

기계 요약의 개체명 사실 수정을 위한

다중 작업 학습 방법 제안

신정완, 노윤석, 박상현, 오영선, 박세영

경북대학교 컴퓨터학부

harryshin88@gmail.com, ysnoh@gmail.com, hun340312@naver.com,

plusmates@naver.com, seyoung@knu.ac.kr

Multi-task learning for entity-centric fact correction on machine summaries

JeongWan Shin, Yunseok Noh, SangHeon Park, YoungSun O, Seyoung Park
Kyungpook National University, School of Computer Science and Engineering

요약

기계요약의 사실 불일치는 생성된 요약이 원문과 다른 사실 정보를 전달하는 현상이며, 특히 개체명이 잘못 사용되었을 때 기계요약의 신뢰성을 크게 훼손한다. 개체명의 수정을 위해서는 두 가지 작업을 수행해야 한다. 먼저 요약 내 각 개체명이 올바르게 쓰였는지 판별을 해야 하며, 이후 잘못된 개체명을 맞게 고치는 작업이 필요하다. 본 논문에서는 두 가지 작업 모두 각 개체명을 문맥적으로 이해함으로써 해결할 수 있다고 가정하고, 이에 따라 두 작업에 대한 다중 작업 학습 방법을 제안한다. 제안한 방법을 통해 학습한 모델은 생성된 기계요약에 대한 후처리 교정을 수행할 수 있다. 제안 모델을 평가하기 위해 강제적으로 개체명을 훼손시킨 요약데이터와 기계 요약 데이터에 대해서 성능을 평가 하였으며, 다른 개체명 수정 모델과 비교하였다. 제안모델은 개체명 수준에서 92.9%의 교정 정확도를 달성했으며, KoBART 요약모델이 만든 기계요약의 사실 정확도 4.88% 포인트 향상시켰다.

주제어: 기계 요약, 사실 불일치 교정, 다중 작업 학습

1. 서론

자연어 처리 분야 중 하나인 기계 문서 요약은 딥러닝이 발전함에 따라 좋은 성능을 보여주고 있다. 그럼에도 불구하고 여전히 기계 문서 요약에서는 여러 가지 문제점들이 있다. 그중 하나는 원문 대비 사실관계가 틀린 개체명을 생성한다는 것이다. 예를 들어 표1에서 원문과 다른 사실관계를 가진 “니시마쓰건설” 개체명을 생성한 거짓 기계 요약은 잘못된 정보를 전달할 수 있다. 그렇기 때문에 생성된 요약을 원문과 비교하여 잘못된 개체명이 무엇인지 인식하는 것이 중요하며, 잘못된 개체명을 원문과 사실관계가 일치하는 개체명으로 수정함으로써 기계 요약문의 사실적 일관성을 높일 필요가 있다.

이전 연구들에서는 거짓 요약의 개체명 오류를 수정하기 위한 다양한 시도들이 있었다[1,2,3,4,5,6,7]. 한국어에서는 사실 관계가 잘못된 개체명을 수정하기 위해서 각 개체명의 문맥적 의미표현(문맥의미표현)을 사용하여 수정하는 연구가 있었다[7]. 개체명의 문맥의미표현을 만들기 위해 사전 학습된 BERT모델의 출력에 트리플넷 네트워크(Triplet Network)를 사용하여 개체명 문맥의미표현을 학습하도록 재학습하였다. 그리고 요약과 원문의 개체명 문맥의미표현 간 비교를 통해 적합한 개체명으로

표 1. 기계 요약

원 문	... 니카이도시히로(二階俊博) 경제산업상 등 “자민당” 인사까지 수사를 확대하기로 하면서 여야 간 희비가 교차되고 있다. ... 모리 요시로(森喜朗) 전 총리 등의 정치조직도 “니시마쓰건설”의 정치단체로부터 정치자금을 받은 만큼 수사 대상이 될 공산이 크다.
기계요약	• “니시마쓰건설”에 대한 검찰 수사를 확대하면서 여야 간 희비가 교차하고 있다.

수정하였다. 하지만 개체명 문맥의미표현 모델[7]은 개체명 수정에만 집중하였으며, 사실 관계가 일치하는 개체명도 수정될 수 있다. 또한 모든 개체명을 비교해야 되기 때문에 계산 복잡도가 높다는 단점이 있다.

