

HanBERT Package

2021.09

(주) 투블록 Ai



1. 도입의 필요성
2. HanBERT 소개
3. HanBERT 패키지
4. HanBERT 도입방법

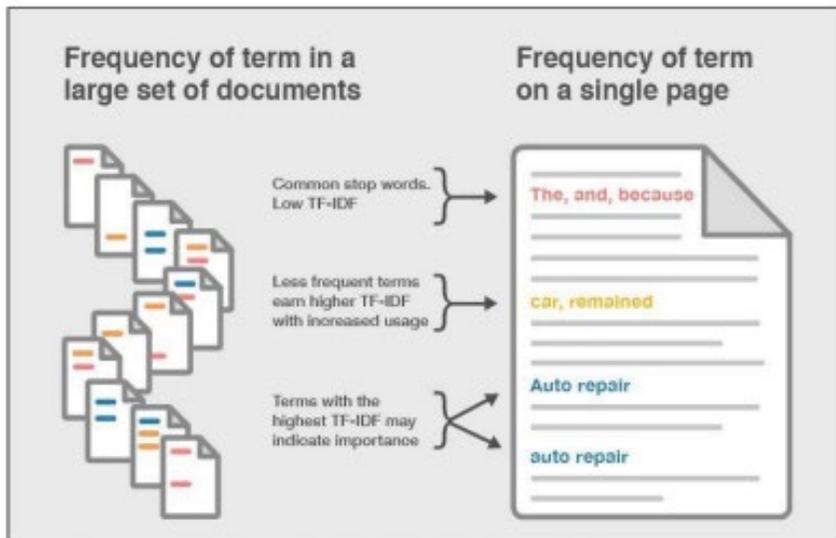
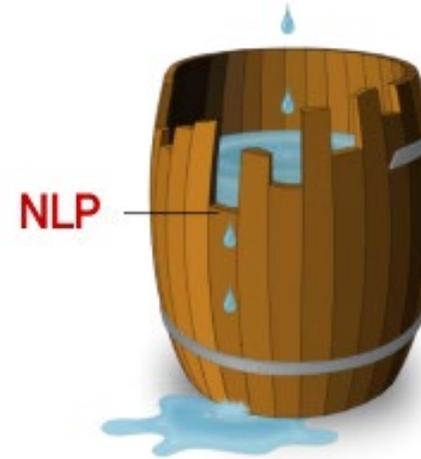
1. 도입의 필요성 | 70점짜리 키워드 분석 수준의 한계

정보량의 법칙 (tf/idf) 의 한계

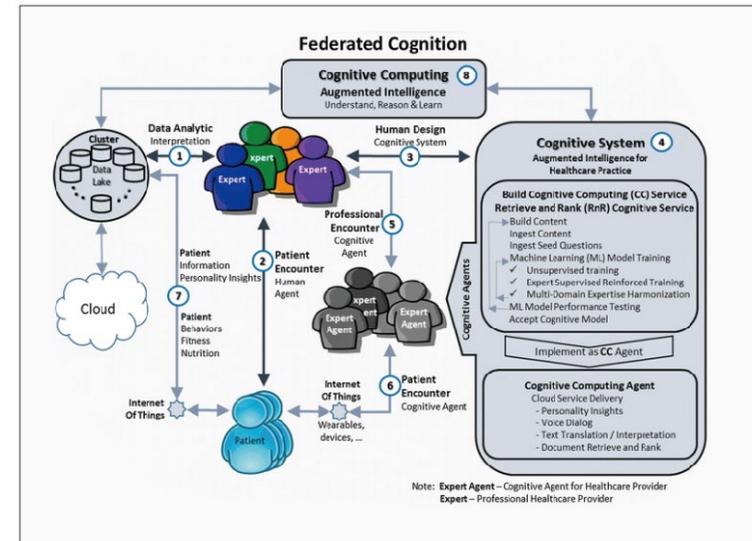
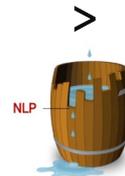
- 문서에서 중요한 단어 추출하여 문서의 의미를 대신하는 방법
- 문서를 자동으로 요약하고 싶은데, 지금 수준으로는 못 쓰겠어요.
- 게시판 댓글을 분석하려는데, 시스템 구축하는 비용이 부담스러워요.

