다국어 정보 검색을 위한 적대적 언어 적응을 활용한 ColBERT

김종휘⁰¹, 김윤수^{†1,2}, 이근배^{†1,2} 포항공과대학교 인공지능대학원¹, 포항공과대학교 컴퓨터공학과² {jhkim980112, yunsu.kim, gblee}@postech.ac.kr

ColBERT with Adversarial Language Adaptation for Multilingual Information Retrieval

Jonghwi Kim°¹, Yunsu Kim^{†1,2}, Gary Geunbae Lee^{†1,2} Graduated School of Artificial Intelligence, Pohang University of Science and Technology¹, Computer Science and Engineering, Pohang University of Science and Technology²

요 약

신경망 기반의 다국어 및 교차 언어 정보 검색 모델은 타켓 언어로 된 학습 데이터가 필요하지만, 이는 고자원 언어에 치중되어있다. 본 논문에서는 이를 해결하기 위해 영어 학습 데이터와 한국어-영어 병렬 말뭉치만을 이용한 효과적인 다국어 정보 검색 모델 학습 방법을 제안한다. 언어 예측 태스크와 경사 반전 계층을 활용하여 인코더가 언어에 구애 받지 않는 벡터 표현을 생성하도록 학습 방법을 고안하였고, 이를 한국어가 포함된 다국어 정보 검색 벤치마크에 대해 실험하였다. 본 실험 결과 제안 방법이 다국어 사전학습 모델과 영어 데이터만을 이용한 베이스라인보다 높은 성능을 보임을 실험적으로 확인하였다. 또한 교차 언어 정보 검색 실험을 통해 현재 검색 모델이 언어 편향성을 가지고 있으며, 성능에 직접적인 영향을 미치는 것을 보였다.

주제어: Multi-lingual Information Retrieval, Language Adaptation, Adversarial Learning, ColBERT

1. 서론

정보 검색은 쿼리와 유사도가 높은 문서를 찾아내는 태스크로 실사용되는 검색 엔진이나 추천 시스템뿐만 아니라 QA, MRC 등 다른 자연어처리 분야의 다운스트림 태스크에서도 활용된다. 최근 정보 검색에서는 신경망 기반 모델의 발전과 더불어 의미론적 유사도 기반 모델[1, 2, 3]이 연구되고 있으며, 해당 모델들은 쿼리와 문서들을 벡터 공간 상에서 유사한 의미끼리 가까이 위치시키는 것을 목적으로 학습을 진행한다. 하지만 이러한 모델을 위한 라벨링된 학습 데이터(e.g., Query-Relevant Document)는 고자원 언어 (e.g., 영어)에 치중되어 있다. 이를 해결하기 위한 직관적인 방법은 MT를 이용하여 타겟 언어 학습 데이터를 구축하는 것이지만 높은 비용 문제 외 번역투 문제[4]가 존재하기에 저자원 언어에 해당하는 검색 모델을 구축하는 것에는 어려움이 따른다.

한 가지 연구 방향은 다국어 사전학습 언어모델을 활용하는 것이다.[5, 6] 하지만 다국어 사전학습 모델의 경우, 사전학습 단계에서 다양한 언어의 단일 언어 말뭉치를 통한 MLM(Masked Language Model)로 학습하기에 다른 언어 간의 alignment 능력이 떨어지며 벡터 공간 상에서 의미가 아닌 언어별로 군집을 형성하는 언어 편향 문제가 존재하게 된다. 유사한 의미의 문장을 벡터 공간 상에서 서로 가까이 위치시키는 것이 의미론적 유사도 매칭의 핵심 과제이므로 언어 편향 문제는 저자원 언어의 검색 모델 성능에 직접적인 영향을 주게 된다.

본 연구에서는 밀집 표현의 언어 편향 문제를 해결하여 다른 언어 간의 alignment를 향상시키기 위해 영어-타겟 언어 병렬 말뭉치와 언어 예측 태스크를 정보 검색 학습 목적과 같이 사용 하는 것을 제안하며, 이를 통한 효과를 실험적으로 증명하고자 한다.

본 논문의 기여하는 바는 다음과 같다.

- 1. 다국어 정보 검색에서 영어-타겟 언어 병렬 말뭉치와 언어 예측 태스크 및 경사 반전 계층을 도입한 첫 연구이다.
- 2. 제안 방법을 한국어를 포함한 다국어 정보 검색 벤치마크에 실험하여 성능 향상을 확인하였다.
- 3. 실험 결과 및 임베딩 결과를 분석하여 언어 편향 문제를 확인하였다.

