

# 엔티티 중심 멀티 턴 대화 증강을 이용한 Dense Retrieval

박준범<sup>o</sup>, 나승훈 [전북대학교 인지컴퓨팅 연구실]  
홍범석, 최원석, 한영섭, 전병기 [LG 유플러스]

# 서론

---

## [검색 모듈 성능 개선의 중요성]

- 1) 사용자가 입력한 발화에 답변을 하기 위해 해당 정보를 가지고 있는 문서를 찾는다.
- 2) 찾은 문서의 정보를 이용하여 적절한 답변을 생성한다.  
-> 적절한 문서를 찾는 검색 모듈의 성능이 최종 답변 생성에 영향을 미친다.

## [문서 기반의 대화 데이터 생성의 필요성]


- 검색 모듈로 Dense Passage Retrieval 방식을 사용할 경우
- 모델 학습에 필요한 문서 기반 대화 데이터 셋 양의 한계  
-> 문서를 보고 진행된 두 턴 이상의 대화 데이터 증강 방식의 필요성 발생

## [데이터 생성, 성능 개선 방식 제안]

- 1) 문서로부터 Named Entity Recognition 작업을 통한 엔티티 추출
- 2) 추출한 엔티티를 답변으로 삼는 질문을 T5-base 모델로부터 생성
- 3) 생성된 질문들을 조합하여 두 턴의 대화 데이터 조합
- 4) 조합된 대화 데이터를 필터링 과정을 거쳐 DPR 사전학습에 적합한 학습 데이터로 증강

# Dense Passage Retrieval

## [학습 개요]



- 질문-문서의 Similarity


$$\text{sim}(\mathbf{q}, \mathbf{p}) = \mathbf{E}_Q(\mathbf{q})^T \mathbf{E}_P(\mathbf{p})$$

- In-Batch Cross Entropy loss

$$\begin{aligned} \mathcal{L}(q_i, p_i^+, p_{i,1}^-, \dots, p_{i,n}^-) \\ = -\log \frac{e^{\text{sim}(q_i, p_i^+)}}{e^{\text{sim}(q_i, p_i^+)} + \sum_{j=1}^n e^{\text{sim}(q_i, p_{i,j}^-)}} \end{aligned}$$

# 엔티티 기반 싱글 턴 대화 생성

[엔티티 기반 싱글 턴 질문 생성 개요]



# 엔티티 기반 멀티 턴 대화 생성

## [엔티티 기반 멀티 턴 대화 생성 개요]

### Passage

How to change your beneficiaries or reduce, turn down, or restore your SGLI coverage If you re a member of the **Army**, Navy, Air Force, Marines, Coast Guard, please submit your changes online through the SGLI **Online Enrollment System** SOES...

⋮

### Passage

Can I get disability benefits from **VA**? You may be able to get disability benefits if you have a disability believed to be caused by contact with mustard gas or lewisite and your military record shows you had contact with mustard gas or lewisite. If you were in the **Army** and served in these places : **Bari** , Italy Bushnell...

T5-Base

### Generated Question

Question 1 : "Which military branch does the SGLI Online Enrollment System apply to?"  
Answer1 : **Army**

Question 2 : ~~~  
Answer2 : **Online Enrollment System**

⋮

### Generated Question

Question 1 : ~~~  
Answer 1 : **VA**

Question 2 : ~~~  
Answer 2 : **Army**

Question 3 : "Where was the **Army** Camp Lejeune located?"  
Answer 3 : **Bari**

## Multi-turn Dialogue

Question 1  
"Which military branch does the SGLI Online Enrollment System apply to?"

"Army"

Question 2  
"Where was the **Army** Camp Lejeune located?"

