SAMSUNG

자연어 분석을 통한 마케팅 전략 도출

01

OUTLINE

팀 소개, 역할 분담
주제선정이유
데이터 개요

02

ANALYSIS

연구 방법
데이터 수집 / 전처리

03

PREDICT

예측 모델 선택
네이버 카페 / 유투브 댓글 분석

04

CONCLUSION

결론해석
시사점, 연구한계
출처

01

OUTLINE

Outline

1-1 팀 소개

TEAM | 미래전략실

성호*	노태* 	이한*
데이터 크롤링	데이터 크롤링	데이터 크롤링
데이터 전처리	데이터 전처리	데이터 전처리
긍부정 분석 모델링	긍부정 분석 모델링	긍부정 분석 모델링
PPT 제작	과정 총괄	발표

Outline

1-2 데이터 개요

TEAM | 미래전략실

분석 목표

애플, 샤오미, 삼성 전자기기 제품군을 키워드로
SNS채널과 네이버 쇼핑 리뷰에서 수집,
긍부정어 분석을 통해 마케팅 방안 도출

데이터 수집 기간 / 채널

기간 : 2020.01.17 ~ 2021.08.15
채널 : 네이버 카페 (애플, 삼성, 샤오미 사용자 카페),
인스타그램, 유투브(댓글), 네이버쇼핑 리뷰 (총 85,799건)

분석대상

- 3사 대표 전자기기 제품군 분석
- 네이버 카페 사용자 후기
- 네이버 쇼핑 리뷰 긍부정어 분석
- 인스타, 유투브 크롤링 데이터

주요 키워드 / 수집 방법

키워드 : 삼성 : 갤럭시, 버즈라이브, 버즈플러스, 갤탭, 갤럭시북, 갤럭시기어
샤오미 : 미밴드, 홍미노트, 샤오미워치, 어메이즈핏, 샤오미폰, 샤오미휴대폰
애플 : 맥북, M1, 아이폰, 에어팟, 애플워치, 아이패드
방법 : Beautiful Soup과 Selenium을 사용해
각 채널 별 Crawler 제작

Outline

1-3 주제선정이유

하락하는 삼성, 추격하는 애플과 샤오미

애플이 또 애플했다…'아이폰12 효과'에 2분기 역대 최대 매출

[중앙일보]입력 2021.07.28 09:49

IT > ICT

애플·삼성 위협하는 샤오미, 스마트폰 이어 3년 만에 '가성비 태블릿'도 출시

36만원짜리 미패드5 출시

印 스마트폰 시장서 中에 밀린 삼성…애플에도 점유율 뺏겨

장유미 기자 입력 2021.08.04 15:43

2Q 시장점유율 2위 유지에도 1위 샤오미와 격차 10.7%로 더 벌어져

10년간 스마트폰 분야 최대 점유율을 차지하던 삼성은
애플과 샤오미의 증가세에 1위를 위협받고 있다.

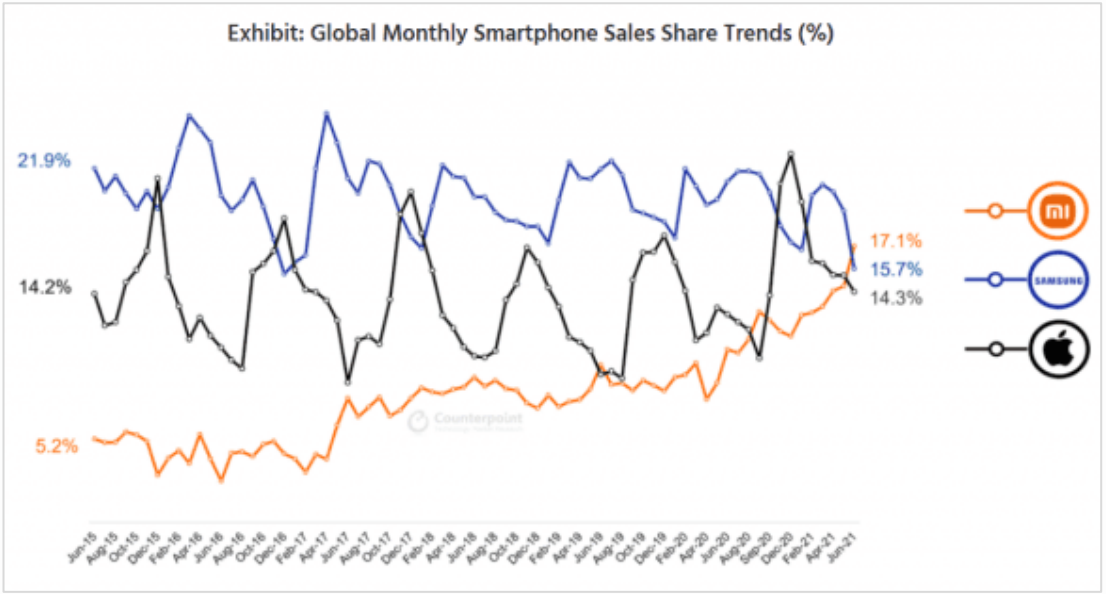

2016년 점유율 21.9%를 차지했던 삼성은
2021년 8.2%가 하락한 15.7%로 하락했다.