2. 관련 연구

2.1 정보 검색

BERT[7] 등장 이전, 전통적인 키워드 매칭 통계 기반 알고리즘(e.g., BM25)[8]이 오픈소스 검색엔진¹에서도 기본값으로 사용되며 정보 검색 분야에서 지배적으로 사용되었다. 해당 모델은 역색인을 지원하여 빠른 검색 속도와 준수한 성능을 보였지만 의미론적으로 유사한 문장을 찾을 수 없다는 한계가 존재한다.

이후 트랜스포머 기반 모델이 등장함에 따라 신경망 모델들이 정보 검색 및 랭킹 모델에 도입되어 바이-인코더[1]와 크로스-인코더[2] 구조의 밀집 벡터 표현 기반 모델들이 활용되고 있다. DPR[1]은 대표적인 바이-인코더 구조로 쿼리와 문서에 대해 독립적인 인코더를 가져 사전에 문서 임베딩을 구한 뒤, 추

https://www.elastic.co/kr/elasticsearch/

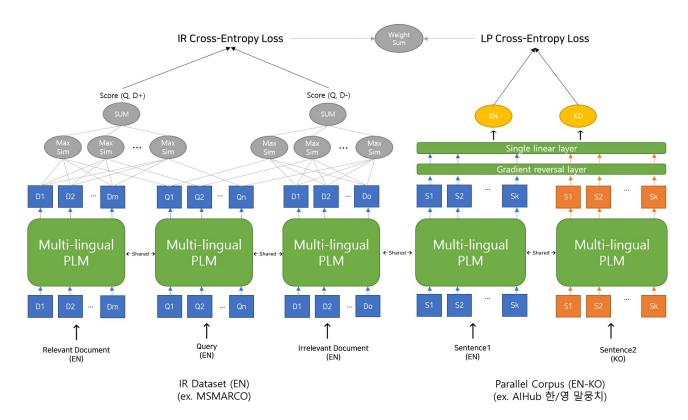


그림 1. 모델 아키텍쳐

론 시점에서는 쿼리 임베딩만 구하여 단일 밀집 벡터의 유사도 기반으로 관련성 높은 문서를 검색한다. 학습 데이터가 1,000 개가 넘어가는 시점에서 BM25의 성능을 능가한다는 보고가 있으며[1], 빠른 추론 속도를 바탕으로 현재까지 정보 검색, QA 시스템에서 활용되고 있다.

크로스-인코더 구조의 모델[2]은 쿼리와 문서가 동시에 입력되어 각 쌍마다의 관련성 점수를 바탕으로 높은 유사도의 문서를 찾아낸다. 해당 모델은 토큰 레벨의 상호작용을 거치기에 문서 단계의 바이-인코더 모델보다 상대적으로 높은 성능을 보이지만[9] 추론 시점에서 쿼리와 모든 후보 문서 쌍 간의 점수를 계산하기에 지연시간이 높다는 단점이 존재하기에 단일모델로 사용하기에 적합하지 않다.

최근에는 크로스-인코더의 토큰 레벨의 세분화된 상호작용과 바이-인코더의 오프라인 인덱성의 장점을 결합한 ColBERT 모델[3]이 제안되었다. ColBERT는 크로스-인코더와 달리 문서를 토큰 레벨의 임베딩으로 저장하고, 추론 시점에서 쿼리와문서 간의 토큰 단계의 상호작용을 하는 "late interaction"을통해 지연시간을 완화하며 높은 성능을 유지하였다. 이후에도네거티브 마이닝, 지식 추출 기법 등 후속연구가 활발히 진행되고 있다.[10, 11] 본 연구에서는 ColBERT v1 모델을 기반으로아키텍쳐와 실험을 구성하였다.

