Úvod do R

Petr Marek

23. - 24. listopadu 2021

Obsah prezentace

Důležité odkazy

- R Project - https://www.r-project.org/
- RStudio - https://www.rstudio.com/products/RStudio/
- Quick R - http://www.statmethods.net/

- Stack Overflow - http://stackoverflow.com/
- R-bloggers - https://www.r-bloggers.com/

- contact@petrmarek.eu

RStudio

- **RStudio != R**

- **Dle https://www.rstudio.com/products/RStudio:**
  - **RStudio is an integrated development environment (IDE) for R. It includes a console, syntax-highlighting editor that supports direct code execution, as well as tools for plotting, history, debugging and workspace management.**

  - **RStudio is available in open source and commercial editions and runs on the desktop (Windows, Mac, and Linux).**

Obsah prezentace

Kalkulačka

```
> 1 + 2
```

```
[1] 3
```

```
> 3 ^ 2
```

```
[1] 9
```

```
> 5 * 5
```

```
[1] 25
```

```
> sqrt(2)
```

```
[1] 1.41
```

```
> 2 ^ (1/2)
```

```
[1] 1.41
```

Kalkulačka

`+`	sčítání
`-`	odečítání
`*`	násobení
`/`	dělení
`^`	mocnění
`%/%`	celočíselné dělení
`%%`	modulo

Nápověda

- **Komplexní nápověda pomocí `?` , popř. `help()`**

```
> ?sqrt
> help(sqrt)
```

- **Zadání názvu funkce vypíše její kód**

```
> sqrt
```

```
function (x)  .Primitive("sqrt")
```

Volání funkcí

```
> seq(1, 5)
```

```
[1] 1 2 3 4 5
```

```
> seq(from = 1, to = 5)
```

```
[1] 1 2 3 4 5
```

```
> seq(1, to = 5)
```

```
[1] 1 2 3 4 5
```

Základní matematické funkce

`abs`	**absolutní hodnota**
`sqrt`	**druhá odmocnina**
`log`	**přirozený logaritmus**
`log10`	**dekadický logaritmus**
`exp`	**exponenciální funkce**
`cos` , `sin` , `tan`	**trigonometrické funkce**

Základy

Úkol

- **Zobrazte nápovědu k funkci** `sum`
- **Spočítejte** $\sqrt{3}$
- **Spočítejte** 3^3
- **Spočítejte** $\sqrt[3]{3}$
- **Spočítejte zbytek po celočíselném dělení** 743 **číslem** 3

Základy

Řešení

```
> ?sum
```

```
> sqrt(3)
```

```
[1] 1.73
```

```
> 3 ^ 3
```

```
[1] 27
```

```
> 3 ^ (1 / 3)
```

```
[1] 1.44
```

```
> 743 %% 3
```

```
[1] 2
```

Proměnné

```
> x = 5
> x + 5
```

```
[1] 10
```

```
> x
```

```
[1] 5
```

```
> x = x + 5
> x
```

```
[1] 10
```

```
> (y = 3)
```

```
[1] 3
```

Proměnné

Alternativní zápis

```
> x <- "Tento zápis nebudeme používat"
> "Tento také ne" -> x
```

Proměnné

Úkol

- Vyrobte proměnnou `x` s hodnotou $\sqrt{3}$
- Vyrobte proměnnou `y` s hodnotou $\frac{\sqrt{3^3}}{\sqrt[3]{11}}$
- Vyrobte proměnnou `z` s logickou hodnotou `TRUE` pokud je `x` větší než `y` a `FALSE` pokud je menší nebo rovna

Proměnné

Řešení

```
> x = sqrt(3)
> x
```

```
[1] 1.73
```

```
> y = sqrt(3 ^ 3) / (11 ^ (1 / 3))
> y
```

```
[1] 2.34
```

```
> z = x > y
> z
```

```
[1] FALSE
```

Logické operátory

```
> 1 < 2
```

```
[1] TRUE
```

```
> 1 > 2
```

```
[1] FALSE
```

```
> 1 == 2 # jsou stejné?
```

```
[1] FALSE
```

```
> 1 != 2 # jsou jiné?
```

```
[1] TRUE
```

Logické operátory

Negace

```
> !TRUE
```

```
[1] FALSE
```

```
> !FALSE
```

```
[1] TRUE
```

```
> !(1 == 2)
```

```
[1] TRUE
```

```
> !1
```

```
[1] FALSE
```

Logické operátory

Kombinace podmínek - a

```
> (1 < 2) & (3 < 4)
```

```
[1] TRUE
```

```
> (1 < 1) & (3 < 4)
```

```
[1] FALSE
```

```
> (1 < 1) & (3 < 4) & FALSE
```

```
[1] FALSE
```

Logické operátory

Kombinace podmínek - nebo

```
> (1 < 2) | (3 < 4)
```

```
[1] TRUE
```

```
> (1 < 1) | (3 < 4)
```

```
[1] TRUE
```

```
> (1 < 1) | (3 < 3)
```

```
[1] FALSE
```

Logické operátory

Kombinace podmínek - mix

```
> (5 > 4) & (3 < 2)
```

```
[1] FALSE
```

```
> (1 < 2) | ((5 > 4) & (3 < 2))
```

```
[1] TRUE
```

```
> !!!!TRUE
```

```
[1] TRUE
```

Logické operátory

Úkol

- **Jakou hodnotu nabývají následující výrazy?**

```
> TRUE & FALSE

> TRUE | FALSE

> (5 > 4) | ((3 < 3) | (1 >= 2))

> (5 > 4) & ((3 < 3) | (1 >= 2))

> (5 > 4) | ((3 < 3) & (1 >= 2))

> (5 > 4) & ((3 < 3) & (1 >= 2))
```

Logické operátory

Řešení

```
>   TRUE & FALSE
```

```
[1] FALSE
```

```
>   TRUE | FALSE
```

```
[1] TRUE
```

Logické operátory

Řešení

```
>   (5 > 4) | ((3 < 3) | (1 >= 2))
```

```
[1] TRUE
```

```
>   (5 > 4) & ((3 < 3) | (1 >= 2))
```

```
[1] FALSE
```

```
>   (5 > 4) | ((3 < 3) & (1 >= 2))
```

```
[1] TRUE
```

```
>   (5 > 4) & ((3 < 3) & (1 >= 2))
```

```
[1] FALSE
```

Obsah prezentace

Funkce str

- **Funkce** `str()`, **viz.** `?str` .

```
> str(1)
```

```
 num 1
```

```
> str('a')
```

```
 chr "a"
```

```
> str(TRUE)
```

```
 logi TRUE
```

Elementární druhy dat 1/2

```
> 1 # num / numeric
```

```
[1] 1
```

```
> "ahoj" # chr / character
```

```
[1] "ahoj"
```

```
> 'ahoj' # chr / character
```

```
[1] "ahoj"
```

```
> NULL # NULL
```

```
NULL
```

Elementární druhy dat 2/2

```
> TRUE # logi / logical
```

```
[1] TRUE
```

```
> FALSE # logi / logical
```

```
[1] FALSE
```

```
> NA # logi / logical
```

```
[1] NA
```

```
> 3+2i # cplx / complex
```

```
[1] 3+2i
```

```
> NaN # num / numeric
```

```
[1] NaN
```

Obsah prezentace

Vektor

Konstrukce 1/2

```
> 10
```

```
 [1] 10
```

```
> c(1, 3, 5, 7)
```

```
 [1] 1 3 5 7
```

```
> c(10, c(1, 3, 5, 7))
```

```
 [1] 10  1  3  5  7
```

```
> rep(1, 5)
```

```
 [1] 1 1 1 1 1
```

Vektor

Konstrukce 2/2

```
> seq(0, 5, by = 0.5)
```

```
 [1] 0.0 0.5 1.0 1.5 2.0 2.5 3.0 3.5 4.0 4.5 5.0
```

```
> seq(0, 100, length.out = 0.5)
```

```
 [1] 0
```

```
> 1:10
```

```
 [1]  1  2  3  4  5  6  7  8  9 10
```

```
> 5:3
```

```
 [1] 5 4 3
```

Vektor

Datové typy 1/2

```
> c(1, 2, 3)
```

```
[1] 1 2 3
```

```
> c('A', 'B', 'C')
```

```
[1] "A" "B" "C"
```

```
> c(TRUE, FALSE, TRUE)
```

```
[1]  TRUE FALSE  TRUE
```

Vektor

Datové typy 2/2

```
> c(1, 'B', TRUE)
```

```
[1] "1"    "B"    "TRUE"
```

```
> c(5, TRUE, FALSE)
```

```
[1] 5 1 0
```

```
> c('D', TRUE, FALSE)
```

```
[1] "D"     "TRUE"  "FALSE"
```

Vektor

Základní operace - mutace

```
> 1:5 > 2
```

```
[1] FALSE FALSE  TRUE  TRUE  TRUE
```

```
> c(1, 2, 3) + 3
```

```
[1] 4 5 6
```

```
> c(1, 2, 3) + c(1, 2, 3)
```

```
[1] 2 4 6
```

```
> c(1, 2, 3) * 3
```

```
[1] 3 6 9
```

Vektor

Úkol

- Vypište uplynulé roky 21. století
- Vyrobte následující proměnné:
  - `x` obsahující deset čísel mezi 1 a 2
  - `y` rovnu druhé odmocnině ze dvou
  - `z` obsahující patnáct nul (funkce `rep`)
  - `total` jež bude obsahovat hodnoty `x`, `y` a `z`
- Zjistěte počet prvků proměnné `total` (funkce `length`), spočítejte průměrnou hodnotu (funkce `mean`) a součet (funkce `sum`)
- Vyrobte proměnnou `halves`, která obsahuje hodnoty odpovídající polovinám hodnot proměnné `total`

Vektor

Řešení

```
> 2000:2020
```

```
 [1] 2000 2001 2002 2003 2004 2005 2006 2007 2008 2009
     2010 2011 2012 2013 2014
16] 2015 2016 2017 2018 2019 2020
```

```
> x = seq(1, 2, length.out = 10)
> y = sqrt(2)
> z = rep(0, 15)
> total = c(x, y, z)
```

Vektor

Základní operace - přístup k prvkům 1/4

```
> x = 5:10
> x
```

```
 [1]  5  6  7  8  9 10
```

```
> x[1]
```

```
 [1] 5
```

```
> x[c(1, 3)]
```

```
 [1] 5 7
```

```
> x[-1]
```

```
 [1]  6  7  8  9 10
```

Vektor

Základní operace - přístup k prvkům 2/4

```
> x = 5:10
> x[c(FALSE, FALSE, FALSE, TRUE, TRUE, TRUE)]
```

```
[1]  8  9 10
```

```
> x > 7
```

```
[1] FALSE FALSE FALSE  TRUE  TRUE  TRUE
```

```
> x[x > 7]
```

```
[1]  8  9 10
```

Vektor

Základní operace - přístup k prvkům 3/4

```
> x = 5:10
> x.halves = x / 2
> x.halves
```

```
[1] 2.5 3.0 3.5 4.0 4.5 5.0
```

```
> x.is.even = (x %% 2 == 0)
> x.is.even
```

```
[1] FALSE  TRUE FALSE  TRUE FALSE  TRUE
```

```
> even.from.x = x[x.is.even]
> even.from.x
```

```
[1]  6  8 10
```

Vektor

Základní operace - přístup k prvkům 3/4

```
> x = 5:10
> x
```

```
 [1]  5  6  7  8  9 10
```

```
> x = x[-1]
> x
```

```
 [1]  6  7  8  9 10
```

```
> x[3] = 0
> x
```

```
 [1]  6  7  0  9 10
```

Vektor

Popis

```
> x = 5:10
> length(x)
```

```
[1] 6
```

```
> mean(x)
```

```
[1] 7.5
```

```
> median(x)
```

```
[1] 7.5
```

```
> summary(x)
```

```
   Min. 1st Qu.  Median    Mean 3rd Qu.    Max. 
   5.00    6.25    7.50    7.50    8.75   10.00 
```

Vektor

Úkol

- Vyrobte vektor `numbers` obsahující čísla od 1 do 100
- Vypište následující
  - hodnoty z `numbers` větší než 50
  - lichá čísla z `numbers`
  - průměrnou hodnotu lichých čísel z `numbers`
  - počet čísel větších než 34 a menších než 66 z `numbers`
  - součet čísel větších než 90 nebo menších než 10 z `numbers`
- Změňte dvě prostřední hodnoty z `numbers` na 0
  a spočtěte průměr z `numbers`

Vektor

Řešení

```
> numbers = 1:100
> numbers[numbers > 50]
```

```
 [1]  51  52  53  54  55  56  57  58  59  60  61  62
     63  64  65  66  67  68  69
[20]  70  71  72  73  74  75  76  77  78  79  80  81
     82  83  84  85  86  87  88
[39]  89  90  91  92  93  94  95  96  97  98  99 100
```

Vektor

Řešení

```
> numbers[numbers %% 2 == 1]
```

```
 [1]  1  3  5  7  9 11 13 15 17 19 21 23 25 27 29 31 33
     35 37 39 41 43 45 47 49
[26] 51 53 55 57 59 61 63 65 67 69 71 73 75 77 79 81 83
     85 87 89 91 93 95 97 99
```

```
> mean(numbers[numbers %% 2 == 1])
```

```
[1] 50
```

Vektor

Řešení

```
> length(numbers[numbers > 34 & numbers < 66])
```

```
[1] 31
```

```
> sum(numbers[numbers > 90 | numbers < 10])
```

```
[1] 1000
```

Vektor

Řešení

```
> length(numbers)
```

```
[1] 100
```

```
> numbers[50] = 0
> numbers[51] = 0
> mean(numbers)
```

```
[1] 49.5
```

Obsah prezentace

Matice

Konstrukce 1/2

```
> x = matrix(1:6, ncol = 3, nrow = 2)
> x
```

```
 [,1] [,2] [,3]
    1    3    5
    2    4    6
```

```
> str(x)
```

```
 int [1:2, 1:3] 1 2 3 4 5 6
```

```
> dim(x)
```

```
 [1] 2 3
```

```
> c(nrow(x), ncol(x))
```

```
 [1] 2 3
```

Matice

Konstrukce 2/2

- **column bind**

```
> cbind(c(1, 2, 3), c(1, 2, 3))
```

```
     [,1] [,2]
[1,]    1    1
[2,]    2    2
[3,]    3    3
```

- **row bind**

```
> rbind(c(1, 2, 3), c(1, 2, 3))
```

```
     [,1] [,2] [,3]
[1,]    1    2    3
[2,]    1    2    3
```

Matice

Přístup k prvkům 1/2

```
> x = rbind(c(1, 2, 3), c(1, 2, 3))
> x
```

```
 [,1] [,2] [,3]
    1    2    3
    1    2    3
```

```
> x[1,1]
```

```
 [1] 1
```

```
> x[2,]
```

```
 [1] 1 2 3
```

```
> x[,1]
```

```
 [1] 1 1
```

Matice

Přístup k prvkům 2/2

```
> x = rbind(c(1, 2, 3), c(1, 2, 3))
> x
```

```
 [,1] [,2] [,3]
    1    2    3
    1    2    3
```

```
> x[-1,]
```

```
 [1] 1 2 3
```

```
> x[1, 1] = 0
> x
```

```
 [,1] [,2] [,3]
    0    2    3
    1    2    3
```

Matice

Mutace

```
> x = rbind(c(1, 2, 3), c(1, 2, 3))
> x * 3
```

```
 [,1] [,2] [,3]
    3    6    9
    3    6    9
```

```
> x %*% t(x)
```

```
 [,1] [,2]
   14   14
   14   14
```

Matice

Funkce

`dim`	rozměry matice
`nrow`	počet řádků matice
`ncol`	počet sloupců matice
`%*%`	maticové násobení
`t`	transpozice matice
`det`	determinant matice
`eigen`	vlastní čísla a vlastní vektory matice
`diag`	extrakce diagonály matice

Matice

Apply 1/2

Funkce apply umožňuje pracovat podle řádků (1) nebo sloupců (2)

```
> x = rbind(c(1, 2, 3), c(1, 2, 3))
> x
```

```
 [,1] [,2] [,3]
    1    2    3
    1    2    3
```

```
> apply(x, 1, sum) # sum pro každý řádek
```

```
 [1] 6 6
```

```
> apply(x, 2, sum) # sum pro každý sloupec
```

```
 [1] 2 4 6
```

Matice

Apply 2/2

```
> x = rbind(c(1, 2, 3), c(1, 2, 3))
> x
```

```
 [,1] [,2] [,3]
    1    2    3
    1    2    3
```

```
> sums = apply(x, 2, sum)
> sums                          # Součty sloupců
```

```
 [1] 2 4 6
```

```
> x[, sums > 3]                 # Sloupce se součtem větším než 3
```

```
 [,1] [,2]
    2    3
    2    3
```

Obsah prezentace

List

Motivace

- Vektory jsou atomické
- Prvky vektoru musí být stejného typu
- Listy umožňují složítější datovou strukturu
- Listy jsou často návratovou hodnotou funkcí