Outline

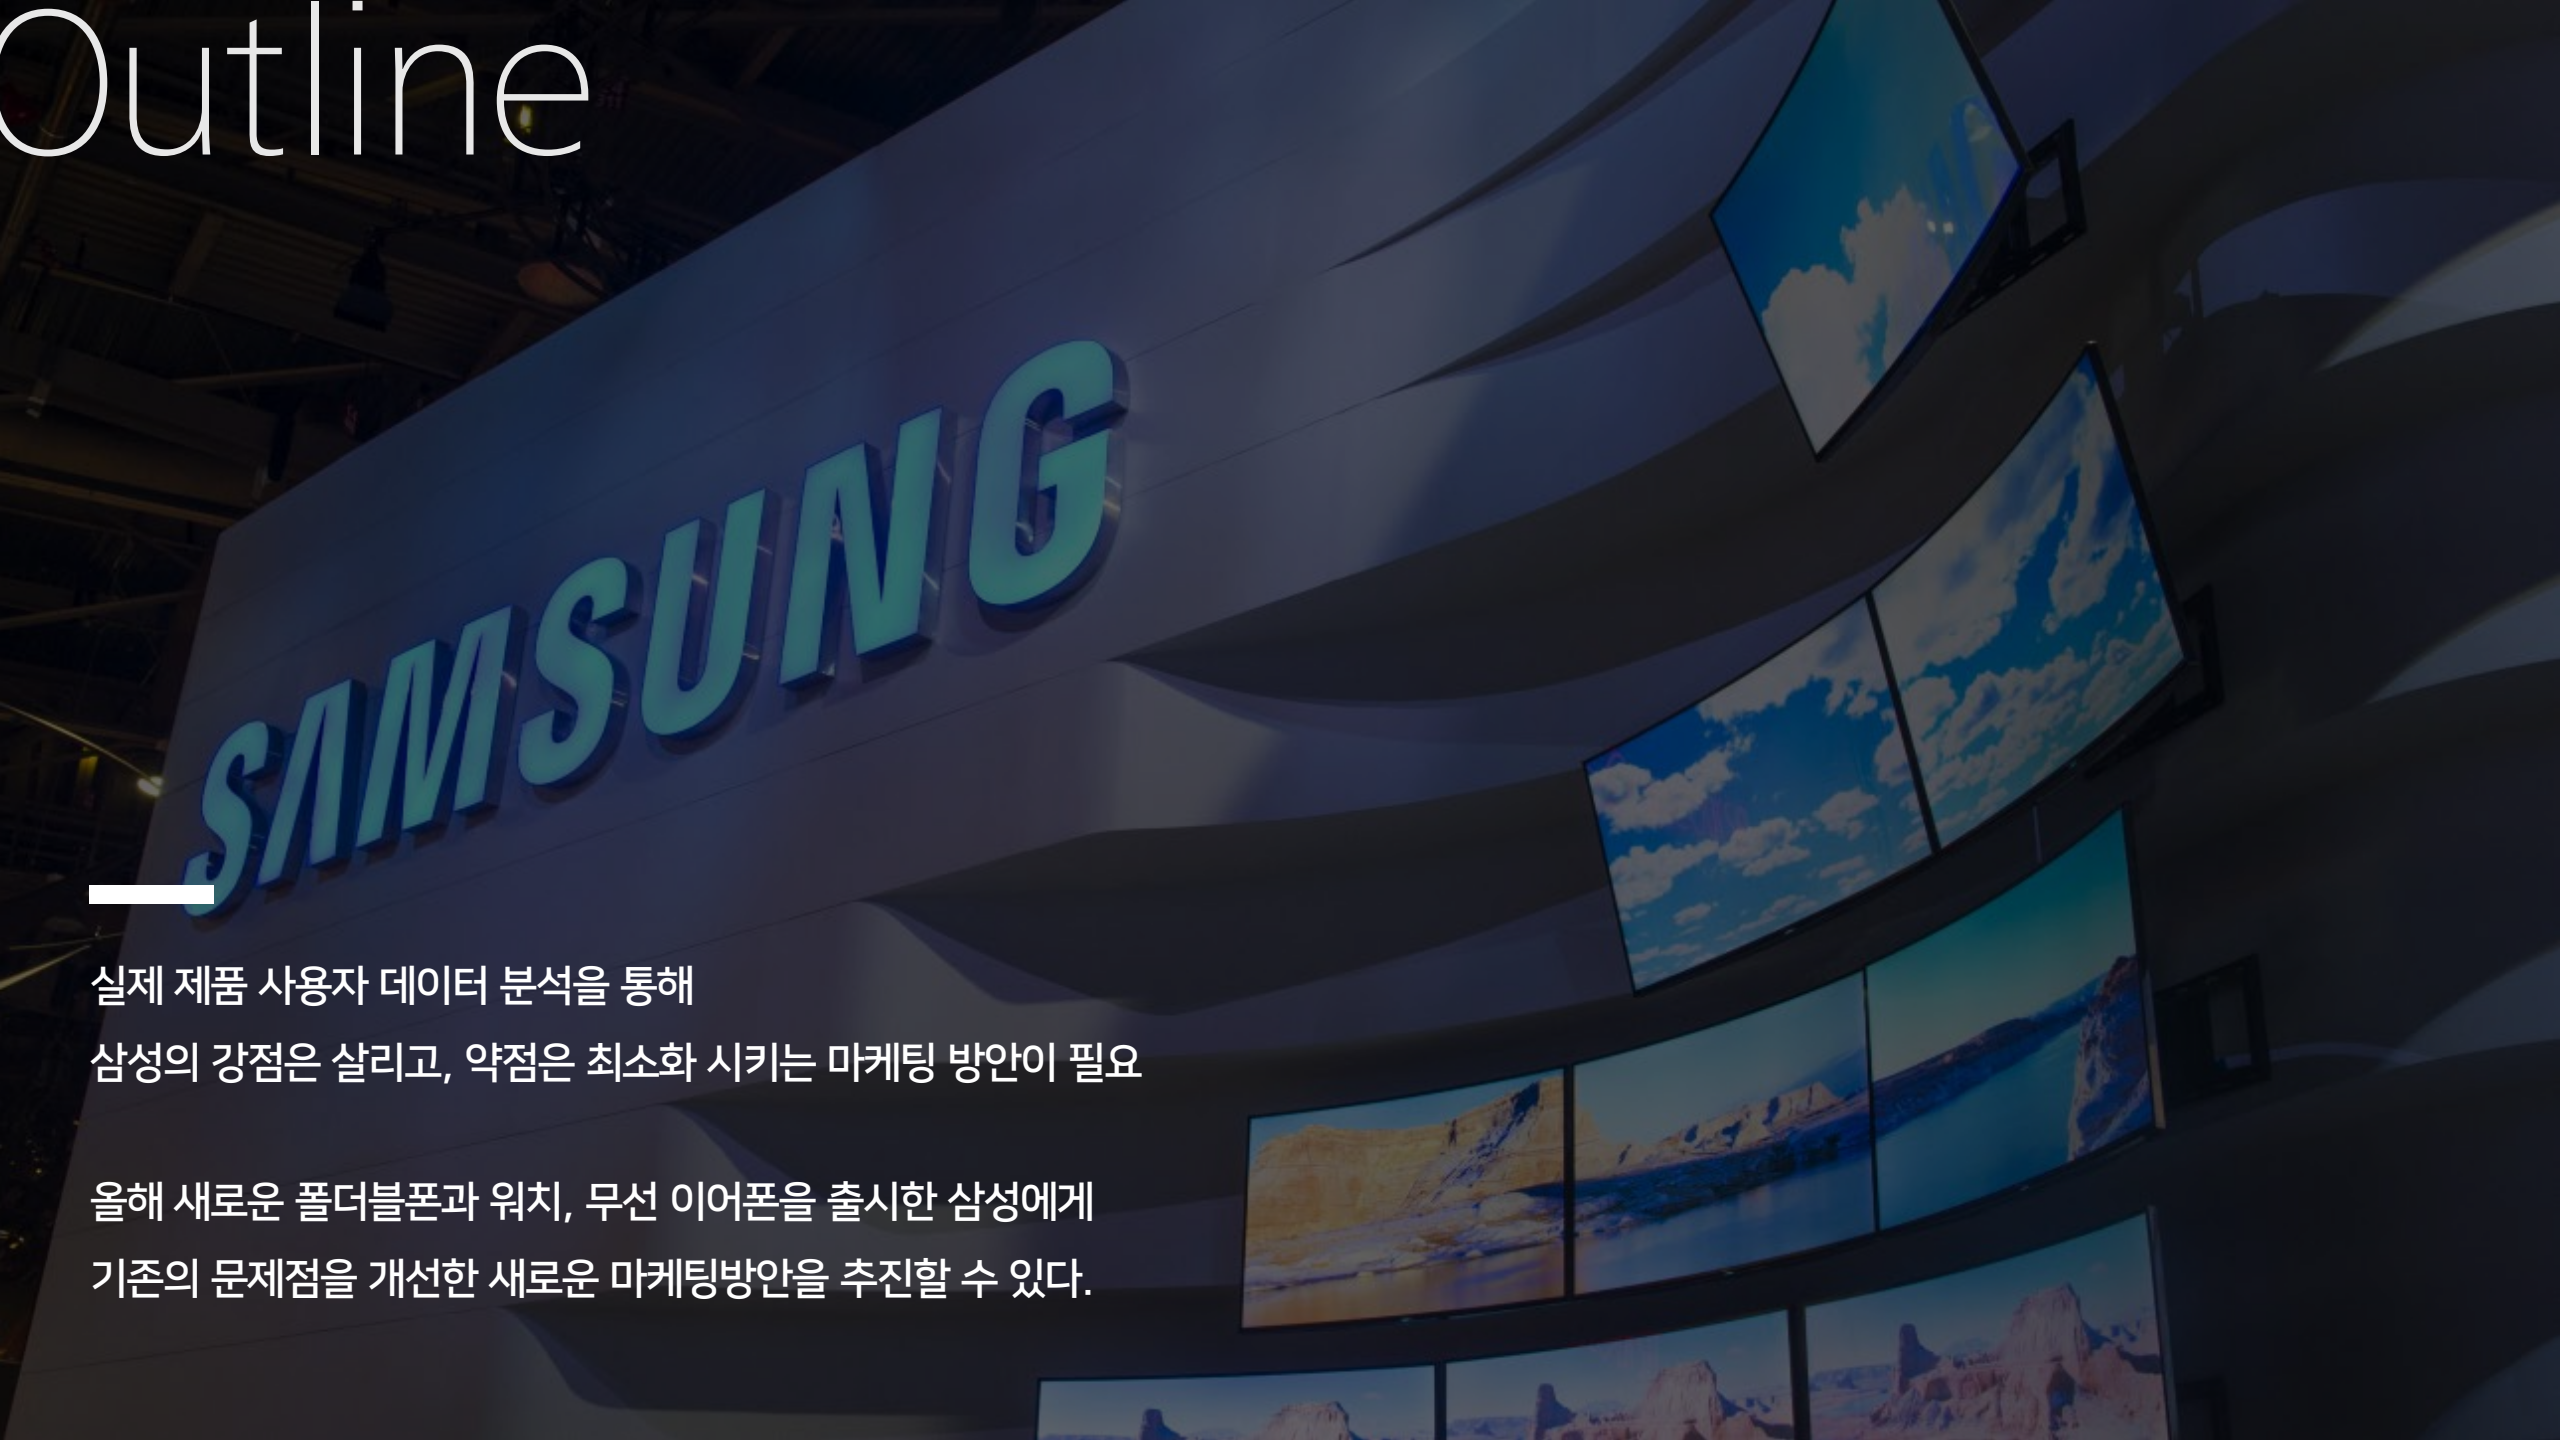

실제 제품 사용자 데이터 분석을 통해
삼성의 강점은 살리고, 약점은 최소화 시키는 마케팅 방안이 필요

올해 새로운 폴더블폰과 워치, 무선 이어폰을 출시한 삼성에게
기존의 문제점을 개선한 새로운 마케팅방안을 추진할 수 있다.

