R 超入門

櫻井彰人

本日の目標

- R言語の概要を知る。
  - 説明を聞く
  - 書いてみる
  - 実行させてみる
  - 説明書を見る

目次

前書: プログラムは何に使うか？

- アイデアが正しいかどうかを調べる
  - 数式
  - データ間の関係
- グラフを書く

- 動かす
- 記録する
- 見せる

Rをつかう

- インストール
  - 参考：RjpWiki→Rのインストール
- 起動
  - デスクトップのアイコンをダブルクリック
  - スタート→すべてのプログラム→R
- 終了
  - 右上の×ボタン→質問に「いいえ」

Rのウィンドウ

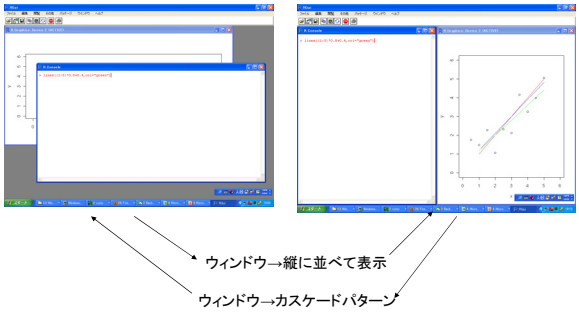

目次

- 前書
- 基本データ型 – ベクトル
  - 作る、代入、読み出し、加算、関数
- 識別子、ヘルプ
- プロット
- 関数の引数 – プロットを例にして
- 再びプロット
- 関数について – 少し丁寧に
- 繰り返しについて
- 補足: 結果の保存

ベクトル

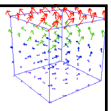

- R で扱えるデータ構造の基本要素にベクトルがある
- ベクトルは、ご存じのように、数値や文字列の列である。:
  - ("altec", "sony", "jbl")
  - (1, 5.2, 10, 7, 2, 21)
  - (3)
- 最後の例は、長さ1のベクトルである

http://www.hulinks.co.jp/software/voxler/images/WebVectorPlot.png

ベクトルを「作る」には

メソッドの名称　メソッドの引数

```
> c(1,5,10, 7, 2, 1)
[1]  1  5 10  7  2  1
```

メソッド実行の結果

```
> c('altec', 'sony', 'jbl')
[1] "altec" "sony" "jbl"
```

文字列は、その左右を、ダブルクォート(")かシングルクォート(')で囲む

長さ1のベクトルを作るときは、c() を書かなくてよい

```
> 3
[1] 3
```

練習問題:
1) 次の要素を持つベクトルを作りなさい
45,5,12,10

2) 次のコマンドの結果、何が起こるか？
c(1:100)

(注) ベクトルは、R において極めて基本的なデータ構造である。R 中の殆どすべてのものは、何らかの意味でベクトルである。勿論、一般には高次元のベクトルである、すなわち、ベクトルのベクトルである

代入

irb とそっくり

irb との違いに注意 ← もっとも、＝も使えます

```
> 4+5              # 4 と 5 の加算
[1] 9
> a<-4             # 変数 a に 4 を代入
> b<-5             # 変数 b に 5 を代入
> a                # 変数 a の値を印字
[1] 4
> b
[1] 5
> a+b              # 変数の加算 a+b (4+5)
[1] 9              # 正しい！
```

#の右は、すべてコメント

ベクトル要素の読み出し

ベクトル要素を取り出すには次のようにする。　Rubyと異なる

```
a[5]        # 第5要素。先頭は第1要素！
```

次のようにしたら、どうなる？

```
a <- c(1,5,10,15,20)

a[c(1,3,5)]

a[1:4]

a[4:1]
```

即レポ1-1

練習

- ベクトルを反転させる（ベクトル要素の並びを左右逆転する）、少なくても2通りの方法を考えて（探して）下さい。

```
a <- c(1,5,10,15,20)      # ベクトルの定義です
                          # それで？
```

http://www.thewisdomjournal.com/Blog/wp-content/uploads/2010/05/reverse.jpg

ベクトルへの加算

- V1 に 1から20の整数からなる配列を代入後
  `> v1 + 10`
  としたらどうなるか？
- 次のものを試してみよう。そして、その規則を推測してください。

```
> a <- c(10,20,30,40)
> b <- c(1,2,3,4)
> c <- c(1.1,2.2)
> d <- c(1,2,3)
> a+b
> a+c
> a+d
```

