

그래프 엣지 정보를 활용한 한국어 서술형 수학 문제 풀이 성능 개선 연구

여상엽, 박제만, 권용인
한국전자통신연구원

tkdduq3450@gmail.com, jeman@etri.re.kr, yongin.kwon@etri.re.kr

A Study on the Performance Improvement of Korean Math Word Problem Solving Using Labeled-Edge Information

SangYeop Yeo, JeMan Park, Yongin Kwon
Electronics and Telecommunications Research Institute

요 약

최근 딥 러닝을 통한 서술형 수학 풀이에 대한 관심이 증가하고 있고, 다양한 풀이 방법들이 제시되어 왔다. 그 중 영어 데이터를 통한 학습 분야에서 SOTA 를 달성한 EEH(Edge Enhanced Hierarchical) 그래프 인코더는 노드간 관계를 담은 엣지 정보를 전역으로 확대하여, 기존의 그래프와 트리를 활용한 방법의 한계점인 지역적 정보만을 활용한다는 점을 개선하였다. 본 논문에서는 영어 데이터에서 좋은 성능을 보인 EEH 그래프 인코더가 한국어 데이터를 통한 학습을 진행했을 때 성능 향상이 되는지 확인한다. 실험 결과 한국어 데이터를 통한 학습에서 0.21% ~ 1.56%의 성능이 향상되었음을 확인할 수 있었다.

I. 서 론

딥 러닝 분야에서 서술형 수학 문제는 회계, 통계, 추론 등의 다양한 상황에서 발생할 수 있는 수학적 문제가 언어와 숫자 표현으로 구성된 형태를 말한다. 서술형 수학 문제 풀이란 자연어 처리 기술을 이용해 문제를 언어적, 수적, 논리적 능력으로 분석하고 이를 해결하는 방법을 말한다. 최근 딥 러닝 분야에서 서술형 수학 문제 풀이에 대한 관심이 높아졌고 많은 방법들이 제시가 되었다. 그 중 그래프와 트리를 활용한 방법은 [1] 개체 간의 관계를 이해하고 수식을 표현하는데 효과적이라는 것을 보여주었다. 하지만 그래프와 트리를 사용한 방법은 최종 표현식을 생성할 때 이미 생성된 토큰의 지역 정보만을 활용하여 다음 토큰을 예측하기 때문에 전체 문제의 정보를 사용하지 않는다는 한계를 가지고 있다. 이를 극복하기 위하여 그래프 노드들의 전역관계 정보를 활용 EEH(Edge Enhanced Hierarchical) 그래프 인코더가 제안되었다.[2] EEH 그래프 인코더는 기존 그래프 트리 방법을 기반으로 간선을 추가하여 추가적인 연관 관계를 나타낸 Edge labeled graph 를 활용하여 학습을 진행한다. 이 방법은 EEH 그래프 인코더를 사용하지 않은 방법 대비 최대 2%의 성능 향상을 보였다. 본 논문에서는 영어 데이터에서 좋은 성능을 보여준 EEH 그래프 인코더를 한국어 데이터에 적용했을 때 성능의 향상이 이루어 지는지 확인한다. 본 실험에서는 서술형 수학 문제 풀이를 위해 널리 사용하는 MAWPS, ASDIV 데이터 세트를 활용하였다. 번역 작업은 1 차로 구글에서 지원하는 번역기를 사용하여 MAWPS, ASDIV 데이터를 전체적으로 변환하는 과정을 거쳤다. 2 차 번역은 대학생 이상의 학력을 갖춘 3 명의 인원을 모집하여 번역 오류와 어색한 문장을 교정하는 수작업을 수행하는 것으로 완료하였다. MAWPS, ASDIV 데이터 세트는 각각 1843, 2305 개의 데이터로 구성되어 있다.

