

# 전통 문화 데이터를 이용한 메타 러닝 기반 전역 관계 추출

김규경<sup>1</sup>, 김경민<sup>1</sup>, 조재춘<sup>2</sup>, 임희석<sup>3\*</sup>

<sup>1</sup>고려대학교 컴퓨터학과 석사과정, <sup>2</sup>고려대학교 컴퓨터학과 연구교수, <sup>3</sup>고려대학교 컴퓨터학과 교수

## Meta Learning based Global Relation Extraction trained by Traditional Korean data

Kuekyeng Kim<sup>1</sup>, Gyeongmin Kim<sup>1</sup>, Jaechoon Jo<sup>2</sup>, Heuiseok Lim<sup>3\*</sup>

<sup>1</sup>Student, Department of Computer Science and Engineering, Korea University

<sup>2</sup>Research Professor, Department of Computer Science and Engineering, Korea University

<sup>3</sup>Professor, Department of Computer Science and Engineering, Korea University

요 약 최근 존재하는 대부분의 관계 추출 모델은 언급 수준의 관계 추출 모델이다. 이들은 성능은 높지만, 장문의 텍스트에 존재하는 다수의 문장을 처리할 때, 문서 내에 주요 개체 및 여러 문장에 걸쳐서 표현되는 전역적 개체 관계를 파악하지 못한다. 그리고 이러한 높은 수준의 관계를 정의하지 못하는 것은 데이터의 올바른 정형화를 막는 중대한 문제이다. 이 논문에서는 이러한 문제를 해결하고 전역적 관계를 추출하기 위하여 외부 메모리 신경망 모델을 이용하는 새로운 방식의 전역 관계 추출 모델을 제안한다. 제안하는 모델은 1차적으로는 단편적인 관계 추출을 실행한 뒤, 외부메모리 신경망을 이용하여 단편적인 관계들을 분석 및 종합하여 텍스트 전체로부터 전역적 관계들을 추출한다. 또한 제안된 모델은 외부 메모리를 통하여 전역적 관계 추출 외에도 주어와 목적어 생략이 잦은 한국어 관계 추출에도 뛰어난 성능을 보인다.

주제어 : 관계 추출, 메모리 증강 신경망, 메타 러닝, 텍스트 요약, 자연어처리, 기계 학습

**Abstract** Recent approaches to Relation Extraction methods mostly tend to be limited to mention level relation extractions. These types of methods, while featuring high performances, can only extract relations limited to a single sentence or so. The inability to extract these kinds of data is a terrible amount of information loss. To tackle this problem this paper presents an Augmented External Memory Neural Network model to enable Global Relation Extraction. the proposed model's Global relation extraction is done by first gathering and analyzing the mention level relation extraction by the Augmented External Memory. Additionally the proposed model shows high level of performances in korean due to the fact it can take the often omitted subjects and objectives into consideration.

**Key Words** : Relation Extraction, Augmented Memory Neural Networks, Meta Learning, Text summarization, Natural language Processing, Machine Learning

### 1. 서론

최근 자연어처리에서 데이터에 대한 중요성이 점점

커지고 그 양도 방대해지면서 구조화되지 않은 정보 (Unstructured Raw Information)를 구조화된 정보 (Structured Information)로 변환하는 중요성이 커지고

\*This research is supported by Ministry of Culture, Sport and Tourism(MCST) and Korea Creative Content Agency(KOCCA) in the Culture Technology(CT) Research&Development Program 2017. (No. R2017030045 ).

\*Corresponding Author : HeuiSeok Lim (limhseok@korea.ac.kr)

