

DeNERT: Named Entity Recognition Model using DQN and BERT

Sung-Min Yang*, Ok-Ran Jeong*

*Student, Dept. of Software, Gachon University, Seongnam, Korea

*Professor, Dept. of Software, Gachon University, Seongnam, Korea

[Abstract]

In this paper, we propose a new structured entity recognition DeNERT model. Recently, the field of natural language processing has been actively researched using pre-trained language representation models with a large amount of corpus. In particular, the named entity recognition, which is one of the fields of natural language processing, uses a supervised learning method, which requires a large amount of training dataset and computation. Reinforcement learning is a method that learns through trial and error experience without initial data and is closer to the process of human learning than other machine learning methodologies and is not much applied to the field of natural language processing yet. It is often used in simulation environments such as Atari games and AlphaGo. BERT is a general-purpose language model developed by Google that is pre-trained on large corpus and computational quantities. Recently, it is a language model that shows high performance in the field of natural language processing research and shows high accuracy in many downstream tasks of natural language processing. In this paper, we propose a new named entity recognition DeNERT model using two deep learning models, DQN and BERT. The proposed model is trained by creating a learning environment of reinforcement learning model based on language expression which is the advantage of the general language model. The DeNERT model trained in this way is a faster inference time and higher performance model with a small amount of training dataset. Also, we validate the performance of our model's named entity recognition performance through experiments.

▶ **Key words:** Natural language processing, Named entity recognition, Reinforcement learning, BERT, DQN, Language model

[요 약]

본 논문에서는 새로운 구조의 개체명 인식 DeNERT 모델을 제안한다. 최근 자연어처리 분야는 방대한 양의 말뭉치로 사전 학습된 언어 표현 모델을 활용하는 연구가 활발하다. 특히 자연어처리 분야 중 하나인 개체명인식은 대부분 지도학습 방식을 사용하는데, 충분히 많은 양의 학습 데이터 세트와 학습 연산량이 필요하다는 단점이 있다. 강화학습은 초기 데이터 없이 시행착오 경험을 통해 학습하는 방식으로 다른 기계학습 방법론보다 조금 더 사람이 학습하는 과정에 가까운 알고리즘으로 아직 자연어처리 분야에는 많이 적용되지 않은 분야이다. 아타리 게임이나 알파고 등 시뮬레이션 가능한 게임 환경에서 많이 사용된다. BERT는 대량의 말뭉치와 연산량으로 학습된 구글에서 개발한 범용 언어 모델이다. 최근 자연어 처리 연구 분야에서 높은 성능을 보이고 있는 언어 모델이며 많은 자연어처리 하위분야에서도 높은 정확도를 나타낸다. 본 논문에서는 이러한 DQN, BERT 두가지 딥러닝 모델을 이용한 새로운 구조의 개체명 인식 DeNERT 모델을 제안한다. 제안하는 모델은 범용 언어 모델의 장점인 언어 표현력을 기반으로 강화학습 모델의 학습 환경을 만드는 방법으로 학습된다. 이러한 방식으로 학습된 DeNERT 모델은 적은 양의 학습 데이터셋으로 더욱 빠른 추론시간과 높은 성능을 갖는 모델이다. 마지막으로 제안하는 모델의 개체명 인식 성능평가를 위해 실험을 통해서 검증한다.

▶ **주제어:** 자연어처리, 개체명 인식, 강화학습, BERT, DQN, 언어모델

- First Author: Sung-Min Yang, Corresponding Author: Ok-Ran Jeong
- Sung-Min Yang (ysm0622@gc.gachon.ac.kr), Dept. of Software, Gachon University
- Ok-Ran Jeong (orjeong@gachon.ac.kr), Dept. of Software, Gachon University
- Received: 2020. 02. 13, Revised: 2020. 04. 08, Accepted: 2020. 04. 09.

I. Introduction

사람과 상호작용하는 다양한 애플리케이션에 있어서 자연어처리 분야의 중요성은 점점 커지고 있다. 자연어처리의 핵심은 인간이 사용하는 불규칙하고 불완전한 상태의 애매한 의도와 표현을 컴퓨터가 이해할 수 있는 형태의 값으로 추상 변화하는 것이다. 자연어처리의 연구 분야는 형태소분석, 감정분석, 관계분석부터 음성인식, 음성합성, 챗봇 등에 이르기까지 다양한 분야에 걸쳐 발전하고 확장하고 있다.