List

Konstrukce

```
> our.list = list("name" = c("Paul", "John", "Joe"),
+                 "age" = c(15, 40, 30),
+                 "weight" = c(60, 90, 80),
+                 "single" = c(FALSE, TRUE, TRUE))
> our.list
```

```
$name
[1] "Paul" "John" "Joe"

$age
[1] 15 40 30

$weight
[1] 60 90 80

$single
[1] FALSE  TRUE  TRUE
```

List

Struktura

```
> str(our.list)
```

```
List of 4
 $ name  : chr [1:3] "Paul" "John" "Joe"
 $ age   : num [1:3] 15 40 30
 $ weight: num [1:3] 60 90 80
 $ single: logi [1:3] FALSE TRUE TRUE
```

```
> str(our.list['age'])
```

```
List of 1
 $ age: num [1:3] 15 40 30
```

```
> str(our.list[['age']])
```

```
num [1:3] 15 40 30
```

List

Přístup k hodnotám 1/2

```
> our.list$name      # vektor
```

```
[1] "Paul" "John" "Joe"
```

```
> our.list['name']   # list
```

```
$name
[1] "Paul" "John" "Joe"
```

```
> our.list[['name']] # vektor
```

```
[1] "Paul" "John" "Joe"
```

List

Přístup k hodnotám 2/2

```
> our.list[1]       # list
```

```
$name
[1] "Paul" "John" "Joe"
```

```
> our.list[[1]]     # vektor
```

```
[1] "Paul" "John" "Joe"
```

```
> our.list[c(1, 2)]  # list
```

```
$name
[1] "Paul" "John" "Joe"

$age
[1] 15 40 30
```

List

Lapply

Funkce `lapply` je obdobou maticového `apply` pro list

```
> lapply(our.list, length)
```

```
$name
[1] 3

$age
[1] 3

$weight
[1] 3

$single
[1] 3
```

List

Jako návratová hodnota 1/2

```
> gaussian.random = rnorm(20)
> head(gaussian.random, 7)
```

```
[1] -0.626  0.184 -0.836  1.595  0.330 -0.820  0.487
```

```
> result = boxplot(gaussian.random)
```

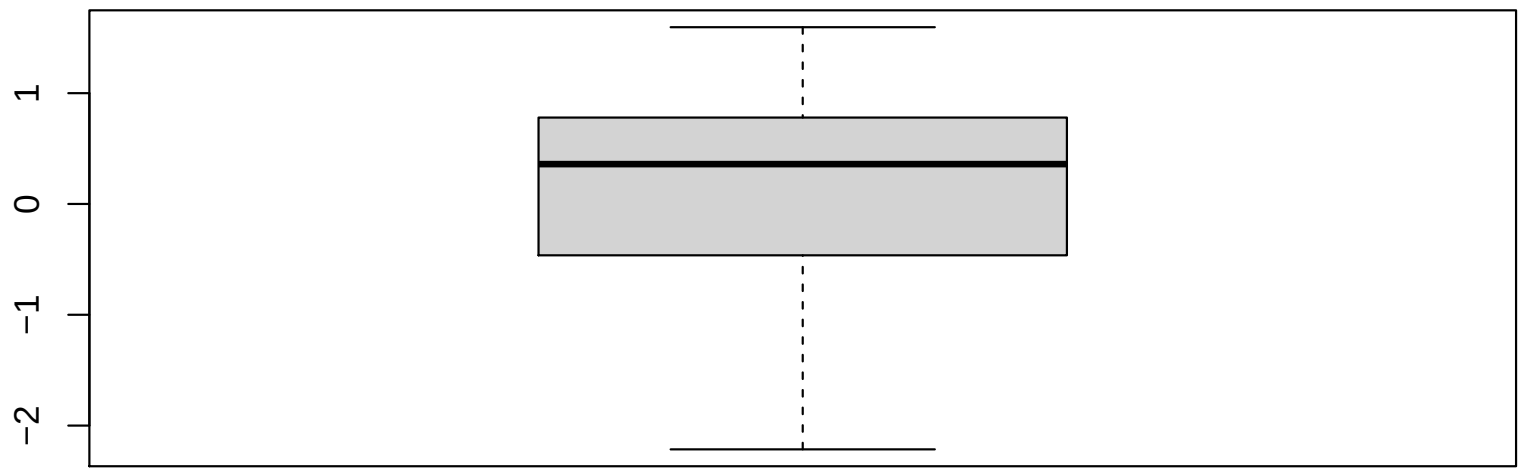

List

Jako návratová hodnota 2/2

```
> str(result)
```

```
List of 6
 $ stats: num [1:5, 1] -2.215 -0.463 0.36 0.78 1.595
 $ n    : num 20
 $ conf : num [1:2, 1] -0.0795 0.7989
 $ out  : num(0)
 $ group: num(0)
 $ names: chr "1"
```

```
> result$n
```

```
[1] 20
```

Obsah prezentace

Data frame

Motivace

- Struktura odpovídající databázové tabulce
- Sloupečky různých typů - řetězce, čísla atd.
- Sloupce = proměnné
- Řádky = záznamy/pozorování

Data frame

Konstrukce

```
> our.data.frame = data.frame(
+   "name" = c("Paul", "John", "Joe"),
+   "age" = c(15, 40, 30),
+   "weight" = c(60, 90, 80),
+   "single" = c(FALSE, TRUE, TRUE),
+   stringsAsFactors = FALSE
+ )
> our.data.frame
```

```
 name age weight single
Paul  15     60  FALSE
John  40     90   TRUE
 Joe  30     80   TRUE
```

Data frame

Struktura

```
> str(our.data.frame)
```

```
'data.frame':^^I3 obs. of  4 variables:
 $ name   : chr  "Paul" "John" "Joe"
 $ age    : num  15 40 30
 $ weight: num  60 90 80
 $ single: logi  FALSE TRUE TRUE
```

```
> dim(our.data.frame)
```

```
[1] 3 4
```

```
> c(nrow(our.data.frame), ncol(our.data.frame))
```

```
[1] 3 4
```

Data frame

Přístup k hodnotám

```
> our.data.frame$age
```

```
[1] 15 40 30
```

```
> our.data.frame[, 'age']
```

```
[1] 15 40 30
```

```
> our.data.frame[2, ]
```

```
name age weight single
John  40     90   TRUE
```

```
> our.data.frame[, 2]
```

```
[1] 15 40 30
```

```
> our.data.frame[2, 2]
```

```
[1] 40
```

Data frame

Mazání sloupce

```
> our.data.frame$age = NULL
> our.data.frame
```

```
 name  weight  single
 Paul      60   FALSE
 John      90    TRUE
  Joe      80    TRUE
```

Data frame

Mazání řádku

```
> our.data.frame = our.data.frame[-1, ]
> our.data.frame
```

```
 name  weight  single
 John      90    TRUE
  Joe      80    TRUE
```

Data frame

Přidání sloupce

```
> our.data.frame$visits = c(19, 30)
>
> our.data.frame = cbind(our.data.frame, value = c(5, 18))
>
> our.data.frame
```

```
 name  weight  single  visits  value
 John      90    TRUE      19      5
  Joe      80    TRUE      30     18
```

Data frame

Přidání řádku

```
> our.data.frame = rbind(our.data.frame, list('Ben', 30, FALSE, 0, 1))
>
> our.data.frame[nrow(our.data.frame) + 1, ] = list('Tom', 12, TRUE, 3, 1)
>
> our.data.frame
```

```
 name weight single visits value
John      90   TRUE     19     5
 Joe      80   TRUE     30    18
 Ben      30  FALSE      0     1
 Tom      12   TRUE      3     1
```

Data frame

Úkol

- Vyrobte data frame `df` o 100 řádcích s následujícími sloupci:
  - `id` obsahující čísla od 413 do 512
  - `weight` obsahující náhodný výběr z Normálního rozdělení $\mathrm{N}(70, 9)$, viz. `?rnorm` (pozor na rozptyl vs směrodatná odchylka)
- Smažte prvních 5 řádků
- Přidejte řádek s hodnotami `id` = `513` a `weight` = `73`
- Vypište prvních pár řádku pomocí funkce `head`
- Spočítejte průměr sloupce `weight`
- Smažte sloupec `id`

Data frame

Řešení

```
> df = data.frame(id = 413:512, weight = rnorm(100, 70, 3))
> df = df[-1:-5, ]
> df[nrow(df) + 1, ] = c(513, 73)
> head(df)
```

```
  id weight
18   69.8
19   69.5
20   65.6
21   68.6
22   71.3
23   74.1
```

```
> mean(df$weight)
```

```
[1] 70.3
```

```
> df$id = NULL
```

Data frame

Úkol

- **Použijte data frame `mtcars`, viz. `?mtcars`**
- **Prohlídněte jej pomocí funkcí `str` a `head`**
- **Vyrobte data frame `mtcars.filtered`, který bude obsahovat jen automobily se čtyřmi válci (sloupeček `cyl`)**
- **Přidejte do `mtcars.filtered` sloupec `lp100km` s průměrnou spotřebou v L/100km dle vzorce**

$$\text{lp100km} = \frac{282.48}{\text{mpg}}$$

Data frame

Řešení

```
> str(mtcars)
```

```
'data.frame':^^I32 obs. of  11 variables:
 $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8
     19.2 ...
 $ cyl : num  6 6 4 6 8 6 8 4 4 6 ...
 $ disp: num  160 160 108 258 360 ...
 $ hp  : num  110 110 93 110 175 105 245 62 95 123 ...
 $ drat: num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69
     3.92 3.92 ...
 $ wt  : num  2.62 2.88 2.32 3.21 3.44 ...
 $ qsec: num  16.5 17 18.6 19.4 17 ...
 $ vs  : num  0 0 1 1 0 1 0 1 1 1 ...
 $ am  : num  1 1 1 0 0 0 0 0 0 0 ...
 $ gear: num  4 4 4 3 3 3 3 4 4 4 ...
 $ carb: num  4 4 1 1 2 1 4 2 2 4 ...
```

Data frame

Řešení

```
> head(mtcars)
```

mpg	cyl	disp	hp	drat	wt	qsec	vs	am	gear	carb
1.0	6	160	110	3.90	2.62	16.5	0	1	4	4
1.0	6	160	110	3.90	2.88	17.0	0	1	4	4
2.8	4	108	93	3.85	2.32	18.6	1	1	4	1
1.4	6	258	110	3.08	3.21	19.4	1	0	3	1
8.7	8	360	175	3.15	3.44	17.0	0	0	3	2
8.1	6	225	105	2.76	3.46	20.2	1	0	3	1

```
> mtcars.filtered = mtcars[mtcars$cyl == 4, ]
> mtcars.filtered$lp100km = 282.48 / mtcars.filtered$mpg
```

Obsah prezentace

Faktor

Motivace

- R implementace kategoriálních proměnných
- v data frame automaticky, pokud nevypneme pomocí argumentu `stringsAsFactors`

Faktor

Konstrukce

```
> x = c('a', 'a', 'b', 'c', 'a', 'b')
> x.factor = factor(x)
> x.factor
```

```
[1] a a b c a b
Levels: a b c
```

```
> str(x.factor)
```

```
Factor w/ 3 levels "a","b","c": 1 1 2 3 1 2
```

```
> summary(x.factor)
```

```
a b c
3 2 1
```

Faktor

Data frame

```
> x = c('a', 'a', 'b', 'c', 'a', 'b')
> y = seq_along(x)
> y
```

```
[1] 1 2 3 4 5 6
```

```
> df = data.frame(x, y)
> str(df)
```

```
'data.frame':^^I6 obs. of  2 variables:
 $ x: chr  "a" "a" "b" "c" ...
 $ y: int  1 2 3 4 5 6
```

Obsah prezentace

Working directory

- `getwd()`
- `setwd()`
- **na lomítkách v cestě nezáleží, pozor na escapování zpětného lomítka**

```
> "D:\\Dokumenty\\R3"
```

```
[1] "D:\\Dokumenty\\R3"
```

```
> "D:/Dokumenty/R3"
```

```
[1] "D:/Dokumenty/R3"
```

R - source

- **Načtení R skriptu a jeho vykonání**
- **Projde cílový skript a vykoná jednotlivé řádky jako bychom je sami znova zadali**
- **V aktuálním kontextu - tj. zůstanou nám všechny proměnné atd.**

```
> source('path/to/my/script.R')
```

Tabulková data

Funkce	`header`	`sep`	`dec`	write funkce
`read.table`	`FALSE`	`""`	`"."`	`write.table`
`read.csv`	`TRUE`	`","`	`"."`	`write.csv`
`read.csv2`	`TRUE`	`";"`	`","`	`write.csv2`
`read.delim`	`TRUE`	`"\t"`	`"."`	`write.delim`
`read.delim2`	`TRUE`	`"\t"`	`","`	`write.delim2`

- `?read.table`
- `?write.table`
- **Parametr** `header`
- **Parametr** `skip`

Data [lengths]

```
> df = read.csv('../../data/lengths.csv')
> df
```

```
 identifier  sex  age  length
    7412301    M   18    11.7
    7412302    F   33    16.7
    7412303    F   41    13.4
    7412304    F   40    12.7
    7412305    M   23    16.2
    7412306    M   58    17.2
    7412307    F   31    11.2
```

Excel 1/2

Data [excel]

Balíček openxlsx [Walker, 2018]

```
> library('openxlsx')
> excel.car.fuel = read.xlsx('../../data/excel.xlsx')
> str(excel.car.fuel)
```

```
'data.frame':^^I1142 obs. of  8 variables:
 $ Model.Yr : num  2012 2012 2012 2012 2012 ...
 $ Mfr.Name : chr  "aston martin" "aston martin"
     "aston martin" "aston martin" ...
 $ Carline  : chr  "V12 Vantage" "V8 Vantage" "V8
     Vantage" "V8 Vantage" ...
 $ Engine   : num  5.9 4.7 4.7 4.7 4.7 4.2 4.2 5.2 5.2
     4.2 ...
 $ Cylinders: num  12 8 8 8 8 8 8 10 10 8 ...
 $ MPG      : num  13.1 16 16 15.2 16 ...
 $ Gears    : num  6 6 7 6 7 6 6 6 6 6 ...
 $ LPH      : num  17.9 14.7 14.7 15.5 14.7 ...
```

Excel 2/2

```
> str(read.xlsx('../../data/excel.xlsx', sheet = 'mtcars'))
```

```
'data.frame':^^I32 obs. of  12 variables:
 $ X1  : chr  "Mazda RX4" "Mazda RX4 Wag" "Datsun 710"
     "Hornet 4 Drive" ...
 $ mpg : num  21 21 22.8 21.4 18.7 18.1 14.3 24.4 22.8
     19.2 ...
 $ cyl : num  6 6 4 6 8 6 8 4 4 6 ...
 $ disp: num  160 160 108 258 360 ...
 $ hp  : num  110 110 93 110 175 105 245 62 95 123 ...
 $ drat: num  3.9 3.9 3.85 3.08 3.15 2.76 3.21 3.69
     3.92 3.92 ...
 $ wt  : num  2.62 2.88 2.32 3.21 3.44 ...
 $ qsec: num  16.5 17 18.6 19.4 17 ...
 $ vs  : num  0 0 1 1 0 1 0 1 1 1 ...
 $ am  : num  1 1 1 0 0 0 0 0 0 0 ...
 $ gear: num  4 4 4 3 3 3 3 4 4 4 ...
 $ carb: num  4 4 1 1 2 1 4 2 2 4 ...
```

Zápis dat

Úkol

- **Uložte data frame `mtcars` do Excel souboru**
  - **Použijte argument `row.names = TRUE`**

- **Uložte sloupce `mpg` a `hp` z data frame `mtcars` do dalšího Excel souboru**
  - **Použijte argument `row.names = TRUE`**

Zápis dat

Řešení

```
> library('openxlsx')
> write.xlsx(mtcars,
+            '/tmp/r-slides/mtcars.xlsx',
+            row.names = TRUE)
> write.xlsx(mtcars[, c('mpg', 'hp')],
+            '/tmp/r-slides/mtcars-mpg-hp.xlsx',
+            row.names = TRUE)
```

Načtení dat

Úkol

- **Stáhněte si tabulku** `Graf 1 Počet obyvatel v letech 1785-2020`

  ČSÚ - Obyvatelstvo - roční časové řady

- **Načtěte z listu** `data` **záznamy o počtu obyvatel a letech (řádky 1 - 237, argument** `rows`**).**
- **Vykreslete pomocí funkce** `plot` **vývoj obyvatelstva do grafu**
  - **použijte křivku (argument** `type = 'l'`**)**
  - **červenou barvu (argument** `col = 'red'`**)**
  - **tlustou čáru (argument** `lwd = 2`**)**
- **Pro zájemce**
  - **Přidejte do načtených dat sloupec uvádějící rozdíl v počtu obyvatel oproti předchozímu roku**
  - **Uložte upravená data do nového Excel souboru**

