram은 중심 단어의 벡터를 이용하여 주변 단어들의 벡터를 예측하는 대표적인 word2vec 모델이다[8]. 주변 문맥을 고려하여 각 단어 간 벡터를 학습하기 때문에 벡터 공간에서의 단어는 유사한 위치의 단어들끼리 유사한 의미를 갖는 특성을 나타낸다. 이러한 Skip-gram 모델을 확장하여 부분 단어 토큰 단위의 좌우 문맥 정보를 학습하도록 하였다.




Fig. 1. Skip-gram Model with Subwords

문서 내의 부분 단어 토큰열 벡터를 (v_1, v_2, \dots, v_n) 라고 할 때, Equation (2)와 같이 연속된 부분 단어 토큰열 벡터들의 평균으로 문서 벡터를 구성하였다[16].

$$V_i = \frac{1}{n} \sum_{j=1}^n v_j \tag{2}$$

문서를 언어 모델에 기반한 부분 단어 토큰열로 분할하여 형태소 임베딩과 같이 미등록어 수를 감소시키는 역할을 할 것이라 예상하였다. 이에 따라 본 논문에서는 부분 단어 토큰화 기법을 이용하여 문서를 구성하고 이를 평균하여 벡터를 구성하는 문서 임베딩 모델을 제안한다. 정치적 편향성 분류 실험에서 뉴스 기사의 본문 텍스트를 하나의 문서로 취급하여 문서 임베딩을 진행하였으며 제안한 부분 단어 토큰화 기

2) <https://github.com/google/sentencepiece>

Table 1. List of Keywords for the Political Article Dataset

Data	Category	Keywords
PBK_10k	Person	홍익표, 이명박, 손혜원, 트럼프, 조국
	Event	지소미아, 패스트트랙, 파업, 하명수사, 검찰개혁
	Main term	교과서, 판문점, 탈북민, 여경, 부동산
PBK_50k	Person	홍익표, 이명박, 손혜원, 트럼프, 조국, 박원순, 전두환, 김기춘, 홍준표, 임종석, 윤상직, 유시민, 박근혜, 아베, 이낙연, 유승연, 김영삼, 황교안, 문재인
	Event	지소미아, 패스트트랙, 파업, 하명수사, 검찰개혁, 재보궐, 채용비리, 지방선거, 국정감사, 여소야대, 총선, 공천, 구조조정, 대북제재, 비리, FTA
	Main term	교과서, 판문점, 탈북민, 여경, 부동산, 정당, 개헌안, 불매, 세월호, 공무원, 대출, 복지, 수출, 유출, 주한미군, 연금, 비핵화, 김영란법, 공수처, 최저시급, 최저임금, 난민, 식발, 노총, 보수, 야권, 사드, 위안부, 미사일, 광화문, 선거법, 서울시, 중국, 진보

법을 이용한 문서 임베딩 모델과 형태소 토큰화 기법을 이용한 문서 임베딩 모델을 비교 실험하였다.

3.2 단어 임베딩 기법을 이용한 정치적 편향성 어휘 분석

정치적 편향성은 보수와 진보에 따른 양극화된 관점이 나타나며 각 성향을 지지하는 정치인들이 존재한다. 뉴스 기사의 경우, 정치인을 중심으로 사건이 기술되며 동일한 사건에 대하여 각 성향에 따른 정치인들의 의견을 서술하기도 한다. 이에 따라 본 논문에서는 뉴스 기사의 정치적 성향을 분류하는 실험에서 가장 높은 성능의 임베딩 모델을 이용하여 정치인과의 벡터 유사도를 통해 정치적 어휘를 추출하였다. 각 성향에 속하는 정치인들과의 벡터 유사도에 따라 추출된 어휘를 평균 유사도를 통해 검증하였으며 보수와 진보, 중립의 편향성 어휘를 분석하였다. 보수와 진보 성향에 속하는 정치인 각 10명을 선별하여 총 20명의 인물과 유사한 어휘를 추출하였으며 정치적 성향에 속하는 정치인 20명은 다음과 같다.