02

ANALYSIS

프로젝트 전체 로드맵

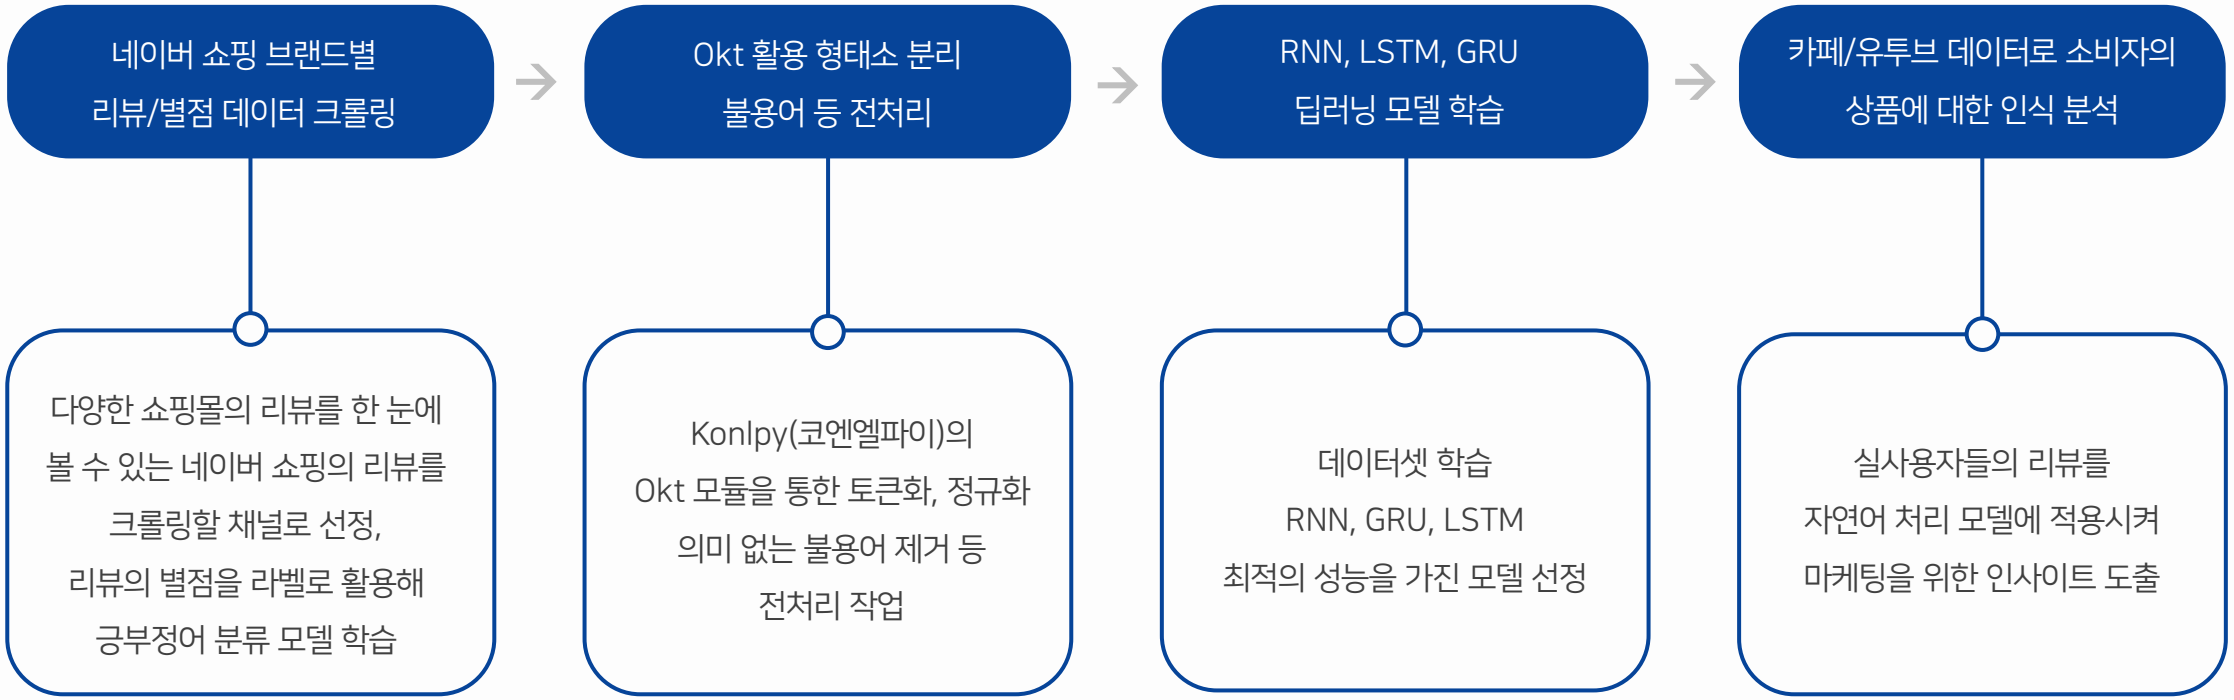
네이버 쇼핑 브랜드별
리뷰/별점 데이터 크롤링
Okt 활용 형태소 분리
불용어 등 전처리
RNN, LSTM, GRU
딥러닝 모델 학습
카페/유투브 데이터로 소비자의
상품에 대한 인식 분석
다양한 쇼핑몰의 리뷰를 한 눈에
볼 수 있는 네이버 쇼핑의 리뷰를
크롤링할 채널로 선정,
리뷰의 별점을 라벨로 활용해
긍부정어 분류 모델 학습
Konlpy(코엔엘파이)의
Okt 모듈을 통한 토큰화, 정규화
의미 없는 불용어 제거 등
전처리 작업
데이터셋 학습
RNN, GRU, LSTM
최적의 성능을 가진 모델 선정
실사용자들의 리뷰를
자연어 처리 모델에 적용시켜
마케팅을 위한 인사이트 도출

Analysis

2-2 데이터 수집

	review	keyword	star
2003	와 레드색이 너무 예뻐요무난한 색상이랑 고민 많이했는데정말 탁월한 선택이였어요진짜...	삼성전자 갤럭시 버즈 라이브	5
2004	갤럭서 버즈의 첫 기능이 있는 제품을 기다렸는데 타사 적용 블루투스 이어폰보다 ...	삼성전자 갤럭시 버즈 라이브	5
2005	발송은 빨랐는데 연초라 택배 물량이 많아서 그런지 배송은 일정도 걸린것 같아요 판매...	삼성전자 갤럭시 버즈 라이브	5
2006	블랙 색상이다 보니 모든 구성품 검은색으로 깔맞춤 되어있어 더 보기가 좋네요 구입 ...	삼성전자 갤럭시 버즈 라이브	5
2007	무선 이어폰을 처음 사용해봤습니다 유선만 이용해서 무선은 음질이 떨어지지 않을까 걱...	삼성전자 갤럭시 버즈 라이브	5
...	...	...	...
3141	아직 오픈형 하려면 양쪽 안정성좀	삼성전자 갤럭시 버즈 라이브	1
3142	음질은 좋은데 노캔기능이 없다시피 하네요불량같다 느낄정도로그리고 귀에 잘 안맞아요 ...	삼성전자 갤럭시 버즈 라이브	1
3143	인식불가한 고장품이 와서 서비스센터에서 분이나 시간 허비하고 부분교품 받았어요 삼성...	삼성전자 갤럭시 버즈 라이브	1
3144	ㅇㅇ	삼성전자 갤럭시 버즈 라이브	1
3145	택배사가 너무 마음에 안들어요ㅠ—ㅠ 더러운 택배사 선택은 안되나ㅠㅠ	삼성전자 갤럭시 버즈 라이브	1

네이버 쇼핑

삼성 : 13437
애플 : 4586
샤오미 : 6984

총 25007개

★☆☆☆☆
★★☆☆☆
★★★☆☆
→ 0 (부정) 라벨링

★★★★☆
★★★★★
→ 1 (긍정) 라벨링

전처리

1 중복 / 결측치 제거

2 정규표현식을 사용해 한글을 제외한 문자열 제거

3 특정 문자열(광고성 키워드)이 포함된 행 제거

Analysis

2-2 데이터 수집

아이패드

	0	1	2
0	인치 가지고 왔습니다	칩을 품은 아이패드 프로 하나 가지고왔습니다 게임용이 주목적으로 구입했고 휴대성도 ...	2021.08.11. 21:02
1	미니	NaN	2021.08.11. 14:14
2	애플펜슬 교환받고 왔는데요ㅠ	아이패드 프로 세대 인치 사용한지는 년 넘었어요굿노트에서 자꾸 필기 오류가 생겨서 ...	2021.08.11. 13:36
3	패드로 책 읽으시는 분 계신가요	출퇴근할 때 전철에서 아이패드로 전자책 읽는데눈이 좀 아픈 것 같아요 ㅜㅜㅜㅜ아이패...	2021.08.11. 09:26
4	아이패드펜촉 팁 글씨필기감	도움말라이센스 동영상 인코딩 중입니다분 이상 소요될 수 있으며 ...	2021.08.11. 01:36

미밴드

	context
829	주말에 직구한 새 휴대폰이 빛의 속도로 도착년간 잘 쓰던 샤오미 홍미노트가 이제 버...
830	블랙박스공기청정기 보조배터리샤오미휴대폰 진열제품구경공짜판플렛공짜남양주진접아이나비공식...
831	샤오미 미맥스 직구가격대비 가성비 좋네 ㅋㅋ휴대폰 가성비갑 샤오미미맥스 샤오미 데일...
832	샤오미휴대폰 카메라 나이성별이 인식댄다 ㅋ신기방기ㅋ 베이징 여행 좋은사람과 샤오미...
833	듀얼 샤오미샤오미 샤오미휴대폰 샤오미 휴대폰 핸드폰 이거한국에서 사용가능 굿굿 ...