본 논문에서는 거짓 요약의 개체명을 수정하는 작업

이외에 추가적으로 원문과 비교해 사실관계의 참, 거짓을 판별하는 문제를 풀 필요가 있다고 제안한다. 즉 개체명 수정과정은 사실 판별과정과 수정과정이라는 두 가지 과정이 필요하다. 첫 번째 과정은 개체명 사실 일치 판별 과정을 통해 개체명에 대한 수정 여부를 결정해야 하며 두 번째 과정은 수정이 필요한 요약문 내 개체명을 원문에서 적합한 개체명으로 교체하는 것이다. 두 과정 모두 각 개체명을 문맥적으로 이해하여야 한다. 예를 들어 표1에서 기계 요약의 개체명인 “니시마쓰건설”이 사실 일치 개체명인지 확인하기 위해서는 “니시마쓰건설”이 원문에서 나타나는 문맥의미를 살펴보아야 한다. 원문의 “니시마쓰건설”은 문맥상 “정치자금을 (자민당에게) 조달한” 업체라고 이해할 수 있으며, 수사 대상이 되는 개체는 “모리 요시로 전 총리 등의 정치조직”이다. 문맥의미를 비교하였을 때 기계요약에 생성된 개체명 “니시마쓰건설”은 사실관계가 거짓으로 판별된다. 거짓으로 판별되면 다음 단계인 개체명 수정 과정을 통해 원문과의 사실 관계가 적합한 개체명으로 수정해야 한다. 원문에서 “자민당” 개체명을 포함하는 문장으로부터 문맥의미를 이해하여 보았을 때 수사를 받을 개체가 “자민당”이라는 것을 알 수 있으며, 기계요약의 개체명 “니시마쓰건설”은 “자민당”으로 고칠 수 있다. 두 과정 모두 개체명 문맥의미를 이해하여야 한다는 공통적인 부분이 존재하며, 사실 판별과 수정이라는 서로의 목적의 차이가 있다.

본 논문에서는 두 과정을 개체명 수정 모델에 적용하기 위한 방법으로 다중 작업 학습(Multi-Task Learning)을 제안한다. 제안하는 방법은 먼저 기계 요약문과 그 원문 내 개체명의 의미표현(Meaning Representation)을 문맥에 따라 달리 표현한다. 제안 모델은 BERT에 기반한 문맥의미표현 네트워크 위에 개체명 사실 일치 판별 작업과 개체명 수정 작업에 대한 다중 작업 학습을 수행한다. 개체명 사실 일치 판별 모델은 개체명의 문맥의미표현을 사용하여 이진 분류(Binary Classification)를 통해 참, 거짓으로 판별하도록 학습하며, 개체명 수정 모델은 트리플넷 네트워크(Triplet Network)를 사용해 문맥의미표현이 가장 일치하는 개체명으로 수정하도록 학습한다. 개체명 사실 판별과 수정은 개체명 문맥의미를 이해해야 된다는 공통적인 부분을 반영하여 모델의 일부분인 사전학습된 BERT모델을 공유하도록 설정하였다. 또한 서로의 목적이 다르므로 다중 작업 학습(Multi-Task Learning)방법을 사용하여 서로 다른 결과를 만들도록 학습하였다.

제안 모델은 추가적으로 개체명 사실 일치 판별 모델의 지식을 개체명 수정 모델 학습에 활용하도록 전달하는 지식 전달(knowledge transfer) 방법을 고안하여 다중 학습에 새로이 적용한다. 개체명 수정 모델은 트리플넷 손실(Triplet Loss)를 사용하여 문맥의미표현이 일치하는 개체명끼리는 손실이 작게 하고 일치하지 않는 것끼리는 손실이 크게 한다. 이때 개체명 사실 일치 판별 모델을 통해 문맥의미가 일치하지 않는 데이터 중 판별하기 가장 어려운 개체명을 부정 개체명으로 하여 지식 전달을 한다. 부정 개체명은 사실 불일치 개체명이지만 문맥의미표현이 일부 일치하여 혼돈을 주는 개체명이다.

지식 전달 방식을 통해 개체명 수정모델이 강건한 학습을 하게 된다면, 조금 더 복잡한 문맥의미표현을 학습할 수 있다.

