

# Textual Entailment Feedback 기반 효율적인 문서 재순위화기

남성욱<sup>1</sup>\*, 한동훈<sup>1</sup>, 박은환<sup>1</sup>, 나승훈<sup>2\*</sup>  
버즈니AI 연구소, 전북대학교  
{zaid, owen, jude}@buzzni.com  
nash@jbnu.ac.kr

## Effective Passage Reranking with Textual Entailment Feedback

Seong-Uk Nam<sup>1</sup>, Donghoon Han, Eunhwan Park, Seung-Hoon Na  
Buzzni AI Lab, Jeonbuk National University

### 요약

재순위화기 연구는 주로 파이프라인 과정 설계, 데이터 증강, 학습 함수 개선, 혹은 대규모 언어 모델의 지식 활용 등에 집중되어있다. 이러한 연구들은 좋은 성능 상승을 이끌어주었지만 실제 적용이 힘들 뿐만 아니라 학습 비용이 크게 발생한다는 한계점을 가지고 있다. 더 나아가 주어진 데이터 집합만을 활용해서는 보다 더 세부적인 학습 신호를 주기 어렵다는 단점 또한 존재한다. 최근 자연어처리 분야의 연구에서는 피드백을 인위적으로 생성하여 반영하여 모델 성능 상승을 이끄는 연구가 제안되었다. 본 연구는, 이러한 연구를 바탕으로 질의와 문서 간의 함의 관계 점수를 피드백으로 사용 및 재순위화기 모델로의 반영을 제안한다. 재순위화기 모델에 대해 피드백을 반영하는것은 그렇지 않은 모델 대비하여 성능 상승을 이끌며 피드백 반영이 더 좋은 표상 도출에 도움이 됨을 확인할 수 있다.

**주제어:** 검색기, 재순위화기, 피드백

### 1. 서론

정보 검색 (Information Retrieval, IR)은 대규모 문서 집합에서 주어진 질의  $q$ 와 연관된 후보 문서 집합  $d$ 를 검색하는 작업이며 이는 오픈 도메인 질의 응답 등에서 활용되고 있다. 최근 오픈 도메인 질의 응답 뿐만 아니라 환각 오류 (Hallucination)을 줄이기 위해 검색 증강된 사전 학습 언어 모델이나 적절한 프롬프트 구성을 위한 검색 등의 연구가 활발히 진행함에 따라 정보 검색 분야 연구의 중요도가 높아지고 있다.

정보 검색은 크게 희소 검색 (Sparse Retrieval), 밀집 검색 (Dense Retrieval)으로 구성되어있다. 희소 검색의 모델은 TF-IDF, BM25 [1]이 대표적이며 질의와 문서 간 토큰 레벨 어휘 중복 (Lexical Overlapping)으로 유사한 문서를 찾을 수 있는 간단한 접근이지만 의미적 유사성을 고려하지 못한다는 단점이 있다. 이러한 단점을 해소하기 위해 밀집 검색은 질의와 문서를 뉴럴 임베딩으로 변환하여 MIPS (Maximum Inner Product Search)를 학습하는 것이 제안되었다 [2]. 하지만, 이러한 정보 검색 방법들에도 불구하고 비용효율적으로 검색 결과를 개선하기 위해서 재순위화기가 필요하다.

최근 재순위화기 연구는 주로 추가적인 파이프라인 과정 설계, 데이터 증강, 학습 함수 개선 혹은 대규모 언어 모델의 지식 활용 등에 집중되어있다. 예를 들어, [3, 4]는 각 파이프라인 과정에서의 표상 보강을 위한 모델 설계에 집중했다. [5, 6]는 질의 데이터를 인위적으로 대규모 증강하는 것을 제안했다. [4]는 대조 학습 함수의 개선을 제안하였다. [7]는 질의와 문서 간 표

상을 강화하는 새로운 자기 지도 학습 방법인 Masked Query Prediction (MQP)을 제안했다. [8]는 ChatGPT<sup>1</sup>같은 대규모 언어 모델 (Large Language Models, LLMs) 기반 Zero-shot 재순위화를 처음으로 제안하였을 뿐만 아니라 경쟁적인 성능을 보여줬다.

이러한 연구들에도 불구하고 현재의 재순위화기는 주어진 데이터 집합만을 활용해서는 보다 더 세부적인 학습 신호를 주기 어려우며, 파이프라인의 복잡한 설계로 인하여 실제 적용이 힘들 뿐만 아니라 학습 비용도 크게 발생한다는 한계점을 가지고 있다.

