

목차

1. 선정 알고리즘
2. 데이터 전처리
3. 후처리 및 모의 분석

“고객 피드백 분류”를 위한 알고리즘 모델 기획서

Team : 머홍

1

선정 알고리즘



1. LSTM, GRU

*비교적 가벼운 언어모델

➤ 무거운 Kobert의 단점을 상쇄시키기 위해 사용

2. Kobert^[1]

*구글에서 개발한 언어모델인 BERT의 한국어 버전

* 현재 가장 보편적이며 성능이 좋은 알고리즘

* Inference가 느리다는 단점

➤ 높은 분류 정확도를 위해 사용



Idea Challenge의 objective

1. 다중분류의 정확도
2. 가볍고 성능이 좋은 모델



문제 해결 Process

1. LSTM or GRU를 통해 '칭찬'과 '불만' 분류

* '중립' 과 '폐기'는 비교적 데이터가 적을거라 예상

(1)중립 해결방안

- 동사가 없거나 명사구로 되어있기 때문에 간단한 조건문으로 해결

(2)폐기 해결방안

- anomaly detection 또는 Rejection Option^[2]을 통해 모델의 output score가 threshold내이면 폐기로 분류

2.Kobert로 중분류와 소분류를 합쳐서 진행

* 중분류와 소분류를 합쳐 총 21개의 카테고리

ex) '고객서비스-상담원', '삼성카드-커뮤니케이션'

[1] <https://github.com/SKTBrain/KoBERT>

[2] Recent Advances in Open Set Recognition: A Survey [Chuanxing Geng *et al.*, IEEE 2020]

2

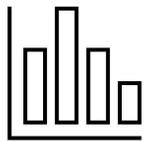
데이터 전처리 - 1

1. 맞춤법 검사

- Py-Hanspell

- ✓ 네이버 한글 맞춤법 검사기를 바탕으로 만들어진 패키지
- ✓ Training시 적용하면 모델이 맞춤법이 맞지 않는 발화에 robust하지 못함

➤ Inference시에만 적용



- 제공 데이터 실습 결과

- 1) Train 데이터에 맞춤법 검사를 하고 학습시킨 모델
- 2) Train 데이터에 맞춤법 검사를 하지 않고 학습시킨 모델

* Test data accuracy 결과

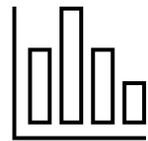
2 > 1

➤ Training시 Py-Hanspell 미적용

2. 토큰화

- 형태소 분석기 종류

1. Mecab
2. KoNLPY의 Okt
3. Pretrained된 문장에 KoBERT의 tokenizer 적용



- 제공 데이터 실습 결과

- 1) Mecab
- 2) Okt
- 3) KoBERT의 tokenizer

* Test data accuracy 결과(같은 조건)