제안하는 모델의 개체명 사실 확인 성능과 수정 성능을 확인하기 위해 국어국립원의 문서 요약 데이터 4389개 중 4000개를 활용하여 학습하였으며, 나머지 389개를 테스트 데이터로 사용하였다. 정답 요약문에서 개체명만 원문의 다른 개체명으로 바꾼 데이터(강제 개체명 훼손 데이터)와 KoBART 기계 요약 데이터를 만들어서 성능을 측정하였으며 개체명 문맥의미표현 학습 모델[cite]과 비교 하였다. 강제 개체명 훼손 데이터는 개체명 별과 문장 별로 나누어 성능 측정을 하였고, [7]보다 4.6%, 5.3% 포인트의 성능향상이 있었다. KoBART 기계 요약은 사람이 평가하여 수정 전과 수정 후의 성능을 측정하였으며, 사실 관계에서 약 5% 포인트가 향상되었다.

2. 관련 연구

2.1 문맥 의미 표현

최근 연구들은 여러가지 작업에 맞는 문맥표현을 만들려고 노력해왔다. ELMo[8], BERT[9], GPT-2[10]등은 사전 훈련된 언어모델(Pre-Trained Language Model)을 사용하는 임베딩(Embedding) 방식을 제안하였다. ELMo[8]는 양방향 언어 모델링(bidirectional language modeling)작업에 대해 훈련된 2계층 biLSTM을 사용하여 각 단어의 문맥표현을 만들도록 하였다. BERT 및 GPT-2는 각각 양방향 및 단방향 트랜스포머(Transformer)[11]기반 언어 모델이다. BERT는 대규모의 말뭉치를 학습하여 효과적인 임베딩(Embedding) 표현을 하도록 사전 학습(Pre-Trained) 후 다양한 작업에 맞춰 정밀 학습(Fine-tuned)하여 사용할 수 있는 모델이다. BERT 및 BERT를 사용한 후속 모델은 문맥을 표현하기 위해 노력해 왔으며, 효과적인 문맥의 표현을 통한 다양한 자연어처리 다운스트림에서 최첨단 성능을 달성하였다. 한국어에서도 개체명 문맥의미표현 학습 모델[7]은 대규모의 한국어 말뭉치로 학습한 BERT를 사용하여 개체명의 문맥의미표현을 했었다. 한국어 모델은 훌륭한 성능을 보여주었으며, 본 논문에서 제안하는 모델도 문맥의미표현을 사용하기 위해 한국어 BERT 모델을 사용한다.

2.2 사실 불일치 해소

최근 연구에서는 요약의 사실적 일관성을 보장하는 새로운 방법을 제안했다.[1][2]은 지식 트리플(Knowledge Triples)시스템을 이용한 RNN과 트랜스포머(Transformer)기반 디코더를 각각 제안하였다. [3]은 합의 보상(Entailment Reward)을 사용한 최대 가능성(Maximum Likelihood) 훈련 목표를 제안하였고 [4]은 소스에 대한 합의 점수(Entailment Scores)를 기반으로 빔 서치(Beam Search) 결과의 순위를 재지정할 것을 제안하였다. 또한 기계 요약을 사후 처리하여 사실 불일치를 해소하는 연