Received August 31, 2018

Revised October 31, 2018

Accepted November 20, 2018

Published November 28, 2018

있다[1]. 그러나 처리해야 하는 텍스트의 내용이 심화될 수록, 두 개체간의 상호관계가 여러 문장에 걸쳐 묘사되는 경우가 잦고 그러한 장거리 개체 간 상호관계야 말로 해당 텍스트 내의 핵심주제를 반영하는 관계일 가능성이 높다. 그러나 현 관계추출 방법들은 구조적인 한계로 대부분 한 문장 내의 존재하는 개체 간 관계를 추출하는 한계를 가지고 있다. 또한 한국어처럼 주어나 목적어가 자주 생략[2]되는 언어를 다룰 경우에는 추출한 결과가 생략된 주어나 목적어에 해당되는 개체들의 관계를 제대로 표현하지 못한다는 약점도 존재한다. 이 논문에서는 그러한 약점들을 극복하기 위하여 각 개체 간 관계를 외부 메모리에 저장하고 분석하여 여러 문장에 걸쳐 표현되는 개체 간 상호관계를 추출하는 관계추출 모델을 제시한다. 이 논문의 2장에서는 이 논문과 관련된 논문들 및 그에 대한 비교들을 설명한 뒤 3장에서는 제안한 모델과 훈련 방법에 대하여 상세히 설명할 것이다. 이후 이어지는 4장에서는 이 모델에 사용된 데이터 셋에 대한 설명과 제안된 모델의 성능 비교를 위한 실험방법을 설명하고, 나온 결과를 해석한다. 마지막 5장에서 이 논문의 결론 및 기여 그리고 향후 미래 연구에 대한 설명과 함께 이 논문을 마친다.

## 2. 관련 연구

### 2.1 관계 추출 (Relation Extraction)

관계 추출은 크게 2가지 종류로 나눌 수 있는데 각각 전역 수준의 관계 추출(Global Level Relation Extraction)과 언급 수준의 관계 추출(Mention Level Relation Extraction)이 존재한다[3]. 현재 대부분의 높은 성능을 자랑하는 관계 추출 모델은 후자에 속하며, 문장 내의 관계 추출 성능은 우수하다. 그러나 이는 많은 양의 정보를 요약하고 그 주제를 파악하는데에는 한계가 있다. 이 논문에서는 전역 수준의 관계 추출을 한 번에 대량의 문서를 전부 분석하여 관계를 추출하기보다는 각 문장을 분석한 뒤, 문장 내에서 추출된 단편적인 관계들을 전체적으로 분석함으로써 전역 수준의 관계추출을 시도한다. 이러한 시도 방법을 취함으로써 전역 수준의 관계 추출을 하되, 언급 수준의 관계 추출을 병행함으로써 정보의 누락을 최대한 방지한다.

전역적 관계 추출에 대한 연구에 대한 시도는 언급 수준 관계 추출에 비하여 적은 수준으로 이루어지고 있다.

그마저도 [4]의 경우처럼 텍스트 내의 시간적인 표기를 통한 방식으로 전역적 관계추출을 제한적인 부분에서만 시도하거나 [5]처럼 더욱 세밀한 훈련 데이터를 통해 이를 극복하려 하는 형식으로 실질적인 모델은 언급 수준의 관계 추출 모델과는 큰 차이점을 보이지 않았다. 그러나 이 논문에서 문장을 처리하는 관계추출기 모델에 전역적인 관계들을 추론하는 외부 메모리 모델을 병행하여 사용함으로써 새로운 방식으로 이 문제를 접근했다.

또한 제안한 모델은 한글 관계 추출 성능 저하의 주원인 중 하나인 한국어 특유의 주어 및 목적어의 잦은 생략에 의한 정보 누락을 일정 부분 해결한다. 최근 한국어 텍스트에 대한 관계추출을 위하여 다양한 접근법이 시도되고 있으나, 아직까지는 기존에 존재하던 방식에 단순히 한글 데이터 셋을 훈련시켜서 적용하는 수준에 지나지 않아 그 성능이 떨어지기 때문에 실질적으로 한글 텍스트를 위한 전역적 관계 추출 모델은 희귀하다.

### 2.2 메모리 증강 신경망 (Memory Augmented Neural Network)

이 논문에서 제안한 전역 수준 관계 추출 모델은 그 실행을 위해 언급 수준의 관계를 추출하는 단편적 관계 추출 모델과 외부 메모리 모델을 병행한다. 이때 외부 메모리로는 메모리 증강 신경망을 이용하여 전역 관계 추출을 실행한다. 언급 수준 관계 추출에서 얻어낸 관계들을 따로 샘플로 외부메모리에 저장하여 해당 관계들을 훈련을 통한 분석 및 조합으로 전역 수준의 관계 추출을 실행한다. 이는 메타 학습(Meta Learning)에서 사용되는 One-shot 학습 방법을 적용한 것이다. 모델을 참조한 [5]에서는 첫 번째로 나온 분류 예측 결과를 외부 메모리에 샘플로 저장하고, 이를 차후 비슷한 유형의 샘플을 예측할 때 가져와서 사용하고, 이 결과에 따라 첫 번째 분류 예측 프로세스에 역전파 신호(Back Propagated Signal)를 보내어 세부 사항을 다시 한 번 재조정하는 방식으로 학습한다.

