

한국어 언어모델 파인튜닝을 통한 협찬 블로그 텍스트 생성

(Generating Sponsored Blog Texts through Fine-Tuning of Korean LLMs)

김보경¹⁾, 변재연²⁾, 차경애³⁾

(Bo Kyeong Kim, Jae Yeon Byun, and Kyung-Ae Cha)

요약 본 논문에서는 대규모 한국어 언어모델인 KoAlpaca를 파인튜닝하고 이를 이용한 블로그 텍스트 생성 시스템을 구현하였다. 소셜 미디어 플랫폼의 블로그는 기업 마케팅 수단으로 널리 활용된다. 수집된 협찬 블로그 텍스트의 감정 분석과 정제를 통한 긍정 리뷰의 학습 데이터를 구축하고 KoAlpaca 학습의 경량화를 위한 QLoRA를 적용하였다. QLoRA는 학습에 필요한 메모리 사용량을 크게 줄이는 파인튜닝 접근법으로 파라미터 크기 12.8B 경우의 실험 환경에서 LoRA 대비 최대 약 58.8%의 메모리 사용량 감소를 확인하였다. 파인튜닝 모델의 생성 성능 평가를 위해서 학습 데이터에 포함되지 않은 100개의 입력으로 생성한 텍스트는 사전학습 모델에 비해서 평균적으로 두 배 이상의 단어 수를 생성하였으며 긍정 감정의 텍스트 역시 두 배 이상으로 나타났다. 정성적 생성 성능 평가를 위한 설문조사에서 파인튜닝 모델의 생성 결과가 제시된 주제에 더 잘 부합한다는 응답이 평균 77.5%로 나타났다. 이를 통해서 본 논문의 협찬물에 대한 긍정 리뷰 생성 언어모델은 콘텐츠 제작을 위한 시간 관리의 효율성을 높이고 일관된 마케팅 효과를 보장하는 콘텐츠 제작이 가능함을 보였다. 향후 사전학습 모델의 생성 요소에 의해서 긍정 리뷰의 범주에서 벗어나는 생성 결과를 감소시키기 위해서 학습 데이터의 증강을 활용한 파인튜닝을 진행할 예정이다.

핵심주제어: KoAlpaca, QLoRA, 파인튜닝, 텍스트 생성, 마케팅 콘텐츠

Abstract In this paper, we fine-tuned KoAlpaca, a large-scale Korean language model, and implemented a blog text generation system utilizing it. Blogs on social media platforms are widely used as a marketing tool for businesses. We constructed training data of positive reviews through emotion analysis and refinement of collected sponsored blog texts and applied QLoRA for the lightweight training of KoAlpaca. QLoRA is a fine-tuning approach that significantly reduces the memory usage required for training, with experiments in an environment with a parameter size of 12.8B showing up to a 58.8% decrease in memory usage compared to LoRA. To evaluate the generative performance of the fine-tuned model, texts generated from 100 inputs not included in the training data produced on average more than twice the number of words compared to the pre-trained model, with texts of positive sentiment also appearing more than twice as often. In a survey conducted for qualitative evaluation of generative performance, responses indicated that the fine-tuned model's generated outputs were more relevant to the given topics on average 77.5% of the time. This demonstrates that the positive review generation language model for sponsored content in this paper can enhance the efficiency of time management for content creation and ensure consistent marketing effects. However, to reduce the generation of content that deviates from the category of positive reviews due to elements of the pre-trained model, we plan to proceed with fine-tuning using the augmentation of training data.

Keywords: KoAlpaca, QLoRA, Fine-Tuning, Text Generation, Marketing Content

* Corresponding Author: chaka@daegu.ac.kr
Manuscript received March 15, 2024 / revised April
08, 2024 / accepted April 26, 2024

1) 대구대학교 AI학과, 제1저자
2) 대구대학교 AI학과, 제2저자
3) 대구대학교 AI학과, 교신저자

1. 서론

인공지능의 발전은 초거대 생성 AI의 출현으로 여러 분야에서 AI가 생성하는 콘텐츠의 활용이 증대되고 있다 (Han et al., 2023; Kang et al., 2024; Nah et al., 2023; Rathore B, 2023; Oh et al., 2023). 특히 OpenAI(2021)에서 대규모 언어모델이 공개되면서 일반화된 사용성이 확보되어 텍스트 기반 콘텐츠 생성이 활발히 이루어지고 있다 (Kim, 2023). 이러한 변화는 마케팅 영역에서도 가능성을 열어준다 (Kim et al., 2023; Vasarhelyi et al., 2023).

본 논문에서는 대규모 언어모델을 블로그 마케팅 콘텐츠 생성에 적용할 수 있도록 파인튜닝하여 텍스트 생성 능력과 실용성에 미치는 영향을 분석하였다. 이를 통하여 블로그 리뷰 텍스트 생성 분야에서 언어모델의 활용성을 보이고자 한다.

소셜 미디어 플랫폼의 블로그는 기업의 고객 확보와 고객 요구 사항을 파악하는 등의 마케팅을 위한 주요 수단으로 활용된다 (Ahn et al., 2017; Han et al., 2017). 특히 협찬물의 리뷰를 포스팅하는 형태의 블로그 마케팅이 자주 사용된다. 이때 협찬물에 대한 긍정적 리뷰를 포스팅할 수도 있지만 부정적 의미를 내포하는 리뷰를 작성하기도 한다 (Soh, 2012). 한편 마케팅의 효과를 높이기 위해서는 협찬물에 대한 긍정적 리뷰를 보장하는 블로그 텍스트가 필요하며 이의 자동 생성 AI를 제공한다면 기업의 블로그 마케팅에 활용할 수 있다.

