

# TensorFlow를 활용한 콘텐츠 분석

김태  
훈

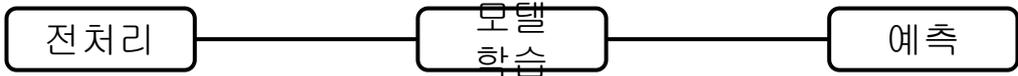
# 개 요

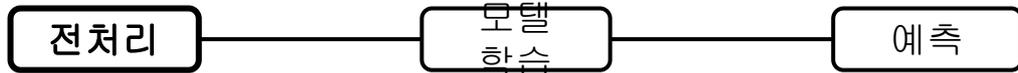
데일리하면서 과하지않은 애교살  
메이크업💜



해당 회원이 콘텐츠를 좋아할 확률은 85.9%  
입니다.

# 과정

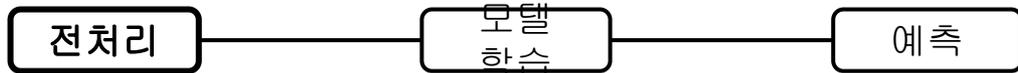




## DB에서 회원이 좋아요 누른 콘텐츠 데이터 가져오기

```
id      la content
00071  0  요거예요! 톤28 세경질이네용
00073  1  진경팩인데 수분감 좋아요! 거즈마스크인 것도 좋아요!
00074  1  롬앤 더스티로즈 강추여! 처음엔 붉고 뽀얗게 올라오는데 갈수록 살짝 안개끼 핑크노킴 들면서 붉은데 너무 뽀얗지 않은 느낌! 쿨톤인데 완전 잘쓰고 있어요!
00079  0  사실 저 키보드 삼,, 키보드 소리 넘 귀여워 소동해 다들 내 키보드 소리 들어줘쓰면 조계씨,, ☆
00112  1  문샷틴트핏블러 발림성 완전 버터 같아요! 지속력이 재금 이쉽지만 걸보속속 ♡ 넘 부드럽게 발라서 계속 비르고 싶은 고론노킴 🍷 #문샷 #틴트핏블러 #틴트추천
00115  1  #클리오#킬커버워터프루프마스카라이거 진짜 썬탠이예요.. 벌써 다써감.. 올영 세일할 때 1+1으로 꼭 갖주세요!!!!
00119  0  화알못이예요 저
```

# 과정



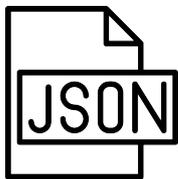
모든 콘텐츠 형태소  
분석



# 과정

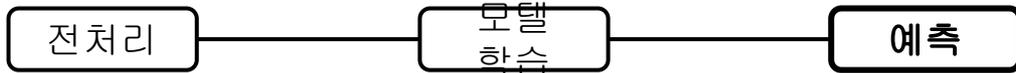


전처리가 완료된 데이터를  
텐서플로우로 학습



모델  
저장!

# 과정



저장된 모델 불러와 결과  
예측

데일리하면서 과하지않은 애교살  
메이크업💜



해당 회원이 콘텐츠를 좋아할 확률은 85.9%  
입니다.

# API 화

- 모델 학습 API

POST http://13.125.247.141:5000/learning/model/526

Params Authorization Headers (9) **Body** Pre-request Script Tests Settings

none  form-data  x-www-form-urlencoded  raw  binary  GraphQL

KEY	VALUE
<input checked="" type="checkbox"/> train_data	526_train_data.txt ×
<input checked="" type="checkbox"/> test_data	526_test_data.txt ×
Key	Value

- 예측 API

POST http://15.164.217.112:5000/analyze/content

Params Authorization Headers (9) **Body** Pre-request Script Tests Settings

none  form-data  x-www-form-urlencoded  raw  binary  GraphQL **JSON** ▾

```
1 {
2   ... "memberId":526,
3   ... "content": "참여방법 참고하세요 ♡퍼스널컬러는 꼭 손글씨로 작성할 필요는 없습니다 ♡♡"
4 }
5
6
```