Načtení dat

Řešení

```
> library('openxlsx')
> data = read.xlsx('../../data/13007021g01.xlsx',
+                  sheet = 'data', rows = 1:234)
> plot(data, type = 'l', col = 'red', lwd = 2,
+      xlab = 'Rok',
+      ylab = 'Stredni stav')
```

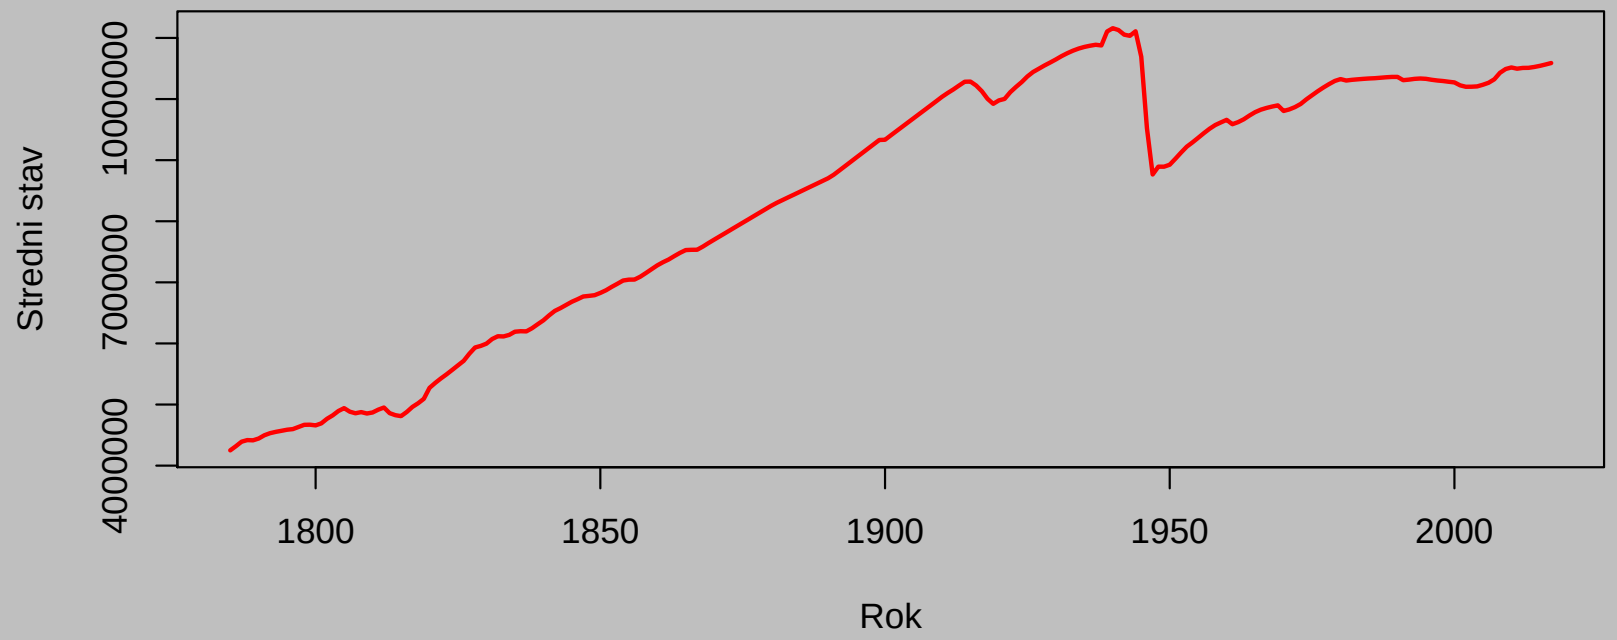

Načtení dat

Řešení

```
> data$differences = NA
> for (i in 2:nrow(data)) {
+   data$differences[i] = data[i, 2] - data[i - 1, 2]
+ }
> write.xlsx(data, '/tmp/r-slides/13007021g01-update.xlsx')
```

Další zdroje dat

SPSS

Balíček foreign [R Core Team, 2014b]

```
> library('foreign')
> read.spss('file-name.spss')
```

viz. `?read.spss`

Další zdroje dat

Stata

Balíček foreign [R Core Team, 2014b]

```
> library('foreign')
> read.dta('file-name.dta')
```

viz. `?read.dta`

Další zdroje dat

SQL databáze 1/2

Balíček odbc [Hester and Wickham, 2021]

```
> library(odbc)
>
> con = DBI::dbConnect(odbc::odbc(),
+                      Driver   = "PostgreSQL Unicode",
+                      Server   = "localhost",
+                      Database = "r_test_database",
+                      UID      = "petr",
+                      PWD      = "petr",
+                      Port     = 5432)
>
> result = DBI::dbGetQuery(con,
+                          "SELECT id, file_name FROM folio_files LIMIT 3")
```

Další zdroje dat

SQL databáze 2/2

```
> head(result)
```

```
id                                          file_name
60           verejna-vyzva-upis-creditas-1911.pdf
87           cni_odkoupene-vydane-akcie_lock.xlsx
56 dodatek-1-statut-creditas-fond-sicav-1911.pdf
```

```
> str(result)
```

```
'data.frame':^^I3 obs. of  2 variables:
 $ id        :integer64 60 87 56
 $ file_name: chr
     "verejna-vyzva-upis-creditas-1911.pdf"
     "cni_odkoupene-vydane-akcie_lock.xlsx"
     "dodatek-1-statut-creditas-fond-sicav-1911.pdf"
```

Obsah prezentace

R balíčky

- `install.packages()`
- `library()`
- `citation()`

Obsah prezentace

Krabičkový graf

```
> boxplot(mtcars$wt)
```

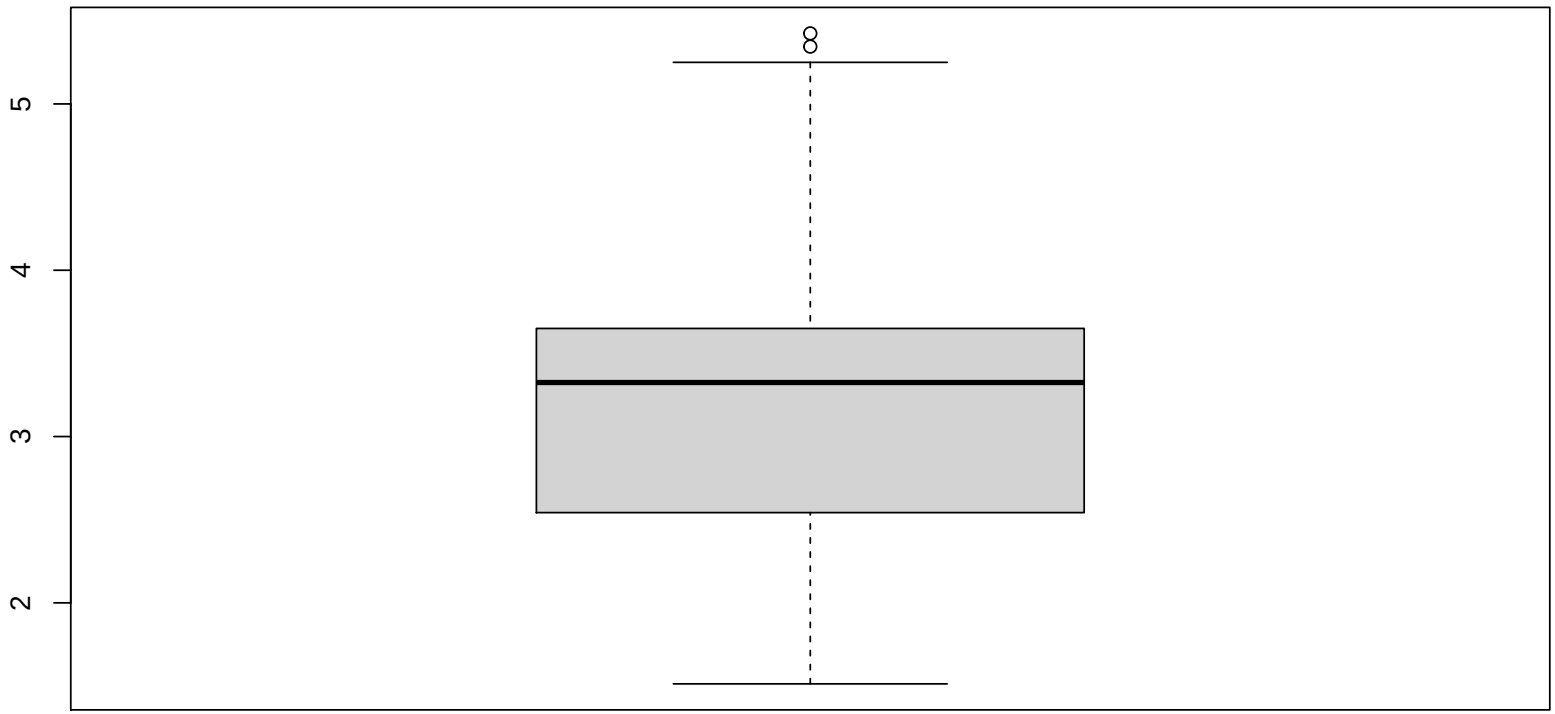

Histogram

```
> gaussian.data = rnorm(150)
> hist(gaussian.data)
```

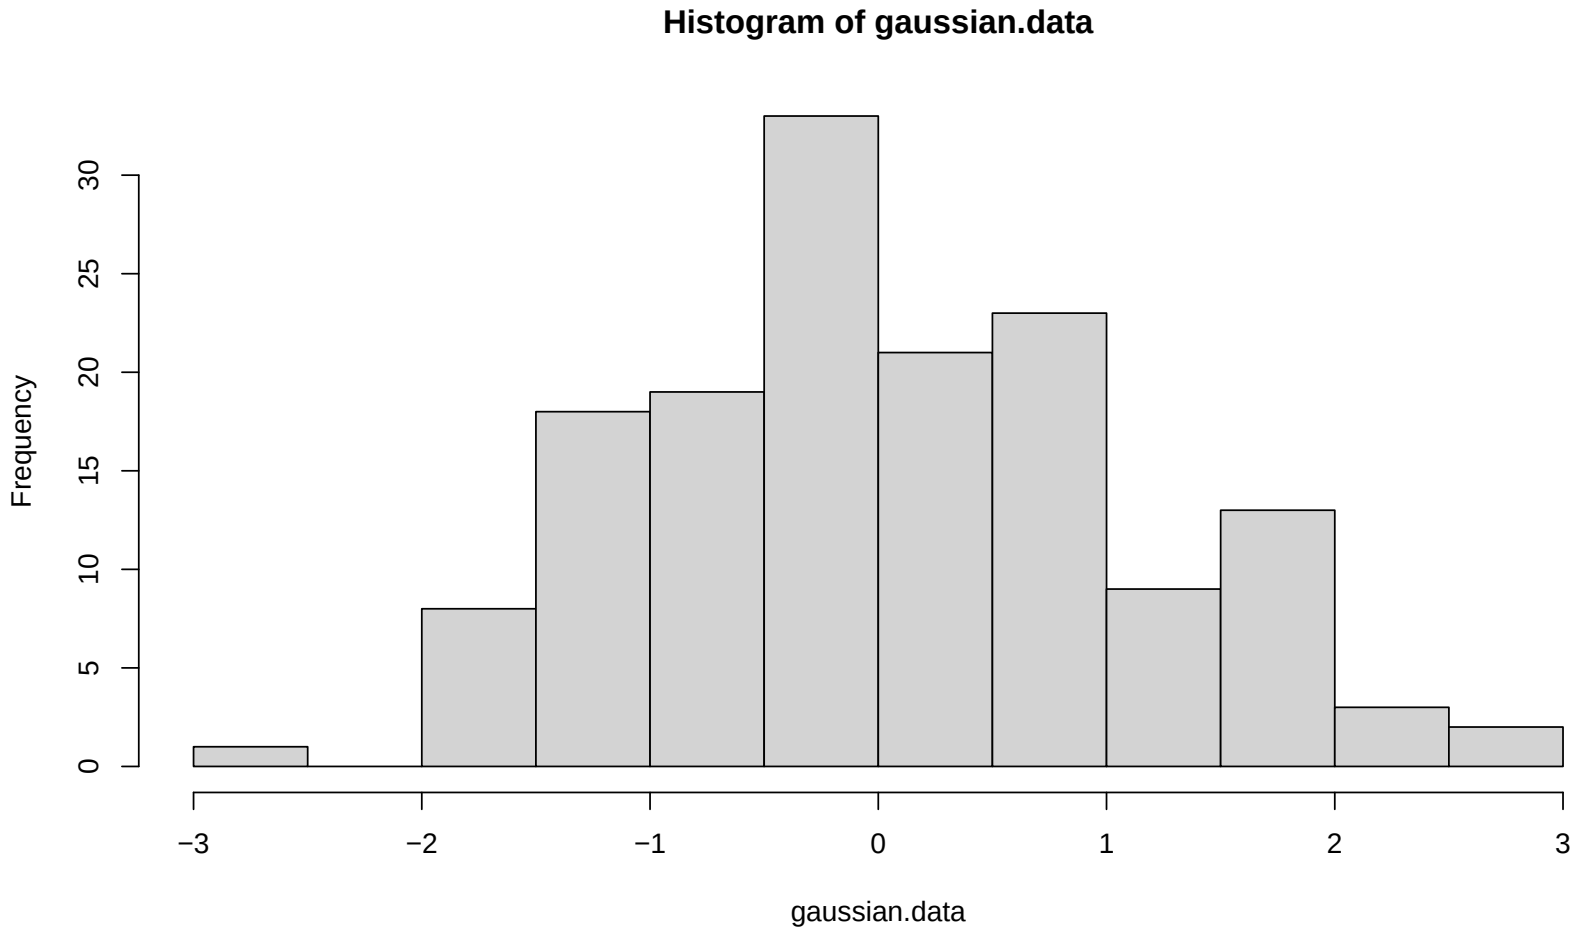

Histogram

breaks 1/3

- **Argument** `breaks`

- **Výchozím nastavením Sturgesovo pravidlo**

$$k = 1 + \log_2 n$$

nevhodné pro velké výběry - má tendenci příliš vyhlazovat použitím nedostatečného počtu intervalů [Scott, 1979].

