

# 연구방법 in 빅데이터

통계학과 권세혁교수  
(<http://wolfpack.hnu.ac.kr>)




@RhoMooHyun\_bot Twitter




# (1) 통계적 방법론


## Confirmatory Data Analysis



## Exploratory Data Analysis




## (2) 데이터 수집(전처리 포함) in 빅데이터. - 크롤링 crawling



### (3) 분석 도구 in 빅데이터

[http://wolpack.hnu.ac.kr/Stat\\_Notes/software/software\\_index.html](http://wolpack.hnu.ac.kr/Stat_Notes/software/software_index.html)



감성 분석


- Opinion mining : 텍스트에 나타난 사람들의 태도, 의견, 성향과 같은 주관적인 데이터를 분석하는 자연어 처리 기술

워드 클라우드

- 문서, 개인의견 사용 단어 빈도 및 시각화

시각화

- GGPlot 라이브러리 함수 - 구글, 네이버 맵




[https://www.sas.com/ko\\_kr/software/university-edition/download-software.html](https://www.sas.com/ko_kr/software/university-edition/download-software.html)

SAS® University Edition

- Web running SAS + Jupyter Notebook

SPSS Python Essentials - How To Install?



## (4) Twitter 워드 클라우드 [http://wolpack.hnu.ac.kr/Big\\_Data/R\\_트위터\\_텍스트마이닝.pdf](http://wolpack.hnu.ac.kr/Big_Data/R_트위터_텍스트마이닝.pdf)

### 계정 만들기

- Twitter 계정 만들기 : <https://twitter.com>
- twitter Apps Key 만들기 : <https://apps.twitter.com>

### 트윗 가져오기

- `tweets.usa<-searchTwitter('남북회담',n=1000, lang="ko", since ="2018-05-01", until="2018-05-18", geocode='43.4060924,-77.6977438,1000km')`
- `tweets.korea<-searchTwitter('남북회담',n=1000, lang="ko", since ="2018-05-01",until="2018-05-18", geocode='37.566535,126.977969,100km')`
- `tweets.blue<-userTimeline(user='TheBlueHouseKR',n=1000) #노무현대통령 어록 트위터 @RhoMooHyun_bot`

### 데이터 프레임 만들기

- `tweets.blue.df<-twListToDF(tweets.blue)` 트윗 데이터 포맷 만들기
- `tweets.blue.df$text` 변수에 내용 저장 -> `tweets.text<-tweets.korea.df$text` #분석 대상 트윗 내용

### 한글 자연어 처리

- # 불필요한 문자를 필터링 : `tweets.text <- gsub("\Wn", "", tweets.text)`
- # 문장에서 단어(명사) 분리 - Map 이용 `tweets.nouns<-Map(extractNoun, tweets.text)`
- #sapply 함수 이용 `txt.nouns<-sapply(tweets.text,extractNoun,USE.NAMES = F)`
- 자연어처리후 불필요단어제거:`gsub()`함수

### 단어빈도 워드 클라우드

- # 단어별 카운팅, 상위 10개 단어 선택 `tweets.count<-table(tweets.word)`
- `wordcloud(names(tweets.count),freq=tweets.count,scale=c(4,0.5),min.freq=5,`
- `random.order=F,rot.per=.1,colors=pal,family='AppleGothic')`

(트윗 검색, 키워드 = '남북회담', 2018.05.01~05.17)

서울, 반경 100km, n=1,000



뉴욕, 반경 1,000km, n=1000(236)



## (5) PDF영어성경 (word cloud) [http://wolfpack.hnu.ac.kr/Big\\_Data/WORD\\_CLOUD\\_영어\\_PDF.pdf](http://wolfpack.hnu.ac.kr/Big_Data/WORD_CLOUD_영어_PDF.pdf)

### 1) 데이터 읽기

```
install.packages("pdftools")
library(pdftools)
#PDF 문서 txt 데이터 변환
txt <- pdf_text("http://wolfpack.hnu.ac.kr/Big_Data/data/NIV_Bible.pdf")
head(txt,1) #읽은 첫문자 콘솔 출력
```

