

내용 기반 질의응답을 위한 구조적 지식 표현 학습

허유정^o, 온경운, 김은솔, 장병탁

서울대학교 컴퓨터공학부

{yjheo, kwon, eskim, btzhang}@bi.snu.ac.kr

Structural Knowledge Representation Learning for Content-based Question Answering

Yu-Jung Heo^o, Kyoung-Woon On, Eun-Sol Kim and Byoung-Tak Zhang

Department of Computer Science and Engineering, Seoul National University

요 약

본 논문에서는 자연 언어 데이터에 내재되어 있는 구조적 지식을 신경망 기반 알고리즘을 통해 학습하여 문서의 내용에 대한 질의의 응답을 효율적으로 추론하는 모델을 제안한다. 자연 언어 데이터 처리를 위한 기존의 깊은 신경망 네트워크 알고리즘은 연속된 단어들을 수평적인 구조로 처리하여 문장 및 단락의 의미를 분석하는 데에 반하여, 제안하는 모델은 자연 언어 데이터에 내재된 통사론적, 의미론적 정보를 함께 사용하여 문서의 내용을 효율적으로 정확하게 분석할 수 있다. 제안하는 계층적 신경 지식 네트워크는 전통적인 자연 언어 처리 기법으로부터 쉽게 얻을 수 있는 의존성 분석, 동일 지시어 분석 등을 이용하여 기저 지식 그래프를 구축한 후, 그래프 컨볼루션 연산과 풀링 연산을 적용하여 문서의 구조적 지식을 학습한다. 문서의 내용에 대해 자연언어로 묻고 답하는 bAbI 데이터를 사용하여 제안 기법을 검증한 결과, 제안하는 모델이 우수한 성능을 보임을 입증하였다.

1. 서 론

자연 언어 데이터 처리를 위한 기존의 순환 신경망 등의 깊은 신경망 기반 알고리즘은 연속된 단어들을 비순환 방향 그래프의 수평적인 구조로 학습하여, 문장 및 단락의 의미를 분석한다. 기존의 알고리즘은 단어의 순차적인 관계만을 고려하여 처리하므로 문장 혹은 단락이 길어지는 경우, 장기 종속성 문제를 보인다. 또한 문제에 대한 그래프 구조가 변화하는 경우, 학습의 일반화가 어렵다.

본 논문에서는 이러한 문제점을 보완할 수 있는 계층적 신경 지식 네트워크(Hierarchical Neural Knowledge network)를 제안한다. 제안하는 모델은 문서를 구성하는 단어들의 수평적 연결과 함께 자연 언어 데이터에 내재된 통사론적, 의미론적 정보를 사용하여 [3] 문서의 구조지식을 학습하여, 장기 종속성 문제를 완화한다. 또한 해당 모델은 Kipf와 Welling에 의해 제안된 그래프 컨볼루션 연산[2]을 적용하여, 가변적인 그래프 구조에서도 그래프 노드의 직접적인 연산이 가능하다. 본 논문에서는 제안하는 네트워크를 적용하여 지식 그래프를 학습하고 이를 기반으로 문서의 내용 기반의 질의 응답 문제에 적용한다.

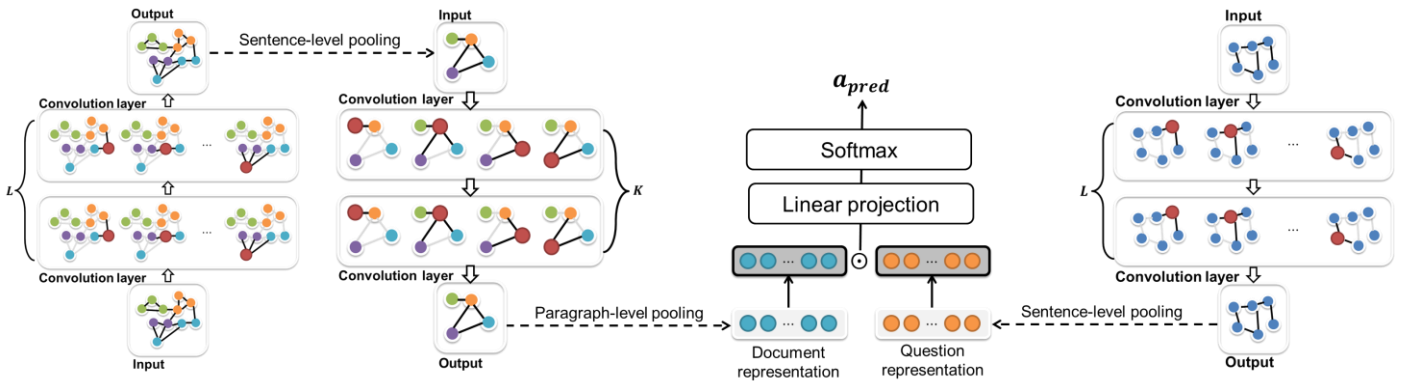
본 논문의 구성은 다음과 같다. 2절에서는 계층적 신경 지식 네트워크를 소개하고, 3절에서는 실험 환경을 설계하며, 추 후 연구의 방향을 소개한다.

