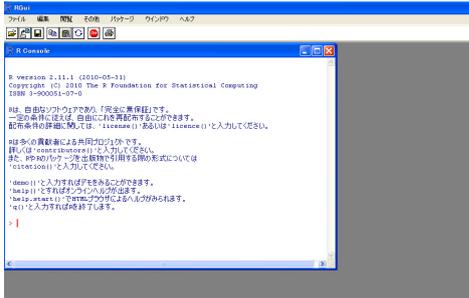


R 入門

櫻井彰人

R 環境

- プロンプト文字: >
- 現在のディレクトリ(working directory): `getwd()`
- ディレクトリの変更: `setwd("c:/R")`
- ヘルプ: `?log` または `help(log)`
 - "fuzzy search" には, `??log`
 - 言語に属するキーワードは、ダブルクォートで括る:
 - `?"for"`, `help("for")`, `??"for"`
- An Introduction to R
 - <http://cran.r-project.org/doc/manuals/R-intro.html>



まずは計算

• 算術計算

```
> -27*12/21
[1] -15.42857

> sqrt(10)
[1] 3.162278

> log(10)
[1] 2.302585

> log10(2+3*pi)
[1] 1.057848

> exp(2.7689)
[1] 15.94109

> (25 - 5)^3
[1] 8000

> cos(pi)
[1] -1

> prod(3:1)
[1] 6

# 10.9.8.7.6.5.4
> prod(10:4)
[1] 604800

> prod(10:4)/prod(40:36)
[1] 0.007659481

> choose(5, 2)
[1] 10

> 1/choose(5, 2)
[1] 0.1
```

Rの値

```
> 2
[1] 2
> 3.1
[1] 3.1
> c(1,2,3,4)
[1] 1 2 3 4
> class(3)
[1] "numeric"
> class(c(1,2,3,4))
[1] "numeric"
> T
[1] TRUE
> TRUE
[1] TRUE
> F
[1] FALSE
> 3:5
[1] 3 4 5
> class(3:5)
[1] "integer"

> "string"
[1] "string"
> class("string")
[1] "character"
> c(1,"string",3.1)
[1] "1" "string" "3.1"
> class(c(1,"string",3.1))
[1] "character"
```

Rの変数

- 大文字・小文字は区別される


```
a <- 5
A <- 7
B <- a+A
```
- 識別子中に空白はダメ


```
var a <- 5
```
- ピリオドはOK. しかし、使わない方が無難


```
var.a <- 5
var.b <- 10
var.c <- var.a + var.b
```

R の式

- 変数 <- 式
- 変数 <- 関数名(引数(達))
`r <- lm(y ~ x)` # linear model fitting
- 算術演算子と比較演算子と論理演算子の例

<code>x + y</code>	<code>x == 5</code>
<code>x - y</code>	<code>x != 5</code>
<code>x * y</code>	<code>y < x</code>
<code>x / y</code>	<code>x > y</code>
<code>x ^ y</code>	<code>z <= 7</code>
	<code>p >= 1</code>

`A & B`
`A | B`
`!`

if 文

```
if ( 論理式 ) {  
  文s  
} else {  
  文s  
}
```

`else` はなくてもよい
`else` は一番近い `if` に繋がる

繰り返し

```
for(i in 1:5) {  
  print(i*i)  
  i <- i+sqrt(i)  
}
```

出力
[1] 1
[1] 4
[1] 9
[1] 16
[1] 25

```
i <- 1  
while(i<=10) {  
  print(i*i)  
  i <- i+sqrt(i)  
}
```

出力
[1] 1
[1] 4
[1] 11.65685
[1] 27.68836
[1] 57.0912

数値列を作る

- 列 `seq(from, to, by)`
- 1 から12まで(1刻み)の配列を値とする変数を作るには:
`> x <- 1:12`
`> x`
[1] 1 2 3 4 5 6 7 8 9 10 11 12

seq の使用例

```
> seq(12)  
[1] 1 2 3 4 5 6 7 8 9 10 11 12  
  
> seq(4, 6, 0.25)  
[1] 4.00 4.25 4.50 4.75 5.00 5.25 5.50 5.75 6.00
```