버즈라이브

	review	keyword
0	끝없는 맥북 논란과 이슈이번에는 화면만 열어도 깨지는디스플레이가 도마 위에 올랐습니다	M1
1	맥북 프로 인치가 저렇게 된 적 있는데 이건 만의 문제가 아니라 맥북 의 문제인 것...	M1
2	개인적으로 애플은 내구성에 대해 조금더 발전된 모습이 필요해 보이는거 같음 아무리 ...	M1
3	고압적인 정책 강제적인 업그레이드 정책 제한된 자유도 이 가지때문에 전 애플로 못...	M1
4	이 영상을 맥북으로 보는 심정이 참 ㅜㅜ	M1

네이버 카페

삼성 : 1881
애플 : 2252
샤오미 : 601

총 4734개

Youtube

삼성 : 20111
애플 : 20117
샤오미 : 11050

총 51278개

인스타그램

삼성 : 1243
애플 : 2704
샤오미 : 833

총 4780개

전처리

1 중복 / 결측치 제거
2 정규표현식을 사용해 한글을 제외한 문자열 제거
3 특정 문자열(광고성 키워드)이 포함된 행 제거

자연어처리 Model 에 적용, 평가

1 자연어 처리

: 말뭉치를 모아 정제 - 토큰화 – 정규화를 거쳐야 한다.

표현 방법이 다른 단어들을 통합시켜서 같은 단어로 만들어준다.

말뭉치에서 더 이상 나눌 수 없는 단위로 나누는 작업

2 감성분류

: 텍스트에 들어있는 의견이나 감성, 평가, 태도 등의 주관적인 정보를 컴퓨터를 통해 분석

Analysis

2-3 자연어 처리

레이블분포

긍정/부정을 나누기 위해 네이버 평점 1~3점을 0으로, 이외는 1점으로 할당

토큰화

불용어 (stopwords) 를 지정, 제거하고 Okt를 이용해 토큰화 실행

훈련용 데이터의 라벨 수

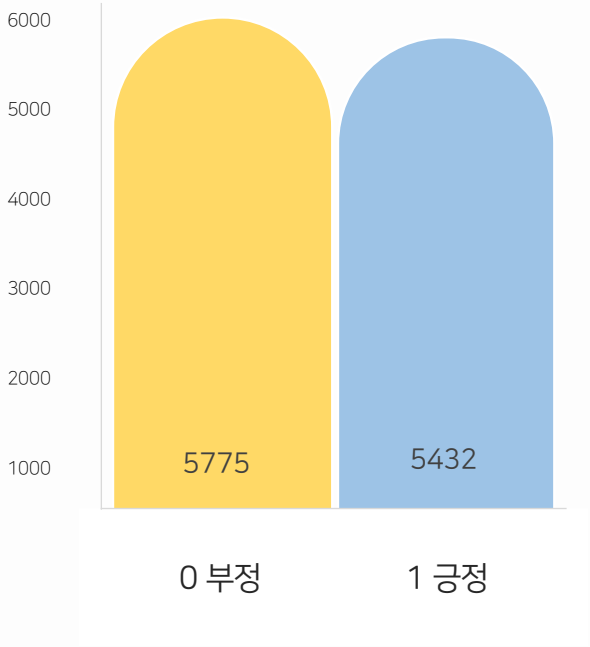


```
stopwords = ['가','게','고','과','네','는','다','도','들','듯','를','에','와','으로',
             '은','을','의','이','인','임','자','잘','좀','지','하다','한']
```

```
X_test = []
for sentence in test_data['review']:
    temp_X = okt.morphs(sentence, stem=True) # 토큰화
    temp_X = [word for word in temp_X if not word in stopwords] # 불용어 제거
    X_test.append(temp_X)
print(X_test[:3])
```

```
[…, ['좋다', '빨르다', '가볍다', '예쁘다'],
['아이', '착용', '가볍다', '좋다'],
['배송', '빠르다', '좋다', '상품', '받다', '매우', '만족하다', '색도', '너무', '이쁘다', '케이스',
'마음', '들다', '다만', '개인', '적', '필름', '붙이다','조금', '힘들다', '저', '실패하다', '전적',
'있다', '따로', '돈', '주다', '붙이다'], …]
```

Analysis

2-3 자연어 처리

정수 인코딩

텍스트를 숫자로 처리하도록 훈련 데이터와 테스트 데이터에 정수 인코딩을 수행

```
tokenizer = Tokenizer()
tokenizer.fit_on_texts(X_train)
```

```
print(tokenizer.word_index)
```

```
{'좋다': 1, '배송': 2, '받다': 3, '있다': 4, '자다': 5, '제품': 6, '보다': 7, '빠르다': 8, '사용': 9,
'너무': 10, '되다': 11, '구매': 12, '로': 13, '같다': 14, '오다': 15, '없다': 16, '이다': 17,
'안': 18, '쓰다': 19, '요': 20, '에서': 21, '않다': 22, '사다': 23, '가격': 24, '하고': 25,
'만족하다': 26, '것': 27, '주문': 28, '때': 29, '만': 30, …}
```

패딩

하나의 행렬로 만들기 위해 서로 다른 길이의 샘플들의 길이를 동일하게 만듦

```
print('리뷰의 최대 길이 :',max(len(l) for l in X_train))
print('리뷰의 평균 길이 :',sum(map(len, X_train))/len(X_train))
plt.hist([len(s) for s in X_train], bins=50)
plt.xlabel('length of samples')
plt.ylabel('number of samples')
plt.show()
```

```
리뷰의 최대 길이 : 1141
리뷰의 평균 길이 : 33.27797026936403
```

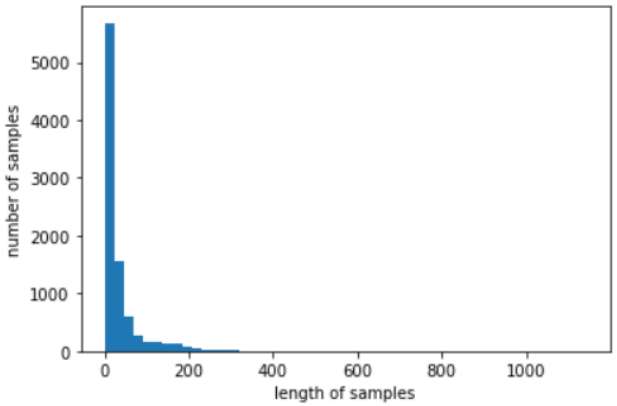


```
max_len = 100
below_threshold_len(max_len, X_train)
```

```
전체 샘플 중 길이가 100 이하인 샘플의 비율: 91.17022465630937
```

Analysis

2-3 자연어 처리

정수 인코딩

텍스트를 숫자로 처리하도록 훈련 데이터와 테스트 데이터에 정수 인코딩을 수행

```
threshold = 3
total_cnt = len(tokenizer.word_index) # 단어의 수
rare_cnt = 0 # 등장 빈도수가 threshold보다 작은 단어의 개수를 카운트
total_freq = 0 # 훈련 데이터의 전체 단어 빈도수 총 합
rare_freq = 0 # 등장 빈도수가 threshold보다 작은 단어의 등장 빈도수의 총 합

# 단어와 빈도수의 쌍(pair)을 key와 value로 받는다.
for key, value in tokenizer.word_counts.items():
    total_freq = total_freq + value

    # 단어의 등장 빈도수가 threshold보다 작으면
    if(value < threshold):
        rare_cnt = rare_cnt + 1
        rare_freq = rare_freq + value
```

```
# 전체 단어 개수 중 빈도수 2 이하인 단어는 제거
# 0번 패딩 토큰을 고려하여 +1
vocab_size = total_cnt - rare_cnt + 1
print("단어 집합의 크기 : ", vocab_size)
```

```
단어 집합의 크기 :  5092
```