2.2 언어 전이 학습

다국어로 구성된 대용량 말뭉치를 통해 사전학습된 언어모델들은 다른 언어 간의 공유되는 잠재 공간을 학습하여 여러언어에 대한 다운스트림 태스크를 지원한다. 하지만 제로샷 성능의 경우 언어에 따른 성능 편차가 크고, 잠재 공간 내에서의미가 아닌 언어에 따라 군집이 형성되는 언어 편향성이 존재한다는 문제가 보고되었다. [12, 13]

이러한 다국어 사전학습 모델이 구축한 잠재 공간에서 언어 편향성을 제거하기 위해 다양한 분야 및 태스크에서 언어 정보를 제거하거나 언어에 구애받지 않는 강건한 벡터 표현을 얻기위한 연구가 진행되고 있다. [14, 15] 또한, 최근 정보 검색 분야에서도 다른 언어에 대한 교차 언어 정보 검색, 다국어 검색모델 구축을 위한 연구[16] 및 대회^{2 3}가 활발하게 진행되고 있다. 하지만 도메인 적응 학습[17] 등의 다양한 전이 학습 방법론들이 정보 검색 분야에서 검증되지 않았다. 본 연구에서는 적대적 언어 적응 방식을 다국어 정보 검색 태스크에 실험해보고자 한다.

3. 제안 방법론

본 연구에서는 기존 ColBERT 모델에 언어 예측 태스크와 및 경사 반전 계층를 활용하는 방법을 제안하며, 이를 통해 언

²https://neuclir.github.io/

³https://project-miracl.github.io/

어에 구애받지 않는 벡터 표현을 얻음으로써 타겟 언어에 대한 정보 검색 성능을 향상시키고자 한다.

3.1 훈련 방법

제안하는 모델의 전체 아키텍쳐는 그림 1과 같으며, 기존 ColBERT 모델의 정보 검색 태스크에 언어 예측 태스크 및 손실 함수를 추가한 구조이다.

기존 ColBERT 모델의 학습 방법은 그림 1 좌측에 해당하며 다음과 같다. 정보 검색 모델 학습에 사용되는 {query - positive passage - negative passage} 형식의 훈련 데이터 세트를 입력 받아 토크나이징 및 BERT 계층을 거쳐 토큰 단위의 임베딩을 얻는다. 다음으로 수식 1의 MaxSim 연산을 통해 positive와 negative 각 샘플에 대해 점수를 구한 뒤, 소프트맥스 교차 엔 트로피 함수를 통해 파라미터를 업데이트한다.

$$\sum_{i \in |E_q|} \max_{j \in |E_d|} E_{q_i} \cdot E_{d_j}^T \tag{1}$$

언어 예측(Language Prediction) 태스크는 그림 1 우측과 같이 ColBERT 모델 인코더 위에 경사 반전 계층과 단일 선형 분류 계층를 쌓아 소스 언어와 타겟 언어로 구성된 병렬 말뭉치에 대해 각 문장의 언어를 예측하는 것이다. 언어 예측 네트워크의 목적함수는 교차 엔트로피 함수를 사용하며, 단일 선형분류 계층이 소스 언어와 타켓 언어를 잘 구별하도록 학습하게된다. 하지만 ColBERT의 인코더 파트에서는 역전파 과정에서경사 반전 계층[17]을 활용하여 인코더가 언어를 구별하지 않는 밀집 벡터 표현를 생성하도록 한다.

$$\frac{\partial L}{\partial \Theta_E} = \alpha_{IR} \frac{\partial L_{IR}}{\partial \Theta_E} - \lambda \alpha_{LP} \frac{\partial L_{LP}}{\partial \Theta_E}$$
 (2)

$$\lambda = \frac{2}{1 + e^{-\gamma p}} - 1\tag{3}$$

최종 손실 함수는 수식 2와 같으며, α {IR, LP}는 2가지 목적함수에 대한 손실 가중치이고, λ 는 반전 경사 스케줄링 매개변수이다. λ 값은 초기 훈련의 노이즈 영향을 줄이기 위해 방정식수식3에 따라 γ 로 스케일링된 훈련 진행률 p에 따라 증가한다. 해당 학습 방법을 통해 인코더는 소스 언어와 타겟 언어의 편향성을 완화한 벡터 표현을 얻음으로써 언어 전이 상황에서의 편향성을 줄이고자 한다.

4. 실험

본 실험은 다국어 정보 검색 태스크에서 언어 예측 손실 함수 와 경사 반전 계층를 활용한 방법론의 효과를 알아보고자 단일 언어 검색과 교차 언어 검색 상황에서 성능을 비교한다.

4.1 데이터 세트

실험에 사용되는 데이터 세트는 영어로 구성된 검색 모델 훈련 데이터와 언어 예측을 위한 병렬 말뭉치, 평가를 위한 다국어 정보 검색 데이터로 총 3가지이다.

