

spacyr

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

https://rdrr.io/cran/spacyr/f/vignettes/using_spacyr.Rmd

Python の spaCy パッケージのラッパー

1. テキストを構文解析し、トークンと文に
2. トークンのレマ化
3. 文法依存関係
4. 連語検索

先に [Anaconda](#) と [Python](#) をインストールして、
[Python](#) で、Spacy をインストールしておく必要がある。

事前準備

1. [Git](#) をインストールする

<https://gitforwindows.org/>

2. miniconda をインストールする (Miniconda3-latest-[Windows-x86_64.exe](#))

<https://www.anaconda.com/download/success>

インストール

使用の実際

サンプルデータ : JPN501.txt from NICER

- ・ 本文部分だけにしたテキストファイル : [JPN501.txt.data](#)

使い始め

- ・ 英語を指定

テキスト解析 (オプションなしだと、POS 付与) : `spacy_parse(txt)`

トークン化 (単語ごとにバラバラにする) : `spacy_tokenize(txt)`

- ・ 出力をデータフレームにできる

「エンティティ」(固有名詞類) の抽出 : `entity_extract(parsedtxt)`

名詞句抽出 : `nounphrase_extract(parsedtxt)`

- ・ テキスト解析する際に、名詞句オプションを付けておく必要がある。

```
spacy_parse(txt, nounphrase = TRUE)
```

名詞句をひと塊として POS タグ付与 : `nounphrase_consolidate(parsedtxt)`

エンティティの一覧作成 : `spacy_extract_entity(txt)`

- ・文中の何単語目か (`start_id`) も表示

名詞句のみの一覧作成 : `spacy_extract_nounphrases(txt)`

文法依存関係

```
spacy_parse( テキスト , dependency = TRUE, output = "data.frame")
```

- ・解析する際に、依存関係のオプションを付ける : `dependency = TRUE`
- ・データフレームにしておく : `output = "data.frame"`

図にする : `textplot`

- ・`textplot` パッケージを使用
 - ・UDpipe を前提にしているので、修正必要
- ・データフレームの見出し `pos` を `upos` に名称変更
- ・一文ずつなので、フィルターで特定の文を選ぶ

パターンマッチング matcher

1. 初期化

```
matcher <- spacy_initialize_matcher()
```

1. パターンの定義

```
pattern <- list( パターンを定義 )
```

1. テキスト解析を施しておく

```
doc <- spacy_parse( テキスト )
```

1. パターンを matcher に追加

```
spacy_add_matcher(matcher, " 文字列 ", pattern)
```

1.matcher の実行

```
result <- spacy_matcher(doc, matcher)
```

1. 結果の出力

```
print(result)
```

終わる前にやっておく : `spacy_finalize()`