패딩

하나의 행렬로 만들기 위해 서로 다른 길이의 샘플들의 길이를 동일하게 만듦

```
print('리뷰의 최대 길이 :',max(len(l) for l in X_train))
print('리뷰의 평균 길이 :',sum(map(len, X_train))/len(X_train))
plt.hist([len(s) for s in X_train], bins=50)
plt.xlabel('length of samples')
plt.ylabel('number of samples')
plt.show()
```

```
리뷰의 최대 길이 : 1141
리뷰의 평균 길이 : 33.27797026936403
```

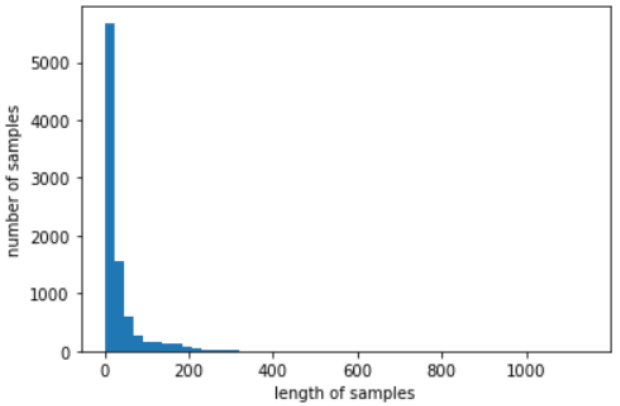


```
max_len = 100
below_threshold_len(max_len, X_train)
```

```
전체 샘플 중 길이가 100 이하인 샘플의 비율: 91.17022465630937
```

03

PREDICT

Predict

3-1 예측모델 선정

RNN

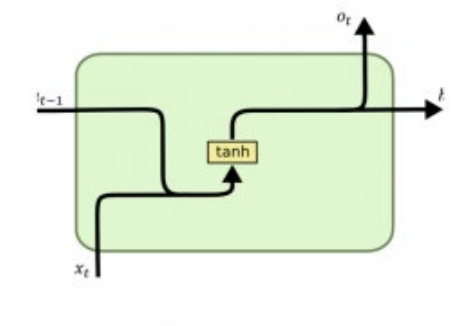

순서가 있는 데이터를
처리하기 위한 인공 신경망

LSTM

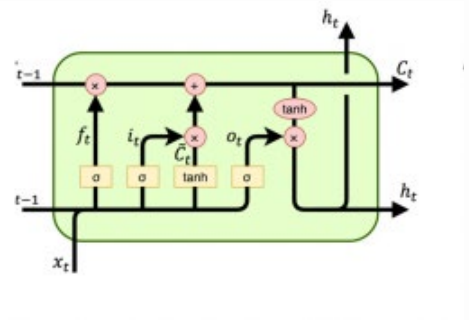

RNN의 Vanishing gradient
problem을 완화한 방법

GRU

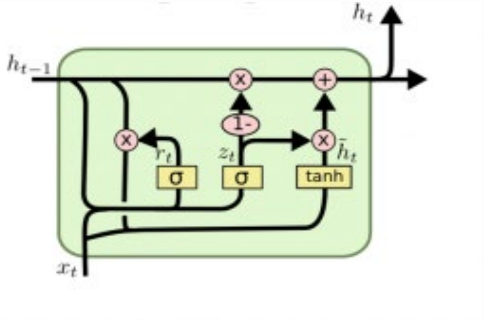

LSTM에 비해서 단순한 구조이면서도
긴 데이터를 잘 처리하는 방법

Predict

3-2 RNN

```
def vanilla_rnn():
    model = Sequential()
    model.add(SimpleRNN(units=50, input_shape=(100, 1), return_sequences=False))
    model.add(Dense(1, activation='sigmoid'))

    es = EarlyStopping(monitor='val_loss', mode='min', verbose=1, patience=4)
    mc = ModelCheckpoint('GRU_model.h5', monitor='val_acc', mode='max', verbose=1, save

    model.compile(optimizer='rmsprop', loss='binary_crossentropy', metrics=['acc'])

    return model
```

```
model_rnn = KerasClassifier(build_fn=vanilla_rnn, epochs=20, batch_size=50, verbose=1)
model_rnn.fit(X_train_rnn, y_train, epochs=15, callbacks=[es, mc], batch_size=60, valid
```

```
Epoch 00004: val_acc did not improve from 0.76693
Epoch 5/15
6020/6020 [==============================] - 3s 529us/step - loss: 0.6818 - acc: 0.560
1 - val_loss: 0.6819 - val_acc: 0.5664
```

Patience : 검증 데이터 손실이 4회 증가하면 학습을 조기종료

Epoch : 20번 수행

batch_size : 각 데이터의 사이즈 50

Validation_split : 훈련데이터 중 20프로를 검증데이터로 사용

정확도 약 82%, loss 약 38%인 **4번째 모델** 확정

```
from sklearn.metrics import confusion_matrix
y_pred = model_rnn.predict(X_test_rnn)
print(confusion_matrix(y_test, y_pred))

from sklearn.metrics import classification_report
print(classification_report(y_test, y_pred))
```

```
3202/3202 [==============================] - 5s 2ms/step
[[ 308 1331]
 [ 203 1360]]
              precision    recall  f1-score   support

           0       0.60      0.19      0.29      1639
           1       0.51      0.87      0.64      1563

    accuracy                           0.52      3202
   macro avg       0.55      0.53      0.46      3202
weighted avg       0.56      0.52      0.46      3202
```

Train 정확도 56% | Test 정확도 52%

F1-score (label 0) 29%

RNN은 부정 리뷰 학습에서 성능 미달

Predict

3-3 GRU

```
model_GRU = Sequential()
model_GRU.add(Embedding(vocab_size, 100))
model_GRU.add(GRU(128))
model_GRU.add(Dense(1, activation='sigmoid'))

es = EarlyStopping(monitor='val_loss', mode='min', verbose=1, patience=4)
mc = ModelCheckpoint('GRU_model.h5', monitor='val_acc', mode='max', verbose=1, save_bes

model_GRU.compile(optimizer='rmsprop', loss='binary_crossentropy', metrics=['acc'])
history_GRU = model_GRU.fit(X_train, y_train, epochs=15, callbacks=[es, mc], batch_size
```

```
Epoch 1/15
6020/6020 [==============================] - 85s 14ms/step - loss: 0.5650 - acc: 0.712
1 - val_loss: 0.4860 - val_acc: 0.7669

Epoch 00001: val_acc improved from -inf to 0.76693, saving model to GRU_model.h5
```

Patience : 검증 데이터 손실이 4회 증가하면 학습을 조기종료

Epoch : 15번 수행

batch_size : 각 데이터의 사이즈 60

Validation_split : 훈련데이터 중 20프로를 검증데이터로 사용

정확도 약 71%, loss 약 56%인 **1번째 모델** 확정

```
from sklearn.metrics import confusion_matrix
y_pred = model_GRU.predict(X_test)
y_pred_ = []

for i in range(len(y_pred)):
    if y_pred[i][0] > 0.5:
        y_pred_.append(1)
    else:
        y_pred_.append(0)
y_pred_

print(confusion_matrix(y_test, y_pred_))

from sklearn.metrics import classification_report
print(classification_report(y_test, y_pred_))
```

```
[[1069  570]
 [ 283 1280]]
              precision    recall  f1-score   support

           0       0.79      0.65      0.71      1639
           1       0.69      0.82      0.75      1563

    accuracy                           0.73      3202
   macro avg       0.74      0.74      0.73      3202
weighted avg       0.74      0.73      0.73      3202
```

Train 정확도 71% | Test 정확도 73%

F1-score 71%

RNN모델에 비해 label 0을 더 잘 분류

Predict

3-4 LSTM

```
model_lstm = Sequential()
model_lstm.add(Embedding(vocab_size, 100))
model_lstm.add(LSTM(128))
model_lstm.add(Dense(1, activation='sigmoid'))

es = EarlyStopping(monitor='val_loss', mode='min', verbose=1, patience=4)
mc = ModelCheckpoint('best_model.h5', monitor='val_acc', mode='max', verbose=1, save_be

model_lstm.compile(optimizer='rmsprop', loss='binary_crossentropy', metrics=['acc'])
history_lstm = model_lstm.fit(X_train, y_train, epochs=15, callbacks=[es, mc], batch_si
```

```
Epoch 4/15
6020/6020 [==============================] - 60s 10ms/step - loss: 0.3896 - acc: 0.823
3 - val_loss: 0.4824 - val_acc: 0.7769

Epoch 00004: val_acc improved from 0.76560 to 0.77689, saving model to best_model.h5
```