그중에서도 개체명 인식 분야는 텍스트 형태로 변환되거나 입력된 문장의 의도나 표현에서 문맥을 파악하기 위하여 꼭 사용되어야 하는 중요한 연구 분야이다. 특히 전자 출판물에 있어서 개체명 인식은 콘텐츠 자체의 정보를 추출하기 위해 반드시 필요한 연구 분야이다. 방대한 양의 전자출판물의 문맥과 내용을 기계가 해석 가능한 형태로 변환하기 위해서는 임베딩, 형태소분석, 언어 표현모델 등이 필요하게 된다. 이러한 방법으로 특정 텍스트 형태로 이루어진 전자출판물을 기계가 이해할 수 있는 형태로 잘 변환되면, 추천시스템에 활용될 때 콘텐츠 그 자체의 정보만을 활용하여 사용자에게 추천해 주거나, 콘텐츠 자체의 유사도 분석 등으로 협업 필터링의 콜드 스타트 문제를 해결할 수 있다.

강화학습은 초기 데이터 없이 시행착오 경험을 통해 학습하는 방식으로 다른 기계학습 방법론보다 조금 더 사람이 학습하는 과정에 가까운 알고리즘으로 아직 자연어처리 분야에는 많이 적용되지 않은 분야이다. BERT는 대량의 말뭉치와 연산량으로 학습된 구글에서 개발한 범용 언어 모델이며, BERT와 같은 최근의 자연어처리 연구들은 대부분 방대한 양의 데이터세트와 GPU를 이용한 연산량으로 범용 언어 표현 모델을 만드는 연구가 많다.

이러한 연구들은 모델 학습에 너무 많은 데이터세트와 엄청난 연산량이 필요하기 때문에 학습 비용이 굉장히 비싸다는 단점을 가지고 있다. 또한 최근 모바일 등 컴퓨팅 자원이 부족한 환경에서 학습하기 위해서는 모델 경량화 등이 필요하다.

이러한 문제점들을 해결하기 위하여 본 논문에서는 강화학습 분야에서 널리 사용되는 DQN(Deep Q-Network) 모델과, 최근 자연어처리 분야에서 높은 성능을 보이는 범용 언어 모델 BERT(Bidirectional Encoder Representations from Transformers)를 이용하여 더 적은 양의 학습 데이터 세트로 빠른 추론시간과 더 나은 성능을 보이는 DeNERT(Deep Q-Network based Named Entity Recognition Transformer) 개체명 인식 모델을 제안한다.

II. Related Works

자연어처리 연구 분야에는 여러 가지 하위 분야가 존재한다. 형태소 분석, 품사 태깅, QA, 관계추출, 감정 분석, 기계 번역, 음성인식, 음성 합성, 요약, 챗봇 등 다양한 하위 분야가 있는데, 개체명 인식도 이러한 자연어처리의 연구 분야 중 하나이다. 개체명 인식이란 문장이나 문서 내에서 인명(Person), 기관명(Organization), 지명(Location) 등과 같이 단어 자체로 고유한 의미를 지니고 있는 명사를 추출하여 어떤 카테고리에 해당하는지 분류하는 것을 말한다.

기계학습을 이용하기 이전 전통적인 개체명 인식 연구는 크게 규칙 기반과 사전 기반 연구로 나뉜다. 대부분의 규칙 기반 개체명 인식은 사람이 직접 수동으로 정의한 규칙을 기반으로 데이터 세트를 분류한다. 이러한 방식은 자연어의 특성상 대부분 불규칙하고 불완전한 형태로 존재하기 때문에 특정 데이터 세트에서만 잘 동작할 확률이 높다는 단점이 있다.

사전 기반 개체명 인식도 역시 수집되어있는 사전이나 사람이 직접 정의한 사전을 기반으로 데이터 세트를 분류한다. 사전 기반 개체명 인식은 빈도수가 적은 용어가 많이 쓰이는 특정 분야에서 정보추출이나 검색에 유리하다. 하지만 이 방법 역시 사전을 수동으로 구성해야 한다는 단점이 있으며, 시간에 흐름에 따라 지속해서 바뀌고 새로 생성되는 신조어들 때문에 사전관리의 비용이 너무 많이 들며, 사전에 정의되지 않은 개체명들은 쉽게 놓치게 된다는 단점도 존재한다.