Histogram

breaks 2/3

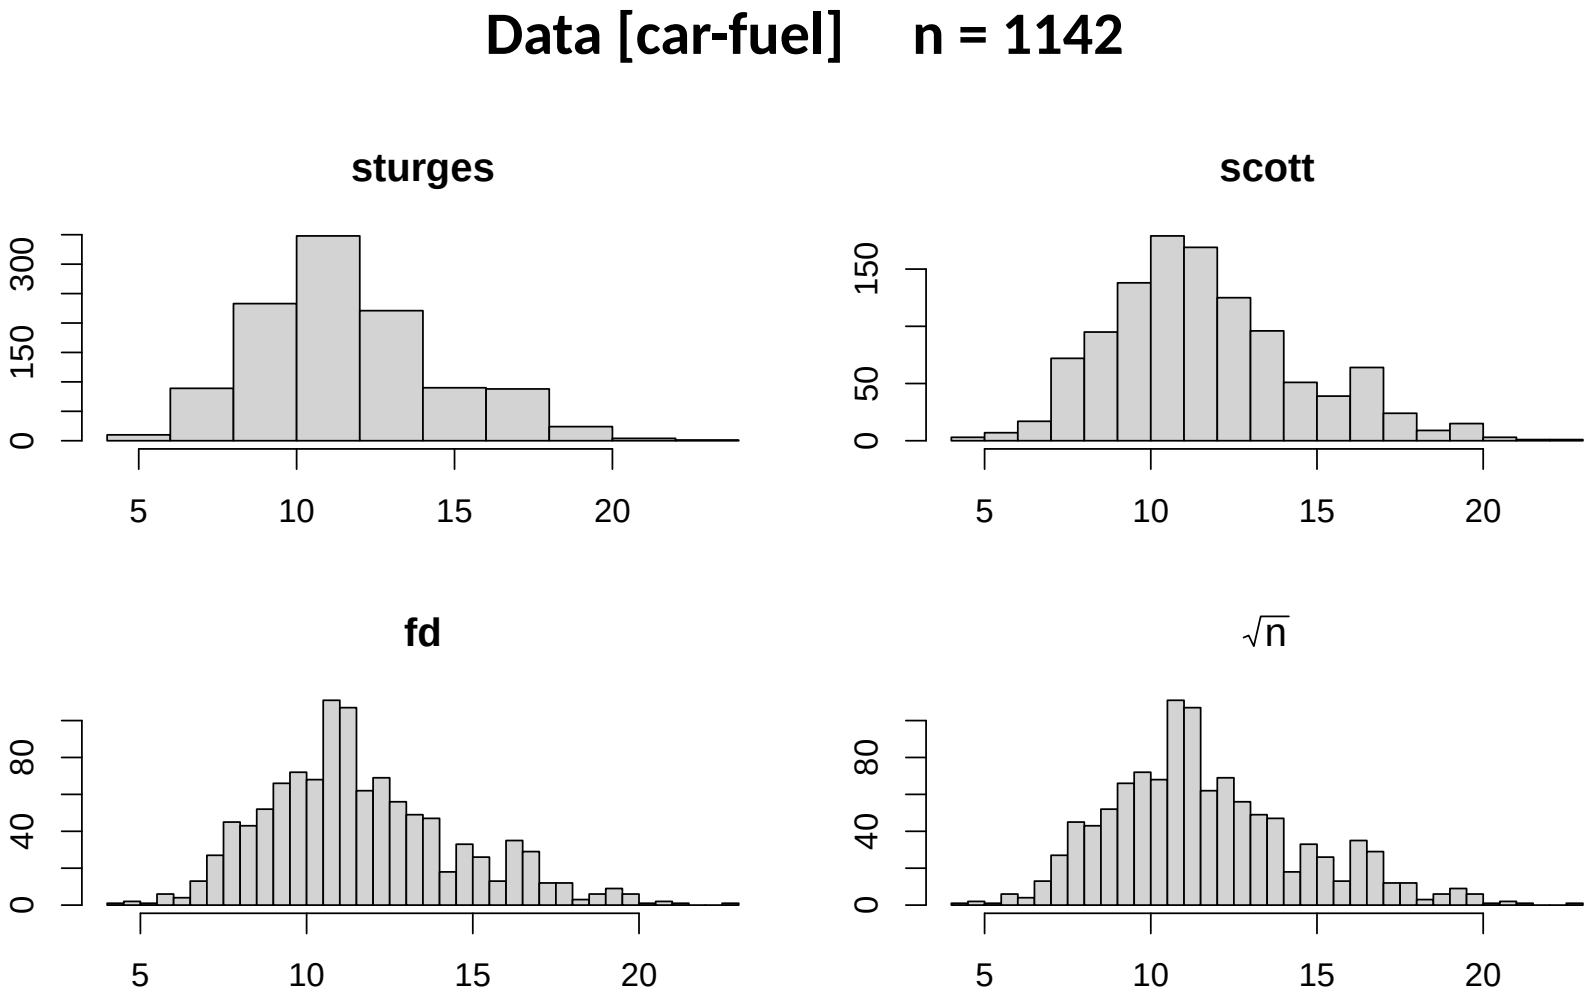

Histogram

breaks 3/3

```
> data = read.csv('../../data/car-fuel.csv')
> par(mfrow = c(2,2), cex = 1.2, mar = c(3,3,3,1))
> rules = c('sturges', 'scott', 'fd')
> for (rule in rules) {
+   hist(data$LPH, breaks = rule, main = rule)
+ }
> hist(data$LPH,
+      breaks = sqrt(length(data$LPH)),
+      main = bquote(sqrt('n')))
```

Jádrový odhad hustoty

```
> set.seed(1)
> gaussian.data = rnorm(150)
> density.est = density(gaussian.data)
> plot(density.est)
```

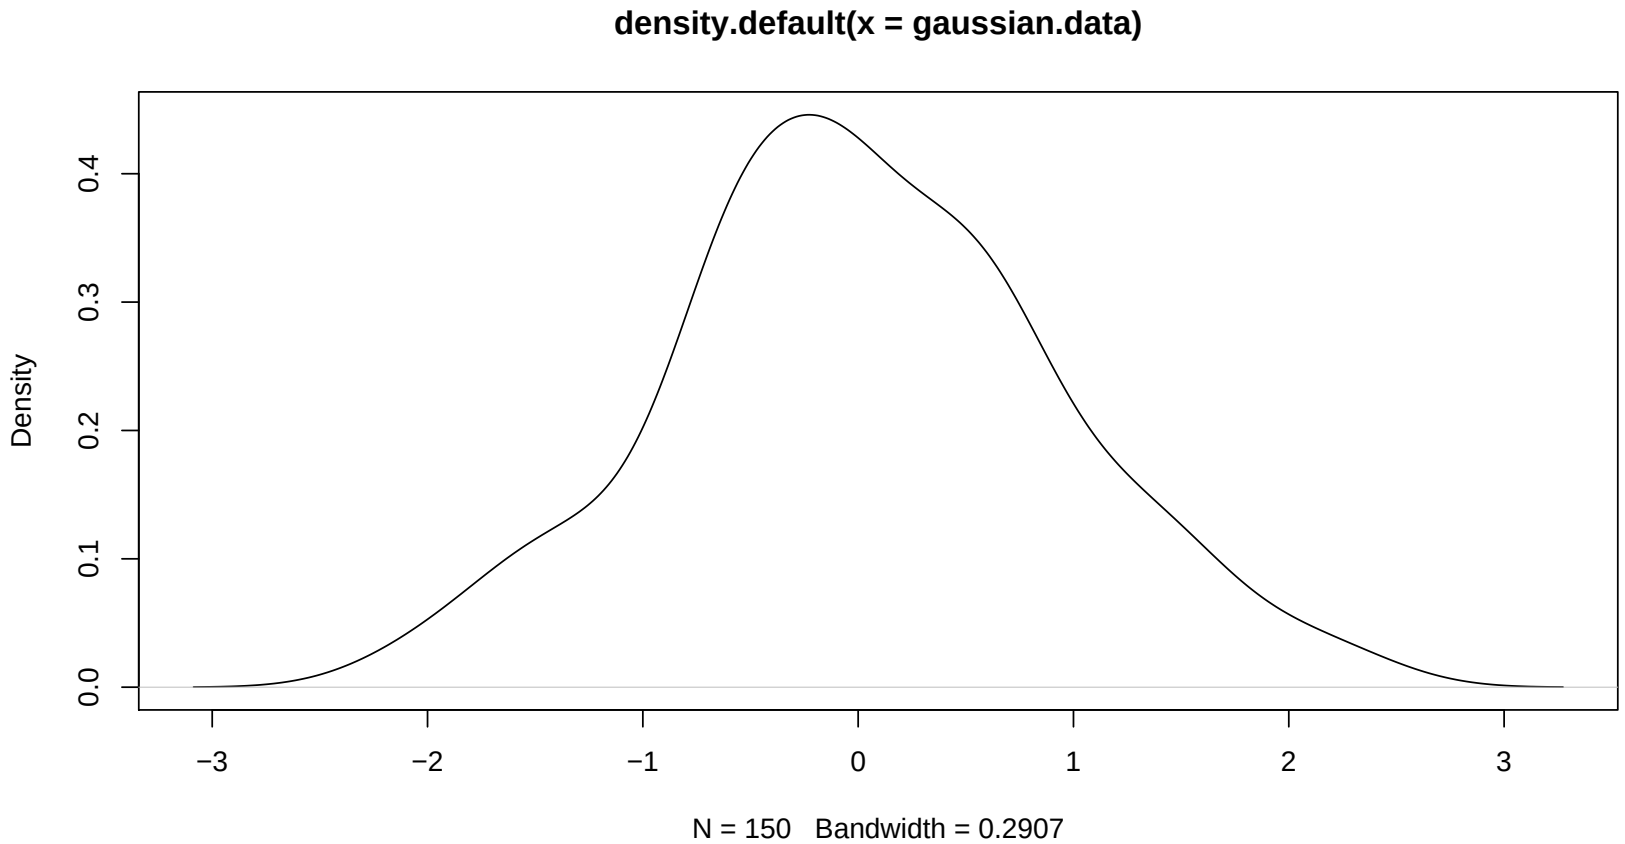

Jádrový odhad hustoty

nad histogramem

```
> set.seed(1)
> gaussian.data = rnorm(150)
> hist(gaussian.data, freq = FALSE)
> lines(density(gaussian.data), col = 'red')
```

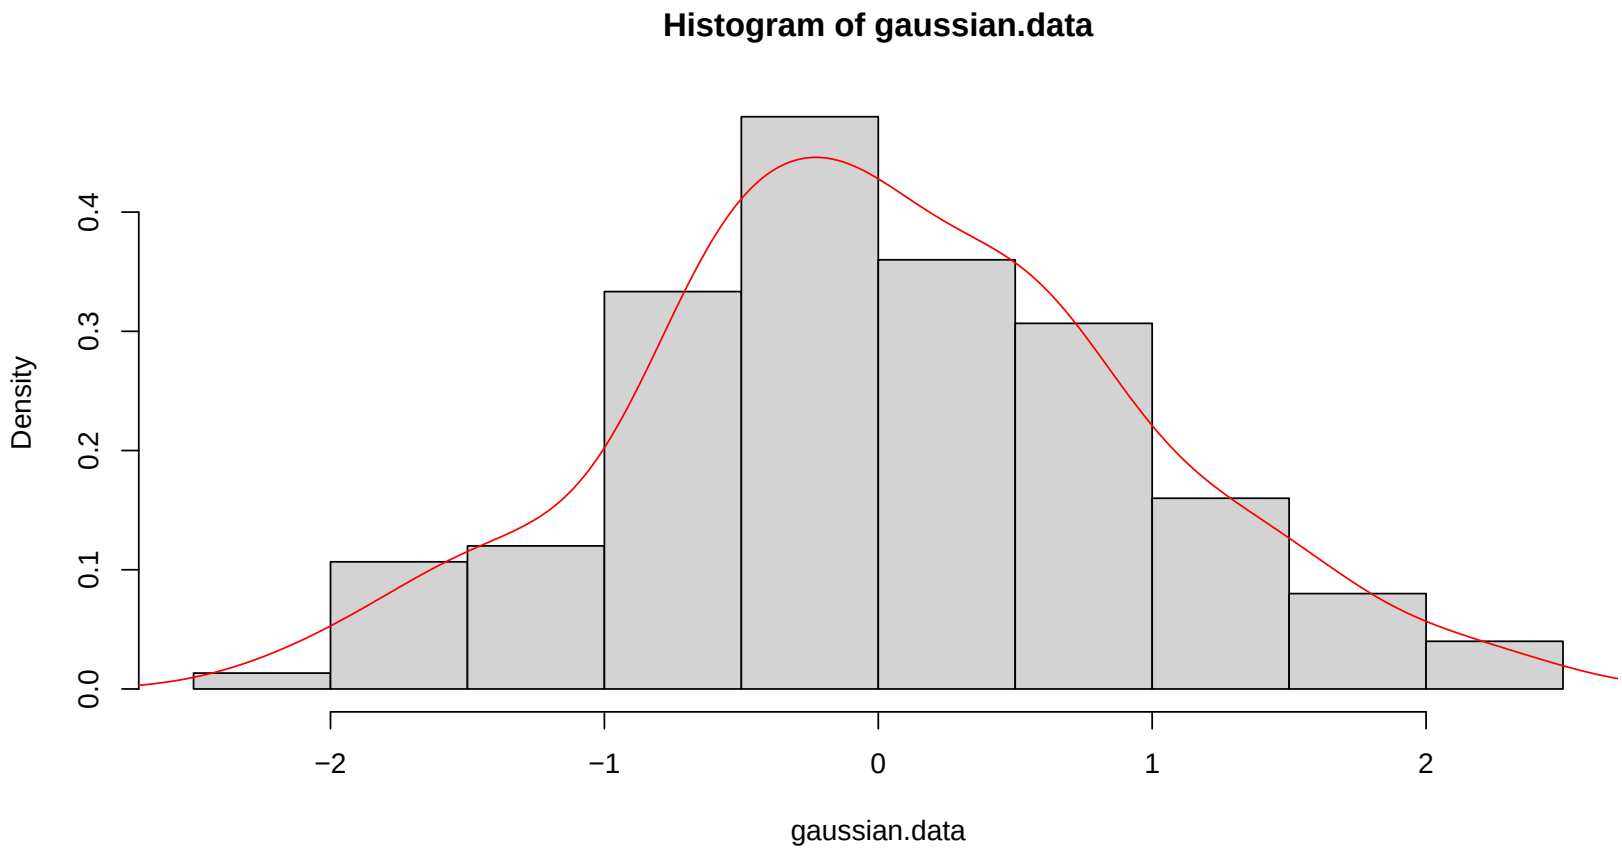

QQ graf

```
> set.seed(1)
> gaussian.data = rnorm(150)
> qqnorm(gaussian.data)
```

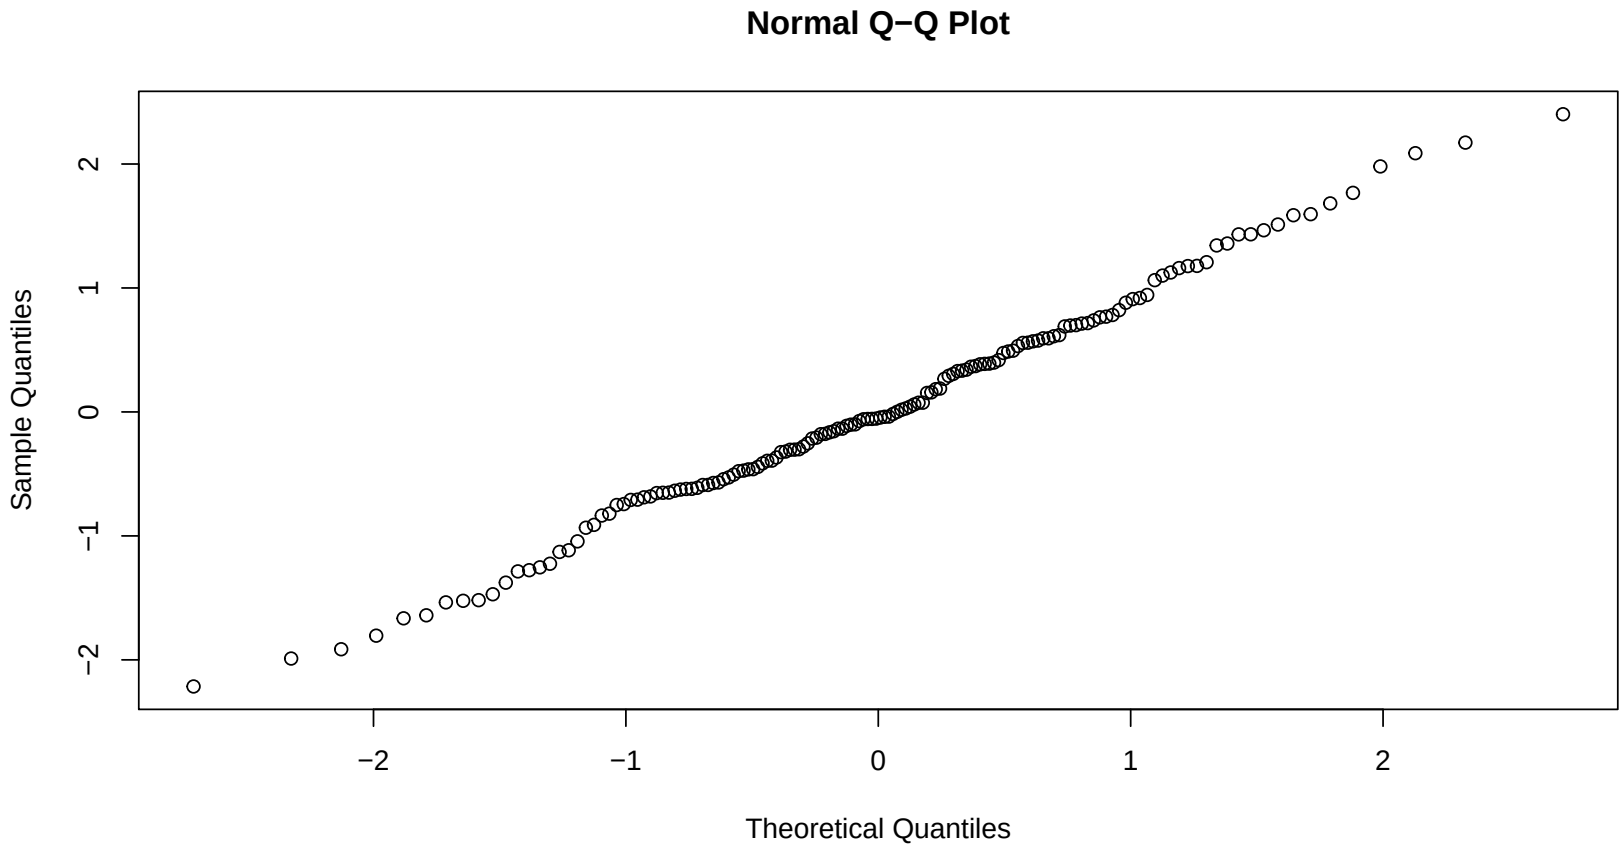

Violin plot

```
> suppressPackageStartupMessages(library('vioplot'))
> set.seed(1)
> vioplot(rnorm(150))
```

