Jak pracovat s jazykem R

Kateřina Konečná, Jan Koláček

Obsah

Úvod

R je volně dostupný jazyk používaný zejména v akademické a vědecké sféře. Jde o program specializovaný především na statistické výpočty. Ve standardní distribuci, popř. v podpůrných balíčcích je implementováno velké množství pokročilých statistických funkcí (množství statistických testů, ANOVA, ...).

Neméně důležitou roli v tomto programu hraje velmi precizně propracovaný výstup s nepřeberným množstvím 2D i 3D grafů. Pomocí několika příkazů můžeme libovolně graf upravovat, přidávat popisky, měnit barvy, vzhled, velikost, ... dle našich představ. Samozřejmostí je i možnost psát vlastní funkce a skripty.

Stejně jako MATLAB, i R může být navíc použito k maticovým výpočtům, řešení systémů lineárních rovnic apod.

Program můžeme stáhnout z webových stránek projektu (`http://www.r-project.org`, [19]), kde jsou k dispozici i podrobné manuály ([17], [10]) a online nápověda.

Srozumitelným a velmi přehledně zpracovaným materiálem s množstvím názorných příkladů a doplňkových otázek je skriptum P. Drozd: Cvičení z biostatistiky [3], z anglické literatury mohu doporučit studijní materiály Theresy A. Scott [11], [12], [13], [14]. Velkým přínosem mi byly i dokumenty srovnávající příkazy v R s ekvivalentními příkazy v MATLABu [5], [4].

Někdy se syntaxe či chování R a MATLABu výrazně liší. V těchto případech je v textu na tyto odlišnosti upozorněno a pro zvýraznění a snadnější orientaci je na okrajích stránek použita ikonka MATLABu [22].

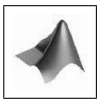

Kapitola 1

První setkání s jazykem R

1.1 Základní ovládání

R je volně dostupný programovací jazyk a softwarové prostředí pro statistické výpočty a grafiku, který je možný provozovat na operačních systémech UNIX, Windows i MacOS. R je skutečně „jen“ programovací jazyk - žádné grafické rozhraní, které by se dalo ovládat myší, zde není. Pro grafické rozhraní (GUI) je potřeba vyzkoušet některé grafické nástavby (Poor Man's GUI, Rcommander, ...). Program lze získat z webových stránek projektu (`http://www.r-project.org`, [19]).

Po spuštění programu se objeví okno s konzolou (R console), ve kterém se dají spouštět funkce, vkládají se objekty, provádí se výpočty a zobrazují se i základní výstupy. Dále se můžeme setkat i s dalšími typy oken:

- **okno nápovědy** - volá se po zadání příkazu `help()`
- **grafické okno** - při spuštění grafické prezentace
- **editor programu** - zobrazíme ho v menu *File* → *New Script*. Toto okno je určeno k tvorbě programů. (U delších zdrojových kódů je výhodné mít k dispozici editor s číslovanými řádky, kontrolu syntaxe R a závorek - jako freeware PSPad, `http://www.pspad.com` , nebo shareware WinEdt, `http://www.winedt.cz`)

To, že je konzole připravena k používání, symbolizuje prompt `>`, za nímž následují jednotlivé příkazy. Pokud nezměníme základní nastavení, řádky, do nichž vepisujeme příkazy, jsou odlišeny červenou barvou. Výstupní řádek je psán modrým písmem, v případě hodnot začíná pořadovým číslem dané hodnoty. Příkaz v konzole spustíme klávesou ENTER. Takto provedený příkaz nelze opravit přímo, ale v již napsaných příkazech můžeme listovat pomocí kláves $\uparrow\downarrow$, jež umožňují pohyb v historii příkazů. Historii příkazů můžeme uložit v menu *File* → *Save History*. Konzole se všemi příkazy může být uložena v menu *File* → *Save to File* ....

Jednotlivé příkazy jsou vkládány na nový řádek, v případě více příkazů za sebou jsou navzájem oddělovány středníkem. Složitější příkazy, které mají být spuštěny bezprostředně po sobě, jsou seskupovány pomocí složených závorek. Každý příkaz je následován kulatými závorkami s argumenty v případě, že jsou požadovány. Argumenty lze uvádět ve stejném pořadí, v jakém byly definovány, nebo je možno je uvádět v libovolném pořadí ve tvaru `nazev.argumentu=hodnota`. Argumenty je často možné zkracovat (jestliže zkratka nemůže znamenat jiný argument), např. `round(x, digits=2)` má naprosto stejný význam jako `round(x, d=2)` (jedná se o funkci zaokrouhlení na 2 desetinná místa).

Příkazem `<-` (popř. `=`, ten se ovšem nedoporučuje) vložíme daný výraz do proměnné. K jejímu zobrazení musí být v konzole z příkazové řádky zavolán jeho název. Další možností je zadání celého příkazu do kulatých závorek.

```
> a <- 2
> a
[1]  2
> (a <- 2)
[1]  2
```

Pro neúplné příkazy se na následujícím řádku objeví prompt `+` , která dává možnost dodat část příkazu, který chybí, a pokračuje dál ve čtení.

```
> a <- (2+3
> + ) * 5
[1]  25
```

Symbol `#` na příkazové řádce způsobí ignoraci zbytku řádky (komentář).

```
> a <- 2 # komentar
> a
[1]  2
```

Při zadávání názvu jednotlivých proměnných či objektů bychom měli dodržovat určitá pravidla. Názvy se mohou skládat z písmen (`a`–`z`, `A`–`Z`), číslic (`0`–`9`), tečky a podtržítka. Název musí začínat písmenem, nesmí začínat číslicí, tečka rovněž není doporučována. Matematické operátory (`+`, `-`, `*`, `/`), mezera a jiné další speciální znaky také nejsou povoleny. Chceme-li použít víceslovný název, rozdělení názvu na dvě části se provádí pomocí tečky (např. průměrnou výšku chlapců můžeme nazvat `chlapci.prumer`), popř. pomocí podtržítka (`chlapci_prumer`). Rovněž bychom se měli vyvarovat používání názvů vestavěných proměnných. R je *case sensitive*, tzn. rozlišuje malá a velká písmena.

```
> a <- 2
> a
[1]  2
```

```
> A
Error: object 'A' not found
```

Běžící program může být zastaven klávesou ESC ve Windows, CTRL + C v Linuxu. Konzolu můžeme vymazat klávesovou zkratkou CTRL + L nebo v menu *Edit* → *Clear Console*.

Pro ukončení programu se používá příkaz `q()`.

1.2 Nápověda

Příkazem `help()` je vyvoláno další okno – okno nápovědy. V levé části můžeme najít abecedně seřazený seznam objektů, poklikáním na některý z nich se v hlavním okně zobrazí popis objektu. Pro zobrazení nápovědy ke konkrétním objektům či funkcím slouží příkaz `help(tema)`, alternativou může být rovněž `?tema` nebo v menu *Help* → *R-functions (text)* .... Chceme-li znát argumenty příkazu, můžeme použít funkci `args(nazev_funkce)`.

Pro vyhledávání témat v kontextu (tzn. ne pouze v názvech a zkrácených popisech funkcí a objektů, ale i v klíčových slovech) slouží příkaz `help.search("tema")`, v menu *Help* → *Search Help* nebo v okně nápovědy pod záložkou *Vyhledávat*. Příkazem `apropos("nazev")` zobrazíme příbuzné příkazy k příkazu `nazev`, pro příklady k nějakému tématu použijeme příkaz `example(tema)`.

K dispozici jsou rovněž PDF manuály, které obsahují základní manuály a reference o funkcích. Spouští se přes menu *Help* → *Manuals (in PDF)*. HTML nápovědu, obsahující manuály, seznamy funkcí, apod. zobrazíme příkazem `help.start()` nebo přes menu *Help* → *Html help*.

Jazyk R nabízí i několik funkcí, které uživatelům usnadňují pochopení některých příkazů. Funkce `demo` je uživatelsky příznivé prostředí, ve kterém běží demonstrace (ukázkové programy) R skriptů. Příkaz `demo()` vypíše seznam všech dostupných demonstrací. Argumenty funkce `demo`:

`topic`	téma, které má být demonstrováno
`package`	název balíčku, ze kterého má být spuštěno `topic`

`> demo(persp)` v novém okně spustí ukázky použití funkce `persp`

V MATLABu je analogickým příkazem funkcí `help(funkce)` a `?funkce` příkaz `help funkce`.

1.3 Workspace (pracovní prostor)

Program R načítá data z jakéhokoliv adresáře. Nejjednodušší pro manipulaci s nimi je ukládat si data do tzv. pracovního adresáře (workspace). Chceme-li zjistit, ve kterém adresáři se právě nacházíme, použijeme příkaz `getwd()`. Ten zobrazí kompletní cestu do aktuální složky. Pro změnu pracovního adresáře použijeme příkaz `setwd()`, jehož argumentem je cesta k adresáři v jednoduchých apostofech (') nebo uvozovkách ("). Změna adresáře je rovněž možná přes menu *File* → *Change dir* ....

```
> (setwd("C:/Documents and Settings/PC/Plocha/R"))
```
nastaví za pracovní adresář složku R umístěnou na ploše a vypíše cestu složky, ze které jsme vycházeli.
```
[1]  "C:/Documents and Settings/PC/Dokumenty"
```
O tom, že se opravdu nacházíme v adresáři R, se můžeme přesvědčit příkazem
```
> getwd()
[1]  "C:/Documents and Settings/PC/Plocha/R"
```

Příkazy `dir()` nebo `list.files()` zobrazíme názvy souborů v aktuálním nebo zadaném adresáři.
```
> dir()
```
výpis souborů v aktuálním adresáři
```
[1]  "cviceni"   "prednasky"   "data"
> dir("C:/Documents and Settings/PC/Plocha/R/cviceni")
[1]  "cviceni 1"   "cviceni 2"   "cviceni 3"   "cviceni 4"
[5]  "cviceni 5"   "cviceni 6"
> list.files("C:/Documents and Settings/PC/Plocha/R/cviceni")
[1]  "cviceni 1"   "cviceni 2"   "cviceni 3"   "cviceni 4"
[5]  "cviceni 5"   "cviceni 6"
```

Všechny objekty, které v průběhu práce vytvoříme, se ukládají do paměti a můžeme s nimi kdykoliv manipulovat. Vytvořené objekty tvoří tzv. workspace (pracovní prostor), chceme-li je uchovat pro pozdější práci, celý workspace uložíme pomocí *File* → → *Save Workspace* .... Tímto způsobem vytvoříme soubor s koncovkou .R, který se při dalším spuštění ze stejného adresáře automaticky nahraje spolu s historií příkazů. V případě, že zavřeme program R bez uložení, při dalším spuštění už dříve definované objekty nejsou k dispozici. Více o ukládání jednotlivých objektů viz odstavec 7.2.