`seq(from = 1, to = 1, by = ((to - from)/(length.out - 1)), length.out = NUL)`

同じ数字パターンを繰り返すには

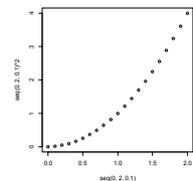
- Repetition - `rep(x, times, ...)`
`> rep(10, 3)`
[1] 10 10 10

`> rep(c(1:4), 3)`
[1] 1 2 3 4 1 2 3 4 1 2 3 4

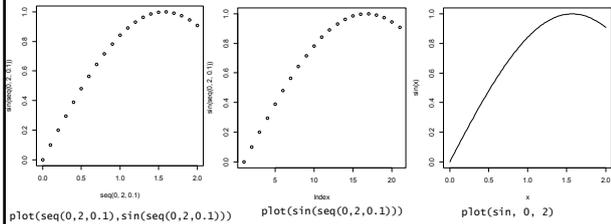
`> rep(c(1.2, 2.7, 4.8), 5)`
[1] 1.2 2.7 4.8 1.2 2.7 4.8 1.2 2.7 4.8 1.2 2.7 4.8 1.2 2.7 4.8

グラフ

```
plot(seq(0,2,0.1),seq(0,2,0.1)^2)
```

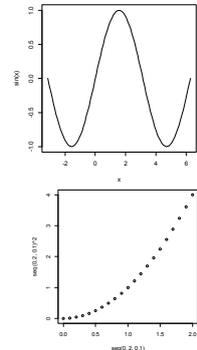


グラフ



グラフ

`plot(sin, -pi, 2*pi)`
`plot(seq(0,2,0.1),seq(0,2,0.1)^2)`



いろいろな例

```

> x <- c(1:10)
> x
[1] 1 2 3 4 5 6 7 8 9 10
> x[(x>8) | (x<5)]
[1] 1 2 3 4 9 10
> x > 8
[1] FALSE FALSE FALSE FALSE FALSE FALSE
[8] FALSE TRUE TRUE
> x < 5
[1] TRUE TRUE TRUE TRUE FALSE FALSE
[8] FALSE FALSE FALSE
> x > 8 | x < 5
[1] TRUE TRUE TRUE TRUE FALSE FALSE
[8] FALSE TRUE TRUE
> x[c(T,T,T,T,F,F,F,T,T)]
[1] 1 2 3 4 9 10
> subset(x, (x>8) | (x<5))
[1] 1 2 3 4 9 10
    x <- c(1:10)
    x[(x>8) | (x<5)]
    x <- c(1:10)
    x
    x > 8
    x < 5
    x > 8 | x < 5
    x[c(T,T,T,T,F,F,F,T,T)]
    subset(x, (x>8) | (x<5))
    
```

いろいろな例

```

> m <- matrix(c(1,2,4,1), ncol=2)
> m
     [,1] [,2]
[1,]    1    4
[2,]    2    1
> solve(m)
     [,1] [,2]
[1,] -0.1428571  0.5714286
[2,]  0.2857143 -0.1428571
    
```

いろいろな例

```

> x <- 1
> y <- 2
> ls()
[1] "x" "y"
> x2 <- 9
> y2 <- 10
> ls()
[1] "x" "x2" "y" "y2"
> ls(pattern="x")
[1] "x" "x2"
> rm(x2,y)
> ls()
[1] "x" "y2"
    
```

ワークスペース内にあるオブジェクトをリストする
 リストするときに、パターンを指定することが可能
 x2とyをワークスペースから削除

Rのワークスペース

- Rを使用している時に生成されたオブジェクトは記憶されている。こうしたオブジェクトの集合を、Rでは、ワークスペースと呼んでいる。
- Rのワークスペースは、自分で保存しない限り、失われる。
- Rを終了するときに、ワークスペースを保存するか否かを聞かれる。保存を選ぶとその時のワーキングディレクトリに .RData というファイル名で保存される。
- または、コマンドで随時保存できる。

R のワークスペース

- 保存するには、

```
## 現在のワーキングディレクトリに保存。ファイル名は .Rdata になる。
save.image()
## 現在のワーキングディレクトリを知るgetwd()
## フルパスとファイル名を指定する
save.image("C:\\Exercises\\R\\R-2.14.0\\Test.RData")
## または
save.image("C:/Exercises/R/R-2.14.0/Test.RData")
```