2. 계층적 신경 지식 네트워크

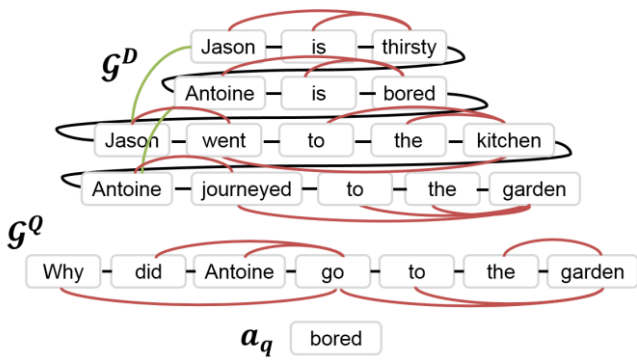
본 절에서는 문서의 구조적 지식을 학습하여 문서의 내용에 대한 질의의 응답을 추론하는 계층적 신경 지식 네트워크를 제안한다. 계층적 신경 지식 네트워크는 기저 지식 그래프를 기반으로 컨볼루션 연산과 풀링 연산을 반복적으로 수행하며 문서의 단어, 문장, 단락, 문서 단위의 구조적 지식을 학습한다. 학습된 문서 표현과 질의 표현은 하다마드 곱셈을 통해 상호 연관을 반영하여 결합되고, 이를 기반으로 정답을 추론한다. 제안한 모델의 개요는 그림 1과 같다.

2.1 기저 지식 그래프

자연 언어 데이터에 내재되어 있는 구조적 지식을 학습하기 위해 기저 지식 그래프를 정의한다. 기저 지식 그래프 $g = (\mathcal{V}, \mathcal{E})$ 의 \mathcal{V} 는 노드의 집합이고 i 번째 노드 v_i 는 word2vec을 이용하여 각 단어를 d 차원의 분산 표현으로 부호화한 벡터이다. 단어 노드 사이의 연결의 집합 $\mathcal{E} = \{v_i, v_j\}$ 는 각 단어 간의 순차적 연결 뿐 아니라 자연 언어 분석을 통해 추출한 통사론적, 의미론적 연결을 포함한다. 문서의 기저 지식 그래프 g^p 와 질의의 기저 지식 그래프 g^q 의 예시는 그림 2와 같다.



[그림 1] 계층적 신경 지식 그래프의 개요도



[그림 2] 생성된 문서의 기저 지식 그래프 G^D 와 질의 기저 그래프 G^Q , 주어진 질의의 정답 a_q 의 예시

2.2 컨볼루션 레이어

그래프 구조로 이루어진 문서 데이터를 학습하기 위해 그래프 컨볼루션 네트워크[2]의 컨볼루션 레이어 연산을 적용한다.

$$H^{l+1} = \sigma \left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^l W^l \right) \quad (1)$$

이 때, A 는 그래프 G 의 인접행렬이며, $\tilde{A} = A + I_N$ 는 N 개의 그래프 노드의 순환 연결(self-connection)을 포함하는 인접행렬이며, $\tilde{D}_{ii} = \sum_j \tilde{A}_{ij}$ 이다. W^l 는 l 번째 레이어의 학습 가능한 가중치 파라미터이며, σ 는 $ReLU = \max(0, \cdot)$ 등의 활성화 함수이다. H^l 는 l 번째 레이어의 행렬이며, 0번째 레이어의 행렬 $H^0 = X$ 이고 이 때 X 는 그래프 G 의 노드 v 의 특징 행렬이다.

