
계층적 다중 레이블 임베딩을 이용한 논문 문장 수사학적 분류

인공지능 부문 – 국내 논문 문장 의미 태깅

주제 : 문장 태깅 모델

김슬기, 김담린, 이주상, 이우진


목차

- 개요
 - 텍스트 분류
 - 대분류
 - 세부분류
 - 모델
 - 실험 및 결과
 - 결론
-


텍스트 분류란 ?

- 텍스트 분류


- 단어, 문장 또는 지문 전체를 n개의 범주 중 하나로 분류하는 작업
- 예시



< 감성 분석 >



<클래스 분류>



< 의도 분류 >

텍스트 분류 - 대분류, 세부분류

- 대분류 (Coarse-grained)

- “크게 나누어 가름”
- 세부분류들을 포함하는 범주형 데이터

- 세부분류 (Fine-grained)

- “작게 나누어 가름”
- 대분류에 속하는 범주형 데이터



대분류 , 세부분류 - 감정분석 적용 예시

문장

세부분류

목표에 도달해서 매우 뿌듯해.

기쁨

기대


...

힘오

화남

...


대분류, 세부분류 - 감정분석 적용 예시



논문 문장 수사학적 분류 – 대분류, 세부분류

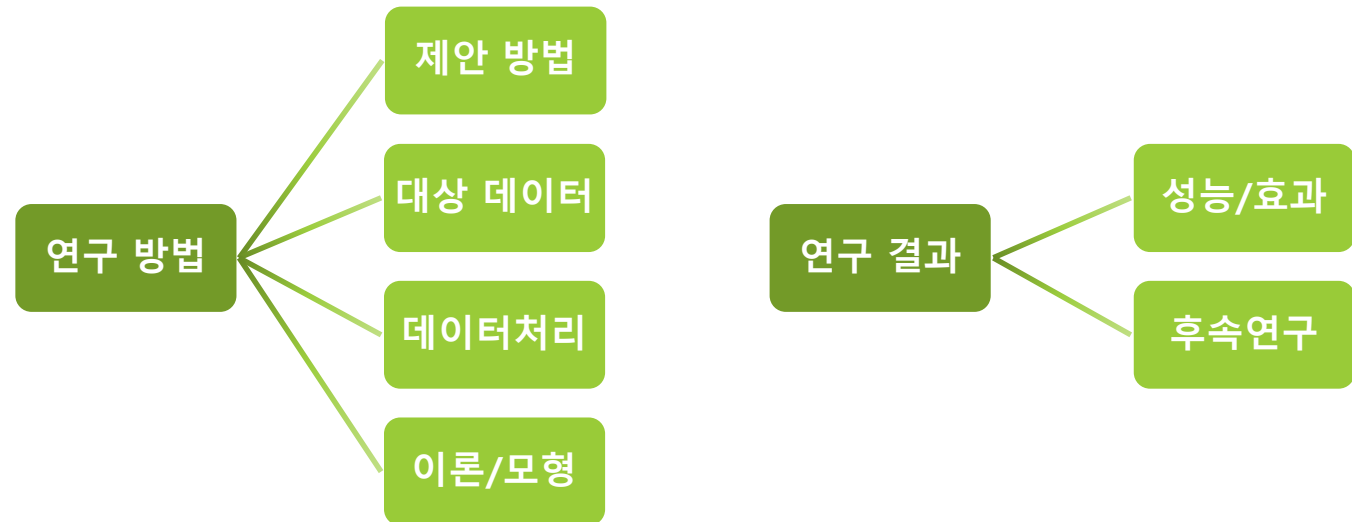
- 대분류

– 의미 구조 분류



- 세부분류

– 문장 의미 세부 분류



제안 모델

- 국내 논문 문장 의미 태깅

- 계층적 다중 레이블 임베딩을 이용한 대분류, 세부분류 태그 예측


- 대분류 태그에 비해 세부분류 태그의 학습데이터 개수 차이가 큼

- 대분류 태그 임베딩 정보를 세부분류 태그 학습에 이용하여 불균형 문제 해결 가능

- 대분류 태그 임베딩도 같이 학습

- 세부분류 태그 뿐만 아니라 대분류 태그도 예측 가능

전체 모델 구조도



대분류 태그 예측

- *Scaled Dot – product Attention*


- $A^1(C_i) = \text{softmax} \left(\frac{Q \cdot K^T}{\sqrt{d_h}} \right) \cdot V$

- $Q = \vec{H}^1, \quad K = V = \text{Emb}_k^{\text{coarse-grained}}$

- *Scaled Dot – product*

- $A^2(C_i) = \text{softmax} \left(\frac{Q \cdot K^T}{\sqrt{d_h}} \right)$

- $Q = \vec{H}^2, \quad K = \text{Emb}_k^{\text{coarse-grained}}$



세부분류 태그 예측

- *Scaled Dot – product Attention*


$$- A^3(C_i) = \text{softmax} \left(\frac{Q \cdot K^T}{\sqrt{d_h}} \right) \cdot V$$

$$- Q = \vec{H}^3, \quad K = V = \text{Emb}_k^{\text{fine-grained}}$$


- *Scaled Dot – product*

$$- A^4(C_i) = \text{softmax} \left(\frac{Q \cdot K^T}{\sqrt{d_h}} \right)$$


$$- Q = \vec{H}^4, \quad K = \text{Emb}_k^{\text{fine-grained}}$$



데이터셋 - 대분류



데이터셋 - 세부분류



평가 방법

- $Macro\ F1 - Score = \frac{1}{n} \sum_{i=1}^n \frac{(2 \times precision_i \times recall_i)}{precision_i + recall_i}$

- $Micro\ Accuracy = \frac{\sum_{i=1}^n TP_i + \sum_{i=1}^n FN_i}{\sum_{i=1}^n TP_i + \sum_{i=1}^n TN_i + \sum_{i=1}^n FP_i + \sum_{i=1}^n FN_i}$

	Positive	Negative
Positive	True Positive	False Positive
Negative	False Negative	True Negative

실험 결과

번호	사전학습 언어모델	모델	대분류		세부분류		대분류+세부분류
			macro F1	micro accuracy	macro F1	micro accuracy	micro accuracy
1	KorSciBERT	LAN (세부분류)	-	-	89.89	89.65	-
2		LAN (대분류, 세부분류)	95.51	96.85	89.95	89.76	88.59
3	KLUE BERT-base	LAN (대분류, 세부분류)	95.54	96.43	89.77	89.58	88.55
4	KLUE roBERTa-base	LAN (대분류, 세부분류)	95.64	96.77	90.00	89.85	88.79

결론

- 계층적 다중 레이블 임베딩을 이용한 대분류, 세부분류 태그를 예측하여 대분류 95.64%, 세부분류 90%의 F1-score를 보임
- 세부분류 뿐만 아니라 대분류 태그도 한번에 예측함
- 문장 분류 뿐만 아니라 다른 태스크에도 적용하여 향후 연구 예정

QnA

감사합니다