

의미론적 feature 공간상에서의 negative sampling을 통한 검색 성능 개선

HCLT 2022

이정우¹, 홍범석², 최원석², 한영섭², 전병기², 나승훈¹

¹ 전북대학교 ² LG U+

목 차

1. Introduction

2. 관련 연구


3. 제안 방법

4. 데이터

5. 실험 및 결론

Introduction


- 개요도



Introduction

- **Retriever**

- query 와 passage 를 독립적으로 encoding



$$sim_{\theta}(q, d) = E_{\theta}(q)^T E_{\theta}(d)$$

$$\mathcal{L} = -\log \frac{e^{sim(q^i, d^i)}}{e^{sim(q^i, d^i)} + \sum_{j=1, j \neq i}^n e^{sim(q^i, d^j)}}$$

관련 연구

- **기존 Negative sampling 전략**

- **in-batch**

배치 내에 각 example 이 {q, p+} 로 positive pair 로 이루어 졌을 때, 자기 자신을 제외한 passage 를 negative 로 두는 방법

- **TF-IDF (or BM25)**

통계 기반 검색을 통해 얻은 topk 개의 passage 를 negative sample 로 사용하는 방법

- **ANCE [Xiong et al. '20]¹**

훈련을 진행하며 전체 passage 를 다시 encoding 하여 계속해서 모델이 어려워하는 hard negative 를 얻는 방법


¹Approximate nearest neighbor negative contrastive learning for dense text retrieval[Xiong et al '20]

제안 방법

- Feature space에서의 negative sampling

- 수정된 Mixed Gaussian Recurrent Chain(MGRC) sampling

positive feature의 semantic space의 경계선상에서 hard negative sample 을 얻는 방법



(x, y) : positive pair

r_x : query의 중심 vector

r_y : positive passage의 중심 vector


\tilde{r}_x : query에 대한 semantic space 반경

\hat{r}_x : negative sample vector

제안 방법

- Feature space에서의 negative sampling

- 수정된 MGRC sampling



$$\hat{r}_x^k = r_x + \tilde{\omega}^k \odot \tilde{r}$$

$$\tilde{r} = r_y - r_x$$

$$\tilde{\omega}^k = \text{sgn}(\omega^k)(|\omega^k| + 1)$$

$$\begin{cases} \omega^k \sim \mathcal{N}(0, \text{diag}(\mathcal{W}_r^2)) & \text{if } k = 1 \\ \omega^k \sim p(\omega | \omega^1, \dots, \omega^{k-1}) & \text{if } k > 1 \end{cases}$$

$$p = \eta \mathcal{N}(0, \text{diag}(\mathcal{W}_r^2)) + (1.0 - \eta) \mathcal{N}\left(\frac{1}{k-1} \sum_{i=1}^{k-1} \omega^i, 1\right)$$

$$\mathcal{W}_r = (1 - \lambda) \frac{|\tilde{r}| - \min(|\tilde{r}|)}{\max(|\tilde{r}|) - \min(|\tilde{r}|)}$$


$$\lambda = \frac{1}{100} \sum_{j \in [-100, -1]} e^{-\mathcal{L}^j}$$

제안 방법

- Feature space에서의 negative sampling

- Feature space mixing[Kalantidis et al '20]²

encoding 된 positive feature 와 negative feature 를 linear-interpolation 시켜 hard negative sample 을 얻는 방법



$$\hat{p}_i^k = \frac{\tilde{p}_i^k}{\|\tilde{p}_i^k\|_2}, \text{ where } \tilde{p}_i^k = \alpha_k p_i^+ + (1 - \alpha_k) p_i^-$$

$$\alpha_k \in (0, 0.5)$$

p_i^+ : q_i 에 대한 positive passage feature
 p_i^- : q_i 에 대한 negative passage feature

데이터

- Multidoc2dial
 - 문서 기반 대화 데이터
- 데이터 통계

Split	Instance Num	Passage Num
Train	21451	3820
Validation	4201	
Test	4094	

실 험

- 실험 세팅

	Baseline-ours	Ours	Others
Batch_size	128	128	128
Learning rate	2e-5	2e-5	-
Encoder	Roberta-base	Roberta-base	Bert-base
Shared-encoder	O	O	X
In-batch negative	O	O	O
TF-IDF(or BM25)	X	X	O
Feature space mixing	X	O	X
MGRC sampling	X	O	X

실 험

- 실험 결과

Performance on validation set					
Model	Architecture	R@1	R@5	R@10	R@100
Baseline-official	DPR	49.0	72.3	80.0	-
[CPII-NLP] – 1 st	DPR	44.5	71.4	-	-
[zsw_dyI_gz] – 2 nd	DPR	42.8	68.0	77.1	-
[CMU-QA] – 4 th	DistilSPLADE	-	-	78.6	94.9
Baseline-Ours	DPR	51.1	77.9	85.2	96.9
Ours	DPR	51.8	78.8	85.6	97.4

- Passage-retriever 를 사용한 팀들과 비교
- 1, 2, 4위 팀은 Test Phase of SEEN leaderboard 상에서의 순위

1st - Grounded Dialogue Generation with Cross-encoding Re-ranker, Grounding Span Prediction, and Passage Dropout[Li et al '22]

2nd - G4: Grounding-guided Goal-oriented Dialogues Generation with Multiple Documents[Zhang et al '22]

4th - R3 : Refined Retriever-Reader Pipeline for Multidoc2dial[Bansal et al '22]

실 험

- 실험 결과

Performance on validation set				
	R@1	R@5	R@10	R@100
Ours	51.8	78.8	85.6	97.4
w/o Feature space mixing	52.2	78.6	85.4	97.0
w/o MGRC sampling	51.1	77.9	85.4	97.1

Performance on test set					
	R@1	R@5	R@10	R@100	MRR
Baseline-Ours	50.5	80.0	87.4	97.7	63.4
Ours	51.4	79.2	86.9	97.9	63.8

감사합니다.