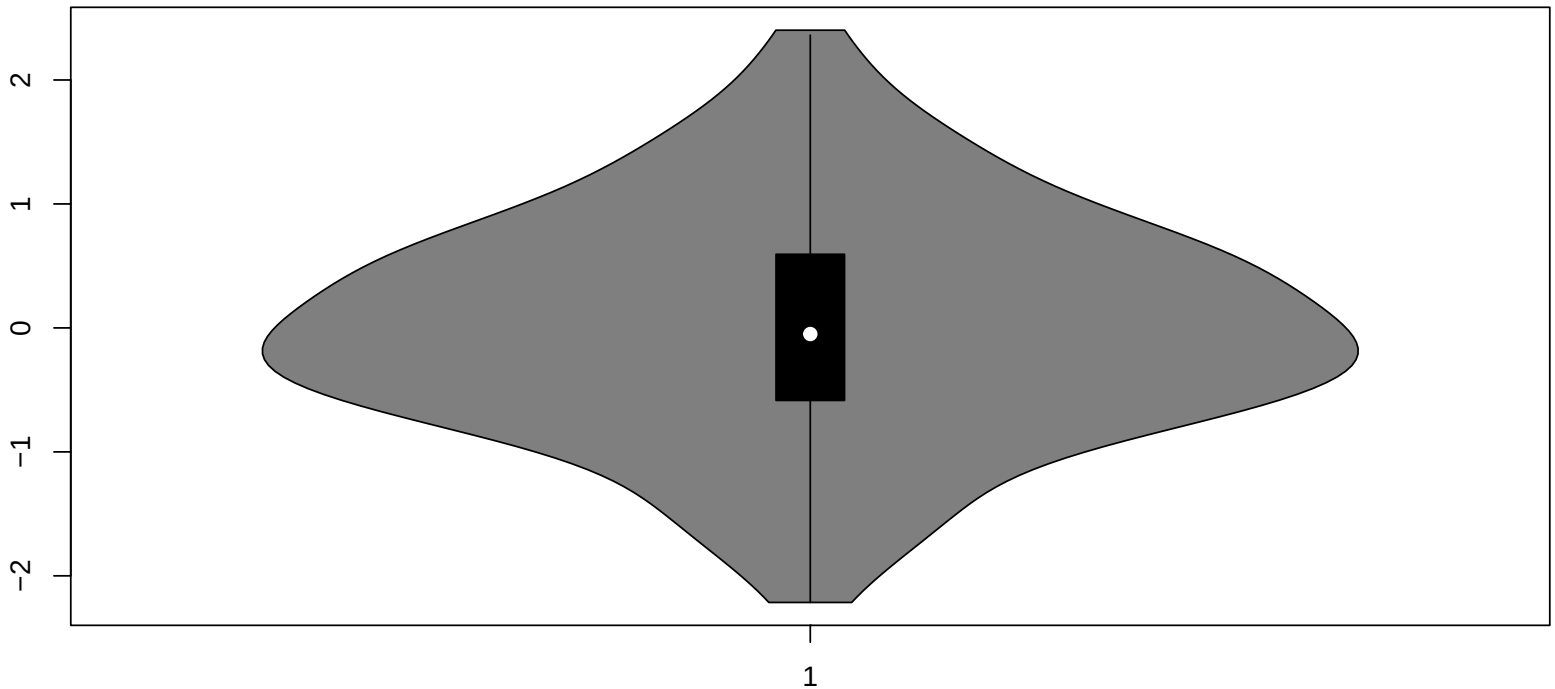

Obsah prezentace

XY graf

Data [car-fuel]

```
> data = read.csv('../../data/car-fuel.csv')
> plot(LPH ~ Engine, data = data, xlab = 'Objem motoru', ylab = 'Spotreba')
```

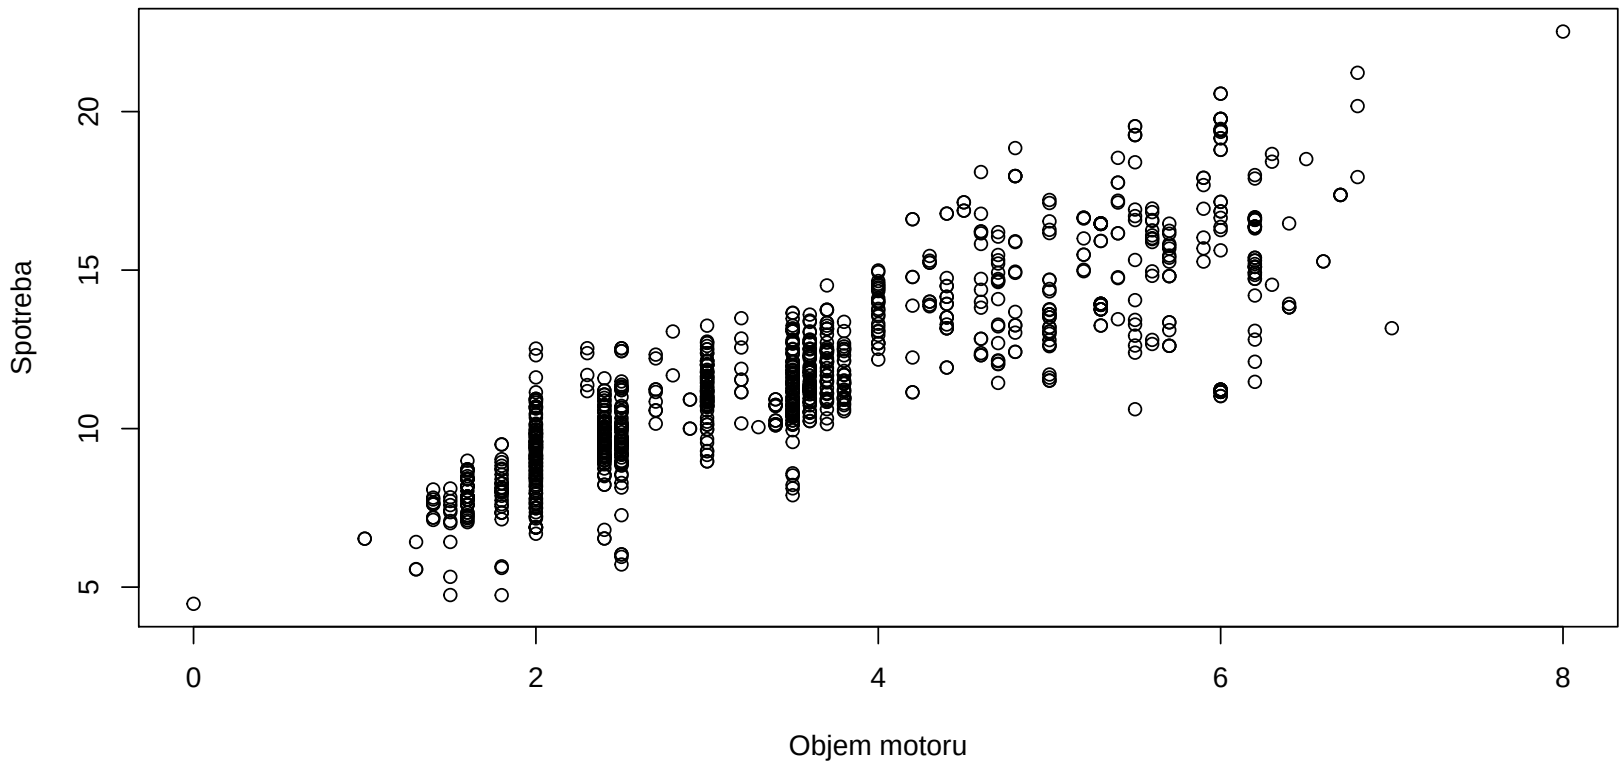

Vícenásobný krabičkový graf

Data [car-fuel]

```
> data = read.csv('../../data/car-fuel.csv')
> boxplot(LPH ~ Cylinders, data = data, varwidth = TRUE)
```

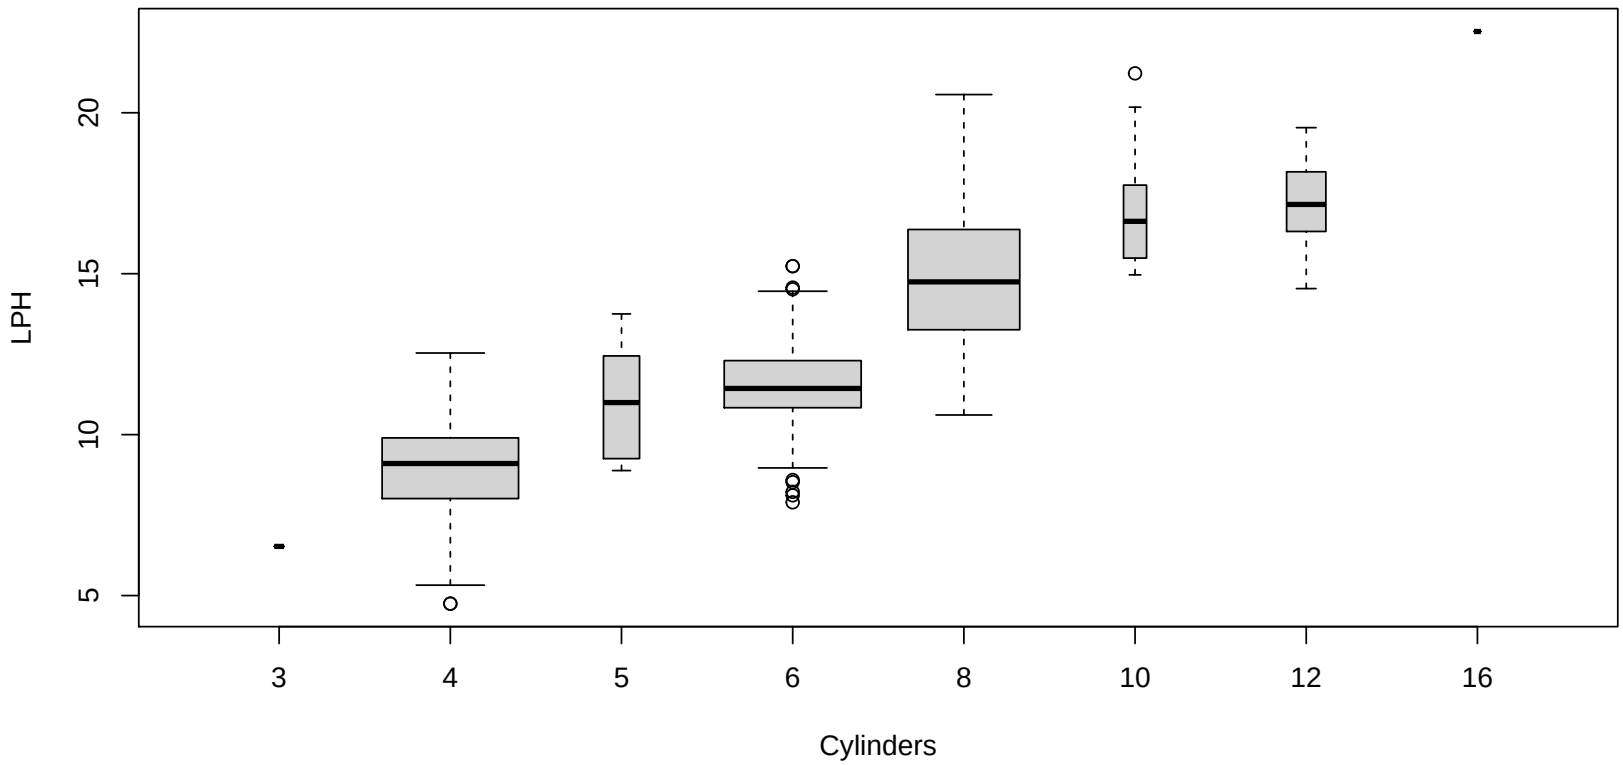

Obsah prezentace

Korelační matice

balíček ellipse

Balíček ellipse [Murdoch and Chow, 2012]

```
> suppressPackageStartupMessages(library('ellipse'))
> plotcorr(cor(mtcars))
```

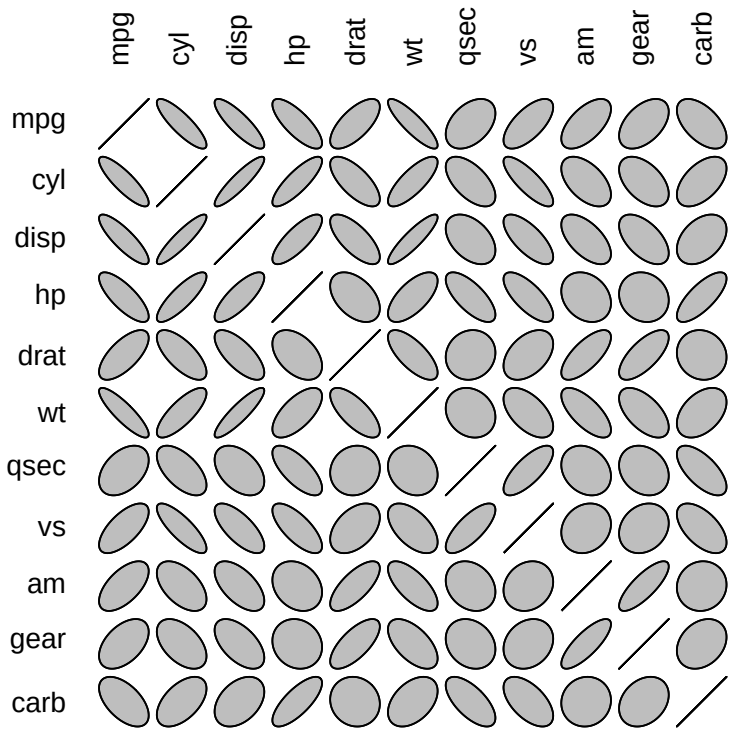

Korelační matice

balíček corrplot

Balíček corrplot [Wei and Simko, 2017]

```
> suppressPackageStartupMessages(library('corrplot'))
> corrplot(cor(mtcars))
```

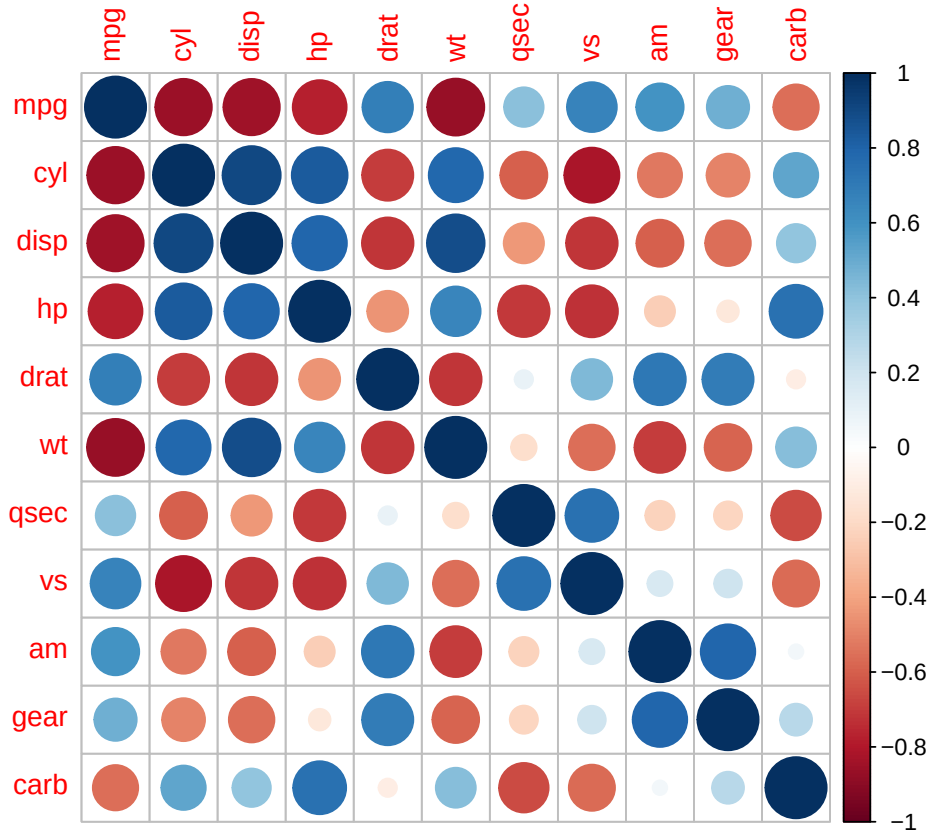

Rainbow plot

Data [mort]

```
> suppressPackageStartupMessages(library('demography'))
> load('../../data/mort.RData')
> plot(mort)
```