II. 본론

한국어 데이터에서의 효과를 확인하기 위하여, 본 논문에서 사용된 EEH 그래프 인코더는 Edge-labeled 그래프를 활용한다. Edge-labeled 그래프는 라벨을 가지고 있는 노드들로 이루어져 있으며, 라벨은 문법적 관계와 종류, 위치 등의 정보를 포함한다. 이러한 정보를 포함하기 위하여 주어진 문제의 문법적 관계를 표현한 의존 트리와, 단어 간의 관계를 기록한 외부 데이터 베이스를 활용한다. 의존 트리는 Stanford CoreNlp Toolkit [3]을 통하여 각 문제 별로 추출하였으며, 각 단어 간의 관계에 대한 정보를 가지는 외부 데이터 베이스는 기존에 번역된 것을 사용하였다. Edge-labeled 그래프는 그림 1 과 같이 구성된다.

그림 1. Edge-labeled 그래프 표현 예시

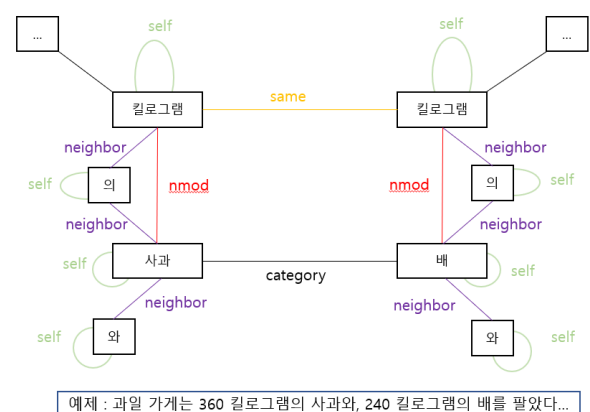


표 1 한국어 데이터에서의 각 모델의 예측 결과

case 1: 어릿광대는 number0 개의 풍선을 가지고 있었다. 그는 파티 후에 number1 개를 남겼다. 그는 파티에서 얼마나 많은 풍선을 사용했는가?
GTO, EEH: - number0 number1 (correct)
case 2: 트리비아 팀은 총 number0 명의 멤버가 있었지만 number1 명의 경기 동안 모습을 드러내지 않았다. 각 멤버가 number2 점을 기록했다면, 몇 점을 합산했을까?
GTO: - - number0 number1 number2 (wrong) EEH: * - number0 number1 number2 (correct)

그림 1 에서 Edge-labeled 그래프는 노드들의 관계 정보 (Labeled Edge)를 지역 정보, 의존 정보, 외부 정보의 3 가지 요소를 기반으로 추가한다.

지역적 정보를 포함하기 위한 자가회귀 노드와 양 옆의 노드를 가리키는 'Self node & Neighbor', 의존 트리를 통해 얻은 문법적 관계를 나타내는 'Dependency', 외부 데이터 베이스를 사용하여 연결하는 같은 노드에 대하여 'Same', 같은 분류의 노드에 대하여 'Category' 간선을 사용하여 관계를 표현한다. 이렇게 구성된 Edge-labeled 그래프는 서술형 수학 문제 노드의 지역적 전역적 관계를 포함하며 학습에 활용된다.

실험은 총 5 회 수행하였고 아래의 식으로 계산하고 평균을 내어 그 결과를 수치화 하였다.

$$Accuracy = \frac{\text{올바르게 예측한 샘플 개수}}{\text{전체 샘플 개수}},$$

편의상 EEH 그래프 인코더의 사용 유무에 따라 그래프와 트리만을 사용한 모델은 GTO(Graph Tree Only), EEH 그래프 인코더를 사용한 모델은 EEH 라고 부른다.

