

쌍 선형 그래프 신경망을 이용한 지식 그래프 기반 질문 응답

이상의, 김인철

경기대학교 컴퓨터과학과

rmrlrmrl124@kyonggi.ac.kr, kic@kyonggi.ac.kr

Question Answering over Knowledge Graphs Using Bilinear Graph Neural Network

Sangui Lee, Incheol Kim

Department of Computer Science, Kyonggi University

요 약


지식 그래프 기반의 질문 응답 문제는 자연어 질문에 대한 이해뿐만 아니라, 기반이 되는 지식 그래프상에서 올바른 답변을 찾기 위한 효과적인 추론 능력을 요구한다. 본 논문에서는 다중 홉 추론을 요구하는 복잡한 자연어 질문에 대해 연관 지식 그래프 위에서 답변 추론을 효과적으로 수행할 수 있는 심층 신경망 모델을 제안한다. 제안 모델에서는 지식 그래프상의 추론 과정에서 추론 경로를 명확히 하기 위한 노드의 양방향 특징 전파와 이웃 노드들 간의 맥락 정보까지 각 노드의 특징값에 반영할 수 있는, 표현력이 풍부한 쌍 선형 그래프 신경망(BGNN)을 이용한다. 본 논문에서는 오픈 도메인의 지식 베이스 Freebase와 자연어 질문 응답 데이터 집합 WebQuestionsSP를 이용한 실험들을 통해, 제안 모델의 효과와 우수성을 확인하였다.

1. 서론

대규모 지식 베이스를 토대로 인간을 대신해 자연어 질문에 스스로 답할 수 있는 지능형 에이전트는 실세계 다양한 분야에서 폭넓게 활용될 수 있다. 특히 최근 들어 심층 신경망(deep neural network)을 이용한 자연어 처리 기술들이 획기적으로 발전함에 따라, 지식 베이스 기반 질문 응답(Knowledge Base Question Answering, KBQA) 문제와 이를 해결하기 위한 다양한 모델들에 관한 관심도 함께 증가하고 있다. 일반적으로 비정형 문서 집합(corpus)에 비해, 지식 베이스(knowledge base)는 대부분 트리플(triplet)과 같은 구조화된 형태로 지식을 저장하고 있으므로 질문 응답(QA)에 활용하기가 상대적으로 용이하다. 하나의 지식 트리플은 주어 개체(subject entity), 관계 서술자(relational predicate), 목적어 개체(object entity)로 구성되는데, 이것은 두 개체 간의 관계를 나타내는 하나의 사실(fact)로 간주할 수 있다. 따라서 다수의 트리플들로 이루어진 지식 베이스는 개체 노드(node)들과 그들 간의 관계를 표현하는 간선(edge)들로 구성되는 하나의 큰 지식 그래프(knowledge graph)로 볼 수 있다. 이러한 지식 그래프를 토대로 자연어 질문에 대한 답변을 찾기 위해서는 지식 그래프 위에서 전개되는 효율적인 추론(reasoning) 혹은 탐색(search) 과정이 요구된다.

한편, 지식 그래프 기반 질문 응답 문제는 추론의 복잡도에 따라 단순 질문(simple question)과 복잡 질문(complex question)으로 나뉜다. 일반적으로 질문에 대한 답변을 위해 지식 그래프 위에서 단일 홉(single hop) 추론이 필요하나 아니면 다중 홉(multi-hop) 추론이 필요하나에 따라 단순 질문과 복잡 질문을 구분한다. 본 논문에서는 특히 다중 홉 추론을 요구하는 지식 그래프 기반 질문 응답 모델을 제안한다.


(그림 1)은 지식 그래프를 이용한 다중 홉 추론의 한 예를 보여준다. (그림 1)에서 개체는 타원형으로, 개체 사이의



(그림 1) 지식 그래프를 이용한 다중 홉 추론의 예

관계는 간선으로 표현되어 있다. (그림 1)의 상단에서처럼 자연어 질문이 주어지면 지식 베이스로부터 질문과 연관된 지식 그래프를 추출해야 한다. 지식 그래프를 추출할 때 질문에 언급된 개체를 중심으로 추출하며, 추출한 지식 그래프로부터 답을 추론할 수 있어야 한다. 다중 홉 추론을 요구하는 복잡 질문인 “Who played Obi-Wan in Episode 2?”에 대해 답변인 Ewan McGregor를 찾으려면 먼저 질문과 연관 있는 트리플 <Star Wars Episode II: Attack of the Clones, characters, Obi-Wan Kenobi>을 찾아야 한다. 이 트리플로부터 질문의 답변인, Obi-Wan Kenobi를 연기한 Ewan McGregor를 포함하는 트리플 <Obi-Wan Kenobi, performer, Ewan McGregor>을 찾을 수 있어야 한다.

