


딥러닝 기반 자연어 처리 세미나

2022.11.14

전북대학교 컴퓨터공학과
인지컴퓨팅 연구실

자연어 처리

- 자연어 (Natural Language)
 - 인간이 일상 생활에서 의사소통을 위해 사용하는 언어
 - 컴퓨터가 사용하는 인공어(기계어, 프로그래밍 언어)와 대비되는 개념
- 자연어 (Natural Language Processing)
 - 인간의 언어 현상을 컴퓨터와 같은 기계를 이용해서 모사 할 수 있도록 연구하고 이를 구현하는 인공지능의 주요 분야 중 하나.



자연어 처리(NLP) 응용 분야


- 감성 분석 (Sentiment Analysis)

- 텍스트에 나타난 사람들의 태도, 의견, 성향과 같은 주관적인 데이터를 분석하는 자연어 처리 기술



- 질의 응답 (Question Answering)



- 사람이 제시한 질문에 대해 자동으로 응답하는 시스템을 구축하는 자연어 처리 기술



자연어 처리(NLP) 응용 분야

- 기계 번역 (Machine Translation)

- 2014년 이후 seq2seq라는 모델 구조가 소개되며 end-to-end 신경망 기반 기계 번역 (neural machine translation)의 시대가 열림



<NMT 어플리케이션>



자연어 처리(NLP) 응용 분야

- 인공지능 비서 (시리, 빅스비 등)
 - 현재 많은 IT 기업들이 인공지능 비서를 상용화하여 배포 중




Siri (Apple)

AI 비서, 넌 누구니?

(스피커) 이름	제조사	호출어	목소리 특징
 빅스비	삼성전자	빅스비	남·녀 전문 성우(우호·윤정), 방송인 서유리 중 선택 가능 수개월 간 직접 녹음
 누구	SK텔레콤	아리아·팅커벨· 레베카·크리스탈	-여자 전문 성우가 6개월 간 직접 녹음 -소녀시대, 엑소 등 SM 소속 연예인 추가 검토
 기가지니	KT	기가지니·지니아· 친구야·자기야	-전문 성우의 목소리 건본 사용 -더 자연스러운 발화 느낌 위해 직접 녹음 준비 중
 카카오톡 미니 (3분기 출시 예정)	카카오	카카오 등	-공유, 아이유 등 인기 연예인과 전문 성우 중 검토
 웨이브 (8월 출시 예정)	네이버	샬리	-자체 제작한 여성 느낌의 기계음

자연어 처리(NLP) 응용 분야

- Charbot(대화 시스템)
 - QA 기반 챗봇, 대화 기반 챗봇




전처리(Preprocessing)

- Text Preprocessing
 - 용도에 맞게 텍스트를 사전에 처리하는 작업
- 코퍼스(Corpus) (말뭉치)
 - 여러 단어들로 이루어진 문장의 뭉치
 - 자연어 처리 분야의 머신러닝, 딥러닝을 수행하려면 많은 수의 코퍼스가 필요함

• 코퍼스 수집 방법

1. 공개된 데이터 이용
<https://www.aihub.or.kr/>
2. 코퍼스 구매
3. 크롤링을 이용한 수집



- 무작정 웹사이트에서 코퍼스를 크롤링하면 법적인 문제로 이어질 수 있기 때문에 적절한 웹사이트에서, 올바른 방법으로, 상업적인 목적이 아닌 경우로 제한된 크롤링을 권장함

Word Embedding

- Word Embedding

- 자연어로 이루어진 단어를 고정된 차원의 실수 벡터로 변환시키는 과정
- 단어를 벡터로 표현 하는 방법
 - 희소 표현(Sparse Representation)
 - One-Hot 인코딩을 통해 단어를 벡터를 표현하는 방법으로 표현하고자 하는 단어의 인덱스의 값만 1로 하고 나머지는 0으로 표현하는 방법
 - 단어의 개수가 늘어나면 벡터의 차원이 한없이 커진다는 단점 존재($|V| \times |V|$)하고 단어의 의미를 잘 담을 수 없어 현재는 거의 사용하지 않음
 - 밀집 표현(Dense Representation)
 - 단어에 대해 특정 다차원 차원(d)을 설정하고 각 벡터는 0,1의 값이 아닌 실수 값을 가짐
 - 단어의 차원이 늘어나도 벡터의 차원은 고정($|V| \times d$)하고 단어의 의미를 잘 표현할 수 있는 방식



Word Embedding

- Word Embedding
 - 학습 데이터로부터 vocab 생성
 - Vocab에 없는 단어는 UNK 할당
 - Embedding Matrix
 - Vocab_size(|V|) * Embedding dim(d)


Embedding Matrix

$$|V| \times d$$

Vocabulary

Word	Index
[PAD]	0
[UNK]	1
Anyway	2
,	3
I	4
love	5
you	6
.	7


Train Sentence	Anyway , I love you .
Dev Sentence	I hate you .
Test Sentence	I will kill you .



Train Sentence	[2 3 4 5 6 7]
Dev Sentence	[4 1 6 7 0 0]
Test Sentence	[4 1 1 6 7 0]

How to Train Word Embedding?


