

Rによる正規表現処理と テキストマイニング

石田 基広

徳島大学総合科学部

Rでテキストデータを解析しよう

- 良くある手順

- Java, C, Perlなどで解析プログラム作成
- テキストデータから必要な数値を取得
- 抽出された数値を R に取り込み解析開始

Rでテキストデータを解析しよう

- 良くある手順
 - Java, C, Perlなどで解析プログラム作成
 - テキストデータから必要な数値を取得
 - 抽出された数値をRに取り込み解析開始
- R上ですべてをシームレスに行えないのか

報告内容

- R によるテキストマイニング
 - **lsa** パッケージ
潜在的意味インデキシング
 - **tm** パッケージ
String Kernel によるクラスタリング

報告内容

- R によるテキストマイニング
 - **lsa** パッケージ
潜在的意味インデキシング
 - **tm** パッケージ
String Kernel によるクラスタリング
- R における正規表現処理
 - **gsubfn** パッケージ

テキストデータの処理

テキストマイニングに必要な古典的な処理

- 各種フォーマットやメタ情報の処理 (**XML** パッケージ)

テキストデータの処理

テキストマイニングに必要な古典的な処理

- 各種フォーマットやメタ情報の処理 (**XML** パッケージ)
- 単語の頻度を計る
- 特殊記号や stopwords を取り除く
 - "a" "about" "above" "across" "after"

テキストデータの処理

テキストマイニングに必要な古典的な処理

- 各種フォーマットやメタ情報の処理 (**XML** パッケージ)
- 単語の頻度を計る
- 特殊記号や stopwords を取り除く
 - "a" "about" "above" "across" "after"
- 大文字・小文字の統一
- stemming を行う (**Rstem, Snowball** パッケージ)
 - "Human machine interface for ABC computer applications"
 - human machin interfac abs comput application

テキストデータの処理

テキストマイニングに必要な古典的な処理

- 各種フォーマットやメタ情報の処理 (**XML** パッケージ)
- 単語の頻度を計る
- 特殊記号や stopwords を取り除く
 - "a" "about" "above" "across" "after"
- 大文字・小文字の統一
- stemming を行う (**Rstem, Snowball** パッケージ)
 - "Human machine interface for ABC computer applications"
 - human machin interfac abs comput application
- Term Document 行列を作成する

ターム・文書行列の例

term	Doc1	Doc2	Doc3	Doc4
abc	1	0	0	0
application	1	0	0	0
comput	1	1	0	0
human	1	0	0	1
interfac	1	0	1	0
machin	1	0	0	0

ターム・文書行列の例

対象とする全テキストに登場するタームを行とし、列には各文書を取る。そして各タームのある文書における頻度を要素として埋める。さらに通常は、この行列に各種の重み付けを行う。

lsa パッケージによる処理

- 潜在的意味インデキシング解析 (lsa)
- lsa_0.57 by Fridolin Wild
 - ディレクトリ内の全テキスト読込
 - オプションで stopwords を削除
 - stemming に対応 (**Rstem** による処理)
 - ターム・文書行列の生成 (重み付け)
 - 特異値分解
 - 文書どうしの類字度 (コサイン距離等) の算出
 - 新規検索タームの文書行列との類似度計算

ベンチマークによる試行例

- 九つのテクニカルメモのタイトルを利用
 - Scott C. Deerwester et al.(1990) “Indexing by Latent Semantic Analysis”
- D1 - D5 (human-computer-interaction)
- D6 - D9 (graph theory)

ベンチマークによる試行例

- 九つのテクニカルメモのタイトルを利用
 - Scott C. Deerwester et al.(1990) “Indexing by Latent Semantic Analysis”
- D1 - D5 (human-computer-interaction)
- D6 - D9 (graph theory)
 - D1: Human machine interface for ABC computer applications
 - D2: A survey of user opinion of computer system response time
 - D3: The EPS user interface management system
 - D4: System and human system engineering testing of EPS
 - D5: Relation of user perceived response time to error measurement
 - D6: The intersection graph of paths in trees
 - D7: Graph minors IV: Widths of trees and well-quasi-ordering
 - D8: The generation of random, binary, ordered trees
 - D9: Graph minors: A survey