### 2) 자연어 처리 - 말뭉치 만들기

```
install.packages(c("NLP","tm"))
library(NLP); library(tm)
docs <- Corpus(VectorSource(txt)) #VectorSource 문자벡터 말뭉치
inspect(docs[2]) #말뭉치 작성 확인 페이지 2
```

### 3) 특수문자 제거 content\_transformer() 함수

```
toSpace<-content_transformer(function (x , pattern ) gsub(pattern,' ', x)) docs <- tm_map(docs, toSpace, '/')
docs <- tm_map(docs, toSpace, '@')
docs <- tm_map(docs, toSpace, 'WW|')
docs <- tm_map(docs, toSpace, 'Wn')
inspect(docs[2]) #특수문자 제외 확인
```

### 4) 불필요 단어 제거 tm\_map() 함수

```
docs <- tm_map(docs, content_transformer(tolower)) # 텍스트 대문자를 소문자로 변환
docs <- tm_map(docs, removeNumbers) # 텍스트 숫자를 제거
docs <- tm_map(docs, removeWords, stopwords("english")) # 텍스트 english 제거
docs <- tm_map(docs, removePunctuation) # 텍스트 물음표 제거
docs <- tm_map(docs, stripWhitespace) # 텍스트 빈칸(white space) 제거
# Text stemming : 동사 기본형으로 표준화 : do, done, doing -> do로 표준화
docs <- tm_map(docs, stemDocument)
# 사용자 지정 제거 단어 설정 및 문서(텍스트)에서 제거
my_custom_stopwords <- c('will', 'come','one', 'said','say','went', 'may', 'let', 'give', 'made','make','came','hous','hand', 'now',
'put','also','call','saw','done','eat','gave','can','left','know','ask','set','even','everi','sent','back','look','took','take')
docs <- tm_map(docs, removeWords, my_custom_stopwords)
inspect(docs[2]) #불필요 단어 제외 확인
```

## 5) 단어 빈도 계산

#문서번호와 단어간의 사용여부 또는 빈도 카운트

```
dtm <- TermDocumentMatrix(docs)
```

```
findFreqTerms(dtm, lowfreq = 500) #500회 이상 사용된 단어 출력
```

```
findFreqTerms(dtm, 500,600) #500에서 600회 사이로 사용된 단어 출력
```

```
> findFreqTerms(dtm, lowfreq = 500)
```

```
[1] "day"      "earth"    "god"      "good"     "great"    "heaven"  
[7] "land"     "live"     "place"    "spirit"   "thing"    "two"  
[13] "water"    "year"     "eye"      "holi"     "life"     "like"  
[19] "lord"     "man"      "name"     "work"     "among"    "answer"
```

```
> findFreqTerms(dtm, 500,600)
```

```
[1] "spirit"   "eye"      "life"     "work"     "answer"   "heard"  
[7] "head"     "destroy"  "righteous" "law"      "christ"
```

## 6) 단어 연관분석

```
#findAssocs - 설정 단어(work)와 연관성이 0.3(상관계수) 이상 높은 단어  
findAssocs(dtm, terms = "sin", corlimit = 0.3)  
findAssocs(dtm, terms = "john", corlimit = 0.3)
```

```
> findAssocs(dtm, terms = "sin", corlimit = 0.3)
```

```
$sin
```

offer	natur	commit	forgiven	sonship
0.32	0.32	0.31	0.31	0.30

```
> findAssocs(dtm, terms = "john", corlimit = 0.3)
```

```
$john
```

baptist	herodia	baptiz	platter	jesus	herod	behead	birthday	amaz
0.53	0.48	0.44	0.42	0.40	0.40	0.38	0.36	0.32

discipl  
0.32

## 7) DTM 만들기

```
#Document Term matrix 만들기
#The function TermDocumentMatrix() 결과 기반
dtm.mat <- as.matrix(dtm)
v <- sort(rowSums(dtm.mat),decreasing=TRUE)
word.freq <- data.frame(word = names(v),freq=v)
#상위 빈도 20개 빈도표 출력 head(word.freq, 20)
```