본 논문에서는 한국어를 이용하는 오픈소스 언어모델인 KoAlpaca (KoAlpaca, 2023)를 파인튜닝(Fine-Tuning)하여 협찬물의 긍정 리뷰를 담은 텍스트를 생성하는 언어모델을 구현하였다. 파인튜닝은 메모리 등 컴퓨팅 리소스 사용을 최대한 줄일 수 있는 QLoRA(Quantized Low-Rank Adaptation)를 적용하였다 (Dettmers et al., 2023).

긍정 리뷰의 텍스트 생성을 보장하는 학습을 위해서 수집된 블로그 텍스트 데이터의 정제와 분석을 통해서 학습 데이터를 구축하였다. 그리고 Instruct-following 언어모델인 KoAlpaca를

활용하는 사용자 인터페이스를 구현하여 입력 키워드에 부합되는 협찬 블로그 텍스트를 생성하도록 하였다. 또한 파인튜닝된 모델의 성능 분석을 위해 학습 데이터셋에 포함되지 않은 새로운 100개의 독립적인 제목을 기반으로 한 텍스트 생성 실험을 수행하고, 파인튜닝 전후의 모델을 비교 분석하여 장문의 텍스트 생성 능력과 감정 분석 및 설문 조사를 통해서 활용성을 평가하였다.

본 논문은 다음과 같이 구성된다. 2장에서는 협찬 콘텐츠의 활용성과 함께 KoAlpaca 모델과 QLoRA 기술을 소개한다. 3장에서는 학습 데이터의 구축 과정, 데이터셋의 감정 분석을 통한 정제, 그리고 최종 데이터셋의 임베딩 연구와 분석 방법을 설명한다. 4장에서는 생성된 블로그 콘텐츠 모델의 결과를 통해 얻은 답변의 품질을 평가하고 모델의 성능을 분석한다. 마지막으로 5장에서는 연구 결과를 종합하여 결론을 도출한다.

2. 관련 연구

2.1 협찬 블로그의 활용성

블로그를 통한 마케팅은 기업에 매력적인 운용 전략으로 자리 잡고 있다. 특히 개인이 운영하는 블로그 마케팅이 더 설득력과 신뢰도가 높고 비용 효율성 또한 우수하다 (Yeu et al., 2020). 이러한 연구에 기반하여 협찬물의 경험을 공유하는 리뷰 형태의 블로그 포스팅은 널리 활용되는 전략이다.

본 논문에서는 한국어 대규모 언어모델을 파인튜닝하여 마케팅 목적의 블로그 콘텐츠 생성이 가능하도록 구현하고자 한다.

언어 모델은 방대한 양의 데이터를 사용하여 사전학습(pre-training)되어 범용적인 언어 이해 능력을 갖추게 된다. 이때, 사전 학습된 모델을 특정 목적에 최적화하기 위해서 목적에 부합되는 학습데이터셋을 이용하여 파인튜닝할 수 있다. 따라서 본 논문에서는 협찬 마케팅 텍스트를 생성하도록 사전학습 모델 중에서 한국어 언

어모델인 KoAlpaca를 긍정 리뷰의 학습데이터셋으로 재학습한 파인튜닝 모델을 생성하고 이의 마케팅에의 활용 가능성을 보인다.

2.2 KoAlpaca와 QLoRA

본 논문에서는 한국어 언어모델인 KoAlpaca를 파인튜닝하여 협찬 블로그 텍스트를 자동 생성한다.

KoAlpaca는 스탠포드 대학의 Alpaca (Taori et al., 2023)의 학습 방식으로 한국어 데이터셋(instruction set)을 제작하여 학습한 모델이다. Alpaca 모델은 LLaMA(Touvron, 2023)를 Instruction-following 형식으로 파인튜닝한 모델이며 공개 소스로 제공되어 다양한 언어모델 연구에 활용한다.

KoAlpaca의 사전학습 모델은 한국어 대규모 언어모델인 Polyglot-Ko (Ko et al., 2023)를 기반으로 하며 기존 Alpaca 모델이 한국어 맥락을 이해하지 못하는 점을 개선한 것이다.

블로그 텍스트 학습을 위한 파인튜닝에는 QLoRA(Dettmers et al., 2023)를 적용하였다. 이는 KoAlpaca 모델에 지원하는 Hugging Face 라이브러리로써 다운스트림 작업의 성능을 유지하면서도 학습에 필요한 메모리나 크기를 줄이는 PEFT(Parameter Efficient Fine-Tuning) 방법 중 하나이다. 특히 LoRA(Low-Rank Adaptation)에 양자화 기법을 적용하여 학습 시 메모리 소모를 효과적으로 감소한다.

QLoRA의 하이퍼파라미터로는 Rank, LoRA-Alpha, 그리고 LoRA-Dropout이 있다. Rank는 Low-rank Adapters 내에서 학습 가능한 파라미터의 수를 결정하여, 모델의 메모리 요구 사항을 최적화하는 데 중요한 역할을 한다. LoRA-Alpha는 학습 과정에서 파라미터 업데이트의 속도를 조절하여, 미세 조정의 효율성을 극대화한다. LoRA-Dropout은 학습 중 일부 연결을 무작위로 생략함으로써 모델의 과적합을 방지하고 일반화 능력을 향상시키는 역할을 한다. 이러한 하이퍼파라미터의 조절을 통해, 본 연구는 KoAlpaca 모델이 한정된 자원하에서도 협찬 블로그 텍스트를 효과적으로 생성할 수 있

도록 학습을 진행하였다.

한편, Low-Rank Adapters 기법은 훈련 중 메모리 요구 사항을 줄이기 위해 소수의 학습 가능한 파라미터를 사용하는 방법론이다. Fig. 1과 같이 gradients가 고정된 사전훈련된 모델 가중치를 4-bit까지 할당이 가능하게 되어 어댑터에 전달되며, 손실 함수를 최적화 하기 위해 업데이트된다. 또한 GPU 사용량이 부족하게 되었을 때, CPU의 d-ram을 paging하게 된다.