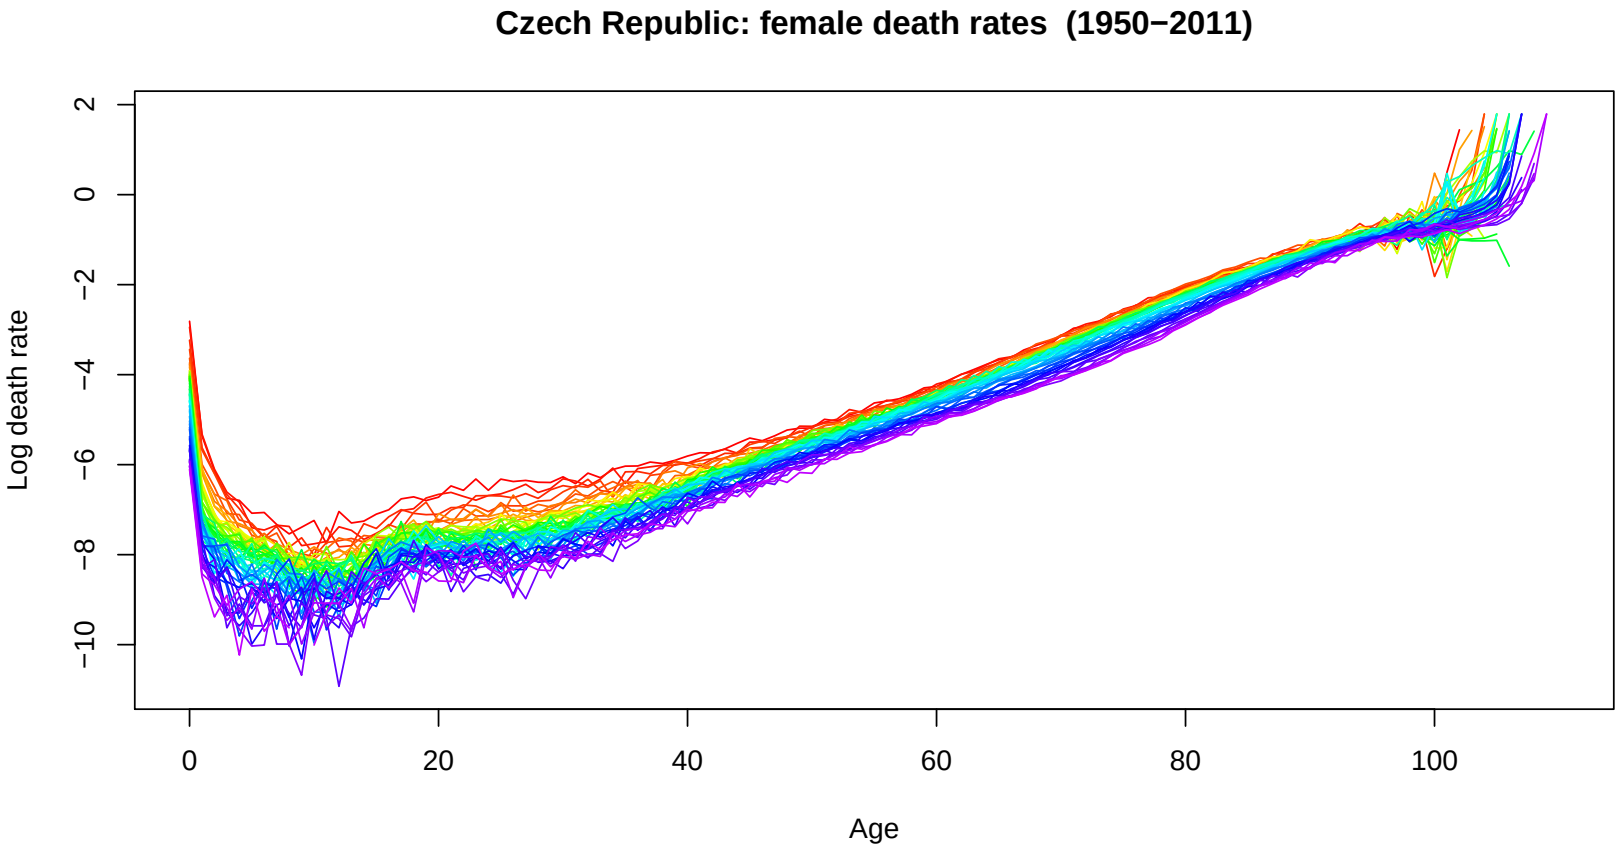

Obsah prezentace

Popisky

`main`	**hlavní nadpis**
`xlab`	**popisek x osy**
`ylab`	**popisek y osy**

Popisky

```
> plot(rnorm(50),
+      main = 'Hlavní nadpis',
+      xlab = 'Popisek x osy',
+      ylab = 'Popisek y osy')
```

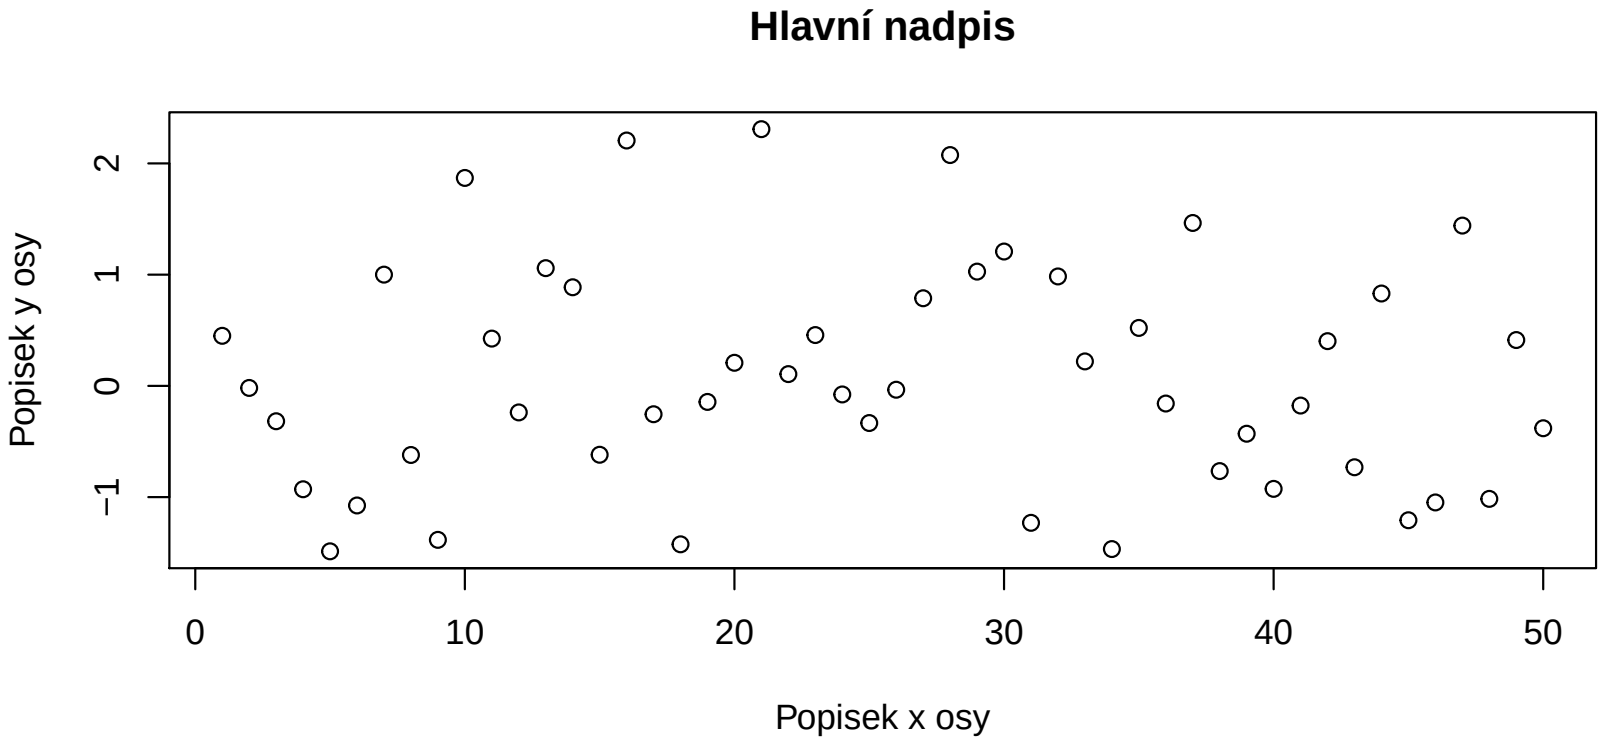

Více grafů v jednom obrázku

```
> par(mfrow = c(2,2))
> hist(rnorm(50))
> hist(runif(50))
> hist(rpois(50, 1.5))
> hist(rt(50, 10))
```

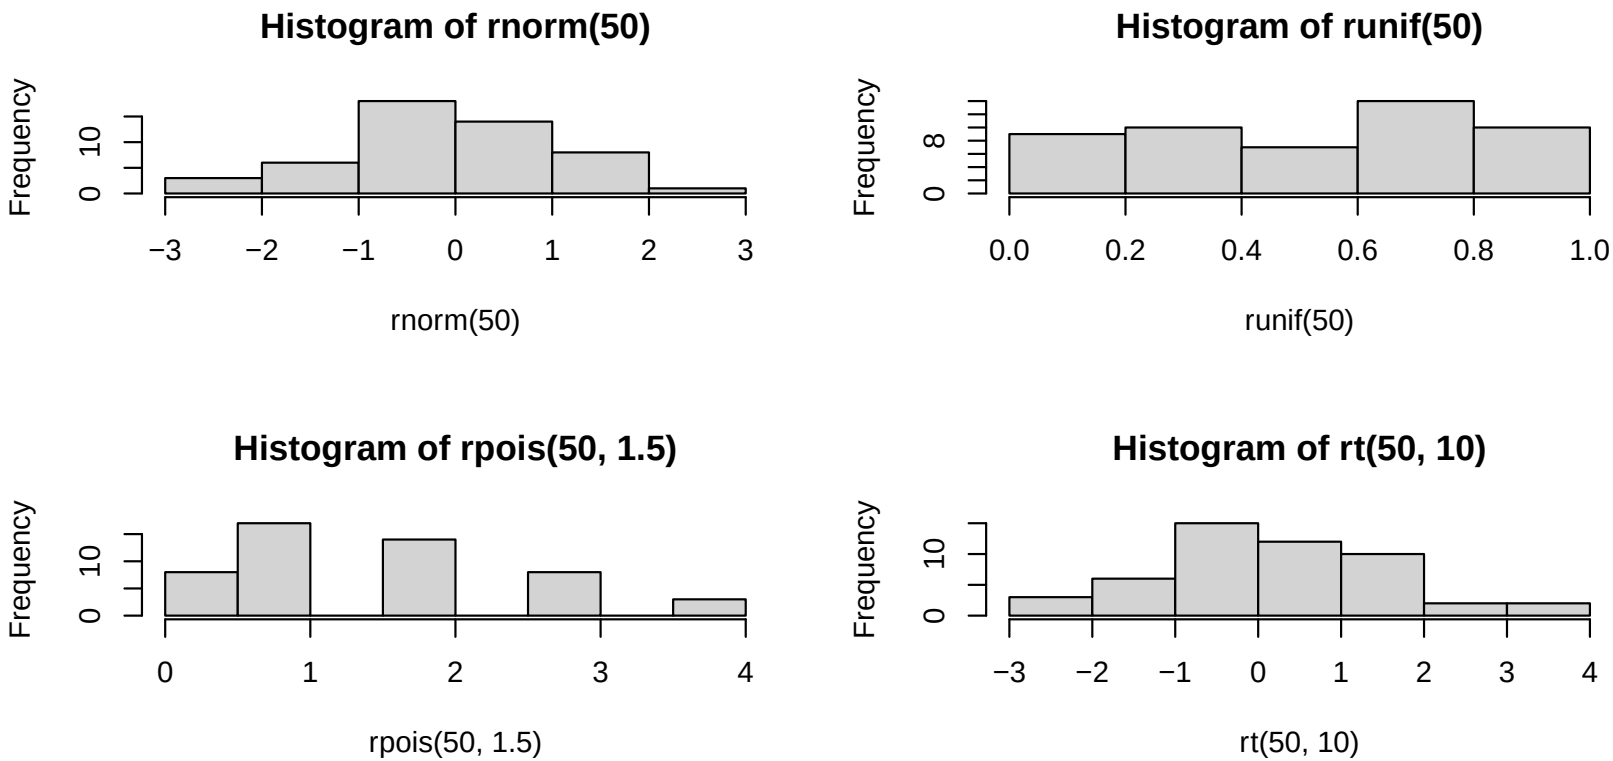

Obsah prezentace

Obsah prezentace

If/else

```
> if (CONDITION) {
+   # run this code if CONDITION is TRUE (or truthy)
+ } else {
+   # run this code if CONDITION is FALSE (or falsey)
+ }
> if (1 < 3) {
+   print('Yes')
+ } else {
+   print('No')
+ }
```

```
[1] "Yes"
```

If bez else

```
> x = 3
>
> if (x < 3) {
+   print('x is lower than 3')
+ }
>
> if (x < 5) {
+   print('x is lower than 5')
+ }
```

```
[1] "x is lower than 5"
```

Vnořené if

```
> x = 10
>
> if (x > 5) {
+   print('x is high')

+   if (x > 7) {
+     print('x is super-high!')
+   }
+ }
```

```
 [1] "x is high"
 [1] "x is super-high!"
```

ifelse

```
> x = c('a', 'b', 'a', 'a', 'c')
> ifelse(x == 'a', 'a', 'not a')
```

```
[1] "a"     "not a" "a"     "a"     "not a"
```

```
> y = 1:6
> data.frame(num = y, compared.to.3 = ifelse(y > 3, '>', '<='))
```

```
  num compared.to.3
1   1           <=
2   2           <=
3   3           <=
4   4            >
5   5            >
6   6            >
```

ifelse

Úkol

- Použijte data frame `mtcars`, viz. `?mtcars`.
- Doplňte sloupec `consumption` s hodnotami `"high"` pro `mpg` < 16 a `"low"` pro ostatní.
- Doplňte sloupec `strong` s hodnotami `TRUE` a `FALSE` podle sloupce `hp` (uvažujme auto jako `strong` pokud má více než 130 koní)

ifelse

Řešení

```
> # Optionally copy mtcars to a new data frame
> # so that we don't override the default
> mtcars.new = mtcars
> mtcars.new$consumption = ifelse(mtcars.new$mpg < 16, 'high', 'low')
> mtcars.new$strong = mtcars$hp > 130
```

Obsah prezentace

For cyklus

```
> for (i in 1:3) {
+   print(i)
+ }
```

```
[1] 1
[1] 2
[1] 3
```

```
> x = c('a', 'b', 'c')
>
> for (i in x) {
+   print(i)
+ }
```

```
[1] "a"
[1] "b"
[1] "c"
```

For cyklus

Proměnné

```
> x = 10:15
> y = c()
>
> for (i in seq_along(x)) {
+   y[i] = x[i]
+ }
>
> y
```

```
 [1] 10 11 12 13 14 15
```

For cyklus - sudé/liché

Úkol

- Pro každé z čísel od 1 do 20 vypište, zda je sudé, nebo liché

For cyklus - sudé/liché

Řešení

```
> for (i in 1:20) {
+   if (i %% 2 == 0) {
+     print('sudé')
+   } else {
+     print('liché')
+   }
+ }
```

```
[1] "liché"
[1] "sudé"
[1] "liché"
[1] "sudé"
[1] "liché"
[1] "sudé"
[1] "liché"
[1] "sudé"
[1] "liché"
[1] "sudé"
[1] "liché"
[1] "sudé"
[1] "liché"
[1] "sudé"
[1] "liché"
```

For cyklus

Příklad s if/else

```
> balance = 5
> transfers = c(100, -5, -20)
> for (transfer in transfers) {
+   if (transfer > 0) {
+     print(paste('received', transfer))
+   } else {
+     print(paste('paid', -transfer))
+   }
+   balance = balance + transfer
+   print(paste('current account balance:', balance))
+ }
```

```
[1] "received 100"
[1] "current account balance: 105"
[1] "paid 5"
[1] "current account balance: 100"
[1] "paid 20"
[1] "current account balance: 80"
```

For cyklus - vektor

Úkol

- Vyrobte vektor `numbers` obsahující čísla od 1 do 100
- Vyrobte proměnnou `numbers.sum` a pomocí `for` cyklu do ní uložte součet všech čísel z vektoru `numbers`

For cyklus - vektor

Řešení

```
> numbers = 1:100
> numbers.sum = 0
> for (i in numbers) {
+   numbers.sum = numbers.sum + i
+ }
> numbers.sum
```

```
[1] 5050
```

For cyklus

Data frame

```
> df = data.frame(letter = c('A', 'B', 'C'),
+                 is.vowel = c(TRUE, FALSE, FALSE))
>
> for (i in 1:nrow(df)) {
+   print(df[i, ])
+ }
```

```
  letter is.vowel
1      A      TRUE
  letter is.vowel
2      B     FALSE
  letter is.vowel
3      C     FALSE
```

For cyklus - mtcars

Úkol

- **Použijte data frame `mtcars`, viz. `?mtcars`**

- **Pro každé auto vypište, jestli je silnější nebo slabší než to předchozí (dle sloupce `hp`)**

For cyklus - mtcars

Řešení

```
> for (i in 2:nrow(mtcars)) {
+   current.value = mtcars$hp[i]
+   previous.value = mtcars$hp[i - 1]
+   if (current.value > previous.value) {
+     print('silnejsi')
+   } else {
+     print('slabsi')
+   }
+ }
```

```
[1] "slabsi"
[1] "slabsi"
[1] "silnejsi"
[1] "silnejsi"
[1] "slabsi"
[1] "silnejsi"
[1] "slabsi"
[1] "silnejsi"
[1] "silnejsi"
[1] "slabsi"
[1] "silnejsi"
```

Obsah prezentace

While cyklus

```
> x = 1
> while (x < 5) {
+   print(x)
+   x = x + 1
+ }
```

```
[1] 1
[1] 2
[1] 3
[1] 4
```

```
> x
```

```
[1] 5
```

While cyklus

Úkol

- Pomocí `while` určete, kolik je potřeba přirozených čísel (vzestupně od 1, tj. 1, 2, 3, ...), aby jejich součet byl větší než 100.