- 딥러닝 기반 Word Embedding 학습
 - 학습된 벡터는 유사한 의미 공간 속에 존재



- 단어 임베딩을 학습하는 알고리즘
 - Word2Vec(CBOW, Skip-Gram), Glove, Fasttext 등등

How to Train Word Embedding?

- Word2Vec



– CBOW

- 주어진 단어에 대해 주위의 앞 뒤의 몇 개의 단어를 입력으로 하여 주어진 단어를 유추하는 모델

– Skip-gram

- CBOW와 반대로 주어진 단어 하나를 이용하여 주위에 등장하는 몇 개의 단어들의 등장여부를 예측

<주위의 단어를 얼마나 볼지에 대한 Window Size 중요>

How to Train Word Embedding?

- Glove

동시 등장 확률과 크기 관계 비(ratio)	k=solid	k=gas	k=water	k=fasion
P(k ice)	0.00019	0.000066	0.003	0.000017
P(k steam)	0.000022	0.00078	0.0022	0.000018
P(k ice) / P(k steam)	8.9	0.085	1.36	0.96

- 단어의 동시 발생 확률을 모델링

- 데이터에 대해 두 단어가 동시에 등장하는 횟수와 그 확률을 계산
- 임베딩 된 중심 단어와 주변 단어 벡터의 내적이 전체 학습 데이터에서의 동시 등장할 log 확률.

$$w_i^T \tilde{w}_k + b_i + \tilde{b}_k = \log X_{ik}$$


- 손실 함수

- 두 벡터 n,m의 내적 값과 실제 동시 등장 로그 확률과의 오차가 최소가 되도록 설정
- 코퍼스 내의 모든 단어 쌍에 대해 적용

$$Loss\ function = \sum_{m,n=1}^V (w_m^T \tilde{w}_n + b_m + \tilde{b}_n - \log X_{mn})^2$$

How to Train Word Embedding?

- Word Embedding을 이용한 자연어 처리
 - Raw 코퍼스로부터 word embedding matrix 학습
 - 응용 태스크에서 embedding matrix 미세조정(fine-tuning)
 - 보통 응용 태스크의 embedding matrix는 랜덤 초기화 수행하지만 사전 학습된 embedding matrix 존재하면 성능 향상



한국어 Word Embedding

- 한국어 자연어 처리의 어려움
 - 한국어는 교착어에 속함
 - 어순이 중요시되는 영어나 중국어와 달리 어근에 접사가 붙어 의미와 문법적 기능이 부여됨
 - 이러한 이유로 한국어 자연어처리에는 형태소 분석(POS tagging)등이 필요함
 - 형태소 : 뜻을 지니고 있는 최소의 단위

원형	피동	높임	과거	추측	전달	결과
잡						+다 잡다
잡	+히					+다 잡히다
잡	+히	+시				+다 잡히시다
잡	+히	+시	+었			+다 잡히셨다
잡			+았(었)			+다 잡았다
잡				+겠		+다 잡겠다
잡					+더라	잡더라
잡		+히	+었			+다 잡혔다
잡		+히	+었	+겠		+다 잡혔겠다
잡	+히	+었	+겠		+더라	잡혔겠더라
잡			+았(었)	+겠		+다 잡았겠다
...						...
잡	+히	+시	+았(었)	+겠	+더라	잡히시었겠더라

<원형인 '잡다'에서 파생될 수 있는 다양한 형태들>

한국어 Word Embedding

- 한국어 Word Embedding

- 어절(단어) 단위 [나는, 학교에, 갔다.]

- OOV(out of vocabulary) 문제에 취약
 - 한국어는 교착어의 특성을 지님

- 음절 단위

- OOV 문제가 거의 발생하지 않음
 - 음절 단위로 의미를 표현하는 것은 한계 존재
 - 아무런 뜻을 지니지 않음

- 형태소 단위

- 형태소는 뜻을 지니는 최소의 단위
 - OOV 문제에 대해서도 강건함
 - 형태소 분석기 성능이 중요



입력문장

나는 오늘 대학교에 갔다.

어절 단위	[나는, 오늘, 대학교에, 갔다.]
음절 단위	[나, 는, 오, 늘, 대, 학, 교, 에, 갔, 다 .]
형태소 단위	[나, 는, 오늘, 대학교, 에, 갔, 다, .]

Feed-Forward Neural Network


- FNN(Feed-Forward Neural Network)
 - 가장 간단한 형태의 인공 신경망
 - 입력층과 출력층 사이에 은닉층을 둡
 - 먼저, 입력 x 와 파라미터 W 와 행렬 연산 후 활성화함수 g 를 취하여 은닉 벡터 h 를 만들어 내고 은닉 벡터에 파라미터와 행렬연산 V 을 하여 출력 층으로 연결




Feed-Forward Neural Network

- FNN(Feed-Forward Neural Network)
 - 활성화함수
 - 노드에 들어오는 값을 바로 다음 레이어로 전달하지 않고 비선형 변환을 수행


$$\sigma(x) = \frac{1}{1 + e^{-x}}$$



$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



$$f(x) = \max(0, x)$$




Recurrent Neural Networks

- RNN(Recurrent Neural Networks)