ファイルの読み込みと行列作成

```
# 文書ディレクトリの指定
td <- (“/home/user/texts/”)
# stopwords をロード
data(stopwords_en)
# ディレクトリを読み込み
# ターム・文書行列作成
myMatrix <- textmatrix(td,
  stopwords = stopwords_en,
  stemming = TRUE)
```

```
# 出力を編集
> myMatrix
```

	docs								
terms	D1	D2	D3	D4	D5	D6	D7	D8	D9
abc	1	0	0	0	0	0	0	0	0
application	1	0	0	0	0	0	0	0	0
comput	1	1	0	0	0	0	0	0	0
human	1	0	0	1	0	0	0	0	0
interfac	1	0	1	0	0	0	0	0	0
machin	1	0	0	0	0	0	0	0	0
opinion	0	1	0	0	0	0	0	0	0
respons	0	1	0	0	1	0	0	0	0
survey	0	1	0	0	0	0	0	0	1
syst	0	1	1	2	0	0	0	0	0

もとの頻度行列と検索語との距離

```
myQuery <-  
  query("user interface",  
        rownames(myMatrix),  
        stemming = TRUE)  
myMat.Que <-  
  cbind(myMatrix,  
        myQuery)  
as.matrix(round(  
  cosine(myMat.Que),  
  dig = 2)[,10])
```

出力を編集

```
[, 1]  
D1  0.29  
D2  0.27  
D3  0.63  
D4  0.00  
D5  0.27  
D6  0.00  
D7  0.00  
D8  0.00  
D9  0.00  
QU  1.00
```

特異値分解

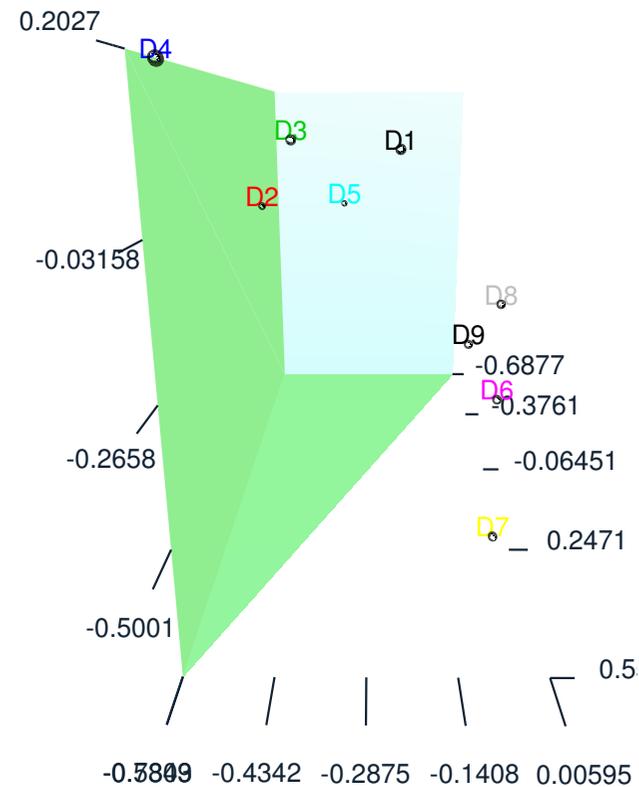
```
# LSA を実行してみる
myLSAspace <-
  lsa(myMatrix,
      dimcalc_share(0.4))
myLSAspace
round(myLSAspace$tk,
      digits= 2)
```

```
# 出力を編集
```

```
      [,1]      [,2]      [,3]
abc      -0.06      0.02      0.07
applicat -0.06      0.02      0.07
comput   -0.22     -0.01     -0.04
human    -0.22      0.09      0.26
interfac -0.18      0.05      0.13
machin   -0.06      0.02      0.07
opinion  -0.16     -0.03     -0.11
respons  -0.26     -0.08     -0.35
survey   -0.18     -0.16     -0.09
syst     -0.58      0.13      0.33
```

文書ベクトルの3次元表現

```
new3Doc <-  
  t(myLSAspace$tk)  
  %*% myMatrix  
rgl.open()  
rgl.bg(color =  
  c("white", "black"))  
rgl.spheres(new3Doc[1,],  
  new3Doc[2,],  
  new3Doc[3,])  
  
rgl.texts(new3Doc[1,],  
  new3Doc[2,],  
  new3Doc[3,],  
  rownames(myLSAspace$dk))
```



北研二他 (2002) 『情報検索アルゴリズム』 共立出版

3次元文書空間での検索

```
myQuery3 <-  
  query("user interface",  
        rownames(myLSAspace$tk),  
        stemming = TRUE )  
new3Query <-  
  t(myLSAspace$tk)  
  %*% myQuery3  
myMat.Que3 <-  
  cbind(new3Doc,  
        new3Query)  
as.matrix(round(  
  cosine(myMat.Que3),  
  dig = 2)[,10])
```