- 보수: 박근혜, 이회창, 이명박, 전두환, 김기춘, 김영삼, 황교안, 홍준표, 장제원, 전원책
- 진보: 김대중, 노무현, 문재인, 추미애, 홍익표, 박원순, 임종석, 유시민, 이낙연, 김부겸

보수 집합에 속하는 인물 x_i , 진보 집합에 속하는 인물 y_i 에 대하여 각 인물과 벡터값이 가장 유사한 10개의 어휘를 코사인 유사도(cosine similarity)를 이용하여 추출하였다. 보수와 진보 성향의 정치인 벡터와 유사도를 통해 추출된 어휘에서 중복을 제거한 어휘 리스트 $[k_1, k_2, \dots, k_n]$ 을 구성하였다. 어휘 리스트에 속하는 어휘들의 정치적 성향을 검증하기 위해 Equation (3)과 같이 리스트 내 어휘를 보수와 진보에 속하는 각 10명 인물과의 유사도 평균을 비교하였다.

$$K_{j(x)} = \frac{1}{N} \sum_{i=1}^N \cos(x_i, k_j), N=10 \quad (3)$$

$$K_{j(y)} = \frac{1}{N} \sum_{i=1}^N \cos(y_i, k_j), N=10$$

$$tendency = \begin{cases} \text{보수,} & \text{if } K_{j(x)} - K_{j(y)} > threshold \\ \text{진보,} & \text{if } K_{j(y)} - K_{j(x)} > threshold \\ \text{중립,} & \text{otherwise} \end{cases}$$

추출된 특정 어휘 k_j 와 각 정치적 인물 10명과의 벡터 유사도를 평균한 보수의 평균 유사도를 $K_{j(x)}$, 진보의 평균 유사도

를 $K_{j(y)}$ 라고 할 때, 두 평균 유사도를 임계치(threshold)를 기준으로 비교하여 특정 어휘 k_j 의 정치적 성향을 검증하고자 한다. 예를 들어 '새누리당'의 보수 평균 유사도 $K_{j(x)}$ 는 0.2703, 진보 평균 유사도 $K_{j(y)}$ 는 0.1821로 평균 유사도의 차이는 0.088이다. 본 논문에서는 임계치를 0.05로 지정하였으며 '새누리당'의 평균 유사도 차이인 0.088은 0.05의 임계치보다 크기 때문에 '새누리당'은 보수 성향의 편향성 어휘로 검증되는 것이다. 반대로 $K_{j(y)}$ 에서 $K_{j(x)}$ 를 뺀 값이 0.05보다 클 경우 진보 성향의 편향성 어휘로 검증된다. 두 정치적 성향의 평균 유사도의 차이가 0.05 이하인 경우, 두 정치적 성향에서 유사도가 높으며 통용되는 어휘일 것으로 추론하여 이는 편향성 어휘가 아닌 중립 성향의 어휘로 검증하였다.

4. 실험 및 평가

4.1 학습 데이터 구축

보수와 진보에 따른 정치적 편향성을 분류하기 위한 학습 데이터를 구축하였다. 데이터는 키워드3)를 기반으로 검색된 기사의 [기사 제목, 본문, url, 기사 업로드 날짜]의 정보를 수집하였다. 정치적 성향이 드러나는 대표적인 언론사 6개(보수 언론사 3개, 진보 언론사 3개)에서 기사를 추출하였으며 데이터는 15개의 키워드로 추출한 PBK4) 10k과 54개의 키워드를 추가하여 총 69개의 키워드로 추출한 PBK_50k로 구축하였다. PBK_10k는 11,584개의 기사, PBK_50k는 50,864개의 기사로 구성되었으며 각각의 검색 키워드는 Table 1과 같다. 인물(person), 사건(event), 주요어(main term)의 카테고리에서 해당 키워드를 6개의 언론사에서 검색하였을 때 검색되는 뉴스 기사들을 수집하였다.

수집한 데이터를 처리하기 위해 전처리 작업을 수행하였으며 다음의 4가지 과정을 진행하였다.

- 기사 본문 내의 날짜 표기 제거
- 괄호로 처리된 문자 제거
- 특수 기호 통일 및 대체
- 문장 단위 구분

정치적 편향성 분류를 위해 사용되는 기사의 본문 데이터

3) <https://namu.wiki/w/분류:2019년%20사건>

4) PBK는 Political Bias of Korean의 약자로, 정치적 편향성을 위해 구축한 데이터셋의 이름으로 지정하였다.