Fig. 1 QLoRA Memory Handling Mechanism

3. 협찬 블로그 텍스트 생성 시스템

3.1 KoAlpaca 파인튜닝 모델 생성 구성도

본 논문에서 긍정 리뷰의 블로그 텍스트 생성 언어모델의 학습을 위한 과정은 Fig. 2과 같다.

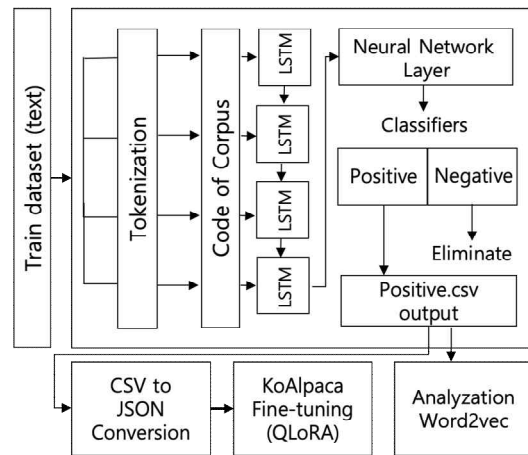


Fig. 2 System Architecture

웹에서 공개된 블로그 텍스트를 수집하고 전

처리와 워드 임베딩 과정을 통해 벡터로 변환한다. 이 코드화 코퍼스는 먼저 LSTM에 입력하여 긍정 혹은 부정의 클래스로 분류한다. 긍정 클래스로 분류된 데이터가 긍정 리뷰의 블로그 텍스트를 생성하기 위해서 적절한지를 분석하고 생성 모델의 입력으로 사용하도록 구축하였다.

KoAlpaca 파인튜닝에 활용하기 위한 긍정 클래스의 학습 데이터는 Instruct-following 모델의 형식에 맞도록 전 처리되며 경량화를 위한 요소로 QLoRA를 적용한다.

3.2 학습 데이터 수집

본 논문에서는 협찬 콘텐츠 생성을 위한 데이터 구축을 위해 네이버 블로그 검색 엔진 내에서 해쉬태그협찬 키워드가 존재하는 URL을 수집하였다. 이는 공정거래위원회의 지침에 근거한 조치로, 협찬 콘텐츠에 있어서 '#협찬' 해시태그를 가장 앞에 배치하도록 명시하고 있기 때문이다 (Kang et al., 2020). 데이터 수집 기간은 2023년 4월 3일부터 2023년 4월 10일까지, 총 8일간 진행하였다. Python과 BeautifulSoup 라이브러리를 이용하여 텍스트 데이터만 수집하였다. 그리고 크롤링시에 부적절한 접근으로 인식하는 경우를 대비하여 headers에 User-Agent를 포함했다. 총 5,368개의 데이터를 수집하였으며, 이를 pandas 라이브러리를 사용하여 데이터 프레임 형식으로 정리하였다. Fig. 3은 수집한 데이터 중 일부를 보여준다.

제목	링크
납득됐던 제주도 점심 맛집	https://blog.naver.com/inju1469/223109768459
푸짐했던 포천 이동길비 맛집	https://blog.naver.com/wiqwjrrjf/223100346314
힐링됐던 포천 이동길비 맛집	https://blog.naver.com/smartk0304/223105891367
한남동 분위기 좋은 브런치 맛집	https://blog.naver.com/keummin/223124928203
후회없던 제주도 갈치조림 맛집	https://blog.naver.com/karazan1/223122517767

내용
해외여행을 다녀와 지저버린 동생의 허기를 채우기 위해 고심 끝에 선택한 제주도 점...
주말에 가족들과 놀러 갔다가포천 이동길비 맛집에 다녀왔어요 직접 만든 말반찬과 고철...
안녕하세요 맛집 맛집 스마트JK 입니다 지난번 지인들과 경기도로 드...
한남동 맛집분위기 좋은 브런치 레스토랑 한남동 브런치 맛집을 소개드릴게요 가끔 ...
얼마 전에 제주로 출장을 갔다가 또다른 제주도 갈치조림 맛집을 발견했어요 20여 년...

Fig. 3 Examples of Collected Text Data

수집한 데이터는 '제목', '링크', '내용'의 각 열에 중복된 값을 제거하기 위해서 Friedl et al.(2006)이 제안한 정규 표현식(regular expression)을 적용하여 구두점, 숫자, 공백문자, HTML 태그, 첫 문자의 공백, 끝 문자의 공백을 제거하였다. 이렇게 전 처리된 데이터는 다시 한번 판다스 데이터 프레임에 저장되고, 이후 LSTM을 이용하여 긍정과 부정 클래스로 분류한다.

3.3 감정 분석을 통한 데이터 정제

위와 같이 협찬 키워드로 수집된 초기 데이터셋에 대하여 부정적 반응의 콘텐츠를 식별하는 데이터 정제 과정을 진행한다. 블로그 글 협찬 글은 특정 제품이나 서비스를 홍보하기 위해 작성되지만, 블로거가 리뷰 형식으로 작성하는 경우가 대부분으로 부정적 리뷰가 포함될 수 있다.

감정 분석은 머신러닝 분류 기법이나 딥러닝 모델을 활용하여 감정을 판별할 수 있다 (Kim et al., 2023). 본 논문에서는 긍정 및 부정 감정 분석을 통해 텍스트의 속성을 파악하기 위해서 LSTM Classifier (Hochreiter et al., 1997) 모델을 활용하였다. 사용한 LSTM Classifier는 네이버 쇼핑 리뷰 데이터 20만 건을 학습하여 텍스트의 감정을 추론하는 모델이다. 따라서 이를 기반으로 본 논문의 학습 데이터를 긍정과 부정으로 분류하여 파인튜닝에 활용하였다.