자연어처리뿐만 아니라 다양한 분야에서 높은 성능을 보이는 기계학습을 이용한 개체명 인식 연구도 활발하다. [1]의 연구에서는 문장의 나온 단어들을 주변 단어들로 예측하는 방식으로 각 단어의 함축적인 의미를 벡터로 표현할 수 있는 단어 임베딩 기법으로 각 단어를 벡터화한 후 학습하는 방식을 소개했다. 하지만 단어 임베딩 기법 역시 토큰나이징된 단어를 기준으로 벡터화하기 때문에 동음이의어의 함축된 의미를 제대로 처리하지 못하여 하늘에서 내리는 '눈'과 사람의 '눈' 등과 같은 두 단어를 다르게 인식하지 못하고 두 단어를 같은 벡터 공간 안에 매핑한다는 단점을 가지고 있다.

최근에는 기계학습 방법론 중에서도 딥러닝을 이용한 개체명 인식이 가장 활발하다. [2]의 연구에서는 대량의 말뭉치로부터 지도학습 기반의 음절 단위 임베딩 표현과 비지도 학습 기반의 어절 단위 임베딩 표현을 이용하여 시계열 데이터에 의미 있는 성능을 보이는 Bi-LSTM-CRF 모델로 개체명 인식을 수행하는 딥러닝 모델을 소개했다.

가장 최근의 딥러닝을 이용한 개체명 인식 연구들은 대량의 말뭉치로부터 사전 학습된 언어 표현 모델을 이용한다. AllenNLP에서 공개한 ELMo[3], OpenAI에서 공개한 GPT[4], Google에서 공개한 BERT[5]와 같은 모델들이 이러한 방식의 사전 학습된 언어 표현 모델에 대한 대표적인 연구들이다. 이와 같은 언어 표현 모델 연구들의 특징은 모델의 디코더에서 단어를 예측하는 시점의 입력된 문장을 인코더에서 다시 한번 연산에 사용하는 어텐션 메커니즘[6]을 사용하는 것이 두드러진 특징이다.

강화학습 알고리즘은 기계학습의 세가지 큰 분야 중 한 가지 연구 분야이며 행동심리학으로부터 영감을 받았다. 그림 1과 같이 특정한 시뮬레이션 환경 안에서 학습 대상인 에이전트가 현재의 상태를 인식하여, 선택 가능한 행동들 중에서 보상을 최대화하는 행동 순서를 학습하는 방법이다. 지도학습, 비지도 학습과는 다르게 초기에 아무런 데이터를 갖지 않고 학습을 한다. 일반적으로 학습을 하는 대상인 에이전트와 이 에이전트가 속해있는 환경이 상호작용하면서 학습을 해가는 방식을 사용한다. 이러한 이유로 강화학습은 보통 게임, 시뮬레이션, 로봇제어 등과 같이 완전 관측 가능한 환경(Fully Observable Environment)에서 많이 연구됐다. 근래의 강화학습 연구들은 대부분 1992년에 소개된 Q-Learning[7]을 근간으로 한다.

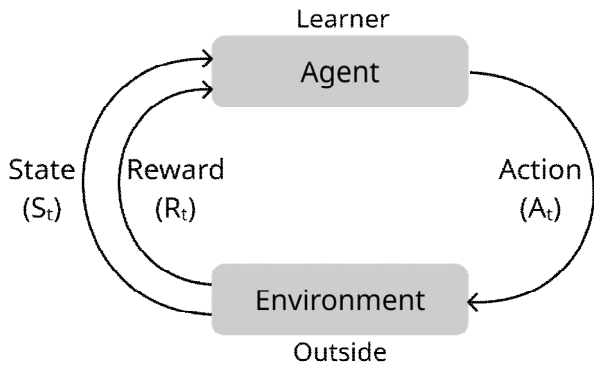


Fig. 1. Concept of Reinforcement Learning

DQN[8-9]은 구글에서 개발한 강화학습에 딥러닝을 적용한 알고리즘으로, 알파고(AlphaGo)에도 사용된 강화학습 알고리즘으로 잘 알려져 있다. DQN은 기존의 Q-Learning이 시뮬레이션 환경의 연속적인 상태나, 너무 큰 상태 공간 때문에 학습이 잘되지 않는 문제를 심층신경망을 통해 Q 값을 근사하는 방식으로 해결하였다. M. Fang [10]의 연구에서는 정책기반 활성 학습(Policy-based Active Learning) 방식을 사용해 CoNLL 데이터 세트에 강화학습을 적용하여, 개체명 인식 문제는

푸는데 시도하는 방식을 제안했다. 마르코프 결정 과정(Markov Decision Process)에 기반한 순차 활성 학습(Sequential Active Learning) 방식을 제안해 개체명 인식에 강화학습이 적용될 수 있음을 증명하였다. Y. Yang [11]의 연구에서는 Bidirectional LSTM-CRF 모델[12]과 DQN을 함께 사용해 중국어 개체명 인식에 적용하는 방법을 제안했다. 특히 NEWS 도메인의 데이터 세트에는 83.4의 높은 F1 Score를 보였다.