# 개발환경 세팅, 실행, 구현 방법

김태  
훈

# 개발환경 세팅

os: mac Ventura 13.0 M1

Anaconda : 4.12.0

python : 3.9.0

라이브러리

nlTK : 3.7

numpy : 1.22.3

konlpy : 0.6.0

tensorflow : 2.9.1

sklearn : 1.1.1

flask : 2.1.2

# 라이브러리

## 설치

```
import json
import os
import time
from pathlib import Path

import nltk
import numpy as np
from konlpy.tag import Okt
okt = Okt()

from tensorflow.keras import models
from tensorflow.keras import layers
from tensorflow.keras import optimizers
from tensorflow.keras import losses
from keras.wrappers.scikit_learn import KerasClassifier
from sklearn.model_selection import KFold
from sklearn.model_selection import cross_val_score

from flask import Flask, request
from werkzeug.utils import secure_filename
app = Flask(__name__)
```

```
>>> import nltk
Traceback (most recent call last):
  File "<stdin>", line 1, in <module>
ModuleNotFoundError: No module named 'nltk'
```

설치되지 않은 라이브러리는

(base)% conda activate tf (가상환경 실행)

(tf)% conda install nltk (라이브러리

설치)

명령어로 설치

# 라이브러리 설정

## Linux or mac os 이슈!

라이브러리 설치하면서 설치가 안 되는 애들이 있는데  
java jdk 가 필요한 것들이 있다.

근데 또 버전이 안 맞으면 설치가 안 된다.

```
openjdk version "15.0.7" 2022-04-19  
OpenJDK Runtime Environment Zulu15.40+19-CA (build 15.0.7+4-MTS)  
OpenJDK 64-Bit Server VM Zulu15.40+19-CA (build 15.0.7+4-MTS, mixed mode)
```

이 버전으로 하면 설치가 될 것이다.

설치 URL

<https://www.azul.com/downloads/?version=java-15-mps&os=macos&architecture=x86-64-bit&package=jdk>

본인 OS 환경에 맞는 jdk  
설치

# 모델 학습 API

회원 id, 학습데이터, 테스트데이터를 받는다

```
def read_data(filename):  
    with open(filename, 'r') as f:  
        data = [line.split(' ') for line in f.read().splitlines()]  
        data = data[1:]  
    return data
```

```
@app.route("/learning/model/<int:memberId>", methods=['POST'])  
def learning_model(memberId):  
  
    if (not memberId):  
        return {"error": "memberId is missing"}, 400  
  
    file = request.files['train_data']  
    filename = secure_filename(file.filename)  
    file.save(filename)  
    train_data = read_data(str(memberId) + '_train_data.txt')  
  
    file = request.files['test_data']  
    filename = secure_filename(file.filename)  
    file.save(filename)  
    test_data = read_data(str(memberId) + '_test_data.txt')
```

id	la	content
00071	0	요거예요! 톤28 세정젤이내용
00073	1	진정팩인데 수분감 좋아요! 거즈마스크인 것두 좋아요!
00074	1	룸앤 더스티로즈 강추여! 처음엔 붉고 원하게 올라오는데 갈수록 살짝 안개낀 핑
00079	0	사실 저 키보드 삼,, 키보드 소리 넘 귀여워 소등해 다들 내 키보드 소리 들어
00112	1	문샷틴트핏블러 발림성 완전 버터 같아요! 지속력이 재금 아쉽지만 걸보속속 💕
00115	1	#클리오#킬커버워터프루프마스카라이거 진짜 썬탱이예요..벌써 다써감.. 올영 세

train\_data.txt

```
print(train_data[0])  
print(train_data[1])
```

```
['00071', '0', '요거예요! 톤28 세정젤이내용']  
['00073', '1', '진정팩인데 수분감 좋아요! 거즈마스크인 것두 좋아요!']
```