Patience : 검증 데이터 손실이 4회 증가하면 학습을 조기종료

Epoch : 15번 수행

batch_size : 각 데이터의 사이즈 60

Validation_split : 훈련데이터 중 20프로를 검증데이터로 사용

정확도 약 82%, loss 약 38%인 **4번째 모델** 확정

```
from sklearn.metrics import confusion_matrix
y_pred = model_lstm.predict(X_test)
y_pred_ = []

for i in range(len(y_pred)):
    if y_pred[i][0] > 0.5:
        y_pred_.append(1)
    else:
        y_pred_.append(0)
y_pred_

print(confusion_matrix(y_test, y_pred_))

from sklearn.metrics import classification_report
print(classification_report(y_test, y_pred_))
```

```
[[1171  468]
 [ 367 1196]]
              precision    recall  f1-score   support

           0       0.76      0.71      0.74      1639
           1       0.72      0.77      0.74      1563

    accuracy                           0.74      3202
   macro avg       0.74      0.74      0.74      3202
weighted avg       0.74      0.74      0.74      3202
```

Train 정확도 82% | Test 정확도 74%

F1-score 74%

RNN / GRU 모델에 비해 높은 예측률 >>> 모델 선정

3-5 네이버 카페 분석

```
plt.figure(figsize=(12, 10))
ratio = [len(df_apple), len(df_samsung), len(df_xiaomi) ]
labels = ["apple","samsung","xiaomi"]



plt.pie(ratio, labels=labels, autopct='%.1f%%', startangle=260, counterclock=False)
plt.show()
print('전처리 후 테스트용 샘플의 개수 :',len(df_apple)+len(df_samsung)+len(df_xiaomi))
```

전처리 후 테스트용 샘플의 개수 : 4272

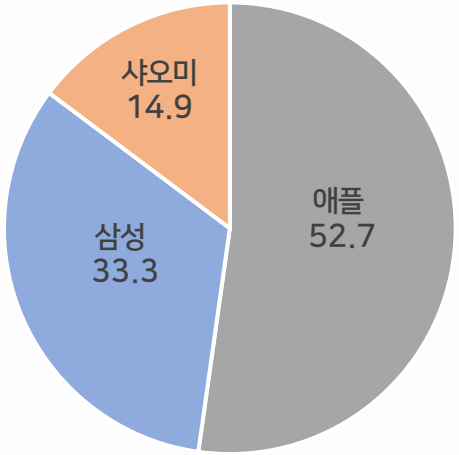

단위(%)

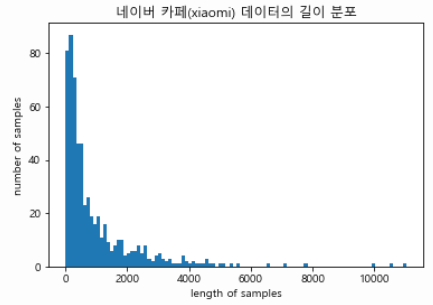

리뷰의 최대 길이 : 23341
리뷰의 평균 길이 : 335.18

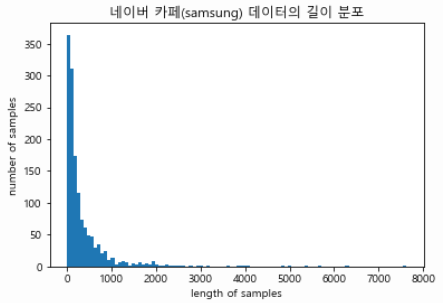

리뷰의 최대 길이 : 7624
리뷰의 평균 길이 : 367.8029556650246

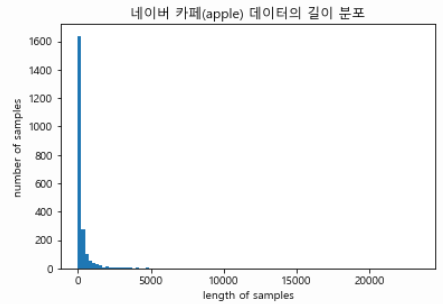

리뷰의 최대 길이 : 11025
리뷰의 평균 길이 : 984.2993311036789

Predict

3-5 네이버 카페 분석

```
label = []
score_list = []
for review in df_apple["review"]:
    new_sentence = okt.morphs(review) # 토큰화
    new_sentence = [word for word in new_sentence if not word in stopwords] # 불용어 제거
    encoded = tokenizer.texts_to_sequences([new_sentence]) # 정수 인코딩
    pad_new = pad_sequences(encoded, maxlen = 100)
    score = float(model_test.predict(pad_new))
    if(score > 0.5):
        label.append(1)
        score_list.append(score)
    else:
        label.append(0)
        score_list.append(score)

xiaomi_score = pd.DataFrame([label, score_list]).T
xiaomi_score.columns = ["label", "score"]
print(xiaomi_score[xiaomi_score["label"]==0].mean())
print(xiaomi_score[xiaomi_score["label"]==1].mean())
print(xiaomi_score.describe())
print('-----------------------------------------------------------------------------------')
```

```
label    0.000000
score    0.207032
dtype: float64
label    1.000000
score    0.863782
dtype: float64
             label        score
count  2250.000000  2250.000000
mean      0.658222     0.639320
std       0.474411     0.344702
min       0.000000     0.002578
25%       0.000000     0.318488
50%       1.000000     0.768040
75%       1.000000     0.961851
max       1.000000     0.999201
```

```
label    0.000000
score    0.207032
dtype: float64
label    1.000000
score    0.863782
dtype: float64
             label        score
count  2250.000000  2250.000000
mean      0.658222     0.639320
std       0.474411     0.344702
min       0.000000     0.002578
25%       0.000000     0.318488
50%       1.000000     0.768040
75%       1.000000     0.961851
max       1.000000     0.999201
```

```
label    0.000000
score    0.206288
dtype: float64
label    1.000000
score    0.874746
dtype: float64
             label        score
count  1421.000000  1421.000000
mean      0.695285     0.671057
std       0.460449     0.338299
min       0.000000     0.002628
25%       0.000000     0.372983
50%       1.000000     0.823559
75%       1.000000     0.966880
max       1.000000     0.998767
```

```
label    0.000000
score    0.198157
dtype: float64
label    1.000000
score    0.901951
dtype: float64
             label        score
count  598.000000  598.000000
mean     0.789298    0.753660
std      0.408149    0.313595
min      0.000000    0.002463
25%      1.000000    0.605136
50%      1.000000    0.918632
75%      1.000000    0.974123
max      1.000000    0.998602
```

부정 (score < 0.5) | 긍정 (score > 0.5)

	애플	삼성	샤오미
긍부정 비율	긍정 65 : 35 부정	긍정 70 : 30 부정	**긍정 78 : 22 부정**
Score 평균	긍정 0.86 : 0.2 부정	긍정 0.87 : 0.2 부정	**긍정 0.9 : 0.19 부정**

샤오미 > 삼성 > 애플

3-6 유투브 댓글 분석

```
plt.figure(figsize=(12, 10))
ratio = []
labels = []
for word in df["company"].unique():
    ratio.append(len(df[df["company"]==word]))
    labels.append(word)
plt.pie(ratio, labels=labels, autopct='%.1f%%', startangle=260, counterclock=False)
plt.show()
print('전처리 후 테스트용 샘플의 개수 :',sum(ratio))
```