본 연구는 데이터 증강을 하지 않고 재순위화기 모델 구조의 수정 없이 검색 성능을 개선하는 피드백 기반 재순위화기를 제안한다. 구체적으로, [9, 10, 11]은 질의와 문서 간 함의 관계 (Textual Entailment)의 개선이 의미적 표상 강화를 통하여 검색 성능 개선으로 이끌어주는 것을 보여주었다. 이에 따라, 학습된 함의 관계 모델로 질의와 문서 간의 피드백 점수를 예측하고, 이를 재순위화기 모델 학습에 반영하는 것을 제안한다.

### 2. 관련 연구

#### 2.1 Retrieval & Reranking

정보 검색은 주로 희소 및 밀집 검색으로 나누어진다. 희소 검색에 적용가능한 모델로는 토큰 레벨 어휘 중복으로 유사한 정보를 검색하게 해주는 TF-IDF, BM25가 대표적이며 [1], 의미적 유사성을 고려하여 정보를 검색하는 모델이 연구되고

\*교신저자 (Corresponding author)

<sup>1</sup><https://chat.openai.com/>

있다. 의미적 유사성을 고려하는 모델로는 MIPS로 학습하는 DPR (Dense Passage Retrieval) [2]을 예로 들 수 있다. 밀집 검색에서는 부정적 샘플링에 따라 성능이 크게 달라진다. 이에 따라, [12]은 부정적 샘플링을 강화한 밀집 검색이 제안하였다. [13]은 밀집 검색의 추가적인 학습 함수를 제안, 검색 성능의 상승을 이끌었다. [14]는 최근 제안된 Masked Auto-Encoder 모델 기반 사전 학습 후 밀집 검색을 제안했다.

상위 검색 결과 기반으로 재순위화하는 것은 검색기를 학습하는 것보다 비용효율적이며 이에 따라 관련 연구가 활발히 진행되었다. [4]는 검색 최상위 결과로부터 부정적인 샘플 분포를 지역화하는 지역화된 대조 추정 (Localized Contrastive Estimation, LCE) 과 대조 학습 함수 (Contrastive Learning) 의 사용을 제안하였다. [8]는 대규모 언어 모델 기반 Zero-shot 재순위화를 처음으로 제안하였을 뿐만 아니라 경쟁적인 성능을 보여주었지만 기존 재순위화기와 API 호출 비용으로 인하여 다르게 소규모의 후보 문서만을 입력으로 사용할 수 있다는 한계점이 존재한다.

## 2.2 Feedback Learning

[15]은 모델 출력물에 대한 사람의 피드백을 구성하여 강화 학습으로 미세 조정하는 것을 제안하였다. [16]은 보상 모델을 구성하여 모델에 피드백을 반영하며 좋은 성능을 보여주었다. [17]은 문장 임베딩 모델 학습 시 ChatGPT 기반 피드백을 생성 및 반영함으로써 성능 상승을 이끌었고, [18]은 점수가 아닌 자연어 형식의 피드백을 생성하여 모델 출력물을 수정하는 피드백 기반 학습을 제안했다. [19]는 모델 출력 결과물에 대하여 Textual Entailment Feedback 을 이용하여 환각 오류를 해소하는 요약 생성 연구를 제안했다.

## 3. 피드백 기반 재순위화기 모델

본 연구에서는 주어진 검색기로 검색한 결과가 있다고 가정한다. 구체적으로, 검색기는 주어진 질의  $q$ 에 대해 문서 집합  $\mathcal{D} = \{d_i\}_{i=1}^N$ 으로부터  $k$ 개의 관련 문서를 검색한다. 검색된 상위 문서 집합  $\mathcal{D}_{\text{top-}j} = [d_1, \dots, d_j]$ 를 재순위화하여 검색 성능을 효과적으로 개선하는 것이 본 연구의 주요 목표이다.

### 3.1 Textual Entailment 모델

재순위화기 학습에 사용되는 데이터 집합의 경우 주로 질의 응답과 관련이 있다는 공통점을 가지고 있다. 그렇기 때문에, 함의 관계 학습에 사용되는 데이터 집합은 그와 유사한 QNLI (Question-Answering NLI) [20] 를 사용했다.