지식 그래프를 이용한 다중 홉 추론에 관해 기존 연구 [1]에서는 (키(key), 값(value)) 쌍의 메모리 슬롯에 트리플들을 저장하고, 자연어 질문과 키(key)의 연관성에 따른 값(value)들의 가중치 합(weighted sum)을 이용해 메모리 슬롯을 반복적으로 참조하여 답변 개체를 예측하는 KVMN 모델을 제안하였다. 이때 키(key)는 트리플의 주어 개체와 관계 서술자로 이루어진 튜플(tuple)에 해당하고 값(value)은 목적어 개체에 해당한다. 한편, 기존 연구



(그림 2) 제안 모델의 전체 구조

[2]에서는 그래프 합성곱 신경망(Graph Convolutional Network, GCN)[3]과 페이지랭크(PageRank) 점수를 이용한 지식 그래프 추론을 수행하는 GraftNet 모델을 제안하였다. 그러나 이러한 기존 연구들은 KVMN 모델과 같이 지식 그래프 추론 과정에 그래프 이웃 노드들과의 맥락 정보(structural context)를 반영하려는 별도의 노력이 없거나, 그래프 합성곱 신경망(GCN)에 기초한 GraftNet 모델처럼 이웃 노드들의 특징 정보를 단순 선형 응집(Linear Aggregation, LA)해서 얻은 맥락 정보만을 활용하였다. 하지만 대규모 지식 그래프 위에서 다중 홉 추론을 요구하는 다양한 복잡 질문(complex question)들에 대한 올바른 답변을 찾아내려면, 각 노드와 이웃 노드 간의 맥락 정보뿐만 아니라 이웃 노드와 이웃 노드 간의 맥락 정보도 효과적으로 활용할 수 있는 그래프 신경망(Graph Neural Network) 기반의 지식 그래프 추론 모델이 요구된다.

이러한 기존 연구들의 한계점을 고려하여, 본 논문에서는 새로운 그래프 신경망 기반의 질문 응답 모델을 제안한다. 제안 모델에서는 질문에 대한 효과적인 지식 그래프 추론을 위해 그래프 노드들 간의 양방향 특징 정보 전파(bidirectional propagation) 기능을 포함하고 있을 뿐만 아니라, 두 이웃 노드들 간의 맥락 정보도 활용할 수 있는 쌍 선형 응집(Bilinear Aggregation, BA) 연산이 추가된 쌍 선형 그래프 신경망(Bilinear Graph Neural Network, BGNN)을 새롭게 채용하고 있다. 본 논문에서는 제안 모델의 성능 평가를 위해 WebQuestionsSP[4] 벤치마크 데이터 집합을 이용한 다양한 실험들을 수행하고, 그 결과를 소개한다.

2 다중 홉 오픈 도메인 질문 응답

2.1 문제 정의

본 논문에서는 지식 베이스로부터 추출된, 질문과 연관된 지식 그래프상에서 자연어 질문에 대한 답을 추론하는 문제를 다루고 있다.

지식 베이스는 $K = (V, E, R)$ 로 정의할 수 있다. 여기서 K 는 지식 베이스, V 는 개체들의 집합, E 는 트리플 $t = (s, r, o)$ ($s, o \in V, r \in R$)들의 집합, R 은 개체들 사이의 관계 서술자들의 집합이다. Q 는 자연어 질문들의 집합, 질문은 단어들의 집합으로 정의할 수 있다. $q \in Q$ 에 대해, K 에서의 q 와 연관된 지식 그래프 g 를 $g = (q, K)$ 로 정의할 수 있다.

질문 응답(QA) 작업은 g 에서 q 에 대한 답 $v \in V$ 찾기 로 정의할 수 있다. 다중 홉 추론은 v 를 찾기 위해 g 에서 q 에 언급된 개체 s 로부터 v 까지의 경로 $d = (t_1, t_2, \dots, t_{|d|})$ 찾기로 정의할 수 있다. d 를 구성하는 t_{n-1} 의 o 는 t_n 의 s

와 같은 개체이다.