### 2.3 메타 러닝 (Meta Learning)

메타 러닝, 또는 Learning to Learn은 한 학습에 대하여 다양한 기계 학습 방법에 대한 관찰을 통하여 경험, 또는 메타 데이터(Meta Data)를 쌓은 뒤 해당 과제에 대한 학습을 더욱 빠르게 배우는 기계학습 방법을 가리킨다[6]. 이는 기계학습에 사용되는 신경망이나 알고리즘들

의 개선 속도를 대폭 늘릴 뿐만 아니라 그 성능 또한 사람이 손수 조정할 모델보다 더욱 효과적인 성능을 보여 주기도 한다. 그러나 바이어스(bias)와 데이터에 대한 추측을 통하여 이상적인 기계학습 모델로 가공되어져 가는 만큼 이러한 모델은 유연성이 매우 중요하다[7]. 이 논문에서 단편적 관계 추출 모델과 외부 신경망의 훈련을 번갈아 가면서 시키는 이유도 두 개의 훈련과정을 분리한 채 서로의 영향을 주고받도록 하여 유연성을 대폭 늘리기 위함이다. 또한 부가적인 효과로 동일한 기법을 사용했던 [5]처럼 이를 통하여 학습 시간을 대폭적으로 감소시키는 것 또한 메타 러닝을 사용한 이유이다.

### 3. 모델 및 훈련

이 논문에서 제안하는 모델은 크게 2 부분으로 이루어져 있으며 훈련은 3단계에 걸쳐서 진행된다. 모델은 단편적 관계 추출 모델과 외부 메모리 신경망으로 이루어져 있다. 그리고 훈련은 각각 단편적 관계 추출 모델의 훈련, 전역 관계를 위한 메모리 증강 신경망 훈련, 마지막으로 메모리 증강 신경망 훈련의 결과를 반영한 관계 추출 모델의 재훈련으로 총 3단계가 존재한다.

단편적인 관계 추출을 시도하기에 앞서 먼저 텍스트의 전처리가 요구된다. 텍스트의 전처리는 문장 분리 및 문장 내 개체명 인식(Named Entity Recognition)[8], 그리고 마지막으로 문장 내의 관계를 연결(Entity Linking)[9] 및 분류(Relation Classification)할 2 개체를 마킹하는 것이다. 해당 작업은 [8]을 이용함으로써 해결하였으며 각 개체 간 마킹은 문장 내의 모든 개체들 간 관계를 추출할 때까지 각각 마킹하여 관계를 파악한다.

#### 3.1 단편적 관계 추출 모델

전처리를 마친 텍스트는 Fig. 1.과 같은 단편적 관계 추출 모델에 입력된다. 이 단계에서는 텍스트를 각 문장 단위로 분석하기 시작한다. 이때 문장  $x$ 에 존재하는 각 토큰  $x = \{x_1, x_2, \dots, x_n\}$  들을  $k$ 차원의 벡터에 임베딩하기 위하여 행렬  $W \in R^{|V| \times k}$ 를 사용한다. 이때  $|V|$ 는 vocabulary의 크기를 나타낸다. 입력된 문장에 마킹된 개체 1과 개체 2를 기준으로 타 문장요소들인 토큰의 위치가 개체1 또는 개체 2에 더 가까운 지, 아니면 그 어느 쪽 개체와도 거리가 먼지에 따라 각각의 위치를