검색 모델 모델 학습에 사용된 데이터는 Q&A, 정보 검색, MRC 태스크에서 활용되는 대표적인 벤치마크 데이터 세트인 MSMARCO[18]를 사용한다. MSMARCO 훈련 데이터 세트는 {query - positive passage - negative passage} 형식으로 약 400 만개로 구성된다. 언어 예측을 위한 병렬 말뭉치는 번역 모델 개발을 위해 구축된 AI-Hub 한국어-영어 번역(병렬) 말뭉치⁴를 사용하였으며, 총 160만개의 한국어-영어 문장으로 구성된다.

모델 평가를 위한 데이터로는 WSDM 2023 Cup Challenge에서 공개된 다국어 정보 검색 벤치마크 데이터 세트인 MIRACL[19]의 한국어 dev set을 사용하였으며, 검색 대상이되는 passage는 1,486,752개 평가용 쿼리는 213개로 구성된다. 또한, 쿼리와 문서 언어가 다른 언어 교차 정보 검색 (e.g., 쿼리: 영어, 문서:한국어)에 대한 성능 평가를 위해 한국어 쿼리 213 개를 Google Translate API⁵로 번역한 영어 쿼리도 사용한다.

4.2 실험 구성

본 실험에서는 언어 예측 손실 함수의 효과를 검증하기 위해 베이스 라인으로 영어 데이터만으로 학습한 mBERT 기반의 ColBERT과 한/영 병렬 말뭉치를 추가로 활용하여 LP 손실함수를 추가한 모델 간의 성능을 비교한다.

베이스 라인 모델은 ColBERT v1의 공식 리포지토리 를 참조하여 BERT를 multilingual BERT 로 대체하여 구현하였으며, MSMARCO 훈련 데이터를 32 배치사이즈로 200,000 step학습을 진행하였다. LP 손실 함수를 추가한 제안 모델은 마찬가지로 multilingual BERT와 ColBERT v1을 동일한 배치사이즈와 학습 step으로 학습을 진행하였으며, 병렬 말뭉치에 대해언어 예측에 사용되는 임베딩은 문장 전체 토큰 임베딩의 평균을 사용하였다. 기존 정보 검색 손실 함수와 LP 손실 함수의비율은 $\{1:1, 3:1, 10:1, 100:1, 1000:1\}$ 로 경사 반전 스케줄링파라미터 γ 는 $\{10, 40, 100\}$ 내에서 실험을 통해 결정하였다. 또한 언어 예측에 사용되는 임베딩은 문장 전체 토큰 임베딩의 평균를 사용한다. 그외의 하이퍼 파라미터는 ColBERT 논문[3]을 따른다.

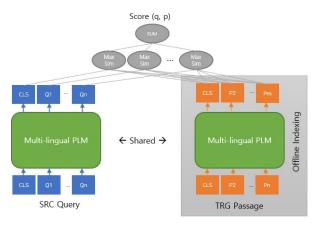
모델 평가 시나리오는 그림 2와 같으며, MIRACL 한국어 dev set을 활용하여 2가지 방식으로 평가를 진행한다. 첫번째

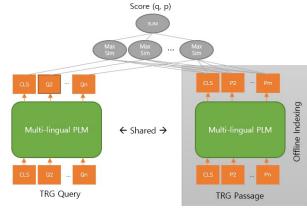
⁴https://www.aihub.or.kr/aihubdata/data/view.do? currMenu=115&topMenu=100&aihubDataSe=realm&dataSetSn= 126

⁵https://cloud.google.com/translate/?hl=ko

 $^{^6 {\}tt https://github.com/stanford-futuredata/ColBERT}$

⁷https://huggingface.co/bert-base-multilingual-uncased





Cross-lingual IR

Monolingual IR

그림 2. 모델 평가 시나리오

표 1. Mono-Lingual Retrieval 실험 결과

	nDCG@10	Recall@100
BM25	0.419	0.783
mDPR (en only)	0.419	0.737
mColBERT (en only)	0.5151	0.8287
mColBERT (+ LP 손실 함수)	0.5159	0.8442

표 2. Cross-Lingual Retrieval 실험 결과

	nDCG@10	Recall@100
mColBERT (en only)	0.1703	0.4005
mColBERT (+ LP 손실 함수)	0.1829	0.4099

실험은 그림 2의 우측과 같이 쿼리와 문서가 같은 언어로 구성된 시나리오로 추가적인 한국어 검색 모델 훈련 데이터 없이도 성능을 향상시킬 수 있는지 확인하기위한 실험이다. 두번째실험은 그림 2의 좌측에 해당하는 시나리오로 다른 언어지만같은 의미를 공유하는 경우, 잠재 공간에서 비슷한 위치에 맵핑되기에 교차 언어 정보 검색을 통해 언어 간 alignment를 통해성능의 향상이 있는지 확인하고자 한다.

