creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

공학석사 학위논문

생성형 거대 언어 모델을 이용한 문서 수준 관계 추출 과제 해결

2023년 8월

서울대학교 대학원
공과대학 협동과정 인공지능전공
박 희 강

생성형 거대 언어 모델을 이용한 문서 수준 관계 추출 과제 해결

지도교수 서 봉 원

이 논문을 공학석사 학위논문으로 제출함
2023년 7월

서울대학교 대학원
공과대학 협동과정 인공지능전공
박 희 강

박희강의 석사 학위논문을 인준함
2023년 7월

위 원 장 곽 노 준 (인)

부위원장 서 봉 원 (인)

위 원 이 교 구 (인)

국문 초록

생성형 거대 언어 모델에 관한 여러 연구들은 생성형 거대 언어 모델이 자연어에 대한 이해를 넘어 상당한 '지식'을 가지고 있음을 시사한다. 이에 생성형 거대 언어 모델의 지식을 활용해 여러 추론 문제를 풀려고 하는 시도들이 계속되고 있다. 한편 문서 수준 관계 추출은 두 문장 이상으로 구성된 텍스트에서 두 개체 간의 관계를 찾아내는 과제로, 대규모 지식 그래프 구축에 있어 필수적인 과제이다.

본 학위논문에서는 생성형 거대 언어 모델을 이용해 '사전학습-프롬프트-예측' 패러다임으로 문서 수준 관계 추출 과제를 해결하는 방법을 연구하였다. 기반 모델로는 Meta에서 공개한 LLaMA-7B 모델을 사용하였다. 학습 데이터 셋으로는 문서 수준 관계 추출 학습/벤치마크 데이터 셋인 Re-DocRED를 사용하였다. 기반 모델은 Chain of Thought를 활용해 만들어진 입력 프롬프트-출력 기댓값 쌍들에 대해 지시사항 미세조정된다. 이때 LoRA를 활용해 효율적인 방식으로 학습을 진행했다.

제안한 방법의 성능을 확인하기 위해 다양한 실험을 수행하였다. 우선 Re-DocRED에 대한 F1 점수는 0.47로, '사전학습-미세조정' 패러다임에 기반한 기존 방법들에 비해 성능이 낮게 측정되었다. 하지만 모델이 실제로 생성한 다양한 정답/오답 사례들에서 데이터 셋의 한계와 평가 방법의 한계 등을 확인할 수 있었다. 또한 지시사항 미세조정과 Chain of Thought를 각각 사용했을 때와 사용하지 않았을 때의 모델 성능을 비교해, 두 방법이 모델 성능에 유의미한 기여를 하고 있음을 확인하였다. 특히 재현율만 높이는 방향으로 모델을 미세조정할 경우, 재현율 0.73을 달성하는 것을 확인할 수 있었다.

주요어 : 생성형 거대 언어 모델, 문서 수준 관계 추출, 지시사항 미세조정, Chain of Thought, LoRA
학 번 : 2021-22918

목 차

제 1 장 서론 ····· 1
제 1 절 연구의 배경 ····· 1
제 2 절 연구의 필요성 및 목표 ····· 9
제 3 절 문서의 구성 ····· 9
제 2 장 관련 연구 ····· 11
제 1 절 언어 모델 ····· 11
제 2 절 거대 언어 모델 ····· 12
제 3 절 문서 수준 관계 추출 ····· 15
제 3 장 제안 방법 ····· 17
제 1 절 개요 ····· 17
제 2 절 목표 데이터 셋 : Re-DocRED ····· 17
제 3 절 기반 거대 언어 모델 : LLaMA ····· 21
제 4 절 모델 학습 ····· 22
제 5 절 모델 추론 ····· 32
제 4 장 실험 및 결과 ····· 34
제 1 절 실험 설계 ····· 34
제 2 절 실험 결과 및 분석 ····· 37
제 5 장 결론 ····· 51
제 1 절 연구 요약 ····· 51
제 2 절 논의점 ····· 52

제 3 절 연구의 한계 및 향후 연구 방향 ····· 54

참 고 문 헌 ····· 56

부록 1. Re-DocRED의 관계 종류 ····· 68

부록 2. 지도학습 미세조정을 위한 입력 프롬프트-출력 기댓값 예시 81

표 목차

표 1 거대 언어 모델 ····· 13

표 2 주요 문서 수준 관계 추출 데이터 셋 ····· 15

표 3 Re-DocRED 각 스플릿 별 통계량 ····· 18

표 4 LLaMA 각 버전 별 하이퍼파라미터 ····· 21

표 5 LLaMA 사전학습 말뭉치 내 말뭉치 비율 ····· 21

표 6 각 LLaMA 버전 별 다양한 추론 문제에 대한 성능 ····· 22

표 7 실험 1 결과 : 모델 성능 ····· 37

표 8 실험 2 결과 : 지시사항 미세조정의 효과 ····· 47

표 9 실험 3 결과 : Chain of Thought의 효과 ····· 48

표 10 실험 4 결과 : 적절한 no_rel_rate 값 탐색 ····· 48

표 11 실험 5 결과 : 재현율만 높인 모델 ····· 49

그림 목차

그림 1 사전학습-미세조정 패러다임 ····· 2

그림 2 사전학습-프롬프트-예측 패러다임 ····· 6

그림 3 지식 그래프 ····· 6

그림 4 관계 추출 ····· 8

그림 5 문서 수준 관계 추출 ····· 9

그림 6 모델 학습 방법 ····· 17

그림 7 모델 추론 방법 ····· 17

그림 8 영화 댓글 긍/부정 감성 분석 과제를 위한 입력 프롬프트-출력 기댓값 쌍 예시 ····· 24

그림 9 Chain of Thought 예시 ····· 25

그림 10 Re-DocRED를 위한 입력 프롬프트 구조 ····· 27

그림 11 Re-DocRED를 위한 출력 기댓값 구조 ····· 29

그림 12 LoRA ····· 31

그림 13 정규 표현식 ····· 33

그림 14 실험 2를 위한 입력 프롬프트 구조 ····· 34

그림 15 정답 사례 1 ····· 38

그림 16 정답 사례 2 ····· 39

그림 17 오답 사례 1 ····· 43

그림 18 오답 사례 2 ····· 43

그림 19 오답 사례 3 ····· 45

수식 목차

수식 1 정밀도(Precision), 재현율(Recall), F1 점수(F1 Score) ·· 20

수식 2 causal language modelling을 위한 손실 함수 ····· 25

제 1 장 서론

제 1 절 연구의 배경

트랜스포머(transformer)〔1〕 모델 이전에 자연어 처리 과제를 푸는 방법은 일반적으로 다음과 같았다. 우선 해당 과제에 대한 레이블링(labeling)된 데이터 셋을 수집/정제한다. 둘째로, 해당 과제에 맞게 적절히 설계된 모델을 만든다. 각 토큰(token)의 순서 정보가 중요한 자연어의 특성 상, 주로 RNN(Recurrent Neural Network) 기반 모델들을 사용한다. 마지막으로, 적절한 손실 함수(loss function)을 이용해 모델을 학습시킨다. 즉 매 과제마다 새로운 모델을 바닥부터 학습시키는 방식을 사용했다.

하지만 트랜스포머 모델의 등장은 자연어 처리의 패러다임을 크게 바꿨다. 어텐션(attention) 연산과 전방향 신경망(feed-forward network)만으로 구현된 트랜스포머 모델은 기존 모델 대비 병렬화가 쉬워, 더 큰, 더 깊은 모델을, 더 큰 데이터 셋에 대해 학습시킬 수 있다. 이로 인해, 하나의 커다란 트랜스포머 언어 모델을 대규모 말뭉치(corpus)에 대해 비지도학습(unsupervised learning) 방식으로 학습시키고[1], 이렇게 만들어진 사전학습 언어 모델(Pretrained Language Model, PLM)을 기반

1) 레이블링하지 않은 데이터를 이용해 학습한다는 관점에서 비지도학습이라 표현했지만, 클러스터링 등의 일반적인 비지도학습 알고리즘을 사용하는 것은 아니다. 사전학습 언어 모델의 사전 학습은 다음 토큰(causal language modeling) 또는 마스킹된 토큰(masked language modeling)을 예측하는 방식으로 이루어지는데, 이는 말하자면 레이블이 없는 데이터 셋(말뭉치)에서 레이블(다음 토큰 또는 마스킹된 토큰)을 직접 만들고 이를 예측하는, 일종의 지도학습 방식으로 이루어진다. 이와 같은 사전학습 언어 모델의 사전학습 방법을, 명시적인 레이블을 직접 제공하는 전통적인 사전학습과 구분하기 위해 반지도학습(semi-supervised learning)이라 부르기도 한다.

모델(foundation model) 삼아 여러 과제에 맞게 각각 미세조정(fine-tuning)해 사용하는, 이른바 "사전학습-미세조정 패러다임(pretrain-finetune paradigm)"[2]이 제안되었다.

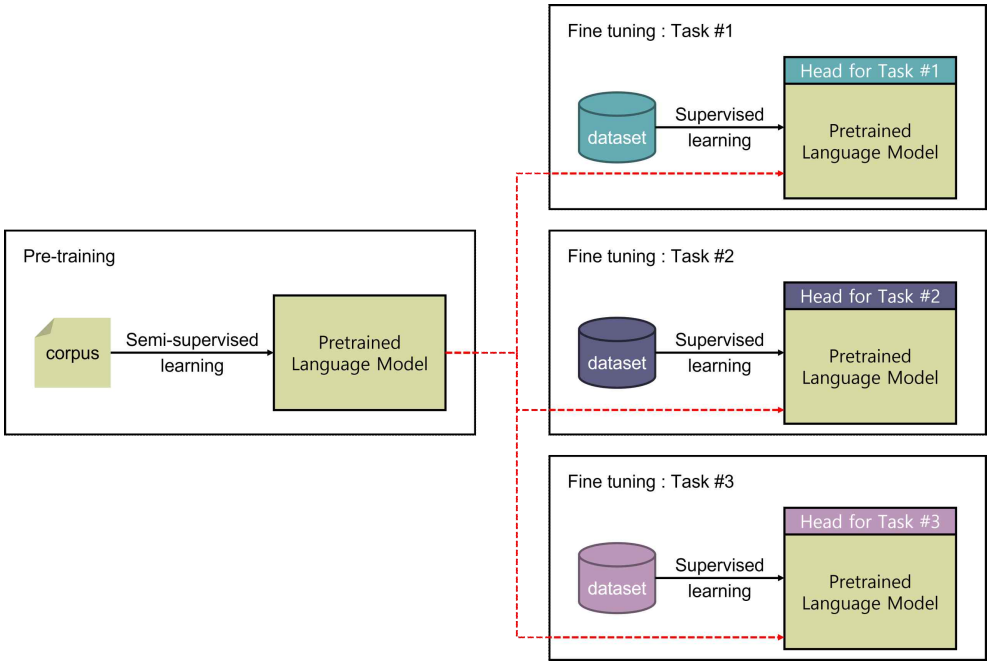

그림 1 사전학습-미세조정 패러다임

사전학습-미세조정 패러다임에서는 위 그림과 같이 하나의 커다란 트랜스포머 언어 모델을 대규모 말뭉치(corpus)에 대해 반지도학습(semi-supervised learning) 방식으로 학습시키고, 이렇게 만들어진 사전학습 언어 모델(Pretrained Language Model, PLM, 그림의 녹색 사각형)을 기반 모델(foundation model) 삼아 여러 과제에 맞게 각각 미세조정(fine-tuning)해 사용한다.

사전학습-미세조정 패러다임 하에서는 이제 더 이상 각 과제를 풀기 위해 매번 새로운 모델을 바닥부터 학습시킬 필요가 없다. 사전학습 언어 모델을 과제에 맞게 적당히 변형하고 미세조정만 거치면 과제를 풀 수 있다. 예를 들어 한국어 댓글들에 대한 긍/부정 감성 분석(sentiment analysis) 과제를 진행한다고 해 보자. 가장 먼저 해당 과제에 대한 레이블링 된

데이터 셋을 수집/정제한다. 이때 우린 이미 자연어에 대한 상당한 이해를 하고 있는 사전학습 언어 모델을 기반 모델로 사용하기 때문에, 과제에 맞는 개별 모델을 바닥부터 직접 지도학습할 때 대비 데이터 셋의 크기가 상당히 작아도 된다. 둘째로, 해당 과제와 관련된 말뭉치에 대해 사전학습된 적절한 사전학습 언어 모델을 선택한다. 사전학습 언어 모델은 학습 방법에 따라 masked 언어 모델(Masked Language Model, MLM)[2], causal 언어 모델(Causal Language Model, CLM)[3], 조건부 언어 모델(Conditional Language Model)[4], 이렇게 크게 세 가지로 분류할 수 있는데, 이 중 자연어 이해 관련 과제에서 좋은 성능을 보이는 BERT〔3〕와 같은 masked 언어 모델을 한국어 댓글/구어체 말뭉치 등에 대해 사전학습시킨 사전학습 언어 모델을 선택하는 것이 적절하다. 셋째로, 과제를 풀 수 있도록 사전학습 언어 모델의 구조를 약간 변경한다. 일반적으로는 사전학습 언어 모델 위에 추가적인 레이어를 몇 층 쌓는 수준의 변경을 수행한다. 한국어 댓글들에 대한 긍/부정 감성 분석 과제에서는 각 문장 앞 〔CLS〕 토큰에 대한 임베딩 벡터(embedding vector)를 입력으로 받아 0(부정), 1(긍정)로 분류하는 한 층짜리 FC(fully-connected) 레

---

2) Masked 언어 모델은 말뭉치를 양방향(bi-directional)으로 읽으며 가려진(masked) 토큰을 예측하는 방식으로 학습된 모델로, 주로 자연어 이해와 관련된 분야에서 좋은 성능을 낸다. Masked 언어 모델의 예로는 BERT〔3〕, RoBERT〔4〕, ELECTRA〔5〕, ALBERT〔6〕 등이 있다.

3) Causal 언어 모델은 말뭉치를 단방향(uni-directional)으로 읽으며 다음 토큰을 예측하는 방식으로 학습된 모델로, 주로 자연어 생성과 관련된 분야에서 좋은 성능을 낸다. Causal 언어 모델의 예로는 GPT-1〔7〕, GPT-2〔8〕, GPT-3〔9〕 등이 있다.

4) 조건부 언어 모델은 입력 시퀀스에 따라 출력 시퀀스를 생성해야 하는 번역, 요약 등과 같은 과제에 사용하기 위해, 입력 시퀀스의 이해를 위해 masked 언어 모델을, 출력 시퀀스의 생성을 위해 causal 언어 모델을 사용하는 모델이다. 조건부 언어 모델의 예로는 UniLM〔10〕, UniLMv2〔11〕, BART〔12〕, XLNet〔13〕, T5〔14〕 등이 있다.

이어를 쌓는다. 마지막으로, 적절한 손실 함수를 이용해 학습을 진행한다. 한국어 댓글들에 대한 긍/부정 감성 분석 과제에서는 이진 크로스-엔트로피(Binary Cross-Entropy, BCE) 손실 함수를 사용해 학습을 진행한다. 이때 학습 과정에서 사전학습 언어 모델의 매개변수는 상황에 따라 고정시켜(freeze) 놓을 수도 있고 같이 업데이트할 수도 있다.

사전학습-미세조정 패러다임 하에서 과제에 대해 좋은 성능을 내기 위해서는 과제에 맞는 적절한 손실 함수를 선택하는 것과 더불어 기반 모델로 사용되는 사전학습 언어 모델로 성능 좋은 모델을 선택해 사용하는 것이 중요하다. 사전학습 언어 모델의 성능이 좋을수록 자연어에 대한 이해가 더 깊은 언어 모델이라는 뜻이고, 자연히 각 과제에 맞게 미세조정했을 때의 성능도 더 좋아지기 때문이다. 다양한 연구들은 더 큰, 더 깊은, 더 큰 데이터 셋에 대해 학습된 사전학습 언어 모델일수록 성능이 좋다는 것을 실험적으로 보여주었다〔3〕〔15〕. 이에 사전학습 언어 모델의 크기를 키우려는 연구가 지속적으로 수행되었다. 예를 들어 2020년 공개된 OpenAI의 GPT-3〔9〕의 경우 1,730억 개의 매개변수를 가지고 있는데, 인간 뇌의 뉴런이 약 860억 개인 것을 생각해 보면〔16〕 엄청나게 큰 모델임을 알 수 있다. 말하자면 거대 언어 모델(Large Language Model, LLM)의 시대가 열린 것이다.

이때 거대 언어 모델은 재미있는 성질을 가지고 있음이 알려졌는데, 바로 in-context learning이 가능하다는 것이다〔9〕. In-context learning이란 기존의 사전학습-미세조정 패러다임과는 다르게 모델 구조 변경이나 추가 학습 과정 없이 거대 모델 모델에게 과제에 대한 설명과 몇 가지 예시만 프롬프트(prompt)로 입력하고 과제를 풀도록 만드는 것이다. 즉 In-context learning을 이용하면 few-shot learning, 심지어 zero-shot learning까지 가능한 것이다.[5] 연구진에 의하면 과제가 간단할수록

5) few-shot learning이란 전체 데이터가 아닌 몇 개의 데이터만 주고도 모델이 과제를 수행할 수 있도록 만드는 것을 말한다. zero-shot learning이란

더 적은 예시만으로도 in-context learning을 수행할 수 있다. 또한 모델의 크기가 클수록, 더 많은 수의 예시를 프롬프트에 넣어 줄수록 in-context learning의 성능이 높아진다고 한다.