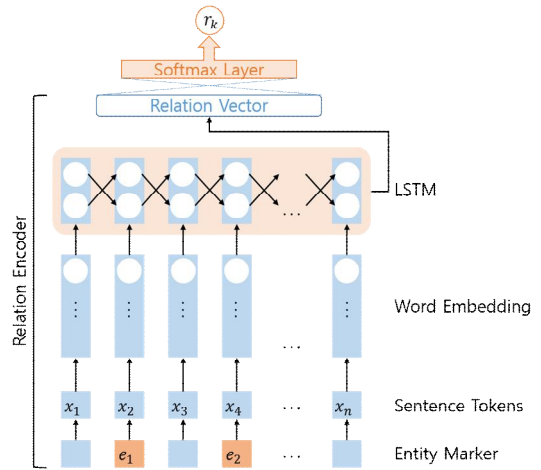


Fig. 1. LSTM based Local Relation Extraction

마킹한다. 이는 구문분석(Part of Speech Tagging)을 통해 이루어지며 각 토큰을 문법적으로 더 가까운 개체 쪽으로 분류하도록 하는 것이다. 그리고 일정 임계값이 넘는 거리가 나오면 그 어느 쪽과도 관계가 없는 것으로 표기하는 것이다. 이렇게 만들어진 토큰 임베딩들은 LSTM신경망(Long Short Term Memory Network)을 통하여  $n$ 개의 벡터들을 고정된 크기의 출력 벡터로 변환한다[10]. 이 출력 벡터는 문장 내 관계 인코딩을 시도하는 2 개체의 관계를 나타낸다. 학습된 모델은 해당 출력 벡터  $o_v$ 를 소프트맥스 레이어에(Softmax Layer) 입력하여 해당 개체 쌍의 관계여부의 판별 및 관계 분류를 통해 언급 수준의 관계 추출을 실행한다. 여기서 관계 분류기를  $P(r)$ , 소프트맥스 레이어를  $f_i$ , 첫 번째 개체와 두 번째 개체를  $e_1, e_2$ 라고 정의하였을 때 관계 분류기는 다음과 같다[10].

$$P(r|\langle e_1, e_2 \rangle, x; \theta) = \frac{\exp(f_r)}{\sum_{i=1}^{n_r} \exp(f_i)}$$

$$f_i = w_i \cdot o_s + b_i$$

이때  $w_i$ 는 무게 벡터이며  $b_i$ 는 바이어스이다.

#### 3.2 외부 메모리

단편적 관계 추출 모델에서 얻어낸 결과들은 그러나 어디까지나 언급 수준의 관계들로 여러 문장에 걸쳐져있는 관계를 가진 개체들을 분석하기 위해서는 추가적인 조치가 요구된다. 그렇기 때문에 텍스트 내의 관계들에

대한 종합적인 분석이 요구된다. 그렇기 때문에 1차적으로 외부 메모리에 텍스트에서 얻어낸 언급 수준의 관계들의 출력벡터를 차례대로 저장하며 문장을 건너뛰는 관계 후보들을 찾는다. 이후 각 개체 사이에 공유하고 있는 중간 단계 개체들이 존재한다면 이러한 관계들을 모두 통합하여 새로운 예측 벡터를 생성한다. 이후 생성된 예측 벡터는 훈련된 메모리 증강 신경망을 통하여 타 문장에 속하는 개체들 간의 관계들을 정의한다. 이 때  $t$ 번째 순서에 입력된 언급 수준의 관계를  $r_t$ 라고 정의하고,  $r_t$ 가 속해있는 전역 관계를  $R$ 이라고 한다. 이때  $R$ 의 양 끝에 해당하는 전역 관계를 대표하는 개체를  $E_t$ 로 표기하며 그에 속한 개체들은  $e_t$ 로 표기한다. 그에 해당 이러한 전역관계를 나타내는 예측 벡터  $V_R$ 은 다음과 같다[11].

$$V_R = \text{softmax}\left(\sum_i r_i(t) \times \frac{d_t}{D}\right)$$

이후  $V_R$ 을 분류하는 데에는 코사인 유사도를 사용하여 해당 전역관계가 어떠한 분류에 속하는지 파악한다.