Classical NLP 구축 절차와 비용

- 사전, 문법, 동의어 사전, 온톨로지, 의미 분류 등의 지식 베이스 구축이 필요
- 패턴 수집과 규칙 작성의 일관성과 상호 간섭을 고려하기가 어려움
- 시장에서 기대하는 성능을 만족시키지 못하고 있음



NLP 성능 리비히의 법칙



1. 도입의 필요성 | BERT의 놀라운 성능

과거 기술을 통한 언어이해 성능을 혁신적으로 추월.

BERT 는 구글이 공개한 모델이며 업체마다 자신들만의 Corpus와 다양한 전처리 방법을 사용하여 자신들만의 모델로 학습을 시켜야 함. (자체 한국어 BERT 모델 보유 기업은 많지 않음. ETRI가 공개한 KoBERT 가 대표적)

(예) 네이버 영화평 DB에서 긍정과 부정의 판별

적용기술	성능	속도	학습비용
임의로 긍/부정 판별	50점	0ms	0원
Symbolic NLP 기술	75점 수준	50ms~100ms	1억원 수준
범용 딥러닝 기술을 활용	85점 수준	10ms~20ms	100만원
BERT에 추가학습	91점	15ms~20ms	10만원

(예)논문에서 발표된 BERT와의 성능 비교

System	MNLI-(m/mm) 392k	QQP 363k	QNLI 108k	SST-2 67k	CoLA 8.5k	STS-B 5.7k	MRPC 3.5k	RTE 2.5k	Average
Pre-OpenAI SOTA	80.6/80.1	66.1	82.3	93.2	35.0	81.0	86.0	61.7	74.0
BiLSTM+ELMo+Attn	76.4/76.1	64.8	79.8	90.4	36.0	73.3	84.9	56.8	71.0
OpenAI GPT	82.1/81.4	70.3	87.4	91.3	45.4	80.0	82.3	56.0	75.1
BERT _{BASE}	84.6/83.4	71.2	90.5	93.5	52.1	85.8	88.9	66.4	79.6
BERT _{LARGE}	86.7/85.9	72.1	92.7	94.9	60.5	86.5	89.3	70.1	82.1

2. HanBERT 소개

- 한국어 분석기 Moran 탑재 • 빠른 처리 속도 • 높은 품질 • 다양한 크기의 모델 • Vocab에 충분한 여유 공간 •

HanBERT

HanBERT Base 언어모델 라이선스

설치되는 서버의 GPU수, 기업규모, 서비스 목적, 규모에 따라 최적화
Domain 전용 언어모델 개발



필요한 Deep NLP 추가모델 NER, MRC, Sentiment 등



Task를 위한 학습



학습용 데이터 정제



형태소 분석기 튜닝



고객 특화 Deep NLP 모델, 서비스용 API 등



고객 컨설팅 기획, 전략 등의 서비스

모델코드	설명			
54k / 90k	Vocab의 크기	54k : 54000 표제어 90k : 90000 표제어		
S/N/ML	모델의 크기와 학습량	S 6층	히든 768	3.8M 학습
		N 12층	히든 768	5 M 학습
		ML 18층	히든 1024	10M 학습

3. HanBERT 패키지

Basic	Basic 한국어 분석기 Moran 기본 탑재 모델 사용 라이선스 용도에 맞게 모델 선택	10천만원 / 4 GPU + License Fee / year
Premium	고객 데이터 학습 지원 Task별 추가 학습을 위한 기술지원	Basic + 3천만원/Task
기술이전	한국어 분석기 튜닝 Vocab 튜닝 기술 지원 BERT 학습용 코퍼스 레코드 제공 BERT 학습 기술지원 Domain 별 BERT 구축	별도 협의