Další užitečné příkazy:
`objects()`, `ls()` vypíše všechny názvy objektů, které jsou momentálně definovány v aktuálním adresáři
`ls(name, pattern, all.names=T)` vypíše ty objekty, které jsou omezeny volitelnými parametry:

`name` výpis konkrétního objektu podle čísla nebo názvu prostředí

`pattern` vyhledávací výraz (např. objekty začínající na "a")
`all.names` nastavený na hodnotu `TRUE` vyhledává také objekty začínající tečkou
`rm()` maže vybrané objekty
`rm(list=ls())` maže všechny objekty

```
> ls(pattern="v")
[1]  "v"    "vec"    "vector"
> ls(pattern="v", all.names=T)
[1]  ".vec"    "v"    "vec"    "vector"
> rm(v,vec)    příkaz analogický příkazu rm(list=c("v","vec"))
> ls()
[1]  ".vec"    "vector"
```

Kapitola 2

Rozdělení objektů

2.1 Datové typy objektů

Jazyk R používá následující datové typy:

- *číslo (numeric)* vypisujeme klasickým způsobem, k oddělení desetinných míst používáme desetinnou tečku, tzn.
  ```
  > 1.234
  ```

- *komplexní* - numerická hodnota je doplněna o komplexní jednotku i, např.
  ```
  > 1 + 2i
  [1]  1 + 2i
  > 3 + 1i   Pozor! Komplexní jednotka musí být vždy doplněna o numerickou hodnotu
  [1]  3 + 1i
  > 3 + i
  Error: object 'i' not found
  ```

- *logické hodnoty* - hodnoty `TRUE`, `T` a `FALSE`, `F` (Pozor! Jazyk R je citlivý na velká a malá písmena, proto logické hodnoty nelze psát jinak než uvedeným způsobem.) Logické hodnoty se používají pro některé argumenty funkcí, jsou výsledkem testování výrazů, např.
  ```
  > 2.3 > 3
  [1]  FALSE
  ```

- *řetězec* - používá se pro textové hodnoty, pro popisky os, název grafu, ... Řetězec musí být zadán do jednoduchých apostrofů (') nebo dvojitých uvozovek (”):

```
> r <- "retezec"
[1]  "retezec"
> r <- 'retezec'
[1]  "retezec"
```

K dispozici jsou rovněž speciální hodnota `NA` ("Not Available"), která reprezentuje chybějící nebo neznámou hodnotu, a další speciální konstanty: `NULL`, odpovídající prázdnému objektu, `Inf`, odpovídající nekonečnu (např. `1/0`) a `NaN` ("Not-a-Number"), která je výsledkem numerických výpočtů, jež nejsou definovány (např. `0/0` nebo `Inf - Inf`).

2.2 Datové struktury

Vedle datových typů objektů, jazyk R poskytuje i množství datových struktur, které umožňují vícero hodnot specifikovat jako samostatný objekt. Mezi základní datové struktury patří vektor, faktor, matice, pole, tabulka dat a seznam. V následujících kapitolách se dozvíme, jak jednotlivé datové objekty definujeme, jak s nimi pracujeme. Protože každý objekt má svá specifika, následující tabulka souhrnně uvádí základní datové struktury a odpovídající datové typy, kterými mohou být tvořeny.

datová struktura	**datový typ**	**možnost více typů dat současně**
vektor	numerický, komplexní, logický, řetězec	ne
faktor	numerický, řetězec	ne
matice	numerický, komplexní, logický, řetězec	ne
pole	numerický, komplexní, logický, řetězec	ne
tabulka dat	numerický, komplexní, logický, řetězec	ano
seznam	numerický, komplexní, logický, řetězec, funkce, výraz, ...	ano

Tab. 2.1. Přehled datových typů objektů

Kapitola 3

Vektory

3.1 Základní příkazy, tvorba vektorů

Jazyk R pracuje nad datovými strukturami. Nejjednodušší takovou strukturou je vektor. Např. jednoduchá hodnota (logická hodnota `TRUE`, numerická hodnota `2`, ...) je vektor délky 1. Vektory jsou 1-dimenzionální struktury, skládající se z posloupnosti prvků. Všechny prvky vektoru musí být stejného datového typu (modu) - *numerický*, *komplexní*, *logický* nebo typu *řetězec*.

Některé prvky vektoru ovšem nemusí být známy - v těchto případech je na místo příslušného prvku vektoru umístěna speciální hodnota `NA` („Not Available“). Všechny operace nad `NA` vrací hodnotu `NA`. Funkce `is.na(x)` vrací hodnoty `TRUE` na těch pozicích vektoru `x`, na kterých mají prvky hodnotu `NA`, na ostatních pozicích vrací hodnotu `FALSE`. Rovněž některé prováděné operace nemusí dávat smysl (např. `0/0`, `Inf - Inf`), v těchto případech vrací příkaz hodnotu `NaN` („Not a Number“).

Pro vytvoření numerického vektoru `x` o hodnotách -1.2, 31.8., 10.7, 5.6, 9.22 použijeme příkaz `x <- c(-1.2, 31.8, 10.7, 5.6, 9.22)`. Analogicky můžeme použít příkazu `assign("nazev", c())`, v našem případě tedy `assign("x", c(-1.2, 31.8, 10.7, 5.6, 9.22))`. Přiřazení může být rovněž provedeno v opačném směru: `c(-1.2, 31.8, 10.7, 5.6, 9.22) -> x`.

Naprosto analogickým způsobem můžeme zadávat komplexní vektory, např. `y <- c(1+2i, 3, 5i)`, vektory logických hodnot, např. `z <- (x<12 & x>-1)`, nebo vektory textových hodnot, např. `ovoce <- c("banan", "broskev", "jablko", "pomeranc")`.

```
> c(2, 4, "v", F)    jedna z hodnot je znak, vektor tedy bude textový
[1]  "2"   "4"   "v"   "FALSE"
```

Příkaz `vector(mode, length)` vytvoří vektor daného typu `mode` a dané délky `length` s nulovými hodnotami.

```
> vector(mode="logical", length=3)
[1]  FALSE  FALSE  FALSE
> vector(m="character", length=5)
[1]  ""  ""  ""  ""  ""
```

Nejjednodušším způsobem ke generování posloupností čísel je použít operátoru `:`. Příkaz `a:b` vygeneruje aritmetickou posloupnost prvků od `a` do `b` s krokem 1. Funkce `sequence(n)` slouží ke generování posloupnosti hodnot od čísla 1 do čísla (vektoru hodnot) uvedeného v argumentu funkce.

```
> 4:10
[1]  4  5  6  7  8  9  10
> 2.4:7
[1]  2.4  3.4  4.4  5.4  6.4
> sequence(6)
[1]  1  2  3  4  5  6
> sequence(c(3,5))
[1]  1  2  3  1  2  3  4  5
```

Ke generování posloupností s daným krokem MATLAB používá funkci `a:krok:b`. R tuto syntaxi nezná, je proto třeba použít jiných funkcí.

Pro generování složitějších posloupností se používá funkce `seq`, která má 5 argumentů, ale pouze některé z nich mohou být specifikovány současně při jednom volání.

- První 2 argumenty specifikují počáteční a koncový bod posloupnosti, příkaz `seq(2,10)` je ekvivalentní příkazu `2:10`. Argumenty mohou být rovněž volány pomocí `from=a, to=b`.
  Příkazy `seq(1,30)`, `seq(from=1, to=30)` a `seq(to=30, from=1)` vrací stejný výsledek.
- Argument velikosti kroku: `by=krok`.
- Argument délky posloupnosti: `length=delka`.
- V případě, že je použit argument `along.with`, musí být jediným argumentem fukce. Argument `along.with=v` generuje posloupnost o délce shodné s délkou vektoru v.

Příkaz `seq()` vytváří prázdnou posloupnost.

```
> seq()
[1]  1
```

```
> seq(from=2, to=10)
[1]  2   3   4   5   6   7   8   9   10
> seq(from=2, to=15, by=3)
[1]  2   5   8   11   14
> seq(length=6)
[1]  1   2   3   4   5   6
> seq(from=3, length=6)
[1]  3   4   5   6   7   8
> (k <- seq(to=13, length=6))
[1]  8   9   10   11   12   13
> 7 + seq(along.with=k)
[1]  8   9   10   11   12   13
```

Pro vytvoření vektoru, v němž se opakuje určitý objekt (hodnota nebo vektor), se používá funkce `rep(x)`. Jejími argumenty jsou:

`times=pocet` udává počet, kolikrát má být objekt za sebe poskládán

`each=pocet` udává počet opakování každé složky objektu

`length.out` udává délku výsledného vektoru

```
> x <- 2:5
> rep(x, times=3)   stejný výsledek dává i rep(x, 3)
[1]  2   3   4   5   2   3   4   5   2   3   4   5
> rep(x, each=3)
[1]  2   2   2   3   3   3   4   4   4   5   5   5
> rep(x, length.out=10)
[1]  2   3   4   5   2   3   4   5   2   3
> rep(rep(x, each=2), times=2)
[1]  2   2   3   3   4   4   5   5   2   2   3   3   4   4   5   5
```

Náhodná čísla generovaná v R (a obecně ve všech softwarech) nejsou ve skutečnosti zcela náhodná, ale jsou generována na základě specifických algoritmů tak, aby se náhodným číslům podobala (tzv. pseudonáhodná čísla). Podle pravděpodobnosti výskytu jednotlivých hodnot můžeme generovat čísla z různých typů rozdělení:

`runif(n, min=a, max=b)` Náhodně vygeneruje `n` náhodných čísel z intervalu (`a`, `b`), každé číslo má stejnou pravděpodobnost výskytu.

`rpois(n, lambda)` Náhodně vygeneruje `n` celých čísel z Poissonova rozdělení s parametrem `lambda`.

`rnorm(n, mean=mi, sd=sigma)` Náhodně vygeneruje `n` reálných čísel z normálního rozdělení se střední hodnotou `mi` a směrodatnou odchylkou `sigma`.

```
> runif(10, min=2, max=8)
[1]  3.468575   2.006183   5.151939   4.864977   5.117221   5.981666
[7]  6.186421   6.470627   7.230629   7.726394
> rpois(10, 5)
[1]  7   11   1   4   3   5   6   3   1   5
> rnorm(10, mean=5, sd=2)
[1]  3.880884   5.902384   9.645860   3.955287   3.923085   3.763641
[7]  1.782563   6.003977   7.512364   4.685642
```

Dalším užitečným příkazem ke generování vektorů je funkce `sample()`. Funkce `sample(x, size, replace=FALSE, prob=NULL)` vytvoří náhodnou permutaci prvků objektu `x`. Objekt `x` může být vektor (číselný, komplexní, logický nebo vektor znaků) nebo přirozené číslo. Argument `size` je přirozené číslo udávající délku výsledného vektoru. Argument `replace=TRUE` umožňuje opakování vybraných prvků, zatímco implicitní nastavení `replace=FALSE` opakování nepovoluje. Argument `prob` umožňuje nastavení pravděpodobnostních vah výběru jednotlivých prvků.

```
> x <- c(1, 3, 5, 7, 2, 6)
> sample(x, 3)
[1]  6   7   2
> sample(x, 3, replace=TRUE)
[1]  3   3   2
> x <- letters[1:15]    vektor prvních 15 písmen abecedy (a–o)
> sample(x, 4, prob=c(1, rep(0.1, 13), 1))
[1]  "a"   "o"   "d"   "l"
> sample(x, 8, prob=c(1, rep(0.1, 13), 1), replace=TRUE)
[1]  "e"   "b"   "o"   "o"   "n"   "a"   "a"   "c"
```

3.2 Subvektory

K výpisu určité podmnožiny prvků vektoru můžeme použít hranatých závorek, `[]`. Obecně má pro vektor `x` tento příkaz tvar `x[index]`, kde `index` je vektor jednoho z následujících tvarů:

1. **Vektor přirozených čísel.** Jedná se o vektor indexů, který nabývá hodnot z množiny $\{1, 2, \ldots, \texttt{length(x)}\}$.
   ```
   > x <- 2:16
   > x[7]    vypíše 7. složku vektoru x
   [1]  8
   > x[4:12]    vypíše 4.–12. složku vektoru x
   [1]  5   6   7   8   9   10   11   12   13
   ```

Hodnota `NA` je vrácena v případě, že vektor `index` obsahuje přirozené číslo větší než je délka vektoru. Podobně R vrací prázdný vektor `numeric(0)` v případě, že vektor `index` obsahuje nulu:

```
> x[13:18]    vypíše 13.–18. složku vektoru x
[1]  14   15   16   NA   NA   NA
> x[c(7, 0, 5, 12)]    index 0 se ignoruje
[1]  8   6   13
> x[0]
[1]  integer(0)
```