Table 1은 감정 분석의 결과이며 긍정과 부정의 클래스 추론 비율이 약 4:1 비율로 나타났다. 이때 출력된 결과인 확률점수가 0.5 이상일 경우 긍정으로, 그렇지 않을 경우 부정으로 분류되어 점수가 유효하지 않은 범위에 있을 경우에는 데이터셋에서 제거하였다.

이처럼 학습 데이터 구축 과정에서 실제로 소셜 플랫폼에 게시된 협찬 콘텐츠 중 기업의 의도와는 달리 부정적 표현을 담고 있는 경우가 존재함을 확인할 수 있었다. 따라서 기업 홍보의 목적에 부합되는 콘텐츠를 생성하는 언어모델 개발이 필요함을 알 수 있다.

Table 1 Statistical Information on Positive Reviews & Negative Reviews

	Positive	Negative	Not Defined
count	3815	1548	5

분류된 텍스트의 감정 요소를 그래프로 나타내면 Fig. 4와 같다. 긍정 리뷰는 높은 평균 점수와 낮은 표준 편차로 긍정적인 감정을 일관되게 인식하고 있다. 부정적 리뷰의 경우 평균 점수가 긍정적 리뷰보다 낮게 나타났지만, 중앙값과 최댓값이 상대적으로 높다.




Fig. 4 Density Estimate of Sentiment Probability: Original Text dataset

한편, 수집된 데이터 중 부정적 리뷰의 예는 Table 2와 같다. 이것은 제품의 품질에 대한 불만을 직접적으로 드러내고 있어 마케팅 활동에 부정적 영향을 미칠 수 있다.

Table 2 Negative Review Example

"The most satisfying product for me was the Anua Heartleaf Toner. Personally, **I don't recommend** Anua's foam cleanser because the scent is odd, and Dany really hates it... etc." ...

3.4 학습 데이터 분석

텍스트 데이터의 의미론적 특성을 분석하기 위해 워드 임베딩 기술 중 하나인 Word2Vec을

사용하였다. Word2Vec은 코퍼스로부터 단어를 벡터로 변환하는 기술이다(Goldberg et al., 2014). 이 모델은 주변 단어의 맥락을 이용하여 단어의 의미를 수치화된 벡터 형태로 표현하는데, 이렇게 생성된 벡터는 단어 사이의 의미적 관계를 반영한다.

Fig. 5와 같은 과정을 통해서 긍정 클래스로 분류된 데이터셋을 Word2Vec 모델을 통해서 고차원 벡터로 변환하는 작업을 수행하였다.

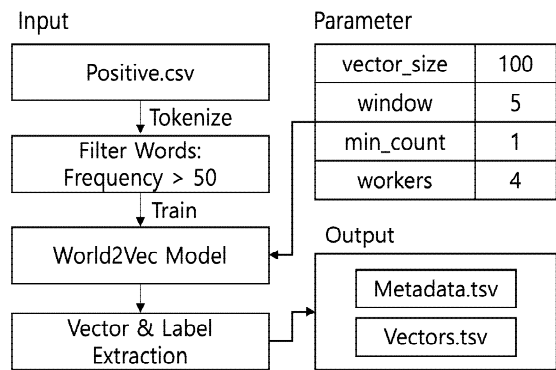


Fig. 5 Word Embedding & Visualization Flowchart

데이터셋을 토큰화하는 과정에서 나타난 빈도수를 기반으로, 맞춤법 오류나 부정확한 단어 사용 문제를 해결하기 위해, 최소 50번 이상 사용된 단어들만을 선별하여 중복을 제거했다. 이를 통해 정제된 데이터셋에서 각 단어를 벡터화하며, 변환된 단어 벡터들은 구글이 제공하는 임베딩 프로젝터를 통해 시각화하였다. 데이터의 차원 축소에는 McInnes et al.(2018)이 제안한 UMAP(Uniform Manifold Approximation and Projection) 방법을 사용하였는데, 이는 고차원 데이터의 복잡한 구조를 보존하며 저차원으로 맵핑할 수 있는 기술이다.

Fig. 6에서는 '제품협찬'이라는 키워드 벡터의 Cosine Distance를 통해 가까운 단어들이 시각화된 예를 보이고 있다. '네이버 쇼핑', '뷰티', '원고료' 등이 가까운 위치에 나타나 일상에서 인지되는 유사도로 단어들이 표현되고 있음을 확인할 수 있다.

이는 구축된 학습 데이터의 유효성을 분석함

으로써, 긍정 리뷰 생성을 위한 파인튜닝에 효과적인 데이터임을 사전에 확인하는 과정을 수행하였다.




Fig. 6 Embedding Vector Visualization: product provision

3.5 파인튜닝 최종 학습 데이터 구축

초기에 수집된 블로그 텍스트를 정제하고 긍정 리뷰를 선별한 데이터셋은 KoAlpaca 모델이 요구하는 'instruction', 'input', 'output'의 세 가지 필드를 포함하는 JSON 형식으로 구성한다. 이는 특정 목적에 대한 추론 결과를 도출하기 위해서 지도학습의 형태로 구축되어야 하기 때문이다.

'instruction' 필드는 모델에게 수행할 작업의 지시를 포함하며, 'input' 필드는 해당 작업을 수행하기 위한 구체적인 입력으로 제공하는 부분으로 공란으로 설정되어 있다. 이는 파인튜닝 모델이 'instruction'을 기반으로 'output'을 생성하는 형식이기 때문이다. 'input' 필드는 'instruction'의 입력 문장에 추가적 정보가 필요한 경우에 사용되는데, 본 논문의 학습 데이터셋의 경우는 이 필드가 요구되지 않는다.

'output' 필드는 모델이 생성해야 하는 결과물, 즉 지시 사항에 대한 응답을 말한다. 모델에 적합한 데이터셋 형태를 Table 3의 예와 같이 "한남동 분위기 좋은 브런치 맛집"이라는 제목을 'instruction'으로 주고, 상세한 본문 브런치 레스토랑 리뷰를 'output'으로 구성하였다.