전처리 후 테스트용 샘플의 개수 : 51278

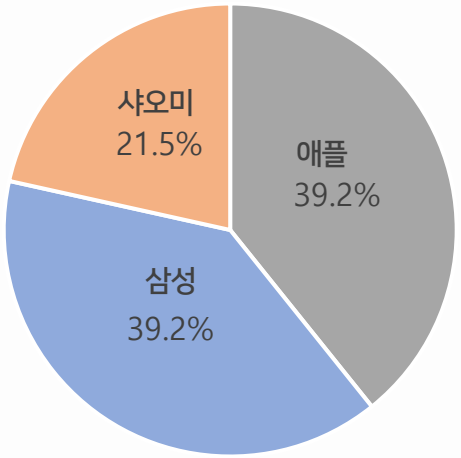

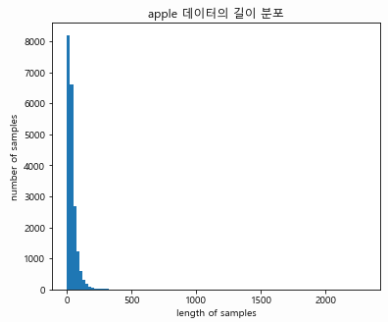

리뷰의 최대 길이 : 2305
리뷰의 평균 길이 : 41.45414326191778

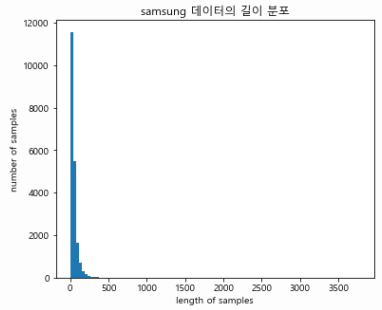

리뷰의 최대 길이 : 3778
리뷰의 평균 길이 : 47.91939734473671

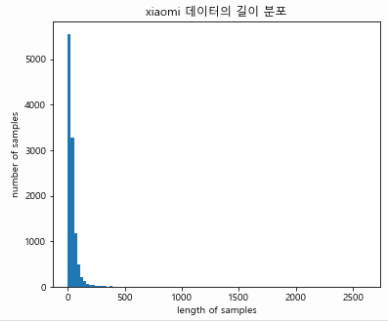

리뷰의 최대 길이 : 2609
리뷰의 평균 길이 : 39.46850678733032

Predict

3-6 유투브 댓글 분석

```
from keras.models import load_model
model_test = load_model('model_lstm.h5')
```

```
def sentiment_predict(new_sentence):
    new_sentence = okt.morphs(new_sentence) # 토큰화
    new_sentence = [word for word in new_sentence if not word in stopwords] # 불용어 제거
    encoded = tokenizer.texts_to_sequences([new_sentence]) # 정수 인코딩
    pad_new = pad_sequences(encoded, maxlen = 100) # 패딩
    score = float(model_test.predict(pad_new)) # 예측
    if(score > 0.5):
        print("{:.2f}% 확률로 긍정 리뷰입니다.".format(score * 100))
    else:
        print("{:.2f}% 확률로 부정 리뷰입니다.".format((1 - score) * 100))
```

```
df["review"][0]
```

'끝없는 맥북 논란과 이슈이번에는 화면만 열어도 깨지는디스플레이가 도마 위에 올랐습니다'

```
sentiment_predict(df["review"][0])
```

53.79% 확률로 부정 리뷰입니다.

```
label = []
score_list = []
for review in df[df["company"]=="apple"]["review"]:
    new_sentence = okt.morphs(review) # 토큰화
    new_sentence = [word for word in new_sentence if not word in stopwords] # 불용어 제거
    encoded = tokenizer.texts_to_sequences([new_sentence]) # 정수 인코딩
    pad_new = pad_sequences(encoded, maxlen = 100)
    score = float(model_test.predict(pad_new))
    if(score > 0.5):
        label.append(1)
        score_list.append(score)
    else:
        label.append(0)
        score_list.append(score)

apple_score = pd.DataFrame([label, score_list]).T
apple_score.columns = ["label", "score"]
```

apple_score.describe()

	label	score
count	20117.000000	20117.000000
mean	0.421683	0.464113
std	0.493841	0.304285
min	0.000000	0.000294
25%	0.000000	0.204277
50%	0.000000	0.411476
75%	1.000000	0.736177
max	1.000000	0.999599

samsung_score.describe()

	label	score
count	20111.000000	20111.000000
mean	0.394461	0.441921
std	0.488747	0.306040
min	0.000000	0.001033
25%	0.000000	0.172755
50%	0.000000	0.382359
75%	1.000000	0.708176
max	1.000000	0.999583

xiaomi_score.describe()

	label	score
count	11050.000000	11050.000000
mean	0.365520	0.417977
std	0.481598	0.286300
min	0.000000	0.000631
25%	0.000000	0.171708
50%	0.000000	0.361418
75%	1.000000	0.644604
max	1.000000	0.998846

부정 (score < 0.5) | 긍정 (score > 0.5)

	애플	삼성	샤오미
긍부정 비율	긍정 42 : 58 부정	긍정 39 : 61 부정	긍정 36 : 64 부정

애플 > 삼성 > 샤오미

3-6 유투브 댓글 분석

제품군 별 분석 결과 | 애플 > 삼성 > 샤오미

M1 apple

	label	score
label	0.000000	
score	0.239886	
dtype: float64		
label	1.000000	
score	0.756351	
dtype: float64		
count	2664.000000	2664.000000
mean	0.394895	0.443835
std	0.488920	0.290931
min	0.000000	0.000294
25%	0.000000	0.200231
50%	0.000000	0.388998
75%	1.000000	0.680971
max	1.000000	0.997786

맥북 apple

	label	score
label	0.000000	
score	0.242141	
dtype: float64		
label	1.000000	
score	0.792609	
dtype: float64		
count	2451.000000	2451.000000
mean	0.498164	0.516365
std	0.500099	0.311318
min	0.000000	0.006728
25%	0.000000	0.240062
50%	0.000000	0.496348
75%	1.000000	0.817271
max	1.000000	0.998983

에어팟 apple

	label	score
label	0.000000	
score	0.219999	
dtype: float64		
label	1.000000	
score	0.736549	
dtype: float64		
count	3775.000000	3775.000000
mean	0.305960	0.378043
std	0.460874	0.277886
min	0.000000	0.001840
25%	0.000000	0.140239
50%	0.000000	0.308940
75%	1.000000	0.571305
max	1.000000	0.998588

아이패드 apple

	label	score
label	0.000000	
score	0.245622	
dtype: float64		
label	1.00000	
score	0.82697	
dtype: float64		
count	3563.000000	3563.000000
mean	0.591075	0.589242
std	0.491704	0.320734
min	0.000000	0.002047
25%	0.000000	0.307106
50%	1.000000	0.626519
75%	1.000000	0.904676
max	1.000000	0.999599

아이폰 apple

	label	score
label	0.000000	
score	0.238112	
dtype: float64		
label	1.000000	
score	0.752589	
dtype: float64		
count	3976.000000	3976.000000
mean	0.375503	0.431300
std	0.484313	0.288270
min	0.000000	0.001541
25%	0.000000	0.197092
50%	0.000000	0.372581
75%	1.000000	0.655108
max	1.000000	0.998580

애플워치 apple

	label	score
label	0.000000	
score	0.240979	
dtype: float64		
label	1.000000	
score	0.761864	
dtype: float64		
count	3688.000000	3688.000000
mean	0.394794	0.446621
std	0.488873	0.292089
min	0.000000	0.001258
25%	0.000000	0.198009
50%	0.000000	0.390847
75%	1.000000	0.692045
max	1.000000	0.998416

갤럭시기어 samsung

	label	score
label	0.000000	
score	0.223804	
dtype: float64		
label	1.000000	
score	0.760232	
dtype: float64		
count	1975.000000	1975.000000
mean	0.346329	0.409585
std	0.475920	0.292863
min	0.000000	0.003022
25%	0.000000	0.158054
50%	0.000000	0.341415
75%	1.000000	0.647948
max	1.000000	0.997394

갤럭시북 samsung

	label	score
label	0.000000	
score	0.231957	
dtype: float64		
label	1.000000	
score	0.785557	
dtype: float64		
count	3715.000000	3715.000000
mean	0.433109	0.471726
std	0.495572	0.310139
min	0.000000	0.002556
25%	0.000000	0.201500
50%	0.000000	0.416459
75%	1.000000	0.758837
max	1.000000	0.999408

갤럭시 samsung

	label	score
label	0.000000	
score	0.227785	
dtype: float64		
label	1.000000	
score	0.766739	
dtype: float64		
count	3284.000000	3284.000000
mean	0.399817	0.443268
std	0.489935	0.301254
min	0.000000	0.002040
25%	0.000000	0.179190
50%	0.000000	0.391075
75%	1.000000	0.707962
max	1.000000	0.998436

갤탭 samsung

	label	score
label	0.000000	
score	0.222832	
dtype: float64		
label	1.000000	
score	0.815007	
dtype: float64		
count	3837.000000	3837.000000
mean	0.518634	0.529954
std	0.499718	0.330402
min	0.000000	0.001864
25%	0.000000	0.222664
50%	1.000000	0.528763
75%	1.000000	0.862163
max	1.000000	0.999583

버즈라이브 samsung

	label	score
label	0.000000	
score	0.230694	
dtype: float64		
label	1.000000	
score	0.743343	
dtype: float64		
count	4143.000000	4143.000000
mean	0.336230	0.403062
std	0.472476	0.282337
min	0.000000	0.001033
25%	0.000000	0.163200
50%	0.000000	0.348822
75%	1.000000	0.606500
max	1.000000	0.997306

버즈플러스 samsung

	label	score
label	0.000000	
score	0.210754	
dtype: float64		
label	1.00000	
score	0.74223	
dtype: float64		
count	3157.000000	3157.000000
mean	0.299018	0.369675
std	0.457900	0.282711
min	0.000000	0.002066
25%	0.000000	0.124701
50%	0.000000	0.308741
75%	1.000000	0.572858
max	1.000000	0.998553

샤오미워치 xiaomi

	label	score
label	0.000000	
score	0.223597	
dtype: float64		
label	1.000000	
score	0.733945	
dtype: float64		
count	1499.000000	1499.000000
mean	0.346898	0.400635
std	0.476142	0.281695
min	0.000000	0.001102
25%	0.000000	0.162116
50%	0.000000	0.343649
75%	1.000000	0.622508
max	1.000000	0.993839