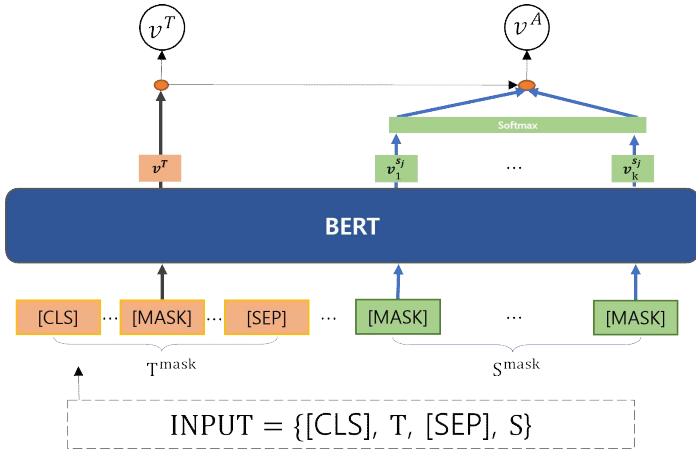


그림 1. 객체명 문맥의미표현 모델

구들이 있었다[5][6]. [6]의 모델은 질의응답(Question Answering)모델로 부터 영감을 받아 요약의 개체명을 마스크토큰([MASK])하여 원문으로부터 마스크토큰과 대체할 적합한 부분을 찾아 변경한다. [5]의 경우 기계 요약과 원문을 인코더(Encoder)에 입력으로 넣어 디코더(Decoder)가 원문과 일치하는 요약을 다시 생성하도록 재학습하였다. 한국어 사실 불일치 해소 연구에는 개체명 문맥의미표현을 학습하여 개체명의 사실 불일치를 수정하는 연구가 있었다[7]. 개체명 문맥의미표현을 사용하여 좋은 성능을 보여주었으나 모델 특성상 모든 개체명에 대해 수정을 시도 하며, 계산 복잡도가 높은 단점이 있었다.

3. 제안 모델

본 논문에서 3.1) 개체명의 문맥의미표현과 3.2) 개체명 사실 확인 모델, 3.3) 개체명 수정 모델을 제안한다. 또한 두 가지 모델은 서로 학습 파라미터(Parameter)를 공유 학습하기 위한 방법으로 3.4)다중 작업 학습(Multi-Task Learning)제안한다. 그리고 개체명 사실 확인 모델의 신뢰도(Confidence)를 바탕으로 네거티브 샘플링(Negative Sampling)하여 3.3)개체명 수정 모델의 강건한 학습 방식을 제안한다.

3.1 개체명의 문맥의미표현

제안하는 모델에서는 개체명의 사실 여부 판단과 수정을 위해서 그림1에서처럼 사전 학습된 한국어 BERT모델로 개체명 문맥의미표현을 한다. 원문의 다른 문장에 있는 동일한 개체명의 문맥이 상이할 수 있다라고 주장한 것[7]과 대조적으로 제안하는 모델은 원문에서 개체명이 가지는 전체적인 문맥의미를 이해하기 위해 어텐션 메커니즘(Attention Mechanism)을 사용하여 원문의 동일한 모든 개체명을 아우르는 문맥의미표현을 만든다.

요약문 T 와 T 에 포함된 N 개의 개체명들을

$E^T = \{e_1^T, e_2^T, \dots, e_i^T\}$ 라고 하자. 그리고 M 개의 서로다른 개체명을 포함하는 원문 S 가 주어졌을 때, 특정 개체명 e_j^S 를 포함하는 K 개 문장들의 시퀀스를 $S_j = (s_1, \dots, s_K)$ 라고 하면 S_j 에는 L 개의 e_j^S 가 포함될 것이다. 여기서 s_k 는 각 문장을 의미하며 $L \geq K$ 가 항상 성립한다. 요약문의 한 개체명 e_i^T 와 원문의 특정 개체명 e_j^S 에 대한 문맥의미표현을 함께 얻기 위해 T 와 S_j 를 먼저 BERT에 입력한다. 이때 T 와 S_j 에 포함된 모든 e_i^T 와 e_j^S 는 [MASK]로 대체하여 T^{mask} , S_j^{mask} 를 만든다. 그 이유는 개체명의 직접적인 의미보다 문맥의미에 집중하기 위해서 [MASK]로 대체한다. 시작 토큰으로 [CLS]와 구별토큰으로 [SEP]를 사용하여 입력 시퀀스 $INPUT = ([CLS], T^{mask}, [SEP], S_j^{mask})$ 를 만든다. 그런 다음 T^{mask} 의 [MASK] 된 위치를 BERT 모델로부터 출력 받는다. 이것을 요약 개체명 문맥의미표현 v 이라 한다. 그리고 S_j^{mask} 의 L 개의 e_j^S 가 대체된 모든 [MASK]로부터 만들어진 원문 문맥의미표현 v^A 이라고 한다. v 는 v 를 쿼리로 사용하여 수식 (4)의 닷-프로덕트 어텐션(Dot-Product Attention)연산을 통해 e_j^S 중 가장 중요한 개체명에 비중을 크게 두게 한다. 그리하여 e_j^S 에 대한 최종 문맥의미표현은 v^A 가 된다.