Table 3 Example of KoAlpaca model Dataset Composition

instruction	"Good brunch restaurant in Hannam-dong"
input	" "
output	"A brunch restaurant with a great atmosphere in Hannam-dong. I will introduce you to a brunch restaurant in Hannam-dong. (...) They are great to eat as an appetizer before a meal. The atmosphere was friendly and I had a great time. Highly recommended."

이 과정을 통해 최종적으로 총 3,815개의 학습 데이터를 구축하고 파인튜닝에 사용하였다.

3.6 KoAlpaca 파인튜닝

본 논문에서 KoAlpaca 모델의 파인튜닝을 Hugging Face 플랫폼상에 공개된 'beomi/polyglot-ko-12.8b-safetensors' 및 'beomi/KoAlpaca-Polyglot-5.8B' 레포지토리를 사용하였다.

사용된 KoAlpaca 12.8B 및 5.8B 모델은 Polyglot-Ko를 기반으로 일반 한국어 문장 생성에 우수한 성능을 보인다. 이에 블로그 텍스트를 학습하여 파인튜닝 하여 활용할 수 있다.

학습을 위한 컴퓨팅 환경은 NVIDIA H100 GPU를 사용하였으며, 메모리 사용량을 평가하기 위해서 12.8B와 5.8B 크기의 두 모델에 대하여 Hugging Face PEFT 라이브러리인 LoRA와 QLoRA 방식을 각각 적용한 실험을 총 4회 실시하였다. 모든 실험에서는 Table 4과 같이 일관된 하이퍼파라미터 설정을 적용하여, 실험 결과를 비교하였다. 실험 모니터링 및 결과 분석은 Wandb(Weights & Biases) 플랫폼을 이용하여 수행되었다. Wandb는 기계 학습 실험을 효율적으로 관리하고 모니터링할 수 있는 클라우드 서비스로, 실시간 데이터 로깅 및 시각화 기능을 제공한다. 이를 통해, GPU 메모리 사용량, 학습 속도 등 학습 메트릭스를 실시간으로 추적하고 기록하였다.

Table 4 Hyper Parameters

Batch	16
Epochs	3
Learning-Rate	5e-4
Rank	32
LoRA-Alpha	16
LoRA-Dropout	0.5

하이퍼파라미터로는 Rank, LoRA-Alpha, 그리고 LoRA-Dropout이 포함된다. Rank 32는 LoRA 변환 시 적용되는 저랭크 행렬의 차원을 지정하며, 이는 모델의 파라미터 수를 효율적으로 조절하여 학습 효율성을 높인다. LoRA-Alpha는 16으로 설정되어, LoRA 방식에서의 가중치 업데이트 시 스케일링 인자로 작용한다. 마지막으로, LoRA-Dropout 비율을 0.5로 설정하여, 학습 과정 중 일부 뉴런을 임의로 비활성화시켜 과적합을 방지하는 기법이 적용되었다.

4. 실험 결과

4.1 PEFT 기법의 GPU 할당 성능 비교

Table 5에서 LoRA와 QLoRA 방식을 적용하여 GPU 메모리 사용량과 학습 시간을 비교 분석했다. 이는 12.8B와 5.8B 크기의 모델을 대상으로 수행되었으며, 주요 목적은 메모리 사용 감소와 학습 속도 변화를 측정하는 것이었다. 실험 결과, 12.8B 모델에서 QLoRA 방식으로 전환 시 GPU 메모리 사용량이 70.1에서 28.9로 약 58.8% 감소하였으며, 5.8B 모델에서는 51.9% 감소하였다.

Table 5 GPU Allocation Performance Comparison

Parameters Size(B)	LoRA		QLoRA	
	12.8	5.8	12.8	5.8
GPU Memory Allocated(GB)	70.1	39.8	28.9	19.1

QLoRA 적용으로 메모리 사용량은 크게 줄었으나, Fig. 7과 같이 학습 시간은 일부 증가했다. 이는 QLoRA가 메모리 사용을 줄이는 데 효과적이지만, 계산 복잡도를 높여 학습 시간에 영향을 준다는 것을 의미한다. 그러나, 절약된 메모리를 이용해 배치 크기를 늘릴 수 있으므로, 학습 속도를 개선할 수 있는 가능성을 제시한다.




Fig. 7 Process GPU Memory Allocated

실험 결과 분석에 의해서 QLoRA 방식은 모델 크기가 클수록 성능이 향상되며, QLoRA를 사용하면 큰 모델을 더 효율적으로 학습할 수 있다. 이에 따라, 본 연구는 12.8B 크기의 QLoRA 방식을 적용한 KoAlpaca 모델로 협찬 블로그 텍스트를 생성하는 파인튜닝 모델을 학습하였다.

본 논문에서 구현한 KoAlpaca를 QLoRA 파인 튜닝 모델은 Hugging Face의 모델 허브에 'ByunByun/qlora_0303'로 업로드되어 있다.

4.2 훈련 모델의 생성 성능 평가

훈련된 파인튜닝 모델의 생성 성능을 평가하기 위해 학습 데이터셋에 포함되지 않은 100개의 독립적인 제목을 기반으로 한 텍스트 생성 실험을 수행하였다. 또한, 파인튜닝 전후의 모델을 비교 분석하여 장문의 텍스트 생성 능력을 평가하였다.

Table 6는 입력 프롬프트에서 100개의 주제에 해당하는 제목 문장을 입력하여 파인튜닝 이전의 KoAlpaca 모델과 파인튜닝된 모델이 생성

하는 결과 텍스트를 비교한 것이다. 이 결과는 통계적 수치 분석 정보를 나타내는 pandas 라이브러리를 이용하였으며 mean(평균), std(표준편차), min(최솟값), max(최댓값)의 네 가지 주요 통계량에 초점을 맞추어 데이터의 중심 경향성과 변동성, 그리고 범위를 평가하는 비교 분석을 수행하였다.