표 2 한국어 데이터셋 학습 결과

	MAWPS	ASDIV
GTO	82.81%	78.22%
EEH	83.02%	79.78%

표 3 영어 데이터셋 학습 결과

	MAWPS	ASDIV
GTO	88.23%	84.38%
EEH	89.09%	85.21%

표 2 는 한국어 데이터 세트를 통한 학습 결과를 보여준다. GTO 방법을 통한 한국어 데이터 학습은 MAWPS, ASDIV 각각 82.81%, 78.22%의 정확도를 보여주었다. EEH 방법을 통한 한국어 데이터 학습은 두 데이터 세트 각각 83.02%, 79.78%의 정확도를 보여주었다. 표 3 은 영어 데이터 세트를 통한 학습 결과를 보여준다. GTO 방법을 통한 영어 데이터 학습은 MAWPS, ASDIV 각각 88.23%, 84.38%의 정확도를 보여주었다. EEH 방법을 통한 영어 데이터 학습은 두 데이터 세트 각각 89.09%, 85.21%의 정확도를 보여주었다. 한국어 데이터 세트를 통한 학습에서 EEH 방법은 GTO 방법 대비 0.21% ~ 1.56% 성능이 향상되었음을 확인할 수 있었다. 영어 데이터 세트를 통한 학습에서는 EEH 방법이 0.83% ~ 0.86% 정도 성능이 향상되었음을 확인하였다. EEH 방법을 통한 학습이 영어 데이터 세트를 사용한 학습에서 성능의 향상을 보여주는 것을 확인할 수 있었고, 한국어로 번역한 데이터 세트를 활용한 학습에서도 최대

1.56%의 성능 향상이 이루어짐을 확인할 수 있었다.

표 1 은 방법 별로 비슷하지만 다른 예측 결과를 보이는 예시를 보여준다. case1 의 경우 주어진 문제는 하나의 연산자를 필요로 하는 단순한 문제로 2 가지 방법 모두 정답을 예측한 것을 확인할 수 있었다. case 2 의 경우 총 2 가지의 연산자와 3 개의 숫자를 맞춰야 하는 문제로 GTO 방법의 경우 정답을 예측하지 못하였다. 이는 지역적인 특성만을 학습하는 GTO 방법의 한계상 먼 거리에 위치한 토큰에 대한 연산 방법을 예측하지 못하는 것으로 유추한다. 이에 반해 EEH 방법을 통한 학습은 정답을 정확하게 예측하였음을 확인할 수 있다. 이는 EEH 그래프 인코더를 통한 한국어 데이터의 학습이 토큰 간 장거리의 관계를 파악하고 학습하는데 도움을 줄 수 있다는 것을 시사한다.

III. 결론

본 논문에서는 그래프 엣지 정보를 활용한 서술형 수학 문제 풀이 성능 개선에 대한 연구를 진행하였다. 그 결과 한국어 데이터에서 기존 방법 대비 EEH 그래프 인코더를 사용한 모델의 정확도가 0.21% ~ 1.56%의 향상되었음을 확인할 수 있었다. 하지만 MAWPS, ASDIV 데이터 세트 각각 1843, 2305 개의 적은 개수의 데이터로 구성되어 일반화를 수행하기에는 한계가 있다. 향후 더 많은 데이터를 통한 추가적인 연구가 필요해 보인다.

ACKNOWLEDGEMENT

이 논문은 2023 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2022-0-00454, 스마트 엣지 디바이스 SW 개발 플랫폼 개발)

참 고 문 헌

- [1] Zhang, Jipeng and Wang, Lei and Lee, Roy Ka-Wei and Bin, Yi and Shao, Jie and Lim, Ee-Peng, "Graph-to-Tree Learning for Solving Math Word Problems", ACL 2020, pages 3928- 3937, 2020
- [2] Qinzhuo Wu, Qi Zhang, Zhongyu Wei, "An Edge-Enhanced Hierarchical Graph-to-Tree Network for Math Word Problem Solving", ACL 2021, pages 1473-1482, 2021
- [3] Christopher Manning, Mihai Surdeanu, John Bauer, Jenny Finkel, Steven Bethard, David McClosky, "The Stanford CoreNLP Natural Language Processing Toolkit", ACL 2014, pages 55-60, 2014