이처럼 아직까지 자연어처리, 개체명인식, QA 등 게임이나 가상 시뮬레이션 환경 이외에 다른 분야에 강화학습을 적용하는 연구는 드물다. 하지만 자연어처리에 강화학습 방법론을 적용함으로써 얻을 수 있는 이점이 많다. 더 적은 데이터셋 크기로 비슷하거나 더 나은 성능의 모델을 얻을 수 있으며, 학습 시와 추론 시 모두 연산량을 감소시킬 수 있다. 이러한 다양한 이점들을 위해 개체명 인식 문제에 DQN, BERT를 이용한 DeNERT 모델을 제안한다.

III. DeNERT Model

이 장에서는 본 논문에서 제안하는 DeNERT 모델의 전체적인 구조와 BERT 기반 전처리 모델, DQN 기반 강화학습 모델에 대해서 설명한다.

1. Model Architecture

최근 대부분의 개체명 인식 분야의 연구는 방대한 양의 말뭉치(Corpus)와 연산량(Computing Power)을 이용하여 수십 세대에 걸쳐 불규칙하게 발전해온 사람의 자연언어를 벡터표현 방식으로 모델링하는 연구가 활발히 진행되어 왔다. 이러한 학습 방법은 기계학습의 비지도 학습이나 준 지도학습을 사용하는 방법도 있지만, 대부분은 지도 학습 방법을 사용한다. 이러한 방식의 지도학습 방식은 정답이 존재하는 데이터 세트로 학습하기 때문에 직관적이며 어느 정도 보장된 정확도의 모델을 만들 수 있다는 장점이 있지만, 충분히 많은 양의 방대한 학습 데이터와 연산량이 필요하다는 단점도 존재한다. 이러한 문제를 해결하기 위해 강화학습 알고리즘 DQN과 자연어처리 분야에서 높은 성능을 보이는 언어 표현 모델 BERT, 두 모델을 이용하여 개체명 인식에 적용하는 방법을 소개한다.

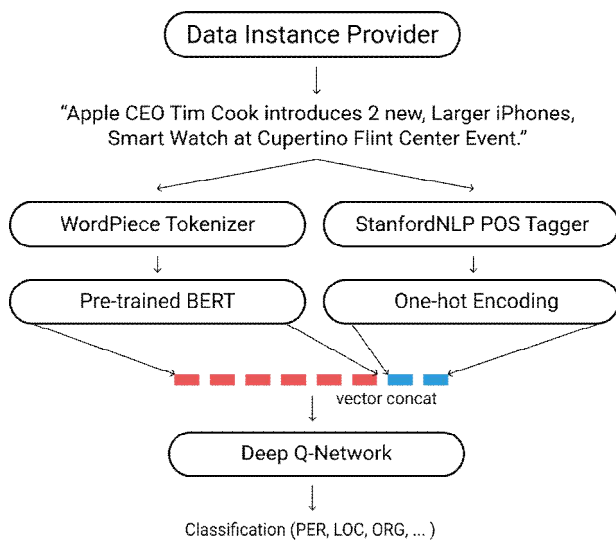


Fig. 2. DeNERT Model Architecture

제안하는 모델의 전체적인 구조도는 그림 2와 같다. 입력된 문장의 개체명 인식을 위해 문장을 토큰나이징하고 벡터화하여 전처리 역할을 담당하는 언어 모델 BERT 부분과 이렇게 벡터화된 문장의 단어들을 입력받아 개체명을 분류하는 문제를 푸는 DQN 에이전트 모델 부분으로 나뉜다. 개체명 인식은 자연어처리 분야에서 각 단어가 개체명인지 아닌지, 개체명이라면 어떤 개체명 카테고리에 속하는지 판단하는 전통적인 분류 문제(Classification Task)에 해당한다. 하지만 강화학습은 일반적으로 알파고와 게임과 같은 시뮬레이션할 수 있는 환경에 많이 적용한다. 따라서 강화학습으로 분류 문제인 이 개체명 인식에 적용하기 위해서는 이 문제를 강화학습 에이전트가 학습할 수 있는 환경으로 바꾸는 과정이 필요하다. 그렇게 하기 위해서는 먼저 강화학습에 사용되는 몇 가지 중요한 요소들을 정의할 필요가 있다. 먼저 개체명 인식을 위한 문장이 주어지면, BERT 부분과 POS Tagger 두 모델로 입력된다. BERT 모델 영역에서는 입력된 문장을 BERT에서 공식 권장하는 워드피스 토큰나이저(WordPiece Tokenizer)[13]를 사용하여 입력된 문장을 토큰나이징한 후, 사전학습(Pre-trained)된 BERT 모델로 입력된다. 입력된 각 단어는 BERT 모델에 의해 단어 표현 벡터(Word Representation Vector)로 표현된다. POS Tagger 부분에서는 StanfordNLP[14]의 POS Tagger로 각 단어의 POS를 태깅하고, 태깅된 각 단어는 34차원의 벡터로 원핫(one-hot) 인코딩된다. 이후 BERT 모델과 POS Tagger에서 출력된 각 벡터를 1차원 결합하여 Deep Q-Network 강화학습 모델의 입력으로 사용된다. 강화학습 에이전트는 입력 문장이 BERT를 통해 벡터 형태로 주어지면, 문장의