거대 언어 모델에서 in-context learning이 가능하다는 것은 거대 언어 모델이 상당한 '지식'을 가지고 있음을 시사한다.[6] 그 결과 "사전학습-프롬프트-예측 패러다임(pretrain-prompt-predict paradigm)"[2]이라 불리는 새로운 패러다임이 제안되었다. 이전의 사전학습-미세조정 패러다임에서는 사전학습된 언어 모델이 자연어에 대해 상당한 이해를 하고 있다고 전제하고, 이 자연어에 대한 이해를 바탕으로 각 과제에 맞게 모델 구조를 약간 변형해 만든 모델로 과제를 풀었다. 하지만 사전학습-프롬프트-예측 패러다임에서는 거대 언어 모델이 대규모 말뭉치를 학습하는 과정에서 자연어에 대한 이해에서 한 걸음 더 나아가 상당량의 '지식'을 얻었다고 전제한다. 그래서 각 과제를 풀 때 모델의 구조는 전혀 건드리지 않고(zero-shot learning 등을 위해 아주 약간만 미세조정하고), 모델에 저장된 '지식'을 잘 끌어내는 적절한 프롬프트를 탐색/생성하는, 소위 프롬프트 엔지니어링(prompt engineering)을 수행하여 과제를 푼다. 기존의 사전학습-미세조정 패러다임 대비 사전학습-프롬프트-예측 패러다임은 많은 장점이 있기에, 많은 연구자들은 프롬프트 엔지니어링을 깊게 연구하고 있다[17]. 몇몇 급진적인 연구자들은 거대 언어 모델이 단순히 '지식'을 가지고 있을 뿐만 아니라 상황에 맞춰 합리적인 '판단'까지 가능한 수준의 지성을 가지고 있다고 믿고, 거대 언어 모델을 복잡한 작업을

아무런 데이터를 주지 않고도 모델이 바로 과제를 수행할 수 있도록 만드는 것을 말한다.

6) 몇몇 연구자들은 거대 언어 모델에서의 in-context learning이 가능한 것은 거대 언어 모델이 지식을 진정으로 이해해서가 아니라 사용자의 요청에 따라 학습 과정에서 보았던 지식을 그저 나열하는(retrieve) 것 뿐이라 해석한다. 어느 쪽이 더 맞는지는 아직 명확하게 단정 지을 수 없지만, 본 연구는 거대 언어 모델이 진정으로 지식을 이해한 것이라는 관점에서 진행되었다.

통제하는 에이전트로 사용하는 연구를 진행하기도 했다[18].

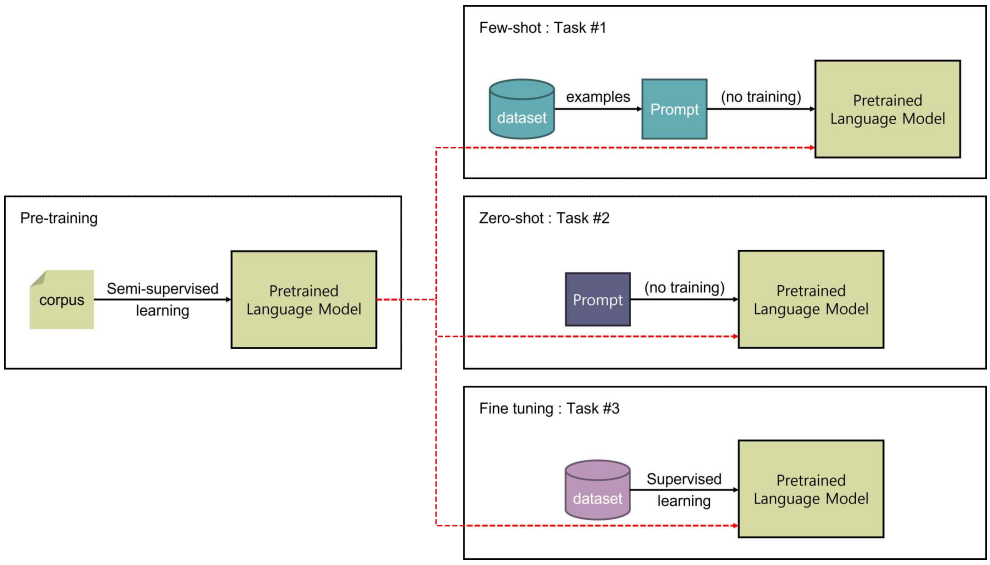

그림 2 사전학습-프롬프트-예측 패러다임

사전학습-프롬프트-예측 패러다임에서는 사전학습된 거대 언어 모델(Large Language Model, LLM, 그림의 녹색 사각형)이 대규모 말뭉치를 학습하는 과정에서 상당량의 '지식'을 얻었다고 전제하고, 각 과제를 풀 때 모델을 건드리지 않고(또는 아주 약간만 미세조정하고) 모델에 저장된 '지식'을 잘 끌어내는 적절한 프롬프트를 탐색/생성하는 프롬프트 엔지니어링(prompt engineering)을 수행하여 과제를 푼다.

한편, 지식 그래프(Knowledge Graph, KG)란 현실 세계의 지식을 축적하고 전달하기 위한 목적으로, 개체(entity)들을 노드(node)로, 개체 쌍 간의 관계를 간선(edge)으로 하여 나타낸, 간선 레이블링된 유향 그래프(directed edge-labelled graph)이다[19]. 그림 3은 지식 그래프의 예를 보여주고 있다. 지식 그래프를 이용하면 지식을 효율적으로 저장하고 자동화된 방식으로 탐색할 수 있다. 오늘날 지식 그래프는 웹 검색([20], [21]), 비즈니스([22], [23], [24]) 등 다양한 분야에서 적극적으로 사용되고 있다.

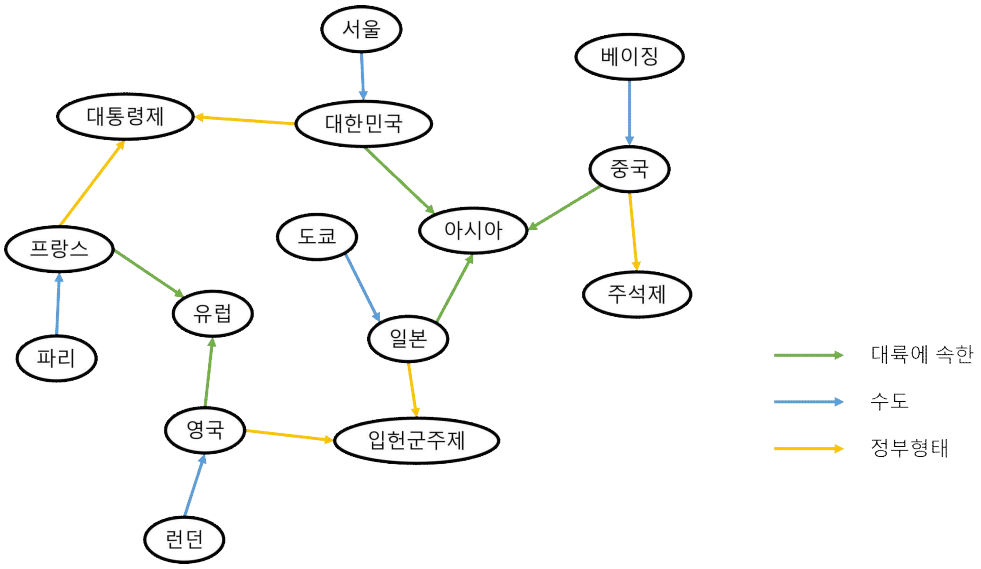

그림 3 지식 그래프

지식 그래프(Knowledge Graph, KG)란 현실 세계의 지식을 축적하고 전달하기 위한 목적으로, 개체(entity)들을 노드(node)로, 개체 쌍 간의 관계를 간선(edge)으로 하여 나타낸, 간선 레이블링된 유향 그래프(directed edge-labeled graph)이다.

지식 그래프는 그 크기가 클수록 더 많은 일을 할 수 있다. 이때 인간의 지식의 상당수가 텍스트 형태로 저장되어 있기 때문에, 관계 추출(Relation Extraction, ER) 과제의 중요성이 커졌다. 관계 추출이란 텍스트가 주어졌을 때, 텍스트 속 두 개체 사이의 관계(relationship)를 추출해 내는 것을 말한다.[7] 예를 들어, "서울은 대한민국의 수도이다."라는 텍스트

7) 관계 추출을 하려면 관계 추출의 대상이 되는 개체들을 탐색하는 과정이 선행되어야 한다. 주어진 텍스트로부터 (관계 추출을 수행할) 개체들을 탐색하는 과제를 개체 이름 인식(Named Entity Recognition, NER) 과제라 한다. 연구자에 따라 개체 이름 인식 과제를 관계 추출 과제의 일부라 보는 사람도 있고, 독립적인 과제라 보는 사람도 있다. 본 연구에서 사용한 목표 데이터 셋 Re-DocRED은 개체 이름 인식 과제와 관계 추출 과제가 독립적인 과제라 보는 관점에서 만들어진 데이터셋으로, 이미 문서 내 개체들을 모두 추출하여 제공하고 있다.

에서 ("서울", "대한민국", "수도")와 같은 관계 트리플렛(relation triplet)을 뽑아내는 것이다. 관계 추출을 사용하면 대규모 지식 그래프를 쉽게 만들어 낼 수 있다.

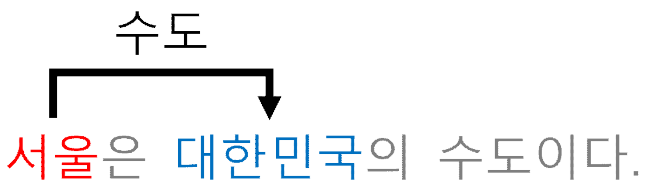

그림 4 관계 추출

관계 추출(Relation Extraction, RE)이란 텍스트가 주어졌을 때, 텍스트 속 두 개체 사이의 관계(relationship)를 추출해 내는 것을 말한다.

관계 추출은 주어진 텍스트의 종류에 따라 문장 수준 관계 추출(Sentence-level Relation Extraction)과 문서 수준 관계 추출(Document-level Relation Extraction, DocRE)로 구분할 수 있다. 문장 수준 관계 추출은 이름 그대로 텍스트로 하나의 문장이 주어진 경우이다. 문장 수준 관계 추출 과제를 위해서는 주어진 문장을 잘 이해하고, 그 안에서 관계 트리플렛을 뽑아 내면 된다. 한편 문서 수준 관계 추출은 텍스트로 둘 이상의 문장이 주어진 경우이다. 문서 수준 관계 추출에선 문장 수준 관계 추출에서와 다르게 두 개체 간의 관계가 여러 문장에 걸쳐 나타나 있을 수도 있다. 예를 들어 "대한민국의 수도는 서울이다. 철수는 대한민국의 수도에서 태어났다."와 같은 텍스트에서, 두 문장 사이에 걸쳐 있는 ("철수", "서울", "고향") 관계를 추출하는 것이다. 따라서 문서 수준 관계 추출 과제를 위해서는 단순히 문장 하나가 아니라 전체 문서를 통합적으로 이해하고, 그 안에서 관계 트리플렛을 뽑아낼 수 있어야 한다. 또 인류가 이때까지 축적한 지식들의 대부분은 한 문장이 아닌 문서의 형태로 저장되어 있다. 그래서 문장 수준 관계 추출이 문서 수준 관계 추출보다 더 어렵고, 더 중요한 과제로 평가된다.

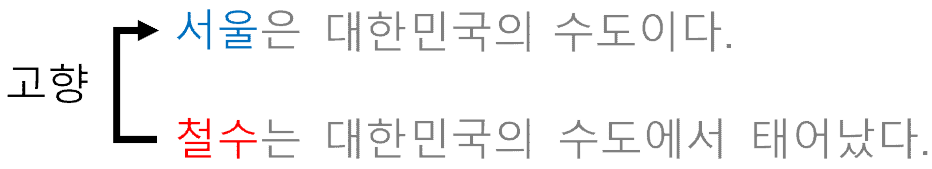

그림 5 문서 수준 관계 추출

문서 수준 관계 추출(Document-level Relation Extraction, DocRE)은 텍스트로 둘 이상의 문장이 주어졌을 때, 텍스트 속 두 개체 사이의 관계를 추출해 내는 것을 말한다.

제 2 절 연구의 필요성 및 목표

causal 언어 모델은 일반적으로 자연어 이해 과제에서 좋은 성능이 나오지 못했다. 하지만 최근의 연구들은 적절한 프롬프트를 사용하면 causal 언어 모델도 자연어 이해 과제를 할 수 있다는 것을 보여주고 있다[9][25][26][27]. 한편 문서 수준 관계 추출 과제는 주로 사전학습-미세조정 패러다임 하에서 masked 언어 모델을 기반 모델로 하여 분류 문제를 푸는 방식으로 접근되었다[28][29].

이에 본 연구는 causal 언어 모델을 이용해 사전학습-프롬프트-예측 패러다임으로 문서 수준 관계 추출 과제를 푸는 방법을 제시하는 것을 목표로 한다. 구체적으로, Tan 등이 구축한 Re-DocRED[30] 데이터 셋에 대해 Facebook/Meta가 공개한 causal 언어 모델 LLaMA[31]를 이용해 생성적(generative) 방식으로 과제를 푸는 방법을 제시하는 것을 목표로 한다. 제안한 방법의 유효성을 확인하기 위해, 해당 방법으로 만든 모델의 성능과, 각 방법을 구성하는 요소들을 사용했을 때와 사용하지 않았을 때의 성능 차이 등을 비교한다.

제 3 절 문서의 구성

본 문서는 총 5개의 장으로 구성되어 있다. 첫 번째 장인 서론 장에서는 연구의 배경, 연구의 필요성 및 목표, 그리고 본 문서의 구성을 정리하였다. 두 번째 장인 관련 연구 장에서는 본 연구와 관련된 연구들을 언어 모델, 거대 언어 모델, 문서 수준 관계 추출, 이렇게 3개의 절로 나눠 정리하였다. 세 번째 장인 제안 방법 장에서는 본 논문에서 제안하는, 거대 언어 모델을 이용해 문서 수준 관계 추출 과제를 푸는 모델을 학습/추론 방법을 설명한다. 네 번째 장인 실험 및 결과 장에서는 제안한 방법의 성능 및 유효성을 확인하기 위한 여러 가지 실험들을 설계하고, 그 결과 및 해석을 서술하였다. 마지막 장인 결론 장에서는 전체 연구 내용을 요약하고, 논의사항들을 서술한 후, 연구의 한계점 및 향후 연구 방향 등을 서술한다.

제 2 장 관련 연구

본 장에서는 본 연구와 관련된 연구들을 언어 모델, 거대 언어 모델, 문서 수준 관계 추출, 이렇게 3개의 절로 나누어 정리하였다.

제 1 절 언어 모델

언어 모델(language model)이란 언어의 확률 분포를 나타낸 모델을 뜻한다. 초창기의 언어 모델은 Markov 가정에 근거해 이전 단어 군이 등장했을 때 다음 단어의 등장 빈도를 세는 방식으로 만들어졌다[56][57][58][59]. 이런 방식으로 만들어진 언어 모델을 확률 언어 모델(Statistical Language Model, SLM)이라 부른다. 확률 언어 모델은 정보 추출(information retrieval)[60], POS(part of speech) 태깅[61], 음성 인식[62], 기계번역[63] 등의 다양한 자연어 처리 분야에 응용되었다. 하지만 확률 기반 언어 모델은 희소 문제(중요한 단어이지만 등장 횟수가 적다면 적절한 확률 분포를 계산할 수 없다) 등의 한계가 있었다.

이후 RNN을 기반으로 한 신경망 언어 모델(Neural Language Model, NLM)이 등장하였다. 신경망 언어 모델은 주변 단어가 비슷한 단어는 의미가 비슷할 것이라는 분포 가설(distributional hypothesis)에 근거해, RNN 등의 신경망 모델을 이용해 주변 단어로부터 각 단어에 대한 분산 표현(distribution representation)을 학습하는 방식으로 동작한다[64][65]. 얕은 신경망을 이용해 구현된 Word2Vec은 언어 모델링 과제뿐만 아니라 다양한 자연어 처리 분야에서 좋은 성능을 보였다[66][67]. Word2Vec의 성공은 언어 모델을 기반 모델로 사용해 다양한 자연어 처리 분야를 푸는 사전학습-미세조정 패러다임을 여는 시발점이 되었다. ELMo는 말뭉치에 대해 사전학습하여 주변 문맥으로부터 적절한 단어 표현(word representation)을 학습한 양방향 LSTM(biLSTM)을 각 세부

과제(downstream task)에 대해 미세조정해 사용하는 방법을 제안했다〔68〕.

기존 RNN 대비 병렬처리가 가능해 더 깊은 모델을 쌓아 대규모 말뭉치에 대해 대규모 사전학습을 수행할 수 있는 트랜스포머〔1〕 모델의 등장은 언어 모델을 한 단계 더 진화시켰다. 트랜스포머 모델의 인코더 부분만을 가져온 BERT〔30〕, 디코더 부분만을 가져온 GPT〔7〕는 각각 자연어 이해 분야(Natural Language Understanding, NLU)와 자연어 생성 분야(Natural Language Generation, NLG) 분야에서 좋은 성능을 보였다. 이후 더 좋은 성능의, 더 경량화된 masked 언어 모델〔4〕〔5〕〔6〕, causal 언어 모델〔8〕〔9〕, 조건부 언어 모델〔10〕〔11〕〔12〕〔13〕〔14〕 등이 제안되었다.[8)]

제 2 절 거대 언어 모델

OpenAI가 1,730억 개의 매개변수를 가진 GPT-3〔9〕를 공개한 이후로, 다양한 기업들이 다양한 방식으로 거대 causal 언어 모델을 만들어 공개했다. NVidia는 830억 개의 매개변수를 가진 Megatron-LM〔42〕을 만들었다. Microsoft는 172억 개의 매개변수를 가진 T-NLG〔32〕, 5,300억 개의 매개변수를 가진 MT-NLG〔33〕 등을 만들었다. Eluther AI는 27억 개의 매개변수를 가진 GPT-Neo〔34〕, 60억 개의 매개변수를 가진 GPT-J〔35〕, 200억 개의 매개변수를 가진 GPT-NeoX〔36〕 등을 만들고 공개했다. Facebook/Meta는 660억 개의 매개변수를 가진 OPT

8) 전통적인 언어 모델은 “이전 단어 군으로부터 다음 단어를 예측하는 형태의 모델”이었기에, 엄밀히 말하면 causal 언어 모델만이 언어 모델로 불릴 수 있을 것이다. 하지만 오늘날에는 언어 모델의 의미가 확장되어 “주변 단어 군으로부터 특정 단어를 예측하는 형태의 모델”이라는 의미로 사용된다. 확장된 언어 모델의 정의에 따르면 masked 언어 모델과 조건부 언어 모델 모두 언어 모델이라 부를 수 있을 것이다.