먼저, QNLI 데이터 집합으로부터 주어진 질의  $q$ 와 정답  $a$ 의 형식일 때 언어 모델에 아래와 같이 입력을 구성하여 표상  $\text{Emb}_{\text{feedback}}$ 을 추출한다. 이후, 학습 가능한 매개변수

$\mathbf{W}_{\text{feedback}}^T \in \mathbb{R}^d$ 와 추출한 표상  $\text{Emb}_{\text{feedback}}$ 의 내적에 시그모이드 함수  $\sigma$ 를 합성하는 것으로 피드백 점수  $s_{\text{feedback}}$ 를 생성한다.  $\sigma(\cdot)$ ,  $[\cdot; \cdot]$ 는 시그모이드 함수와 연결 연산을 의미한다.

$$\begin{aligned} \text{Emb}_{\text{feedback}}(q, a) &= \text{LM}_{[\text{CLS}]}([q; a]) \\ s_{\text{feedback}}(q, a) &= \sigma(\mathbf{W}_{\text{feedback}}^T \text{Emb}_{\text{feedback}}(q, a)) \end{aligned} \quad (1)$$

### 3.2 Feedback 기반 Reranking 시스템

본 연구의 재순위화기는 [4]에서 제안된 리스트 기반 대조 학습 (List-wise Contrastive Learning) 을 사용하며 이는 여러 재순위화기 연구에서 사용되는 학습 함수이다. 주어진 질의  $q$ 와  $j$ 개의 후보 문서 집합  $[d_1, \dots, d_j]$ 를 언어 모델에 입력으로 넣는다.

$$\begin{aligned} \text{Emb}_{\text{reranking}}(q, d) &= \text{LM}_{[\text{CLS}]}([q; d]) \\ s_{\text{reranking}}(q, d) &= \mathbf{W}_{\text{reranking}}^T \text{Emb}_{\text{reranking}}(q, d) + \mathbf{b} \end{aligned} \quad (2)$$

재순위화 점수  $s_{\text{reranking}}(q, d)$ 를 통해 질의와 문서 간 의미적 유사 점수를 계산할 수 있으며 아래와 같이 리스트 기반 대조 학습의 손실함수를 사용한다.

$$\mathcal{L}_{\text{reranking}} = -\log \frac{\exp(s_{\text{reranking}}(q, d^+))}{\sum_{d \in \mathcal{D}_{\text{top-}j}} \exp(s_{\text{reranking}}(q, d))} \quad (3)$$

3.1에서 학습한 모델을 통하여 재순위화기에 영향을 줄 피드백 점수를 생성하며 [17]에서 제안한 것처럼  $\text{Emb}_{\text{feedback}}(q, d) \leftrightarrow \text{Emb}_{\text{reranking}}(q, d)$  간의 의미적 유사도 점수  $s_{\text{feedback}}(q, d)$  간 평균제곱오차 함수를 통해 학습한다.<sup>2</sup>

$$\mathcal{L}_{\text{feedback}} = \frac{1}{N} \sum_{i=1}^N (\cos(\mathbf{H}, \mathbf{O}) - s_{\text{feedback}}(q, d))^2 \quad (4)$$

최종적으로, 학습 함수는 아래와 같다.

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{reranking}} + \lambda \cdot \mathcal{L}_{\text{feedback}} \quad (5)$$

$\lambda$ 는 초매개변수이다.

## 4. 실험

### 4.1 실험 세팅

본 연구는 정보 검색에 널리 쓰이는 데이터 집합인 MS MARCO [22] 을 사용했다. 평가 지표로 공식 리더보드<sup>3</sup>에서 사용되는 MRR@K를 채택하였으며 테스트 데이터 집합의 비공개로 인해 개발 데이터 집합에 대해서 평가했다. 실험에 사용한 언어 모델은 BERT를 사용하였으며 모델 크기는 base, large 를 사용했다.

<sup>2</sup>학습 함수에서는 편의상  $\text{Emb}_{\text{feedback}}(q, d)$ 와  $\text{Emb}_{\text{reranking}}(q, d)$ 는  $\mathbf{H}, \mathbf{O}$ 로 표기한다.

