

개요

PDF 문서에서 자주 사용되는 단어(키워드)를 분류한 Text mining 결과를 시각적으로 표현하는 것을 word cloud라 한다.

예제 (PDF) 문서

한글개역(신약) 성경 [http://wolfpack.hnu.ac.kr/Big_Data/data/한글성경_신약.pdf] - 한글 성경 전체를 워드 클라운드를 위한 단어 빈도 작성 시 메모리 문제로 작업 종료 오류가 나서 신약 성경만 사용한 분석 결과임

(마1:8)아사는 여호사밧을 낳고 여호사밧은 요람을 낳고 요람은 웃시야를 낳고
 (마1:9)웃시야는 요담을 낳고 요담은 아하스를 낳고 아하스는 히스기야를 낳고
 (마1:10)히스기야는 므낫세를 낳고 므낫세는 아몬을 낳고 아몬은 요시야를 낳고
 (마1:11)바벨론으로 이거할 때에 요시야는 여고냐와 그의 형제를 낳으니라
 (마1:12)바벨론으로 이거한 후에 여고냐는 스알디엘을 낳고 스알디엘은 스룹바벨을 낳고
 (마1:13)스룹바벨은 아비훗을 낳고 아비훗은 엘리아김을 낳고 엘리아김은 아소르를 낳고

[txt 성경] [http://wolfpack.hnu.ac.kr/Big_Data/data/개역개정.txt]

태초에 하나님이 천지를 창조하시니라
 땅이 혼돈하고 공허하며 흑암이 깊음 위에 있고 하나님의 영은 수면 위에 운행하시니라
 하나님이 이르시되 빛이 있으라 하시니 빛이 있었고
 빛이 하나님이 보시기에 좋았더라 하나님이 빛과 어둠을 나누사
 하나님이 빛을 낮이라 부르시고 어둠을 밤이라 부르시니라 저녁이 되고 아침이 되니 이는 첫째 날이니라
 하나님이 이르시되 물 가운데에 궁창이 있어 물과 물로 나뉘라 하시고
 하나님이 궁창을 만드사 궁창 아래의 물과 궁창 위의 물로 나뉘게 하시니 그대로 되니라
 하나님이 궁창을 하늘이라 부르시니라 저녁이 되고 아침이 되니 이는 둘째 날이니라
 하나님이 이르시되 천하의 물이 한 곳으로 모이고 물이 드러나라 하시니 그대로 되니라
 하나님이 물을 땅이라 부르시고 모인 물을 바다라 부르시니 하나님이 보시기에 좋았더라
 하나님이 이르시되 땅은 풀과 씨 맺는 채소와 각기 종류대로 씨 가진 열매 맺는 나무를 내라 하시니 그대로 되어
 땅이 풀과 각기 종류대로 씨 맺는 채소와 각기 종류대로 씨 가진 열매 맺는 나무를 내니 하나님이 보시기에 좋았더라

PDF 데이터 텍스트 데이터로 읽기 : pdf_text() 함수

```
# Read text data from text file.
txt <- readLines("http://wolpack.hnu.ac.kr/Big_Data/data/개역개정.txt",
encoding="UTF-8")
head(txt,3)
library(pdftools)
txt.pdf <- pdf_text("http://wolpack.hnu.ac.kr/Big_Data/data/한글성경 신
약.pdf") #PDF -> text
head(txt.pdf,1)
```

```
> head(txt,3)
```

- [1] "태초에 하나님이 천지를 창조하시니라"
- [2] "땅이 혼돈하고 공허하며 흑암이 깊음 위에 있고 하나님의 영은 수면 위에 운행하시니라"
- [3] "하나님이 이르시되 빛이 있으라 하시니 빛이 있었고"

PDF는 페이지 단위, txt 파일은 행(라인) 단위 읽어 들이기 - 본 강의 예제는 PDF 파일 기준임

```
> head(txt.pdf,1)
```

```
[1] "(마1:8)아사는 여호사밧을 낳고 여호사밧은 요람을 낳고 요람은 웃시아를 낳고\n(마1:9)웃시아는 요담을 낳고
요담은 아하스를 낳고 아하스는 히스기야를 낳고\n(마1:10)히스기야는 므낫세를 낳고 므낫세는 아몬을 낳고 아몬은 요시
야를 낳고\n(마1:11)바벨론으로 이거할 때에 요시아는 여고냐와 그의 형제를 낳으니라\n(마1:12)바벨론으로 이거한 후
에 여고냐는 스알디엘을 낳고 스알디엘은 스룹바벨을 낳고\n(마1:13)스룹바벨은 아비훗을 낳고 아비훗은 엘리아김을 낳고
엘리아김은 아소르를 낳고\n(마1:14)아소르는 사독을 낳고 사독은 아킴을 낳고 아킴은 엘리웃을 낳고\n(마1:15)엘리
웃은 엘르아살을 낳고 엘르아살은 맛단을 낳고 맛단은 야곱을 낳고\n(마1:16)야곱은 마리아의 남편 요셉을 낳았으니 마
리아에게서 그리스도라 칭하는 예수가 나시니라\n(마1:17)그런즉 모든 대 수가 아브라함부터 다윗까지 열네 대요 다윗부
```