〔37〕, 650억 개의 매개변수를 가진 LLaMA〔31〕 등을 만들고 공개했다. BigScience는 1,760억 개의 매개변수를 가진 BLOOM〔38〕을 만들고 공개했다. Google은 1,370억 개의 매개변수를 가진 LaMDA〔39〕, 6,500억 개의 매개변수를 가진 PaLM〔40〕, 3,400억 개의 매개변수를 가진 PaLM2〔41〕 등을 만들었다.

이름	연구자	연도	매개변수 수
GPT-1〔7〕	Radford 등	2018	110M
GPT-2〔8〕	OpenAI	2019	1.5B
Megatron-LM〔42〕	NVidia	2019	8.3B
T-NLG〔32〕	Microsoft	2020	17.2B
GPT-3〔9〕	OpenAI	2020	175B
GPT-Neo〔34〕	EleutherAI	2021	2.7B
GPT-J〔35〕	EleutherAI	2021	6B
MT-NLG〔33〕	Microsft	2022	530B
GPT-NeoX〔36〕	EleutherAI	2022	20B
OPT〔37〕	Facebook	2022	66B
BLOOM〔38〕	BigScience	2022	176B
LaMDA〔39〕	Google	2022	137B
PaLM〔40〕	Google	2022	650B
LLaMA〔31〕	Meta AI	2023	65B
PaLM2〔41〕	Google	2023	340B

표 1 거대 언어 모델

거대 언어 모델이 할 수 있는 일들을 탐색하는 연구도 여럿 진행되었다. Brown 등은 충분히 큰 causal 언어 모델은 자연어 생성 과제를 넘어 자

연어 이해 과제도 풀 수 있음을 보였다[9]. Liu 등은 p-tuning이라는 방법을 제시하면서 causal 언어 모델의 자연어 이해 과제에서의 성능을 크게 높였다[25]. Lester 등은 prompt tuning이라는 방법을 제시하면서 사전학습-프롬프트-예측 패러다임이 모델을 직접 수정하던 사전학습-미세조정 패러다임만큼의 성능이 나올 수 있음을 보였다[26]. Wei 등은 거대 언어 모델에서 효과적으로 지식을 끌어낼 수 있는 Chain of Thought(CoT)라는 프롬프트 생성 방법을 제시하였다[27].

특정 과제에 맞춰 거대 언어 모델의 성능을 높이거나 zero-shot 성능을 높이는 연구도 다수 진행되었다. Wei는 언어 모델의 zero-shot 성능을 올릴 수 있는 지시사항 미세조정(instruction tuning)이라는 방법을 제안했다[43]. Christiano, Stiennon 등은 인간의 피드백을 보상(reward)으로 하는 강화학습을 이용해 언어 모델이 더 유용한 답변을 생성하도록 하는 RLHF(Reinforcement Learning with Human Feedback) 방법론을 제안했다[44][45]. Ouyang 등은 GPT-3을 RLHF 방식으로 미세조정해 만든 InstructGPT가 성능이 더 좋아짐을 보였다[46].

한편 거대 언어 모델의 크기가 계속해서 커짐에 따라 모델을 학습하고 사용하는 비용이 점점 커지고 있다. 그래서 더 적은 자원으로 더 큰 모델을 학습하는 방법들이 꾸준하게 제안됐다. Rajbhandari, Ren 등은 거대 언어 모델을 학습/사용할 때 GPU 메모리를 효율적인 방법으로 사용하는 ZeRO[47], ZeRO-Offload[48], ZeRO-Infinity[49] 등의 방법을 제안했다. Microsoft는 심층 신경망을 효율적으로 학습/사용할 수 있는 최적화 라이브러리 DeepSpeed를 공개했다[50]. Hu 등은 거대 언어 모델을 미세조정할 때 전체 모델이 아니라 소수의 추가 레이어만 학습하는 LoRA라는 방법론을 제안했다[51]. Huggingface는 LoRA 등 거대 언어 모델을 매개변수-효율적인(parameter-efficient) 방법으로 미세조정하는 peft라는 라이브러리를 공개했다[52].

제 3 절 문서 수준 관계 추출

주요 문서 수준 관계 추출 데이터 셋에는 다음과 같은 것들이 있다. Quirk 등은 distant supervision[9)]으로 구축한 DISCREX라는 데이터 셋을 공개했다[53]. Li 등은 사람이 직접 레이블링한, PubMed에서 추출한 1,500개의 문서로 이루어진 BC5CDR이라는 데이터셋을 구축하고 공개했다[54]. Yao 등은 사람이 직접 레이블링한, Wikipedia에서 추출한 5,000여 개의 문서로 이루어진 DocRED라는 데이터 셋을 구축하고 공개했다[55]. Tan 등은 DocRED 데이터 셋에서 false negative 샘플이 많다는 사실을 지적하고, 추가 레이블링을 진행하여 Re-DocRED라는 데이터 셋을 구축하고 공개했다[30]. 표 2는 주요 문서 수준 관계 추출 데이터 셋을 정리한 것이다.

문서 수준 관계 추출 과제는 일반적으로 분류(classification) 과제로 인식되었다. 기존 연구들은 사전학습-미세조정 패러다임 하에서, 문서에서 추출하고자 하는 관계의 종류들을 레이블로 BERT, RoBERTa 등과 같은 masked 언어 모델을 이용해 주어진 개체 쌍이 어떤 레이블(관계)에 해당하는지를 분류하는 방식으로 진행되었다. Yao 등은 DocRED 데이터 셋에 대해 Bi-LSTM을 사용하는 모델을 제안하였다[55]. Tan 등은 adaptive focal loss와 지식 추출(knowledge distillation) 기법을 사용하는 BERT 기반 모델을 제안하였다[29]. Ma 등은 근거 문장(evidence)을 이용해 어텐션을 정렬하는 RoBERTa 기반 모델 DREEAM을 제안하였다[28].

9) 외부 지식 저장소(Knowledge Base, KB)를 이용해, 텍스트 속 두 개체가 관계가 '있다'고 나오면 해당 관계를 해당 텍스트에서 뽑은 두 개체의 관계라 추정하는 방법

데이터 셋	연구자	연도	문서 수
BC5CDR[54]	Li 등	2016	1,500
DISCREX[53]	Quirk 등	2017	10,000
DocRED[55]	Yao 등	2019	5,053
Re-DocRED[30]	Tan 등	2022	4,053

데이터 셋	관계 종류 수	관계 쌍 수	원본 데이터
BC5CDR[54]	1	3,116	PubMed
DISCREX[53]	1	64,000	PubMed
DocRED[55]	96	63,427	Wikipedia
Re-DocRED[30]	96	50,503	Wikipedia (DocRED)

데이터 셋	특징
BC5CDR[54]	human annotation 방식 chemical-disease 관계만 고려
DISCREX[53]	distant supervision 방식 drug-gene 관계만 고려
DocRED[55]	human annotation 방식 general domain 데이터 셋
Re-DocRED[30]	human annotation 방식 general domain 데이터 셋 DocRED 데이터 셋 개선

표 2 주요 문서 수준 관계 추출 데이터 셋

제 3 장 제안 방법

제 1 절 개요

본 연구에서는 사전학습-프롬프트-예측 패러다임에 기반해 거대 언어 모델을 지시사항 미세조정하여 문서 수준 관계 추출 과제를 해결하는 방법을 제시한다. 본 장에서는 해당 방법에 대한 설명과 학습/사용 방법을 서술한다. 제 1절에서는 학습/사용 방법에 대한 개요를 서술한다. 제 2절에서는 본 연구에서 사용한 목표 데이터 셋 Re-DocRED에 대한 설명을 서술한다. 제 3절에서는 본 연구에서 사용한 거대 언어 모델 LLaMA에 대한 설명을 서술한다. 제 4절에서는 학습 방법 및 학습 상세를, 제 5절에서는 모델 추론 방법 및 사용 상세를 설명한다.

모델 학습 그림 6은 본 연구에서 제안하는 모델 학습 방법을 보여준다. 학습은 2단계로 이루어진다. 우선 Re-DocRED의 train 스플릿으로부터 지시사항 미세조정용 데이터 셋을 구축한다. 그리고 거대 언어 모델 LLaMA-7B를 데이터 셋에 대해 지시학습 미세조정한다.

모델 추론 그림 7은 이렇게 학습된 모델을 이용해 추론(inference)을 수행하는 과정을 보여준다. 추론은 3단계로 이루어진다. 우선 주어진 문서와 관계를 추출하고 싶은 개체 쌍에 대해 입력 프롬프트를 생성한다. 그리고 이를 학습된 LLaMA-7B에 입력해 텍스트를 생성한다. 마지막으로, 생성된 텍스트로부터 관계를 추출한다.

제 2 절 목표 데이터 셋 : Re-DocRED

모델 학습 및 평가를 위한 데이터 셋으로는 문서 수준 관계 추출에서 가장 많이 사용되는 Re-DocRED[30]를 이용했다. Re-DocRED는 Wikip

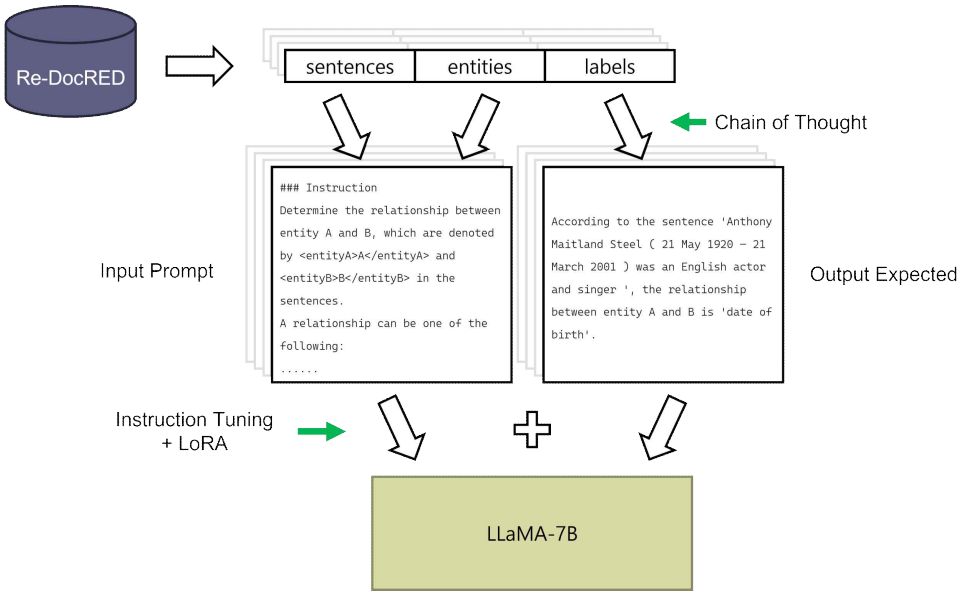

그림 6 모델 학습 방법

위 그림은 본 연구에서 제안하는 모델의 학습 방법을 보여준다. 1) Re-DocRED (그림 왼쪽 위 보라색) train 스플릿의 각 데이터로부터 입력 프롬프트-출력 기댓값 쌍을 만들고(그림 가운데), 2) LLaMA-7B(그림 아래 노란색)를 지시사항 미세조정(instruction tuning)한다.

edia에서 수집한 총 4,053개의 문서에 대해, 문서 내 개체를 모두 식별한 후, 96종의 두 개체 간 관계를 사람이 직접 분류한 human-annotated 데이터 셋이다. Re-DocRED의 96종 관계의 종류 및 설명은 부록 1을 참조하자.

데이터 셋 스플릿 Re-DocRED는 train 스플릿(train split), dev 스플릿(dev split), test 스플릿(test split), 이렇게 세 개의 스플릿(split)으로 되어 있다. 표 3은 각 스플릿의 통계량을 정리한 것이다.

데이터 셋의 구조 Re-DocRED의 구조는 다음과 같다. 우선 각 스플릿은 문서들의 리스트(list)이다. 각 문서는 **`title`**, **`sents`**, **`vertexSet`**, **`labels`** 키를 가지는 딕셔너리(dictionary)이다. **`title`**은 문서의 제목을

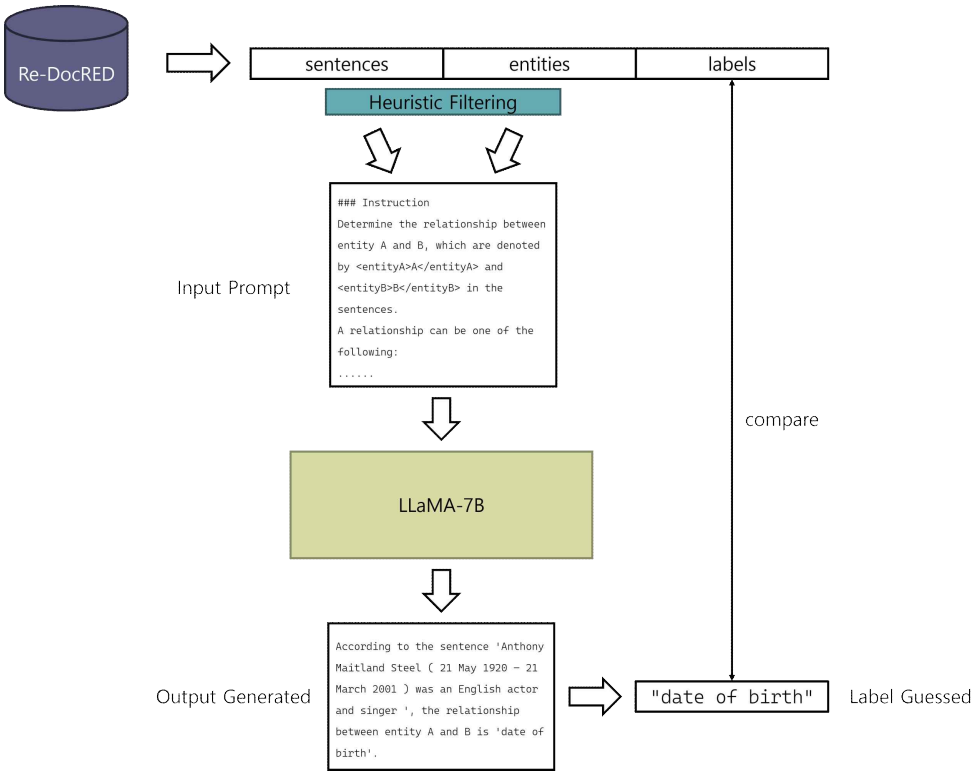

그림 7 모델 추론 방법

위 그림은 본 연구에서 제안하는 모델의 추론 방법을 보여준다. 1) 문서와 관계를 추출하고 싶은 개체 쌍에 대해 입력 프롬프트를 생성하고, 2) 이를 학습된 LLaMA-7B에 입력해 텍스트를 생성하고, 3) 생성된 텍스트로부터 관계를 추출한다.

	train 스플릿	dev 스플릿	test 스플릿
문서 수	3,053	500	500
평균 문장 수	7.9	8.2	7.9
평균 관계 수	28.1	34.6	34.9
평균 개체 수	19.4	19.4	19.6

표 3 Re-DocRED 각 스플릿 별 통계량

나타내는 문자열(string)이다. **sents**는 문장들의 리스트로 되어 있다.

각 문장은 토크나이즈(tokenize) 된 단어(토큰)들의 리스트로 되어 있다. **vertexSet**은 (개체명 추출을 통해 추출된) 개체들의 리스트이다. Re-DocRED에는 이와 같이 개체들을 사전에 추출하여 제공하고 있으므로, 추가로 개체명 추출을 할 필요는 없다. 이때 하나의 개체는 문서 내 여러 곳에서 다양한 모습으로 존재할 수 있으므로(ex. "the U.S.A.", "the United States of America", "America" 등은 모두 같은 개체를 의미한다) **vertexSet**의 각 항목은 문서에서의 등장 모습(**name**)과 등장 위치(**sent_id**, **pos**) 등을 나타내는 딕셔너리들의 리스트로 되어 있다. 마지막으로 **labels**에는 문서에 존재하는 모든 관계들(**h**, **t**, **r**)과 그 관계의 근거가 되는 문장의 인덱스(**evidence**)가 딕셔너리의 형태로 저장되어 있다.[10)]

<u>데이터 셋의 평가</u> Re-DocRED에 대한 성능은 F1 점수를 이용해 측정된다. 입력된 문서와 두 개체 쌍에 대해 분류 모델이 찾은 관계 트리플렛이 Re-DocRED에 포함되어 있으면 맞은 것으로 계산한다. 이렇게 했을 때, 정밀도(precision)은 모델이 찾은 모든 관계 트리플렛 수 대비 모델이 찾은 정답 관계 트리플렛 수로 계산한다. 재현율(recall)은 Re-DocRED의 있는 정답 관계 트리플렛 수 대비 모델이 찾은 정답 관계 트리플렛 수로 계산한다. 이렇게 계산한 정밀도와 재현율을 이용해 F1 점수를 계산할 수 있다.

$$\text{Precision} = \frac{\text{TP}}{\text{TP}+\text{FP}} = \frac{\text{모델이 찾은 정답 관계 트리플렛 수}}{\text{모델이 찾은 총 관계 트리플렛 수}}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP}+\text{FN}} = \frac{\text{모델이 찾은 정답 관계 트리플렛 수}}{\text{정답 관계 트리플렛 수}}$$

$$\text{F1 score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

수식 1 정밀도(Precision), 재현율(Recall), F1 점수(F1 Score)

10) test 스플릿의 경우 **labels** 키가 존재하지 않는다.

이때 모델이 찾은 정답 트리플렛 중 일부는 학습 중 train 스플릿에 똑같이 존재해, 모델은 주어진 문서를 보고 관계를 찾은 것이 아니라 학습 과정 중 해당 관계 트리플렛을 그저 기계적으로 '외운 것'을 반환했을 가능성이 있다. 따라서 모델이 찾은 관계 트리플렛 중 train 스플릿에 똑같이 존재하는 관계 트리플렛은 정밀도 계산에서 제외하고 F1 점수를 구할 수 있다. train 스플릿에 똑같이 존재하는 관계 트리플렛을 제외하고 계산한 정밀도를 ignore 정밀도(ign. precision), ignore 정밀도를 이용해 계산한 F1 점수를 ignore F1(ign. F1) 점수라 한다.