Vektor `index` můžeme definovat rovněž použitím funkcí ke konstrukci numerických vektorů, např. `c(), :, rep(), sample(), seq()`

```
> x[c(3, 8, 10, 4, 7)]
[1]  4   9   11   5   8
> x[c(rep(4, 2), rep(7, 3))]
[1]  5   5   8   8   8
> x[sample(x, 5, replace=TRUE)]
[1]  6   10   11   4   6
> x[seq(from=4, to=20, by=3)]
[1]  5   8   11   14   NA   NA
```

Můžeme rovněž použít funkcí `head()` a `tail()`, které vrací prvních/posledních `n` prvků vektoru (implicitní nastavení `n=6`):

```
> head(x)
[1]  2   3   4   5   6   7
> tail(x, n=3)
[1]  14   15   16
```

2. **Vektor záporných celých čísel.** Vektorem záporných celých čísel `index` vymezujeme ty indexy vektoru `x`, jejichž odpovídající hodnoty nemají být vytištěny. Všechny prvky vektoru `x`, kromě těch specifikovaných vektorem `index`, jsou do výsledné podoby vypsány v jejich původním pořadí. Délka výsledného vektoru je `length(x) - length(index)`.

```
> x[-c(1:10)]    vynechá prvních deset prvků vektoru
[1]  12   13   14   15   16
> x[-tail(x, 10)]
[1]  2   3   4   5   6   7
```

3. **Logický vektor.** Prvky odpovídající hodnotám `TRUE` vektoru `index` jsou vypisovány, zatímco prvky odpovídající hodnotám `FALSE` jsou vynechány. Výsledný

vektor je stejné délky jako počet hodnot `TRUE` vektoru `index`.

```
> x[c(TRUE, FALSE, TRUE, TRUE, FALSE, rep(c(TRUE, FALSE), 5))]
```
vektor `index` může být zadán vektorem hodnot `TRUE` a `FALSE`
```
[1]  2   4   5   7   9   11   13   15
```
```
> x[x>7 & x<=12]
```
vektor `index` může být dán omezujícími podmínkami – použitím porovnávacích a logických operátorů (porovnávací a logické operátory viz odstavec 6.2)
```
[1]  8   9   10   11   12
```

V případě, že vektor `x` obsahuje hodnoty `NA`, potřebujeme pomocí funkce `is.na()` zajistit, aby byly správně vynechány:
```
> (y <- c(7, 3, NA, 5, NA, NA, 9))
[1]  7   3   NA   5   NA   NA   9
> y[y<6]
[1]  3   NA   5   NA   NA
> y[y<6 & !is.na(y)]
```
vypíše ty hodnoty vektoru `y`, které jsou menší než `6` a jsou různé od hodnoty `NA`
```
[1]  3   5
```

Alternativou v této situaci může být funkce `subset()`. Jejím prvním argumentem je vektor, ze kterého chceme získat jeho podmnožinu, druhým argumentem je vektor omezujících podmínek. Výhodou této funkce je, že hodnoty `NA` jsou automaticky považovány za `FALSE`, takže nemusí být odstraňovány pomocí funkce `is.na()`.
```
> subset(y, y<6)
[1]  3   5
```

4. **Vektor znakových řetězců.** Tento způsob může být použit pouze v případě, kdy prvky vektoru mají názvy. V tom případě může být vektor `index` použit stejným způsobem jako v případě přirozených čísel v odrážce 1, řetězce ve vektoru `index` odpovídají názvům prvků vektoru `x`.

```
> (ovoce <- c(banan=3, broskev=8, jablko=7, pomeranc=5))
```
přiřazení názvu jednotlivým prvkům vektoru
```
 banan  broskev  jablko  pomeranc
     3        8       7         5
```
```
> names(ovoce)
```
každý prvek vektoru má opravdu svůj název
```
[1]  "banan"   "broskev"   "jablko"   "pomeranc"
```

Jiný způsob definice přiřazení názvu jednotlivým prvkům vektoru:

```
> ovoce <- c(3, 8, 7, 5)
> names(ovoce) <- c("banan", "broskev", "jablko", "pomeranc")
> ovoce[c("broskev", "jablko")]
 broskev  jablko
       8       7
```

MATLAB používá pro výpis subvektorů kulatých závorek, pro nekladné argumenty vrací chybové hlášení.

3.3 Délka a změna délky vektoru

Každý vektor má svou délku, což je počet jeho prvků. Ke zjištění délky definovaného vektoru slouží funkce `length()`.

Každý prázdný objekt je nějakého datového typu. Např. příkazem

```
> numeric()
[1]  numeric(0)
```

vytvoříme prázdný numerický vektor, analogicky příkazem `character()` vytvoříme prázdný textový vektor, atd. K již existujícímu objektu libovolné délky můžeme přidávat nové složky, a to jednoduše umístěním indexu hodnoty do hranaté závorky. Tak příkazem `u[2] <- 5` vytvoříme nový vektor `u` délky 2 (1. složka není známa, má tedy hodnotu `NA`, 2. složka má hodnotu 5). Tento příkaz můžeme použít pro jakoukoliv strukturu za předpokladu, že datový typ přidávaných prvků je shodný s datovým typem objektu.

Naopak, ke zkrácení délky objektu je třeba jen operátor přiřazení `<-`, kde za název proměnné umístíme do hranatých závorek ty indexy prvků, které nás zajímají. Symbol záporného znaménka před vektorem indexů v hranatých závorkách určuje ty hodnoty, které nemají být vypsány na výstupu.

```
> u <- 5:12
[1]  5   6   7   8   9   10   11   12
> length(u)
[1]  8
> u[c(1, 3, 5)]    vypíše 1., 3. a 5. prvek vektoru u.
[1]  5   7   9
> u[-c(1, 3, 5)]    vynechá 1., 3. a 5. prvek vektoru u.
[1]  6   8   10   11   12
```

V případě, že chceme získat prvních `n` složek vektoru, použijeme příkaz `length(v) <- n`. Stejným způsobem můžeme i prodlužovat vektory, přidané pozice budou mít hodnotu `NA`.

```
> length(u) <- 3
> u    přesvědčíme se, že vektor u opravdu obsahuje jen původní 3 složky
[1]  5   6   7
```

Pracujme opět s vektorem `u <- 5:12`. Analogickými příkazy k výše uvedenému může být `u[c(1,2,3)]`, `u[1:3]`, `head(u,3)`.

```
> (w <- head(u,3))
[1]  5   6   7
> length(w) <- 5
> w
[1]  5   6   7   NA   NA
```

3.4 Faktory

Faktory jsou speciálním případem vektorů s nominálními nebo ordinálními daty. Jedná se o datovou strukturu, která umožňuje přiřadit smysluplné názvy jednotlivým kategoriím. Na první pohled vypadají faktory podobně jako numerické a textové vektory, ale není tomu tak. Faktory v sobě navíc obsahují informaci `Levels` – jedná se o konečnou množinu hodnot, kterých kategorická proměnná může nabývat. Jednotlivé prvky `Levels` jsou uspořádány podle jejich typu (numericky nebo abecedně), hodnoty `NA` zde ovšem nejsou zahrnuty.

```
> factor(c("kocka", "kun", NA, "pes", "kocka", "pes", "pes"))
[1]  kocka   kun   <NA>   pes   kocka   pes   pes
 Levels:  kocka   kun   pes
```

Poznámka. Je důležité si uvědomit, že prvky numerického faktoru nejsou interpretovány jako numerické hodnoty:

```
> mean(factor(1:5))    funkce mean slouží k výpočtu průměru
[1]  NA
 Warning message:
In mean.default(factor(1:5)) :
argument is not numeric or logical: returning NA
```

Funkce `factor()` má několik volitelných argumentů. Argument `levels` může být použit k definování úrovní (`Levels`) faktoru. Např. můžeme vytvořit faktor i s úrovní, která se mezi daty nevyskytuje:

```
> factor(c(2, 3, 1, NA, 3, 2), levels=1:4)    hodnoty NA nejsou do Levels vypisovány
[1]  2   3   1   <NA>   3   2
 Levels:   1   2   3   4
```

Argument `levels` rovněž může sloužit ke změně pořadí prvků úrovní:

```
> factor(c(2, 3, 1, NA, 3, 2), levels=c(1, 3, 2, 4))
[1]  2   3   1   NA   3   2
 Levels:   1   3   2   4
```

Argument `labels` se používá k definici popisků:

```
> factor(c(0, 1, 1, 0, 1), labels=c("nepritomen", "pritomen"))
[1]  nepritomen   pritomen   pritomen   nepritomen   pritomen
 Levels:   nepritomen   pritomen
```

Argument `exclude` ignoruje vybrané prvky, tyto prvky jsou nahrazeny hodnotami `NA`

```
> factor(c(2, 3, 1, NA, 3, 2), exclude=3)
[1]  2   <NA>   1   <NA>   <NA>   2
 Levels:   1   2   <NA>
```

`> factor(c(2, 3, 1, NA, 3, 2), exclude=NULL)` argument `exclude=NULL` slouží pro zobrazení hodnoty `NA` v `Levels`

```
[1]  2   3   1   <NA>   3   2
 Levels:   1   2   3   <NA>
```

Argument `ordered=TRUE` slouží k seřazení úrovní faktoru. Jediným rozdílem na výstupu je zobrazení porovnávacího operátoru `<` mezi jednotlivými úrovněmi faktoru. Tuto vlastnost můžeme použít např. při porovnávání jednotlivých prvků.

```
> (velikost <- factor(c(3, 1, 5, 4, 3, 2, 4), labels=c("mravenec",
+ "hlemyzd", "koza", "slon", "zirafa")))
[1]  koza   mravenec   zirafa   slon   koza   hlemyzd   slon
 Levels:   mravenec   hlemyzd   koza   slon   zirafa
> (velikost <- factor(c(3, 1, 5, 4, 3, 2, 4), labels=c("mravenec",
+ "hlemyzd", "koza", "slon", "zirafa"), ordered=TRUE))
[1]  koza   mravenec   zirafa   slon   koza   hlemyzd   slon
 Levels:   mravenec < hlemyzd < koza < slon < zirafa
```

`> velikost >= "koza"` vrací vektor logických hodnot, na pozicích splňujících podmínku jsou hodnoty `TRUE`, na ostatních pozicích `FALSE`

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

Kapitola 4

Matice a pole

4.1 Základní příkazy, tvorba matic a polí

Matice je 2-dimenzionální datová struktura, která se skládá z řádků a sloupců. Stejně jako vektory, všechny prvky matice musí být stejného datového typu (numerický, komplexní, logický nebo textový), mohou rovněž obsahovat prvky s hodnotami `NA`, `NaN`, `NULL` nebo `Inf`. Pole je k-dimenzionální struktura, matice je jejím speciálním typem pro $k = 2$.