<sup>3</sup><https://microsoft.github.io/msmarco/>

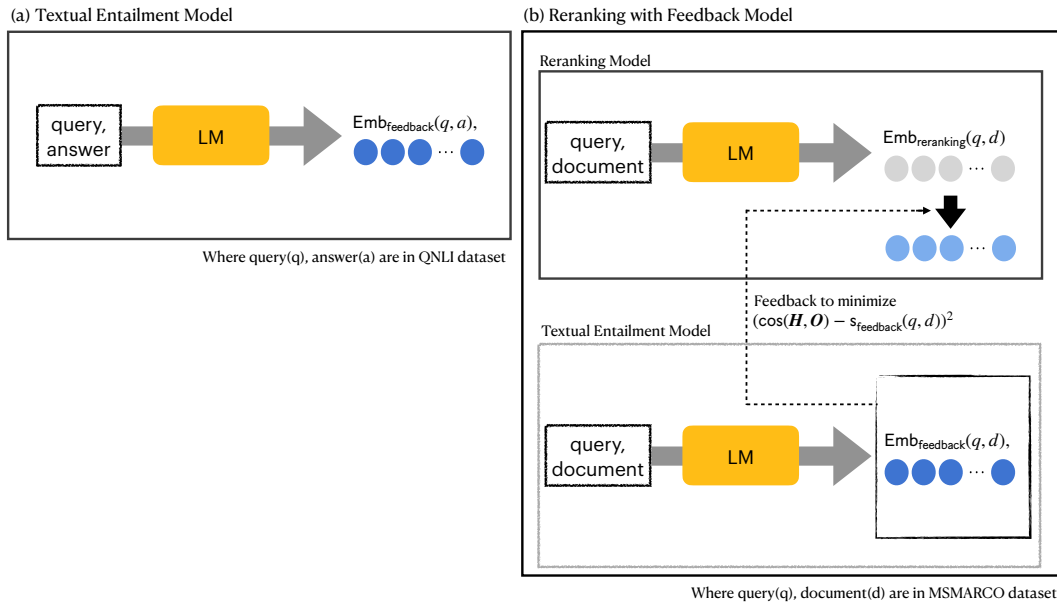


그림 1. Textual Entailment Feedback 을 반영한 문서 재순위화기의 모델 구조도.

Model	Sparse Retrieval		Dense Retrieval	
	MRR@10	MRR@100	MRR@10	MRR@100
Retriever	18.7	19.8	38.3	39.4
BERT <sub>base</sub> + Reranking	34.4	35.5	40.1	41.1
BERT <sub>large</sub> + Reranking	35.4	36.3	41.0	42.0
BERT <sub>base</sub> + Reranking + Feedback	<b>34.8</b>	<b>35.9</b>	<b>41.0</b>	<b>41.2</b>
BERT <sub>large</sub> + Reranking + Feedback	<b>36.0</b>	<b>36.7</b>	<b>41.4</b>	<b>42.1</b>

표 1. MS MARCO 개발 데이터 집합으로 평가한 재순위화기의 성능 결과. [21]에서 공개한 BM25 (Sparse Retrieval), DPR (Dense Retrieval) 모델을 사용했다.

## 4.2 실험 결과

표 1은 희소 및 밀집 검색 방법 기반으로 상위 검색 결과를 바탕으로 재순위화한 실험 결과이다. Textual Entailment 모델을 이용한 재순위화기에 대한 피드백 반영이 효과적인지 직접적으로 비교하였다. 피드백을 반영한 모델의 경우 희소 검색 기준 BERT<sub>base</sub> 에서 MRR@10, MRR@100 에서 각각 +0.4의 성능 향상을 보여주었다. 밀집 검색 결과 기반 재순위화를 했을 때, +0.9, +0.1로 MRR@10 에서 뚜렷한 성능 상승 폭을 보여주었으며 이는 초기 검색 결과의 품질이 성능에 영향을 준 것으로 추측된다. 또한, 이와 비슷하게 BERT<sub>large</sub> 도 피드백 반영 시 성능 상승을 보여주었다. 이는, Textual Entailment 모델이 재순위화기에 긍정적인 영향을 끼칠 수 있음을 보여주었을 뿐만 아니라 피드백 점수 생성의 고도화를 통해 재순위화기 연구에 더 많은 발전 가능성이 있음을 시사한다.