- 순환 신경망

- 시퀀스 데이터를 모델링 할 수 있는 뉴럴 신경망
 - RNN에서는 히든 노드가 방향을 가진 엣지로 연결되어 순환 구조를 이룸
 - 입력 뿐 아니라 이전 히든 상태를 받기 위해 별도의 U 파라미터를 추가로 둬



RNNs : Update Formula

- Update Formula


- 은닉 상태의 계산

$$\mathbf{h}^{(t)} = \tanh(\mathbf{W}\mathbf{x}^{(t)} + \mathbf{U}\mathbf{h}^{(t-1)})$$

- 은닉 상태 → 출력

$$\mathbf{o}^{(t)} = \mathbf{V}\mathbf{h}^{(t)}$$

$$\mathbf{h}^{(t)} = \mathbf{f}(\mathbf{x}^{(t)}, \mathbf{h}^{(t-1)})$$



Using explicit bias terms

$$\mathbf{h}^{(t)} = \tanh(\mathbf{W}\mathbf{x}^{(t)} + \mathbf{U}\mathbf{h}^{(t-1)} + \mathbf{b})$$


$$\mathbf{o}^{(t)} = \mathbf{V}\mathbf{h}^{(t)}$$

Recurrent Neural Networks

- RNN(Recurrent Neural Networks)


- Unfold

- 각 time step t 에 따라 입력 시퀀스를 모델링




- 한계점

- Gradient vanishing 문제
 - 역전파 시 Time Step이 너무 길어지면 기울기가 전달되지 못하고 소멸되는 문제가 발생




Backpropagation through Time(BPTT)




Long Short Term Memory

- LSTM(Long Short Term Memory)
 - 장거리 의존성(long-term dependencies)를 모델링
 - Memory Cell의 도입
 - 3개의 Gate를 이용하여 Memory Cell 및 출력 값을 조정



Long Short Term Memory

- LSTM(Long Short Term Memory)
 - 은닉 층에서 3개의 Gate를 이용
 - input-gate
 - 입력 값의 정보를 얼마나 메모리 cell에 전달할지를 결정
 - forget-gate
 - 현재 메모리 cell의 정보를 얼마나 제거할지를 결정
 - output-gate
 - 메모리 cell의 정보를 얼마나 출력할지를 결정



Computing gate values

$$f^{(t)} = g_f(x^{(t)}, h^{(t-1)}) \text{ (forget gate)}$$

$$i^{(t)} = g_i(x^{(t)}, h^{(t-1)}) \text{ (input gate)}$$

$$o^{(t)} = g_o(x^{(t)}, h^{(t-1)}) \text{ (output gate)}$$


(new memory cell)

$$\tilde{c}^{(t)} = \tanh(W^{(c)}x^{(t)} + U^{(c)}h^{(t-1)})$$

$$c^{(t)} = i^{(t)} \circ \tilde{c}^{(t)} + f^{(t)} \circ c^{(t-1)}$$
$$h^{(t)} = o^{(t)} \circ \tanh(c^{(t)})$$

Long Short Term Memory

- Update Formula



- $i^{(t)} = \sigma(W^{(i)}x^{(t)} + U^{(i)}h^{(t-1)})$ (Input gate)
- $f^{(t)} = \sigma(W^{(f)}x^{(t)} + U^{(f)}h^{(t-1)})$ (Forget gate)
- $o^{(t)} = \sigma(W^{(o)}x^{(t)} + U^{(o)}h^{(t-1)})$ (Output/Exposure gate)
- $\tilde{c}^{(t)} = \tanh(W^{(c)}x^{(t)} + U^{(c)}h^{(t-1)})$ (New memory cell)
- $c^{(t)} = f^{(t)} \circ c^{(t-1)} + i^{(t)} \circ \tilde{c}^{(t)}$ (Final memory cell)
- $h^{(t)} = o^{(t)} \circ \tanh(c^{(t)})$

Gated Recurrent Unit


- GRU(Gated Recurrent Unit)

- LSTM과 유사한 long-term dependencies를 모델링할 수 있는 신경망

- LSTM 보다 좀 더 간략한 구조, 성능은 유사
- 2개의 gate만을 사용하기 때문에 더 적은 parameter를 가짐

- 2개의 게이트 사용

- reset-gate
 - 과거의 정보를 얼마나 지울지를 결정
- update-gate
 - 이전 값을 얼마나 합할지를 결정



- $z^{(t)} = \sigma(W^{(z)}x^{(t)} + U^{(z)}h^{(t-1)})$ (Update gate)
- $r^{(t)} = \sigma(W^{(r)}x^{(t)} + U^{(r)}h^{(t-1)})$ (Reset gate)
- $\tilde{h}^{(t)} = \tanh(r^{(t)} \circ U h^{(t-1)} + W x^{(t)})$ (New memory)
- $h^{(t)} = (1 - z^{(t)}) \circ \tilde{h}^{(t)} + z^{(t)} \circ h^{(t-1)}$ (Hidden state)


Bidirectional RNN

- 양방향의 RNN의 사용

- Forward RNN : 입력 sequence의 앞에서부터 정방향으로 이동
- Backward RNN : 입력 sequence의 역순인 뒤에서부터 역방향으로 이동
- 출력 층에서 양방향 RNN의 결과를 결합