Základním způsobem k vytvoření matice nebo pole je příkaz `dim()`, který vektor ve svém argumentu uspořádá po sloupcích do pole požadované dimenze.

```
> u <- 1:20
> dim(u) <- c(4, 5)    vektoru u stanoví dimenzi – 4 řádky, 5 sloupců
> u
     [,1] [,2] [,3] [,4] [,5]
[1,]    1    5    9   13   17
[2,]    2    6   10   14   18
[3,]    3    7   11   15   19
[4,]    4    8   12   16   20
```

Další způsoby, jak vytvořit matice, popř. pole, je použít příkazy `matrix()`, popř. `array()`:

```
> matrix(u, 4, 5)    vytvoří matici o 4 řádcích a 5 sloupcích, prvky jsou skládány po sloupcích
> matrix(u, 4, 5, byrow=TRUE)    vytvoří matici 4 x 5, argument byrow=TRUE stanovuje, že prvky jsou skládány po řádcích
     [,1] [,2] [,3] [,4] [,5]
[1,]    1    2    3    4    5
[2,]    6    7    8    9   10
[3,]   11   12   13   14   15
[4,]   16   17   18   19   20
```

Pro definování polí slouží příkaz `array()`, s nímž je práce analogická.

```
> (ar <- array(u, c(2, 5, 2)))   vytvoří pole o rozměrech 2 x 5 x 2
 , , 1

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

, , 2

      [,1] [,2] [,3] [,4] [,5]
 [1,]   11   13   15   17   19
 [2,]   12   14   16   18   20
```

Příkazy `matrix(u, ncol=5)`, `matrix(u, nrow=4)` a `matrix(u, 4)` jsou ekvivalentní, všechny seskládají po sloupcích vektor `u` do pěti sloupců a čtyř řádků.

Pro zjištění velikosti matice či pole slouží funkce `dim()`. Výstupem je vektor, jehož první složka udává počet řádků, druhá udává počet sloupců a v případě polí odkazují další složky na příslušné dimenze. Pro zjištění počtu řádků či sloupců matic i polí slouží rovněž funkce `nrow()` či `ncol()`.

```
> dim(u)
[1] 4 5
> dim(ar)
[1] 2 5 2
> nrow(ar)
[1] 2
> ncol(ar)
[1] 5
```

V systému MATLAB lze funkcí `size()` získat rozměry matice, pole i vektoru. Analogickou funkcí pro `size()` je v jazyce R funkce `dim()`, tu ovšem nemůžeme použít pro zjištění délky vektoru. Funkcím `nrow(x)` a `ncol(x)` odpovídají v MATLABu funkce `size(x,1)` a `size(x,2)`.

Názvy řádků a sloupců mohou být specifikovány argumentem `dimnames`. Jedná se o argument typu seznam (pro více podrobností viz Kapitola 5) o dvou složkách – textových vektorech obsahujících názvy jednotlivých řádků a sloupců.

```
> matrix(u, ncol=5, dimnames=list(c("r1", "r2", "r3", "r4"), c("sl1",
+ "sl2", "sl3", "sl4", "sl5")))
     sl1  sl2  sl3  sl4  sl5
 r1    1    4    9   13   17
 r2    2    5   10   14   18
 r3    3    6   11   15   19
 r4    4    8   12   16   20
```

Dalšími příkazy pro tvorbu matic mohou být `cbind()` nebo `rbind()`, které své argumenty skládají vertikálně (po sloupcích) nebo horizontálně (po řádcích). Argumenty mohou být vektory libovolných délek a/nebo matice se stejným počtem řádků nebo sloupců.

```
> cbind(1:3, 4:6)
      [,1]  [,2]
 [1,]    1     4
 [2,]    2     5
 [3,]    3     6
> cbind(matrix(1:4, c(2, 2)), matrix(c(8, 11), c(2, 1)))
      [,1]  [,2]  [,3]
 [1,]    1     3     8
 [2,]    2     4    11
> rbind(1:8, 1:5)
```

v případě, že vektory nejsou stejné délky, složky kratšího vektoru se opakují tak dlouho, dokud nedosáhne rozměru delšího vektoru

```
      [,1]  [,2]  [,3]  [,4]  [,5]  [,6]  [,7]  [,8]
 [1,]    1     2     3     4     5     6     7     8
 [2,]    1     2     3     4     5     1     2     3
Warning message:
In rbind(1:8 1:5) :
number of columns of result is not a multiple of vector length
(arg 2)
```

Argument `nazev.vektoru=vektor` slouží k pojmenování jednotlivých řádků (v případě `rbind`) a sloupců (v případě `cbind`):

```
> cbind(sl1=1:3, sl2=4:6)
      sl1  sl2
 [1,]   1    4
 [2,]   2    5
 [3,]   3    6
```

Na rozdíl od MATLABu nelze v jazyce R matici o jednom sloupci získat transpozicí vektoru (funkce `t()`), je třeba použít jeden z příkazů `matrix()`, `dim()` nebo `rbind()`.

4.2 Submatice

K výpisu určité podmnožiny prvků matice či pole můžeme použít hranatých závorek `[]`. Obecně má pro n-rozměrné pole `A` tento příkaz tvar `A[index_1, index_2, ..., index_n]`, kde `index_1`, odkazuje na řádky, `index_2` na sloupce a `index_3, ..., index_n` na ostatní dimenze. Odkaz na každou dimenzi může být jedním ze čtyř tvarů uvedených v podkapitole 3.2. V případě, že některý z indexů není specifikován, v úvahu je brána celá délka příslušné dimenze.

```
> (A <- matrix(1:20, 4))
     [,1] [,2] [,3] [,4] [,5]
[1,]    1    5    9   13   17
[2,]    2    6   10   14   18
[3,]    3    7   11   15   19
[4,]    4    8   12   16   20
> A[-c(1, 2), c(3, 4, 5)]
     [,1] [,2] [,3]
[1,]   11   15   19
[2,]   12   16   20
```

Jazyk R se vždy snaží vracet objekty s nejnižší možnou dimenzí. Např. chceme-li vypsat jediný sloupec matice, R jej zobrazí jako řádkový vektor. To ovšem může být v některých případech nežádoucí – toto chování můžeme vypnout argumentem `drop=FALSE`:

```
> A[, 2]
[1] 5 6 7 8
> A[, 2, drop=FALSE]
     [,1]
[1,]    5
[2,]    6
[3,]    7
[4,]    8
```

4.3 Funkce pro manipulaci s maticemi

`nrow(), ncol()`	počet řádků a sloupců pole
`dim()`	dimenze pole
`t()`	transpozice matice
`diag()`	vypíše diagonálu matice
`diag(v)`	vytvoří diagonální matici se složkami vektoru `v` na diagonále
`diag(k)`	pro každé přirozené číslo `k` vygeneruje jednotkovou matici rozměrů $k \times k$
`lower.tri()`, `upper.tri()`	výstupem je matice logických hodnot stejných rozměrů jako matice v argumentu. Hodnoty `TRUE` odpovídají prvkům v dolní/horní trojúhelníkové matici. Implicitní nastavení `diag=FALSE` nezahrnuje diagonálu.
`det()`	determinant matice
`eigen()`	výstupem je seznam o dvou položkách - `values` (vlastní čísla) a `vectors` (vlastní vektory). V případě, že nás zajímají pouze vlastní čísla, popř. pouze vlastní vektory matice, použijeme operátoru `$`: `eigen()$values`, popř. `eigen()$vectors`.
`qr()`	QR rozklad. Jedním z výstupů je i hodnost matice, chceme-li zjistit pouze hodnost matice, můžeme použít příkaz `qr()$rank`
`svd()`	singulární rozklad trojúhelníkové matice
`norm()`	norma matice. Je potřeba nainstalovat a načíst podpůrný balíček `Matrix` pomocí příkazů `install.packages("Matrix")` a `library(Matrix)`. Volitelnými argumenty můžeme zvolit typ normy: `"O"`, `"o"` nebo `"1"` pro maximální součty ve sloupcích, `"I"` nebo `"i"` pro maximální součty v řádcích, `"F"` nebo `"f"` pro Frobeniovu normu
`sum(diag())`	stopa matice

```
> (A <- matrix(c(3, 2, -1, 0), 2))
     [,1] [,2]
[1,]    3   -1
[2,]    2    0
> (v <- diag(A))
[1] 3 0
> diag(v)
     [,1] [,2]
[1,]    3    0
[2,]    0    0
```

```
> diag(2)
      [,1]  [,2]
 [1,]    1     0
 [2,]    0     1
> lower.tri(A)
       [,1]   [,2]
 [1,] FALSE  FALSE
 [2,]  TRUE  FALSE
> A[lower.tri(A)] <- 0
```

horní trojúhelníková matice

```
      [,1]  [,2]
 [1,]    3    -1
 [2,]    0     0
> eigen(A)
$values
[1]  2   1
$vectors
           [,1]       [,2]
 [1,] 0.7071068  0.4472136
 [2,] 0.7071068  0.8944272
> eigen(A)$values
[1]  2   1
> qr(A)$rank
[1]  2
> norm(A, "1"); norm(A, "i"); norm(A, "f")
[1]  5
[1]  4
[1]  3.741657
> sum(diag(A))
[1]  3
```

Násobení matic

Pro násobení matic po složkách se používá operátor `*`, navíc musí mít násobené matice souhlasné rozměry. Pro součin matice a vektoru (v libovolném pořadí) se uplatňuje pravidlo *recycling rule*, tzn. jednotlivé složky matice jsou po sloupcích postupně násobeny složkami vektoru.

```
> u <- c(1, 0, 0)
> v <- c(1, 0, 0, 0, 1)
> A <- matrix(c(1, 0, 0, 1, 0, 1, 1, 1, 0, 0, 1, 1), ncol=3)
```

```
> A
      [,1]  [,2]  [,3]
 [1,]    1     0     0
 [2,]    0     1     0
 [3,]    0     1     1
 [4,]    1     1     1
> u * A   použití pravidla recycling rule
      [,1]  [,2]  [,3]
 [1,]    1     0     0
 [2,]    0     0     0
 [3,]    0     1     0
 [4,]    1     0     0
> v * A   použití pravidla recycling rule. Výstup navíc obsahuje varovné hlášení, neboť počet prvků matice A není dělitelný délkou vektoru v
      [,1]  [,2]  [,3]
 [1,]    1     0     0
 [2,]    0     0     0
 [3,]    0     1     0
 [4,]    1     0     0
Warning message:
In v * A : longer object length is not a multiple of shorter object
length
```

Pro maticové násobení se používá operátor `%*%`, oba činitelé musí být odpovídajících rozměrů (vnitřní rozměry obou činitelů musí být shodné). Výjimku tvoří násobení sloupcovým vektorem – může být nahrazen vektorem řádkovým.

```
> A %*% u   sloupcový vektor může být nahrazen vektorem řádkovým
      [,1]
 [1,]    1
 [2,]    0
 [3,]    0
 [4,]    1
> B <- matrix(c(0, 1, 1, 1, 0, 1, 0, 1), ncol=4)
      [,1]  [,2]  [,3]  [,4]
 [1,]    0     1     0     0
 [2,]    1     1     1     1
> A %*% B   nesouhlasné rozměry matic
Error in A %*% B : non-conformable arguments
> B %*% A
      [,1]  [,2]  [,3]
 [1,]    0     1     0
 [2,]    2     3     2
```

Zatímco v systému MATLAB operaci násobení po složkách zajišťuje operátor `.*`, v jazyce R je to `*`. Operátor `*` v systému MATLAB označuje maticové násobení, v jazyce R je to operátor `%*%`.