## 5. 결론

여러 재순위화기 연구는 파이프라인 과정 설계, 데이터 증강, 학습 함수 개선, 혹은 대규모 언어 모델의 지식 활용을 중점으로 진행되어왔다. 이는 좋은 성능을 이루는데 결정적인 기여를 했지만 실제 적용이 힘들 뿐만 아니라 학습 비용이 크게 발생한다는 한계점을 가지고 있다. 본 연구은, 기본적인 재순위화기 모델에 피드백 모델 기반 피드백 점수를 생성하여 재순위화기에 반영하는 것을 제안한다. 피드백을 반영한 재순위화기 모델의 성능 상승을 보여줌으로서 재순위화기에 대한 피드백 반영이 긍정적인 영향을 끼칠 수 있을 뿐만 아니라 추후 피드백 모델의 고도화를 통해 더 많은 발전 가능성이 있음을 시사한다.

## 참고문헌

[1] S. Robertson and H. Zaragoza, "The probabilistic relevance framework: Bm25 and beyond," *Foundations*

- and Trends*® in *Information Retrieval*, Vol. 3, No. 4, pp. 333–389, 2009. [Online]. Available: <http://dx.doi.org/10.1561/15000000019>
- [2] V. Karpukhin, B. Oguz, S. Min, P. Lewis, L. Wu, S. Edunov, D. Chen, and W.-t. Yih, “Dense passage retrieval for open-domain question answering,” *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pp. 6769–6781, Nov. 2020. [Online]. Available: <https://aclanthology.org/2020.emnlp-main.550>
- [3] Y. Zhang, D. Long, G. Xu, and P. Xie, “Hlatr: Enhance multi-stage text retrieval with hybrid list aware transformer reranking,” 2022.
- [4] L. Gao, Z. Dai, and J. Callan, “Rethink training of bert rerankers in multi-stage retrieval pipeline,” *Advances in Information Retrieval: 43rd European Conference on IR Research, ECIR 2021, Virtual Event, March 28 – April 1, 2021, Proceedings, Part II*, p. 280–286, 2021. [Online]. Available: [https://doi.org/10.1007/978-3-030-72240-1\\_26](https://doi.org/10.1007/978-3-030-72240-1_26)
- [5] Z. Zheng, K. Hui, B. He, X. Han, L. Sun, and A. Yates, “BERT-QE: Contextualized Query Expansion for Document Re-ranking,” *Findings of the Association for Computational Linguistics: EMNLP 2020*, pp. 4718–4728, Nov. 2020. [Online]. Available: <https://aclanthology.org/2020.findings-emnlp.424>
- [6] R. Padaki, Z. Dai, and J. Callan, “Rethinking query expansion for bert reranking,” *Advances in Information Retrieval*, J. M. Jose, E. Yilmaz, J. Magalhães, P. Castells, N. Ferro, M. J. Silva, and F. Martins, Eds., pp. 297–304, 2020.
- [7] X. Zhu, T. Hao, S. Cheng, F. L. Wang, and H. Liu, “A self-supervised joint training framework for document reranking,” *Findings of the Association for Computational Linguistics: NAACL 2022*, pp. 1056–1065, Jul. 2022. [Online]. Available: <https://aclanthology.org/2022.findings-naacl.79>
- [8] X. Ma, X. Zhang, R. Pradeep, and J. Lin, “Zero-shot listwise document reranking with a large language model,” 2023.
- [9] J. Lee, A. Wettig, and D. Chen, “Phrase retrieval learns passage retrieval, too,” *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, pp. 3661–3672, Nov. 2021. [Online]. Available: <https://aclanthology.org/2021.emnlp-main.297>
- [10] C. Samarinas, W. Hsu, and M. L. Lee, “Improving evidence retrieval for automated explainable fact-checking,” *Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies: Demonstrations*, pp. 84–91, Jun. 2021. [Online]. Available: <https://aclanthology.org/2021.naacl-demos.10>
- [11] D. Guzman Olivares, L. Quijano, and F. Liberatore, “Enhancing information retrieval in fact extraction and verification,” *Proceedings of the Sixth Fact Extraction and VERification Workshop (FEVER)*, pp. 38–48, May 2023. [Online]. Available: <https://aclanthology.org/2023.fever-1.4>
- [12] L. Xiong, C. Xiong, Y. Li, K.-F. Tang, J. Liu, P. N. Bennett, J. Ahmed, and A. Overwijk, “Approximate nearest neighbor negative contrastive learning for dense text retrieval,” *International Conference on Learning Representations*, 2021. [Online]. Available: <https://openreview.net/forum?id=zeFrfgYzln>
- [13] R. Ren, S. Lv, Y. Qu, J. Liu, W. X. Zhao, Q. She, H. Wu, H. Wang, and J.-R. Wen, “PAIR: Leveraging passage-centric similarity relation for improving dense passage retrieval,” *Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021*, pp. 2173–2183, Aug. 2021. [Online]. Available: <https://aclanthology.org/2021.findings-acl.191>
- [14] X. Wu, G. Ma, M. Lin, Z. Lin, Z. Wang, and S. Hu, “Contextual masked auto-encoder for dense passage retrieval,” *Thirty-Seventh AAAI Conference on Artificial Intelligence, AAAI 2023, Thirty-Fifth Conference on Innovative Applications of Artificial Intelligence, IAAI 2023, Thirteenth Symposium on Educational Advances in Artificial Intelligence, EAAI 2023, Washington, DC, USA, February 7-14, 2023*, B. Williams, Y. Chen, and J. Neville, Eds., pp. 4738–4746, 2023. [Online]. Available: <https://ojs.aaai.org/index.php/AAAI/article/view/25598>
- [15] D. M. Ziegler, N. Stiennon, J. Wu, T. B. Brown, A. Radford, D. Amodei, P. Christiano, and G. Irving, “Fine-tuning language models from human preferences,” 2020.
- [16] L. Ouyang, J. Wu, X. Jiang, D. Almeida, C. L. Wainwright, P. Mishkin, C. Zhang, S. Agarwal, K. Slama,