앞에서부터 차례대로 단어별 벡터를 입력받아 단어가 어떤 개체명 카테고리에 해당하는지 분류하는 행동을 취한다. 에이전트가 각 단어를 알맞게 분류했다면 양수의 보상, 잘못 분류했다면 음수의 보상을 부여한다. 이러한 하나의 에포크(Epoch)로 데이터 세트에서 랜덤 샘플링하여 최적 정책에 수렴하며 지속적으로 학습하게 된다.

2. BERT-based Preprocessing Model

BERT는 2018년 말 구글에서 공개한 사전학습된 언어 표현 딥러닝 모델이다. BERT는 트랜스포머(Transformer) 구조를 이용한 언어 표현모델이며 위키피디아, 책 등과 같은 대용량 말뭉치로부터 비지도 학습으로 미리 학습한 후, 자연어처리 특정 하위 분야 문제에 지도 학습으로 모델을 구성하는 방법으로, 일종의 준 지도학습이라고 할 수 있으며, 미리 학습된 파라미터들을 사용하여 재학습(Fine-tuning) 하므로 전이학습(Transfer Learning)이라고도 할 수 있다. 대부분의 자연어처리 하위 분야 문제(Downstream Tasks)에서 리더보드 1위를 차지하는 높은 성능을 보이는 모델이다. 이러한 이유로 현재까지 KoBERT, BioBERT, RoBERT 등 여러 연구에서 BERT를 이용한 다양한 파생연구가 활발하게 이루어지고 있다. 기존 ELMo나 OpenAI GPT 같은 모델이 이러한 방식으로 자연어처리 분야의 높은 성능을 보였다. 하지만 이러한 모델들은 단방향 모델로, 충분한 언어 표현을 하지 못하기 때문에 BERT는 양방향(Bidirectional) 인코딩 방식을 제안했다. 본 논문에서는 문장 전처리에 BERT에서 기본적으로 제공하는 여러 모델 중 BERT-base와 BERT-large 사전 학습 모델을 사용하였다. 또한 기본 모델에 자질 확장을 위해 StanfordNLP를 이용하여 각 단어의 형태소 원핫(POS one-hot) 벡터를 추가하여 학습하였다. 모델 학습에 사용된 파라미터는 표 1과 같다.

Table 1. BERT Model Parameters

Parameter	Base	Large
Layer	12	24
Attention head	12	16
Vector size	768	1024
Max-sequence length	25	
Batch size	256	
Vocab size	28996	
Dropout rate	0.1	

3. DQN-based Reinforcement Learning Model

개체명인식은 토큰나이징된 각 단어가 개체명인지 아닌지, 개체명이라면 어떤 개체명 분류에 속하는지 판단하는 전

통적인 분류 문제이다. 이러한 분류 문제에 강화학습 모델을 적용하기 위해서는 이 분류 문제를 강화학습 에이전트가 학습할 수 있는 환경으로 변환하는 과정이 필요하다. 그렇게 하기 위해서는 앞서 설명한 강화학습에서 사용되는 주요 요소들 에이전트, 환경, 상태, 보상함수 등을 해당 문제에 맞게 재정의해야 한다. 아래는 본 논문에서 정의한 강화학습 모델의 세 가지 핵심 요소인 상태, 행동, 보상함수이다.