Table 2. The Number of Articles, Sentences, Words from Dataset

		PBK_10k			PBK_50k		
		Conservative	Liberal	All	Conservative	Liberal	All
Article	Total	5,792	5,792	11,584	25,432	25,432	50,864
	Train	4,658	4,609	9,267	20,415	20,276	40,691
	Test	1,134	1,183	2,317	5,017	5,156	10,173
Sentence	Total	122,544	163,264	285,808	539,731	699,544	1,239,275
	Train	99,211	130,124	229,335	434,456	558,139	992,595
	Test	23,333	33,140	56,473	105,275	141,405	246,680
Word	Total	2,082,330	2,748,160	4,830,490	8,952,426	11,545,683	20,498,109
	Train	1,677,357	2,193,816	3,871,173	7,206,514	9,213,215	16,419,729
	Test	404,943	554,344	959,287	1,745,912	2,332,468	4,078,380

에 작성된 낱자는 텍스트를 처리하기 위한 정보로 불필요한 정보이기 때문에 이를 제거하였다. 뉴스 기사는 글의 출처나 부가적인 정보를 입력하기 위해 괄호를 사용한다. 하지만 괄호는 특수 기호로써 단어의 토큰과 함께 처리될 경우, '단독'과 '[단독]'이 서로 다른 토큰으로 간주되는 문제가 발생하기 때문에 이를 처리해주어야 한다. 기사에서 '['와 같은 대괄호는 '[단독]', '[속보]'와 같이 글의 강조를 위해 주로 사용된다. 이는 정치적 편향성을 분류할 때 불필요한 정보로, 본문의 정보를 내포하지 않기 때문에 제거하였다. 또한 '(와 같은 소괄호는 글의 부가적인 정보를 작성하기 위해 사용된다. 이는 본문의 정보를 내포하지만 사람의 정보나 요약어와 같은 짧은 언어로 불필요한 정보를 작성하는 경우가 존재하기 때문에 괄호 안의 문자가 5개 음절 이하인 경우 이를 제거하였다.

6개의 언론사 각각에 대하여 15개와 69개의 키워드를 기반으로 기사를 수집하기 때문에 기사의 소속과 글을 작성한 기자의 특성에 따라 특수기호의 형태와 모양이 다르게 나타난다. 이를 통일하기 위해 물결 기호 (~, ∞, ~, ~, ~)를 ~로, 따옴표 기호 (" , " , " , ")를 " , 그리고 중간 기호점(· , ·)를 ·로 대체하였다.

특수기호와 낱자, 괄호와 같이 기호로 작성된 정보를 처리하고 이를 문장 단위로 구분하기 위해 문장 끝 기호로 마침표(.)와 물음표(?), 느낌표(!)를 사용하였다. 인용문 내의 문장 끝 기호의 출현은 이를 구분하지 않고 인용문을 포함한 문장으로 구분하였다. 보수와 진보 각각의 정치적 성향에 대하여 균등한 데이터의 크기로 구성하였으며 학습 데이터와 평가 데이터를 각각 8:2로 분할하여 사용하였다. 데이터의 기사와 문장 및 어절 수는 Table 2와 같이 확인하였다.

4.2 편향성 분류 실험 및 결과 분석

정치적 편향성 분류를 위한 부분 단어 토큰화 기법으로 SentencePiece를 사용하였으며 구축 데이터를 8:2의 비율로 분할하여 학습 데이터와 평가 데이터를 구성하였다. 분할된 학습 데이터를 이용하여 SentencePiece 토큰화 모델을 학습하였으며 학습된 모델을 이용하여 문서를 연속된 부분 단어 토큰열로 분할하였다. 연속된 부분 단어 토큰열로 구성된 문서 임베딩을 이용하여 정치적 편향성 분류 실험을 진행하였다. 비교 실험을 위해 교착어인 한국어의 특성을 고려한 형태소 토큰화⁵⁾ 기법으로 문서 임베딩을 구성한 모델을

Baseline으로 하여 정치적 편향성 분류 실험을 진행하였다.