	Term 1	Term 2	Term 3	...	Term M
Tweet 1	0	1	1	0	0
Tweet 2	0	1	0	0	0
Tweet 3	0	0	0	3	0
...	0	0	0	1	1
Tweet N	0	0	0	1	0

Document Term Matrix (DTM)

```
> head(word.freq, 20)
```

```
      word freq
lord   lord 7809
god    god  4451
son    son  3227
king   king  2881
peopl  peopl 2375
```

```
> head(v, 5)
```

```
lord   god   son   king peopl
7809  4451  3227  2881  2375
```

## 7) 시각화 : 워드 클라우드, 바차트

```
install.packages(c('SnowballC','RColorBrewer','wordcloud'))  
library(SnowballC); library(RColorBrewer); library(wordcloud)  
  
#Generate the Word cloud  
wordcloud(words = word.freq$word, freq = word.freq$freq, min.freq =  
100, random.order=F, rot.per=0.35, colors=brewer.pal(8, 'Dark2'))
```

```
#Frequency Table  
require(ggplot2)  
ggplot(word.freq[1:20,],aes(x=freq,y=word,col=word)) +  
  geom_segment(aes(yend=word),xend=0,color='grey') +  
  geom_point(size=2,aes(color=word)) + ggtitle('단어 빈도')
```



## (6) 주가 데이터, 환율, 경제, 미세먼지 데이터, 기상 데이터 가져오기

```
install.packages("quantmod"); library(quantmod)
today <- Sys.Date()

#야후 금융: https://finance.yahoo.com/
kospi <- getSymbols("^KS11",src='yahoo', from='2017-11-01', to='2018-05-23', auto.assign = F)
head(kospi,3); plot(kospi$KS11.Close)
#삼성전자 주가
stock_ss <- getSymbols("005930.KS",src='yahoo', from=today-90, to=today, auto.assign = F)
head(stock_ss,3); plot(stock_ss[,4]) #삼성전자 주가 증가

# OANDA 환율: https://www.oanda.com/
exchange <- getSymbols(Symbols="USD/KRW", src = "oanda", from=today-60, to=today, auto.assign=F)
head(exchange,3)

# 경제 데이터: https://fred.stlouisfed.org/
unemp_xts <- getSymbols(Symbols="LRHUTTTTKRA156N", src = "FRED", from='2017-01-01', to='2018-5-23', auto.assign=F)
head(unemp_xts,3)

# 미세먼지 데이터 : https://www.airkorea.or.kr/last_amb_hour_data
mise <- read.csv('http://wolfpack.hnu.ac.kr/Stat_Notes/example_data/mise_dj.csv',header=T); head(mise,3)
```

## (7) to SAS, SPSS from R


```
#csv format 저장
write.csv(data.frame(stock_ss),"삼성전자.csv") #date 포함

#software data type 저장
install.packages("haven")
library(haven)
data() # R 내장 데이터 리스트
write_sas(mtcars, "mtcars.sas7bdat"). #sas는 변수명이 한글인 경우 작동에 문제 있음
write_sav(mise, "mise.sav")
write_dta(mise, "mise.dta")
```

## (8) SAS University Edition 사용하기

설치가이드 : [https://www.sas.com/ko\\_kr/software/university-edition/download-software.html](https://www.sas.com/ko_kr/software/university-edition/download-software.html)

맛보기 : [http://wolfpack.hnu.ac.kr/Stat\\_Notes/software/about\\_R/SAS\\_Univ.Ed\\_맛보기.pdf](http://wolfpack.hnu.ac.kr/Stat_Notes/software/about_R/SAS_Univ.Ed_맛보기.pdf)



서버 파일 및 폴더



폴더 바로 가기

내 폴더

mySAS

- import.sas7bdat
- mtcars.sas7bdat
- US\_crime.csv
- us\_crime.sas
- 삼성전자.csv

sasuser.v94

TEST

CLASS회귀분석.sas



열려는 항목을 여기로 끌어옵니다.

