

R.package

corpus

- <https://cran.r-project.org/web/packages/corpus/index.html>

■ raw data に整形しておく

■ corpus_frame() で「corpus data frame object」形式のデータとして保存

title	text
-------	------

■ text_tkens() でトークン化

■ text_filter()

- オプションを指定することで各種整形ができる

■ text_ntoken()

- token の数

■ text_ntype()

type の数

■ text_nsentence()

文の数

■ text_stats()

- 上三つをまとめて行う

■ term_stats()

- 各用語が、コーパス・データ中のいくつのサブコーパスに含まれるか

term_stats(data)

- オプションで ngram も同様に

term_stats(data, ngrams = 5)

- 特定の語を含む ngram も同様に
 - グラム数の範囲指定可能
 - 何語目に含むか指定可能

```
term_stats(data, ngrams = 2:3, types = TRUE,  
            subset = type1 == "dorothy" & !type2 %in% stopwords_en)
```

■ `text_locate()` で KWIC 検索

- ・ `stemmer` オプションでステミング可能
- ・ 複数の `keyword` の指定可能

■ `text_sample()` で同様にランダムに検索可能