본 연구에서는 Re-DocRED train 스플릿만을 보고 학습한 모델을, (정답이 공개되어 있는) Re-DocRED dev 스플릿에서의 F1 점수를 이용해 성능을 평가하였다.

제 3 절 기반 거대 언어 모델 : LLaMA

본 연구에서는 동급 모델 중 가장 추론 성능이 좋다고 알려진 LLaMA [31]를 거대 언어 모델로 사용했다. LLaMA는 Meta AI에서 2023년 공개한 causal 언어 모델이다. LLaMA는 총 7B, 13B, 33B, 65B, 이렇게 총 4개의 버전이 공개되었다. 표 4는 LLaMA 각 버전 별 하이퍼파라미터를 정리한 것이다.

거대 언어 모델 학습 데이터 LLaMA는 다른 거대 언어 모델이 일반적으로 사전학습에 사용하는 말뭉치들 중 공개적으로 사용 가능한 말뭉치들을 모아 140억 개의 토큰들로 이루어진 하나의 커다란 말뭉치를 만들고, 이를 이용해 사전학습을 진행하였다. 표 5는 LLaMA가 사전학습에 사용한 말뭉치에 포함된 말뭉치들의 종류와 그 양을 정리한 것이다.

거대 언어 모델의 추론 성능 Meta AI는 LLaMA를 다양한 추론 문제(reasoning problem)에 대해 적용해 보고 그 성능을 보고했다. 표 6

	LLaMA-7B	LLaMA-13B	LLaMA-33B	LLaMA-65B
매개변수 수	6.7B	13.0B	32.5B	65.2B
은닉상태 차원	4096	5120	6656	8192
head 수	32	40	52	64
레이어 수	32	40	60	80

표 4 LLaMA 각 버전 별 하이퍼파라미터

말뭉치	크기	비율
English CommonCrawl	3.3TB	67.0%
C4	783GB	15.0%
Github	328GB	4.5%
Wikipedia	83GB	4.5%
Gutenberg and Books	85GB	4.5%
ArXiv	92GB	2.5%
Stack Exchange	78GB	2.0%

표 5 LLaMA 사전학습 말뭉치 내 말뭉치 비율

은 LLaMA의 각 버전을 여러 추론 문제에 대해 zero-shot으로 사용했을 때의 성능을 정리한 것이다.

제 4 절 모델 학습

거대 언어 모델이 문서 수준 관계 추출 과제를 잘 풀 수 있도록 Chain of Thought를 이용한 지시사항 미세조정을 수행한다. 이때 LoRA를 적용하여 적은 컴퓨팅 자원으로도 학습이 가능하게 한다.

	LLaMA-7B	LLaMA-13B	LLaMA-33B	LLaMA-65B
BoolQ	76.5	87.1	83.1	85.3
PIQA	79.8	80.1	82.3	82.8
SIQA	48.9	50.4	50.4	52.3
HellaSwag	76.1	79.2	82.8	84.2
WinoGrade	70.1	73.	76	77
ARC-e	76.7	78.1	81.4	81.5
ARC-c	47.6	52.7	57.8	56
OBQA	57.2	56.4	58.6	60.2
COPA	93	94	92	94

표 6 각 LLaMA 버전 별 다양한 추론 문제에 대한 성능

<u>지시사항 미세조정(Instruction Tuning)</u> 지시사항 미세조정(Instruction Finetuning)[43]이란 거대 언어 모델이 사용자가 입력한 지시사항(instruction)에 따라 (zero-shot으로) 적절한 답변을 생성하도록 미세조정하는 방법이다. 지시사항 미세조정을 수행하면 작은 모델로도 큰 모델과 비슷하거나 그 이상의 추론 성능을 달성할 수 있다고 알려져 있다.

지시사항 미세조정은 두 단계로 이루어진다. 우선 미세조정을 위한 데이터 셋을 구축한다. 그리고 구축한 데이터 셋을 이용, 사전학습 때와 동일한 손실 함수(causal language modelling)를 이용해 거대 언어 모델을 학습시킨다.

각 단계를 자세히 살펴보자. 우선 첫 번째 단계에서, 미세조정을 위한 데이터 셋은 입력 프롬프트-출력 기댓값 쌍들로 구성된다. 입력 프롬프트란 과제에 대한 지시사항을 담은, 모델에 입력될 규격화된 양식의 텍스트를 의미한다. 출력 기댓값은 입력 프롬프트가 모델에 입력되었을 때 출력되기를 희망하는 텍스트를 의미한다.[11] 예를 들어 지시사항 미세조정을

이용해 영화 댓글에 대한 긍/부정 감성 분석을 하는 모델을 만드는 상황을 생각해 보자. 그림 8은 이를 위한 입력 프롬프트-출력 기댓값 쌍 예시를 보여준다.

입력 프롬프트	### Instruction: Determine if the given comment is positive or negative. ### Input: I love this movie! ### Response:
출력 기댓값	The given comment is positive.

그림 8 영화 댓글 긍/부정 감성 분석 과제를 위한 입력 프롬프트-출력 기댓값 쌍 예시

지시사항 미세조정을 위해서는 위와 같은 입력 프롬프트-출력 기댓값 쌍들을 모은 데이터 셋이 필요하다.

두 번째 단계에서는, 첫 번째 단계에서 구축한 데이터 셋의 입력 프롬프트와 출력 프롬프트를 합친(concatenate) 텍스트들로 구성된 말뭉치를 이용, 이전 단어들이 주어졌을 때 다음에 올 단어를 예측하는 causal language modelling 방식으로 거대 언어 모델을 학습시킨다. 수식 2는 causal language modelling을 위한 손실 함수를 보여준다. 이렇게 하면 거대 언어 모델은 입력 프롬프트 뒤에 와야 할 단어(들)이 출력 기댓값임을 자연스럽게 학습하게 되고, 결과적으로 학습이 완료된 모델에 입력 프롬프트를 입력하면 출력 기댓값대로 출력이 나오게 된다.[12)]

11) 일종의 지도학습 데이터 셋을 만든다고 생각하면 된다.

$$L = -\frac{1}{n}\sum_{i=1}^{n}\log P(x_i | x_{<i})$$

(단 $\{x_1, x_2, \cdots, x_n\}$는 시퀀스를, $x_{<i}$는 $x_1, x_2, \cdots, x_{i-1}$를 의미한다)

수식 2 causal language modelling을 위한 손실 함수

지시사항 미세조정은 거대 언어 모델의 매개변수를 실제로 업데이트한다는 점에서 프롬프트 엔지니어링과 구분된다. 또한 지시사항 미세조정은 모델 구조에 어떠한 변경도 가하지 않고 어떠한 과제에 대해서도 (사전학습 때와) 동일한 손실 함수(causal language modelling)를 사용한다는 점에서, 모델의 구조를 변경하고 과제에 따라 다른 손실 함수를 사용하는 사전학습-미세조정 패러다임에서의 미세조정 방법들과 구분된다.

<u>Chain of Thought</u> Chain of Thought(CoT)〔27〕란 적절한 프롬프트를 주어 거대 언어 모델이 과제를 '차근차근(step-by-step)' 생각하여 해결하도록 유도하는 프롬프트 엔지니어링 기법이다. 거대 언어 모델은 풀이에 여러 단계가 필요한 복잡한 추론 문제를 잘 못 풀었는데, Chain of Thought를 사용하면 복잡한 추론 문제에서의 성능을 비약적으로 높일 수 있다.

예를 들어 다음과 같은 문장형 수학 문제를 생각해 보자.

"한 카페테리아는 23개의 사과를 가지고 있었다. 점심을 만들기 위해 20개를 사용하고, 6개를 추가로 구매했다면, 현재 총 몇 개의 사과를 가지고 있는가? (The cafeteria had 23 apples. If they used 20 to make lunch and bought 6 more, how many apples do they have?)"

---

12) 수식 1의 손실함수는 perplexity에 log를 씌운 것이기도 하다. 학습이 잘 된 모델일수록 perplexity가 낮아지게(매 시점 모델이 단어를 선택할 때 덜 헷갈린다는 말이) 된다.

입력 프롬프트	Q. Roger has 5 tennis balls. He buys 2 more cans of tennis balls. Each can has 3 tennis balls. How many tennis balls does he have now? A. The answer is 11. Q. The cafeteria had 23 apples. If they used 20 to make lunch and bought 6 more, how many apples do they have?
모델 출력	A. The answer is 27.

입력 프롬프트	Q. Roger has 5 tennis balls. He buys 2 more cans of tennis balls. Each can has 3 tennis balls. How many tennis balls does he have now? A. Roger started with 5 balls. 2 cans of 3 tennis balls each is 6 tennis balls. 5 + 6 = 11. The answer is 11. Q. The cafeteria had 23 apples. If they used 20 to make lunch and bought 6 more, how many apples do they have?
모델 출력	A. The cafeteria had 23 apples originally. They used 20 to make lunch. So they had 23 - 20 = 3. They bought 6 more apples, so they have 3 + 6 = 9. The answer is 9.

그림 9 Chain of Thought 예시

복잡한 추론 문제를 풀 때 아래와 같이 chain of thought 기법(초록색)을 적용해서 프롬프트를 설계하면 거대 언어 모델의 추론 성능을 높일 수 있다.

이 문제를 풀기 위해 그림 9의 위 표와 같이 1-shot 프롬프트를 구성할 수 있다. 하지만 이 프롬프트를 사용하면 모델이 잘못된 답을 출력하는 경우가 많다. 하지만 사람이 어려운 문제를 풀 때 여러 중간 단계를 거치며 '차근차근' 생각하는 것처럼, 그림 9의 아래 표와 같이 문제를 푸는 중간 과정을 명시하도록 프롬프트를 만들어 주면 정답률을 높일 수 있다. 이런 식으로 프롬프트를 구성하는 것을 Chain of Thought라 한다.

Chain of Thought는 거대 언어 모델의 추론 성능을 높일 수 있다는 장점 뿐 아니라 모델/과제의 종류에 상관없이 쉽게 적용할 수 있고 거대 언어 모델의 추론의 근거를 볼 수 있다는 장점이 있다.

적용 : 지시사항 미세조정용 데이터 셋 구축 사전학습-프롬프트-예측 패러다임으로 LLaMA-7B를 이용해 Re-DocRED를 풀기 위해서는 분류 문제를 생성 문제로 바꿔야 한다. 이를 위해 문서와 문서 내 특정 개체 쌍이 주어졌을 때, 그림 10과 같은 형태로 프롬프트를 구성한다.

입력 프롬프트는 instruction 영역(**### Instruction**), input 영역(**### Input**), response 영역(**### Response**), 이렇게 3개의 영역으로 구성된다. instruction 영역에서는 문서 추출 과제에 대한 설명과 Re-DocRED의 관계 종류들을 모두 입력하여 거대 언어 모델이 과제에 대한 충분한 이해를 할 수 있도록 한다. 이때 서로 아무런 관계가 없는 개체 쌍이 입력되었을 때는 관계가 없다(**no relationship**)는 레이블이 출력될 수 있도록 해당 설명을 과제 설명에 명시한다. input 영역에서는 문서 수준 관계 추출을 진행할 문서의 문장들(**Sentences**)과 문서 수준 관계 추출을 위한 질문(**Question**)을 입력하였다. 이때 입력된 개체 쌍의 문서 내 위치를 XML 태그(**<entityA></entityA>**, **<entityB></entityB>**) 형태로 표시하여 모델이 두 개체를 볼 수 있도록 한다.

출력 기댓값은 그림 11과 같은 형태로 만든다. 개체 쌍의 관계가 존재

입력 프롬프트	### Instruction: Determine the relationship between entity A and B, which are denoted as <entityA>A</entityA> and <entityB>B</entityB> in the sentences. A relationship can be one of the following: head of government, country, place of birth, ...[쉼표로 구분된 96개의 관계 종류] If two entities are not related, please select 'no relationship'. ### Input: Sentences: [관계를 추출하고픈 개체를 <entityA></entityA>, <entityB></entityB> 스타일로 포맷팅한 문서] Question: What is the relationship between entity A and B? ### Response:

그림 10 Re-DocRED를 위한 입력 프롬프트 구조

검은색 텍스트 부분은 항상 고정이고, 초록색 텍스트가 있는 부분을 매 질의마다 바꿔서 사용한다.

하고, 그 근거 문장(**evidence**)도 주어진 경우 chain of thought 기법을 활용해 그림 11의 두 번째 행과 같이 출력 기댓값을 만든다. 만약 주어진 개체 쌍의 관계가 존재하지 않는다면 관계가 없다(**no relationship**)는 레이블을 사용해 출력 기댓값을 만든다. 부록 2는 이 방법으로 구축한, Re-DocRED train 스플릿의 ′Ministry of Home Security′ 문서에서 “John Anderson”과 “British” 간의 관계를 묻기 위한 입력 프롬프트-출

출력 기댓값	The relationship between entity A and B is '[관계]'.
	According to the sentence '[근거 문장]', the relationship between entity A and B is '[관계]'.

그림 11 Re-DocRED를 위한 출력 기댓값 구조

검은색 텍스트 부분은 항상 고정이고, 초록색 텍스트가 있는 부분을 매 질의마다 바꿔서 사용한다. 만약 근거 문장이 주어진 경우 chain of thought 기법을 응용하여 출력 기댓값을 구성한다.

력 기댓값 예시를 보여준다.

이때 문서 내 가능한 모든 관계 쌍들의 조합에서, 대부분의 관계 쌍들은 관계가 없는(**no relationship**) 쌍이다. **no relationship** 관계의 입력 프롬프트-출력 기댓값 쌍이 데이터 셋에 너무 많이 포함되면 편향된(biased) 데이터 셋이 된다. 따라서 데이터 셋의 균형을 위해 **no relationship**의 개체 쌍들 중 일부만을 무작위 추출해 사용한다. 본 모델에서는 관계가 존재하는 개체 쌍 수의 3배의 **no relationship** 개체 쌍을 추출해 사용하였다.[13] 관계가 존재하는 개체 쌍 대비 몇 배의 **no relationship** 개체 쌍을 사용할 것인지는 하이퍼파라미터(**no_rel_rate**)로 설정한다.

<u>LoRA</u> LoRA(Low-Rank Adaptation)[51]는 거대 언어 모델의 미세조정에 들어가는 엄청난 시간과 비용을 경감하기 위해, 거대 언어 모델의 전체 매개변수를 업데이트하는 것이 아니라(전체 미세조정, full finetuning), 사전학습된 매개변수는 업데이트하지 않고(freeze) 어텐션 연산의 가중치 행렬(W_q, W_k, W_v)을 저차원 분해한(low rank decompositio

13) **no_rel_rate**=3일 때, 총 271,232개의 입력 프롬프트-출력 기댓값 쌍이 데이터 셋에 포함된다.

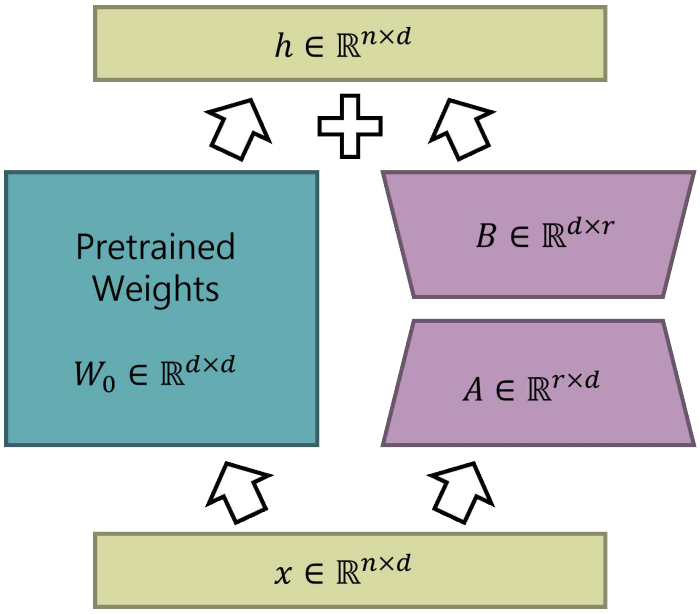

그림 12 LoRA

LoRA 사전학습된 매개변수는 업데이트하지 않고(freeze) 어텐션 연산의 가중치 행렬(W_q, W_k, W_v)을 저차원 분해한(low rank decomposition) 행렬만 업데이트하여 미세조정을 수행하는 방법이다.

n) 행렬만 업데이트하여 미세조정을 수행하는 방법이다.

구체적으로, 사전학습된 2차원 행렬 $W_0 \in \mathbb{R}^{d \times k}$를 가중치로 가지는 FC layer가 있다고 해 보자. 미세조정이란 미세조정용 학습 데이터 셋에 대해 손실 함수를 최소화하는 가중치 W를 찾는 과정이라 볼 수 있다.

$$W = W_0 + \Delta W$$

이때 ΔW를 $\Delta W = BA$를 만족하는 $B \in \mathbb{R}^{d \times r}$, $A \in \mathbb{R}^{r \times k}$(단, $r \ll d, k$)로 저차원 분해하면, 미세조정은 다음과 같은 식으로 나타낼 수 있다.

$$W = W_0 + BA$$

여기서 사전학습 가중치 W_0를 고정시켜 두고(freeze), A와 B만 학습 가능하게 하여 그라디언트 업데이트를 수행해도 동일한 미세조정 결과를 얻을 수 있다. 이 방법을 언어 모델의 어텐션 연산 가중치 행렬에 대해 적용한 것이 LoRA이다. 그림 12는 LoRA의 동작 모습을 보여준다.