문서 임베딩을 위한 파라미터로 window size 5, min count 1, negative sampling 5의 Skip-gram 모델을 이용하였으며 벡터 크기 100, 200, 300, 400, 500과 iteration 100, 200, 300에 대하여 비교 실험하였다. 각각의 파라미터에 따라 학습된 벡터로 문서 임베딩을 구성하고 SVM⁶⁾과 전방향 뉴럴 네트워크 구조에 적용하여 분류 실험을 진행하였다. 전방향 뉴럴 네트워크 구조의 경우, 학습률 0.001의 SGD(Stochastic Gradient Descent)로 설계하였으며 활성화 함수(activation function)는 softmax, batch size 64, epoch 2000으로 파라미터를 설계하였다. 전체 데이터를 8:2의 비율로 분할한 학습 데이터와 평가 데이터 중 학습 데이터를 8:2로 재분할하여 학습 모델을 검증하였다.

형태소 토큰화 기법을 이용한 형태소 임베딩은 단어(또는 어절) 임베딩보다 미등록어 수가 적게 나타나는 장점이 있으며 한국어를 이용한 임베딩 연구에서 많이 사용되고 있다. 본 논문에서는 부분 단어 토큰이 형태소 토큰보다 미등록어 수를 감소시킬 것이라 예상하였으며 Table 3과 같이 토큰화 기법에 따른 미등록어 수를 분석하였다. 정치적 편향성 분류 실험을 위해 구축한 PBK_10k와 PBK_50k 모두 형태소 토큰화 기법보다 부분 단어 토큰화 기법을 이용한 경우 미등록어 수가 적게 나타났다.

11,584개의 문서로 이루어진 PBK_10k와 50,864개의 문서로 이루어진 PBK_50k 각각에 대하여 정치적 편향성 분류 실험을 진행하였다. 부분 단어 토큰화 기법을 이용하여 문서 임베딩을 구성하기 위한 vocab size는 100k와 150k로 지정하여 실험을 진행하였다. 각 데이터의 벡터 크기 별 SVM 정확도는 Table 4와 같다. Table 4는 각 토큰화 기법을 이용한 문서 임베딩 모델을 SVM에 적용하여 정치적 편향성 분류 실험을 진행한 결과이며 벡터 크기에 따라 가장 성능이 좋은 벡터 학습 iteration의 정확도를 나타낸다. PBK_10k에서는 SP_100k⁷⁾의 정확도가 76.87%, PBK_50k에서는 SP_150k의 정확도가 78.22%로 가장 높은 성능을 보였다. 각 데이터에 대하여 SVM을 적용하여 분류 실험한 결과, 형태소 토큰화 기법을 이용한 문서 임베딩 모델보다 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델의 성능이 높게 나타났다.

전방향 뉴럴 네트워크 구조를 이용한 정치적 편향성 분류 실험의 정확도는 벡터 학습 iteration을 300으로 고정하여

5) KoNLPy의 Hannanum, Komoran, Okt 형태소 분석기를 이용하였다.

6) <http://svmlight.joachims.org/>

7) SentencePiece 토큰화 기법을 이용한 모델의 경우, SP_vocab size와 같이 표기하였다. ex) SP_100k, SP_150k

Table 3. The Number of Unknown Tokens by Tokenizer per Dataset

	Hannanum	Komorán	Okt	SP_100k	SP_150k
PBK_10k	30,174	5,047	11,631	39	95
PBK_50k	95,179	10,092	24,107	77	75

Table 4. SVM Accuracy for Dataset

Data	PBK_10k					PBK_50k				
	100	200	300	400	500	100	200	300	400	500
Hannanum	71.21	70.18	71.86	71.56	74.02	69.35	71.18	73.10	69.19	73.41
Komorán	72.64	74.71	74.75	75.44	75.49	70.55	73.03	74.44	75.25	76.06
Okt	72.81	73.72	75.27	75.70	75.57	71.30	73.33	74.46	75.57	76.50
SP_100k	74.15	74.75	76.31	76.35	76.87	73.73	75.70	77.02	77.57	77.94
SP_150k	74.28	74.84	76.18	76.78	76.69	73.59	75.74	76.94	77.25	78.22