# 모델 학습 API

모든 콘텐츠를 형태소 분석 하여 토큰화 후 저장합니다.

```
def tokenize(doc):  
    # norm은 정규화, stem은 근어로 표시하기를 나타냄  
    return ['/'.join(t) for t in okt.pos(doc, norm=True, stem=True)]
```

```
if os.path.isfile(str(memberId) + '_rating_data.json'):  
    with open(str(memberId) + '_rating_data.json') as f:  
        train_docs = json.load(f)  
    with open(str(memberId) + '_test_data.json') as f:  
        test_docs = json.load(f)  
else:  
    train_docs = [(tokenize(row[2]), row[1]) for row in train_data]  
    test_docs = [(tokenize(row[2]), row[1]) for row in test_data]  
    # JSON 파일로 저장  
    with open(str(memberId) + '_rating_data.json', 'w', encoding="utf-8") as make_file:  
        json.dump(train_docs, make_file, ensure_ascii=False, indent="\t")  
    with open(str(memberId) + '_test_data.json', 'w', encoding="utf-8") as make_file:  
        json.dump(test_docs, make_file, ensure_ascii=False, indent="\t")  
  
tokens = [t for d in train_docs for t in d[0]]
```

# 모델 학습 API

데이터  
전처리

```
text = nltk.Text(tokens, name='NMSC')
selected_words = [f[0] for f in text.vocab().most_common(10000)]

def term_frequency(doc):
    return [doc.count(word) for word in selected_words]

train_x = [term_frequency(d) for d, _ in train_docs]
test_x = [term_frequency(d) for d, _ in test_docs]
train_y = [c for _, c in train_docs]
test_y = [c for _, c in test_docs]

x_train = np.asarray(train_x).astype('float32')
x_test = np.asarray(test_x).astype('float32')

y_train = np.asarray(train_y).astype('float32')
y_test = np.asarray(test_y).astype('float32')
```

가장 빈번한 단어 10000개만  
사용

각 단어 별 등장 횟수를 리턴하는  
함수

x에는 등장 횟수, y에는  
단어

다차원 배열을 빠르게  
처리하기 위한 마지막  
전처리

# 모델 학습 API

모델 정의 및  
생성

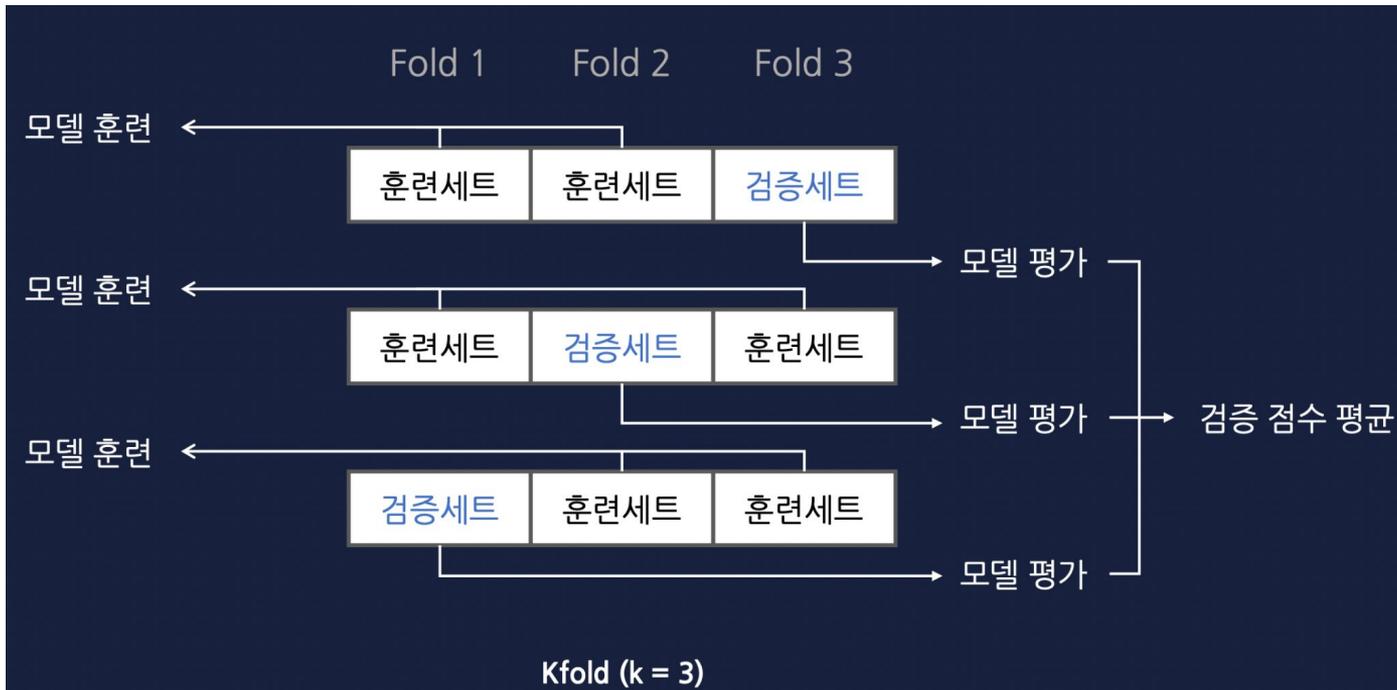
```
def create_model():  
    model = models.Sequential()  
    model.add(layers.Dense(64, activation='relu', input_shape=(10000,)))  
    model.add(layers.Dense(64, activation='relu'))  
    model.add(layers.Dense(1, activation='sigmoid'))  
    model.compile(optimizer=optimizers.RMSprop(lr=0.001),  
                 loss=losses.binary_crossentropy,  
                 metrics=["acc"])  
    return model
```