	[, 1]
D1	0.63
D2	0.98
D3	0.82
D4	0.56
D5	0.76
D6	-0.04
D7	-0.04
D8	-0.06
D9	0.17
QU	1.00

tm パッケージ

- tm_0.2-3 by Ingo Feinerer
 - S4 クラスに基づく実装
 - 各種フォーマット・メタ情報 (XML, HTML, Gmane, RSS) への対応
 - 空白, stopwords の処理 (英独露など 13 言語に対応)
 - stemming の処理 (11 言語に対応)
 - 文章・ターム行列の作成
 - 各種重み付け (tf-idf など)

Feinerer: tm パッケージによる解析例

- テキストクラスタリング
 - Reuters-21578 データセットのサブテキスト (1720 文書)
 - bag of words : 単語頻度情報
 - 古典的 k-mean 法 (`kmeans()`)

A.Karatzoglou & I. Feinerer: Text clustering with string kernels in R: Advances in Data Analysis, 2006.

H.Lodhi et al.: Text Classification using String Kernels: Machine Learning Research 2, 2002

Feinerer: tm パッケージによる解析例

- テキストクラスタリング
 - Reuters-21578 データセットのサブテキスト (1720 文書)
 - bag of words : 単語頻度情報
 - 古典的 k-mean 法 (`kmeans()`)
 - String Kernels : 文字の位置情報 (`stringdot()`)
 - **kernlab** パッケージによる kernel ベースの技法
 - Kernel k -means (`kkmeans()`)
 - Spectral Clustering (`specc()`)

A.Karatzoglou & I. Feinerer: Text clustering with string kernels in R: Advances in Data Analysis, 2006.

H.Lodhi et al.: Text Classification using String Kernels: Machine Learning Research 2, 2002

日本語テキスト

- 日本語テキスト解析
 - 文字解析
 - **grubsub** パッケージを利用

日本語テキスト

- 日本語テキスト解析

- 文字解析

- **grubsub** パッケージを利用

- 形態素解析

- 「すもももももももものうち」

日本語テキスト

■ 日本語テキスト解析

■ 文字解析

- **grubsub** パッケージを利用

■ 形態素解析

- 「すもももももももものうち」
- 茶釜や和布蕪などの形態素解析器との連携
- すもも も もも も もも の うち
- 名詞, 助詞, ...

和布蕪との C インターフェイスの例

```
#include <Rdefines.h>
#include <Rinternals.h>
#include <mecab.h>
#include <stdio.h>
SEXP mecab(SEXP str){
    SEXP parsed;
    const char input = CHAR(STRING_ELT(str,0));
    mecab_t mecab;    mecab_node_t node;    const char result;
    mecab = mecab_new2 (input);
    result = mecab_sparse_tostr(mecab, input);
    PROTECT(parsed = mkString(result));    UNPROTECT(1);
    mecab_destroy(mecab);
    return(parsed);    }
```

和布蕪との C インターフェイスの例

```
#include <Rdefines.h>
#include <Rinternals.h>
#include <mecab.h>
#include <stdio.h>
SEXP mecab(SEXP str){
    SEXP parsed;
    const char input = CHAR(String_ELT(str,0));
    mecab_t mecab;    mecab_node_t node;    const char result;
    mecab = mecab_new2 (input);
    result = mecab_sparse_tostr(mecab, input);
    PROTECT(parsed = mkString(result));    UNPROTECT(1);
    mecab_destroy(mecab);
    return(parsed);    }
```

```
R CMD SHLIB mecab.c でコンパイル後
> dyn.load("mecab.so")
> .Call("mecab", "すももももももものうち")
"すもも\t 名詞, 一般,*,*,*, すもも, スモモ, スモモ"
"も\t 助詞, 係助詞,*,*,*, も, モ, モ"
```

Rmecabの実装？

- R 上から日本語テキスト処理を一括して行う
 - n-gram などの文字カウント機能 (R の正規表現)
 - mecab へ形態素解析を委託
 - stopword の設定 (名詞のみ etc)
 - ターム文書行列の作成 (**lsa** の関数を利用)

Rmecabの実装？

- R 上から日本語テキスト処理を一括して行う
 - n-gram などの文字カウント機能 (R の正規表現)
 - mecab へ形態素解析を委託
 - stopword の設定 (名詞のみ etc)
 - ターム文書行列の作成 (**lsa** の関数を利用)
- yahoo のトピックス記事の分類
 - 防衛省人事問題, 内閣改造, 中華航空機事故
 - 検索語「防衛」との類似度測定