- Nápověda
  - vnější proměnné `count` a `total`
  - `1:count`, funkce `sum`

While cyklus

Řešení

```
> count = 0
> total = 0
> while (total < 100) {
+   count = count + 1
+   total = sum(1:count)
+ }
> count
```

```
[1] 14
```

Obsah prezentace

Funkce

Motivace

- **flexibilita, znovupoužitelnost, organizace delších skriptů**
- **DRY kód**

```
> FunctionName = function() {
+   return(1 + 2)
+ }
> FunctionName()
```

```
[1] 3
```

Funkce

Argumenty 1/2

```
> MySum = function(x, y) {
+   return(x + y)
+ }
>
> MySum(2, 3)
```

```
[1] 5
```

Funkce

Argumenty 2/2

```
> MySum = function(x = 3, y = 5) {
+   return(x + y)
+ }
>
> MySum()
```

```
[1] 8
```

```
> MySum(1)
```

```
[1] 6
```

```
> MySum(1, 2)
```

```
[1] 3
```

```
> MySum(y = 0)
```

```
[1] 3
```

Funkce

Variable scope 1/2

```
> MySum = function(x) {
+   inner.variable = 3
+   return(x + inner.variable)
+ }
> MySum(5)
```

```
[1] 8
```

```
> inner.variable
```

```
Error in eval(expr, envir, enclos): object 'inner.variable' not found
```

Funkce

Variable scope 2/2

```
> z = 1
> MySum = function(x) {
+   print(paste('z:', z))
+   z = z + 2
+   print(paste('z:', z))
+   return(x + z)
+ }
> MySum(5)
```

```
[1] "z: 1"
[1] "z: 3"
[1] 8
```

```
> z
```

```
[1] 1
```

Funkce

Příklad 1/2

```
> NumberIsEven = function(x) {
+   if (x %% 2 == 0) {
+     return(TRUE)
+   } else {
+     return(FALSE)
+   }
+ }
> NumberIsOdd = function(x) {
+   return(!NumberIsEven(x))
+ }
```

Funkce

Příklad 2/2

```
> NumberIsEven(11)
```

```
[1] FALSE
```

```
> NumberIsOdd(11)
```

```
[1] TRUE
```

```
> NumberIsEven(28)
```

```
[1] TRUE
```

```
> NumberIsOdd(28)
```

```
[1] FALSE
```

Funkce - součet sloupce

Úkol

- Vytvořte funkci `SumColumn` přijímající dva argumenty
  - data frame
  - jméno či index sloupce

- Funkce by měla vrátit součet hodnot v daném sloupci

```
> SumColumn(mtcars, 'cyl')
[1] 198
```

Funkce - součet sloupce

Řešení

```
> SumColumn = function(df, name.or.index) {
+   column = df[, name.or.index]
+   return(sum(column))
+ }
> SumColumn(mtcars, 'cyl')
```

```
[1] 198
```

Funkce - čtvercová matice

Úkol

- **Vytvořte funkci `SquareMatrix` přijímající číslo `n` jako argument.**
- **Funkce by měla vrátit čtvercovou matici o rozměrech $n \times n$ vyplněnou přirozenými čísly postupně od 1**

```
> SquareMatrix(2)
     [,1] [,2]
[1,]    1    3
[2,]    2    4
```

Funkce - čtvercová matice

Řešení

```
> SquareMatrix = function(n) {
+   numbers = 1:(n^2)
+   square.matrix = matrix(numbers, nrow = n, ncol = n)
+   return(square.matrix)
+ }
> SquareMatrix(2)
```

```
 [,1] [,2]
    1    3
    2    4
```

Funkce - variační koeficient

Úkol

- **Vytvořte funkci `CoefficientOfVariation` přijímající vektor jako argument, ze kterého spočítá variační koeficient.**

$$c_v = \frac{\sigma}{\mu}$$

- **Pro odhad μ použijte průměr `mean`**

- **Pro odhad σ použijte směrodatnou odchylku `sd`, viz. `?sd`**

Funkce - variační koeficient

Řešení

```
> CoefficientOfVariation = function(data) {
+   data.mean = mean(data)
+   data.sd = sd(data)
+   return(data.sd / data.mean)
+ }
> CoefficientOfVariation(c(1, 2, 3))
```

```
[1] 0.5
```

Obsah prezentace

Data

Data [mort] a balíček demography [Hyndman et al., 2012] pro snazší práci s daty

```
> load('../../data/mort.RData')
> suppressPackageStartupMessages(library('demography'))
> mort
```

```
Mortality data for Czech Republic
     Series: female male total
     Years: 1950 - 2011
     Ages:   0 - 110
```

Regresní analýza úmrtnosti mužů v roce 2011.

```
> last.column = ncol(mort$rate$male)
> data.mortality = mort$rate$male[, last.column]
> data.ages = mort$age
```

Data

Graf

Prozkoumejme data graficky

```
> plot(data.mortality ~ data.ages)
```

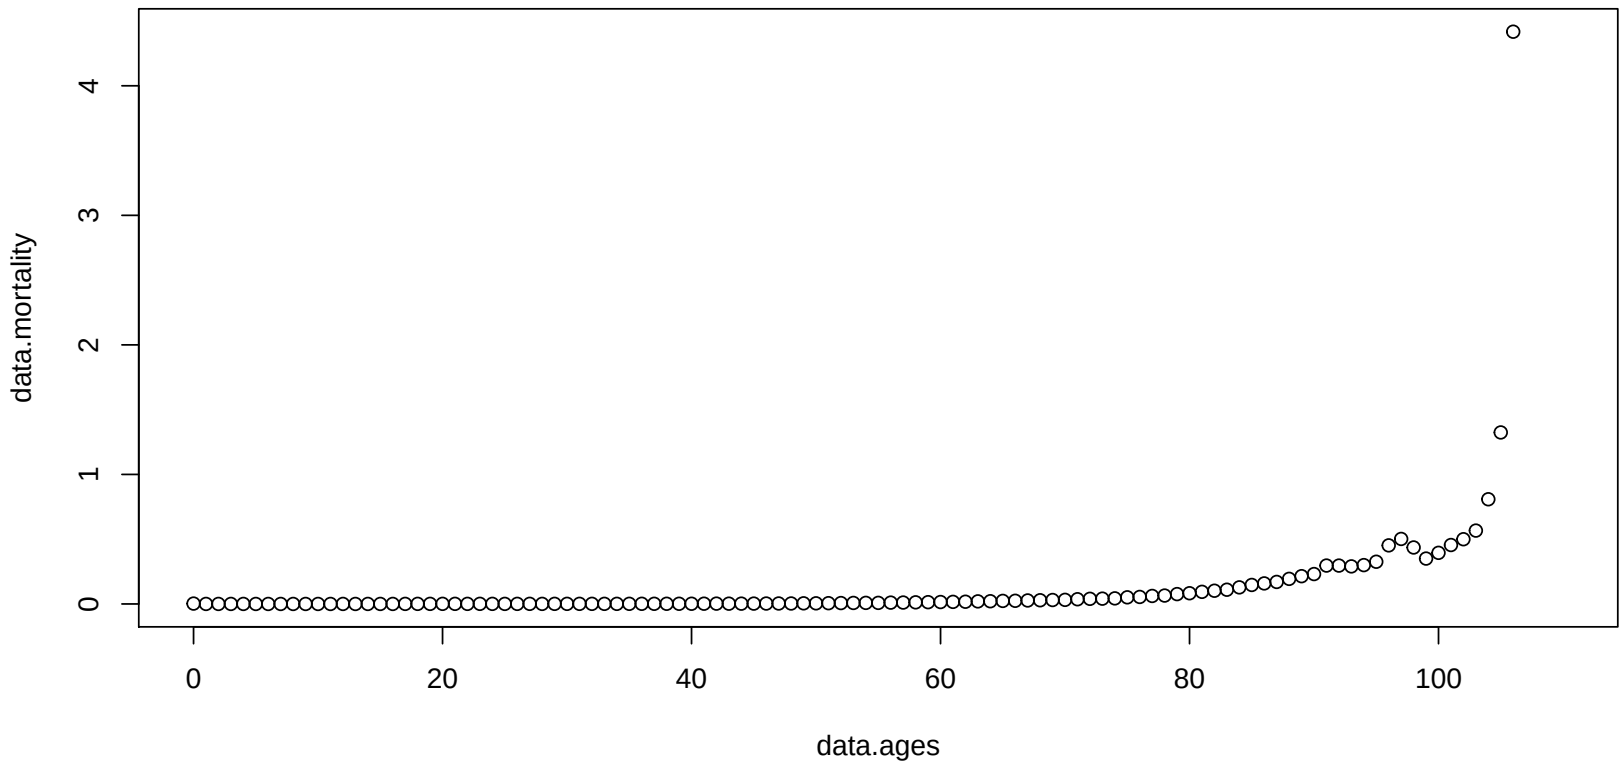

Data

Graf

Prozkoumejme data graficky

```
> plot(data.mortality ~ data.ages)
```

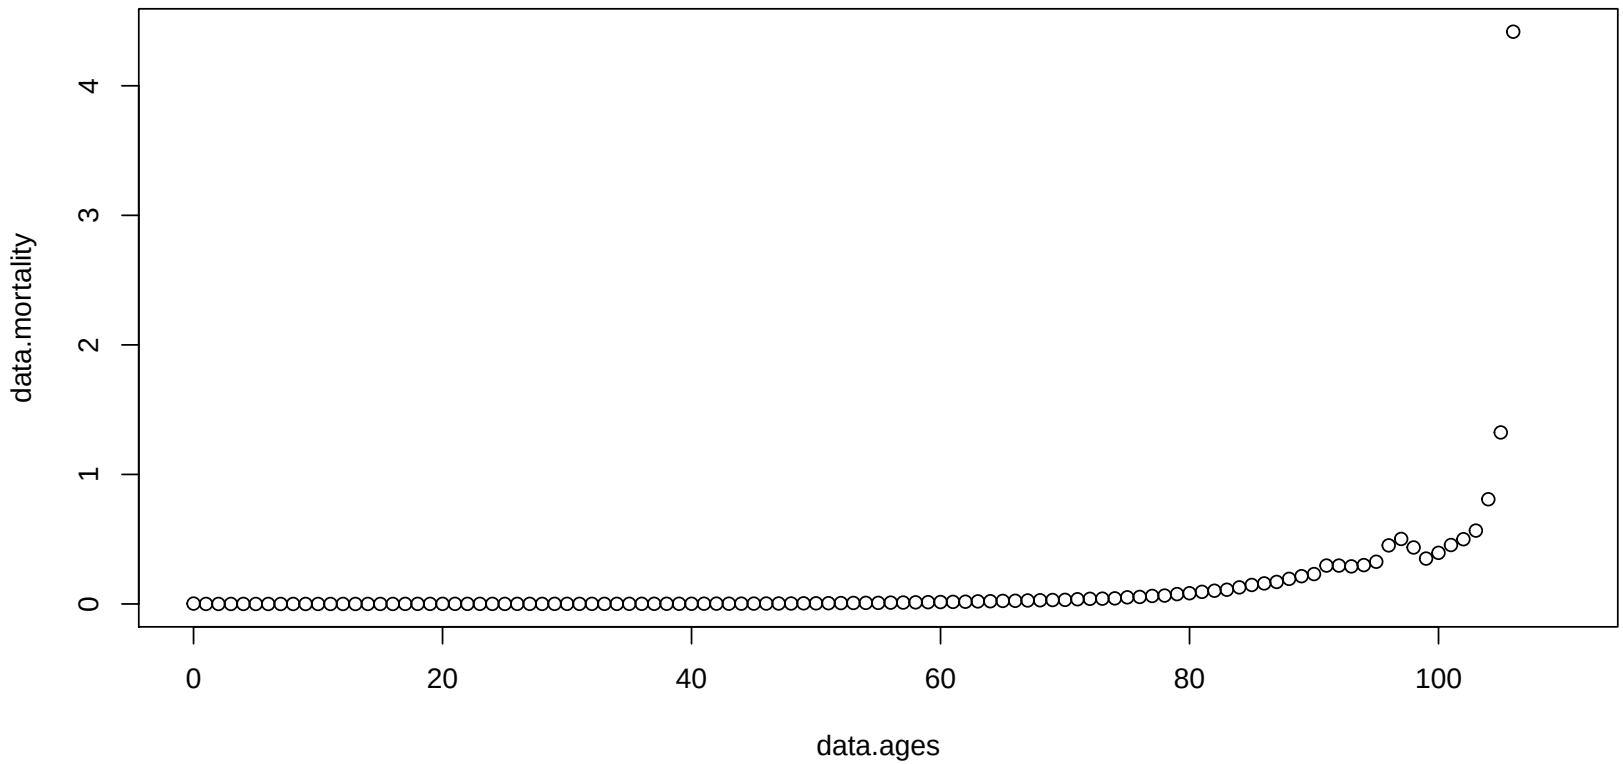

Naivní regresní přímka I

```
> fit.line = lm(data.mortality ~ data.ages)
> summary(fit.line)
```

```
Call:
lm(formula = data.mortality ~ data.ages)

Residuals:
   Min     1Q Median     3Q    Max
-0.225 -0.164 -0.068  0.066  3.951

Coefficients:
             Estimate Std. Error t value  Pr(>|t|)
(Intercept) -0.20047    0.08049   -2.49     0.014 *
data.ages    0.00629    0.00131    4.79 0.0000054 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.'
    0.1 ' ' 1
```

Naivní regresní přímka II

```
Residual standard error: 0.419 on 105 degrees of
    freedom
  (4 observations deleted due to missingness)
Multiple R-squared:  0.18,^^IAdjusted R-squared:  0.172
F-statistic:   23 on 1 and 105 DF,  p-value: 0.00000543
```

Grafická diagnostika přes

```
> plot(fit.line)
```

Funkce pracující s výstupem lm()

`coefficients`	**vektor odhadů parametrů**
`confint`	**intervaly spolehlivosti pro odhady parametrů**
`fitted`	**hodnoty modelu**
`residuals`	**rezidua**
`anova`	**anova tabulka**
`vcov`	**kovarianční matice parametrů**
`influence`	**hodnoty pro další hodnocení kvality modelu**

Naivní regresní přímka

Zobrazení odhadu

```
> plot(data.mortality ~ data.ages)
> lines(fitted(fit.line), col = 'red')
```