LoRA를 사용하면 다양한 장점이 있다. 미세조정 과정에서 고정된 매개변수에 대한 옵티마이저 상태(optimizer state)는 메모리에 들고 있을 필요가 없으므로, LoRA를 사용하면 VRAM 사용량을 전체 미세조정 방법 대비 1/3까지 떨어뜨릴 수 있다.[14] 또한 사전학습된 매개변수는 업데이트되지 않으므로, 모델의 매개변수를 저장할 때는 저차원 분해된 행렬만 저장하면 되어, LoRA를 사용하면 미세조정한 모델을 저장할 때 전체 미세조정 방법 대비 저장 공간 사용량을 10,000배 줄일 수 있다.[15] 그러나 필요하다면 LoRA로 미세조정한 모델의 전체 매개변수를 손쉽게 계산해($W = W_0 + BA$) 저장할 수도 있어, 다른 미세조정 개선 방법 대비 실 사용 시(inference) 추가적인 연산이 필요 없어 속도가 빠르다는 장점도 있다. 게다가 모델의 대부분의 매개변수는 고정되어 있는 바, 학습 시 실제로 그라디언트(gradient)를 계산하는 매개변수의 수가 매우 적어 학습 속도도 빨라진다.[16]

---

14) GPT-3(173B)의 경우, 전체 미세조정 방법으로는 1.2TB의 VRAM을 사용하던 것을 350GB까지 떨어뜨릴 수 있다.

15) GPT-3(173B)의 경우, 350GB의 저장 공간을 사용하던 미세조정 모델 체크포인트(model checkpoint)의 크기를 35MB까지 줄일 수 있다($r = 4$, W_q, W_v 행렬만 저차원 분해한 경우). 단 모델을 실제 사용하기 위해서는 사전학습된 모델이 있어야 하므로 여전히 350GB의 저장 공간이 필요하다. 다만 하나의 사전학습 모델로부터 미세조정된 100개의 모델을 만드는 경우, 전체 미세조정 방법으로는 100 × 350GB ≈35TB의 저장 공간이 필요하지만 LoRA를 사용하면 350GB + 100 × 35MB ≈ 354GB의 저장 공간만 있으면 된다.

16) GPT-3(173B)의 경우, 전체 미세조정 방법 대비 LoRA 사용 시 약 25%

적용 : LoRA를 이용한 지시사항 미세조정 LLaMA-7B 모델을 미세조정하려면 매우 큰 VRAM을 가진 GPU가 필요하다.[17] 본 연구가 수행된 컴퓨팅 환경(NVidia A6000 48GB × 1)에서는 LLaMA-7B를 전체 미세조정(full finetuning)할 수 없기에 LoRA를 사용했다. Huggingface의 peft 라이브러리를 이용, $r=8$, $\alpha=16$, $p_{\text{dropout}}=0.05$, W_q, W_v 행렬만 저차원 분해하는 설정으로 LoRA를 적용해 1 epoch만큼 지시사항 미세조정을 수행한다.

제 5 절 모델 추론

이렇게 미세조정한 모델을 사용해 문서와 문서 내 개체 쌍이 질의되었을 때 문서 수준 관계 추출 과제를 수행하는 방법은 3단계로 구성된다. 우선 품사 기반 휴리스틱 필터링을 통해 관계가 존재할 수 없는 개체 쌍을 필터링한다(휴리스틱 필터링). 둘째로, 휴리스틱을 통과한 개체 쌍들에 대해, 입력 프롬프트를 구성하여 미세조정된 거대 언어 모델에 입력, 텍스트를 생성한다(텍스트 생성). 셋째로, 생성된 텍스트로부터 관계를 추출한다(관계 추출). 각 과정을 조금 더 자세히 알아보자.

휴리스틱 필터링 Re-DocRED는 각 개체들의 품사(part of speech tag, pos tag) 정보를 제공한다. train 스플릿의 모든 관계가 존재하는 개체 쌍들의 품사 조합 정보를 모은 후, 질의된 개체 쌍의 품사 조합이 절

의 학습 속도 향상이 관찰되었다.

17) LLaMA-7B 모델을 추론(inference)용으로 사용하려면 대략 28GB의 VRAM이 필요하다(float32). float16의 정밀도를 쓴다 해도 14GB의 VRAM이 필요하다. 통상적으로 학습을 위해서는 추론 시 필요한 메모리의 3배 + α(데이터 batch를 위한 메모리)가 필요하다고 알려져 있다. 즉 LLaMA-7B 모델을 학습시키려면 대략 84GB/42GB + α의 VRAM이 필요하다는 말이고, 이 정도의 메모리 요구량은 일반 사용자용 GPU로는 감당할 수 없는 양이다.

대 관계가 존재할 수 없는 조합인 경우 필터링한다.

텍스트 생성 질의된 문서와 개체 쌍들에 대해 그림 10과 같이 입력 프롬프트를 구성하고, 이를 미세조정된 모델에 입력하여 텍스트를 생성한다. 텍스트 생성 전략은 탐욕 전략(greedy strategy)을 사용하고, 〔EOS〕 태그 혹은 개행 문자가 출력되거나 최대 생성 토큰 수 제한에 도달하면 텍스트 생성을 멈춘다.

관계 추출 모델이 생성한 텍스트를 모두 소문자로 바꾼 후, 그림 13과 같은 정규 표현식을 이용해 관계를 추출한다. 만약 생성된 텍스트에 그림 15의 정규 표현식이 존재하지 않거나, 추출된 관계가 Re-DocRED에 있는 96종 + 1종(**no relationship**)에 포함되지 않는다면 **no relationship** 관계를 추출한 것으로 한다.

```
the relationship between entity a and b is '(.+)'.
```

그림 13 정규 표현식

모델이 생성한 텍스트를 모두 소문자로 바꾼 후, 위 정규표현식을 이용해 관계를 추출한다.

제 4 장 실험 및 결과

본 장에서는 제안한 방법의 성능 및 각 요소들의 유효성을 확인하기 위해 수행한 실험 및 실험 결과를 서술한다.

제 1 절 실험 설계

제안된 방법으로 만들어진 모델의 성능 및 각 요소들의 유효성을 확인하기 위해 다음과 같은 실험을 설계하였다.

실험 1. 모델의 성능 확인 본 연구에서 제안한 방식으로 만들어진 모델의 성능을 확인하기 위해, Re-DocRED dev 스플릿에 대한 정밀도, 재현율, F1 점수, ignore 정밀도, ignore F1 점수를 계산한다. 구체적으로, Re-DocRED dev 스플릿의 각 문서에 대해, 가능한 모든 개체 쌍들의 조합을 입력으로 넣고, 정답(**labels**)과 대조해 몇 개를 맞췄는지 정밀도, 재현율, F1 점수를 계산한다.

실험 2. 지시사항 미세조정의 효과 확인 지시사항 미세조정의 효과를 확인하기 위해, 오직 프롬프트 엔지니어링만을 사용하고 지시사항 미세조정은 수행하지 않은(사전학습만 진행된) 거대 언어 모델의 성능을 확인한다. 구체적으로, 그림 14와 같은 2-shot 입력 프롬프트를 이용해 Re-DocRED dev 스플릿에 대한 성능을 계산해 본다. 2-shot의 예시들은 Re-DocRED train 스플릿에서 무작위로 추출한 2개의 개체 쌍에 대해 만든다.

실험 3. Chain of Thought의 효과 확인 지시사항 미세조정용 데이터 셋을 구축하는 과정에서 사용한 Chain of Thought의 효과를 확인하기 위해, Chain of Thought를 사용하지 않고 구축한 데이터 셋으로

입력 프롬프트	### Instruction: Determine the relationship between entity A and B, which are denoted as <entityA>A</entityA> and <entityB>B</entityB> in the sentences. A relationship can be one of the following: head of government, country, place of birth, ...[쉼표로 구분된 96개의 관계 종류] If two entities are not related, please select 'no relationship'. ### Input: Sentences: [Example #1 문서] Question: What is the relationship between entity A and B? ### Response: According to the sentence [Example #1 근거 문장], the relationship between entity A and B is [Example #1 관계]. ### Input: Sentences:

	[Example #2 문서] Question: What is the relationship between entity A and B? ### Response: According to the sentence [Example #2 근거 문장], the relationship between entity A and B is [Example #2 관계]. ### Input: Sentences: [Query 문서] Question: What is the relationship between entity A and B? ### Response:

그림 14 실험 2를 위한 입력 프롬프트 구조

지시사항 미세조정의 효과를 확인하기 위해, 위와 같은 2-shot 프롬프트를 구성하고 미세조정하지 않은 모델에 입력하여 성능을 확인한다. 검은색 텍스트 부분은 항상 고정이고, 초록색 텍스트가 있는 부분을 매 질의마다 바꿔서 사용한다.

미세조정한 모델의 성능을 확인한다. 구체적으로, 근거 문장을 사용하지 않은 출력 기댓값을 이용해 지시사항 미세조정용 데이터 셋을 구축하고, 이를 이용해 모델을 미세조정한 후, Re-DocRED dev 스플릿에 대한 성능을 확인한다.

실험 4. 적절한 no_rel_rate 값 탐색 적절한 no_rel_rate 값을 탐

색하기 위해, no_rel_rate 값으로 1, 3, 5를 사용한 지시사항 미세조정 데이터 셋을 각각 만들어 모델을 학습시키고, 세 모델의 성능을 비교한다.

실험 5. 재현율만 높인 모델 **no_rel_rate**=0으로 하여 관계가 존재하는 개체 쌍만 이용해 지시사항 미세조정을 수행한 LLaMA-7B 모델을 이용해, 관계가 존재하는 개체 쌍만을 입력으로 넣었을 때 그 관계를 얼마나 잘 추론하는지를 확인해 보았다.

제 2 절 실험 결과 및 분석

실험 1. 모델의 성능 확인 표 7은 미세조정된 LLaMA-7B 모델을 Re-DocRED dev 스플릿에 적용했을 때의 성능을 보여준다. 본 연구에서 제안된 방법으로 만들어진 모델의 성능은 현 SotA에 비해서 떨어진다. 하지만 본 연구의 모델이 생성한 결과를 보면 데이터 셋 및 평가 방법 자체에 문제가 있어 보이는 경우를 여럿 볼 수 있다.

모델	정밀도	재현율	F1	Ign. 정밀도	Ign. F1
제안 모델	0.55	0.41	0.47	0.51	0.46
DREEAM(SotA)	0.89	0.69	0.78	0.87	0.77

표 7 실험 1 결과 : 모델 성능

첫 번째 행은 미세조정된 LLaMA-7B 모델을 Re-DocRED dev 스플릿에 적용했을 때의 성능을 나타낸다. 두 번째 행은 2023년 현재 SotA인 DREEAM[28]을 Re-DocRED dev 스플릿에 적용했을 때의 성능을 나타낸다.

그림 15, 16은 본 연구의 모델이 정답을 추론한 사례들을 보여준다. 그림 15는 모델이 정확한 근거 문장에 기반해 두 개체 간 관계를 정확히 추론한 사례를 보여준다. 특히 문서에는 단 한 번도 등장하지 않았던 “date

of birth"라는 관계를 잘 찾은 것을 볼 수 있는데, 이는 거대 언어 모델이 다양한 말뭉치를 학습하면서 사람이 태어난 날과 죽은 날을 "이름(탄생 - 죽음)"과 같은 형태로 서술한다는 것을 자연스럽게 학습한 것으로 보인다.

문서	<entityA>Anthony Maitland Steel</entityA> (<entityB>21 May 1920</entityB> - 21 March 2001) was an English actor and singer best known for his appearances in British war films of the 1950s such as The Wooden Horse (1950) , and his marriage to Anita Ekberg . He was described as " a glorious throwback to the Golden Age of Empire ... the perfect imperial actor , born out of his time , blue - eyed , square - jawed , clean - cut . " As another writer put it , " whenever a chunky dependable hero was required to portray grace under pressure in wartime or the concerns of a game warden in a remote corner of the empire , <entityA>Steel</entityA> was sure to be called upon . "
출력 기댓값	According to the sentence 'Anthony Maitland Steel (21 May 1920 - 21 March 2001) was an English actor and singer best known for his appearances in Br

	itish war films of the 1950s such as The Wooden Horse (1950) , and his marriage to Anita Ekberg .', the relationship between entity A and B is 'date of birth'.
모델 생성	According to the sentence 'Anthony Maitland Steel (21 May 1920 – 21 March 2001) was an English actor and singer best known for his appearances in British war films of the 1950s such as The Wooden Horse (1950) , and his marriage to Anita Ekberg .', the relationship between entity A and B is 'date of birth'.

그림 15 정답 사례 1

Re-DocRED dev 스플릿의 'Anthony Steel (actor)' 문서에 대해 미세조정된 LLaMA-7B 모델이 생성한 텍스트. 빨간색은 head 개체, 파란색은 tail 개체, 하늘색은 근거 문장, 초록색은 관계를 의미한다. 모델이 정확한 근거 문장에 기반해 두 개체 간 관계를 정확히 추론한 것을 볼 수 있다.

그림 16은 모델이 두 개체 간 관계는 정확히 추론했지만, 근거 문장을 하나 찾지 못한 사례를 보여준다.

문서	The Sacramento Bee is a daily newspaper published in Sacramento , California , in <entityB>the Unit

	ed States</entityB> . Since its founding in 1857 , The Bee has become the largest newspaper in Sacramento , the fifth largest newspaper in California , and the 27th largest paper in the <entityB>U.S.</entityB> It is distributed in the upper Sacramento Valley , with a total circulation area that spans about : south to Stockton , California , north to the Oregon border , east to <entityA>Reno</entityA> , Nevada , and west to the San Francisco Bay Area . The Bee is the flagship of the nationwide McClatchy Company . Its " Scoopy Bee " mascot , created by Walt Disney in 1943 , has been used by all three Bee newspapers (Sacramento , Modesto , and Fresno) .
출력 기댓값	According to the sentence 'The Sacramento Bee is a daily newspaper published in Sacramento , California , in the United States .', and 'It is distributed in the upper Sacramento Valley , with a total circulation area that spans about : south to Stockton , California , north to the Oregon border , east to Reno , Nevada , and west to the San Francisco

	Bay Area .', the relationship between entity A and B is 'located in the administrative territorial entity'.
모델 생성	According to the sentence 'It is distributed in the upper Sacramento Valley , with a total circulation area that spans about : south to Stockton , California , north to the Oregon border , east to Reno , Nevada , and west to the San Francisco Bay Area .', the relationship between entity A and B is 'located in the administrative territorial entity'.

그림 16 정답 사례 2

Re-DocRED dev 스플릿의 'The Sacramento Bee' 문서에 대해 미세조정된 LLaMA-7B 모델이 생성한 텍스트. 빨간색은 head 개체, 파란색은 tail 개체, 하늘색은 근거 문장, 초록색은 관계를 의미한다. 모델이 두 개체 간 관계는 정확히 추론했지만, 근거 문장을 하나 찾지 못한 사례를 보여준다.

그림 17, 18, 19는 본 연구의 모델이 정답을 추론하는데 실패한 사례들을 보여준다. 그림 17의 사례에서 모델은 개체 "Schizoanalysis"와 개체 "Gilles Deleuze" 간의 관계를 "creator"라 추정했지만 Re-DocRED에는 두 개체 간 관계가 존재하지 않는 것으로 되어 있다. 하지만 문서의 첫 번째 문장 "**Schizoanalysis (; schizo- from Greek σχίζειν skhizein , meaning " to split ") is a concept created by philosopher Gilles Deleuze and psychoanalyst Félix Guattari and first expounded in their book Anti - Oedipus (1972) .**"을 보면 "Schizoanalysis"라는 개념은 철학자 "Gilles Deleuze"에 의해 만들어졌다고 되어 있는 것을 볼 수 있다. 이는 Re-DocRED의 레이블링이 잘못되어 발생하는 False Negative의 사례이다.

문서	<entityA>Schizoanalysis</entityA> (; schizo- from Greek σχίζειν skhizein , meaning " to split ") is a concept created by philosopher <entityB>Gilles Deleuze</entityB> and psychoanalyst Félix Guattari and first expounded in their book Anti - Oedipus (1972) . Its formulation was continued in their follow - up work , A Thousand Plateaus . <entityA>Schizoanalysis</entityA> acquires many different definitions during the course of its development in their collaborative work and individually in the work of Guattari . In Chaosmosis , Guattari explains that " rather than moving in the direction of reductionist modifications which simplify the complex " , schizoanalysis " will work towards its complexification , its processual enrichment , towards the consistency of its virtual lines of bifurcation and differentiation , in short towards its ontological heterogeneity " .
출력 기댓값	The relationship between entity A and B is 'no relationship'.

모델 생성	**The relationship between entity A and B is 'creator'.**

그림 17 오답 사례 1

Re-DocRED dev 스플릿의 'Schizoanalysis' 문서에 대해 미세조정된 LLaMA-7B 모델이 생성한 텍스트. 빨간색은 head 개체, 파란색은 tail 개체, 초록색은 관계를 의미한다. 모델은 개체 "Schizoanalysis"와 개체 "Gilles Deleuze" 간의 관계를 "creator"라 추정했지만 Re-DocRED에는 두 개체 간 관계가 존재하지 않는 것으로 되어 있다.

그림 18의 사례에서 모델은 개체 "Toronto"와 "Roadhouse" 간의 관계가 "located in the administrative territoral entity"라 추론했지만, Re-DocRED에는 두 개체 간 관계가 존재하지 않는 것으로 되어 있다. 하지만 문서의 두 번째 문장 "**Four of the album 's tracks were recorded live in front of audiences , two of the live tracks at the Islington Academy in London , and the other two live tracks at Jeff Healey 's Roadhouse in Toronto .**"를 보면 Jeff Healey의 "Roadhouse"가 "Toronto"에 위치해 있다고 되어 있는 것을 볼 수 있다. 하지만 두 번째 문장의 "Roadhouse"는 Re-DocRED의 개체 목록에 포함되어 있지 않다. 이는 Re-DocRED의 개체 추출 및 레이블링이 잘못되어 발생하는 False Negative 사례이다.