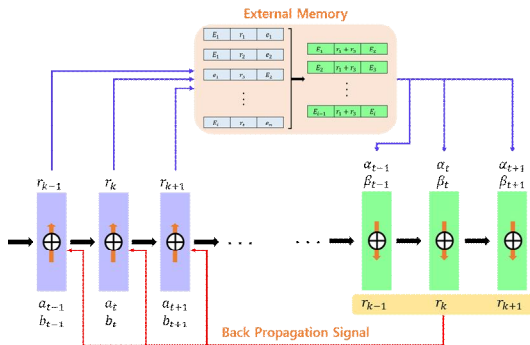


Fig. 2. Meta Learning via Augmented External Memory Neural Network

### 3.3 훈련 방법

이 논문에서 소개하는 2가지 모델을 훈련시키기 위해서는 총 3단계의 훈련이 필요하다. 첫 번째 훈련은 단편적 관계 추출 모델에 대한 학습으로, 이는 [10]의 훈련 방식과 동일하게 두 개체가 마킹이 된 구문 부석이 이루어진 문장에서 정답 개체 간 관계를 통해 End-to-End 방식의 훈련을 통해 학습이 이루어졌다. 이는 외부 메모리에서 전역적 관계 추출을 학습할 때에도 마찬가지다. 다만 이 경우에는 텍스트를 통한 학습이 아닌 여러 관계 tuple을 제공하며 전역적 관계로 이어지는 여러 tuple들

의 합성곱을 통한 예측 벡터와 주어진 정답을 통한 End-to-End 방식의 훈련으로 1차 훈련을 마친다.

1차적인 훈련을 마친 뒤에는 메모리 증강 신경망을 통한 2차 훈련을 시작한다. 이는 전역적 관계를 언급 수준의 관계에 반영하는 것이다. 이때는 각 전역관계  $R$ 에서 순서  $t$ 에 해당되는 개체들과  $R$ 의 주요개체 간 관계추출을 재 정의할 때 해당되는 문장을  $x_t$ 라고 정의한다. 또한 해당 문장 내의 존재하는 전역관계  $R$ 에 속하는 개체를  $k_t$ 라고 정의하며  $k_t$ 가 속한 언급 수준의 관계를 외부 메모리에 있는  $R$ 의 타 관계들과 비교하게 된다. 이때  $k_t$ 가 속해있는  $R$  중 그 예측 벡터  $V_R$ 이 해당 문장 내의  $k_t$ 가 포함된 언급 수준의 관계와 유사한지 확인한다. 이를  $M(k_t)$ 라고 하여 코사인 유사도를 이용하여 유사도를 계산한다.

$$K(k_t, M(k_t)) = \frac{k_t \cdot M(k_t)}{\|k_t\| \cdot \|M(k_t)\|}$$

이 계산을 통하여 무게 벡터  $w_t$ 를 생성할 수 있는데, 무게 벡터  $w_t$ 를 이용하여 문장  $x_t$ 내의 개체  $k_t$ 가 속한 관계를 전역관계  $R$ 을 반영하여 재정의해야 또는 변화를 주어야하는지, 그리고 준다면 어떻게 변화를 주는지 결정하게 된다.  $w_t$ 를 구하는 방법은 다음과 같다.

$$w_t \leftarrow \frac{\exp(K(k_t, M(k_t)))}{\sum_j \exp(K(k_t, M(j)))}$$

구한  $w_t$ 가 임계값보다 클 경우 언급 수준의 관계 예측 벡터인  $o_v$ 에 합성곱을 통하여 새로운  $o_v$ 를 생성하도록 하며 단편적 관계 추출 모델을 재훈련시킨다. 1차 훈련을 반복한 뒤 다시 이를 통한 2차 훈련을 반복하여 성능이 최대한 높아질 때까지 이 과정을 반복한다.

## 4. 데이터 및 실험

### 4.1 데이터

훈련을 위해 사용된 데이터는 한국 전통문화 위키 사이트[12]에서 얻은 것으로, 1차 훈련에 쓰인 데이터는 해당 데이터 셋의 텍스트 항목과 항목 간 링크가 걸린 항목들 간의 관계분류를 통해 훈련을 하였으며 2차 훈련에서 외부 메모리 신경망을 훈련시킬 때는[12]에서 제작한 온톨로지들을 훈련 데이터로 사용한다.

### 4.2 실험

이 논문에서 제안하는 모델의 성능을 확인하기 위하여 2가지 실험이 진행된다. 첫 번째 실험은 전역적 관계 추출의 정확도를 평가하기 위하여 타 모델[13-15]들과 함께 문서 단위의 평가 데이터로부터 관계 추출을 실행한다. 이 때 비교하는 성능은 각 단편적 관계 추출과 전역적 관계 추출의 Precision, Recall 그리고 F1 Score를 측정하여 성능을 비교했다. 단편적 관계 추출을 진행할 때는 각 문장에 대한 개체가 주어지고, 해당 평가 데이터의 정답과의 비교를 통한 검증이 이루어졌다. 반면 전역적 관계 추출을 평가할 때는 평가 데이터를 온톨로지 구조로 바꾼 뒤 해당 온톨로지와 전역 관계 추출 결과물들을 비교함으로써 성능을 측정이 이루어진다.