- 양방향 LSTM, GRU등 기본적으로 적용 가능

- Pytorch, Tensorflow 등 딥러닝 라이브러리에서 기본적인 인자로 제공



RNN 계열 모델의 응용

- 다양한 자연어 처리 응용 분야에 적용 가능



– Many to One


- 감성 분석 : RNN 출력의 마지막 은닉 상태는 문장의 모든 정보를 담고 있어 위 정보를 이용해 문장 분류를 수행

– Many to Many

- 기계 번역 : [2가지 RNN 모델 사용] 인코더는 입력 문장을 인코딩하고 디코더에서는 인코더와 입력 단어를 이용하여 출력 단어를 생성
- 개체명 인식 : 문장의 각 토큰에 대한 은닉 상태를 이용하여 각 토큰에 대한 (PER, ORG, LOC, O) 등의 레이블을 부착


Bi-LSTM CRF

- Bidirectional LSTM-CRF Models for Sequence Tagging
 - 양방향으로 순환하는 LSTM을 통해 문장을 인코딩 한 후 출력 층에서 출력 태그간의 의존성을 모델링하는 CRF와 결합
 - 순차 태깅 문제에 대해 높은 성능을 보여줌



Neural Encoder-Decoder


- Neural Encoder-Decoder



- 시퀀스를 출력 시퀀스로 변환하는 모델로 번역기에서 대표적으로 사용되는 모델
- Sequence-to-Sequence(seq2seq)모델로도 부름
 - 한 종류의 Sequence를 다른 한 종류의 Sequence로 변환
 - 두 시퀀스의 길이는 서로 다를 수 있음

Neural Encoder-Decoder

- Neural Encoder-Decoder




- 인코더(Encoder)-디코더(Decoder)의 두 파트로 구성

- 인코더 : 입력 문장을 인코딩 하여 문맥 벡터를 생성하고 마지막 히든 상태를 디코더로 전달
- 인코더의 마지막 hidden state(은닉상태)가 디코더의 초기 hidden state
- 디코더 : 디코더의 초기 입력은 <s>(START 심볼)로 다음 입력은 이전에 생성된 단어로 </s>(END 심볼)이 생성될 때까지 시퀀스를 생성

Attention Encoder-Decoder

- 어텐션 인코더 디코더(Attention Encoder-Decoder)



– 어텐션 메커니즘

- 기계 번역에서 입력 문장이 길어지면 번역 성능이 떨어지는 것을 해결하기 위해 고안
- 디코더의 매 타입 스텝 t 마다 입력 문장을 참고하여 해당 시점에 예측해야 할 단어와 연관이 있는 단어 부분을 좀 더 집중

Attention Encoder-Decoder

- 어텐션 인코더 디코더(Attention Encoder-Decoder)

1. Attention score $e_{ij} = a(s_{i-1}, h_j)$ [스칼라]	3. Attention output $c_i = \sum_{j=1}^{T_x} \alpha_{ij} h_j$ [벡터]
2. Attention distribution $\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^{T_x} \exp(e_{ik})}$ [스칼라]	4. Decoder hidden state $s_i = f(s_{i-1}, y_{i-1}, c_i)$ [벡터]

– 어텐션 메커니즘

- Attention Score : 어텐션 함수 a 를 통해 디코더의 각 단어에 대해 인코더의 어느 입력 단어에 집중할 것인지에 대한 점수화
- Attention distribution : 어텐션 점수에 대해 softmax를 취해 확률 값으로 정규화
- Attention distribution : 위의 어텐션 점수를 인코더 벡터에 대해 aggregation 후 최종적인 벡터를 계산 (이 벡터는 디코딩 시점마다 다름)
- Decoder hidden state : 어텐션 출력 벡터, 이전 디코더 은닉 상태, 이전 디코더 출력을 이용하여 다음 디코더 은닉 상태 출력

Attention Encoder-Decoder

• 어텐션 함수(scoring function)

- 디코더의 특정 t 시점의 벡터와 전체 인코더 벡터 사이의 점수 계산
 - 가중치 : [decoder의 길이 x 인코더의 길이]
 - Aggregation : 어텐션 가중치가 반영된 벡터를 얻는 과정
 - 가중치와 인코더 벡터의 곱
 - [decoder length x encoder length] X [encoder length x 은닉 차원] => [decoder length x 은닉 차원]
- Original scoring function

$$\text{score}(\mathbf{h}_{t-1}, \bar{\mathbf{h}}_s) = \mathbf{v}^T \tanh(\mathbf{W}\mathbf{h}_{t-1} + \mathbf{V}\bar{\mathbf{h}}_s)$$


- Extension of scoring functions

$$\text{score}(\mathbf{h}_t, \bar{\mathbf{h}}_s) = \begin{cases} \mathbf{h}_t^\top \bar{\mathbf{h}}_s & \text{dot} \\ \mathbf{h}_t^\top \mathbf{W}_a \bar{\mathbf{h}}_s & \text{general} \\ \mathbf{W}_a [\mathbf{h}_t; \bar{\mathbf{h}}_s] & \text{concat} \end{cases}$$