- 回復するには

```
## 現在のワーキングディレクトリからであれば、
load(".Rdata")
## 任意のディレクトリからは
load("C:\\Exercises\\R\\R-2.14.0\\Test.RData")
## または
load("C:/Exercises/R/R-2.14.0/Test.RData")
```

ワーキングディレクトリ

- 現在のワーキングディレクトリを知るには

```
getwd()
```

- 設定するには

```
mydirectory <- "c:/docs/mydir"
setwd(mydirectory)
## または
setwd("c:/docs/mydir")
```

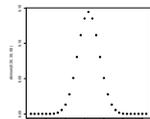
確率の計算

二項分布

$$P(k | n, p) = C_k^n p^k (1-p)^{n-k}$$

```
dbinom(k, n, p)
```

```
> dbinom(2, 3, 0.60)
[1] 0.432
```



例:

```
plot(dbinom(0:30, 30, 0.5))
plot(dbinom(0:30, 30, 0.5, log))
```

ポアソン分布

$$P(X = k | \lambda) = \frac{e^{-\lambda} \lambda^k}{k!}$$

```
dpois(k, \lambda)
```

$$P(X = 2 | \lambda = 1) = \frac{e^{-1} 1^2}{2!} = 0.1839$$

```
> dpois(2, 1)
[1] 0.1839397
```

確率の計算

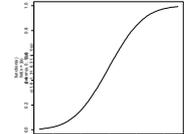
正規分布

$$P(a \leq X \leq b) = \int_a^b f(x) dx$$

$$\text{pnorm}(a, \text{mean}, \text{sd}) = \int_{-\infty}^a f(x) dx = P(X \leq a | \text{mean}, \text{sd})$$

高さが、平均 156 標準偏差 4.6 の正規分布に従うとき、高さが150以下である確率は

```
> pnorm(150, 156, 4.6)
[1] 0.0960575
```



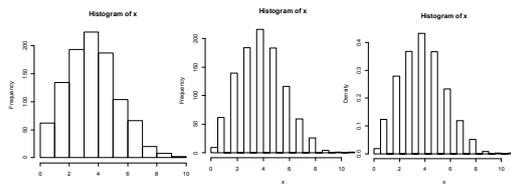
他の例:

```
plot(function(x) pnorm(x, 0, 1), xlim=c(-2.5, 2.5))
plot(function(x) pnorm(x, 0, 1), -2.5, 2.5)
```

簡単なシミュレーション: 二項分布

- ある母集団で 20% が病気であったとしよう。調査時にはこの母集団から20人ランダムに選ぶとする。調査ごとに、何人かは病気であろう。この人数を x とする。1000回調査したときの、この x の分布はどうなるか？

```
x <- rbinom(1000, 20, 0.20)
hist(x)
hist(x, breaks=30)
hist(x, breaks=30, freq=F)
```

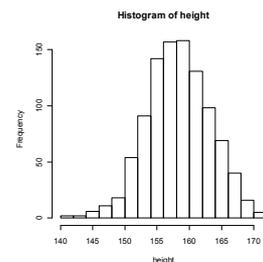


正規分布の場合

- 日本人の20~24歳女性では、平均身長は158.45cm、標準偏差 5.02cm である。この分布から1000回サンプルしたときのヒストグラムをつくろう

```
height <- rnorm(1000, mean=158.45, sd=5.02)
hist(height, breaks=18)
```

breaks には、数字や配列の他、"Sturges" (nclass.Sturges), "Scott" (nclass.scott) や "FD"/"Freedman-Diaconis" (nclass.FD) が標準で指定できる



年齢別体格測定の結果 http://www.mext.go.jp/b_menu/houdou/20/10/08092414/002.xls

サンプリング

- 40人の被験者がいる(1,2,3,...,40)。ランダムに5人を選びたい。どうしたらよいか？

```
> sample(1:40, 5)
[1] 30 29 32 17 6
> sample(1:40, 5)
[1] 39 11 32 9 33
> sample(1:40, 5)
[1] 37 10 21 35 11
> sample(1:40, 5)
[1] 4 32 28 39 15
>
```