부가세 별도

4. HanBERT 도입방법 | Basic

Basic

HanBERT에 Task의
추가 학습을 스스로 하는 경우

Basic 한국어 분석기 Moran 기본 탑재
모델 사용 라이선스
용도에 맞게 모델 선택

기술 지원 범위 : Task에 적합한 모델 선택,
API 서비스 방법 지원, Docker 이미지 제공

1. 오픈소스를 통해서 모델 다운로드 : <https://github.com/tbai2019/HanBert-54k-N>
자체적으로 Task 데이터로 학습 수행
2. 도입 요청을 이메일로 통보 : info@twoblockai.com
 - 1) 상업적 사용의 Task를 알려주면, 적합한 모델을 추천해 드림
 - 2) 도입을 원하는 HanBert 모델 협의
 - 3) 운영 장비 규모를 고려한 도입 라이선스 숫자를 통보
3. 세금 계산서 발행 및 비용 납부
4. HanBert 모델을 제공 : 다운로드 링크 제공 최종 제공할 HanBert 모델과 라이선스 제공
5. 도입한 규모의 범위에서 BERT 모델 활용 자체적으로 Task 학습 / 라이선스 비용협의

4. HanBERT 도입방법 | Premium

<p>Premium</p> <p>HanBert에 Task의 추가 학습을 의뢰하는 경우</p>	<p>고객 데이터 학습 지원 Task별 추가 학습을 위한 기술지원</p>	<p>기술 지원 범위 : Task에 적합한 모델 선택, Task 학습 , Moran 튜닝 + Basic 패키지</p>
--	--	---

1. 협의 요청을 이메일로 통보 : info@twoblockai.com

- 1) 상업적 사용의 Task를 알려주면, 학습 데이터에 대한 컨설팅 제공
- 2) 적합한 HanBert 모델 선택
- 3) 학습 데이터는 고객 측에서 준비

2. Premium 패키지 계약

3. Task 학습 수행

협의를 따라 학습용 장비와 학습 주체 선택
학습 후 성능 확인된 모델에 라이선스 제공

4. 도입한 규모의 범위에서 BERT 모델 활용

Basic 모델과 동일하게 활용하는 GPU의 개수에 따라 비용 산정
Basic 모델에 대한 라이선스 제공

4. HanBERT 도입방법 | 기술이전

기술이전

자체적으로 BERT 를 만드는 경우
(6-7개월 소요)

한국어 분석기 튜닝 /Vocab 튜닝 기술 지원
BERT 학습용 코퍼스 레코드 제공
BERT 학습 기술지원
Domain 별 BERT 구축

기술 지원 범위 : Moran 튜닝, Vocab 설정,
BERT 학습용 데이터 변환, BERT 학습 지원

1. 협의 요청을 이메일로 통보 : info@twoblockai.com

자체 보유 코퍼스의 규모와 BERT 활용 목적을 통보

2. 기술이전 패키지 세금 계산서 발행 및 비용 납부

3. Moran 튜닝 및 Vocab 결정

활용 분야에 따라, 한국어 분석기의 기본 사전을 튜닝 / 활용하는 코퍼스에 따라 Vocab을 결정

4. BERT 학습용 코퍼스 데이터 제공

Vocab을 적용하여 BERT 학습을 위한 학습 데이터 형태로 제공

5. 자체적으로 BERT 학습

고객이 보유하고 있는 코퍼스를 BERT 학습용 데이터로 변환

BERT 학습용 데이터로 BERT 모델 학습

감사합니다.

주 소 서울특별시 서초구 남부순환로 350길 54 (양재동, 브이타워 1층)

전 화 02.6677.1111

이메일 info@twoblockai.com

홈페이지 www.twoblockai.com



말을 알아 듣는 Ai가 만들어 가는 편리한 세상, 사람에 대한 호기심이 세상을 바꿉니다.