Bilinear function

Pointer Networks

- Pointer Networks(포인터 네트워크)




– Attention as output

- Attention Mechanism을 이용하여 어텐션 가중치가 입력 시퀀스에 대응되는 위치에 대한 확률.
- 가장 높은 확률을 갖는 위치가 출력


Transformers

- 순환 구조를 가지지 않는 인코더
 - 인코더(2가지 절차 수행)
 - Self 어텐션
 - 입력 시퀀스에 대해 자기 자신과 어텐션을 수행하여 입력 단어들 간의 유사도를 가중치로 하여 반영
 - Feed Forward Neural Networks
 - 디코더(3가지 절차 수행)
 - Masked Self 어텐션
 - 인코더의 self attention과 동일하나 해당 디코딩 시점까지만 어텐션이 이루어지도록 제약
 - Source 어텐션
 - 입력 시퀀스와의 어텐션 수행
 - Feed Forward Neural Networks



Transformers

- 순환 구조를 가지지 않는 인코더
 - 어텐션 가중치 시각화



- 장점
 - 상대적으로 긴 시퀀스에 대해서 잘 동작
 - 순환 구조를 가지지 않기 때문에 병렬 수행(속도가 빠름)

Machine Reading Comprehension

- Machine Reading Comprehension(기계 독해)

Article: Endangered Species Act

Paragraph: “... Other legislation followed, including the Migratory Bird Conservation Act of 1929, a 1937 treaty prohibiting the hunting of right and gray whales, and the Bald Eagle Protection Act of 1940. These later laws had a low cost to society—the species were relatively rare—and little opposition was raised.”

Question 1: “Which laws faced significant opposition?”

Plausible Answer: later laws

Question 2: “What was the name of the 1937 treaty?”

Plausible Answer: Bald Eagle Protection Act

- 정의

- 기계가 입력으로 받은 문단을 분석하고 추론하는 것을 말하며, 기계 독해를 이용하여 주어진 질문과 문단을 이해하고 이에 알맞은 답을 찾는 것

- 딥러닝을 이용한 기계독해

- Word Embedding, RNN 인코더, Attention Mechanism, Pointer Network가 모두 사용되어 딥러닝 기반 자연어 처리를 이해하는데 도움이 될 수 있는 예시

Machine Reading Comprehension

- 딥러닝 기반 기계 독해

- Question(질문) & Passage(지문) Encoding

- 질문과 지문을 각각 embedding 한 후 LSTM등의 인코더를 통해 인코딩

- Question-Passage Matching


- 질문과 지문 사이에서 Attention을 수행하여 각 Passage 단어와 Question 단어 간의 가중치 계산 후 aggregation

- Passage Self-Matching

- Self Matching 어텐션을 통해 passage 단어에 대한 재인코딩 수행

- Answer Prediction

- Pointer Network를 이용하여 passage 내에서 정답의 start, end 위치를 출력



<R-Net 기계독해 모델의 구조>

문맥 단어 표현

- 기존 Word Embedding의 단점

- 중의적인 단어를 표현 할 수 없음
 - 예) 단어 “배”
- 문맥에 관계 없이 고정된 단어 표현 사용
 - 단어 이불이 언급된 다양한 문장

올해는 이불 하나 장만해야죠..


새로 산 이불이 너무 따듯하다.

이불 밖은 위험해

집 가서 이불 킁할 듯

- 문맥 단어 표현(Contextual Word Representation)


- 같은 단어더라도 문맥에 따라 그 표현 방법(벡터)가 바뀔 수 있는 개념의 Word Embedding
- ELMo, BERT, GPT 계열의 다양한 모델 연구됨



관점	Word Embedding	문맥 단어 표현
Input	단어 단위	문장 단위(단어의 시퀀스)
Layer	(일반적으로) 단층	(일반적으로) 다계층
Output	해당 단어에 대한 Embedding	문장을 구성하는 각 단어에 대한 Embedding들

BERT

- BERT(Pre-training of Deep Bidirectional Transformers for Language Understanding)



– 문맥 단어 표현 학습

- 양방향 Transformer를 이용하여 문장 내 임의의 단어를 예측하고 다음 문장을 예측하는 두 가지 task로 언어 모델 학습
- 동일한 단어에 대해서도 문맥에 따라 다른 의미를 표현

– 응용 Task에 Fine-Tuning하는 방식으로 성능 향상

BERT

- BERT(Pre-training of Deep Bidirectional Transformers for Language Understanding)

- 성능 향상
 - 기계 독해

System	Dev		Test	
	EM	F1	EM	F1
Top Leaderboard Systems (Dec 10th, 2018)				
Human	-	-	82.3	91.2
#1 Ensemble - nlnet	-	-	86.0	91.7
#2 Ensemble - QANet	-	-	84.5	90.5
Published				
BiDAF+ELMo (Single)	-	85.6	-	85.8
R.M. Reader (Ensemble)	81.2	87.9	82.3	88.5
Ours				
BERT _{BASE} (Single)	80.8	88.5	-	-
BERT _{LARGE} (Single)	84.1	90.9	-	-
BERT _{LARGE} (Ensemble)	85.8	91.8	-	-
BERT _{LARGE} (Sgl.+TriviaQA)	84.2	91.1	85.1	91.8
BERT _{LARGE} (Ens.+TriviaQA)	86.2	92.2	87.4	93.2