- A. Ray, J. Schulman, J. Hilton, F. Kelton, L. Miller, M. Simens, A. Askell, P. Welinder, P. Christiano, J. Leike, and R. Lowe, “Training language models to follow instructions with human feedback,” 2022.
- [17] Q. Cheng, X. Yang, T. Sun, L. Li, and X. Qiu, “Improving contrastive learning of sentence embeddings from AI feedback,” *Findings of the Association for Computational Linguistics: ACL 2023*, pp. 11 122–11 138, Jul. 2023. [Online]. Available: <https://aclanthology.org/2023.findings-acl.707>
- [18] A. F. Akyurek, E. Akyurek, A. Kalyan, P. Clark, D. T. Wijaya, and N. Tandon, “RL4F: Generating natural language feedback with reinforcement learning for repairing model outputs,” *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 7716–7733, Jul. 2023. [Online]. Available: <https://aclanthology.org/2023.acl-long.427>
- [19] P. Roit, J. Ferret, L. Shani, R. Aharoni, G. Cideron, R. Dadashi, M. Geist, S. Girgin, L. Hussenot, O. Keller, N. Momchev, S. Ramos Garea, P. Stanczyk, N. Vieillard, O. Bachem, G. Elidan, A. Hassidim, O. Pietquin, and I. Szpektor, “Factually consistent summarization via reinforcement learning with textual entailment feedback,” *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pp. 6252–6272, Jul. 2023. [Online]. Available: <https://aclanthology.org/2023.acl-long.344>
- [20] A. Wang, A. Singh, J. Michael, F. Hill, O. Levy, and S. Bowman, “GLUE: A multi-task benchmark and analysis platform for natural language understanding,” *Proceedings of the 2018 EMNLP Workshop BlackboxNLP: Analyzing and Interpreting Neural Networks for NLP*, pp. 353–355, Nov. 2018. [Online]. Available: <https://aclanthology.org/W18-5446>
- [21] J. Lin, X. Ma, S.-C. Lin, J.-H. Yang, R. Pradeep, and R. Nogueira, “Pyserini: An easy-to-use python toolkit to support replicable ir research with sparse and dense representations,” 2021.
- [22] T. Nguyen, M. Rosenberg, X. Song, J. Gao, S. Tiwary, R. Majumder, and L. Deng, “MS MARCO: A human generated machine reading comprehension dataset,” *Proceedings of the Workshop on Cognitive Computation: Integrating neural and symbolic approaches 2016 co-located with the 30th Annual Conference on Neural Information Processing Systems (NIPS 2016), Barcelona, Spain, December 9, 2016*, ser. CEUR Workshop Proceedings, T. R. Besold, A. Bordes, A. S. d’Avila Garcez, and G. Wayne, Eds., Vol. 1773, 2016. [Online]. Available: [https://ceur-ws.org/Vol-1773/CoCoNIPS\\_2016\\_paper9.pdf](https://ceur-ws.org/Vol-1773/CoCoNIPS_2016_paper9.pdf)