5. 실험 결과 및 분석

베이스라인과 제안한 모델 간의 성능 비교를 위해 평가 방식은 MIRACL 논문 및 WSDM 2023 Cup Challenge 방식을 따라 nDCG@10, Recall@100을 사용하였다. 또한, MIRACL 논문에 보고된 성능을 바탕으로 BM25와 영어 데이터만으로 학습한 mDPR의 성능을 같이 표 1에 첨부하였다. 1의 Mono-Lingual Retrieval 실험 결과를 정리하자면 먼저 mColBERT

에서 영어 데이터 세트를 학습한 것만으로도 한국어 검색 성능에서 BM25나 mDPR의 성능을 능가하였다. 다음으로 LP 손실함수를 추가한 제안 모델의 경우, 두 가지 메트릭 모두 미세한성능 향상을 보였다.

표 2의 Cross-Lingual Retrieval 실험은 MIRACL의 한국어 쿼리가 영어로 번역된 상황으로 쿼리와 문서가 다른 언어 간의 검색 상황이다. 해당 실험 결과, 베이스 라인 및 제안 모델 모두 성능 하락 폭이 크다는 것을 확인하였다. 번역 API의 노이즈를 감안하더라도 이는 검색에 있어 의미적 정보뿐만 아니라 언어에 대한 정보가 여전히 남아 있음을 확인할 수 있었다. 제안모델의 경우 베이스 라인보다는 높은 성능이지만 표 1의 결과 대비 오답율이 증가한 것을 확인할 수 있다.

마지막으로 그림 3에서 사전학습만 진행된 "no tuning" 모델과 영어만을 사용한 베이스라인 모델인 "en only", 본 논문에서 제안한 모델인 "+LP 손실 함수"의 임베딩 t-SNE 시각화 결과이다. 시각화 결과 사전학습만 진행된 모델은 언어 및 문장구조(point type)에 따라 군집을 형성하였고, 제안 모델과 베이스 라인 모델은 상대적으로 문장의 의미적 정보(color)를 더반영하여 군집이 형성되는 것을 확인할 수 있었다.

결론

본 연구에서는 다국어 정보 검색에서 발생하는 언어 편향 문 제를 해결하고 다른 언어 간의 alignment를 향상시키기 위한 방법으로 적대적 언어 적응 학습 방식을 제안하였고, 실험을 통해 타겟 언어의 검색 성능의 향상을 실험적으로 입증하였다.

실험 결과로는 제안한 모델이 베이스라인 모델을 능가하는 성능을 보였고, 이는 영어-타켓 언어 병렬 말뭉치와 언어 예측 태스크를 활용한 학습이 언어 편향 문제를 완화하고 다국어 정보 검색 모델의 성능 향상에 기여할 수 있음을 확인하였다.

그러나 Cross-Lingual Retrieval 실험에서는 번역된 쿼리와

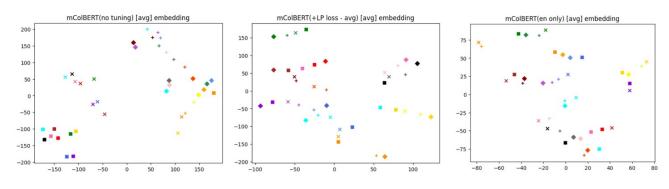


그림 3. 임베딩 시각화 결과

문서 간의 언어적 차이로 인해 모델의 성능 하락이 나타났으며, 이는 언어 간 의미적 정보와 언어적 특성 사이의 상호작용이 여 전히 어려운 과제임을 시사한다. 더 나아가 효과적인 언어 적응 방법에 대한 연구가 필요할 것으로 보인다.

추후 연구로는 ColBERT 모델의 토큰 레벨의 상호작용을 고려하여 문장이 아닌 토큰 단위의 언어 편향성을 제거하기 위한연구를 진행하고자한다.