- 이외의 많은 자연어 처리 응용 분야에서 놀라운 성능 향상을 가져옴

Auto Encoding (AE) vs Autoregressive (AR)

- Denoising Auto Encoder (DAE)

- noise가 섞인 input을 원래의 input으로 예측하는 문제를 품.
- BERT같은 경우는 주어진 input sequence에 임의로 추가한 noise([MASK] token)가 주어졌을 때, [MASK] token 을 원래 input token으로 복구. Denoising Auto Encoder의 방식으로 볼 수 있음.

$$\text{input sequence} : \bar{x} = (x_1, x_2, \dots, x_T)$$

$$\text{corrupted input} : \hat{x} = (x_1, [MASK], \dots, x_T)$$

$$\text{likelihood} : p(\bar{x} | \hat{x}) \approx \prod_{t=1}^T p(x_t | \hat{x})$$

$$\text{training objective} : \max_{\theta} \log p(\bar{x} | \hat{x}) = \max_{\theta} \sum_{t=1}^T m_t \log p(x_t | \hat{x})$$

Auto Encoding (AE) vs Autoregressive (AR)

- Autoregressive (AR) => 자가 회귀 모델

- 이전 token들을 보고 다음 token을 예측하는 문제

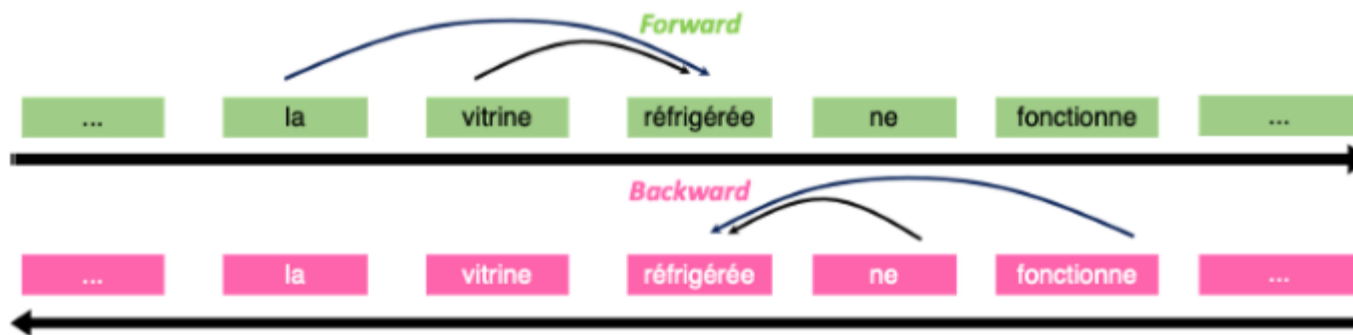
input sequence : $x = (x_1, x_2, \dots, x_T)$

forward likelihood : $p(x) = \prod_{t=1}^T p(x_t | x_{<t})$

training objective(forward) : $\max_{\theta} \log p_{\theta}(x) = \max_{\theta} \sum_{t=1}^T \log p(x_t | x_{<t})$

- 단점

- AR은 방향성(forward, backward)이 정해져야 하므로, 한쪽 방향의 정보만을 이용 가능.




Autoregressive (AR) Language Model

GPT Series

- GPT-3 - Language Models are Few-Shot Learners

- Autoregressive 방식의 언어 모델

- 인류 역사상 가장 뛰어난 '언어 인공지능' 이자 few-shot learning에 최적화된 인공지능
 - few shot learning - 풀고자 하는 문제에 대해 몇 개의 예시만 보고 태스크에 적응하여 문제를 푸는 것
 - 96층의 레이어, 12,288차원의 히든 차원, 96개 attention head를 가지는 총 1750억 개의 파라미터의 모델. 3,000억 토큰의 학습 데이터에 대해 학습함
 - few shot learning - 풀고자 하는 문제에 대해 몇 개의 예시만 보고 태스크에 적응하여 문제를 푸는 것




BART


- 자연어 생성을 위한 언어모델

- Sequence-to-Sequence 구조


- BART는 손상된 text를 입력받아 bidirectional 모델로 인코딩. 정답 text에 대한 likelihood를 autoregressive 디코더로 계산



<BERT>



<GPT>



<BART>

- 생성 task에서 fine-tuning 성능 향상

	CNN/DailyMail			XSum		
	R1	R2	RL	R1	R2	RL
Lead-3	40.42	17.62	36.67	16.30	1.60	11.95
PTGEN (See et al., 2017)	36.44	15.66	33.42	29.70	9.21	23.24
PTGEN+COV (See et al., 2017)	39.53	17.28	36.38	28.10	8.02	21.72
UniLM	43.33	20.21	40.51	-	-	-
BERTSUMABS (Liu & Lapata, 2019)	41.72	19.39	38.76	38.76	16.33	31.15
BERTSUMEXTABS (Liu & Lapata, 2019)	42.13	19.60	39.18	38.81	16.50	31.27
BART	44.16	21.28	40.90	45.14	22.27	37.25