ベクトルに関する関数

- ベクトルに関する関数はいくつかある。名称は論理的につけられている。例えば、
  - length(): ベクトルの要素数
- そこで、練習問題
  - 要素の値が、1から10000までの整数である配列を作れ（ a:b 構文を用いる)
  - 要素のすべての和（sum）を求めよ
  - 要素の平均値（mean）を求めよ

目次

識別子と名前

- 識別子（identifier）は、

  Identifiers consist of a sequence of letters, digits, the period ('.') and the underscore. They must not start with a digit nor underscore, nor with a period followed by a digit.
- つまり、文字、数字、ピリオド、下線のいずれからなり、先頭は文字（少し例外あり）。
- 名前（names）には、もっと自由な文字列が使えるが、その値の読書きには get と assign を使う

http://blog.viarezo.com/wp-content/uploads/2012/05/identifier-bon-repreneur.jpg

即レポ1-2

ヘルプ

- R には関数が多すぎる（それがメリットなのだが）。そのため、ヘルプが結構充実している。
- その使い方は

```
?関数名                  # または
help(関数名)             # または
?"関数名"                # または
help("関数名")           # または
help.search(何か)        # 'fuzzy' 検索
```

練習問題

- 関数 sample() と sort() のヘルプを調べ、1から10000を要素とするベクトルに（結果を予想して）適用しなさい
- ところで、RSiteSearch("sample") とすると何が起こるか？

http://www.smartdriving.co.uk/Assets/Driving_Assets/Photos/help_keyboard.jpg

目次

- 前書
- 基本データ型 – ベクトル
  – 作る、代入、読み出し、加算、関数
- 識別子、ヘルプ
- プロット
- 関数の引数 – プロットを例にして
- 再びプロット
- 関数について – 少し丁寧に
- 繰り返しについて
- 補足: 結果の保存

ベクトルのプロット

- まずプロットするデータを作る。

```
d <- rnorm(100)  # 100 個の正規乱数
```

- 次のを試してみよう:

```
plot(d)
plot(d, type="l")
barplot(d)
hist(d)
```

プロットする plot も関数である

- 何が図示されているか、確認してください。

次ページのようにするには、plot の前に、一度、par(mfrow=c(2,2)) として下さい

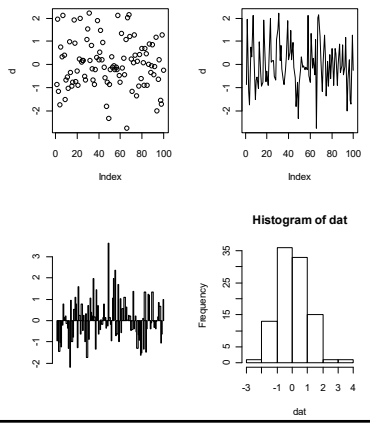

プロット・オプション

- 次のようにオプションが指定できる

plot(あるベクトル, col="blue")

要は、関数の引数！

基本的なオプションとしては、次のようなものがある。複数個指定が可能

```
type= "l", "b"
col= "pink"
main= "important plot"
```

構文規則では、これらのオプションは、plot() の引数である

目次

- 前書
- 基本データ型 – ベクトル
  – 作る、代入、読み出し、加算、関数
- 識別子、ヘルプ
- プロット
- 関数の引数 – プロットを例にして
- 再びプロット
- 関数について – 少し丁寧に
- 繰り返しについて
- 補足: 結果の保存

引数について

関数は、大抵の場合、何らかの入力が必要となる。
例えば、 plot(d). ここで 'd' は名前なし（無名）引数であり,
これがうまくいくのは, plot() では, 第一引数が x 値（「y値」の書き間違いではない）であると仮定しているからである。
plot() の場合は, 名前付き引数も使える。この場合は、plot(x=d) とすればよい（plot(d) と同じ結果）。
「x=」のように書く引数を名前付き引数という（xが名前である）。
引数の個数が多いときには、多くの引数が（誤りを避けたり、default値を用いるようにするため）名前付き引数となっている。

plot(あるベクトル, col="blue", type="s")

名前なし引数は順序が大切

- 名前なし引数は、その順序で、意味が決まっている（勿論、関数ごとに）
  - "普通" ですね。
- 次の違いを知ろう

```
a <- rnorm(100)
b <- rnorm(100)*2
plot(a,b)
plot(b,a)
plot(x=b, y=a)
```