이 실험에 사용된 모델들은 각각 End-to-end CNN 기반의 관계추출기[13], End-to-end LSTM 기반의 관계추출기[14], Global Distant Supervision 기반 관계추출기[15]이다.

### 4.3 결과

Table 1. Performances Comparisons on Local and Global Relation Extraction

	[13]	[14]	[15]	AEMM
Local Precision	0.327	0.341	0.390	0.269
Local Recall	0.315	0.347	0.259	0.307
Local F1 Score	0.321	0.344	0.311	0.287
Global Precision	0.194	0.183	0.198	0.383
Global Recall	0.313	0.332	0.262	0.287
Global F1 score	0.240	0.236	0.226	0.328

Table 1의 결과를 보면 단편적 관계 추출에 한해서는 [13]과 [14]의 성능은 크게 차이가 나지 않는 것을 확인할 수 있다. [15]의 경우 Local Precision에서는 모든 모델 중 가장 높은 성능을 보이나 F1 score를 통해 비교하면 [14]가 가장 높은 성능을 보인다. 이에 반하여 제안한 모델인 Augmented External Memory Model(AEMM)은 전체적으로 다른 모델들에 비하여 더 낮은 성능을 보이는데, 이는 외부 메모리 신경망의 전역 관계 분류의 결과에 따라 영향을 받는 것이 오히려 단편적 관계 분류에 악영향을 끼치는 것으로 보인다.

반면 전역적 관계 추출을 진행하면 AEMM은 타 모델에 비하여 확연히 높은 Global Precision을 보여준다. 이 때문에 비록 Global Recall에서는 타 모델들과 비슷한 성능을 보임에도 F1 score에서 더 높은 성능을 보이는 것을 관측할 수 있다. 자동 온톨로지 형식의 지식기반을 구축하는데 이 모델의 강점을 볼 수 있다.

## 5. 결론

이 논문에서는 문서 관계 추출을 시도할 시 문서 내의 여러 문장을 통해 관계가 형성되는 개체들의 관계를 추출을 외부 메모리 신경망을 통한 접근으로 전역 관계 추출 모델을 개발하여 소개한다. 일반적으로 자연어로 이루어진 장문의 텍스트에서 단 하나의 문장 내에서 성립되는 관계보다는 여러 문장에 걸쳐 표현되어지는 개체들 간의 관계가 더 해당 텍스트 내의 주제를 더 잘 반영한다 [1]. 그렇기 때문에 이러한 여러 문장에 걸쳐서 표현되어지는 관계를 추출하는 것이 해당 문서를 더욱 정확하게 요약하며, 단순히 단편적인 관계들을 사용하는 것보다 훨씬 정형화되고 사용하기 편한 지식베이스를 구축할 있도록 해준다[3]. 이는 점점 데이터가 많아지고 그 분류가 사람의 손으로 거치기 어려워지는 현 태세의 상황을 보면 앞으로 정확한 전역 관계 추출의 가치는 점점 높아질 것으로 보인다.

또한 이 논문에서 제안한 모델은 해당 문장 내에 존재하지 않는 개체들도 지속적으로 고려하기 때문에 주어와 목적어의 생략이 잦은 한국어 관계 추출에도 용이하다.

향후 미래연구로는 오랜 훈련시간에 비하여 비교적 덜 높은 성능 상승량에 대한 개선과 거대한 크기의 데이터에 대하여 전역 관계 추출에 대한 연구를 할 계획이다. 또한 문서 단위로 관계가 정의되어지는 개체들의 관계추출이 가능한지 알아보고, 이를 통하여 자동적인 지식베이스 구축을 시도해볼 계획이다.


## REFERENCES

- [1] Konstantinova, N. (2014, April). Review of relation extraction methods: What is new out there?. In International Conference on Analysis of Images, Social Networks and Texts\_x000D\_ Springer, Cham, 15-28.
- [2] Sujeong Kwak, Bogyum Kim, Jae Sung Lee. (2014).