파인튜닝 후 모델은 평균적으로 두 배 이상의 단어를 생성하는 것으로 나타났으며, 표준편차가 감소하였다. 표준편차의 감소는 모델이 생성하는 텍스트의 길이와 문맥에서 변동성이 줄었다는 것을 나타낸다.

Table 6 Average Number of Characters in Output Texts

	Before Fine-Tuning	After Fine-Tuning
mean	97.846	217.18
std	78.959	39.473
min	1	41
max	283	303

다음 테스트에는 파인튜닝 전과 후의 두 가지 모델의 생성 결과에 대한 감정 분석을 수행하였다. 각 모델로부터 생성된 텍스트에 대한 감정 분석을 실시한 결과, 파인튜닝 전 모델에서는 부정적 감정을 담은 텍스트의 비율이 파인튜닝 후 모델보다 상대적으로 높게 나타났다. 이러한 결과는 파인튜닝 과정이 긍정 리뷰의 텍스트를 생성하는 데에 효과적임을 시사한다.

Fig. 8은 파인튜닝 이전의 KoAlpaca 모델이 생성한 긍정 및 부정 감정의 확률 밀도 그래프이다. 또한 Fig. 9는 파인튜닝 모델의 출력에 대한 감정 분석 결과이다. Fig. 8과 비교하였을 때 긍정 감정의 블로그 텍스트의 비율이 월등히 높으며 긍정의 감정도 더 강하게 나타남을 알 수 있다. 다만 KoAlpaca는 사전 학습된 대규모 한국어 언어모델인 Polyglot-Ko를 기반으로 하므로 본 논문에서 정제한 학습데이터로 파인튜닝을 하였으나 여전히 부정적인 텍스트를 생성할 수 있는 요인이 있다.




Fig. 8 Kernel Density Estimate of Sentiment Probability for the KoAlpaca Model




Fig. 9 Kernel Density Estimate of Sentiment Probability for the Fine-Tuned KoAlpaca Model

4.3 사용자 UI 구축

Slack은 클라우드 기반의 메시징 플랫폼으로, 다양한 디바이스에서 접근할 수 있다. Slack의 기능을 활용하여 사용자가 프롬프트 창에 입력한 특정 키워드 관련 협찬 텍스트 요청을 처리한다.

Slack 사용자가 프롬프트에 입력한 특정 키워드 관련 협찬 요청은 Slack의 conversations.history 라는 메소드 API를 통해 해당 채널의 기존 메시지를 검색하는 데 활용된다. 구축한 UI는 메소드 API를 사용하여 특정 채널에서 이전에 나

누어진 대화의 맥락을 파악하고 이를 바탕으로 KoAlpaca 모델의 생성기에 입력을 제공한다. 이 모델은 입력된 내용을 분석하여 새로운 콘텐츠를 생성하며, 생성된 내용은 chat.postMessageAPI를 사용하여 Slack 채널로 다시 전송된다. 최종적으로 챗봇은 슬랙과 같은 메시징 플랫폼에 통합되어 사용자 인터페이스를 통해 사용자의 요청에 반응하고, 적절한 응답을 제공한다. 이와 같은 프로세스의 사용자 UI의 구성과 동작 과정은 Fig. 10과 같다.

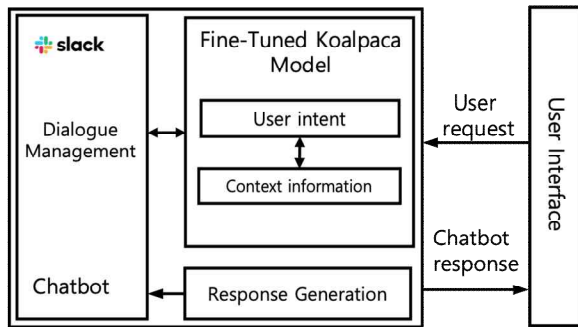


Fig. 10 User Interface Configuration and Operation Process

UI는 핸드폰, 태블릿, 컴퓨터 등 다양한 디바이스를 지원하며, Fig. 11과 같이 프롬프트 입력에 따라, 협찬 블로그 텍스트를 자동으로 생성하여 제공한다.

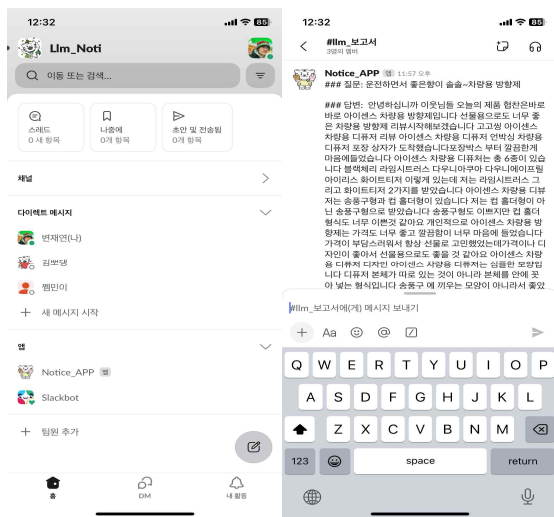


Fig. 11 User Interface

Fig. 12와 같이 사용자의 실제 사용 환경에서 응답속도를 측정하기 위해 20개 문제를 랜덤하게 입력하여 결과에 대한 응답속도를 모바일에서 측정하였다. 모델의 텍스트 생성 속도는 GPU 성능 등의 컴퓨팅 환경에 따라 달라지지만, 본 논문의 실험 환경인 H100 GPU를 사용할 경우 최대 토큰 수 500을 기준으로 최대 2분의 처리 시간이 소요되었으며 대부분의 결과는 1분 이내에 나타났음을 확인하였다.