문서	**Mess of Blues is an album by Jeff Healey .**

	It was released in 2008 less than two weeks after his death and just three weeks shy of his 42nd birthday . Four of the album 's tracks were recorded live in front of audiences , two of the live tracks at the Islington Academy in London , and the other two live tracks at Jeff Healey 's Roadhouse in <entityB> Toronto</entityB> . The other six tracks were recorded at Studio 92 in Canada by Norm Barker and Richard Uglow . The whole album features the band which normally accompanied Jeff at his club , Jeff Healey 's <entityA>Roadhouse</entityA> . The song " Mess of Blues " , which appears on the album was written by Doc Pomus and Mort Shuman and was originally recorded by Elvis Presley .
출력 기댓값	The relationship between entity A and B is 'no relationship'.
모델 생성	The relationship between entity A and B is 'located in the administrative territorial entity'.

그림 18 오답 사례 2

Re-DocRED dev 스플릿의 'Mess of Blues (Jeff Healey album)' 문서에 대해 미세조정된 LLaMA-7B 모델이 생성한 텍스트. 빨간색은 head 개체, 파란색은 tail 개체, 초록색은 관계를 의미한다. 모델은 개체 "Toronto"와 "Roadhouse" 간의 관계가 "located in the administrative territoral entity"라 추론했지만, Re-DocRED에는 두 개체 간 관계가 존재하지 않는 것으로 되어 있다.

그림 19의 사례에서 모델은 개체 "The Sacramento Bee"와 "Sacramento" 간의 관계가 "headquarters location"이라 추론했지만, Re-DocRED에서는 "location"이라 되어 있다. 하지만 문서의 첫 번째 문장 "**The Sacramento Bee is a daily newspaper published in Sacramento ,**

California , in the United States .”를 보면 “The Sacramento Bee”가 “Sacramento”에서 발간되는 신문이라고 되어 있는데, 일반적인 상식에 비추어 봤을 때 이 말은 “The Sacramento Bee”의 본부가 “Sacramento”라는 말과 동일한 말이라 볼 수 있다. 이는 관계 추출 과제가 본질적으론 분류 과제가 아니기에 발생하는 False Negative 문제이다. 레이블로서 사용되고 있는 각 관계들은 서로 대등한 수준에 있는, 이상적인 분류 문제의 레이블이 아니다. 당장 “location”과 “headquarters location”은 상당한 유의어로서, 사람이 ‘분류’하려 해도 상당히 논쟁의 여지가 있는 레이블들이다. 정답 관계 트리플렛을 추출하는 데 성공했는지 실패했는지를 세는 기존의 평가 방식으로는 이런 사례를 충분히 고려할 수 없다.

문서	<entityA>The Sacramento Bee</entityA> is a daily newspaper published in <entityB>Sacramento</entityB> , California , in the United States . Since its founding in 1857 , <entityA>The Bee</entityA> has become the largest newspaper in <entityB>Sacramento</entityB> , the fifth largest newspaper in California , and the 27th largest paper in the U.S. It is distributed in the upper Sacramento Valley , with a total circulation area that spans about : south to Stockton , California , north to the Oregon border , east to Reno , Nevada , and west to the San Francisco Bay Area .

	<entityA>The Bee</entityA> is the flagship of the nationwide McClatchy Company . Its " Scoopy Bee " mascot , created by Walt Disney in 1943 , has been used by all three Bee newspapers (<entityA>Sacramento</entityA> , Modesto , and Fresno) .
출력 기댓값	The relationship between entity A and B is 'location'.
모델 생성	According to the sentence 'The Sacramento Bee is a daily newspaper published in Sacramento , California , in the United States .', and 'It is distributed in the upper Sacramento Valley , with a total circulation area that spans about : south to Stockton , California , north to the Oregon border , east to Reno , Nevada , and west to the San Francisco Bay Area .', the relationship between entity A and B is 'headquarters location'.

그림 19 오답 사례 3

Re-DocRED dev 스플릿의 'The Sacramento Bee' 문서에 대해 미세조정된 LLaMA-7B 모델이 생성한 텍스트. 빨간색은 head 개체, 파란색은 tail 개체, 초록색은 관계를 의미한다. 모델은 개체 "The Sacramento Bee"와 "Sacramento" 간의 관계가 "headquarters location"이라 추론했지만, Re-DocRED에서는 "location"이라 되어 있다.

<u>**실험 2. 지시사항 미세조정의 효과 확인**</u> 지시사항 미세조정이 모델의 성능에 얼마나 영향을 미치는지를 확인해 보았다. 표 8은 지시사항 미세조정을 하지 않은 LLaMA-7B, LLaMA-13B 모델을 이용해 2-shot으로 Re-DocRED dev 스플릿을 추론하게 했을 때의 성능을 각각 나타낸 것이다. 이를 보면 지시사항 미세조정은 모델의 성능에 매우 큰 영향을 미치는 것을 알 수 있다. 특히 지시사항 미세조정은 모델의 분류(생성) 정확

도를 높혀 줄 뿐만 아니라 모델이 주어진 96 + 1종의 관계만을 일정한 형태로 출력하도록 만들어 준다. 또 모델의 크기가 커지면 아주 약간 성능이 올라가긴 하지만 큰 차이는 없는 것으로 확인된다. 이는 문서 수준 관계 추출 문제가 거대 언어 모델이 풀기 상당히 어려운 문제임을 시사한다.

모델	정밀도	재현율	F1	Ign. 정밀도	Ign. F1
제안 모델	0.55	0.41	0.47	0.51	0.46
LLaMA-7B	0.08	0.10	0.09	0.07	0.08
LLaMA-13B	0.09	0.10	0.09	0.07	0.08

표 8 실험 2 결과 : 지시사항 미세조정의 효과

첫 번째 행은 (지시사항 미세조정을 적용한) 제안 모델의 Re-DocRED dev 스플릿에 대한 성능을 나타낸다. 두 번째와 세 번째 행은 지시사항 미세조정을 수행하지 않은 LLaMA-7B 모델과 LLaMA-13B 모델을 이용해 2-shot으로 Re-DocRED dev 스플릿을 추론하게 했을 때의 성능을 나타낸다.

실험 3. Chain of Thought의 효과 확인 미세조정용 데이터 셋을 만들 때 Chain of Thought을 사용하는 것이 얼마나 유의미한지를 확인해 보았다. 표 9는 출력 기댓값에 Chain of Thought를 사용하지 않고 만든 미세조정용 데이터 셋을 이용해 지시사항 미세조정한 LLaMA-7B 모델의 추론 성능을 나타낸 것이다. Chain of Thought는 모델 성능에 유의미한 영향을 미치는 것을 알 수 있다.

실험 4. 적절한 no_rel_rate 값 탐색 표 10은 **no_rel_rate**로 1, 3(제안 모델), 5를 사용해 만든 지시사항 미세조정용 데이터 셋으로 미세조정한 LLaMA-7B 모델의 Re-DocRED dev 스플릿에서의 성능을 나타낸 것이다. **no_rel_rate**=3일 때의 모델 성능이 가장 좋은 것을 볼 수 있다. **no relationship** 개체 쌍이 너무 많으면 데이터가 편향되고, 너무 적으면 **no relationship** 관계를 제대로 학습하지 못하는 것으로 보

인다.

모델	정밀도	재현율	F1	Ign. 정밀도	Ign. F1
제안 모델 (CoT)	0.55	0.41	0.47	0.51	0.46
no CoT	0.43	0.32	0.37	0.39	0.35

표 9 실험 3 결과 : Chain of Thought의 효과

첫 번째 행은 (Chain of Thought를 사용한) 제안 모델의 Re-DocRED dev 스플릿에 대한 성능을 나타낸다. 두 번째 행은 Chain of Thought를 사용하지 않고 만든 미세조정용 데이터 셋을 이용해 지시사항 미세조정한 LLaMA-7B 모델의 Re-DocRED dev 스플릿에 대한 성능을 나타낸다.

모델	정밀도	재현율	F1	Ign. 정밀도	Ign. F1
no_rel_rate=1	0.54	0.41	0.47	0.49	0.45
no_rel_rate=3 (제안 모델)	0.55	0.41	0.47	0.51	0.46
no_rel_rate=5	0.53	0.39	0.45	0.46	0.42

표 10 실험 4 결과 : 적절한 no_rel_rate 값 탐색

첫 번째, 두 번째, 세 번째 행은 각각 **no_rel_rate**로 1, 3, 5를 사용해 만든 지시사항 미세조정용 데이터 셋으로 미세조정한 LLaMA-7B 모델의 Re-DocRED dev 스플릿에서의 성능을 나타낸다.

실험 5. 재현율만 높인 모델 **no_rel_rate**=0으로 하여 관계가 존재하는 개체 쌍에 대해서만 지시사항 미세조정을 수행한 LLaMA-7B 모델을 이용해, Re-DocRED dev 스플릿에서 관계가 존재하는 개체 쌍만을 입력으로 넣었을 때 그 관계를 얼마나 잘 추론하는지를 실험해 보았다. 즉 말하자면 정밀도는 포기하고 재현율만을 추구했을 때 모델의 재현율이 얼마나 나오는지를 확인해 본 것이다. 표 11은 그 결과를 나타낸다.

모델	정밀도	재현율	F1	Ign. 정밀도	Ign. F1
no_rel_rate=0	-	0.73	-	-	-
no_rel_rate=3 (제안 모델)	0.55	0.41	0.47	0.51	0.46

표 11 실험 5 결과 : 재현율만 높인 모델

첫 번째 행은 **no_rel_rate**=0으로 하여 관계가 존재하는 개체 쌍에 대해서만 지시사항 미세조정을 수행한 LLaMA-7B 모델을 이용해 Re-DocRED dev 스플릿에서 관계가 존재하는 개체 쌍만을 입력으로 넣었을 때의 성능을 나타낸다. 두 번째 행은 **no_rel_rate**=3을 사용한 제안 모델의 성능을 나타낸다.

표 11을 보면 정밀도를 포기할 경우 재현율을 상당히 높일 수 있는 것으로 보인다. 이런 현상이 발생하는 이유에 대한 다양한 추측이 가능하다.

한 가지 이유는 데이터 셋에 있는 False Negative 때문일 수도 있다. 위 실험 1의 결과에서도 밝혔듯이, 제안 모델이 생성한 오답들은 사람이 봤을 때 정답으로 보이는 오답들이 많다. Re-DocRED가 False Negative를 최대한 없앴지만 여전히 False Negative가 존재하는 것으로 보인다.

두 번째 이유는 제안 모델이 자연어로 된 관계 이름을 '이해해' 사용하는 과정에서, 관계 이름(레이블)이 해당 관계를 설명하는 데 부족하기 때문일 수 있다. 예를 들어, 관계 "father"는 친부(親父)만을 의미하는 관계로, 양부(養父) 관계면 father 관계로 분류되면 안 된다. 하지만 "father"라는 관계 이름만으로는 거대 언어 모델이 이 정보를 알기 쉽지 않다.

세 번째 이유는 주어진 텍스트에서는 두 개체 간 명시적인 관계가 드러나 있지 않아도, 거대 언어 모델이 사전학습 중 가지게 된 '배경지식'으로부터 관계가 추론되었기 때문일 수 있다. 사실 이 문제는 인간이 관계 추

출 문제를 풀 때도 직면하는 문제이다. 예를 들어 “철수는 귀국 후 인천 국제 공항 앞 한 국밥집에서 늦은 저녁 식사를 했다. 한국을 떠난 지 20년 만에 먹는 국밥의 맛은 매우 각별했다,”라는 문서에서, “인천 국제 공항”과 “한국”의 관계가 “영토 내 있음(located in the administrative territorial entity)”임은 아주 약하게 드러나 있다. 상식적인 배경지식을 가진 사람이라면 해당 관계를 비교적 어렵지 않게 읽어낼 수 있지만, 배경지식을 가지고 있지 않은 사람은 해당 관계를 못 읽어낼 수도 있다. 이처럼 사람은 가지고 있는 배경지식의 수준에 따라 텍스트를 이해하는 역량이 달라지고, 그 결과 관계 추출에도 영향이 발생할 수 있다. 사람이 직접 구축한(human-annotated) 데이터 셋 역시 이 문제에서 자유로울 수 없다.

이 정밀도 문제는 어쩌면 평가 방법의 한계에서 발생한 문제일 수 있다. 거대 언어 모델은 ‘최선을 다해’ 주어진 두 개체 사이의 관계를 추론하려 한다. 그 과정에서 관계가 없는 개체 쌍에 대해서도 ‘최선을 다해’ 관계를 찾다 보니 정밀도가 낮아지는 추론을 하게 된다. 하지만 정밀도는 분류 모델에서 사용하는 평가 방법으로, 거대 언어 모델을 이용해 생성적 방법으로 관계 추출 문제를 풀 때는 정밀도가 아닌 다른 평가 방법을 쓰는 것이 더 적절할 수 있다.

제 5 장 결론

제 1 절 연구 요약

본 연구는 사전학습-프롬프트-예측 패러다임 하에서 거대 언어 모델을 이용해 문서 수준 관계 추출 과제를 푸는 방법을 제안했다. 구체적으로, Meta AI에서 공개한 거대 언어 모델 LLaMA-7B를 지시사항 미세조정해 문서 수준 관계 추출 데이터 셋 Re-DocRED를 푸는 방법을 제안하였다.

모델 학습 방법은 2단계로 구성된다(그림 6 참조). 우선 입력 프롬프트-출력 기댓값 쌍들을 모은 지시사항 미세조정용 데이터 셋을 구축한다(그림 10, 11 참조). 출력 기댓값을 만들 때는 Chain of Thought 기법을 활용한다. 그리고 LoRA를 이용해 LLaMA-7B 모델을 매개변수 효율적으로(parameter-efficient) 지시사항 미세조정한다.

모델 추론 방법은 3단계로 구성된다(그림 7 참조). 문서와 문서 내 관계를 추출하고 싶은 개체 쌍이 질의되었을 때, 우선 품사 기반의 휴리스틱 필터링을 진행한다. 그리고 질의된 문서와 개체 쌍에 대해 입력 프롬프트를 만들고, 이를 미세조정된 모델에 입력, 텍스트를 생성한다. 마지막으로 정규 표현식을 이용(그림 13 참조), 생성된 텍스트에서 관계를 나타내는 구(phrase)를 추출한다.

이렇게 만들어진 모델의 성능을 확인하기 위해 여러 가지 실험을 수행하였다. 우선 2023년 현재 SotA 모델인 DREEAM과 성능을 비교했을 땐, 제안된 모델의 성능이 부족하다(표 7 참조). 하지만 모델이 실제 생성한 다양한 정답/오답 사례들을 보면(그림 15-19 참조) 모델의 낮은 성능은 데이터 셋 또는 평가 방법의 한계에서 기인한 부분이 있다는 것을 볼

수 있다. 모델 학습 과정에서 사용한 지시사항 미세조정과 Chain of Thought의 효과를 확인하기 위해 각각을 사용하지 않은 모델을 만들고 성능을 비교해 보았더니, 모델의 성능에는 지시사항 미세조정과 Chain of Thought가 중요한 역할을 하고 있음을 확인할 수 있었다(표 8, 9 참조). 적절한 하이퍼파라미터 **no_rel_rate**의 값을 찾기 위한 실험에서, **no_rel_rate**=3을 사용하는 것이 가장 성능이 높음을 확인할 수 있었다(표 10 참조). 마지막으로 모델의 재현율만을 높여 보는 실험에서, 모델의 재현율만을 높이면 재현율을 상당한 수준까지 올릴 수 있음을 확인하였다(표 11 참조).

제 2 절 논의점

기존의 연구들은 문서 수준 관계 추출 과제를 사전학습-미세조정 패러다임으로 풀었다. 즉 BERT[3], RoBERTa[4] 등의 masked 언어 모델을 기반 모델로 하여, 분류 과제를 푸는 방식으로 문서 수준 관계 추출 과제를 푼 것이다[29][28]. 하지만 본 연구는 본 연구자가 아는 범위 내에서는 문서 수준 관계 추출 과제를 사전학습-프롬프트-예측 패러다임으로 푼 최초의 접근이다. 본 연구는 causal 언어 모델을 기반 모델로 하여 생성적 방법으로 문서 수준 관계 추출 과제를 풀었다. 거대 언어 모델이 점점 더 발전해 나가고, 거대 언어 모델의 '지성'을 이용한 다양한 모델들이 나오는 오늘날, 거대 언어 모델을 이용해 문서 수준 관계 추출이라는 어려운 추론 과제를 시도하는 것은 매우 중요하다.

본 연구에서 사용한 패러다임인 사전학습-프롬프트-예측 패러다임은 기존 패러다임 대비 많은 장점이 있다. 우선 범용성이 높다는 장점이 있다. 사전학습-미세조정 패러다임에서는 매 과제마다 사전학습 언어 모델을 변형하고 손실함수를 새로 설계해야 했다. 하지만 사전학습-프롬프트-예측 패러다임에서는 하나의 동일한 거대 언어 모델을 어떠한 모델 변형 없이 사용하여 여러 과제를 푼다. 쉬운 과제의 경우 추가적인 학습 시간과 비용

을 전혀 들이지 않고 프롬프트 엔지니어링만으로도 과제를 풀 수 있다. 이런 거대 언어 모델의 범용성 덕분에 거대 언어 모델은 여러 종류의 작업을 수행하고 관리할 수 있는 자동화 에이전트로서 동작할 수 있다〔72〕〔18〕〔73〕.

또한 사전학습-프롬프트-예측 패러다임은 생성 방식으로 과제를 풀기에[18] 모델의 판단이 설명 가능하다는 장점이 있다. 기존의 사전학습-미세조정 패러다임으로 만들어진 모델은 블랙박스 모델이어서 모델이 한 판단의 근거를 알 수가 없었다. 하지만 사전학습-프롬프트-예측 패러다임에서는 적절한 프롬프트를 사용하면 모델이 판단뿐만 아니라 판단의 근거도 생성하게 할 수 있어 인공지능 모델들의 블랙박스적 특성을 상당 부분 해소할 수 있다〔69〕〔70〕. 실제로 본 연구에서는 Chain of Thought〔27〕 기법을 사용해 모델이 근거 문장을 함께 출력하도록 하여 모델의 성능을 높였을 뿐만 아니라 관계 추출의 근거도 함께 볼 수 있도록 하였다.