한국어 자연어 처리 소개

형태소 분석

- 정의(두 가지의 과정으로 구분)
 - 형태소 분석 : 문장 내의 어절을 뜻을 지니는 최소의 단위인 형태소로 분해하고 해당 형태소의 품사 후보를 생성
 - 품사 태깅 : 형태소의 품사 후보로부터 가장 적절한 품사를 결정하는 과정
 - 입력문
 - 예) 거리는 사람의 물결로 넘쳤다

거리는 → 거리 [NNG] 는 [JX]


사람의 → 사람 [NNG] 의 [JKG]

물결로 → 물결 [NNG] 로 [JKB]

넘쳤다. → 넘쳤 [VV~EP] 다 [EF] . [SF]

형태소 분석


- Bi LSTM CRFs 형태소 분석
 - 음절 단위의 품사 태깅 방법
 - 순차 데이터를 모델링하는 양방향 LSTM에 출력 태그 간의 전이 확률을 얻는 CRF와 결합하는 방식
 - [B(Begin),I(Inside)] 등의 태그 등을 붙인 품사 태그를 결정하는 방식



의존 파싱(구문 분석)

- 정의

- 문장의 구조를 결정하는 구문 분석(파싱)의 한 갈래로 단어의 Head(지배소)와 Modifier(의존소)의 관계에 따라 문장의 구조를 결정



- Paradigm

<전이 기반 방식>

버퍼와 스택으로부터 자질을 추출한 후 모델을 통해 다음 전이 액션을 결정하고 결정된 액션에 따라 버퍼와 스택의 상태를 갱신하면서 트리를 생성해 나가는 방식

지역적 탐색 모델

<그래프 기반 방식>


문장 내의 가능한 모든 단어 쌍의 의존관계를 찾아서 점수화하여 가장 높은 점수를 갖는 의존 트리를 찾는 방식

전역적 탐색 모델

관계 분류

- 정의


- 문장 내에서 두 개체(entity)가 주어질 때, 두 명사 사이의 관계를 분류하는 것



상호 참조 해결

- 정의

- 문서 내에서 선행하는 명사구와 현재 등장한 명사구 간의 같은 개체를 의미하는지를 결정하는 문제
- 문맥을 이해하는데 중요한 역할을 하며 기계 번역, 질의 응답 문서 요약 시스템 등에 응용



"I voted for Nader because he was most aligned with my values," she said.


개체명 연결

- 개체명
 - 문서에서 나타나는 고유한 의미를 가지는 단어 또는 구절을 의미
 - 문서에서 나타난 개체 표현을 개체 맨션이라고 부름
 - 개체 표현과 실제 엔티티는 다를 수 있음
 - “트럼프”, “도널드 존 트럼프”, 도널드 트럼프” 등 다양한 형태로 문서에서 나타날 수 있음

Vancouver is a coastal seaport city on the mainland of British Columbia.
The city's mayor is Gregor Robertson.


개미 사회에 대한 묘사가 참 뛰어나서 진실이라고 믿게 한 이 작품 『개미』
을 저는 베르나르 베르베르의 가장 뛰어난 작품으로 여기고 있습니다.

- 개체명 인식
 - 개체명 인식은 문서로부터 개체명을 추출하고 추출된 개체명의 종류를 분류하는 자연언어처리의 한 분야



- 문서 내에서 개체 맨션을 찾은 후 적절한 타입을 부여
- 주로 Bi-LSTM-CRF 기반의 연구가 주를 이루었음

- Bi-LSTM-CRF 기반의 개체명 인식
 - 주어진 sequence에 대해서 label을 부여하는 sequence labeling(순차 태깅) 방식
 - 위 예제는 멀티 토큰에 대한 적절한 예가 아님



- Bi-LSTM-CRF 기반의 개체명 인식

- 한국어 예제)

- 입력은 “형태소”와 “태그”의 임베딩을 한 후 LSTM을 거친 후 [B,I]가 포함된 태그를 labeling.

Morpheme	Morpheme Tag	NE B/I/O Tag
박지성	NNP	PER_B
은	JX	O
맨체스터	NNP	ORG_B
유나이티드	NNG	ORG_I
FC	SL	ORG_I
소속	NNG	O
축구	NNG	CVL_B
선수	NNG	CVL_I
이	VCP	O
다	EF	O
.	SF	O

- 개체명 연결(Entity Linking)

- 주어진 문장에 출현한 엔티티를 위키피디아와 같은 지식 베이스(Knowledge base) 상의 하나의 개체와 연결하여 특정 개체가 무엇인지 식별하는 작업
- 보통 2 단계로 이루어짐
 - Mention Detection(멘션 추출): 문서 내에 나타나는 개체를 인식하는 과정
 - Disambiguation(중의성 해결): 인식된 개체 표현에 대해 후보 개체 중에서 중의성을 해결하여 특정 개체로 연결하는 과정

개미 사회에 대한 묘사가 참 뛰어나서 진실이라고 믿게 한 이 작품 『개미』을 저는 베르나르 베르베르의 가장 뛰어난 작품으로 여기고 있습니다.



- 개체명 연결(Entity Linking)
 - 소설 개미 page

개미 (소설)

위키백과, 우리 모두의 백과사전.