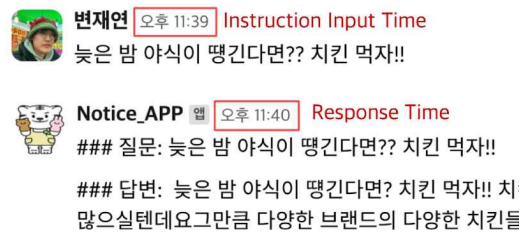


Fig. 12 Measurement of Response Time

4.4 협찬 텍스트 생성 평가를 위한 설문조사

파인튜닝된 모델의 생성 성능을 평가하기 위해서 학습 데이터셋에 포함되지 않은 새로운 입력 키워드에 부합되는 긍정 리뷰의 블로그 텍스트를 생성하는지 여부를 설문하였다.

설문조사는 Fig. 13과 같이 참가자들에게 파인튜닝 전과 후에 생성된 텍스트 샘플들을 무작위로 제시하고, 각 샘플이 제시된 제목의 키워드와 얼마나 잘 부합하는지 평가하도록 하였다.

자연어 생성모델 학습전후 비교

연구 설문지 목적

- 목적: 이 설문지는 인공지능(AI)의 발전이 인간만이 수행할 수 있다고 여겨졌던 창작 분야에서 어느 정도의 역할을 할 수 있는지, 특히 협찬 블로그 글 생성에 시가 얼마나 유용하게 활용될 수 있는지를 평가하는 것을 목적으로 합니다.

설문지 내용

- AI 생성: 참여자는 AI를 이용해 생성된 4개의 글 중에서 주어진 주제에 가장 부합하고 자연스럽게 느껴지는 글을 선택해야 합니다.
- 응답 처리: 참여자의 응답은 연구 목적으로만 사용되며, 모든 응답은 익명으로 처리되어 통계법 제 33조 2항에 따라 보호됩니다.
- 소요 시간: 설문지는 총 4개의 문항으로 구성되어 있으며, 완료하는 데 약 2분에서 4분 정도 소요됩니다.

이메일 *

유리한 이메일 주소

이 양식에서는 이메일 주소가 수집됩니다. [설정 변경](#)

요즘 유행간식 까먹는 건과류, 허니비 구운 껌질 마카미마이 추천

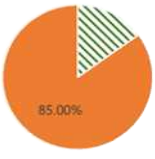
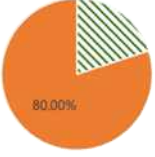

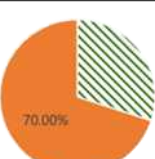
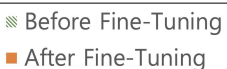
안녕하세요. 저는 건과류 중에 마카미마이 설탕을 추천 헤드로그 싶네요요즘 허니비마카미에 대해서도 불리는 허니버터 마...

허니비 구운 껌질 마카미마이 안녕하세요오늘 리뷰 할 제목은 허니비 구운 껌질 마카미마이 인데요이름부터 달달 고소함...

Fig. 13 Example of Survey Form

설문조사에는 블로그를 사용한 경험이 있으며 SNS 활용에 익숙한 20에서 30대로 이루어진 총 20명이 응답하였다. Table 7과 같이 4개의 샘플에 대해서 모두 파인튜닝 모델이 생성한 텍스트가 제시된 제목과 더 잘 부합한다고 응답하였으며 평균은 77.5%로 나타났다. 이것은 파인튜닝된 모델이 특정 주제나 제목에 대해 더 정확하고 관련성 높은 텍스트를 생성할 수 있음을 보여준다.

Table 7 Results of Survey

Title Keywords (prompt input)	Survey Results
Meat restaurant, company dinner location, recommended restaurant	
Boneless, low-salt boneless fish, boneless mackerel	
Are you looking for a bar with delicious thin ice beer and value for money? A beer restaurant in Sogong-dong!	
A popular snack these days, peeled nuts, Honeybee roasted shell macadamias are recommended.	
	

5. 결론

소셜 미디어 플랫폼에서의 급증하는 콘텐츠와 이용자 수를 감안할 때, 효율적인 마케팅과 콘텐츠 생성은 매우 중요한 과제로 부상하고 있다. 이에 본 논문에서는 긍정 리뷰의 텍스트를

정제하여 Koalpaca 모델을 파인튜닝하고 협찬물에 대한 긍정적 리뷰의 텍스트 생성 성능 평가 결과를 보였다.

분석 결과에서 본 논문에서 파인튜닝된 모델은 사전학습모델에 비해서 두 배 이상의 장문 텍스트를 생성하였으며, 긍정 리뷰의 텍스트 생성 비율도 두 배 정도 높음을 확인하였다, 또한 설문조사를 통해서 정성적 평가에서도 입력 키워드에 부합되는 협찬 텍스트가 생성된다는 평가가 우세함을 알 수 있었다. 따라서 소셜 미디어 플랫폼에서의 콘텐츠 및 사용자 수의 급증을 고려할 때, 본 모델의 개발은 마케팅과 콘텐츠 생성에 있어 중요한 의의를 가진다. 즉 기존의 블로거에게 의존하는 협찬 콘텐츠 마케팅 방식의 일부 부정적 측면을 개선할 수 있는 유효한 대안을 제시할 수 있다.

그러나 사전학습 모델의 부정 리뷰 텍스트 생성 요소를 감소시키기 위해서 학습데이터셋의 증강이나 보다 다양한 데이터의 확보가 필요함을 알 수 있었다. 또한 마케팅에의 실제적 활용성 평가를 위한 융합적 실험이 필요하므로 향후 연구로 추진하고자 한다.

References

Ahn, H. J. and Ha, Y. (2017). Analysis of the Relationship between the Type of Experience and Blog Texts. *The Journal of Korean Institute of Information Technology*, 15(2), 131-140.