Table 5. Feedforward Neural Network Accuracy for Dataset

Data	PBK_10k					PBK_50k				
	100	200	300	400	500	100	200	300	400	500
Hannanum	66.76	67.02	66.37	65.34	67.11	66.82	68.09	67.80	66.97	65.09
Komorán	66.42	67.50	68.45	67.67	67.93	67.25	68.90	69.45	69.66	69.82
Okt	70.60	70.30	70.39	69.74	70.86	69.12	69.93	70.23	70.84	71.60
SP_100k	70.69	71.38	71.77	72.59	71.94	72.02	73.08	73.62	73.75	74.46
SP_150k	71.64	71.16	72.07	72.16	72.33	72.12	73.33	74.35	74.56	74.93

벡터 크기 별 성능을 확인하였으며 이는 Table 5와 같다. 각 토큰화 기법을 이용한 문서 임베딩 모델에 전방향 뉴럴 네트워크 구조를 적용한 결과, PBK_10k에서는 SP_100k의 정확도가 72.59%, PBK_50k에서는 SP_150k의 정확도가 74.93%로 가장 높은 정확도를 보였다. 전방향 뉴럴 네트워크 구조를 적용한 실험 결과는 SVM을 적용한 실험 결과와 동일하게 형태소 토큰화 기법을 이용한 문서 임베딩 모델보다 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델의 성능이 좋게 나타났다. 이는 Table 3과 같이 형태소 토큰화보다 부분 단어 토큰화의 미등록어 수가 적은 것을 통해 성능을 추론할 수 있다. 많은 임베딩 연구에서 단어를 형태소로 분할함으로써 미등록어 토큰 수를 감소시켜 OOV 문제를 완화시키고 좋은 성능을 보인 것으로 알려져 있다[18, 19]. 이에 따라 본 논문에서는 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델을 제안하였으며 정치적 편향성 분류 실험을 통해 부분 단어 토큰화 기법이 미등록어 토큰 수를 감소시키고 OOV 문제를 완화시켜 높은 정확도를 보인 것을 입증하였다.

4.3 정치적 편향성 어휘 분석 결과

정치적 편향성 문서 분류 실험을 통해 정치적 편향성 문제를 다루었다. 자연어처리 시스템에서 정치적 편향성 문제는 어휘 편향성 문제를 포함하며 이를 분석하기 위해 정치적 편향성 데이터로부터 나타나는 어휘 편향성을 분석하였다. 이를 위해 정치적 편향성 분류 실험에서 가장 좋은 성능을 보인 임베딩 모델을 이용하여 정치적 성향에 따라 나타나는 어휘를 추출하여 분석하였다. PBK_50k 데이터에 대하여 벡터 학습 iteration 300, 벡터 크기 500으로 조정된 SP_150k 모델의 성능이 78.22%로 가장 좋은 성능을 보였으며 해당 부분 단어 집합의 벡터를 이용하여 어휘를 추출하였다.

PBK_50k를 이용한 SP_150k 모델은 129,583개의 부분 단어 집합을 생성하며 부분 단어 집합으로 구성된 벡터를 이

용하여 정치적 편향성 어휘를 추출하였다. 또한, 형태소 분석기 중 가장 좋은 성능을 보인 PBK_50k 데이터의 Okt 임베딩 벡터를 통해 편향성 어휘를 추출하여 각 성향으로 편향된 어휘들의 특성을 비교하였다. 이 때 Okt를 이용한 문서 임베딩은 233,329개의 형태소 단어 집합으로 벡터를 구성하였다.

편향성 어휘를 추출하기 위해 정치적 편향성 문서 분류에서 학습했던 문서 임베딩 모델의 벡터를 이용하여 특정 인물과 가장 높은 유사도를 나타내는 10개의 어휘를 추출하였다. 보수와 진보 성향에 속하는 정치인 총 20명의 유사도로 추출된 200개의 어휘에서 중복을 제거하여 어휘 리스트를 구성하였다. SP_150k의 경우, 146개의 어휘가 추출되었으며 Okt는 174개의 어휘가 추출되었다. 벡터 유사도를 통해 추출된 어휘는 보수와 진보의 각 정치적 인물 10명과의 평균 유사도 값을 갖게 되며 보수 평균 유사도와 진보 평균 유사도의 차이를 통해 해당 어휘가 실제 각 성향에 속하는 어휘와 유사한지 검증하였다.