重複を許したサンプリング

- 重複を許したサンプリング: 10人の被験者を50人のなかから選びたい。しかし、重複してよい。どうしたらよいか。

```
> sample(1:50, 10, replace=T)
[1] 49 29 7 33 19 19 18 44 7 45
```

Dataframe

Excelのシート	data.frame
列	変数 (variable)
行	観測 (observations)

a	ka
0.117	0.155
0.196	0.127
0.106	0.115
0.16	0.068
0.143	0.105
0.222	0.083
0.259	0.102
0.136	0.173
0.107	0.144
0.139	0.083

Data frame: songs

変数: a, ka

観測数: 10

csvファイルをメモリに読み込んだようなもの
列名でアクセスできる - songs["a"]

c()を用いた直接書込み

```
> a <- c(0.117,0.196, 0.106, 0.16, 0.143, 0.222, 0.259, 0.136, 0.107, 0.139)
> ka <- c(0.155, 0.127, 0.115, 0.068, 0.105, 0.083, 0.102, 0.173, 0.144, 0.083)
> songs <- data.frame(a, ka)
> attach(songs)
```

The following object(s) are masked by_ '.GlobalEnv':

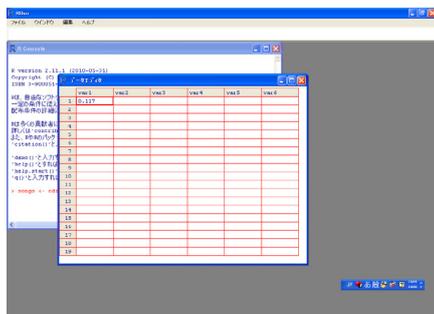
```
a, ka
> songs
  a ka
1 0.117 0.155
2 0.196 0.127
3 0.106 0.115
4 0.160 0.068
5 0.143 0.105
6 0.222 0.083
7 0.259 0.102
8 0.136 0.173
9 0.107 0.144
10 0.139 0.083
>
```

これ以降、songs\$aで、aの列ベクトルが参照できる。なお、aとkaの代わりにあとかを用いることもできる。試してみてください

a	ka
0.117	0.155
0.196	0.127
0.106	0.115
0.16	0.068
0.143	0.105
0.222	0.083
0.259	0.102
0.136	0.173
0.107	0.144
0.139	0.083

edit(data.frame())を用いたデータ入力

```
songs <- edit(data.frame())
```



ファイルからの読み込み: read.table()

```
あかきたなはほちのむきんふがほほほほほ a l u = 0
0.117 0.155 0.039 0.136 0.107 0.058 0.068 0.117 0.039 0.019 0.01 0.029 0.019 0.019 0.01 0.029 0.029 0 0.34 0.117 0.117
0.144 0.252
0.196 0.127 0.049 0.137 0.088 0.029 0.089 0.069 0.118 0 0 0.01 0.02 0.02 0 0.01 0.039 0 0.275 0.167 0.137 0.088 0.314
0.106 0.115 0.139 0.042 0.119 0.053 0.083 0.097 0.108 0.018 0 0.009 0.009 0.062 0 0.018 0.038 0 0.416 0.177 0.124 0.097
0.144
0.14 0.088 0.123 0.091 0.082 0.014 0.11 0.041 0.091 0.003 0.014 0.05 0.041 0.009 0.027 0.032 0.041 0 0.301 0.247 0.137
0.11 0.205
0.149 0.105 0.095 0.042 0.039 0.029 0.086 0.019 0.037 0 0 0.081 0.062 0.037 0.01 0.037 0.01 0.033 0.303 0.174 0.176
0.09 0.232
0.222 0.083 0.056 0.083 0.139 0.069 0.111 0.042 0.056 0 0 0.014 0.014 0.028 0.014 0.042 0.028 0 0.232 0.278 0.208 0.083
0.208
0.239 0.102 0.102 0.137 0.046 0.037 0.083 0.019 0.028 0.009 0.009 0 0.074 0.065 0 0 0.028 0 0.213 0.204 0.241 0.083
0.234
0.136 0.179 0.042 0.042 0.136 0.049 0.049 0.042 0.099 0.062 0.012 0.025 0.012 0.025 0 0 0.481 0.148 0.16
0.048 0.15
0.107 0.144 0.048 0.102 0.112 0.086 0.091 0.037 0.102 0.021 0.011 0.021 0 0.043 0.005 0.032 0.037 0 0.321 0.187 0.134
0.123 0.238
0.139 0.083 0.046 0.093 0.167 0.037 0.148 0.083 0.111 0 0.009 0 0.009 0.009 0.046 0.019 0 0 0.239 0.241 0.185 0.093
0.222
```

```
setwd("d:/R/Sample")
songs <- read.table("Sample01.txt", header=TRUE)
```