$$w, \alpha^k = \frac{\exp(w_{ik})}{\sum_{t=1}^k \exp(w_{it})}, v^A = v_{ij}^S = \sum_{k=1}^K \alpha^k w_{ik} \quad (4)$$

3.2 개체명 사실 일치 판별 모델

개체명 사실 판별 모델(Fact-Checking, FC)은 요약의 개체명을 원문과 비교하여 사실 관계를 판별한다. 그림2는 제안하는 모델의 전체 설계도이며, 모델 상단의 왼쪽 부분이 개체명 사실 확인 모델이다. FC는 문맥의미표현 모델의 출력인 문맥의미표현 v, v^A 를 받아 연결(Concatenation) 한 뒤 2개의 밀집층(Dense Layer)과 시그모이드(Sigmoid)를 통과하여 참 또는 거짓으로 출력하는 이진 분류를 한다. 개체명 사실 일치 확인 모델이 참으로 판별할 경우 수정을 하지 않으며, 거짓으로 판별할 경우 개체명 수정 모델을 통한 수정을 진행한다.

3.3 개체명 수정 모델

요약의 개체명이 거짓이라고 판별되면, 원문에 있는 적합한 개체명으로 수정이 필요하다. 개체명 수정 모델은 요약 개체명 문맥의미표현과 가장 유사한 원문 개체명 문맥의미표현을 찾아 수정하는 모델이다.

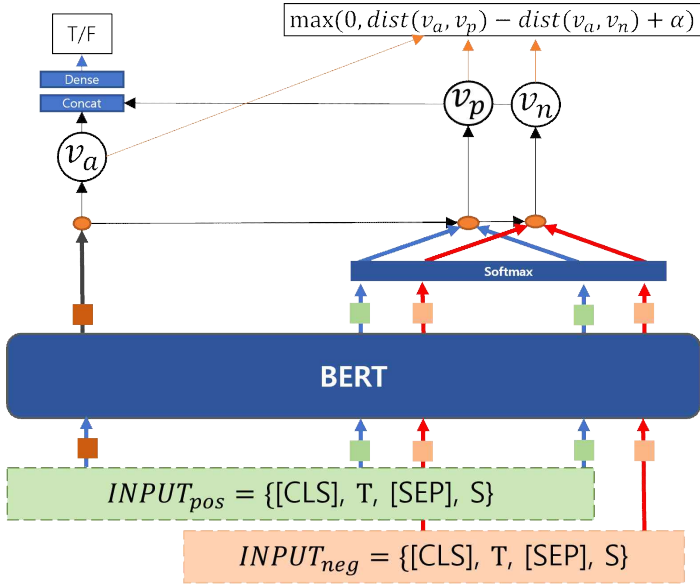


그림 2. 개체명 사실 수정을 위한 다중 작업 학습 모델

$$v_{best}^A = \underset{v_m^A \in NV^A}{\operatorname{argmin}} (\operatorname{dist}(v_n^T, v_m^A)),$$

$$\operatorname{dist}(a, b) = \|a - b\|_2 \quad (6)$$

개체명 수정은 3.1) 모델을 통해 얻는 문맥의미표현으로 수행한다. 먼저 요약 T 의 수정하고자 하는 개체명 e_i^T 에 대해 원문 S 에서 e_i^T 와 일치하지 않는 모든 후보 개체명 $E^S = \{e_1^S, e_2^S, \dots, e_j^S\}$ 으로 각각의 INPUT을 만든다. 모든 INPUT은 각각 문맥의미표현 V 와 V 를 생성한 뒤 v 와 v 의 거리를 측정한다. 그렇게 하여 수식(6)에서처럼 거리가 가장 가까운 v_{best}^A 를 찾아 해당되는 개체명으로 수정한다.

3.4 다중 작업 학습(Multi-Task Learning)

앞서 제안한 개체명 사실 확인 모델과 개체명 수정 모델은 개체명의 주변 문맥을 이해 해야된다는 동일한 관점에서 그림2 처럼 3.1)개체명의 문맥의미표현의 BERT 모델을 공유하도록 설정한다. 또한 사실 확인과 수정이라는 서로의 목적이 다르므로 다중 작업 학습(Multi-Task Learning)을 하도록 설정하였다. 추가적으로 개체명 수정 모델의 강건한 학습을 위해 개체명 사실 확인 모델의 지식 전달(knowledge transfer)방법을 고안한 네거티브 개체명을 선택한다.