"Bari"

## Augmented Input Data

Current\_utterance : Question 1

★ Utterance\_History : Question 1, "Army"  
Current\_utterance : Question 2

# 대화 데이터 증강

## [선행 질문에 대한 후속 질문 필터링 규칙]

- 정답 엔티티가 문장에 포함되어 있는 경우 제외.
- 문장 발생 빈도가 높은 경우의 엔티티 제외. Ex) ['Social Security', 245346], ['one', 107371], ['New York', 83873]
- 선행 질문과 후속 질문의 정답을 포함하는 passage가 서로 같은 경우 제외.
  - > 다른 passage에서 후속 질문을 선택함으로써 선행 질문의 passage로부터 알 수 없는 정보를 학습에 제공.
  - > 검색 기능 학습에 변별력 부여 기대.

## [생성된 질문 데이터 셋]

- 기존 데이터 구성 : 1) passage – 3,820 2) 엔티티 – 4,640 // 학습 데이터 셋 : **21,451**
- 싱글 턴 데이터 생성 : 18,261 
- 멀티 턴 데이터 조합 : 약 3,400,000
- 필터링 이후 증강된 데이터 셋 : **약 340,000**



# Dense Retrieval 증강 실험

---

## [실험 세팅]

- 배치 사이즈-128, 학습률- 2e-05, Optimizer-Adam, In Batch negative
- Epoch - baseline 및 파인 튜닝 : 30 epoch, 사전학습 : 10 epoch
- Dataset - MultiDoc2Dial
- Metric - MRR(Mean Reciprocal Rank) , R@K (Recall at top-k)

## [증강 데이터 사전학습을 추가한 DPR]

- 생성한 질문들 중 무작위로 선정한 20,000개의 멀티 턴 대화 사전학습 데이터를 구성.  
각각의 멀티 턴 대화마다 총 두개의 입력 데이터 1){선행 질문} // 2){대화 기록[선행 질문, 정답 엔티티], 후속 질문}
- 40,000개의 학습 데이터를 이용한 사전학습은 RoBERTa-base를 인코더로 삼아 10 Epoch 진행, 기존 데이터로 미세 조정하여 baseline 성능과 비교.

## [증강 데이터 수에 따른 DPR 성능]

- 증강 데이터의 수를 실험마다 10,000개, 20,000개, 30,000개로 다르게 하여 증강 데이터 수에 따른 성능의 변화 확인.

# Dense Retrieval 증강 실험 결과

[증강 데이터 사전학습을 추가한 DPR 성능]

|                                 | MRR          | Recall@1     |
|---------------------------------|--------------|--------------|
| RoBERTa-base                    | 58.97        | 46.11        |
| Pretrain with Data Augmentation | <b>60.35</b> | <b>47.70</b> |

- 증강 데이터로 사전학습 후 기존 데이터로 미세조정된 결과, baseline보다 높은 성능 확인

[증강 데이터 수에 따른 DPR 성능 변화]

| Number of Augmented Data | MRR          | Recall@1     |
|--------------------------|--------------|--------------|
| 10,000                   | 60.11        | 47.14        |
| 20,000                   | 60.19        | 47.19        |
| 30,000                   | 60.22        | 47.38        |
| 40,000                   | <b>60.35</b> | <b>47.70</b> |

- MRR 지표의 경우 최소 1.1%p, Recall 지표의 경우 최소 1%p의 상승
- 증강 데이터 수 증가에 따른 성능의 상승치도 확인 가능

# 결론

---

---

- 문서 기반 대화 시스템을 위한 검색 모듈 (DPR) 학습에 필요한 대화 데이터 셋의 부족
- 엔티티를 중심으로 한 멀티 턴 대화 생성 방식 및 학습 데이터로 증강 방법 제시
- 생성된 멀티 턴 대화 데이터의 검색 모듈 학습에 대한 기여를 확인하기 위해 DPR의 인코더 모델에 사전학습 실험 진행.
- 단발성 질문들을 조합하여 만들어진 멀티 턴의 대화도 사전학습을 통해 검색 모듈에 긍정적 영향 확인.