Řešení lineárních rovnic a inverze

Řešení lineárních rovnic je inverzní operací k maticovému násobení

```
> b <- A %*% x
```

`A` značí čtvercovou matici koeficientů pro lineární systém, `b` je vektor nebo matice pravé strany. Vektor/matice `x` je řešením systému lineárních rovnic $Ax = b$, které získáme příkazem `solve(A, b)`. V lineární algebře řešení formálně dostaneme $x = A^{-1}b$, kde A^{-1} značí matici inverzní k matici `A`. Matici inverzní můžeme v R spočítat pomocí `solve(A)`.

```
> (A <- matrix(c(1, 3, 1, -1), 2))
     [,1] [,2]
[1,]    1    1
[2,]    3   -1
> (b <- matrix(c(3, 1), 2))
     [,1]
[1,]    3
[2,]    1
> solve(A, b)
     [,1]
[1,]    1
[2,]    2
> solve(A) %*% b
     [,1]
[1,]    1
[2,]    2
```

Příkaz `backsolve(A, b, k, upper.tri, transpose)` rovněž slouží k řešení lineárních rovnic s horní (`upper.tri=TRUE`, implicitně) nebo dolní trojúhelníkovou maticí (`upper.tri=FALSE`). Vektor `b` je vektor/matice pravých stran, `k` je počet sloupců matice `A`, které mají být použity. Pro `transpose=TRUE` řešíme systém $A'x = b$, implicitní nastavení je `transpose=FALSE`.

```
> backsolve(A, b, upper.tri=TRUE)
```

řeší systém lineárních rovnic $\left(\begin{array}{cc|c} 1 & 1 & 3 \\ 0 & -1 & 1 \end{array}\right)$

```
     [,1]
[1,]    4
[2,]   -1
```

Poznámka. Stejně jako u maticového násobení, ani u funkcí `solve` a `backsolve` není nezbytně nutné zadávat vstupní vektory jako sloupcové vektory. Pro vstupní řádkový vektor bude výstupem řádkový vektor.

Kapitola 5

Datové tabulky a seznamy

5.1 Základní příkazy, tvorba datových tabulek a seznamů

Datová tabulka je 2-dimenzionální struktura, která slouží k uchování souboru dat. Soubor dat se skládá z množiny proměnných (sloupce), které jsou pozorovány na množství případů (řádky). Jednotlivé sloupce mohou být různých datových typů, ale prvky každého sloupce musí být stejného datového typu. Počet případů musí být pro každou proměnnou stejný.

Seznam je nejobecnější datová struktura v R, která seskupuje několik (různých) objektů do objektu většího rozsahu. Jedná se o datovou strukturu skládající se z posloupnosti objektů, kterým se říká složky. Každá složka může obsahovat objekt jakéhokoliv datového typu. Seznam tedy může obsahovat vektory různých datových typů a délek, matice, pole, datové tabulky, funkce a/nebo jiné seznamy. Proto jsou seznamy vhodnými výstupy nejrůznějších výpočtů.

Rovněž je důležité si uvědomit, že datová tabulka je speciálním případem seznamu. Nejedná se o nic jiného, než seznam, jehož složky jsou vektory stejné délky a odpovídající pozice vyjadřují stejné případy (např. výskyt aut červené a modré barvy během středy).

Datovou tabulku vytvoříme příkazem `data.frame`. Argumenty `nazev_1=vektor_1, nazev_2=vektor_2, ...` specifikujeme názvy sloupců (proměnných) a jejich hodnoty, názvy sloupců jsou nepovinné, stačí zadat pouze hodnoty. Argument `row.names` (implicitní nastavení `NULL` případy čísluje) specifikuje názvy případů. Argument `check.names` s implicitním nastavením `TRUE` kontroluje, zda jsou názvy proměnných syntakticky správné a zda se neopakují, v případě duplikací se stará o jejich přejmenování.

```
> data.frame(obor=factor(c(1, 0, 0, 1, 1), labels=c("OM", "MAEK")),
+ body=c(18, 13, 15, 20, 15))
    obor  body
 1  MAEK    18
 2    OM    13
 3    OM    15
 4  MAEK    20
 5  MAEK    15
> data.frame(obor=factor(c(1, 0, 0, 1, 1), labels=c("OM", "MAEK")),
+ body=c(18, 13, 15, 20, 15), row.names=c("Petr", "Pavel", "Jirina",
+ "Adela", "Matej"))
         obor  body
   Petr  MAEK    18
  Pavel    OM    13
 Jirina    OM    15
  Adela  MAEK    20
  Matej  MAEK    15
> data.frame(a=c(1,2), a=c(T,F), check.names=T)
    a    a.1
 1  1   TRUE
 2  2  FALSE
> data.frame(a=c(1,2), a=c(T,F), check.names=F)
    a      a
 1  1   TRUE
 2  2  FALSE
```

Funkce `list()` slouží k vytvoření seznamu. Stejně jako u funkce `data.frame()` mohou být i složky seznamu pojmenovány pomocí argumentů `nazev_1=slozka_1`, `nazev_2=slozka_2`, ...

```
> (l <- list(barva=c("cervena", "modra", "bila"), data.frame(Petr=
+ sample(5, replace=T), Pavel=1:5, row.names=c("po","ut", "st", "ct",
+ "pa"))))
$barva
[1]  "cervena"   "modra"   "bila"

[[3]]
     Petr  Pavel
 po     1      1
 ut     3      2
 st     3      3
 ct     5      4
 pa     3      5
```

Funkce `dim()`, `names()` a `contents()` slouží k výpisu vlastností datové tabulky. Funkce `dim()` vypisuje dimenze tabulky dat, funkce `names()` zobrazuje názvy proměnných. Funkce `contents()` vrací vnitřní strukturu datové tabulky. Funkce je obsažena v balíčku `Hmisc`, který není ve standardní distribuci, je třeba jej proto doinstalovat příkazem `install.packages("Hmisc")` a načíst příkazem `library(Hmisc)`.

K výpisu vlastností seznamu můžeme použít funkci `names()`, která vrací názvy složek seznamu. Funkce `dim()` a `contents()` u seznamu použít nemůžeme, můžeme je ovšem nahradit funkcemi `length()`, která vrací počet složek seznamu, a `str()`, která vypisuje vnitřní strukturu seznamu.

5.2 Podmnožiny seznamů

K vypsání podmnožiny seznamu můžeme použít jednoduchých `[]` nebo dvojitých `[[]]` hranatých závorek. Jednoduchými závorkami uvádíme, které složky seznamu chceme získat. Jestliže jednotlivé složky seznamu nejsou pojmenovány, požadovanou složku specifikujeme jejím číslem. K výpisu více složek můžeme použít operátoru `:` nebo funkce `c()`. Jestliže jsou složky seznamu pojmenovány, požadované prvky specifikujeme jejich názvy v uvozovkách. Podmnožina seznamu vytvořená pomocí jednoduchých hranatých závorek je opět typu seznam.

Naopak, příkaz pro vytváření podmnožiny pomocí dvojitých hranatých závorek vrací objekt takového typu, jakým byl při definování seznamu. V tomto případě je na každou složku odkazováno jednotlivě, nepoužívá se proto operátor `:` ani funkce `c()`. Stejně jako u jednoduchých hranatých závorek, na každou složku je odkazováno jejím číslem, má-li požadovaná složka název, můžeme na ni odkazovat jejím názvem v uvozovkách nebo můžeme použít operátoru `$`.

```
> l <- list(barva=c("cervena", "modra", "bila"), matrix(1:4, 2),
+ data.frame(Petr=sample(5, replace=T), Pavel=1:5, row.names=c("po",
+ "ut", "st", "ct", "pa")))
> l["barva"]
$barva
[1]  "cervena"   "modra"   "bila"
> typeof(l["barva"])    příkaz typeof() určí typ svého argumentu
[1]  "list"
> l[[2]]
      [,1]  [,2]
 [1,]    1     3
 [2,]    2     4
> typeof(l[[2]])
[1]  "integer"
```

```
> typeof(l$barva)
[1]  "character"
```

Protože datové tabulky jsou speciálním případem seznamů, řádky a/nebo sloupce tabulky dat mohou být získány pomocí `[]`, `[[]]` a/nebo operátoru `$`. Datové tabulky mohou být považovány i za zobecněné matice, k vytvoření podmnožiny můžeme proto použít `[,]`.

```
> tab <- data.frame(cervena=c(1,2,3), modra=c(3,6,0), bila=c(2,5,1),
+ row.names=c("pondeli", "utery", "streda"))
> tab[1]
         cervena
pondeli        1
utery          2
streda         3
> typeof(tab[1])
[1]  "list"
> tab[[1]]   ekvivalentní příkaz příkazům tab[["cervena"]] a tab$cervena
[1]  1   2   3
> typeof(tab[[1]]); typeof(tab[["cervena"]]; typeof(tab$cervena))
[1]  "double"
[1]  "double"
[1]  "double"
> tab["utery", "bila"]
[1]  5
```

K výběru podmnožiny datové tabulky slouží i příkaz `subset(x, )`. Argument `x` specifikuje název datové tabulky, z níž podmnožinu vybíráme. Argument `subset` specifikuje řádky vyhovující dané podmínce, přičemž hodnoty `NA` jsou brány jako `FALSE`. Argument `select` specifikuje sloupce, které chceme vypsat, můžeme použít funkce `c()`, operátoru `:` i operátoru `-` pro vynechání složek.

```
> subset(tab, subset=cervena==3, select=c(modra, bila))
        modra  bila
streda      0     1
```

Funkce `subset()` vždy vrací tabulku dat, i když má jen jeden řádek nebo sloupec. K tomu, aby vrátila jen jednoduchý vektor, musíme za vlastní definici podmnožiny datové tabulky použít operátor `$`, za nímž následuje název sloupce:

```
> tab["pondeli", "cervena"]
[1]  1
> subset(tab, subset=cervena==1, select=cervena)
         cervena
pondeli        1
```

```
> subset(tab, subset=cervena==1, select=cervena)$cervena
[1]  1
```

5.3 Funkce pro manipulaci s datovými tabulkami a seznamy

Přidání dalších sloupců

Prvním způsobem, jak do datové tabulky přidat nový sloupec s hodnotami, je příkaz tvaru
`datová_tabulka$nazev_noveho_sloupce <- hodnoty`. Druhým způsobem je provést přiřazení pomocí funkce `data.frame()` (bez přiřazení zobrazuje nové hodnoty pouze dočasně).

```
> (knihy <- data.frame(nazev=c("Dekameron", "Maj", "Temno", "Bidnici",
+ "Babicka"), autor=c("Boccaccio", "Macha", "Jirasek", "Hugo",
+ "Nemcova")))
       nazev      autor
 1  Dekameron  Boccaccio
 2        Maj      Macha
 3      Temno    Jirasek
 4    Bidnici       Hugo
 5    Babicka    Nemcova
> knihy$pocet <- c(3, 6, 4, 3, 5)
> knihy
       nazev      autor  pocet
 1  Dekameron  Boccaccio      3
 2        Maj      Macha      6
 3      Temno    Jirasek      4
 4    Bidnici       Hugo      3
 5    Babicka    Nemcova      5
> (knihy <- data.frame(knihy, k_dispozici=c(F, F, T, F, T)))
       nazev      autor  pocet  k_dispozici
 1  Dekameron  Boccaccio      3        FALSE
 2        Maj      Macha      6        FALSE
 3      Temno    Jirasek      4         TRUE
 4    Bidnici       Hugo      3        FALSE
 5    Babicka    Nemcova      5         TRUE
```

Funkce `transform()` pouze tiskne aktuální datovou tabulku, nepřidává nastálo novou proměnnou (v opačném případě musíme provést přiřazení).

```
> transform(knihy, rok=c(1971, 1997, 1983, 2003, 1992))
```
přidá sloupec `rok` s danými hodnotami, proměnná `knihy` ovšem zůstane nezměněna

```
        nazev      autor  pocet  k_dispozici   rok
  1  Dekameron  Boccaccio      3        FALSE  1971
  2        Maj      Macha      6        FALSE  1997
  3      Temno    Jirasek      4         TRUE  1983
  4    Bidnici       Hugo      3        FALSE  2003
  5    Babicka    Nemcova      5         TRUE  1992
```