1 > 2 = 3

➤ Mecab을 사용하여 토큰화

3. 복문 처리

- 복문 처리 방법

- ✓ 복문 또는 구형태의 문장은 주로 접속사 이후에 발화의 목적이 담겨있음
- 토큰화시 접속사등을 기준으로 뒷문장에 집중

2

데이터 전처리 - 2

4. 대분류

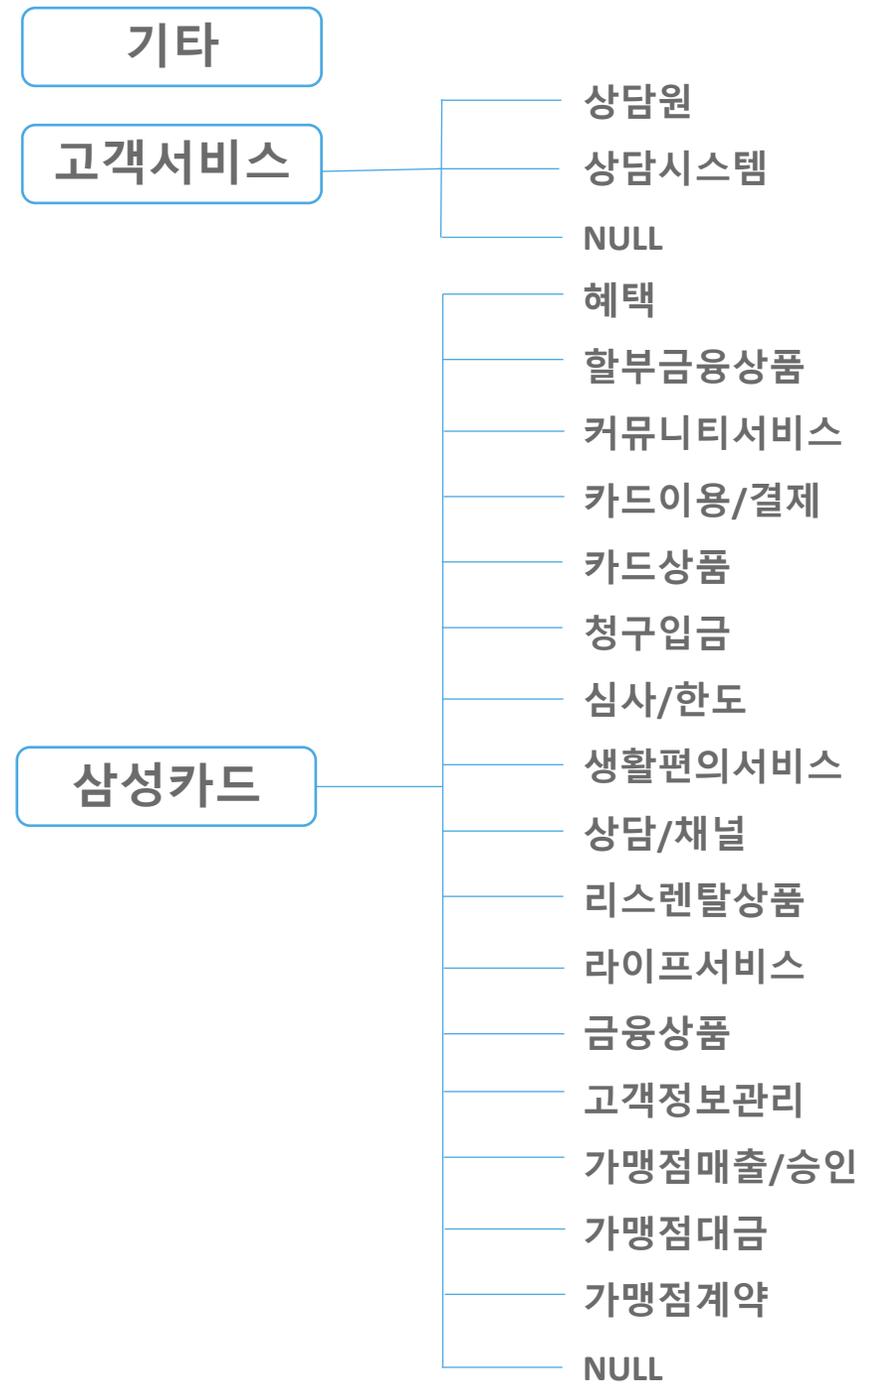
- Labeling

- ✓ '중립' 또는 '폐기' 분류는 조건문과 rejection option 또는 anomaly detection으로 해결
- '대분류'는 '칭찬'과 '불만'의 **binary classification**

5. 중,소 분류

- Labeling

- ✓ 중분류는 '삼성카드', '고객서비스', '기타' 3가지
- ✓ 삼성카드의 소분류 17가지, 고객서비스의 소분류 3가지, 기타를 합쳐 총 21가지로 분류
- **총 21가지의 카테고리**로 나눈 **multi classification**



3

후처리 및 모의 분석

후처리 방법

- 결과값 처리

- ✓ 제공 데이터에서 복수개의 분류가 채택된 발화가 존재함을 확인
- ✓ 복수 분류의 경우 우선순위를 통해 최종 분류가 되는 조건이 있음을 확인
- **Category별 %와 우선순위 score를 지정하여 최종분류의 근거를 보여줄 계획**

모의 분석

- LSTM 모델을 이용한 대분류

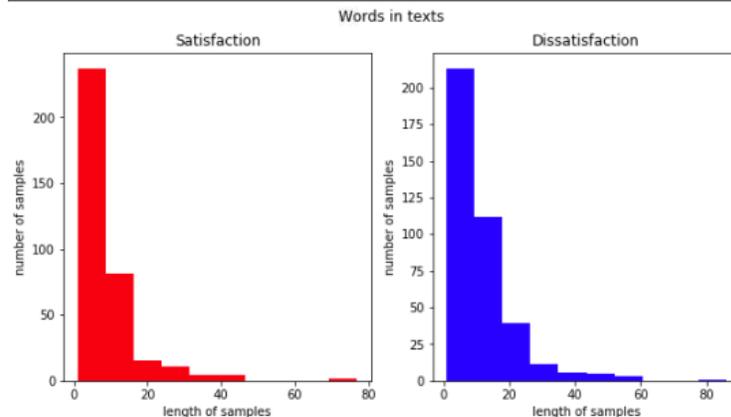
전체 데이터 수: 1000
 모델이 맞춘 데이터 수: 956
 모델이 틀린 데이터 수: 37
 정답률: 0.956
 1000개의 데이터에 대한 수행시간: 29.017874717712402

- KoBERT 모델을 이용한 대분류

전체 데이터 수: 1000
 모델이 맞춘 데이터 수: 987
 모델이 틀린 데이터 수: 13
 정답률: 0.987
 1000개의 데이터에 대한 수행시간: 180.29840993881226

- ✓ LSTM과 KoBERT를 통해 Inference 시간과 정확도가 trade-off 관계인것을 알수 있었으며 실험을 통해 본 challenge의 GOAL에 부합한 알고리즘을 설계

칭찬 발화의 평균 길이 : 8.694915254237289
 불만 발화의 평균 길이 : 11.923076923076923



발화의 최대 길이 : 61
 발화의 평균 길이 : 9.065860215053764