어휘의 정치적 성향을 검증하기 위한 임계치는 0.05로 지정하였으며 보수와 진보에 속하는 차별화된 어휘의 수가 유사하도록 하였다. 정치적 성향에 따라 편향된 어휘의 수는 Table 6과 같다. Table 6의 편향성 어휘 예시는 평균 유사도의 차이가 큰 순으로 정렬된 상위 20개의 어휘이다. 각 성향으로 검증된 편향성 어휘의 특성을 확인한 결과, 보수 성향의 Okt 벡터 모델은 '사주였던', '3.2' 등 보수 성향과 관련 없는 편향성 어휘가 함께 추출된 반면, SP_150k 벡터 모델은 '박정희', '최순실' 등 보수 성향을 나타내는 편향성 어휘가 추출된 것을 확인하였다.

SP_150k를 이용한 편향성 어휘 추출 결과, 보수 성향에서 '박근혜', '김기춘', '이회창' 등과 같이 보수의 정치적 성향으로 지칭했던 정치인들의 성향이 보수에 속하는 것을 검증하였다. 이외에도 '박정희', '최순실', '노태우', '새누리당' 등 보수적 성향의 편향성 어휘가 추출되었다. 진보 성향의 편향성 어휘 결과, '박원순', '유시민' 등의 정치인 성향을 검증하였으며 이외에도 '노무현재단', '더불어민주당', '이해찬', '박영선' 등 진보

Table 6. Political Tendency Keywords using Person Keyword Analysis Method(Conservative, Liberal, Neutral)

Tendency	Tokenizer	Biased vocabulary size	Biased keyword(Top 20)
Conservative	Okt	42	박근혜 노태우 이명박 김영삼 황교안 박정희 홍준표 MB 한나라당 사주였던 추악했다 격렬해진다 3.2 서리였던 양승태 눈이처럼 되어가나 합친다는 632만원 이병기
	SP_150k	37	박근혜 김기춘 이회창 전두환 이명박 김영삼 박정희 국정농단 최순실 황교안 노태우 홍준표 양승태 새누리당 YS 탄핵 한나라당 전두환이 신군부 김무성
Liberal	Okt	41	더불어 노무현재단 김현미 행정안전부 노영민 김영춘 이해찬 행안부 이인영 김진표 이사장 류효립 원만하다면 정세균 서울시장 살아오느냐 도봉구갑 이재정 한병도 콜럼
	SP_150k	43	박원순 노무현재단 행정안전부 더불어민주당 유시민 이해찬 박영선 김현미 민주당 이인영 서울시장은 노영민 원혜영 서울시장 한병도 김영춘 정세균 서울시장이 국무총리와 이사장이
Neutral	Okt	91	9454 강경합니다 문 이재명 대통령비서실장 돌아오느냐고 오지마 자셨잖아요 이정우선임기 겸손함을 했다는것이 28.03 38.74 박주민 6.3715 40.27 내세우자는 27.04 대표 524회
	SP_150k	66	권성동 참여정부 창국 황영철 조강특위 5.18 광주학살 대표가 보안사령관이 조직강화특위 행정자치부 노무현 수석대변인은 이사장의 총리 통일민주당 비서실장은 대통령은 DJ 윤성혜

성향의 특성을 보이는 편향성 어휘를 확인하였다. 임베딩 기법을 이용하여 정치적 어휘를 추출하고 추출된 어휘의 정치적 특성을 검증하여 편향성 어휘를 확장하였다. 인물 키워드 기반의 정치적 어휘 분석으로 정치인들의 성향을 검증하였으며 정치적 성향에 따라 검증된 편향성 어휘를 분석하였다.