Dettmers, T., Pagnoni, A., Holtzman, A. and Zettlemoyer, L. (2023). Qlora: Efficient Finetuning of Quantized LLMs, *arXiv preprint arXiv:2305.14314*.

Friedl, J. E. F. (2006). Mastering Regular Expressions. O'Reilly Media, the United States of America.

Goldberg, Y. and Levy, O. (2014). Word2vec Explained: Deriving Mikolov et al.'s Negative-Sampling Word-Embedding Method, *arXiv preprint arXiv:1402.3722*.

- Han, Y., Kim, H. and Lee, S. (2017). Experience Transfer in Social Media: Impact of Indirect Experience from Blog Posts, *Journal of Channel and Retailing*, 22(1), 39-50.
- Kang, H. and Cheon, H.J. (2020). Sponsorship Disclosures in Influencer Marketing: Focusing on Characteristics of Influencer, Viewing Satisfaction, and Attitudes toward Sponsorship, *Journal of Communication Research in Korea*, 19(3), 215-244.
- Kang, S.Y., Lee, Y.J., Jung, H.A., Cho, S.A. and Lee, H.G. (2024). An User-Friendly Kiosk System Based on Deep Learning, *Journal of Korea Society of Industrial Information Systems*, 29(1), 1-13.
- Kim, H. and Oh, Y. (2023). Design of a Mirror for Fragrance Recommendation Based on Personal Emotion Analysis, *Journal of Korea Society of Industrial Information Systems*, 28(4), 11-19.
- Kim, J. (2023). A Study on Fine-Tuning and Transfer Learning to Construct Binary Sentiment Classification Model in Korean Text, *Journal of Korea Society of Industrial Information Systems*, 28(5), 15-30.
- Kim, S., Shin, J.B., Yun, H.G., Lee, J., Cho, H.J., Choi, J. and Han, J.H. (2023). Technology Trends of Large Language Models in the Age of Generative AI, *Communications of the Korean Institute of Information Scientists and Engineers*, 41(11), 25-33.
- Ko, H., Yang, K., Ryu, M., Choi, T., Yang, S., Hyun, J., Park, S. and Park, K. (2023). A Technical Report for Polyglot-Ko: Open-Source Large-Scale Korean Language Models. *arXiv preprint arXiv:2306.02254*.
- KoAlpaca (2023). *GitHub Repository*. <https://github.com/Beomi/KoAlpaca> (Accessed on Jan. 10th, 2024).
- McInnes, L., Healy, J. and Melville, J. (2018). UMAP: Uniform Manifold Approximation and Projection for Dimension Reduction, *arXiv preprint arXiv:1802.03426*.
- Nah, F. F.-H., Zheng, R., Cai, J., Siau, K. and Chen, L. (2023). Generative AI and ChatGPT: Applications, Challenges, and AI-human Collaboration, *Journal of Information Technology Case and Application Research*, 25(3), 277-304.
- Oh, C., Kim, C. and Park, K. (2023). Building Robust Korean Speech Recognition Model by Fine-tuning Large Pretrained Model, *Phonetics and Speech Sciences*, 15(3), 75-82.
- OpenAI. (2021). *GPT-3.5 (Turbo) - API Documentation*, <https://platform.openai.com/docs/models/gpt-3-5> (Accessed on Jan. 10th, 2024)
- Rathore, B. (2023). Future of AI & Generation Alpha: ChatGPT Beyond Boundaries, *Eduzone: International Peer Reviewed/Refereed Multidisciplinary Journal*, 12(1), 63-68.
- S. Hochreiter and J. Schmidhuber. (1997). Long Short-Term Memory, *Neural Computation*, 9(8) 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Soh, H. (2012). Examining the Effects of Message Sidedness and Rewarded Consumer Referral in the Context of Blog Product Reviews, *Journal of Practical Research in Advertising and Public Relations*, 5(2), 112-143.
- Taori, R., Gulrajani, I., Zhang, T., Dubois, Y., Li, X., Guestrin, C., Liang, P. and Tatsunori, B. (2023). Stanford Alpaca: An Instruction-following LLaMA model, [howpublished = https://github.com/tatsu-lab/stanford_alpaca](https://github.com/tatsu-lab/stanford_alpaca)
- Touvron, H., Lavril, T., Izacard, G., Martinet, X., Lachaux, M. A., Lacroix, T., Rozière, B., Hambro, E., Azhar, F., Rodriguez, A., Grave, E. and Lample, G. (2023). Llama: Open and Efficient Foundation Language Models. *arXiv preprint arXiv: 2302.13971*.

Vasarhelyi, M. A., Moffitt, K. C., Stewart, T. and Sunderland, D. (2023). Large Language Models: An Emerging Technology in Accounting. *Journal of Emerging Technologies in Accounting*, 20(2), 1-10.

Yeu, M., Lee, D.H. and Jeong, J.E. (2020). How Sponsorship Type Affects the Review Adoption of Blog Reviews: Focusing on Moderating Effect of Self-Control. *Journal of Product Research*, 38(2), 63-70.



김 보 경 (Bo Kyeong Kim)

- 정회원
- (현재) 대구대학교 경영학부 경영학전공 학부생
- (현재) 대구대학교 AI학부 AI소프트웨어전공 학부생

• 관심분야: 생성 AI, 자연어 처리, 멀티모달 등



변 재 연 (Jae Yeon Byun)

- 정회원
- (현재) 대구대학교 경영대학 무역학과 학부생
- (현재) 대구대학교 AI학부 AI소프트웨어전공 학부생

• 관심분야: 생성 AI, 자연어 처리, 멀티모달 등



차 경 애 (Kyung-Ae Cha)

- 종신회원
- 경북대학교 컴퓨터과학과 학사
- 경북대학교 컴퓨터과학과 석사
- 경북대학교 컴퓨터과학과 박사
- (현재) 대구대학교 AI학과 교수

• 관심분야: 인공지능, 딥러닝, 생성 AI, 스마트 어플리케이션