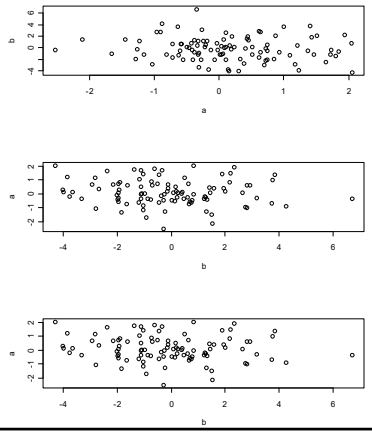

目次

plot()用パラメータ

- 引き続く plot() に共通なパラメータを, par() で設定することができる. 非常にたくさんのパラメータがある. 試しに, ?par としてみてください。
- 例えば:
  mfrow() と mfcol(); 一ページ（ウィンドウ一個）に複数のプロットするためのもの。配置方向と個数を示す。
  - 長さ2のベクトルを値とする。それにより一ページ中の、プロットするセルの個数が決まる（次頁）

```
> par( mfrow=c(3,1) )
> plot (a,b)
> plot (b,a)
> plot(x=a, y=b)
>
```

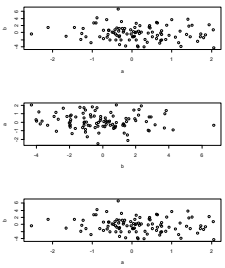

```
> par( mfrow=c(2,2) )
> plot (a,b)
> plot (b,a)
> plot(x=a, y=b)
>
```

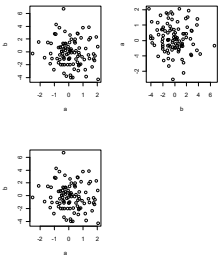

```
> par( mfcol=c(3,1) )
> plot (a,b)
> plot (b,a)
> plot(x=a, y=b)
>
```

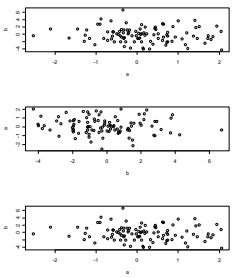

```
> par( mfcol=c(2,2) )
> plot (a,b)
> plot (b,a)
> plot(x=a, y=b)
>
```

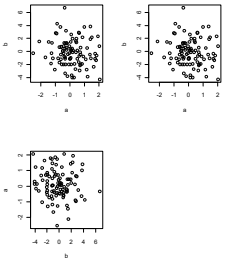

即レポ1-3

課題

- 一行に3個のグラフをプロットしてください

グラフの重ね書き1

- 一つのグラフの上に他のグラフを重ねたい（2個や3個のグラフを重ねがきしたい）場合には、例えば、lines() や points() を使えばよい。

```
> plot(b, type="l", col="blue")
> lines(a, col="red")
>
```

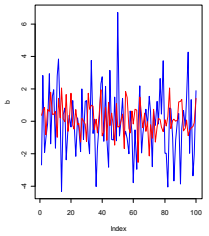


```
a<-rnorm(100)
b<-rnorm(100)*2
```

プロットの重ね書き2

- コマンドによっては、add=T をパラメータとすることで、重ねがきができます。

```
> plot( (0:20)*(pi/10),cos( (0:20)*(pi/10) ) )
> curve(cos,0,2*pi,col=2, add=T)
>
```

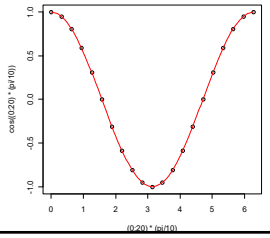

プロットの重ね書き3

- コマンドによっては、par(new=T) とすることにより、重ね書きができます。

```
> plot( (0:20)*(pi/10),cos( (0:20)*(pi/10) ) )
> par(new=T)
> plot(cos,0,2*pi, col=2)
>
```

縦軸・横軸のラベルやティックが重ね書きになるので、注意。どちらかのコマンドで、軸のラベルを書かないようにするのが、一方

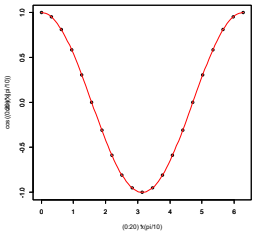

軸の上下限

- x軸、y軸の上下限を変更するには、

```
x軸の上下限: xlim = c( 開始点, 終点)
y軸の上下限: ylim = c( 開始点, 終点)
```

例

```
plot(a, type="l", col="blue")
```

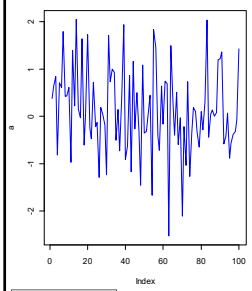


```
plot(a, type="l", col="blue", ylim=c(-5,5))
```