2.2 제안 모델

(그림 2)는 본 논문에서 제안하는 모델의 전체 구조도를 나타낸다. 입력으로 질문과 지식 그래프를 갖고, 출력으로 질문에 대한 답변인 개체를 갖는다. 여기서 지식 그래프는 [2]의 전처리(preprocessing)를 이용하여 지식 베이스인 FreeBase로부터 추출한, 질문과 연관된 지식 그래프를 이용한다. 제안하는 모델은 질문 인코딩(Question Encoding), 지식 그래프 추론(Knowledge Graph Reasoning), 답변 예측(Answer Prediction)으로 이루어져 있다.

질문 인코딩은 순환 신경망(Recurrent Neural Network)의 한 종류인 LSTM(Long Short-Term Memory)으로 자연어 질문을 인코딩하여 특징을 추출한다. 추출된 특징은 지식 그래프 추론에서 초기에 사용된 후 매 레이어(layer)마다 질문에 언급된 개체들의 노드 특징들 간의 맥락 정보로 다시 인코딩된다.

지식 그래프 추론은 지식 그래프상에서 질문에 대한 답변을 찾는 다중 홉 추론을 수행한다. 지식 그래프가 입력으로 들어오면, 각 노드에 대해 쌍 선형 그래프 신경망을 이용하여 이웃 노드들 간의 맥락 정보를 얻는다. 이렇게 얻은 맥락 정보와 질문 인코딩에서 얻은 질문의 특징을 활용하여 노드의 특징을 갱신하는 개체 노드 갱신(Entity node update)을 수행한다.


마지막으로 답변 예측은 지식 그래프 추론을 거쳐 나온 개체 노드들에 대해 시그모이드(sigmoid) 함수를 적용한다. 그 결과로 가장 높은 점수를 받은 개체 노드가 질문에 대한 답변으로 선택된다.

2.3 지식 그래프 추론

지식 그래프 추론에 앞서 신경망을 학습하기 위해 질문, 개체와 관계 서술자를 임베딩한다. 질문과 관계 서술자는 GloVe 임베딩 값을 이용한다. 개체 노드의 초기 특징값은 GloVe 임베딩 값과 지식 그래프를 미리 학습한 임베딩 값을 이용한다.

지식 그래프 추론 과정에서 다중 홉 추론을 수행하기 위해 쌍 선형 그래프 신경망의 구조를 채용한다. 즉, 기존에 선형 응집만 수행하던 연구들과 다르게 본 논문에서는 쌍 선형 응집(BA)을 추가하여 같이 사용한다. 갱신되는 노드를 목표 노드(target node)라고 할 때, 쌍 선형 응집을 사용하면 목표 노드와 이웃 노드 간의 맥락 정보뿐만 아니라 목표 노드의 이웃 노드들 간의 맥락 정보도 활용할 수 있다. 쌍 선형 응집으로 얻은 맥락 정보는 노드들

간의 요소별 곱(element-wise product)으로 인해 서로 유사한 특징 정보가 강조된 정보를 갖는다. 선형 응집과 쌍 선형 응집을 같이 사용함으로써 노드에 대한 다양한 맥락 정보를 토대로 효과적인 다중 홉 추론을 기대할 수 있다.



(그림 3) BA-A와 BA-T의 구조

쌍 선형 응집은 계산 방식에 따라 BA-A와 BA-T로 나눌 수 있고, 그에 따라 쌍 선형 그래프 신경망의 형태가 BA-A를 사용한 BGNN-A와 BA-T를 사용한 BGNN-T로 나눌 수 있다. (그림 3)은 BA-A와 BA-T를 나타낸 그림이다.

BA-A는 목표 노드와 이웃 노드, 이웃 노드와 이웃 노드끼리 요소별 곱을 수행하여 맥락 정보를 구하는 방식으로 (식 1)과 같다.

$$BA-A^l(v) = FFN\left(\frac{1}{2} \sum_{v'} \sum_{v''} (h_v^{(l-1)} \odot h_{v'}^{(l-1)}) + \sum_{v'} (h_v^{(l-1)} \odot h_{v''}^{(l-1)})\right) \quad (v', v'' \in N(v), v' \neq v'') \quad (식 1)$$

$N(v)$ 은 목표 노드의 이웃 노드들의 집합을 뜻한다. (식 1)에서 이웃 노드끼리 요소별 곱을 수행하면 같은 계산을 2번 하게 되므로 2로 나눈다.