하지만 사전학습-프롬프트-예측 패러다임에는 아직 한계가 많다. 우선 사전학습-미세조정 패러다임 대비 매개변수 효율적인(parameter-efficient) 성능을 달성하기 어렵다. 당장 본 연구에서는 670억 개의 매개변수를 가진 LLaMA-7B를 기반 모델로 사용했지만, 3.6억 개의 매개변수를 가진 RoBERTa large를 기반모델로 사용한 DREEAM〔28〕의 성능을 뛰어넘지 못했다. 매개변수 수만 놓고 봤을 때 사전학습-프롬프트-예측 패러다임은 효율이 매우 나쁘다 평가할 수 있다.

사전학습-프롬프트-예측 패러다임에서는 모델 학습이 필요 없다는 장점이 오직 쉬운 과제에서만 성립한다는 점도 한계다. 지시사항 미세조정의 효과를 확인했던 실험 2의 결과에서 볼 수 있듯이, 문서 수준 관계 추출과 같은 어려운 추론 과제의 경우 프롬프트 엔지니어링만으로는 성능을 낼 수 없다. 성능을 얻기 위해서는 본 연구에서 제안한 방법과 같이 지시사항

18) causal 언어 모델을 사용하는 경우.

미세조정 등과 같은 추가적인 학습이 필요하다. 하지만 매우 많은 매개변수를 가진 거대 언어 모델을 추가로 학습시키는 것은 엄청난 시간과 비용이 들어간다. LoRA[51] 등의 매개변수 효율적인 학습법을 쓰면 시간과 비용을 상당 부분 아낄 수 있으나, 전체 미세조정을 할 때 대비 성능이 떨어질 수 있다는 문제점이 있다.

사전학습-프롬프트-예측 패러다임에서는 성능 좋은 거대 언어 모델을 기반 모델로 선택하는 것이 중요한데, 성능 좋은 거대 언어 모델을 만드려면 엄청난 시간과 비용이 필요하다는 점도 한계다. 예를 들어 1,760억 개의 매개변수를 가진 BLOOM[38]의 경우 약 4개월의 학습 시간과 약 20~50만 달러의 학습 비용이 들었다고 추산된다.

사전학습-프롬프트-예측 패러다임은 그 추론 속도가 느리다는 한계도 있다. 거대 언어 모델을 통한 텍스트 생성은 반드시 시간 순서대로 진행되어야 하기에[19] 병렬 처리를 통한 속도 향상이 불가능하다. 이 때문에 사전학습-프롬프트-예측 패러다임은 실시간(real-time) 서비스에서는 부적합하다는 단점이 있다. 이 문제를 해결하기 위해 본 연구에서 제안한 방법에서는 적극적인 조기 종료(early stop) 정책을 사용한다. 본 연구에서 제안한 방법에서는 개행 문자가 출력되면 생성을 종료하는 방법을 사용해 하나의 질의(문서와 개체 쌍)에 대한 생성 시간을 평균 0.08초로 단축시켰다. 또한 배치 입력(batch input)이 가능하도록 하여 처리량(throughput)을 늘렸다. A6000 48GB × 1 환경 기준 본 연구의 모델은 float16 정밀도로 모델 적재 후 배치 크기를 16으로 설정할 수 있다.

제 3 절 연구의 한계 및 향후 연구 방향

거대 언어 모델은 그 크기가 커질수록 추론 성능이 좋아지는 특징이 있다. 본 연구에서 사용한 LLaMA-7B 모델은 연구 환경에서 사용할 수 있

19) 이전 단어가 생성되어야 다음 단어를 생성할 수 있다.

었던 가장 큰 모델을 사용한 것이다. 만약 더 큰 컴퓨팅 자원을 사용 가능했거나, 향후 더 경량화된 학습/추론 방법, 더 경량화된 모델이 나온다면 성능을 더 높일 수 있었을 것으로 기대된다.

거대 언어 모델은 그 계산 집약적인(computation-intensive) 특성 때문에 환경적 문제를 야기하기도 한다. 거대 언어 모델의 학습과 사용은 상당히 큰 탄소 발자국(carbon footprint)을 남긴다는 것이 이미 여러 연구자들에 의해 지적되었다〔71〕〔74〕.

추가 비용을 들여 사람의 피드백을 이용하는 RLHF(Reinforcement Learning with Human Feedback)〔44〕를 적용하면 사용하면 성능이 더 좋아질 것으로 기대된다. RLHF는 사람의 피드백(feedback)을 보상으로 하여 강화학습(reinforcement learning)을 하는 거대 언어 모델 미세조정 방법이다. RLHF의 개략적인 동작 방식은 다음과 같다. 우선 거대 언어 모델로 하나의 프롬프트에 대해 여러 개의 답변 후보들을 생성하도록 한다. 그리고 사람이 직접 답변 후보들에 점수를 매겨 좋은 답변에 높은 점수를 부과하도록 한다.[20] 마지막으로, 부여한 점수를 보상(reward)로 하여 PPO(Proximal Policy Optimization) 방식〔75〕으로 거대 언어 모델을 강화학습시킨다. 이렇게 하면 거대 언어 모델은 사람이 좋은 답이라 평가한 답변을 내놓는 방향으로 미세조정된다.

---

20) RLHF를 실제로 사용할 땐 비용 문제 때문에 사람은 소수의 예제에 대해서만 평가를 진행하고, 사람의 평가를 모사하는 보상 모델(Reward Model)을 추가로 학습시켜 이를 대신 사용한다.

참 고 문 헌

〔1〕 A. Vaswani et al., “Attention is All you Need,” in Advances in Neural Information Processing Systems, Curran Associates, Inc., 2017.

〔2〕 P. Liu, W. Yuan, J. Fu, Z. Jiang, H. Hayashi, and G. Neubig, “Pre-train, Prompt, and Predict: A Systematic Survey of Prompting Methods in Natural Language Processing,” ACM Comput. Surv., vol. 55, no. 9, p. 195:1-195:35, Jan. 2023, doi: 10.1145/3560815.

〔3〕 J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding.” arXiv, May 24, 2019. doi: 10.48550/arXiv.1810.04805.

〔4〕 Y. Liu et al., “RoBERTa: A Robustly Optimized BERT Pretraining Approach.” arXiv, Jul. 26, 2019. doi: 10.48550/arXiv.1907.11692.

〔5〕 K. Clark, M.-T. Luong, and Q. V. Le, “ELECTRA: PRE-TRAINING TEXT ENCODERS AS DISCRIMINATORS RATHER THAN GENERATORS,” 2020.

〔6〕 Z. Lan, M. Chen, S. Goodman, K. Gimpel, P. Sharma, and R. Soricut, “ALBERT: A Lite BERT for Self-supervised Learning of Language Representations.” arXiv, Feb. 08, 2020. doi: 10.48550/arXiv.1909.11942.

〔7〕 A. Radford, K. Narasimhan, T. Salimans, and I. Sutskever, "Improving Language Understanding by Generative Pre-Training," 2018.

〔8〕 A. Radford, J. Wu, R. Child, D. Luan, D. Amodei, and I. Sutskever, "Language Models are Unsupervised Multitask Learners," 2019.

〔9〕 T. B. Brown et al., "Language Models are Few-Shot Learners." arXiv, Jul. 22, 2020. doi: 10.48550/arXiv.2005.14165.

〔10〕 L. Dong et al., "Unified Language Model Pre-training for Natural Language Understanding and Generation." arXiv, Oct. 15, 2019. doi: 10.48550/arXiv.1905.03197.

〔11〕 H. Bao et al., "UniLMv2: Pseudo-Masked Language Models for Unified Language Model Pre-Training." arXiv, Feb. 28, 2020. doi: 10.48550/arXiv.2002.12804.

〔12〕 M. Lewis et al., "BART: Denoising Sequence-to-Sequence Pre-training for Natural Language Generation, Translation, and Comprehension." arXiv, Oct. 29, 2019. doi: 10.48550/arXiv.1910.13461.

〔13〕 Z. Yang, Z. Dai, Y. Yang, J. Carbonell, R. Salakhutdinov, and Q. V. Le, "XLNet: Generalized Autoregressive Pretraining for Language Understanding." arXiv, Jan. 02, 2020. doi: 10.48550/arXiv.1906.08237.

〔14〕 C. Raffel et al., "Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer." arXiv, Jul. 28, 2020. doi: 10.48550/arXiv.1910.10683.

〔15〕 J. Kaplan et al., "Scaling Laws for Neural Language Models." arXiv, Jan. 22, 2020. doi: 10.48550/arXiv.2001.08361.

〔16〕 S. Herculano-Houzel, "The Human Brain in Numbers: A Linearly Scaled-up Primate Brain," Front Hum Neurosci, vol. 3, p. 31, Nov. 2009, doi: 10.3389/neuro.09.031.2009.

〔17〕 Q. Dong et al., "A Survey on In-context Learning." arXiv, Feb. 07, 2023. doi: 10.48550/arXiv.2301.00234.

〔18〕 J. S. Park, J. C. O'Brien, C. J. Cai, M. R. Morris, P. Liang, and M. S. Bernstein, "Generative Agents: Interactive Simulacra of Human Behavior." arXiv, Apr. 06, 2023. doi: 10.48550/arXiv.2304.03442.

〔19〕 A. Hogan et al., "Knowledge Graphs," ACM Comput. Surv., vol. 54, no. 4, pp. 1–37, May 2022, doi: 10.1145/3447772.

〔20〕 "Introducing the Knowledge Graph: things, not strings," Google, May 16, 2012. https://blog.google/products/search/introducing-knowledge-graph-things-not/

〔21〕 “Bring rich knowledge of people, places, things and local businesses to your apps,” Jul. 12, 2017. https://blogs.bing.com/search-quality-insights/2017-07/bring-rich-knowledge-of-people-places-things-and-local-businesses-to-your-apps/

〔22〕 “Understanding News Using the Bloomberg Knowledge Graph,” Speaker Deck, May 14, 2019. https://speakerdeck.com/emeij/understanding-news-using-the-bloomberg-knowledge-graph

〔23〕 X. L. Dong, “Building a Broad Knowledge Graph for Products,” in 2019 IEEE 35th International Conference on Data Engineering (ICDE), Apr. 2019, pp. 25–25. doi: 10.1109/ICDE.2019.00010.

〔24〕 “Cracking the Code on Conversational Commerce,” Apr. 06, 2017. https://www.ebayinc.com/stories/news/cracking-the-code-on-conversational-commerce/

〔25〕 X. Liu et al., “GPT Understands, Too.” arXiv, Mar. 18, 2021. doi: 10.48550/arXiv.2103.10385.

〔26〕 B. Lester, R. Al-Rfou, and N. Constant, “The Power of Scale for Parameter-Efficient Prompt Tuning.” arXiv, Sep. 02, 2021. doi: 10.48550/arXiv.2104.08691.

〔27〕 J. Wei et al., “Chain-of-Thought Prompting Elicits Reasoning in Large Language Models.” arXiv, Jan. 10, 2023. doi: 10.48550/arXiv.2201.11903.

〔28〕 Y. Ma, A. Wang, and N. Okazaki, "DREEAM: Guiding Attention with Evidence for Improving Document-Level Relation Extraction." arXiv, Feb. 16, 2023. doi: 10.48550/arXiv.2302.08675.

〔29〕 Q. Tan, R. He, L. Bing, and H. T. Ng, "Document-Level Relation Extraction with Adaptive Focal Loss and Knowledge Distillation." arXiv, Mar. 21, 2022. doi: 10.48550/arXiv.2203.10900.

〔30〕 Q. Tan, L. Xu, L. Bing, H. T. Ng, and S. M. Aljunied, "Revisiting DocRED -- Addressing the False Negative Problem in Relation Extraction." arXiv, Oct. 25, 2022. doi: 10.48550/arXiv.2205.12696.

〔31〕 H. Touvron et al., "LLaMA: Open and Efficient Foundation Language Models." arXiv, Feb. 27, 2023. doi: 10.48550/arXiv.2302.13971.

〔32〕 A. Hagen, "Turing-NLG: A 17-billion-parameter language model by Microsoft," Microsoft Research, Feb. 10, 2020. https://www.microsoft.com/en-us/research/blog/turing-nlg-a-17-billion-parameter-language-model-by-microsoft/

〔33〕 S. Smith et al., "Using DeepSpeed and Megatron to Train Megatron-Turing NLG 530B, A Large-Scale Generative Language Model." arXiv, Feb. 04, 2022. doi: 10.48550/arXiv.2201.11990.

〔34〕 S. Black, L. Gao, P. Wang, C. Leahy, and S. Biderman, "GPT-Neo: Large scale autoregressive language modeling with mesh-tensorflow." Zenodo, Mar. 2021. doi: 10.5281/zenodo.5297715.

〔35〕 B. Wang and A. Komatsuzaki, "GPT-J-6B: A 6 billion parameter autoregressive language model." May 2021. 〔Online〕. Available: https://github.com/kingoflolz/mesh-transformer-jax

〔36〕 S. Black et al., "GPT-NeoX-20B: An Open-Source Autoregressive Language Model." arXiv, Apr. 14, 2022. doi: 10.48550/arXiv.2204.06745.

〔37〕 S. Zhang et al., "OPT: Open Pre-trained Transformer Language Models." arXiv, Jun. 21, 2022. doi: 10.48550/arXiv.2205.01068.

〔38〕 B. Workshop et al., "BLOOM: A 176B-Parameter Open-Access Multilingual Language Model." arXiv, Mar. 13, 2023. doi: 10.48550/arXiv.2211.05100.

〔39〕 R. Thoppilan et al., "LaMDA: Language Models for Dialog Applications." arXiv, Feb. 10, 2022. doi: 10.48550/arXiv.2201.08239.

〔40〕 A. Chowdhery et al., "PaLM: Scaling Language Modeling with Pathways." arXiv, Oct. 05, 2022. doi: 10.48550/arXiv.2204.02311.

〔41〕 R. Anil et al., "PaLM 2 Technical Report." arXiv, May 17, 2023. doi: 10.48550/arXiv.2305.10403.

〔42〕 M. Shoeybi, M. Patwary, R. Puri, P. LeGresley, J. Casper, and B. Catanzaro, "Megatron-LM: Training Multi-Billion Parameter Language Models Using Model Parallelism." arXiv, Mar. 13, 2020. doi: 10.48550/arXiv.1909.08053.

〔43〕 J. Wei et al., "Finetuned Language Models Are Zero-Shot Learners." arXiv, Feb. 08, 2022. doi: 10.48550/arXiv.2109.01652.

〔44〕 P. Christiano, J. Leike, T. B. Brown, M. Martic, S. Legg, and D. Amodei, "Deep reinforcement learning from human preferences." arXiv, Feb. 17, 2023. doi: 10.48550/arXiv.1706.03741.

〔45〕 N. Stiennon et al., "Learning to summarize from human feedback." arXiv, Feb. 15, 2022. doi: 10.48550/arXiv.2009.01325.

〔46〕 L. Ouyang et al., "Training language models to follow instructions with human feedback." arXiv, Mar. 04, 2022. doi: 10.48550/arXiv.2203.02155.

〔47〕 S. Rajbhandari, J. Rasley, O. Ruwase, and Y. He, "ZeRO: Memory Optimizations Toward Training Trillion Parameter Models." arXiv, May 13, 2020. doi: 10.48550/arXiv.1910.02054.

〔48〕 J. Ren et al., "ZeRO-Offload: Democratizing Billion-Scale Model Training." arXiv, Jan. 17, 2021. doi: 10.48550/arXiv.2101.06840.

〔49〕 S. Rajbhandari, O. Ruwase, J. Rasley, S. Smith, and Y. He, "ZeRO-Infinity: Breaking the GPU Memory Wall for Extreme Scale Deep Learning." arXiv, Apr. 15, 2021. doi: 10.48550/arXiv.2104.07857.

〔50〕 J. Rasley, S. Rajbhandari, O. Ruwase, and Y. He, "DeepSpeed: System Optimizations Enable Training Deep Learning Models with Over 100 Billion Parameters," in Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, in KDD '20. New York, NY, USA: Association for Computing Machinery, 20 2020, pp. 3505–3506. doi: 10.1145/3394486.3406703.

〔51〕 E. J. Hu et al., "LoRA: Low-Rank Adaptation of Large Language Models." arXiv, Oct. 16, 2021. doi: 10.48550/arXiv.2106.09685.

〔52〕 L. D. Sourab Mangrulkar, Sylvain Gugger Younes Belkada, Sayak Paul, "PEFT: State-of-the-art parameter-efficient fine-tuning methods." 2022. 〔Online〕. Available: https://github.com/huggingface/peft

〔53〕 C. Quirk and H. Poon, "Distant Supervision for Relation Extraction beyond the Sentence Boundary," in Proceedings of the 15th Conference of the European Chapter of the Association for Computational Linguistics: Volume 1, Long Papers, Valencia, Spain: Association for Computational Linguistics, Apr. 2017, pp. 1171–1182.

〔54〕 J. Li et al., "BioCreative V CDR task corpus: a resourc e for chemical disease relation extraction," Database, v ol. 2016, p. baw068, Jan. 2016, doi: 10.1093/database /baw068.

〔55〕 Y. Yao et al., "DocRED: A Large-Scale Document-Level Relation Extraction Dataset," in Proceedings of the 57t h Annual Meeting of the Association for Computational Linguistics, Florence, Italy: Association for Computatio nal Linguistics, Jul. 2019, pp. 764–777. doi: 10.1865 3/v1/P19-1074.

〔56〕 Frederick Jelinek, Statistical Methods for Speech Reco gnition. MIT Press, 1998

〔57〕 J. Gao and C.-Y. Lin, "Introduction to the special issue on statistical language modeling," ACM Transactions o n Asian Language Information Processing, vol. 3, no. 2, pp. 87–93, Jun. 2004, doi: 10.1145/1034780.10347 81.

〔58〕 R. Rosenfeld, "Two decades of statistical language mod eling: where do we go from here?," Proceedings of the I EEE, vol. 88, no. 8, pp. 1270–1278, Aug. 2000, doi: 1 0.1109/5.880083.

〔59〕 A. Stolcke, "SRILM – an extensible language modeling t oolkit," in 7th International Conference on Spoken Lan guage Processing (ICSLP 2002), ISCA, Sep. 2002, pp. 901–904. doi: 10.21437/ICSLP.2002-303.