- Considerations for Relation Extraction using Korean Dependency Parsing. *Proceedings of the KISS conference*, 831-833.
- [3] Pawar, S., Palshikar, G. K., & Bhattacharyya, P. (2017). Relation Extraction: A Survey. arXiv preprint arXiv:1712.05191.
- [4] Moschitti, A., Patwardhan, S., & Welty, C. (2013). Long-distance time-event relation extraction. *In Proceedings of the Sixth International Joint Conference on Natural Language Processing*, 1330-1338.
- [5] Zeng, X., He, S., Liu, K., & Zhao, J. (2018). Large scaled relation extraction with reinforcement learning. *Relation*, 2, 3.
- [6] Vanschoren, J. (2018). Meta-Learning: A Survey. arXiv preprint arXiv:1810.03548.
- [7] Lemke, C., Budka, M., & Gabrys, B. (2015). Metalearning: a survey of trends and technologies. *Artificial intelligence review*, 44(1), 117-130.
- [8] D. Y. Lee, W. H. Yu & H. S. Lim. (2017). Bi-directional LSTM-CNN-CRF for Korean Named Entity Recognition System with Feature Augmentation. *Journal of the Korea Convergence Society*, 8(12), 55-62.
- [9] Shen, W., Wang, J., & Han, J. (2015). Entity linking with a knowledge base: Issues, techniques, and solutions. *IEEE Transactions on Knowledge and Data Engineering*, 27(2), 443-460.
- [10] Sorokin, D., & Gurevych, I. (2017). Context-Aware Representations for Knowledge Base Relation Extraction. In *Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing*, 1784-1789.
- [11] Santoro, Adam, et al. "Meta-learning with memory-augmented neural networks." *International conference on machine learning*. 2016.
- [12] Hyun, Kim et al. 2017. "Digital humanities - Research Administration of Archives and Humanities" *Proceedings at Digital humanities*.  
DOI: <http://dh.aks.ac.kr/Encyves/wiki>
- [13] Nguyen, T. H., & Grishman, R. (2015). Relation extraction: Perspective from convolutional neural networks. In *Proceedings of the 1st Workshop on Vector Space Modeling for Natural Language Processing* (pp. 39-48).
- [14] Miwa, M., & Bansal, M. (2016). End-to-end relation extraction using lstms on sequences and tree structures. arXiv preprint arXiv:1601.00770.
- [15] Han, X., & Sun, L. (2016, March). Global distant supervision for relation extraction. In *Thirtieth AAAI Conference on Artificial Intelligence*.

김 규 경(Kim, Kuekyeng)


[정회원]



- 2016년 2월 : 고려대학교 정보통신학부(이학사)
- 2018년 3월 ~ 현재 : 고려대학교 컴퓨터학과 석사과정
- 관심분야 : 딥 러닝, 이미지 처리 및 분석, 자연어처리
- E-Mail : overmind22@korea.ac.kr

김 경 민(Kim, Gyeongmin)

[정회원]



- 2017년 8월 : 백석대학교 정보통신학부(이학사)
- 2018년 3월 ~ 현재 : 고려대학교 컴퓨터학과 석사과정
- 관심분야 : 딥 러닝, 자연어처리, 대화 시스템
- E-Mail : totoro4007@korea.ac.kr

조 재 춘(Jo, Jaechoon)

[정회원]



- 2010년 2월 : 제주대학교 컴퓨터교육과(이학사)
- 2012년 2월 : 고려대학교 컴퓨터교육과(이학석사)
- 2018년 2월 : 고려대학교 컴퓨터과(공학박사)
- 2018년 3월 ~ 현재 : 고려대학교 정보대학 연구교수
- 관심분야 : AI in Education, NLP, Deep Learning, ITS
- E-Mail : jaechoon@korea.ac.kr

임 희 석(Lim, Heuseok)

[정회원]



- 1992년 : 고려대학교 컴퓨터학과(이학학사)
- 1994년 : 고려대학교 컴퓨터학과(이학석사)
- 1997년 : 고려대학교 컴퓨터학과(이학박사)
- 2008년 ~ 현재 : 고려대학교 컴퓨터학과 교수
- 관심분야 : 자연어처리, 인공지능, 딥러닝
- E-Mail : limhseok@korea.ac.kr