3.1 State

상태(State)는 에이전트로부터 관측되는 환경을 나타낸다. 환경의 변화에 따라 에이전트가 다음 행동을 어떻게 취해야 할지 정하는 방법을 학습하게 된다. 강화학습 모델은 BERT 모델로부터 추출된 각 단어의 고차원 벡터표현을 입력받기 때문에, 상태를 기반으로 어떤 행동을 취해야 할지 각 확률값을 추론하기 위해서 Q 함수에 Deep Neural Network를 사용한다. 즉 강화학습 모델의 상태 공간은 연속적이다. 본 논문에서는 BERT 모델에 BERT-base와 BERT-large 두 모델을 사용한다. 두 모델의 벡터 크기는 각각 768차원, 1,024차원이고, 형태소 태깅된 원핫(one-hot) 벡터의 크기가 34차원이므로 DQN 모델 입력 레이어의 사이즈는 각 802차원, 1,058차원 벡터를 사용한다.

3.2 Action

강화학습 모델의 행동(Action)은 불연속적(Discrete)이며, 에이전트가 취할 수 있는 행동 차원의 크기는 최종 분류될 개체명 인식 카테고리 수와 일치한다. CoNLL 데이터 세트[15]는 인명(PER), 지명(LOC), 기관명(ORG), 기타(MISC), 비개체명(O) 총 5가지 카테고리로 분류되는 데이터 세트며, 일반적으로 개체명 인식 태깅에는 개체명의 시작을 나타내는 Begin(B-) 접두사(Prefix)와 개체명의 중간, 혹은 계속됨을 나타내는 Inside(I-) 접두사를 붙이기 때문에 에이전트가 취할 수 있는 행동은 B-PER, I-PER, B-LOC, I-LOC, B-ORG, I-ORG, B-MISC, I-MISC, O 총 9차원으로 데이터 세트의 분류 태그 수와 일치한다.

3.3 Reward

보상함수는 강화학습이 지도학습이나 비지도 학습 등 다른 기계학습 방법과 가장 크게 다른 점이다. 보상함수를 어떻게 설계하느냐에 따라 에이전트가 학습을 진행하며 이상적인 목표에 잘 수렴할 수도, 혹은 수렴하지 못하게 될 수도 있으며 학습 속도에도 큰 영향을 미친다. 본 논문의 DQN 모델은 에이전트가 해당 개체명에 대해 카테고리를 알맞게 분류했다면 양수(+1)의 보상을, 잘못 분류했다

면 음수(-1)의 보상을 받게 된다. 가장 간단한 방식이지만 강화학습 방법론에서 널리 사용되며 강력한 방식이기도 하다. 표 2은 학습에 사용된 DQN 강화학습 모델의 학습 파라미터를 나타낸다.

Table 2. DQN Model Parameters

Parameter	Base	Large
Gamma	0.9 ~ 0.99	
Epsilon	0.1 ~ 0.2	
Learning rate	0.001	
Input vector size	802	1058
Hidden unit	100	200
Ouput unit	9	
Dropout rate	0.1	
Optimizer	Adam, RMSProp	

IV. Experiments

이 장에서는 제안하는 모델 학습에 사용한 데이터세트, 실험 환경 및 실험 방법, 실험 결과에 대하여 설명한다.

1. Dataset

모델 학습과 성능 평가에 사용된 데이터 세트는 개체명 인식을 위한 전통적인 영문 데이터세트 CoNLL 2003 이다. LOC, ORG, PER, MISC 총 4가지 개체명 범주로 분류되어있으며, 각 개체명 범주의 데이터 세트의 크기는 표 3과 같다. 약 15,000개의 훈련 세트와 약 3,500개의 Dev 세트, 3,700개의 테스트 세트로 구성되어있지만, 강화학습과 제안하는 모델의 구조 특성상 데이터세트 레코드 하나 당 에이전트 학습에 여러 번 사용될 수 있기 때문에 실제 학습에는 개체명을 마스킹하고, 실제 이 문장을 모델에 입력으로 넣을 때에는 각 개체명 리스트에서 임의 샘플링하여 완성된 문장을 입력으로 사용한다.

Table 3. CoNLL Dataset number of record of each class

Data	LOC	MISC	ORG	PER
Train	7140	3438	6321	6600
Dev	1837	922	1341	1842
Test	1668	702	1661	1617

예를 들어, "Nader Jokhadar had given Syria the lead with a well-struck header in the seventh minute."이라는 문장이 입력으로 주어지면, 실제 모델 학습에는 마스킹 된 개체명 부분을 동일 범주의 다른 단어로 치환해서 이 문장을 여러 번 학습에 사용한다. 인명이나

지명 등은 동일 범주의 다른 단어로 대체되어도 고유한 의미를 잃어버리지 않기 때문에 이렇게 다른 단어로 대체하여 학습에 사용할 수 있다.