5. 결 론

정치 분야의 뉴스 기사에서는 보수와 진보에 대한 양극화된 관점에서 정보를 기술하는 경향이 있으며 이로 인해 정치적 편향성 문제가 제기된다. 이러한 정치적 편향성 문제에 접근하기 위해 본 논문에서는 키워드 기반으로 검색되는 기사를 수집하여 학습 데이터를 구축하였다. 미등록어 토큰의 수를 감소시키기 위한 형태소 임베딩의 특성을 고려하여 부분 단어 토큰화 기법이 미등록어 토큰의 수를 감소시키는 데에 효과적일 것이라 예상하였다. 이를 실험하기 위해 구축한 데이터에 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델을 적용하여 정치적 편향성 분류 실험을 진행하였으며 형태소 토큰화 기법을 이용한 문서 임베딩 모델과 비교 실험하였다. 실험 결과, PBK_50k 데이터에서 vocab size 150k의 SentencePiece 부분 단어 토큰화 기법을 이용한 문서 임베딩 모델의 정확도가 78.22%로 가장 높은 성능을 보였다.

미등록어에 대처하는 부분 단어 토큰화 기법의 효과를 입증하기 위해 미등록어 수를 확인하였으며 형태소 토큰화 기법보다 부분 단어 토큰화 기법을 통해 미등록어 수가 월등히 감소되는 것을 확인하였다. 이를 통해 부분 단어 토큰화 기법을 이용하여 미등록어 수를 감소시킬 수 있으며 OOV 문제를 완화시키는 방법으로 효율적임을 입증하였다.

PBK_50k 데이터에서 가장 높은 성능을 보인 SP_150k 임베딩 모델을 이용하여 정치적 편향성 어휘를 추출하였다. 정치인 키워드를 기반으로 정치적 어휘를 추출하고 평균 유사도를 통해 보수와 진보, 중립의 성향에 속하는 편향성 어휘를 확장하였다. 확장된 어휘 분석 결과, 성향에 따라 검증된 편향성 어휘가 해당 정치적 성향의 특성을 나타내는 것을 확인하였으며 형태소 분석기를 이용한 임베딩 모델보다 부분 단어를 이용한 임베딩 모델로 검증한 어휘가 편향적 특성을 잘 나타내는 것을 확인하였다.

감사의 글

국민대학교 자연어처리 연구실에 학부생 연구원으로 참여하여 본 연구를 수행하는데 필요한 학습데이터를 수집하고, 편향성 분류 실험을 도와준 컴퓨터공학부 박지훈 학생(참여 기간: 2019/07~2020/02)에게 감사드립니다.

References

- [1] S. Greene and P. Resnik, "More than words: Syntactic packaging and implicit sentiment," in *Proceedings of the Human Language Technologies: The 2009 Annual Conference of the North American Chapter of the Association for Computational Linguistics, Boulder*, pp.503-511, 2009.
- [2] M. Recasens, C. Danescu-Niculescu-Mizil, and D. Jurafsky, "Linguistic models for analyzing and detecting biased language," in *Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, Sofia*, Vol.1, pp.1650-1659, 2013.
- [3] C. Hube and B. Fetahu, "Detecting biased statements in wikipedia," in *Companion Proceedings of the Web Conference 2018, Lyon*, pp.1779-1786, 2018.
- [4] L. Fan, M. White, E. Sharma, R. Su, P. Choubey, R. Huang, and L. Wang, "In plain sight: media bias through the lens of factual reporting," in *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, Hong Kong*, pp.6343-6349, 2019.
- [5] N. Mehrabi, F. Morstatter, N. Saxena, K. Lerman, and A. Galstyan, "A survey on bias and fairness in machine learning," in arXiv preprint arXiv:1908:09635, 2019.
- [6] T. Bolukbasi, K. Chang, J. Zou, V. Saligrama, and A. Kalai, "Man is to computer programmer as woman is to homemaker? debiasing word embeddings," in *Proceedings of the Advances in Neural Information Processing Systems, Red Hook*, pp.4349-4357, 2016.

[7] S. Bordia and S. Bowman, "Identifying and reducing gender bias in word-level language models," in *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics*, Minneapolis, pp.7-15, 2019.

[8] J. Font and M. Costa-Jussa, "Equalizing gender biases in neural machine translation with word embeddings techniques," in *Proceedings of the 1st ACL Workshop on Gender Bias in Natural Language Processing*, Florence, pp.147-154, 2019.