다중 작업 학습은 먼저 개체명 사실 일치 확인 모델을 학습한다. T 의 특정 개체명 e_i^T 에 대해 S 의 e_j^S 가 동일

표 2. 강제 훼손 데이터 사실 확인 및 수정 실험 결과

	사실 확인 성능		개체명 수정 성능	
	개체명 별	문장 별	개체명 별	문장 별
준모 모델	-	-	88.3	77.1
제안 모델	98.6%	86.4%	92.9	82.4

하고 e_i^T 와 e_j^S 의 문맥의미는 일치한다고 가정하자. e_i^T 와 e_j^S 를 사용하여 입력 시퀀스 $INPUT_{pos}$ 을 만들어 3.1에서 설명한 문맥의미표현을 만든다. $INPUT_{pos}$ 에 대해 개체명 사실 일치 판별 모델은 참으로 판별하도록 학습하며, 이와 반대로 개체명 사실 일치 판별 모델은 T 의 특정 개체명 e_i^T 에 대해 S 의 e_j^S 가 동일하지 않고 e_i^T 와 e_j^S 의 문맥의미는 일치하지 않을 때는 입력 시퀀스 $INPUT_{neg}$ 를 만들고 거짓으로 판별한다. 수식(7)은 이진교차엔트로피 손실(Binary Cross Entropy Loss)이며, y_i 는 정답값, FC_{out} 은 사실 일치 확인 모델의 출력값이다. 사실 일치 확인 모델 학습 후 e_i^T 를 제외한 $E^S = \{e_1^S, e_2^S, \dots, e_j^S\}$ 에 대해 $FC_{score}^{E^S} = \{FC_{score}^{e_1^S}, \dots, FC_{score}^{e_n^S}\}$ 를 얻는다. 수식(8)에서 E^S 중 가장 높은 값으로 가지는 부정 개체명을 e_{NEG}^S 를 선택하여 다음 학습 단계인 개체명 수정 모델에 부정 개체명으로 사용한다. 개체명 문맥의미표현은 e_i^T 와 e_{NEG}^S 를 사용하여 문맥의미표현 (V_a, V_p, V_{neg}) 를 얻는다. 개체명 수정 모델은 (V_a, V_p, V_{neg}) 사용해 수식(8)과 같이 트리플넷 손실(Triplet Loss)을 계산한 뒤 3.3)개체명 수정 모델을 업데이트 한다.

$$BCE_{loss} = -\frac{1}{N} \sum_{i=1}^N (y_i \cdot \log(FC_{out}) + (1 - y_i) \cdot \log(1 - FC_{out})) \quad (7)$$

$$e_{NEG}^S = \operatorname{argmax}_{E_j^S \in E^S} (FC_{score}^{E_j^S}) \quad (8)$$

$$Triplet_{loss} = \max(\|v_a - v_p\|_2 - \|v_a - v_{NEG}\|_2 + \alpha, 0) \quad (9)$$

4. 실험

4.1 실험 설정

학습데이터는 국어국립원의 문서 요약 데이터 4389개로부터 389개를 테스트데이터로 사용했다. 테스트 데이터는 개체명 강제 훼손 데이터와 SKT KoBART¹⁾로 부터 기계 요약 데이터를 생성 하였다. 강제 훼손 데이터의

1) <https://github.com/SKT-AI/KoBART>

경우 포로로(PORORO)²⁾로 요약과 원문의 개체명을 검출

표 3. 사람 평가 결과

	KoBART	개체명문맥 의미표현모델	제안 모델
사실 관계 정확도	72.49%	75.57%	77.37

한 뒤 요약의 개체명과 다른 원문의 개체명으로 대체하여 사실관계가 거짓인 데이터를 만든다.