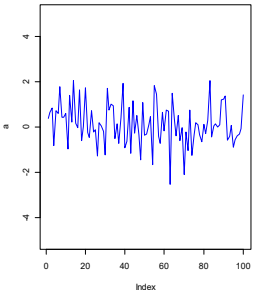


```
a<-rnorm(100)
b<-rnorm(100)*2
```

目次

- 前書
- 基本データ型 – ベクトル
  - 作る、代入、読み出し、加算、関数
- 識別子、ヘルプ
- プロット
- 関数の引数 – プロットを例にして
- 再びプロット
- 関数について – 少し丁寧に
- 繰り返しについて
- 補足: 結果の保存

関数の定義

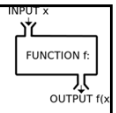

- 何度も(そっくりなことを)行う場合、それを関数として定義しておくのが妥当

  例: 引数を x とするとき、x^2+x+1 を返す関数

```
my_f<- function(x) {
       return(x^2 + x + 1)
}
```

関数名: 適宜　　関数であることを宣言

引数. 関数の定義本体で使用する

値を、関数の値とし、この関数の計算を終了する

{} で括られた部分が、関数の本体の定義

http://upload.wikimedia.org/wikipedia/commons/thumb/3/3b/Function_machine2.svg/159px-Function_machine2.svg.png

関数の使用例

```
> myF <- function(x) {
+   return(x^2 + x + 1)
+ }
> myF(10)
[1] 111
> myF(20)
[1] 421
>
```

```
myF <- function(x) {
  return(x^2 + x + 1)
}
myF(10)
myF(20)
```

即レポ1-4

練習問題

- x^3+x^2+x+1 を計算する関数を作りなさい。正しいことを検証しなさい
- x が与えられたとき、1+2+…+x を計算する関数を作りなさい。正しいことを検証しなさい。
- x と y が与えられたとき、x+(x+1)+…+y を計算する関数を作りなさい。正しいことを検証しなさい

関数の値(戻り値、返り値)

- R では、関数本体内で、最後に実行した式の結果が、関数の値として、戻される
- ただし、return() という関数を使うと、return 関数引数の演算結果を値(return value, 戻り値、返り値)として、呼び出し元に戻る

「戻り値」の例

```
> myF <- function(x){
+   x^2 + x + 1
+ }
> myF(10)
[1] 111
> myF(20)
[1] 421
>
```

```
myF <- function(x) {
  return(x^2 + x + 1)
}
myF(10)
myF(20)
```

```
> myF <- function(x){
+   v <- x^2 + x + 1
+   return( v )
+ }
> myF(10)
[1] 111
> myF(20)
[1] 421
>
```

```
myF <- function(x) {
  v <- x^2 + x + 1
  return( v )
}
myF(10)
myF(20)
```

引数の個数は重要

```
> myF <- function(x,y){
+   sum( x:y )
+ }
> myF(10)
 以下にエラー x:y :  'y'が見つかりません
> myF(1,10)
[1] 55
> myF(10,1)
[1] 55
>
```

```
myF <- function(x,y){
  sum( x:y )
}
myF(10)
myF(20)
```

引数の個数に柔軟対処するには

- 仮引数に名前をつけることができ、デフォールト値が設定できる

```
> myF <- function(x=1,y=10){
+   sum( x:y )
+ }
> myF(9)
[1] 19
> myF(,2)
[1] 3
> myF(x=9)
[1] 19
> myF(y=2)
[1] 3
> myF(y=2,x=9)
[1] 44
>
```

```
myF <- function(x=1,y=10){
  sum( x:y )
}
myF(9)
myF(,2)
myF(x=9)
myF(y=2)
myF(y=2,x=9)
```

目次

- 前書
- 基本データ型 – ベクトル
  - 作る、代入、読み出し、加算、関数
- 識別子、ヘルプ
- プロット
- 関数の引数 – プロットを例にして
- 再びプロット
- 関数について – 少し丁寧に
- 繰り返しについて
- 補足: 結果の保存

繰返し

- 同じ処理（平均値の計算）を複数個のデータ（1月の売上げ、2月の売上げ、、、、）に対し適用したいことはしばしばある。
- このような繰返し処理を行わせる道具が loop であり、iterator である。

http://poco.phys.tohoku.ac.jp/fractals/self-affine/fig2-1.gif

繰返しの例

```
> for(i in 5:8){
+   print(i)
+ }
[1] 5
[1] 6
[1] 7
[1] 8
>
```

```
for(i in 5:8){
  print(i)
}
```

```
myF <- function( x ) {
  for(i in x){
    print(i)
  }
}
```