〔60〕 C. Zhai, Statistical Language Models for Information R etrieval. in Synthesis Lectures on Human Language Te chnologies. Cham: Springer International Publishing, 2 009. doi: 10.1007/978-3-031-02130-5.

〔61〕 S. M. Thede and M. P. Harper, "A Second-Order Hidde n Markov Model for Part-of-Speech Tagging," in Procee dings of the 37th Annual Meeting of the Association for Computational Linguistics, College Park, Maryland, U SA: Association for Computational Linguistics, Jun. 19 99, pp. 175 - 182. doi: 10.3115/1034678.1034712.

〔62〕 L. R. Bahl, P. F. Brown, P. V. de Souza, and R. L. Me rcer, "A tree-based statistical language model for natur al language speech recognition," IEEE Transactions on Acoustics, Speech, and Signal Processing, vol. 37, no. 7, pp. 1001 - 1008, Jul. 1989, doi: 10.1109/29.32278.

〔63〕 T. Brants, A. C. Popat, P. Xu, F. J. Och, and J. Dean, "Large Language Models in Machine Translation," in Pr oceedings of the 2007 Joint Conference on Empirical M ethods in Natural Language Processing and Computati onal Natural Language Learning (EMNLP-CoNLL), Pr ague, Czech Republic: Association for Computational L inguistics, Jun. 2007, pp. 858 - 867.

〔64〕 Y. Bengio, R. Ducharme, P. Vincent, and C. Janvin, "A neural probabilistic language model," J. Mach. Learn. Res., vol. 3, no. null, pp. 1137 - 1155, Spring 2003.

〔65〕 T. Mikolov, M. Karafiát, L. Burget, J. Cernocký, and S. Khudanpur, "Recurrent neural network based langua ge model," presented at the Proceedings of the 11th An nual Conference of the International Speech Communic ation Association, INTERSPEECH 2010, Jan. 2010, p p. 1045 - 1048.

〔66〕 T. Mikolov, I. Sutskever, K. Chen, G. Corrado, and J. Dean, "Distributed Representations of Words and Phras es and their Compositionality." arXiv, Oct. 16, 2013. d oi: 10.48550/arXiv.1310.4546.

〔67〕 T. Mikolov, K. Chen, G. S. Corrado, and J. Dean, "Effi cient Estimation of Word Representations in Vector Sp ace." 2013.

〔68〕 M. E. Peters et al., "Deep contextualized word represen tations." arXiv, Mar. 22, 2018. doi: 10.48550/arXiv.18 02.05365.

〔69〕 L. Li, Y. Zhang, and L. Chen, "Personalized Prompt Le arning for Explainable Recommendation." arXiv, Jan. 1 3, 2023. doi: 10.48550/arXiv.2202.07371.

〔70〕 Z. Cui, J. Ma, C. Zhou, J. Zhou, and H. Yang, "M6-Re c: Generative Pretrained Language Models are Open-E nded Recommender Systems." arXiv, May 19, 2022. do i: 10.48550/arXiv.2205.08084.

〔71〕 N. Bannour, S. Ghannay, A. Névéol, and A.-L. Ligoza t, "Evaluating the carbon footprint of NLP methods: a survey and analysis of existing tools," in Proceedings of the Second Workshop on Simple and Efficient Natural Language Processing, Virtual: Association for Computa tional Linguistics, Jan. 2021, pp. 11–21. doi: 10.1865 3/v1/2021.sustainlp-1.2.

〔72〕 H. Yang, S. Yue, and Y. He, "Auto-GPT for Online Dec ision Making: Benchmarks and Additional Opinions." a rXiv, Jun. 03, 2023. doi: 10.48550/arXiv.2306.02224.

〔73〕 Y. Liang et al., "TaskMatrix.AI: Completing Tasks by Connecting Foundation Models with Millions of APIs." arXiv, Mar. 28, 2023. doi: 10.48550/arXiv.2303.1643 4.

〔74〕 A. S. Luccioni, S. Viguier, and A.-L. Ligozat, "Estimati ng the Carbon Footprint of BLOOM, a 176B Parameter Language Model." arXiv, Nov. 03, 2022.

〔75〕 J. Schulman, F. Wolski, P. Dhariwal, A. Radford, and O. Klimov, "Proximal Policy Optimization Algorithms." arXiv, Aug. 28, 2017. doi: 10.48550/arXiv.1707.0634 7.

부록 1. Re-DocRED의 관계 종류

관계 ID	관계 이름	관계 설명
P6	head of government	head of the executive power of this town, city, municipality, state, country, or other governmental body
P17	country	sovereign state that this item is in (not to be used for human beings)
P19	place of birth	most specific known (e.g. city instead of country, or hospital instead of city) birth location of a person, animal or fictional character
P20	place of death	most specific known (e.g. city instead of country, or hospital instead of city) death location of a person, animal or fictional character
P22	father	male parent of the subject. For stepfather, use "stepparent" (P3448)
P25	mother	female parent of the subject. For stepmother, use "stepparent" (P3448)
P26	spouse	the subject has the object as their spouse (husband, wife, partner, etc.). Use "unmarried partner" (P451) for non-married companions

P27	country of citizenship	the object is a country that recognizes the subject as its citizen
P30	continent	continent of which the subject is a part
P31	instance of	that class of which this subject is a particular example and member; different from P279 (subclass of); for example: K2 is an instance of mountain; volcano is a subclass of mountain (and an instance of volcanic landform)
P35	head of state	official with the highest formal authority in a country/state
P36	capital	seat of government of a country, province, state or other type of administrative territorial entity
P37	official language	language designated as official by this item
P39	position held	subject currently or formerly holds the object position or public office
P40	child	subject has object as child. Do not use for stepchildren—use "relative" (P1038), qualified with "type of kinship" (P1039)

P50	author	main creator(s) of a written work (use on works, not humans); use P2093 when Wikidata item is unknown or does not exist
P54	member of sports team	sports teams or clubs that the subject represents or represented
P57	director	director(s) of film, TV-series, stageplay, video game or similar
P58	screenwriter	person(s) who wrote the script for subject item
P69	educated at	educational institution attended by subject
P86	composer	person(s) who wrote the music [for lyricist, use "lyrics by" (P676)]
P102	member of political party	the political party of which a person is or has been a member or otherwise affiliated
P108	employer	person or organization for which the subject works or worked
P112	founded by	founder or co-founder of this organization, religion or place
P118	league	league in which team or player plays or has played in
P123	publisher	organization or person responsible for publishing books, periodicals, printed music, podcasts, games or software

P127	owned by	owner of the subject
P131	located in the administrative territorial entity	the item is located on the territory of the following administrative entity. Use P276 for specifying locations that are non-administrative places and for items about events. Use P1382 if the item falls only partially into the administrative entity.
P136	genre	creative work's genre or an artist's field of work (P101). Use main subject (P921) to relate creative works to their topic
P137	operator	person, profession, or organization that operates the equipment, facility, or service
P140	religion	religion of a person, organization or religious building, or associated with this subject
P150	contains administrative territorial entity	(list of) direct subdivisions of an administrative territorial entity
P155	follows	immediately prior item in a series of which the subject is a part, preferably use as qualifier of P179 〔if the subject has replaced the preceding item, e.g. political offices, use "replaces" (P1365)〕

P156	followed by	immediately following item in a series of which the subject is a part, preferably use as qualifier of P179 〔if the subject has been replaced, e.g. political offices, use ″replaced by″ (P1366)〕
P159	headquarters location	city, where an organization′s headquarters is or has been situated. Use P276 qualifier for specific building
P161	cast member	actor in the subject production 〔use ″character role″ (P453) and/or ″name of the character role″ (P4633) as qualifiers〕 〔use ″voice actor″ (P725) for voice-only role〕
P162	producer	person(s) who produced the film, musical work, theatrical production, etc. (for film, this does not include executive producers, associate producers, etc.) 〔for production company, use P272, video games - use P178〕
P166	award received	award or recognition received by a person, organization or creative work
P170	creator	maker of this creative work or other object (where no more specific property exists)

P171	parent taxon	closest parent taxon of the taxon in question
P172	ethnic group	subject's ethnicity (consensus is that a VERY high standard of proof is needed for this field to be used. In general this means 1) the subject claims it themselves, or 2) it is widely agreed on by scholars, or 3) is fictional and portrayed as such)
P175	performer	actor, musician, band or other performer associated with this role or musical work
P176	manufacturer	manufacturer or producer of this product
P178	developer	organization or person that developed the item
P179	series	series which contains the subject
P190	sister city	twin towns, sister cities, twinned municipalities and other localities that have a partnership or cooperative agreement, either legally or informally acknowledged by their governments
P194	legislative body	legislative body governing this entity; political institution with elected representatives, such as a parliament/legislature or council

P205	basin country	country that have drainage to/from or border the body of water
P206	located in or next to body of water	body of water on or next to which a place is located
P241	military branch	branch to which this military unit, award, office, or person belongs, e.g. Royal Navy
P264	record label	brand and trademark associated with the marketing of subject music recordings and music videos
P272	production company	company that produced this film, audio or performing arts work
P276	location	location of the object, structure or event. In the case of an administrative entity as containing item use P131. For statistical entities use P8138. In the case of a geographic entity use P706. Use P7153 for locations associated with the object.
P279	subclass of	this item is a subclass (subset) of that item; all instances of this item are instances of that item; different from P31 (instance of), e.g.: K2 is an instance of mountain; volcano is a subclass of mountain (and an instance of volcanic landform).

P355	subsidiary	subsidiary of a company or organization; generally a fully owned separate corporation. Compare with "business division" (P199). Opposite of parent organization (P749).
P361	part of	object of which the subject is a part (if this subject is already part of object A which is a part of object B, then please only make the subject part of object A), inverse property of "has part" (P527, see also "has parts of the class" (P2670))
P364	original language of work	language in which a film or a performance work was originally created. Deprecated for written works and songs; use P407 ("language of work or name") instead.
P400	platform	platform for which a work was developed or released, or the specific platform version of a software product
P403	mouth of the watercourse	the body of water to which the watercourse drains
P449	original network	network(s) or service(s) that originally broadcast a radio or television program

P463	member of	organization, club or musical group to which the subject belongs. Do not use for membership in ethnic or social groups, nor for holding a political position, such as a member of parliament (use P39 for that)
P488	chairperson	presiding member of an organization, group or body
P495	country of origin	country of origin of this item (creative work, food, phrase, product, etc.)
P527	has part	part of this subject; inverse property of "part of" (P361). See also "has parts of the class" (P2670).
P551	residence	the place where the person is or has been, resident
P569	date of birth	date on which the subject was born
P570	date of death	date on which the subject died
P571	inception	time when an entity begins to exist; for date of official opening use P1619
P576	dissolved, abolished or demolished	point in time at which the subject (organisation, building) ceased to exist; see "date of official closure" (P3999) for closing a facility, "service retirement" (P730) for retiring equipment, "discontinued date" (P2669) for stopping a product

P577	publication date	date or point in time when a work was first published or released
P580	start time	time an entity begins to exist or a statement starts being valid
P582	end time	time an entity ceases to exist or a statement stops being valid
P585	point in time	time and date something took place, existed or a statement was true
P607	conflict	battles, wars or other military engagements in which the person or item participated
P674	characters	characters which appear in this item (like plays, operas, operettas, books, comics, films, TV series, video games)
P676	lyrics by	author of song lyrics
P706	located on terrain feature	located on the specified (geo)physical feature. Should not be used when the value is only political/administrative (P131) or a mountain range (P4552).

P710	participant	person, group of people or organization (object) that actively takes/took part in an event or process (subject). Preferably qualify with "object has role" (P3831). Use P1923 for participants that are teams.
P737	influenced by	this person, idea, etc. is informed by that other person, idea, etc., e.g. "Heidegger was influenced by Aristotle"
P740	location of formation	location where a group or organization was formed
P749	parent organization	parent organization of an organization, opposite of subsidiaries (P355)
P800	notable work	notable scientific, artistic or literary work, or other work of significance among subject's works
P807	separated from	subject was founded or started by separating from identified object
P840	narrative location	the narrative of the work is set in this location
P937	work location	location where persons or organisations were actively participating in employment, business or other work

P1001	applies to jurisdiction	the item (institution, law, public office, public register...) or statement belongs to or has power over or applies to the value (a territorial jurisdiction: a country, state, municipality, ...)
P1056	product or material produced	material or product produced by a government agency, business, industry, facility, or process
P1198	unemployment rate	portion of a workforce population that is not employed
P1336	territory claimed by	administrative divisions that claim control of a given area
P1344	participant of	event in which a person or organization was/is a participant; inverse of P710 or P1923
P1365	replaces	person, state or item replaced. Use "structure replaces" (P1398) for structures. Use "follows" (P155) if the previous item was not replaced or predecessor and successor are identical
P1366	replaced by	other person or item which continues the item by replacing it in its role. Use P156 ("followed by") if the item is not replaced nor identical, but adds to the series (e.g. books in a series).

P1376	capital of	country, state, department, canton or other administrative division of which the municipality is the governmental seat
P1412	languages spoken, written or signed	language(s) that a person or a people speaks, writes or signs, including the native language(s)
P1441	present in work	this (fictional or fictionalized) entity, place, or person appears in that work as part of the narration (use P2860 for works citing other works, P361/P1433 for works being part of other works, P1343 for entities described in non-fictional accounts)
P3373	sibling	the subject and the object have at least one common parent (brother, sister, etc. including half-siblings); use "relative" (P1038) for siblings-in-law (brother-in-law, sister-in-law, etc.) and step-siblings (step-brothers, step-sisters, etc.)

부록 2. 지도학습 미세조정을 위한 입력 프롬프트-출력 기댓값 예시

Re-DocRED train 스플릿의 ′Ministry of Home Security′ 문서에서 “John Anderson”과 “British” 간의 관계에 대한 입력 프롬프트-출력 기댓값 예시

입력 프롬프트	### Instruction: Determine the relationship between entity A and B, which are denoted as <entityA>A</entityA> and <entityB>B</entityB> in the sentences. A relationship can be one of the following: head of government, country, place of birth, place of death, father, mother, spouse, country of citizenship, continent, instance of, head of state, capital, official language, position held, child, author, member of sports team, director, screenwriter, educated at, composer, member of political party, employer, founded by, league, publisher, owned by, located in the administrative territorial entity, genre, operator, religion, contains administrative territorial entity, follows, followed by, headquarters location, cast member, producer, award received, creator, parent taxon, ethnic group, performer, manufacturer, developer, series, sister city, legislative body, basin country, located in or next to body of w

	ater, military branch, record label, production company, location, subclass of, subsidiary, part of, original language of work, platform, mouth of the watercourse, original network, member of, chairperson, country of origin, has part, residence, date of birth, date of death, inception, dissolved, abolished or demolished, publication date, start time, end time, point in time, conflict, characters, lyrics by, located on terrain feature, participant, influenced by, location of formation, parent organization, notable work, separated from, narrative location, work location, applies to jurisdiction, product or material produced, unemployment rate, territory claimed by, participant of, replaces, replaced by, capital of, languages spoken, written or signed, present in work, sibling If two entities are not related, please select 'no relationship'. ### Input: Sentences: The Ministry of Home Security was a <entityB>British</entityB> government department established in 1939 to direct national civil defence (primarily tasked with organising air raid precautions) during the Second World War . The Ministry for Home Security was headed by Sir

	<entityA>John Anderson</entityA> the Home Secretary and Minister of Home Security . The Ministry 's responsibilities covered all central and regional civil defence organisations (such as air raid wardens , rescue squads , fire services , and the Women ’s Voluntary Service) . It was also responsible for giving approval to local ARP schemes , and providing public shelters . The Ministry (run under the auspices of the Home Office) produced hundreds of leaflets that were delivered to the population advising on how to deal with the impending air raids . It also managed propaganda poster campaigns to encourage , amongst other things , the carrying of gas masks and for volunteers to join civil defence groups like the Fire Guards . In October 1940 , Sir <entityA>John Anderson</entityA> was replaced by Herbert Morrison in a reshuffle precipitated by Neville Chamberlain 's resignation due to ill - health . With the Allied victory in Europe the Ministry was disbanded in May 1945 . Question: What is the relationship between entity A and B? ### Response:

출력 기댓값	According to the sentence 'The Ministry of Home Security was a British government department established in 1939 to direct national civil defence (primarily tasked with organising air raid precautions) during the Second World War .', and 'The Ministry for Home Security was headed by Sir John Anderson the Home Secretary and Minister of Home Security .', the relationship between entity A and B is 'country of citizenship'.

Abstract

Solving Document-level Relation Extraction Task with Large Generative Language Model

Heekang Park
Interdisciplinary Program in Artifical Intelligence
The Graduate School
Seoul National University

Multiple studies on large generative language models indicate that these models possess significant "knowledge" beyond their understanding of natural language. As a result, there have been ongoing efforts to utilize the knowledge of large generative language models to solve various reasoning problems. On the other hand, document-level relation extraction is a task to identify relationships between entities in texts consisting of more than one sentence and is essential for constructing large-scale knowledge graphs.

In this thesis, we research a method to address document-level relation extraction task using a large generative language model in the "pretraining-prompt-prediction" paradigm. We utilize the LLaMA-7B model released by Meta as our base model. For training, we use the Re-DocRED dataset, which is a training/benchmark dataset for document-level relation extraction. The base model is instruction fine-tuned with input prompt-expected output pairs generated with Chain of Thought. LoRA is used during the training process to facilitate efficient learning.

To validate the performance of the proposed method, we perform various experiments. Firstly, the F1 score on Re-DocRED is measured to be 0.47, which is lower compared to existing approaches based on the "pretraining-finetuning" paradigm. However, we are able to identify the limitations of the dataset as well as evaluation methods through various correct and incorrect answers generated by the model. Furthermore, by comparing the model's performance with and without the use of fine-tuning instructions and Chain of Thought, we confirm that both techniques contribute significantly to the model's performance. In particular, we figure out that we can achieve a recall of 0.73 when fine-tuning the model with a focus on improving recall.

keywords : Large Generative Language Model, Document-level Relation Extraction, Instruction Fine-tuning, Chain of Thought, LoRA
Student Number **: 2021-22918**