BA-T는 목표 노드와 이웃 노드만 요소별 곱을 수행하여 맥락 정보를 구하는 방식으로 (식 2)와 같다.

$$BA-T^l(v) = FFN\left(\sum_{v'} (h_v^{(l-1)} \odot h_{v'}^{(l-1)})\right) \quad (v' \in N(v)) \quad (식 2)$$

본 논문에서는 목표 노드와 이웃 노드 간의 맥락 정보를 활용하는 BA-T를 이용한다. 3.2절 성능 평가 실험에서 BA-A를 사용한 모델과 BA-T를 사용한 모델의 다중 홉 추론 능력을 비교한다.


개체 노드 갱신은 (그림 4)와 같은 구조를 갖는다. 이는 (식 3)과 같이 나타낼 수 있다.

$$h_v^l = (1 - \alpha) * LA^l(v) + \alpha * BA^l(v) \quad (식 3)$$

(식 3)에서 α 는 하이퍼파라미터에 해당한다. α 의 값에 따라 선형 응집(LA)과 쌍 선형 응집(BA)의 적용 비율이 달라진다. LA에 대한 계산은 (식 4)에서처럼 차례대로 목표 노드의 특징 $h_v^{(l-1)}$, 자연어 질문의 특징 $h_q^{(l-1)}$, 선형 응집에 의한 이웃 노드들의 맥락 정보 $h_N^{(l-1)}$ 을 이용한다. (식 4)의 $\parallel$ 기호는 연결(concatenation)을 뜻한다.

$$LA^l(v) = FFN([h_v^{(l-1)} \parallel h_q^{(l-1)} \parallel h_N^{(l-1)}]) \quad (식 4)$$

선형 응집에 의한 이웃 노드들의 맥락 정보 $h_N^{(l-1)}$ 을 계산할 때는 목표 노드에 연결된 간선의 방향을 고려한다. 다중 홉 추론에서 목표 노드로 들어오는 간선과 연결된 이웃 노드들의 특징들은 목표 노드에 대한 추론 경로에 해당하는 정보로 볼 수 있다. 반대로, 목표 노드로부터 나가는 간선과 연결된 이웃 노드들의 특징들은 목표 노드에 대한 추론 경로에 해당하지 않는 정보로 볼 수 있다. 따라



(그림 4) 개체 노드의 갱신

서, (식 5)와 같이 선형 응집에 의한 이웃 노드들의 맥락 정보 $h_N^{(l-1)}$ 을 계산할 때 목표 노드로 들어오는 간선과 연결된 이웃 노드들의 특징들은 더하고 목표 노드로부터 나가는 간선과 연결된 이웃 노드들의 특징들은 빼도록 계산한다. 또한, 목표 노드가 이웃 노드들과 맺는 관계와 질문의 연관성에 따라 다른 주의집중(attention)을 주면서 가중치 합을 계산한다. 이렇게 함으로써 질문과 연관성이 높은 관계를 맺는 이웃 노드의 특징에 더 큰 가중치를 줄 수 있다.

$$h_N^{(l-1)} = FFN\left(\sum_r \sum_{v' \in N_r^-(v)} \gamma_r^{v'} FFN(x_r, h_{v'}^{(l-1)})\right) - FFN\left(\sum_r \sum_{v' \in N_r^+(v)} \gamma_r^{v'} FFN(x_r, h_{v'}^{(l-1)})\right) \quad (식 5)$$

(식 5)에서 $r \in INR$ 에 대해, N_r^- 는 노드로 들어오는 간선과 연결된 이웃 노드들의 집합, N_r^+ 는 노드로부터 나가는 간선과 연결된 이웃 노드들의 집합을 뜻한다.

질문 응답을 수행하기 위해서 신경망을 학습할 때 질문의 정보를 이용해야 한다. 따라서, (그림 4)처럼 개체 노드의 특징 $h_v^{(l-1)}$ 을 갱신할 때 자연어 질문의 특징 $h_q^{(l-1)}$ 을 이용한다. 또한, 선형 응집에 의한 이웃 노드들의 맥락 정보 $h_N^{(l-1)}$ 을 계산할 때도 질문을 이용한 주의집중 γ_r^v 을 준다. 자연어 질문의 특징 $h_q^{(l-1)}$ 은 초기값으로 (식 6)처럼 LSTM의 직전 은닉 상태(hidden state)를 이용한다. 이후 그래프 신경망에서 각 레이어를 거칠 때마다 자연어 질문에 언급된 개체들의 노드들의 맥락 정보로 갱신한다. 자연어 질문과 지식 그래프상의 개체 노드는 서로 다른 멀티모달(multimodal)이므로 처음에만 자연어 질문의 특징을 LSTM으로 인코딩하고 이후에는 질문에 언급된 개체들의 노드 특징들을 이용한 것이다.

$$h_q^l = \begin{cases} LSTM(q) & l = 0 \\ FFN(\sum_{v \in V_q} h_v^l) & l > 0 \end{cases} \quad (식 6)$$

(식 6)의 $v \in V_q$ 는 질문에 언급된 개체의 노드를 뜻한다.