2. Environment

모델 학습과 실험에 사용된 컴퓨터의 성능은 다음과 같다.

Intel Xeon E5-2620 v3@2.40GHz /
Ubuntu16.04 / GTX 1080 / 32GB / 3.6TB

DQN 모델은 자바스크립트 기반 머신러닝 라이브러리인 Tensorflow.js(tf.js) 사용하여 구현하였다. 모델 학습에는 브라우저의 WebGL GPU 가속 기술을 이용해 내장된 GPU로 학습한다. BERT 모델은 tensorflow[16] 파이썬 라이브러리를 통해 구현되었다.

3. Result

실험 결과는 표 4와 같다.

Table 4. Experiment results by model

Model	Precision	Recall	F1-Score
Base	91.48 ± 0.041	85.18 ± 0.052	88.22 ± 0.032
Base + POS	92.75 ± 0.055	87.07 ± 0.049	89.82 ± 0.033
Large	95.12 ± 0.061	89.72 ± 0.026	92.34 ± 0.047
Large + POS (DeNERT)	96.08 ± 0.042	93.46 ± 0.053	94.75 ± 0.023

CoNLL-2003 데이터세트에 대해서 BERT-base, BERT-large 모델과 품사 임베딩 벡터를 적용했을 때, 적용하지 않았을 때를 조합해 총 4가지의 모델을 실험하였다. POS 임베딩과 BERT 모델의 크기에 따라서 정확도가 얼마나 차이 나는지 확인하기 위해서 POS 태깅을 적용했을 때와 적용하지 않았을 때, BERT-base와 BERT-large 각 모델로 실험을 진행하였다. 평가 시 강화학습 모델의 엡실론(ϵ) 파라미터는 0으로 설정한 후 성능을 평가하였으며, 각 실험의 결과는 10번씩 학습시킨 모델들의 Precision, Recall, F1 Score의 (평균 ± 표준편차)를 구한 값이다. 모델의 학습 파라미터가 많고 크기가 클수록 정확도가 높으며, POS 임베딩을 추가하였을 때 조금 더 높은 정확도를 보인다. 강화학습 특성상 학습 시 환경의 상태의 따라 보상을 얻을 확률값이 낮기 때문에 Recall이 상대적으로 낮게 나오는 것을 볼 수 있다. 가장 성능이 높

은 모델은 Large + POS 모델이, 본 논문에서 제안하는 DeNERT 모델이다. 이 모델의 성능은 A. Akbik 연구[17]에서의 모델 성능 93.18%보다 약 1.5% 높은 성능을 보이는 것을 볼 수 있다. 이는 강화학습을 적용한 개체명인식 모델에 있어서 의미 있는 결과라고 할 수 있다.

V. Conclusions

본 논문에서는 아타리 게임이나 알파고 등 게임 환경에서 많이 사용되는 강화학습 알고리즘인 구글의 DQN과 최근 자연어처리 연구 분야에서 높은 정확도를 보이며 많은 자연어처리 하위분야에서 높은 성능을 보이는 언어 표현 모델인 BERT 두 모델을 이용한 DeNERT 개체명 인식 모델을 제안했다. 제안한 모델은 강화학습과 개체명 마스킹 방식으로 조금 더 적은 데이터셋으로 기존 모델보다 비슷하거나 약간 좋은 성능을 보였다. 개체명 인식의 경우에는 적은 개수의 개체명 범주, 즉 강화학습 모델의 행동이 유한하기 때문에 DQN을 적용할 수 있었지만, 다른 자연어처리 분야의 경우 이러한 방법을 적용하기 어렵다. 향후 연속적인 행동을 가진 문제에도 적용 가능한 강화학습 알고리즘인 A3C 알고리즘[18]이나 Policy Gradient[19]와 같은 알고리즘을 적용해 좀 더 다양한 자연어처리 분야에 강화학습 방법을 적용할 수 있을 것으로 기대한다.