[9] E. Sheng, K. Chang, P. Natarajan, and N. Peng, "The woman worked as a babysitter: On biases in language generation," in *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing*, Hong Kong, pp.3407-3412, 2019.

[10] T. Mikolov, I. Sutskever, K. Chen, G. Corrado and J. Dean, "Distributed representations of words and phrases and their compositionality," in *Proceedings of the Advances in Neural Information Processing Systems*, Nevada, pp.3111-3119, 2013.

[11] T. Mikolov, K. Chen, G. Corrado and J. Dean, "Efficient estimation of word representations in vector space," in *Proceedings of the 1st International Conference on Learning Representations*, 2013.

[12] J. Pennington, R. Socher and C. Manning, "Glove: Global vectors for word representation," in *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing*, Doha, pp.1532-1543, 2014.

[13] J. Botha and P. Blunsom, "Compositional morphology for word representations and language modelling," in *Proceedings of the International Conference on Machine Learning*, Beijing, Vol.32, pp.1899-1907, 2014.

[14] R. Cotterell and H. Schutze, "Morphological word embeddings," in *Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics*, Denver, pp.1287-1292, 2015.

[15] J. Wieting, M. Bansal, K. Gimpel, and K. Livescu, "Towards universal paraphrastic sentence embeddings," in *Proceedings of the 4th International Conference on Learning Representations*, 2016.

[16] T. Kudo, "Subword regularization: Improving neural network translation models with multiple subword candidates," in *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics*, Melbourne, Vol.1, pp.66-75, 2018.

[17] M. Domingo, M. Garcia-Marinez, A. Helle, F. Casacuberta, and M. Herranz, "How much does tokenization affect neural machine translation?," in arXiv preprint arXiv:1812.08621, 2018.

[18] P. Bojanowski, E. Grave, A. Joulin, and T. Mikolov, "Enriching word vectors with subword information," in *Transactions of the Association for Computational Linguistics*, Vol.5, pp.135-146, 2017.

[19] D. Cho, H. Lee, and S. Kang, "Sentiment analysis for informal text by using sentencepiece tokenizer and subword embedding," in *Proceedings of the Korea Computer Congress 2020*, Online, pp.395-397, 2020.



조 단 비

<https://orcid.org/0000-0003-1611-3192>

e-mail : daanv319@kookmin.ac.kr

2020년 국민대학교 경영학부

빅데이터경영통계전공(학사)

2020년~현 재 국민대학교 컴퓨터공학과

석사과정

관심분야 : 자연어처리, 기계학습, 인공지능, 정보검색, 텍스트마이닝, 빅데이터 분석



이 현 영

<https://orcid.org/0000-0003-2553-6576>

e-mail : hyunyoung2@kookmin.ac.kr

2016년 국민대학교 컴퓨터공학부(학사)


2016년~2017년 SK Hynix Memory

Solutions Inc. Intern

2019년 국민대학교 컴퓨터공학과(석사)

2019년~현 재 국민대학교 컴퓨터공학과 박사과정

관심분야 : 자연어처리, 기계학습, 인공지능, 정보검색, 빅데이터 분석, 추천시스템



정 원 섭

<https://orcid.org/0000-0002-3910-0880>

e-mail : wonsupj@kyungnam.ac.kr

1989년 서울대학교 철학과(학사)

1991년 서울대학교 철학과(석사)


2004년 서울대학교 철학과(박사)

2007년 Purdue University post-doctor

2018년 서울대학교 선임연구원

2019년~현 재 경남대학교 자유전공학부 교수

관심분야 : Fairness and ethics in artificial intelligence



강 승 식

<https://orcid.org/0000-0003-3318-6326>

e-mail : sskang@kookmin.ac.kr

1986년 서울대학교 컴퓨터공학과(학사)

1988년 서울대학교 컴퓨터공학과(석사)

1993년 서울대학교 컴퓨터공학과(박사)

2001년~현 재 국민대학교

소프트웨어학부 교수

관심분야 : 자연어처리, 텍스트마이닝, 빅데이터 분석, 상황인지 컴퓨팅