(식 5)에서 자연어 질문과 연관성이 높은 관계에 대해 더 큰 주의집중을 주기 위해 (식 7)과 같이 주의집중 γ_r^v 을 계산한다.

$$\gamma_r^v = \text{softmax}(x_r^T h_q^{(l-1)}) \quad (식 7)$$

x_r 은 관계 서술자의 임베딩 벡터다. v 가 이웃 노드들과 맺는 관계에 대해 소프트맥스(softmax) 정규화가 행해진다.

BA에 대한 계산은 (식 8)에서처럼 쌍 선형 응집 BA-T로 구한, 목표 노드와 이웃 노드 간의 맥락 정보를 이용한다. 실험상 모든 이웃 노드에 대해 쌍 선형 응집을 하는 것보다 목표 노드로 들어오는 간선과 연결된 이웃 노드들에 대해서만 하는 것이 더 좋은 성능을 보였다. 따라서, 본

논문에서는 목표 노드로 들어오는 간선과 연결된 이웃 노드들에 대해서만 쌍 선형 응집을 수행한다.

$$BA^l(v) = FFN([h_v^{(l-1)} \parallel h_q^{(l-1)} \parallel FFN(\sum_{v'} (h_v^{(l-1)} \odot h_{v'}^{(l-1)}))] (v' \in \mathcal{N}_r(v)) \quad (\text{식 8})$$

답변을 추론할 때 모든 노드에 대해 답인지 아닌지 분류하는 이진 분류를 수행한다. 손실 함수로 바이너리 크로스 엔트로피 손실(binary cross entropy loss)을 사용한다.

3. 구현 및 실험

3.1 데이터 집합과 모델 학습

본 논문의 제안 모델은 Ubuntu 16.04 LTS에서 Python 딥러닝 라이브러리인 PyTorch를 이용하여 구현하였다. 모델의 학습 및 평가를 위한 질문-응답 데이터 집합으로는 WebQuestionsSP[4]를 사용하였다. WebQuestionsSP는 지식 베이스인 FreeBase를 토대로 생성한 오픈 도메인 질문-응답 데이터 집합이다. 이 데이터 집합은 총 4737개의 자연어 질문과 답변들 중 3098개는 훈련용(training set), 1639개는 검증용(validation set)으로 구성되어 있다. 특히 전체 질문의 약 70%는 단일 홉 추론을 요구하는 단순 질문들(single-hop simple questions), 약 30%는 2-홉 질문들(double-hop complex questions)이다.

모델 학습을 위해 쌍 선형 그래프 신경망(BGNN)의 레이어 수(number of layers)는 3, 반복 학습주기(epoch)는 100, 배치 크기(batch size)는 10, 학습률(learning rate)은 0.001로 설정하였다. 실험은 64GB의 메인 메모리와 Geforce RTX 2080 SUPER 1개를 포함한 컴퓨터 환경에서 수행되었다.

3.2 성능 평가 실험

본 논문에서는 제안하는 모델의 성능 평가 척도로 Hits@K와 F1 score을 채택하였다. Hits@K는 답변이라고 예측한 것들 중 가장 점수가 높은 K개를 선택했을 때 실제 답변이 포함되어 맞춘 비율을 나타낸 것이다.

첫 번째 실험은 제안하는 모델의 지식 그래프 추론에서 쌍 선형 응집의 효과를 보이는 실험이다. 선형 응집만 썼을 때(LA), 쌍 선형 응집만 썼을 때(BA-A와 BA-T) 그리고 둘 다 사용했을 때(BGNN-A와 BGNN-T) 나타난 성능을 비교하였다. <표 1>은 첫 번째 실험을 수행하여 측정한 표이다. 이 실험에서는 BGNN의 α 값을 BGNN-A에서는 0.1, BGNN-T에서는 0.3으로 설정하였다.