3개의 레이어로 구성된 모델  
호출에 추가적인 지표 설정

- optimizer: 값 조정 함수
- loss: 손실 함수
- metrics: 평가 지표 설정

# 모델 학습 API

K-Fold로 교차  
검증



# 모델 학습 API

K-Fold로 교차

검증

```
seed = 7
np.random.seed(seed)

model = KerasClassifier(build_fn=create_model, epochs=10, batch_size=512, verbose = 0)
kfold = KFold(n_splits=10, shuffle=True, random_state=seed)
results = cross_val_score(model, x_train, y_train, cv=kfold)
```

```
model = create_model()
model.fit(x_train, y_train, epochs=10, batch_size=512, validation_data=(x_test, y_test))
model.save("saved_model/" + str(memberId) + "_model")

response = {
    "kfold_average": "{:.2f}".format(results.mean()),
}

return response, 200
```

## 콘텐츠 예측

### API

회원 id, 콘텐츠를 받는다.

```
@app.route("/analyze/content", methods=['POST'])
def analyze_content():
    params = request.get_json()

    memberId = params['memberId']
    if (not memberId):
        return {"error": "memberId is missing"}, 400

    content = params['content']
    if (not content):
        return {"error": "content is missing"}, 400
```

## 콘텐츠 예측

### API

학습 모델을 생성하면서 전처리 된 json 데이터를 가져옵니다.

```
if os.path.isfile(str(memberId) + '_rating_data.json'):
    with open(str(memberId) + '_rating_data.json') as f:
        train_docs = json.load(f)
else:
    return {"error": "memberId: " + str(memberId) + " No learning model found"}, 400

tokens = [t for d in train_docs for t in d[0]]
text = nltk.Text(tokens, name='NMSC')
selected_words = [f[0] for f in text.vocab().most_common(10000)]
```

## 콘텐츠 예측

### API

model.predict 함수로 콘텐츠 예측

```
def term_frequency(doc):  
    return [doc.count(word) for word in selected_words]  
  
def predict_pos_neg(model, content):  
    token = tokenize(content)  
    tf = term_frequency(token)  
    data = np.expand_dims(np.asarray(tf).astype('float32'), axis=0)  
    score = float(model.predict(data))  
    return score
```

# 콘텐츠 예측

## API

모델 불러오기, 콘텐츠 예측하기

```
model_dir = Path("saved_model/" + str(memberId) + "_model")
if not model_dir.is_dir():
    return {"error": "memberId: " + str(memberId) + " No learning model found"}, 400

model = models.load_model("saved_model/" + str(memberId) + "_model")
score = predict_pos_neg(model, content)

response = {
    "ai_feedback": round(score, 2)
}

return response, 200
```