텍스트 문장 자연어 처리 : KoNLP 라이브러리 - Corpus() 함수. 말뭉치 만들기

```
library(rJava)
library(KoNLP)
# Use Korean dictionary.
useSejongDic(). #세종단어사전 이용

library(tm)
docs <- Corpus(VectorSource(txt.pdf)) #말뭉치 만들기 - VectorSource 문자벡터
말뭉치
inspect(docs[1]) #말뭉치 작성 확인 - 페이지 지정
```

- inspect() 함수 : 만들어진 말뭉치(docs 오브젝트) 1 페이지 결과 보기

```
> inspect(docs[1]) #말뭉치 작성 확인 - 페이지 지정
<<SimpleCorpus>>
Metadata: corpus specific: 1, document level (indexed): 0
Content: documents: 1

[1] (마1:8)아사는 여호사밧을 낳고 여호사밧은 요람을 낳고 요람은 웃시야를 낳고\n(마1:
9)웃시야는 요담을 낳고 요담은 아하스를 낳고 아하스는 히스기야를 낳고\n(마1:10)히스기야
는 므낫세를 낳고 므낫세는 아몬을 낳고 아몬은 요시야를 낳고\n(마1:11)바벨론으로 이거할
때에 요시야는 여고냐와 그의 형제를 낳으니라\n(마1:12)바벨론으로 이거한 후에 여고냐는
스알디엘을 낳고 스알디엘은 스룹바벨을 낳고\n(마1:13)스룹바벨은 아비훗을 낳고 아비훗은
```

특수문자 빈칸(space) 변환 : content_transformer() 함수

#tm_map() 함수 활용 : content_transformer() 함수
#특수문자 "/", "@", "|", "\n" 을 space(공백)으로 변환 혹은 대체

```
toSpace<-content_transformer(function (x , pattern ) gsub(pattern,' ', x))
docs <- tm_map(docs, toSpace, ':')
inspect(docs[1]) #특수문자 제외 확인
```

```
toPeriod<-content_transformer(function (x , pattern ) gsub(pattern,'.', x))
docs <- tm_map(docs, toPeriod, '\n')
inspect(docs[1]) # 마침표 변환 확인
```

- toSpace 오브젝트는 content_transformer() 함수를 이용하여 적용되는 특수문자(:)를 ' '(공백)으로 변환 하였고 - toPeriod는 특수문자 '\n'을 특수문자 '.'로 변경하였음

> inspect(docs[1]) #특수문자

```
<<SimpleCorpus>>
```

```
Metadata: corpus specific: 1, document level (indexed): 0
```

```
Content: documents: 1
```

```
[1] (마1 8)아사는 여호사밧을 낳고 여호사밧은 요람을 낳고 요람은 웃시야를 낳고\n(마1 9)웃시야는 요담을 낳고 요담은 아하스를 낳고 아하스는 히스기야를 낳고\n(마1 10)히스기야는 므낫세를 낳고 므낫세는 아몬을 낳고 아몬은 요시야를 낳고\n(마1 11)바벨론으로 이거할 때에 요시야는 여고냐와 그의 형제를 낳으니라\n(마1 12)바벨론으로 이거한 후에 여고냐는 스알디엘을 낳고 스알디엘은 스룹바벨을 낳고\n(마1 13)스룹바벨은 아비훗을 낳고 아비훗은
```

> inspect(docs[1]) #마침표 변환 확인

```
<<SimpleCorpus>>
```

```
Metadata: corpus specific: 1, document level (indexed): 0
```

```
Content: documents: 1
```

```
[1] (마1 8)아사는 여호사밧을 낳고 여호사밧은 요람을 낳고 요람은 웃시야를 낳고.(마1 9)웃시야는 요담을 낳고 요담은 아하스를 낳고 아하스는 히스기야를 낳고.(마1 10)히스기야는 므낫세를 낳고 므낫세는 아몬을 낳고 아몬은 요시야를 낳고.(마1 11)바벨론으로 이거할 때에 요시야는 여고냐와 그의 형제를 낳으니라.(마1 12)바벨론으로 이거한 후에 여고냐는 스알디엘을 낳고 스알디엘은 스룹바벨을 낳고.(마1 13)스룹바벨은 아비훗을 낳고 아비훗은 엘리아קים
```