감사의 글

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음(IITP-2023-2020-0-01789) 또한, 본 논문은 2023년도 정부(과학기술 정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아수행된 연구임 (No.2022-0-00653, 보이스피싱 정보 수집·가공및 빅데이터 기반 수사지원시스템 개발)

참고문헌

- [1] 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
- [2] R. Nogueira and K. Cho, "Passage re-ranking with bert," arXiv preprint arXiv:1901.04085, 2019.
- [3] O. Khattab and M. Zaharia, "Colbert: Efficient and effective passage search via contextualized late interaction over bert," Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval, ser. SIGIR '20, p. 39–48, 2020. [Online]. Available: https://doi.org/10.1145/3397271.3401075

- [4] E. Vanmassenhove, D. Shterionov, and M. Gwilliam, "Machine translationese: Effects of algorithmic bias on linguistic complexity in machine translation," arXiv preprint arXiv:2102.00287, 2021.
- [5] S. Nair, E. Yang, D. Lawrie, K. Duh, P. McNamee, K. Murray, J. Mayfield, and D. W. Oard, "Transfer learning approaches for building cross-language dense retrieval models," *European Conference on Information Retrieval*, pp. 382–396, 2022.
- [6] X. Zhang, K. Ogueji, X. Ma, and J. Lin, "Towards best practices for training multilingual dense retrieval models," arXiv preprint arXiv:2204.02363, 2022.
- [7] J. Devlin, M.-W. Chang, K. Lee, and K. Toutanova, "Bert: Pre-training of deep bidirectional transformers for language understanding," arXiv preprint arXiv:1810.04805, 2018.
- [8] S. Robertson, H. Zaragoza et al., "The probabilistic relevance framework: Bm25 and beyond," Foundations and Trends® in Information Retrieval, Vol. 3, No. 4, pp. 333–389, 2009.
- [9] N. Thakur, N. Reimers, A. Rücklé, A. Srivastava, and I. Gurevych, "Beir: A heterogenous benchmark for zeroshot evaluation of information retrieval models," arXiv preprint arXiv:2104.08663, 2021.
- [10] K. Santhanam, O. Khattab, J. Saad-Falcon, C. Potts, and M. Zaharia, "ColBERTv2: Effective and efficient retrieval via lightweight late interaction," Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, pp. 3715–3734, Jul. 2022. [Online]. Available: https://aclanthology.org/2022.naacl-main.272
- [11] M. Li, S.-C. Lin, B. Oguz, A. Ghoshal, J. Lin,

- Y. Mehdad, W.-t. Yih, and X. Chen, "CITADEL: Conditional token interaction via dynamic lexical routing for efficient and effective multi-vector retrieval," Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers), pp. 11891–11907, Jul. 2023. [Online]. Available: https://aclanthology.org/2023.acl-long.663
- [12] T. Pires, E. Schlinger, and D. Garrette, "How multilingual is multilingual bert?" arXiv preprint arXiv:1906.01502, 2019.
- [13] P. Keung, Y. Lu, J. Salazar, and V. Bhardwaj, "Don't use english dev: On the zero-shot cross-lingual evaluation of contextual embeddings," arXiv preprint arXiv:2004.15001, 2020.
- [14] S. Joty, P. Nakov, L. Màrquez, and I. Jaradat, "Crosslanguage learning with adversarial neural networks: Application to community question answering," arXiv preprint arXiv:1706.06749, 2017.
- [15] T. Sherborne and M. Lapata, "Zero-shot cross-lingual semantic parsing," arXiv preprint arXiv:2104.07554, 2021.
- [16] X. Hu, X. Chen, P. Qi, D. Kong, K. Liu, W. Y. Wang, and Z. Huang, "Language agnostic multilingual information retrieval with contrastive learning," arXiv preprint arXiv:2210.06633, 2022.
- [17] Y. Ganin, E. Ustinova, H. Ajakan, P. Germain, H. Larochelle, F. Laviolette, M. Marchand, and V. Lempitsky, "Domain-adversarial training of neural networks," The journal of machine learning research, Vol. 17, No. 1, pp. 2096–2030, 2016.
- [18] P. Bajaj, D. Campos, N. Craswell, L. Deng, J. Gao, X. Liu, R. Majumder, A. McNamara, B. Mitra, T. Nguyen et al., "Ms marco: A human generated machine reading comprehension dataset," arXiv preprint arXiv:1611.09268, 2016.
- [19] X. Zhang, N. Thakur, O. Ogundepo, E. Kamalloo, D. Alfonso-Hermelo, X. Li, Q. Liu, M. Rezagholizadeh, and J. Lin, "Making a miracl: Multilingual information retrieval across a continuum of languages," arXiv preprint arXiv:2210.09984, 2022.