勿論、関数の中でも、繰返しは使えます。

```
> myF <- function( x ) {
+   for(i in x){
+     print(i)
+   }
+ }
> myF(1:3)
[1] 1
[1] 2
[1] 3
> myF( rnorm(4) )
[1] 0.7225764
[1] -1.779531
[1] 1.212787
[1] -0.6368527
>
```

繰返しの例（続）

- ベクトル（配列）に対する繰返しは、Rubyと同様に、要素に対する繰返しと、要素番号（index）に対する繰返しとがある。

```
> b <- c(2,7,1,8)
> for(e in b){
+   print( e )
+ }
[1] 2
[1] 7
[1] 1
[1] 8
>
```

```
b <- c(2,7,1,8)
for(e in b){
  print( e )
}
```

```
> b <- c(2,7,1,8)
> for(i in 1:length(b)){
+   print( b[i] )
+ }
[1] 2
[1] 7
[1] 1
[1] 8
>
```

1 からベクトルの長さまで。Rubyでは 0 から長さ–1 である。

```
b <- c(2,7,1,8)
for(i in 1:length(b)){
  print( b[i] )
}
```

目次

- 前書
- 基本データ型 – ベクトル
  - 作る、代入、読み出し、加算、関数
- 識別子、ヘルプ
- プロット
- 関数の引数 – プロットを例にして
- 再びプロット
- 関数について – 少し丁寧に
- 繰り返しについて
- 補足: 結果の保存

グラフのコピー

- グラフがあるウィンドウ上で、右クリックし、「メタファイルファイルにコピー」「ビットマップにコピー」

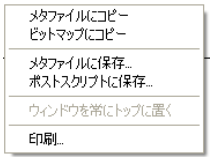

R-console のコピー

- 編集 → 全て選択 → コピー

  予め、編集 → コンソール画面を消去 (Ctrl+l) しておき、必要なものを改めて実行してから、上記操作を行う。

  （勿論、コピーしてから編集するのもOK）

最後に

- R は、プログラミング言語である。
- 統計計算用に、いろいろな道具が用意されている
  - 具体的な内容は、順次
- 機械学習の道具もいろいろあり
  - これも、講義の進展に従い、順次
- Rを使って、機械学習のアルゴリズムを試してみよう！

補足

要約統計量（の例）

- hist(): ヒストグラム表示。
- mean(): 平均値
- median(): メディアン
- summary(): クォンタイル他

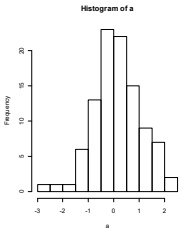


```
> summary(a)
    Min.  1st Qu.   Median     Mean  3rd Qu.     Max.
-2.53100 -0.41550  0.07624  0.13130  0.71530  2.05200
```

経験度数分布

- 経験度数分布（経験相対頻度分布、累積度数分布、経験分布） ecdf (empirical cumulative distribution function) は、次のようにして表示することができる。

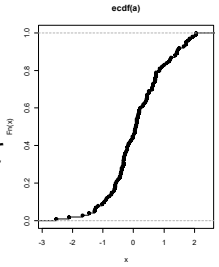


```
> ecdf(a)
Empirical CDF
Call: ecdf(a)
 x[1:100] = -2.5311, -2.1125, -1.6676,  ..., 2.0393, 2.0521
> plot(ecdf(a))
```

```
a<-rnorm(100)
b<-rnorm(100)*2
```

経験度数分布（続）

- データ数を減らして、見やすくしてみました。

```
> a1<-rnorm(10)
> a1 <- c(a1,5,6,10)
> plot(ecdf(a1))
>
```

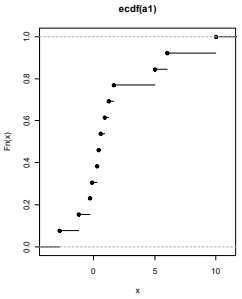


```
a<-rnorm(100)
b<-rnorm(100)*2
```

箱型図(箱ひげ図)

- boxplot です

```
> a1<-rnorm(10)
> a2 <- c(a1,5,6,10)
> boxplot(a1)
> rug(a1,side=2)
> boxplot(a2)
> rug(a2,side=2)
```