워드 클라우드 불필요 단어 제외 : tm_map() 함수

```
# 텍스트 대문자를 소문자로 변환
docs <- tm_map(docs, content_transformer(tolower))
# 텍스트 숫자를 제거
docs <- tm_map(docs, removeNumbers)
# 텍스트 english 제거
docs <- tm_map(docs, removeWords, stopwords("english"))
# 텍스트 물음표 제거
docs <- tm_map(docs, removePunctuation)
# 텍스트 빈칸(white space) 제거
docs <- tm_map(docs, stripWhitespace)
# 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('불필요단어1','단어2')
docs <- tm_map(docs, removeWords, my_custom_stopwords)
inspect(docs[1]) #불필요 단어 제외 확인

docs <- tm_map(docs, removeWords, my_custom_stopwords)
inspect(docs[2]) #불필요 단어 제외 확인
```

```
> inspect(docs[1]) #불필요 단어 제외 확인
```

```
<<SimpleCorpus>>
```

```
Metadata: corpus specific: 1, document level (indexed): 0
```

```
Content: documents: 1
```

```
[1] 마 아사는 여호사밧을 낳고 여호사밧은 요람을 낳고 요람은 웃시야를 낳고마 웃시야는 요
담을 낳고 요담은 아하스를 낳고 아하스는 히스기야를 낳고마 히스기야는 므낫세를 낳고 므낫세
는 아몬을 낳고 아몬은 요시야를 낳고마 바벨론으로 이거할 때에 요시야는 여고냐와 그의 형제
를 낳으니라마 바벨론으로 이거한 후에 여고냐는 스알디엘을 낳고 스알디엘은 스룹바벨을 낳고
마 스룹바벨은 아비훗을 낳고 아비훗은 엘리아김을 낳고 엘리아김은 아소르를 낳고마 아소르는
사독을 낳고 사독은 아킴을 낳고 아킴은 엘리우을 낳고마 엘리우은 엘르아살을 낳고 엘르아살은
```

문장 단어 카운트 및 결과 보기

```
#문서번호와 단어간의 사용여부 또는 빈도 카운트
dtm <- TermDocumentMatrix(docs)
#생성된 document term matrix에서 1-10번 빈도 높은단어의
#100번째에서 150번째 문서의 분포를 확인
#Sparsity : 공백 수 (%로 표현)
inspect(dtm[1:10,100:150])

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

- TermDocumentMatrix() 문장 내 단어 빈도 행렬 표현
- 빈도가 높은 단어들의 문서내 분포

```
> inspect(dtm[1:10,100:150])
<<TermDocumentMatrix (terms: 10, documents: 51)>>
Non-/sparse entries: 165/345
Sparsity : 68%
Maximal term length: 5
Weighting : term frequency (tf)
Sample :
      Docs
Terms 102 104 107 108 111 121 122 125 128 136
가다가      0   0   0   0   0   0   0   0   0   0
가라사대마  0   0   0   0   0   0   0   0   0   0
가로되      7   6   5   5   6   7   8   6   3   9
```

```
> findFreqTerms(dtm, lowfreq = 500) #500회 이상 사용된 단어 출력
[1] "가로되" "것을" "그" "내" "또"
[6] "모든" "예수께서" "이" "이는" "내가"
[11] "너희가"

> findFreqTerms(dtm, 500,600) #500에서 600회 사이로 사용된 단어 출력
[1] "가로되" "내" "또" "이는" "너희가"
```

문장 내 함께 사용된 단어들의 연관분석

```
#findAssocs - 설정 단어(work)와 연관성이 (상관계수) 기준 이상 높은 단어
findAssocs(dtm, terms = "죄", corlimit = 0.4)
findAssocs(dtm, terms = "요한", corlimit = 0.75)
```

- 단어 '죄' 와 함께 쓰인 빈도가 0.4 이상인 단어 : 사한다

```
> findAssocs(dtm, terms = "죄", corlimit = 0.4)
```

```
$죄
```

사함을	사하는	세관에	쓸데없고	의원이	
0.55	0.41		0.41	0.41	0.41
자에게라야	중풍병자를				
0.41	0.41				

- 단어 '요한' 와 함께 쓰인 빈도가 0.4 이상인 단어 : 살아났다, 걸으니 - 기적