《**개미**》(프랑스어: Les Fourmis)는 프랑스의 작가 베르나르 베르베르의 동단작이자 가장 유명한 작품이다.[[][]] PC를 이용해 120번에 가까운 개작을 해서 1991년 탈고했다.

목차 [숨기기]

1

한국에서 출판되며 달라진 점들

2

등장인물

3

소품

4

여담

5

같이 보기

- 곤충 개미 page

개미

위키백과, 우리 모두의 백과사전.

다른 뜻에 대해서는 **개미** (동음이의) 문서를 참조하십시오.

개미(ant)는 벌목 **개미과**(표준어: 개밧과)에 속하는 **진사회성 곤충**(eusocial insect)의 총칭으로, **말벌**, **벌**과 더불어 **벌목**에 속한다. **속씨식물**이 등장한 이후 분화하였다. 오늘날에는 12,000~14,000 여 종의 개미가 생존하고 있는 것으로 추산된다. 한국에는 137 별할 수 있다. 개미는 군체를 이루어 사는데, 수십 마리 규모로 작은 구멍에 사는 포식성 개미 군체가 있는가 하면 넓은 지역에 개미 대다수가 일개미나 병정개미 혹은 여타 분업 집단 등의 계급을 이루며, 그 밖에 임성이 있는 수개미와 하나 이상의 여왕개 하기도 하는데, 개미는 군체 전체를 위해 협동하며 단일한 개체처럼 움직이는 것으로 보이기 때문이다.^[3]

개미는 벌목 개미과(표준어: 개밧과)에 속하는 진사회성 곤충(eusocial insect)의 총칭으로, 말벌, 벌과 더불어 벌목에 속한다. 속씨식물이 등장한 이후 분화하였다. 오늘날에는 12,000~14,000 여 종의 개미가 생존하고 있는 것으로 추산된다. 한국에는 137 별할 수 있다. 개미는 군체를 이루어 사는데, 수십 마리 규모로 작은 구멍에 사는 포식성 개미 군체가 있는가 하면 넓은 지역에 개미 대다수가 일개미나 병정개미 혹은 여타 분업 집단 등의 계급을 이루며, 그 밖에 임성이 있는 수개미와 하나 이상의 여왕개 하기도 하는데, 개미는 군체 전체를 위해 협동하며 단일한 개체처럼 움직이는 것으로 보이기 때문이다.

- 개미 동음이의어 page 목록


개미 (동음이의)

위키백과, 우리 모두의 백과사전.


개미에는 다음과 같은 뜻이 있다.

- 개미**는 곤충의 하나이다.
- 개미**는 베르나르 베르베르의 소설이다.
- 개미**는 애니메이션 영화이다.
- 개미**는 대한민국의 작곡가이다.
- 개미**는 투자업계에서 **개인투자자**를 일컫는 속어이다.

- 개체명 연결(Entity Linking) 모델
 - 개체명 인식 절차를 통해 개체명이 인식되었다고 가정하고 중의성 해결에 목표를 둠
 - Modeling Mention, Context and Entity with Neural Networks for Entity Disambiguation(Sun, IJCAI '15)
 - 신경망을 통해 mention, context, 후보 엔티티에 대한 vector를 구성하고 결합된 mention-context vector와 후보 entity vector 사이의 유사도를 구하고 유사도가 가장 높은 entity를 선택



- Modeling Mention, Context and Entity with Neural Networks for Entity Disambiguation(Sun, IJCAI '15)



– Mention/Context 표현 파트, Entity 표현 파트로 구성

• Mention/Context 표현 파트

- context는 CNN을 거친 후 max-pooling을 통해 고정 크기 벡터 얻음
- mention은 임베딩 후 평균을 취해 고정 크기 벡터 얻음
- NTN(Neural Tensor Network)로 결합 => 다양한 결합 방법이 있을 수 있음

- Modeling Mention, Context and Entity with Neural Networks for Entity Disambiguation(Sun, IJCAI '15)

- Mention/Context 표현 파트, Entity 표현 파트로 구성
 - Entity 표현 파트
 - 후보 엔티티의 word 표현은 mention과 동일하게 임베딩 후 평균
 - 후보 엔티티의 type 임베딩
 - Type 표현과 Word 표현을 NTN으로 결합하여 하나의 벡터로 구성
- 유사도로 판별
 - 유사도가 최대가 되는 후보 엔티티를 선택

$$sim(e, mc) = cosine(v_e, v_{mc})$$

- 유사도가 최대가 되도록 학습

$$loss = \sum_{(m,c) \in T} max(0, 1 - sim(e, mc) + sim(e', mc))$$

- 개체명 연결(Entity Linking) 모델
 - 엔티티 표현으로 다양한 정보를 이용할 수 있음
 - 예) entity description

개미 (소설)

위키백과, 우리 모두의 백과사전.

《개미》(프랑스어: Les Fourmis)는 프랑스의 작가 베르나르 베르베르의 등단작이자 가장 유명한 작품이다.

- End-to-End 개체명 연결 모델
 - Mention Detection(멘션 추출)과 Disambiguation(중의성 해결)을 단일 모델에서 동시에 수행