Pro přidání dalších složek do seznamu lze pomocí operátoru přiřazení tvaru `seznam$nova_slozka <- objekt` nebo `seznam[["nova_slozka"]] <- objekt`.

```
> (vyzkum <- list(n=28, lokalita="Brno"))
$n
[1]  28

$lokalita
[1]  "Brno"
> vyzkum$obdobi <- 2004:2012
> vyzkum[["jakost"]] <- factor(c(0, 1, 1, 1, 0, 0, 1, 0, 1, 1), labels=
+ c("1", "2"))
> vyzkum
$n
[1]  28

$lokalita
[1]  "Brno"

$obdobi
[1]  2004  2005  2006  2007  2008  2009  2010  2011  2012

$jakost
[1]  1  2  2  2  1  1  2  1  2  2
Levels: 1 2
```

Odstraňování řádků a sloupců

Každý sloupec můžeme z datové tabulky odstranit použitím operátoru `$` nebo `[]` nastavením na hodnotu `NULL`.

```
> knihy$pocet <- NULL
```
analogický příkaz: `knihy["pocet"] <- NULL`. O tom, že sloupce byly opravdu odstraněny, se můžeme přesvědčit funkcí `names()`

```
> names(knihy)
[1]  "nazev"   "autor"   "k_dispozici"
```

K odstranění řádků můžeme použít i operátor `[,]`.

```
> (knihy <- knihy[1:3, c("nazev", "k_dispozici")])
        nazev  k_dispozici
1  Dekameron        FALSE
2        Maj        FALSE
3      Temno         TRUE
```

Slučování

Ke sloučení datových tabulek můžeme použít funkce `cbind()` nebo `rbind()`, které je sloučí po sloupcích nebo řádcích. Při použití funkce `cbind()` musí mít přidávané sloupce stejný počet řádků jako v již existující datové tabulce. Rovněž je vhodné se přesvědčit, že přidávané sloupce mají stejné pořadí řádků. Při použití funkce `rbind()` je třeba dodržovat stejný počet sloupců a jejich shodné názvy.

Alternativou k funkcím `cbind()` a `rbind()` může být funkce

`merge(x, y, by, by.x, by.y, all, all.x, all.y)` sloučí datové tabulky `x` a `y`

`by`, `by.x`, `by.y` specifikují ty názvy sloupců, podle kterých mají být tabulky sloučeny. V případě stejného názvu sloupců použijeme argument `by`. Jsou-li názvy sloupců ke sloučení různé, specifikujeme je pomocí argumentů `by.x` a `by.y`. V případě více podmínek na spojení podmínky uvádíme ve formě vektoru typu řetězec.

`all`, `all.x` a `all.y` specifikace těch řádků, které se mají objevit na výstupu. Implicitní nastavení `all=FALSE` vrací pouze řádky z průniku obou tabulek, `all=TRUE` vrací řádky ze sjednocení obou tabulek. `all.x=TRUE` vrací všechny řádky tabulky `x`, analogicky je tomu u `all.y=TRUE`

Poznámka. Při použití některého z argumentů `all=TRUE`, `all.x=TRUE` nebo `all.y=TRUE` mají „volná“ místa, která vznikla spojením, hodnotu `NA`.

```
> (tab1 <- data.frame(auto=c("fiat", "opel", "skoda", "bmw"), barva=
+ c("seda", "cervena", "cerna", "modra"), rok=c(2003, 1999, 2008,
+ 2004)))
    auto    barva   rok
1   fiat     seda  2003
2   opel  cervena  1999
3  skoda    cerna  2008
4    bmw    modra  2004
> (tab2 <- data.frame(znacka=c("saab", "bmw", "audi"), majitel=c("muz",
+ "zena", "zena")))
   znacka  majitel
1    saab      muz
2     bmw     zena
3    audi     zena
```

`> merge(tab1, tab2)` protože tabulky neobsahují stejný název sloupce, podle kterého by se sloučení mělo řídit, R vytvoří kartézský součin obou tabulek (tzn. ke každému řádku `tab1` se připojí každý řádek `tab2`)

```
      auto    barva   rok  znacka  majitel
 1    fiat     seda  2003    saab      muz
 2    opel  cervena  1999    saab      muz
 3   skoda    cerna  2008    saab      muz
 4     bmw    modra  2004    saab      muz
 5    fiat     seda  2003     bmw     zena
 6    opel  cervena  1999     bmw     zena
 7   skoda    cerna  2008     bmw     zena
 8     bmw    modra  2004     bmw     zena
 9    fiat     seda  2003    audi     zena
 10   opel  cervena  1999    audi     zena
 11  skoda    cerna  2008    audi     zena
 12    bmw    modra  2004    audi     zena
```

`> merge(tab1, tab2, by.x="auto", by.y="znacka")` spojení na základě výskytu `bmw` v obou sloupcích `auto` i `znacka`

```
    auto  barva   rok  majitel
 1   bmw  modra  2004     zena
```

`> merge(tab1, tab2, by.x="auto", by.y="znacka", all.x=T)` argument `all.x=T` zajistil, aby výstup obsahoval všechny hodnoty z `tab1`

```
     auto    barva   rok  majitel
  1    bmw    modra  2004     zena
  2   fiat     seda  2003     <NA>
  3   opel  cervena  1999     <NA>
  4  skoda    cerna  2008     <NA>
```

Řazení

K seřazení tabulek dat se používá funkce `order()`, která vrací vektor indexů vzestupně (implicitně) nebo sestupně uspořádaných prvků. Pro více informací o funkci `order` viz odstavec 6.4.

```
> knihy
       nazev      autor  pocet  k_dispozici
 1  Dekameron  Boccaccio      3        FALSE
 2        Maj      Macha      6        FALSE
 3      Temno    Jirasek      4         TRUE
 4    Bidnici       Hugo      3        FALSE
 5    Babicka    Nemcova      5         TRUE
```

```
> knihy[order(knihy$k_dispozici, knihy$nazev),]
```
seřazuje podle sloupce `k_dispozici`, v případě vícenásobných hodnot řadí podle sloupce `nazev`

```
       nazev      autor  pocet  k_dispozici
4    Bidnici       Hugo      3        FALSE
1  Dekameron  Boccaccio      3        FALSE
2        Maj      Macha      6        FALSE
5    Babicka    Nemcova      5         TRUE
3      Temno    Jirasek      4         TRUE
```

```
> knihy[order(knihy$k_dispozici, -knihy$pocet),]
```
pokud některý ze sloupců tabulky tvoří numerický vektor, pro sestupné uspořádání tohoto sloupce můžeme použít operátoru `-`. Rovněž si můžeme všimnout, že v případě nejednoznačných podmínek na seřazení (řádek č. 1 a 4) dostává přednost řádek s nižším pořadovým číslem, u názvů řádků se postupuje podle abecedního uspořádání.

```
       nazev      autor  pocet  k_dispozici
2        Maj      Macha      6        FALSE
1  Dekameron  Boccaccio      3        FALSE
4    Bidnici       Hugo      3        FALSE
5    Babicka    Nemcova      5         TRUE
3      Temno    Jirasek      4         TRUE
```

Kapitola 6

Konstanty, operátory a matematické výpočty

6.1 Aritmetické operátory

`+`	sčítání
`-`	odčítání
`*`	násobení
`/`	dělení
`^`	umocňování
`%*%`	maticové násobení
`%%`	zbytek po celočíselném dělení (modulo)
`%/%`	celá část z celočíselného dělení
`t()`	transpozice matice nebo datové tabulky

Transpozicí (řádkového) vektoru je v jazyce R stále (řádkový) vektor. Transpozicí řádkového vektoru je v systému MATLAB sloupcový vektor.

```
> a <- c(3, 5, 7, 8); b <- c(1, 2, 3); c <- c(4, 1, 8)
> a + b
[1]  4   7   10   9
 Warning message:
In a + b : longer object length is not a multiple of shorter object
length
```

Protože vektor `b` je menší délky než vektor `a`, je potřeba jeho délku zvětšit o jednu pozici. (Pravidlo pro postupné opakování složek do požadované délky se nazývá *recycling rule*.) Poslední složka výstupního vektoru je tedy součtem 4. složky vektoru `a` a 1. složky vektoru `b`. Na stejném principu fungují i všechny ostatní aritmetické operátory.

MATLAB by v tomto případě hlásil chybu a výpočet by neprovedl, protože sčítance nejsou stejné dimenze.

```
> "a" + "b"
Error in "a" + "b" : non-numeric argument to binary operator
```

Binární operátory můžeme použít pouze na numerické argumenty. Na rozdíl od R, v MATLABu je můžeme použít i na textové řetězce, které jsou převedeny na odpovídající kód v ASCII tabulce a následně provedena příslušná operace.

```
> b / c
[1]  0.250   2.000   0.375
> b %/% c
[1]  0   2   0
> b %% c
[1]  1   0   3
```

6.2 Porovnávací a logické operátory

Porovnávací operátory slouží k porovnávání odpovídajících si složek vektorů. Na výstupu dostáváme vektor logických hodnot `TRUE` a `FALSE` délky nejdelšího vektoru na vstupu. Hodnoty `TRUE` obsazují ty pozice, které splňují danou podmínku, ostatní pozice jsou vyplněny hodnotami `FALSE`.

`==`	rovno
`!=`	není rovno
`<, <=`	menší, menší nebo rovno
`>, >=`	větší, větší nebo rovno
`&`	logické a
`|`	logické nebo
`!`	negace

```
> a <- c(3, 5, 7)
> b <- c(1, 2, 3)
> c <- 1:4
> a <= b
[1]  FALSE   FALSE   FALSE
> a >= 3 & b <= 2
[1]  TRUE   TRUE   FALSE
```

```
> !(a == 5 | a == b)
[1]  TRUE   FALSE   TRUE
```

Při porovnání vektorů o různých délkách je uplatněno pravidlo *recycling rule*:

```
> b == c
[1]  TRUE   TRUE   TRUE   FALSE
 Warning message:
In b == c : longer object length is not a multiple of shorter object
length
```

6.3 Množinové operátory

`all(relace)`	testuje, zda jsou všechny složky `relace` pravdivé
`any(relace)`	testuje, zda je alespoň jedna složka `relace` pravdivá
`which(relace)`	vrací pořadí těch složek `relace`, které jsou pravdivé (popř. které splňují danou podmínku). V případě polí můžeme použít argument `arr.ind=T` pro výpis hodnot v podobě čísel řádků a sloupců, popř. dalších dimenzí
`x %in% y`, `is.element(x, y)`	testuje, zda je `x` podmnožinou množiny `y`, vrací logické hodnoty
`intersect(mnoziny)`	průnik množin
`union(mnoziny)`	sjednocení množin
`setdiff(x, y)`	rozdíl množin, vrací ty prvky vektoru `x`, které nejsou obsaženy v `y`

```
> x <- 1:10
> y <- 2:9
> z <- -5:5
> all(z)
```

testuje, zda jsou všechny prvky vektoru `z` nenulové

```
[1]  FALSE
> all(z > -10)
```

testuje, zda jsou všechny prvky vektoru `z` větší než -10

```
[1]  TRUE
> any(z)
[1]  TRUE
> all(y) >= x[5]
[1]  FALSE
> any(x) == any(y)
[1]  TRUE
```

```
> m <- matrix(2:10, c(3, 3))
      [,1]  [,2]  [,3]
 [1,]    2     5     8
 [2,]    3     6     9
 [3,]    4     7    10
> which(m > 8 | m == 3)
[1]  2  8  9
> which(m > 8 | m == 3, arr.ind=T)
      row  col
 [1,]   2    1
 [2,]   2    3
 [3,]   3    3
> x %in% y
[1]  FALSE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE
[10]  FALSE
> is.element(y, x)
[1]  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE
> union(x[1:5], y[c(7, 8)])
[1]  1  2  3  4  5  8  9
> intersect(x[1:5], y[c(1, 2, 3)])
[1]  2  3  4
> setdiff(x, y)
[1]  1  10
> setdiff(y, x)
integer(0)
```

6.4 Matematické funkce

Předpokládejme, že objekt `x` je numerický, komplexní, logický vektor nebo pole, operace jsou prováděny po složkách.