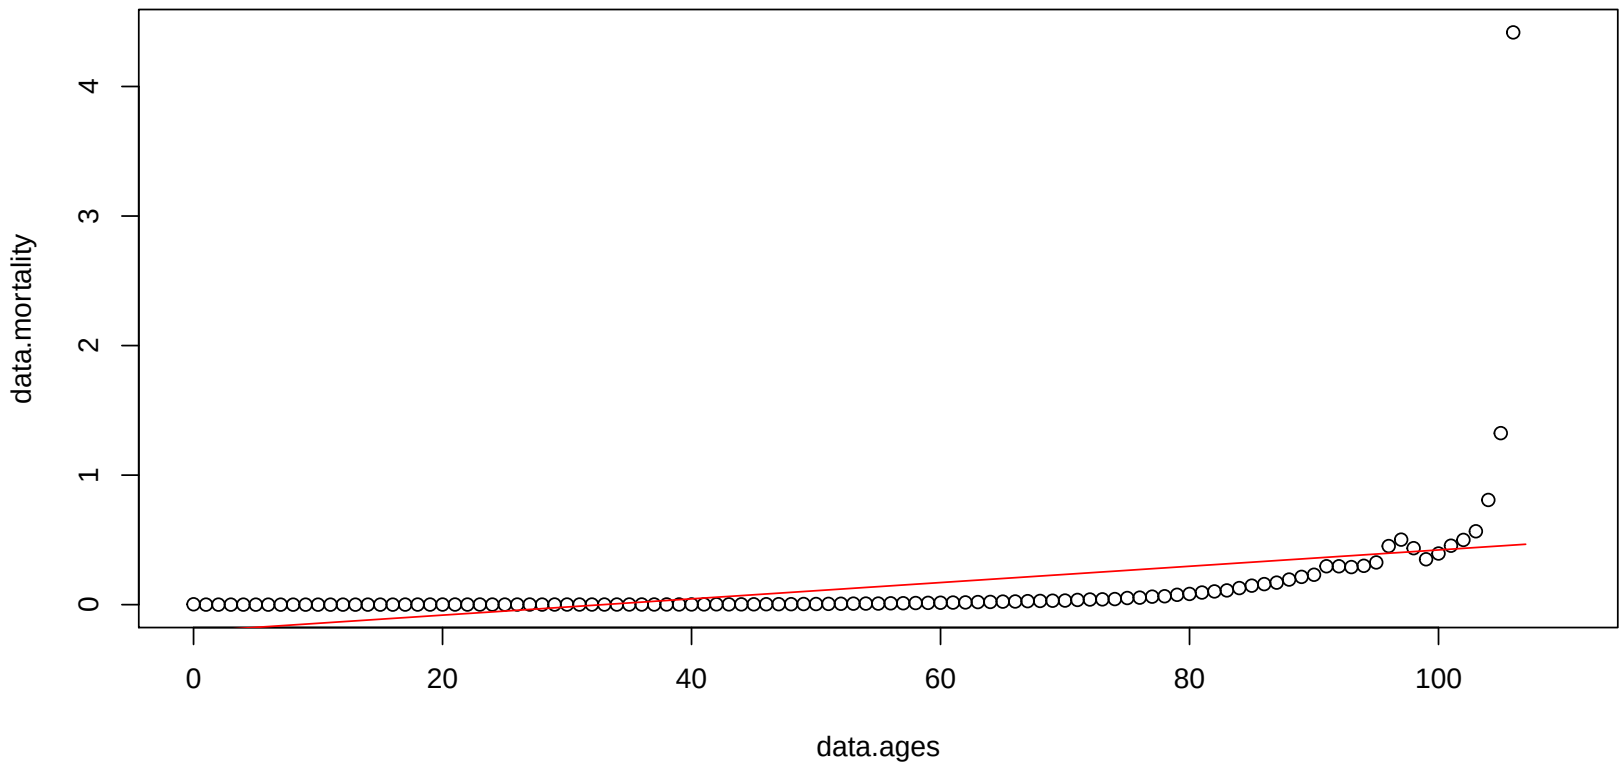

Parabola I

```
> fit.curve = lm(data.mortality ~ data.ages + I(data.ages^2))
> summary(fit.curve)
```

```
Call:
lm(formula = data.mortality ~ data.ages +
    I(data.ages^2))

Residuals:
   Min      1Q  Median      3Q     Max
-0.326  -0.155  -0.008   0.091   3.546

Coefficients:
                 Estimate  Std. Error  t value  Pr(>|t|)
(Intercept)     0.2050832   0.1071423     1.91   0.05835
    .
data.ages      -0.0168855   0.0046714    -3.61   0.00047
    ***
```

Parabola II

```
I(data.ages^2)  0.0002186  0.0000426    5.13 0.0000014
    ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.'
    0.1 ' ' 1

Residual standard error: 0.376 on 104 degrees of
    freedom
  (4 observations deleted due to missingness)
Multiple R-squared:  0.345,^^IAdjusted R-squared:
    0.332
F-statistic: 27.4 on 2 and 104 DF,  p-value:
    0.000000000277
```

```
> plot(fit.curve)
```

Parabola

Zobrazení odhadu

```
> plot(data.mortality ~ data.ages)
> lines(fitted(fit.curve), col = 'red')
```

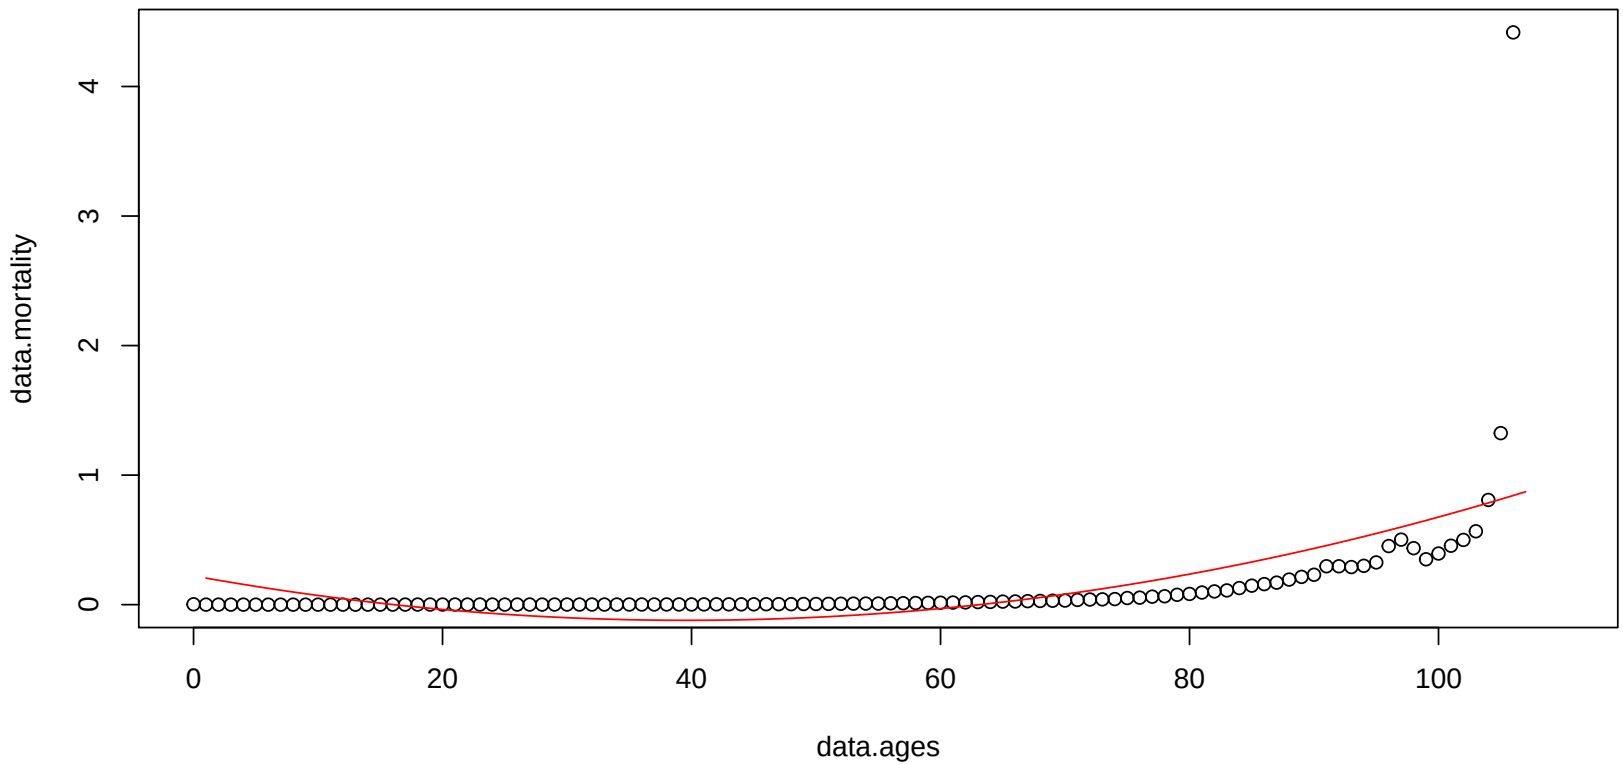

Parabola bez úrovňové konstanty I

```
> fit.curve.no.intercept = lm(data.mortality ~ data.ages + I(data.ages^2) - 1)
> summary(fit.curve.no.intercept)
```

```
Call:
lm(formula = data.mortality ~ data.ages +
    I(data.ages^2) - 1)

Residuals:
   Min      1Q  Median      3Q     Max
-0.293 -0.148   0.034   0.110   3.612

Coefficients:
                 Estimate Std. Error t value   Pr(>|t|)
data.ages       -0.0091831  0.0024025   -3.82
    0.00022 ***
I(data.ages^2)  0.0001584  0.0000291    5.44
    0.00000035 ***
---
```

Parabola bez úrovňové konstanty II

```
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.'
    0.1 ' ' 1

Residual standard error: 0.381 on 105 degrees of
    freedom
  (4 observations deleted due to missingness)
Multiple R-squared:  0.374,^^IAdjusted R-squared:
    0.363
F-statistic: 31.4 on 2 and 105 DF,  p-value:
    0.0000000000201
```

```
> plot(fit.curve)
```

Parabola bez úrovňové konstanty

Zobrazení odhadu

```
> plot(data.mortality ~ data.ages)
> lines(fitted(fit.curve.no.intercept), col = 'red')
```

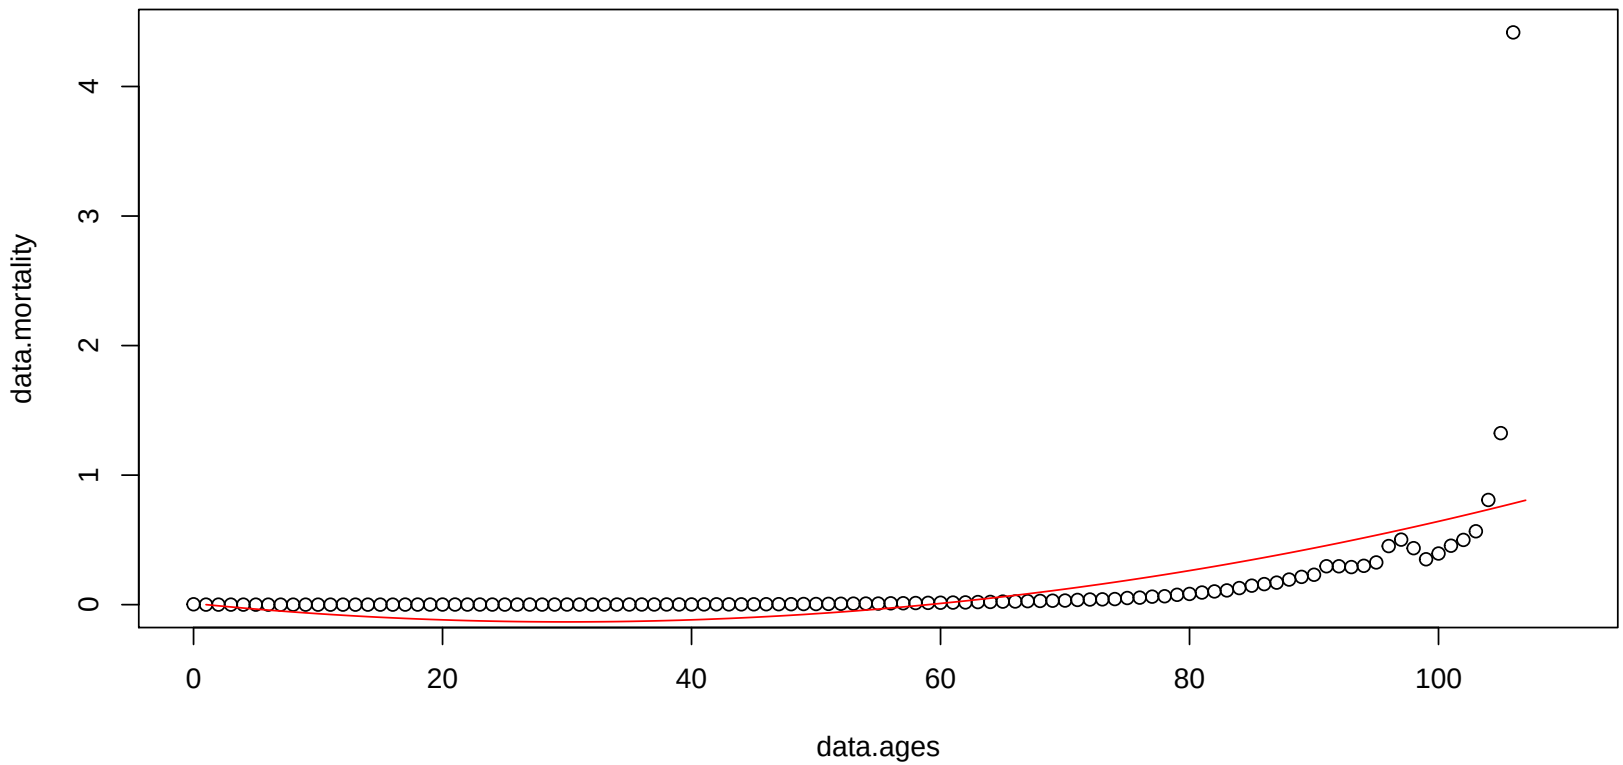

Obsah prezentace

Výpočet úmrtnostních tabulek

Úkol

- Proveďte zjednodušený výpočet úmrtnostních tabulek pro muže / ČR / 2020
- Vstupní data (věk, Dx a Px) z ČSÚ tabulek
- Metodika
  - Zjednodušení na “naivní” výpočet - použijeme jen reálné míry úmrtnosti
- Vstupem cesta k xlsx s ČSÚ tabulkou, výstupem data.frame a vygenerované xlsx s vlastním (naivním) výpočtem.
- Vyrobte R skript, poté zkuste zobecnit na funkci přijímající argumenty, např.

```
NaiveLifeTable = function(czso.xlsx.path, output = NULL) {}
```

Výpočet úmrtnostních tabulek

Řešení

life-tables.R

Skript je vystaven také na http://czso.petrmarek.eu/

Obsah prezentace

Použitá data

lengths.csv

```
> str(read.csv('../../data/lengths.csv'))
```

```
'data.frame':^^I7 obs. of  4 variables:
 $ identifier: int  7412301 7412302 7412303 7412304
     7412305 7412306 7412307
 $ sex       : chr  "M" "F" "F" "F" ...
 $ age       : int  18 33 41 40 23 58 31
 $ length    : num  11.7 16.7 13.4 12.7 16.2 17.2 11.2
```

Použitá data

fuel.csv

```
> str(read.csv('../../data/car-fuel.csv'))
```

```
'data.frame':^^I1142 obs. of  8 variables:
 $ Model.Yr : int  2012 2012 2012 2012 2012 2012 2012
     2012 2012 2012 ...
 $ Mfr.Name : chr  "aston martin" "aston martin"
     "aston martin" "aston martin" ...
 $ Carline  : chr  "V12 Vantage" "V8 Vantage" "V8
     Vantage" "V8 Vantage" ...
 $ Engine   : num  5.9 4.7 4.7 4.7 4.7 4.2 4.2 5.2 5.2
     4.2 ...
 $ Cylinders: int  12 8 8 8 8 8 8 10 10 8 ...
 $ MPG      : num  13.1 16 16 15.2 16 ...
 $ Gears    : int  6 6 7 6 7 6 6 6 6 6 ...
 $ LPH      : num  17.9 14.7 14.7 15.5 14.7 ...
```

Použitá data

excel.xlsx

Kombinace dat Data [car-fuel] a data framu `mtcars` jako jednotlivých listů v Excel sešitu

Použitá data

mort.Rdata

Roční panelová data udávající míry úmrtnosti v Českých zemích mezi lety 1950 a 2011. Data pocházejí z Human Mortality Database a jsou (po registraci) k dispozici ke stažení. Pro jednoduchou práci s daty využívám balíčku demography [Hyndman et al., 2012], který velmi snadno zachází s daty strukturovaných dle Human Mortality Database.

```
> load('../../data/mort.RData')
> suppressPackageStartupMessages(library('demography'))
> class(mort)
```

```
[1] "demogdata"
```

```
> mort
```

```
Mortality data for Czech Republic
    Series: female male total
    Years: 1950 - 2011
    Ages:   0 - 110
```

Reference I

J. Hester and H. Wickham. *odbc: Connect to ODBC Compatible Databases (using the DBI Interface)*, 2021. URL https://CRAN.R-project.org/package=odbc. R package version 1.3.2.

R. J. Hyndman, contributions from Heather Booth, L. Tickle, J. Maindonald, S. Wood, and R. C. Team. *demography: Forecasting mortality, fertility, migration and population data*, 2012. URL http://CRAN.R-project.org/package=demography. R package version 1.14.

D. Murdoch and E. D. Chow. *ellipse: Functions for drawing ellipses and ellipse-like confidence regions*, 2012. URL http://CRAN.R-project.org/package=ellipse. R package version 0.3-7.

Reference II

R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2014a. URL http://www.R-project.org/.

R Core Team. *foreign: Read Data Stored by Minitab, S, SAS, SPSS, Stata, Systat, Weka, dBase, ...*, 2014b. URL http://CRAN.R-project.org/package=foreign. R package version 0.8-61.

D. W. Scott. On optimal and data-based histograms. *Biometrika*, 66 (3):pp. 605–610, 1979. ISSN 00063444. URL http://www.jstor.org/stable/2335182.

A. Walker. *openxlsx: Read, Write and Edit XLSX Files*, 2018. URL https://CRAN.R-project.org/package=openxlsx. R package version 4.1.0.

Reference III

T. Wei and V. Simko. *R package "corrplot": Visualization of a Correlation Matrix*, 2017. URL https://github.com/taiyun/corrplot. (Version 0.84).

Y. Xie. *knitr: A General-Purpose Package for Dynamic Report Generation in R*, 2014. URL http://yihui.name/knitr/. R package version 1.8.

Feedback

https://docs.google.com/forms/d/e/1FAIpQLSf5ERhzT6MXyCG-UBlW_TYM1AaGCCHMcG-HoUaC7EuhkuU5kg/viewform