실험에 사용한 파라미터는 다음과 같다. 3.1)개체명 문맥의미표현을 위해 사전 학습된 한국전자통신연구원에서 배포한 BERT와 닷-프로덕트 어텐션(Dot-Product Attention)을 사용하였다. 3.2)개체명 사실 확인모델은 추가로 2개의 밀집층(Dense Layer)과 시그모이드(Sigmoid)함수를 사용하였다. 이 모델은 학습을 위해 배치크기를 4로하는 미니 배치 학습을 사용하였으며, 학습률은 0.00001, 옵티마이저(Optimizer)로 아담(Adam)을 사용하였다. 학습 횟수(Epoch)는 10회 학습 하였다.

4.2 강제 훼손 데이터 실험 결과

이번 장에서는 제안한 모델의 강제 훼손 데이터에 대한 개체명 사실 확인 성능과 개체명 수정 성능을 보여준다. 개체명 수정 성능에 대해 [7]과 비교하였으나, 개체명 사실 확인 성능 모델이 없는 관계로 비교하지 못하였다. 389개의 테스트 데이터는 원문당 3개의 요약을 가지고 있으며 요약당 개체명은 평균 5개이다. 요약 하나당 개체명 하나를 훼손하여 5728개의 개체명별 강제 훼손 데이터를 만들어 개체명 사실확인 정확도를 측정하였다. 또한 요약 안에 전체 개체명에 대해 50% 확률로 훼손하여 2개 이상의 훼손 개체명을 가지는 1152개 문장별 훼손 데이터를 만들어 정확도를 측정하였다. 표2에서 본 논문의 개체명 사실 확인 실험 결과를 확인할 수 있다. 개체명 별 정확도는 하나의 개체명의 참, 거짓을 맞춘 성능이며 정확도는 98.6%가 측정되었다. 문장 별 정확도는 문장의 모든 개체명의 참, 거짓을 맞춘 성능으로 83.4%가 측정되었다.

강제 훼손 데이터에 대한 수정 성능은 표3에서 보여준다. 개체명 별 수정 정확도는 92.9%이며, 문장 별 수정 정확도는 82.4%가 측정되었다. 문장 별 수정 정확도가 떨어지는 이유는 개체명의 예러가 많을수록 수정 성능이 떨어질 수 있다는 것이다.

4.3 사람 평가 결과

기계 요약의 개체명 수정 성능을 평가하기 위해서 우

리는 389개의 테스트 데이터에 대해서 SKT KoBART 기계 요약을 생성하였다. 그 다음 기계요약에 대해 3명의 사람에게 개체명 사실 관계 평가를 진행하였고 제안 모델

표 4. 다중 학습 유무에 대한 성능 비교

	개체명 수정 모델만 학습	다중 작업 학습
강제 훼손 데이터 개체명 별 정확도	90.4%	92.9%
강제 훼손 데이터 문장 별 정확도	79.2%	82.4%
KoBART 기계요약 사람 평가 사실 관계 정확도	75.57%	77.37

를 사용하여 기계요약을 수정 후 사실 평가를 하였다. 사실 관계 평가는 원문과 요약문을 비교하여 사실관계가 일치하면 참, 일치하지 않으면 거짓이라고 평가하였다.

사람 평가 결과는 표3에서 확인할 수 있다. KoBART의 사실 관계 평가는 72.49%이며 제안 모델은 77.37%로 약 5% 포인트의 사실 관계가 향상되었다. 개체명 문맥의미 표현 모델보다도 1.8% 포인트의 성능향상이 있었다.

4.4 다중 작업 학습

다중 작업학습의 필요성을 증명하기 위해 다중 작업 학습을 진행하지 않은 개체명 수정 모델만 학습한 모델과 다중 작업 학습을 진행한 모델의 성능을 비교하였다.

그 결과 강제 훼손 데이터에 대한 개체명 별 정확도는 2.5% 포인트 높게 나왔으며, 문장 별 정확도는 3.2% 포인트가 높게 측정되었다. 그리고 KoBART 기계요약으로 사실관계 정확도를 사람 평가 시행한 결과에서도 1.8% 포인트 향상이 있었다.