```
> findAssocs(dtm, terms = "요한", corlimit = 0.8)
```

```
$요한
```

가두었으니	막	가운데서	살아났도다	거기서는	
0.82			0.82		0.82
걸으니		것은	막	경계하시고	
0.82			0.82		0.82
고막		고치	더라	막	고치실
0.82			0.82		0.82
곳에서	든지	권	능도	놀라	거늘
0.82			0.82		0.82
느끼면서	도	달	게	달리	다
0.82			0.82		0.82
드러난	지라	들	어가	거든	들
0.82			0.82		0.82

품사 단어 말뭉치 만들기

```
#품사 단어 선택 후 자연어 처리 방법
txt.cnt<-SimplePos22(docs) #하위분류 22 품사 단어 추출
head(txt.cnt,1)
# 품사 태그 중 필요한 품사만 선택
# 영어, 숫자 모두 필요하면 [ㄱ-ㅎ|가-힣|a-z|A-Z|0-9].
# 보통명사 NC, 고유명사 NP 둘 다 필요하면 [NC|NP]
library(stringr)
txt.cnt0<-str_match_all(txt.cnt,'([ㄱ-ㅎ|가-힣|a-z|A-Z|0-9]+)/[NC|NP]')
head(txt.cnt0,1)
txt.cnt0<-unlist(txt.cnt0) #단어를 벡터 포맷으로 리스트 (flatten list)
head(txt.cnt0,5)
txt.cnt00<-Filter(function(x){nchar(x)>3},txt.cnt0) #단어 2글자(/N 포함 4) 이상
head(txt.cnt00,5)
```

docs 데이터는 페이지 5의 tm_map() 함수가 적용된 것임

```
[[1]]$날고
[1] "날/PV+고/EC"
```

```
[[1]]$므낫세는
[1] "므낫세는/NC"
```

```
[[1]]$아몬을
[1] "아몬을/NC"
```

읽어들인 문서 모든 단어에 대하여 품사셋 붙음


명사(NC) 품사 단어만 선택

```
> head(txt.cnt0,1)
[[1]]
      [,1]      [,2]
[1,] "마/N"    "마"
[2,] "아사/N"  "아사"
[3,] "여호사밧을/N" "여호사밧을"
[4,] "여호사밧은/N" "여호사밧은"
[5,] "요람/N"   "요람"
[6,] "요람/N"   "요람"
      시야를/N"   "웃시야를"
```

단어 벡터 포맷 리스트, 글자 2개 이상 단어

```
> txt.cnt0<-unlist(txt.cnt0) #단어를 벡터 포맷으로 리스트 (flatten list)
> head(txt.cnt0,5)
[1] "마/N"      "아사/N"      "여호사밧을/N" "여호사밧은/N" "요람/N"
> txt.cnt00<-Filter(function(x){nchar(x)>3},txt.cnt0) #단어 2글자(/N 포함 4) 이상
> head(txt.cnt00,5)
[1] "아사/N"      "여호사밧을/N" "여호사밧은/N" "요람/N"      "요람/N"
```

카이스트 품사셋



말뭉치 만들기 - 단어 빈도 계산 Corpus() 함수, TermDocumentMatrix()함수

```
library(tm)
words <- Corpus(VectorSource(txt.cnt0)) #말뭉치 만들기
#워드 클라우드 1차 분석 후 제외 단어 추가
stopword <- c(stopwords('english'),'것','고','이','서','요','그','하','나','자',
               '말','내','중','저','지','한','가라사대','내가','우리','저희',
               '너','자기','두','또','안','줄','바','리','라','앞','수','후',
               '하나','대','만')
words <- tm_map(words,removeWords,stopword)
dtm <- TermDocumentMatrix(words)
findFreqTerms(dtm, lowfreq = 100)
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)
```

> #상위 빈도 20개 빈도표 출력

> head(word.freq, 20)

	word	freq
너희	너희	4724
사람	사람	2588
주	주	1510
때	때	1332
예수께서	예수께서	1332
일	일	1328
하나님	하나님	1298
예수	예수	718
말씀	말씀	672

워드 cloud 표현

```
#Generate the Word cloud
#word cloud 라이브러리
library(SnowballC)
library(RColorBrewer)
library(wordcloud)

wordcloud(words = word.freq$word, freq = word.freq$freq,
          min.freq = 100, random.order=F, rot.per=0.35, colors=brewer.pal(8,
'Dark2'), family="AppleGothic")

#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')
```