`abs(x)`, `sqrt(x)` absolutní hodnota a druhá odmocnina objektu `x`
`sign(x)` signum objektu `x`

Logaritmické a exponenciální funkce:
`log(x)`, `log10(x)`, `log2(x)` přirozený logaritmus, logaritmus se základem 10 a 2
`log(x, base)` logaritmus se základem `base`
`exp(x)` exponenciální funkce `x`

Trigonometrické a hyperbolické funkce:
`cos(x), sin(x), tan(x), cosh(x), sinh(x), tanh(x)`

Inverzní trigonometrické a hyperbolické funkce:
`acos(x), asin(x), atan(x), acosh(x), asinh(x), atanh(x)`

`gamma(x)` gamma funkce pro kladná reálná čísla `x`
`choose(n, k)` kombinační číslo $\binom{n}{k}$ pro každé reálné číslo `n` a přirozené číslo `k`
`factorial(x)` faktoriál `x`

`max(x), min(x), sum(x), prod(x)` vrací maximální a minimální prvek, součet a součin prvků argumentu `x`. Pro objekty typu matice nebo pole funkce `sum(x)` a `prod(x)` vrací součet, resp. součin všech prvků.

MATLAB aplikuje funkce `sum()` a `prod()` na matice po sloupcích.

`cummax(x), cummin(x), cumsum(x), cumprod(x)` vrací vektor, jehož složkami jsou maximum, minimum, kumulativní součet a součin prvků argumentu `x`

```
> a <- c(1, 2, 3, 5, 8, 2, 4, 1, 2, 2)
> cumsum(a)
[1]  1   3   6   11   19   21   25   26   28   30
> cummin(a)   vždy nerostoucí posloupnost prvků
[1]  1   1   1   1   1   1   1   1   1   1
> cummax(a)   vždy neklesající posloupnost prvků
[1]  1   2   3   5   8   8   8   8   8   8
```

`range(x)` vektor obsahující minimum a maximum objektu `x`, `range(x)` je ekvivalentní příkazu `c(min(x), max(x))`
`mean(x), median(x)` průměr a medián objektu `x`
`sd(x)` směrodatná odchylka objektu `x`, v případě, že `x` je matice, `sd(x)` vrací směrodatnou odchylku jejích sloupců
`var(x), cov(x, y), cor(x, y)` rozptyl `x`, kovariance a korelace vektorů `x`, `y`, v případě, že `x`, `y` jsou matice, kovariance a korelace jsou počítány mezi sloupci `x` a `y`
`quantile(x)` generická funkce, vrací minimum, dolní kvartil, medián, horní kvartil a maximum objektu `x`

```
> c(min(a), max(a)); range(a)
[1]  1   8
[1]  1   8
> mean(a)
[1]  3
```

```
> var(a)
[1]  4.666667
> quantile(a)
   0%   25%   50%   75%  100%
 1.00  2.00  2.00  3.75  8.00
```

`pmax(x, y, z, ...)`, `pmin(x, y, z, ...)` objekt maximálních/minimálních prvků na odpovídajících si pozicích

```
> b <- 1:10
> pmin(a, b)
[1]  1  2  3  4  5  2  4  1  2  2
```

Pro pole o 2 a více dimenzích s numerickými, komplexními nebo logickými hodnotami nebo pro datové tabulky můžeme použít následující funkce, které vrací průměry, součty a rozptyly po sloupcích či řádcích:

`colMeans(x)`, `colSums(x)`, `colVars(x)`
`rowMeans(x)`, `rowSums(x)`, `rowVars(x)`

```
> (e <- matrix(a,5))
      [,1]  [,2]
 [1,]    1     2
 [2,]    2     4
 [3,]    3     1
 [4,]    5     2
 [5,]    8     2
> rowSums(e)
[1]  3  6  4  7  10
```

`sort(x, decreasing, na.last, index.return)` seřazení objektu `x`

`decreasing=F` vzestupné pořadí (implicitní nastavení), `decreasing=T` sestupné pořadí,

`na.last=NA` zajišťuje vynechání hodnot `NA` (implicitní nastavení), `na.last=T` zajišťuje, aby hodnoty `NA` byly řazeny na konec, `na.last=F` řadí hodnoty `NA` na začátek

`index.return=T` vypíše i původní pořadí hodnot

`order(x, decreasing, na.last)` vypíše indexy seřazených hodnot

`na.last=T` řadí hodnoty `NA` na konec (implicitní nastavení), `na.last=F` řadí hodnoty `NA` na začátek, `na.last=NA` hodnoty `NA` vynechává

`rank(x, na.last, ties.method)` vypíše pořadí jednotlivých hodnot odpovídajících vzestupně seřazenému vektoru `x`

`na.last` stejně jako u funkce `order`

`ties.method` nabývá jedné z hodnot `c("first", "random", "average", "max",`

`"min"`) a používá se pro specifikaci řazení shodných hodnot. `"first"` řadí vzestupně podle pozice v řadě, `"random"` řadí náhodně (implicitní nastavení), `"average"` podle průměrného pořadí a `"min"`/`"max"` podle hodnoty minimálního/maximálního pořadí

`rev(x)` převrácení pořadí hodnot vektoru

```
> a <- c(1, 2, 3, 5, 8, NA, 2, 4, 1, 2, 2)
> sort(a)   hodnoty NA automaticky vynechává
[1]  1   1   2   2   2   2   3   4   5   8
> sort(a, na.last=F)
[1]  NA   1   1   2   2   2   2   3   4   5   8
> order(a)
[1]  1   9   2   7   10   11   3   8   4   5   6
> rank(a, ties.method="average")
[1]  1.5   4.5   7.0   9.0   10.0   11.0   4.5   8.0   1.5   4.5   4.5
> rev(a)
[1]  2   2   1   4   2   NA   8   5   3   2   1
```

6.5 Zaokrouhlování

Pro zaokrouhlování se používají následující funkce:

`ceiling()`	zaokrouhlení k nejbližšímu většímu celému číslu
`floor()`	zaokrouhlení k nejbližšímu menšímu celému číslu
`trunc()`	zaokrouhlení směrem k 0, celá část daného čísla
`round()`	zaokrouhlení k nejbližšímu celému číslu, parametrem `digits=pocet` volíme počet desetinných míst, na jaký má být zaokrouhlení provedeno (implicitně `digits=0`)
`signif()`	zaokrouhlení na určitý počet platných cifer (parametr `digits`, zbytek doplní nulami)

```
> ceiling(c(3.468575, -3.468575))
[1]  4   -3
> floor(c(3.468575, -3.468575))
[1]  3   -4
> trunc(c(3.468575, -3.468575))
[1]  3   -3
> round(c(3.468575, -3.468575), digits=3)
[1]  3.469   -3.469
> signif(c(3.468575,-3.468575), digits=3)
[1]  3.47   -3.47
```

Poznámka. Zaokrouhlování čísla 5: pokud následují za číslicí 5 jen nuly, číslo je zaokrouhleno směrem dolů, pokud následuje jakákoliv jiná číslice, číslo je zaokrouhleno nahoru.

```
> round(7.125, digits=2)
[1]  7.12
> round(7.12501, digits=2)
[1]  7.13
```

6.6 Konstanty

Jazyk R má zabudovány konstanty, z nichž nejpoužívanější jsou:
`pi` ... π, Ludolfovo číslo
`exp(1)` ... e, základ přirozeného logaritmu, Eulerovo číslo
`i` ... i, komplexní jednotka
`.Last.value` ... proměnná obsahující poslední hodnotu, jež nebyla přiřazena do žádné proměnné explicitně
`letters` ... malá písmena abecedy
`LETTERS` ... velká písmena abecedy
`month.name` ... anglické názvy měsíců
`month.abb` ... zkratky anglických názvů měsíců

```
> 3
[1]  3
> .Last.value
[1]  3
> LETTERS[9:14]
[1]  "I"   "J"   "K"   "L"   "M"   "N"
> month.name[c(7, 10)]
[1]  "July"   "October"
```

Kapitola 7

Další příkazy v R

7.1 Práce s knihovnami

Ne všechny funkce jsou přístupné ze základních knihoven, jsou umístěny v dodatečných balíčcích. Výpis aktuálně nainstalovaných knihoven můžeme získat příkazem `library()`. Příkaz `search()` vyhledá přiinstalované knihovny.

```
> search()
 [1] ".GlobalEnv"        "package:stats"  "package:graphics"
 [4] "package:grDevices" "package:utils"  "package:datasets"
 [7] "package:methods"   "Autoloads"      "package:base"
```

Mnohdy je zapotřebí přiinstalovat další balíčky: záložka *Packages* → *Install Package(s) ...* nebo příkazem `install.packages("nazev_balicku")`. Před zahájením práce s přiinstalovanými balíčky je třeba je načíst příkazem `library(nazev_balicku)`, až teprve v tomto okamžiku je balíček připraven k používání. O tom se znovu můžeme přesvědčit:

```
> library(Matrix)
Loading required package : lattice
> search()
 [1] ".GlobalEnv"     "package:Matrix"    "package:lattice"
 [4] "package:stats"  "package:graphics"  "package:grDevices"
 [7] "package:utils"  "package:datasets"  "package:methods"
[10] "Autoloads"      "package:base"
```

7.2 Práce s daty

Funkce pro načítání dat

`scan(file, what, sep, dec, nmax)` je funkce pro načtení vektoru nebo seznamu z konzole nebo souboru. Popis argumentů:

`file`	textový řetězec uvádějící cestu k souboru, při načítání ze schránky `file="clipboard"`
`what`	typ načítané hodnoty (numerické, komplexní, ...)
`sep`	znak, kterým jsou odděleny jednotlivé načítané položky, např. `sep=","`
`dec`	znak pro desetinnou čárku
`nmax`	maximální počet hodnot, který má být načten

Postup pro zobrazení hodnot uložených ve schránce:
1. zkopírovat příslušná data, např. 2; 4; 6; 1; 3; 5
2. zavolat funkci `scan()`

```
> x <- scan(file="clipboard", sep=";")
```

Po jejím zavolání se objeví oznámení:

```
Read 6 items
> x
[1]  2   4   6   1   3   5
> x <- scan(file="clipboard", sep=";", what=character())
Read 6 items
> x
[1]  "2"   "4"   "6"   "1"   "3"   "5"
```

Další takovou funkcí je `read.table(file, header, sep, dec, row.names, col.names)`, která načítá data do tabulky dat (data.frame)

`file, sep, dec`	viz funkce `scan()`
`header`	logická hodnota, zda je v datech obsažena hlavička
`row.names`	textový řetězec názvů řádků nebo číslo odkazující na sloupec názvů
`col.names`	vektor názvů sloupců

1, 2, 3, 4, 5
3, 2, 1, 1, 2

```
> read.table(file="clipboard", sep=",")
   V1  V2  V3  V4  V5
1   1   2   3   4   5
2   3   2   1   1   2
```

1 2 3 4 5 r1
3 2 1 1 2 r2

```
> read.table(file="clipboard", row.names=6, col.names=c("sl1", "sl2",
+ "sl3", "sl4", "sl5", "sl6"))
```

přestože poslední sloupec obsahuje názvy řádků, argument `col.names` musí obsahovat jeho název i tohoto sloupce (`"sl6"`), i když nebude vytištěn

```
    sl1  sl2  sl3  sl4  sl5
r1    1    2    3    4    5
r2    3    2    1    1    2
```

```
sl1 sl2 sl3 sl4 sl5 sl6
1 2 3 4 5 r1
3 2 1 1 2 r2
> read.table(file="clipboard", row.names=6, header=T)
     sl1  sl2  sl3  sl4  sl5
 r1    1    2    3    4    5
 r2    3    2    1    1    2
```

`> read.table(file="dunaj.dat")` načtení dat ze souboru `dunaj.dat` (data znázorňující kolísání [m^3/s] Dunaje během roku, [8])

```
> Dunaj
[1]  1987   1728   1862   2083   2143   2187   2588   2224   2001
[10]  1767   1460   1444
```

Pro usnadnění práce s daty jazyk R obsahuje okolo sta vestavěných datových souborů (v balíčku `datasets`). Funkce `data()` zobrazí seznam dostupných datových souborů. K zobrazení vybraných souborů slouží příkaz `data(nazev, package)`[1], argument `package` slouží ke specifikaci balíčku, ve kterém se data nachází.