<표 1> 지식 그래프 추론 방식에 따른 성능 비교

method	Hits @1	Hits @5	Hits @10	Hits @20	F1 score
LA	66.9	79.7	83.3	86.0	58.2
BA-A	19.6	19.9	29.4	39.6	0.6
BA-T	44.7	68.9	76.5	82.2	35.4
BGNN-A	67.2	80.5	83.3	86.1	59.1
BGNN-T	68.4	80.9	83.9	86.0	61.0

<표 1>에서 보듯이 선형 응집(LA)과 쌍 선형 응집(BA)을 모두 사용하는 BGNN-T가 모든 척도에서 가장 우수한 성능을 보였다. 또한, 선형 응집(LA)과 쌍 선형 응집(BA)만 비교했을 때는, 선형 응집(LA)의 성능이 쌍 선형 응집(BA)보다 우수한 성능을 나타내었다. 또한, Hits@1을 기준으로 보면, 선형 응집과 쌍 선형 응집을 모

두 사용하는 BGNN-T와 BGNN-A가 선형 응집(LA)만 사용했을 때보다 각각 약 1.5%와 약 0.3% 더 높은 성능을 보여주었다. 또, BGNN-T를 사용했을 때가 BGNN-A를 사용했을 때보다 약 1.2% 더 높은 성능을 보였다. 이러한 실험 결과로 볼 때, WebQuestionsSP 질문-응답에서는 선형 응집(LA)이 쌍 선형 응집(BA)에 비해 상대적으로 성능 향상에 좀 더 도움을 주었으나, 제안 모델과 같이 선형 응집(LA)과 쌍 선형 응집(BA)을 함께 채용한 쌍 선형 그래프 신경망(BGNN)이 가장 높은 성능 개선 효과를 보인 것을 확인할 수 있었다.

두 번째 실험은 제안하는 모델과 기존 선형 연구들의 모델들의 성능을 비교하는 실험으로, <표 2>는 그에 대한 성능 비교표이다.

<표 2> 기존 모델들과의 성능 비교

model	Hits@1	F1 score
KVMN[1]	46.7	38.6
GraftNet[2]	66.7	62.4
Ours	68.4	61.0

<표 2>에서 보듯이 제안하는 모델의 성능이 Hits@1에서 68.4%로 GraftNet[2]보다 약 1.7% 더 높고, F1 score에서는 GraftNet[2]보다 약 1.4% 더 낮다. 비록 F1 score에서 GraftNet[2]보다 더 낮은 성능을 보였지만 Hits@1에서 더 높은 성능을 보여, 질문-응답에서 중요한 답변 추론 능력은 더 뛰어난 것을 확인할 수 있었다. 지식 그래프를 (키(key), 값(value)) 쌍의 메모리 슬롯으로 다루는 KVMN[1]은 Hits@1에서 약 46.7%, F1 score에서 약 38.6%를 기록하여 가장 낮은 성능을 보였다.

4. 결론

본 논문에서는 지식 그래프 위에서 다중 홉 추론을 요구하는 복잡한 자연어 질문에 효과적으로 답변을 추론할 수 있는 심층 신경망 모델을 제안하였다. 제안 모델에서는 지식 그래프 노드들 간의 양방향 특징 정보 전파 기능을 포함하고 있을 뿐만 아니라, 두 이웃 노드들 간의 맥락 정보도 활용할 수 있는 쌍 선형 그래프 신경망(BGNN)을 새롭게 채용하고 있다. WebQuestionsSP 벤치마크 데이터 집합을 이용한 다양한 실험들을 통해, 제안 모델의 효과와 우수성을 확인할 수 있었다.

감사의 글

“본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 대학ICT연구센터육성지원사업의 연구결과로 수행되었음” (IITP-2017-0-01642)

참고 문헌

- [1] A. Miller, A. Fisch, and J. Dodge, et al., “Key-Value Memory Networks for Directly Reading Documents,” *Proc. of EMNLP-16*, 2016.
- [2] H. Sun, B. Dhingra, and M. Zaheer, et al., “Open Domain Question Answering Using Early Fusion of Knowledge Bases and Text,” *Proc. of EMNLP-18*, 2018.
- [3] T. N. Kipf, and M. Welling, “Semi-Supervised Classification With Graph Convolutional Networks,” *Proc. of ICLR-17*, 2017.
- [4] W. Yih, M. Richardson, and C. Meek, et al., “The Value of Semantic Parse Labeling for Knowledge Base Question Answering,” *Proc. of ACL-16*, 2016.