서버 파일 및 폴더



폴더 바로 가기

내 폴더

mySAS

- import.sas7bdat
- mtcars.sas7bdat
- US\_crime.csv
- us\_crime.sas
- 삼성전자.csv

sasuser.v94

TEST

CLASS회귀분석.sas

작업 및 유틸리티

라이브러리

파일 바로 가기

\*삼성전자

실행 코드/결과 분할 로그 코드

파일 정보

소스 파일  
 파일 이름: 삼성전자.csv  
 소스 위치: /folders/myfolders/mySAS  
 행 구분자의 끝:

코드 로그 결과

```

1 /* 생성된 코드 (가져오기, 행 번호 지정)
2 /* 소스 파일: 삼성전자.csv */
3 /* 소스 경로: /folders/myfolders/mySAS */
4 /* 코드 생성일: 18. 5. 24. 오전 9:53 */
5
6 %web_drop_table(WORK.IMPORT);
7
8
9 FILENAME REFFILE '/folders/myfolders/mySAS/삼성전
10
11 PROC IMPORT DATAFILE=REFFILE
12
    
```

# (Python + SAS)

jupyter

Files Running Clusters

Select items to perform actions on them.

Up

- Notebook
- Python 3
- SAS
- Other
- Text File
- Folder
- Terminals U

mySAS

sasuser.v94

TEST

Untitled.ipynb

autoexec.sas

삼성전자.csv

# 안녕하세요!

SAS Studio 시작 >

Jupyter Notebook 시작

jupyter Untitled (autosaved)

File Edit View Insert Cell Kernel Help

Trusted Python 3

Show the SAS Log for last executed cell Show the complete SAS Log for the notebook

```
In [3]: import csv
with open('삼성전자.csv') as csvfile:
    readCSV = csv.reader(csvfile, delimiter=',')
    for row in readCSV:
        print(row)
        print(row[0])
        print(row[0],row[1],row[2],)
```

```
['', 'X005930.KS.Open', 'X005930.KS.High', 'X005930.KS.Low', 'X005930.KS.
Close', 'X005930.KS.Volume', 'X005930.KS.Adjusted']

X005930.KS.Open X005930.KS.High
['2018-02-23', '46760', '47800', '46760', '47220', '12423300', '30057.906
25']
2018-02-23
2018-02-23 46760 47800
['2018-02-26', '47280', '47560', '47080', '47380', '9560650', '30159.7539
06']
2018-02-26
2018-02-26 47280 47560
```

# This Summer

## 1. 오픈 API -java

## 2. Data Crawling - Python

## 3. Sentiment Analysis

```
> table(get_sentiments("afinn"))$score)
```


```
-5 -4 -3 -2 -1 0 1 2 3 4 5
16 43 264 965 389 1 208 448 172 45 5
```

```
> table(get_sentiments("bing"))$sentiment) #긍정-부정 이진형
```

```
negative positive
4782 2006
```



```
> table(get_sentiments("nrc"))$sentiment) #10개의 감성단어
```

anger	anticipation	disgust	fear	joy
1247	839	1058	1476	689
negative	positive	sadness	surprise	trust
3324	2312	1191	534	1231



### 사회 연결망 분석 ( Social Network Analysis : SNA )

개인과 집단들 간의 관계를 노드와 링크로서 모델링해 그것의 위상구조와 확산 및 진화과정을 계량적으로 분석하는 방법론이다.



- 태조실록 1권, 태조 1년 7월
- 태조가 백관의 추대를 받아 수창궁에서 왕위에 오르다
  - 태조가 왕위에 있을 당시 여러 가지 계국의 조짐이 나타나다
  - 태조가 왕위에 오르자 가을날에 비가 내리다
  - 태조 신묘가 태조의 등극을 알리기 위해 명의 예부에 사신을 보내자고 청하다
  - 의흥친군위를 설치하고 도총 중의 계군사부를 폐지하다
  - 백관에게 명하여 고려조 제도의 연혁과 장단점을 아뢰게 하다