샤오미폰 xiaomi

	label	score
label	0.000000	
score	0.235623	
dtype: float64		
label	1.000000	
score	0.749864	
dtype: float64		
count	3592.000000	3592.000000
mean	0.394209	0.438342
std	0.488748	0.290123
min	0.000000	0.001124
25%	0.000000	0.185783
50%	0.000000	0.392989
75%	1.000000	0.677632
max	1.000000	0.996894

샤오미휴대폰 xiaomi

	label	score
label	0.000000	
score	0.243046	
dtype: float64		
label	1.00000	
score	0.75153	
dtype: float64		
count	1467.000000	1467.000000
mean	0.405590	0.449282
std	0.491173	0.288468
min	0.000000	0.002429
25%	0.000000	0.204926
50%	0.000000	0.407806
75%	1.000000	0.682368
max	1.000000	0.997976

어메이즈핏 xiaomi

	label	score
label	0.000000	
score	0.212903	
dtype: float64		
label	1.00000	
score	0.73134	
dtype: float64		
count	721.000000	721.000000
mean	0.317614	0.377566
std	0.465872	0.280211
min	0.000000	0.002888
25%	0.000000	0.139912
50%	0.000000	0.308741
75%	1.000000	0.581002
max	1.000000	0.996066

미밴드 xiaomi

	label	score
label	0.000000	
score	0.221195	
dtype: float64		
label	1.000000	
score	0.725211	
dtype: float64		
count	2235.000000	2235.000000
mean	0.286353	0.365522
std	0.452158	0.268025
min	0.000000	0.002086
25%	0.000000	0.134794
50%	0.000000	0.308741
75%	1.000000	0.548272
max	1.000000	0.996175

홍미노트 xiaomi

	label	score
label	0.000000	
score	0.236552	
dtype: float64		
label	1.000000	
score	0.756057	
dtype: float64		
count	1536.000000	1536.000000
mean	0.416016	0.452674
std	0.493057	0.294319
min	0.000000	0.000631
25%	0.000000	0.207641
50%	0.000000	0.417226
75%	1.000000	0.704832
max	1.000000	0.998846

04 CONCLUSION

디자인 하나만보고 넘어가야지 했는데
이 영상보고 더 좋은 선택할 수 있을 거 같아요

앱등이 갈아탔습니다..
제품은 받았는데 아직 미개통 ㅠ 디자인은 만족

YouTube 데이터는 제품 미사용자의 의견을 반영

브랜드에 대한 이미지를 확인할 수 있는 지표

으아 … 아이폰 미니 배터리

아침에 100프로 충전하고
일하면서 노래듣고 점심 때 잠깐
유투브 봤는데 지금 방전됐네요 … ㅜㅜ
6s 처럼 보조배터리 들고 다녀야겠네요
배터리 문제 해결하신 분 계신가요?

드디어 패드병 완치 ㅠㅠ

아이클라우드에 심하게 데인 적이 있어서
아이클라우드는 단순 백업용도로만!!
그러다 보니 기본용량 안에서만 사용해요
M1칩 빠르고 아주 만족입니다!
필기할 때 종이 안 들고 다니니 편하네요

네이버 카페는 다수의 제품 사용자가 모여 있음

성능/디자인/이슈가 되는 문제 등 **제품에 대한 후기** 확인 가능

Conclusion

4-1 결론

모델 결과 데이터 요약

구매 **전** 브랜드 제품 평가	구매 **후** 브랜드 제품 평가
애플 > 삼성 > 샤오미	샤오미 > 삼성 > 애플

유투브 댓글 분석 결과 (브랜드 이미지)	네이버 카페 분석 결과 (제품 후기)
애플 > 샤오미, 삼성	삼성 > 샤오미, 애플

삼성의 마케팅 약점 = 브랜드 이미지 약화

Conclusion

4-1 결론

인스타 데이터를 활용한 워드클라우드와 빈도수 분석

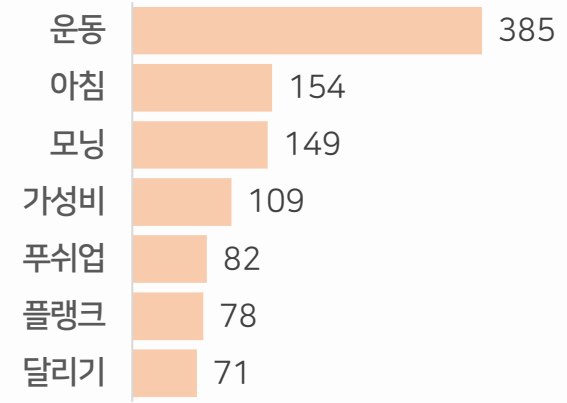

1 운동과 관련된 용어 多

다른 제품군보다 워치 사용이 많음

2 애플 관련 키워드와 가성비 키워드는 두 제품 간의 차이가 보임

가성비라는 이미지가 강함

1 애플은 운동, 드로잉, 공부 등 다양한 키워드 존재

다양한 제품군 사용

* 애플에는 다른 제품군에 대한 언급이 없음

Conclusion

4-1 결론

인스타 데이터를 활용한 워드클라우드와 빈도수 분석

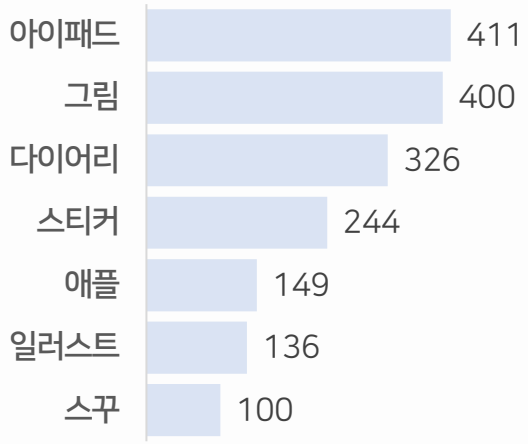

1 애플 검색결과에는 삼성이 없지만
삼성 검색결과에는 애플 관련 키워드가 존재

삼성은 애플과 비교선상에 있다

2 스꾸, 스티커 등 제품을 꾸미는데 사용하는 키워드가 같이 검색

자신이 원하는 대로 커스터마이징하는 갤럭시

사용자 내부의 한정된 문화는 타 브랜드와 다른 양상

> “ 사용자의 일상을 공유할 수 있는 브랜드로서 ”
>
> 이미지 메이킹이 필요하다

Conclusion

4-1 결론

NEW LOGO TYPE

다양성과 어우러지는 모습을 도형으로 표현하고,
삼성의 다양한 제품군을 한 곳에 모아 강한 연동성을 표현하였다.

포스트 코로나를 맞이하는 새로운 시대가 열립니다

Conclusion

4-2 시사점 / 연구한계

연구한계

- 텍스트 전처리

수집 대상 텍스트가 제품평 외의 정보를 포함, 섬세한 전처리를 요구

- 자연어 처리 모델링

모델링에 사용한 Okt는 비교적 최근 단어와 같이 라이브러리 사전에
등록되지 않은 형태소를 정확하게 분류할 수 없어 모델의 성능을 저하

시사점

더 이상 기업과 기업의 영업활동은 단순히 제품의 성능과 가격으로만 판단되지 않는다.
ESG가 그 대표적인 예로, 환경적으로 지속 가능한지, 사회적이고 윤리적인지,
지배구조가 투명한지 등의 비재무적 요소를 고려

전자기기에서도 성능과 별개로 얼마나 친근한지, 무엇이 연상되는지, 자신과 동질감을 느끼는지 등의 요소가
소비에 영향을 끼치므로 기업에서는 장기적으로 소비자들이 가질 브랜드 이미지 또한 충분히 고려해야 한다.

Conclusion

4-3 출처

[조선일보] 애플·삼성 위협하는 샤오미, 스마트폰 이어 3년 만에 '가성비 태블릿'도 출시
https://biz.chosun.com/it-science/ict/2021/08/15/SG5F56VFKBAJHK6TMQR7KTZPI4/

[아시아투데이] 삼성전자 스마트폰 점유율 20% 또 깨졌다…옥 죄어오는 애플·샤오미
https://www.asiatoday.co.kr/view.php?key=20210730010018273

[중앙일보] 애플이 또 애플했다···'아이폰12 효과'에 2분기 역대 최대 매출
https://news.joins.com/article/24115641

글로벌 스마트폰 제조업체별 월 판매량 점유율. 사진=카운터포인트리서치
https://www.etnews.com/20210806000061

[위키독스] 딥 러닝을 이용한 자연어 처리 입문
https://wikidocs.net/94600

텍스트 마이닝 프로젝트 (2020.6~) Data Crawling (휴먼지능정보공학과 류지혜, 이지민)
https://github.com/Jimin980921/Text_mining/blob/master/Project/textmining_project_crawling.ipynb

감사합니다

Q&A