データからデータを作る

```

bfp <- c(16.6, 16.4, 17.7, 17.3, 17.5, 15.2, 17.5, 18.1, 17.5, 17.7, 17.1, 16.4, 17.3, 17.3, 16.2,
17.5, 18.2, 17.3, 15.9, 16.3, 17.2, 16.1, 16.1, 18.3, 17.9, 17.6, 16.8, 16.3, 16.9, 15.2, 17
16.9, 16.8, 15.2, 17.9, 18.3, 18.3, 16.8, 16.6, 16.6, 17.8, 18.1, 17.5, 15.2, 17.7, 18.1, 1
6.8, 16.3, 17.1, 16.1, 17.1, 15.9, 16.4, 16.9, 16.9, 16.4, 17.1, 16.9, 16.4, 17.4, 17.4, 17
7, 17.1, 16.9, 17.1, 18.4, 17.7, 17.4, 17.8, 17.1, 15.7, 15.7, 17.2, 17.9, 17.2, 14.6, 16.8,
17.3, 16.5, 16.7, 17.2, 19.3, 16.2, 15.9, 17.7, 16.9, 17.6, 17.2, 16.8, 17.1, 18.1, 17.1, 16
2, 17.1, 17.9, 16.3, 17.1, 17.7, 17.2, 16.8, 16.9, 17.3, 15.5, 16.6, 18.1, 18.9, 17.7, 17.4,
16.4, 15.3, 16.4, 17.4, 16.7, 15.8, 16.9, 14.8, 15.1, 15.2, 16.4, 16.4, 16.6, 16.2, 13
9, 13.9, 14.5, 15.7, 16.7, 17.7, 16.8, 16.4, 14.5)

bfpRange <- rep(0, length(bfp))
bfpRange[bfp <= 15.5] <- -1
bfpRange[bfp > 15.5 & bfp <= 18.5] <- 2
bfpRange[bfp > 18.5] <- 3
data <- data.frame(bfp, bfpRange)
head(data, 10)

```

bfp	bfpRange	
1	16.6	0
2	16.4	0
3	17.7	0
4	17.3	0
5	17.5	0
6	15.2	-1
7	17.5	0
8	18.0	0
9	17.5	0
10	17.0	0

```

bfpRange <- rep(-10, length(bfp))
bfpRange <- replace(bfpRange, bfp <= 15.5, 1)
bfpRange <- replace(bfpRange, bfp > 15.5 & bfp <= 18.5, 2)
bfpRange <- replace(bfpRange, bfp > 18.5, 3)

```

データの度数分布

- 階級を作り、階級ごとにデータの出現度数を数えればよい。

```

> library(Hmisc)
> grouped <- cut2(bfp, g=4)
> table(grouped)
grouped
[13.9,16.5) [16.5,17.0) [17.0,17.5) [17.5,19.3]
42          26          33          32

```

次に cut2 がここにある
4区間に分割する
頻度を数える

図みに grouped というデータは [17.5, 19.3) の区間に32個

```

> head(grouped, 10)
[1] [16.5,17.0) [13.9,16.5) [17.5,19.3] [17.0,17.5) [17.5,19.3] [13.9,16.5)
[7] [17.5,19.3] [17.5,19.3] [17.5,19.3] [17.0,17.5)
Levels: [13.9,16.5) [16.5,17.0) [17.0,17.5) [17.5,19.3]

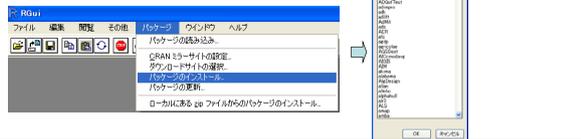
```

パッケージのインストール

- まず CRAN ミラーサイトの設定



- 次に パッケージのインストール



まとめにかえて

- R は、プログラミング言語である。
- インタラクティブにも使える
- 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！