2.3 풀링 레이어

계층적 신경 지식 그래프에서는 평균 풀링(Average pooling)을 수행하여, 상위 계층의 그래프를 구성한다. 단어 수준의 기저 지식 그래프의 풀링 연산으로 형성된 문장-단락-문서 수준의 그래프에서의 노드는 각각 문장,

단락, 문서이며, 노드간의 연결은 기저 지식 그래프의 단어간 연결이 문장간 연결, 단락간 연결, 문서간 연결로 확장된 것과 동일하다.

2.4 정답 레이어

문서에 대한 질의의 응답을 추론하기 위해 정답 레이어는 문서 표현 $\mathcal{D} \in \mathbb{R}^d$ 과 질의 표현 $\mathcal{Q} \in \mathbb{R}^d$ 을 결합한다. 이 때, 두 표현의 상관 관계를 고려하기 위해 바이리니어(full bilinear) 풀링을 근사화 한 하다마드 곱셈(hadamard product) \odot 을 수행한다[5]. 정답 레이어의 출력 a_{output} 은 식 (2)과 같다.

$$a_{output} = \text{softmax} \left(W_0 \left(W_D(\mathcal{D}) \odot W_Q(\mathcal{Q}) \right) + b_0 \right) \quad (2)$$

2.5 학습

정답 $a_q \in \mathbb{R}^o$ 는 one-hot 인코딩된 벡터이며, o 는 전체 데이터에 존재하는 유일한 정답의 개수이다. 모델의 예측값 $a_{pred} = \text{argmax}(a_{output})$ 과 정답 a_q 의 크로스 엔트로피 오차를 줄이도록 학습한다. 해당 모델을 구성하는 각 레이어의 연산은 미분이 가능하며, 오류 역전파와 기울기 하강법을 적용하여 종단간 학습이 가능하다.

3. 실험 설계 및 추후 연구 방향

본 논문에서 제안한 계층적 신경 지식 네트워크를 페이스북의 bAbI 데이터[4]를 비롯한 다양한 텍스트 질의 응답 벤치마킹 데이터에 적용하여 결과를 보인다. 텍스트 질의응답 수행 시, 질의를 반영하여 문서의 각 단어에 대한 주의 기제를 부여하고, 성능 비교 실험을 수행한다.

문서의 크기가 가변적이어서 그래프의 크기의 편차가 큰 경우의 효율적인 질의응답의 수행 혹은 문서가 지속적으로 많아져 그래프의 크기가 지속적으로 증가하는 상황에 대한 온라인 학습 또한 추후 연구의 방향으로 고려될 수 있다.

감사의 글

이 논문은 2017년도 정부(미래창조과학부)의 재원으로 정보통신기술진흥센터(2015-0-00310-SW스타랩), 한국산업기술평가관리원(10044009-HRI.MESSI, 10060086-RISF)의 지원을 받았음.

참고 문헌

- [1] Defferrard, Michaël, Xavier Bresson, and Pierre Vandergheynst. "Convolutional neural networks on graphs with fast localized spectral filtering." *Advances in Neural Information Processing Systems(NIPS)*, 2016.
- [2] Kipf, Thomas N., and Max Welling. "Semi-supervised classification with graph convolutional networks." *International Conference on Learning Representations(ICLR)*, 2017
- [3] Dhingra, Bhuwan, et al. "Linguistic Knowledge as Memory for Recurrent Neural Networks." *arXiv preprint arXiv:1703.02620* (2017).
- [4] Weston, Jason, et al. "Towards ai-complete question answering: A set of prerequisite toy tasks." *International Conference on Learning Representations(ICLR)*, 2016
- [5] Kim, Jin-Hwa, et al. "Hadamard product for low-rank bilinear pooling." *International Conference on Learning Representations(ICLR)*, 2017