5. 결론

우리는 기계 요약의 개체명 수정을 통해 사실성 일관성을 높이는 연구를 진행하였다. 그리고 강제 훼손 데이터와 기계 요약에 대한 사람 평가를 통해 제안한 모델의 우수성을 보여주었다. 하지만 명사구, 동사, 절, 등의 불일치를 해결하지는 못하였다. 또한 강제 훼손데이터와 실제 기계요약 데이터에 대한 성능 차이가 있었다. 이것은 기계 요약의 성능에 따라 개체명 수정 성능이 의존적일수 있다는 문제가 있다. 향후 연구로는 위 문제들을 해결 할 수 있는 방안들을 생각해 볼 것이다.

감사의 글

이 논문은 2021년도 정부(과학기술정보통신부)의 재원

2) <https://github.com/kakaobrain/pororo>

으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2016-0-00145, 어떤 주제에 대한 빅데이터를 스마트 보고서로 요약하는 기술 개발)

of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020.
[6] Yue Dong, Shuohang Wang, Zhe Gan, Yu Cheng,

표 9. 개체명 다중 작업 학습 모델의 수정 결과

원문	문재인 정부 429조 예산안 확정, 큰 정부로 방향 전환 [한겨레] 2018년 예산안 뜯어보니... 본예산 대비 7.1%, 9년 만에 최고 증가율 복지예산 크게 늘고, SOC예산은 20% 감소 공무원 1만5천명 증원, 아동수당·기초연금 배정 추경안 대비론 4.8%, 재정건전성은 오히려 개선 문재인 정부가 429조원 규모의 내년 예산안을 확정하고, 일자리 창출과 복지 확대를 위한 적극적 재정정책으로의 전환을 공식화했다. 정부는 29일 국무회의를 열어, 2017년 본예산 (400조5천억원)에 견줘 7.1%(28조5천억원) 늘어난 ‘2018년 예산안’ 을 확정 의결했다. 글로벌 금융위기에 대응하기 위해 대규모 적자예산을 편성한 2009년(10.6%) 이후로 9년 만에 가장 높은 증가율이다. ...
기계요약	문재인 정부가 정부는 29일 국무회의를 통해 본예산 대비 7.1% 증가한 28조5천억원 규모의 내년 예산안을 확정 의결 의결했으며, 이는 9년 만에 최고 증가율이다.
제안모델	문재인 정부가 정부는 29일 국무회의를 통해 본예산 대비 7.1% 증가한 429조원 규모의 내년 예산안을 확정 의결 의결했으며, 이는 9년 만에 최고 증가율이다.

참고문헌

[1] Ziqiang Cao, Furu Wei, Wenjie Li, and Sujian Li. Faithful to the original: Fact aware neural abstractive summarization. In Thirty-Second AAAI Conference on Artificial Intelligence. 2018.
[2] Chenguang Zhu, William Hinthorn, Ruochen Xu, Qingkai Zeng, Michael Zeng, Xuedong Huang, and Meng Jiang. Boosting factual correctness of abstractive summarization with knowledge graph. arXiv preprint arXiv:2003.08612. 2020.
[3] Haoran Li, Junnan Zhu, Jiajun Zhang, and Chengqing Zong. Ensure the correctness of the summary: Incorporate entailment knowledge into abstractive sentence summarization. In Proceedings of the 27th International Conference on Computational Linguistics, pages 1430-1441. 2018.
[4] Tobias Falke, Leonardo FR Ribeiro, Prasetya Ajie Utama, Ido Dagan, and Iryna Gurevych. Ranking generated summaries by correctness: An interesting but challenging application for natural language inference. In Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics, pages 2214-2220. 2019.
[5] Cao Meng, Yue Cheung Dong, Jiapeng Wu, and Jackie Chi Kit.

Jackie Chi Kit Cheung JingJing Liu. Multi-Fact Correction in Abstractive Text Summarization. In Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP). 2020.
[7] 박준모, “개체명 문맥의미표현 학습을 통한 기계 요약의 사실 불일치 교정” 제32회 한글 및 한국어 정보처리 학술대회 논문집, 2020년
[8] Matthew Peters, Mark Neumann, Mohit Iyyer, Matt Gardner, Christopher Clark, Kenton Lee, and Luke Zettlemoyer. Deep contextualized word representations. In Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers). pages 2227-2237. 2018.
[9] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805 . 2018.
[10] Alec Radford, Jeff Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. 2019. Language models are unsupervised multitask learners .
[11] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention is all you need. In Advances in Neural Information Processing Systems, pages 6000-

6010. 2017.