REFERENCES

- [1] T. Mikolov and I. Sutskever, "Distributed representations of words and phrases and their compositionality," *Advances in neural information processing systems*, pp. 3111-3119, Oct. 2013. DOI: 1310.4546
- [2] G. Lample and M. Ballesteros, "Neural architectures for named entity recognition," *Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, pp.260-270, Jun. 2016. DOI: 10.18653/v1/N16-1030
- [3] ME. Peters and M. Neumann, "Deep contextualized word representations," *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long Papers)*, pp.2227-2237, Jun. 2018. DOI: 10.18653/v1/N18-1202
- [4] A. Radford and K. Narasimhan, "Improving language understanding by generative pre-training," URL <https://cdn.ope>

- nai.com/research-covers/language-unsupervised/language_understanding_paper.pdf
- [5] J. Devlin and MW. Chang, "Bert: Pre-training of deep bidirectional transformers for language understanding," Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers), pp.4171-4186, Jun. 2019. DOI: 10.18653/v1/N19-1423
- [6] A. Vaswani and N. Shazeer, "Attention is all you need," Advances in neural information processing systems, Dec. 2017. <https://arxiv.org/abs/1706.03762>
- [7] CJCH. Watkins and P. Dayan, "Q-learning," Machine learning 8.3-4. pp. 279-292, May. 1992. DOI: 10.1007/BF00992698
- [8] V. Mnih and K. Kavukcuoglu, "Playing atari with deep reinforcement learning," arXiv preprint arXiv:1312.5602, Dec. 2013. <https://arxiv.org/abs/1312.5602>
- [9] V. Mnih and K. Kavukcuoglu, "Human-level control through deep reinforcement learning," Nature 518.7540, pp.529-533, Feb. 2015. DOI: 10.1038/nature14236
- [10] M. Fang and Y. Li, "Learning how to active learn: A deep reinforcement learning approach," Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, pp. 595-605. Sep. 2017. DOI: 10.18653/v1/D17-1063
- [11] Y. Yang and W. Chen, "Distantly supervised ner with partial annotation learning and reinforcement learning," Proceedings of the 27th International Conference on Computational Linguistics, pp. 2159-2169, Aug. 2018. <https://www.aclweb.org/anthology/C18-1183.pdf>
- [12] Z. Huang and W. Xu, "Bidirectional LSTM-CRF models for sequence tagging," Proceedings of the 21st International Conference on Asian Language Processing, Aug. 2015. <https://arxiv.org/abs/1508.01991>
- [13] Y. Wu and M. Schuster, "Google's neural machine translation system: Bridging the gap between human and machine translation," arXiv preprint arXiv:1609.08144, Oct. 2016. <https://arxiv.org/abs/1609.08144>
- [14] CD. Manning and M. Surdeanu, "The Stanford CoreNLP natural language processing toolkit," Proceedings of 52nd annual meeting of the association for computational linguistics: system demonstrations, pp.55-60, Jun. 2014. DOI: 10.3115/v1/P14-5010
- [15] EF. Sang and F. De. Meulder, "Introduction to the CoNLL-2003 shared task: Language-independent named entity recognition," Proceedings of the Seventh Conference on Natural Language Learning at HLT-NAACL, pp.142-147, Jun. 2003. <https://arxiv.org/abs/cs/0306050>
- [16] M. Abadi and A. Agarwal, "Tensorflow: Large-scale machine learning on heterogeneous distributed systems," arXiv preprint arXiv:1603.04467, Mar. 2016. <https://arxiv.org/abs/1603.04467>
- [17] A. Akbik and T. Bergmann, "Pooled contextualized embeddings for named entity recognition," Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics, Volume 1, pp. 724-728, Jun. 2019. DOI: 10.18653/v1/N19-1078
- [18] V. Mnih and AP. Badia, "Asynchronous methods for deep reinforcement learning," International conference on machine learning, Feb. 2016. <https://arxiv.org/abs/1602.01783>
- [19] RS. Sutton and DA. McAllester, "Policy gradient methods for reinforcement learning with function approximation," Advances in neural information processing systems, pp. 1057-1063, Jun. 2000. <https://arxiv.org/abs/1706.06643>

Authors



Sung-Min Yang received the B.S. and M.S. degrees in Software from Gachon University, Korea, in 2019. He is a member of SCLab (Social Computing Laboratory) in the Department of Software at Gachon University.

His current research interests include web development, web mining, machine learning, and deep learning. From 2016 to 2017, he was a research assistant in Wireless Information Networking Lab and Intelligent Software and Natural Language Processing Lab, Gachon University. He worked as a Software Engineer Intern in Impressivo, Inc, and PeopleSpace.



Ok-Ran Jeong received Ph.D. degrees in Computer Science and Engineering from Ewha Womans University, Korea, in 2005. She was a postdoctoral researcher at the University of Illinois at Urbana-Champaign,

USA and Seoul National University, Korea. Dr. Jeong joined the faculty of the Department of Software Design & Management at Gachon University, Seongnam, Korea, in 2009. She is currently an associate Professor in the Department of AI-SW, Gachon University. She is interested in big data mining, machine learning, deep learning and applications of artificial intelligence.