Dalšími užitečnými funkcemi jsou `attach()` a `detach()`.
Funkce `attach()` má použití zejména u seznamů a datových tabulek, kde umožňuje vypisování jejich složek přímo, tzn. bez specifikace objektu. Argumentem funkce je název objektu, u kterého chceme výše uvedené provést.

```
> tabulka <- data.frame(id=c(1:6), skupina=c(1, 2, 2, 1, 2, 1),
+ hodnota=runif(6, 2, 4))
> id
Error : object 'id' not found
> attach(tabulka)
> id
[1]  1   2   3   4   5   6
```

Opakem k funkci `attach` je funkce `detach`, která naopak znemožní, aby byly složky volány pouze svým názvem, nikoliv uvedením i specifikace objektu.

```
> detach(tabulka)
> id
Error : object 'id' not found
> tabulka$id
[1]  1   2   3   4   5   6
```

[1] Od verze 2.0.0 jsou všechny datové soubory přístupné přímo zavoláním jejich názvu. Mnohé balíčky ovšem stále používají dřívější způsob volání pomocí `data(nazev)`, jenž může být stále využíván i dnes.

Ukládání dat
K ukládání objektů `object` do souboru specifikovaného argumentem `file=""` slouží funkce `save(object, file="")`. Objekt může být následně načten pomocí funkce `load`.

```
> l <- list(v=1:5, mat=matrix(2:7, 3))
```
pro ukládání více objektů současně je vhodné seskupit tyto objekty do seznamu

```
> save(l, file="seznam.txt")
> nacteni <- load("seznam.txt")
```
načtení uloženého souboru `seznam.txt`, který obsahuje proměnnou `l`

```
> nacteni
[1]  "l"
> l
$v
[1]  1   2   3   4   5

$mat
      [,1]  [,2]
 [1,]    2     5
 [2,]    3     6
 [3,]    4     7
```

Posloupnost jednotlivých příkazů i s jejich výstupy můžeme uložit v menu *File* → *Save to File...*. Historii příkazů můžeme uložit v menu *File* → *Save History* nebo příkazem `savehistory(file=".RHistory")`, příkazem `loadhistory(file=".RHistory")` ji následně můžeme načíst. V případě, že otevíráme dříve uložený soubor, historie příkazů je načtena automaticky s ním.

7.3 Vlastnosti objektů

Se základními vlastnostmi objektů jsme se již seznámili v předešlých kapitolách. Zde si uvedeme některé další funkce, které nám o vnitřní struktuře objektů vypoví mnohem více.

`summary(object)` jedná se o tzv. generickou funkci (funkce, která si nejprve zjistí, jakého typu je její parametr, podle něj pak vypisuje celkový přehled)

```
> (a <- c(1, 2, 3, 5, 8, 2, 4, 1, 2, 2))
[1]  1   2   3   5   8   2   4   1   2   2
```

```
> summary(a)
```
v případě číselných vektorů funkce `summary()` vrací minimum, 1. kvartil, medián, průměr, 3. kvartil a maximum

```
  Min.  1st Qu.  Median  Mean  3rd Qu.  Max.
  1.00     2.00    2.00  3.00     3.75  8.00
> (b <- c(1+3i, 7-1i, NA))
[1]  1+3i   7-1i   NA
> summary(b)
  Length    Class     Mode
       3  complex  complex
> (c <- c(T, T, F, T, F))
[1]  TRUE   TRUE   FALSE   TRUE   FALSE
> summary(c)
     Mode  FALSE  TRUE  NA's
  logical      2     3     0
> (d <- c("k", "l", "l", "m"))
[1]  "k"   "l"   "l"   "m"
> summary(d)
  Length      Class       Mode
       4  character  character
> (e <- matrix(a, c(5, 2)))
      [,1]  [,2]
 [1,]    1     2
 [2,]    2     4
 [3,]    3     1
 [4,]    5     2
 [5,]    8     2
> summary(e)
```
vypíše přehled pro každý sloupec

```
       V1              V2
  Min.   :1.0  Min.   :1.0
  1st Qu.:2.0  1st Qu.:2.0
  Median :3.0  Median :2.0
  Mean   :3.8  Mean   :2.2
  3rd Qu.:5.0  3rd Qu.:2.0
  Max.   :8.0  Max.   :4.0
> (f <- factor(a))
[1]  1   2   3   5   8   2   4   1   2   2
 Levels: 1   2   3   4   5   8
> summary(f)
```
vypisuje četnosti jednotlivých úrovní faktoru (`Levels`)

```
1   2   3   4   5   8
2   4   1   1   1   1
```

```
> (tab <- data.frame(cervena=c(15, 14, 12, 12), seda=c(13, 17, 10, 9),
+ zelena=c(7, 9, 8, 6)))
     cervena  seda  zelena
  1       15    13       7
  2       14    17       9
  3       12    10       8
  4       12     9       6
```

`> summary(tab)` opět vypisuje přehled pro každý sloupec zvlášť

```
     cervena          seda          zelena
  Min.   :12.00  Min.   : 9.00  Min.   :6.00
  1st Qu.:12.00  1st Qu.: 9.75  1st Qu.:6.75
  Median :13.00  Median :11.50  Median :7.50
  Mean   :13.25  Mean   :12.25  Mean   :7.50
  3rd Qu.:14.25  3rd Qu.:14.00  3rd Qu.:8.25
  Max.   :15.00  Max.   :17.77  Max.   :9.00
```

`str(object)` přehledně vypíše podrobnou vnitřní strukturu objektu, je alternativou k funkci `summary()` s tím rozdílem, že výpis provádí do řádku

```
> str(a)
num   [1:10]   1   2   3   5   8   2   4   1   2   2
> str(b)
cplx   [1:3]   1+3i   7-1i   NA
> str(c)
logi   [1:5]   TRUE   TRUE   FALSE   TRUE   FALSE
> str(d)
chr   [1:4]   "k"   "l"   "l"   "m"
> str(e)
num   [1:5, 1:2]   1   2   3   5   8   2   4   1   2   2
> str(f)
Factor w/   6 levels "1"   "2"   "3"   "4",..:   1   2   3   5   8   2
4   1   2   2
> str(tab)
'data.frame':   4 obs. of 3 variables
 $ cervena: num   15   14   12   12
 $ seda   : num   13   17   10   9
 $ zelena : num   7   9   8   6
```

`comment(object)` nastaví nebo vypíše komentář k danému objektu

`> comment(tab) <- "Pocty aut jednotlivych barev behem 4 casovych obdobi."` nastavení komentáře k objektu `tab`

`> comment(tab)` zobrazení komentáře

```
[1]  "Pocty aut jednotlivych barev behem 4 casovych obdobi."
```

`attributes(object)` vypisuje všechny atributy objektu. K výpisu nebo nastavení konkrétní vlastnosti objektu slouží příkaz `attr(object, name)`, kde parametr `name` udává název zjišťované vlastnosti.

```
> (ar <- array(1:8, c(2, 2, 2)))
, , 1
     [,1] [,2]
[1,]    1    2
[2,]    2    4
, , 2
     [,1] [,2]
[1,]    5    7
[2,]    6    8
> attributes(ar)
$dim
[1] 2 2 2
> attributes(f)
$levels
[1] "1" "2" "3" "4" "5" "8"

$class
[1] "factor"
> attributes(tab)
$names
[1] "cervena" "seda" "zelena"

$row.names
[1] 1 2 3 4

$class
[1] "data.frame"

$comment
[1] "Pocty aut jednotlivych barev behem 4 casovych obdobi."
> attr(tab, "names")
[1] "cervena" "seda" "zelena"
```

Funkce `as.something()` umožňuje změny datových typů všude, kde je to smysluplné.

```
> u <- 1:10
[1]  1  2  3  4  5  6  7  8  9 10
```

```
> v <- as.character(u)
```
převede numerický vektor na vektor textových hodnot
```
[1]  "1"  "2"  "3"  "4"  "5"  "6"  "7"  "8"  "9"  "10"
```
```
> w <- as.integer(v)
```
převede vektor textových hodnot na numerický vektor, vektory `u` a `w` jsou stejného typu
```
[1]  1  2  3  4  5  6  7  8  9  10
```

K převodu objektů z jednoho datového typu na druhý je k dispozici velké množství funkcí typu `as.something()`. Jejich seznam můžeme najít příkazem `methods(as)`.

Kapitola 8

Grafika v R

Systém R umožňuje zobrazovat širokou škálu grafů. Příkazy k vykreslování grafů jsou rozděleny do tří základních skupin:

- **High-level** funkce vytváří kompletní nový graf s osami, popisky, názvem atd.
- **Low-level** funkce přidávají do již existujícího grafu další informace, např. další body, čáry, popisky.
- **Interaktivní grafika** umožňuje interaktivně pomocí myši přidávat data do již existujícího grafu.

V případě, že jsou tyto grafy nedostačující, můžeme použít dalších balíčků - např. `grid`, `lattice`, `iplots`, `misc3D`, `rgl`, `scatterplot` nebo balíček `maps` obsahující nejrůznější mapy.

8.1 High-level funkce

Všechny grafy jsou nejprve vytvořeny pomocí high-level funkcí, které vytváří "kompletní" graf. Kompletní v tom smyslu, že jsou automaticky vygenerovány osy, popisky a nadpis (pokud sami nenastavíme jinak). High-level funkce vždy vykreslují nový graf, v případě, že již nějaký graf existuje, přepíší jej. Je důležité si uvědomit, že data k vykreslení mohou být různé objekty - podle druhu objektu grafické funkce následně vykreslují graf.

Argumenty k high-level funkcím:

`axes`	implicitní hodnota `TRUE`, nastavení na hodnotu `FALSE` potlačuje vykreslování os
`log`	nastavením na hodnoty `log="x"`, `log="y"`, `log="xy"` budou mít vybrané osy logaritmické měřítko

`main`	textový řetězec pro název grafu, je umístěn nad grafem
`sub`	textový řetězec, je umístěn pod grafem a psán menším fontem
`type`	typ výstupního grafu
	`type="p"` vykresluje samostatné body (implicitní nastavení)
	`type="l"` linie
	`type="b"` přerušované linie s body
	`type="c"` přerušované linie bez bodů
	`type="o"` body navzájem spojené liniemi
	`type="h"` vertikální linie
	`type="s"` schodovitý graf s první linií horizontální
	`type="S"` schodovitý graf s první linií vertikální
	`type="n"` žádné vykreslování dat, vykresleny jsou pouze osy, rozsah souřadného systému závisí na datech
`xlab, ylab`	textové řetězce pro názvy os x a y, tyto argumenty mění implicitně zadané názvy os při volání high-level funkcí
`xlim, ylim`	2-prvkový vektor specifikující minimální a maximální hodnotu k vykreslení dané osy

Dále jsou uvedeny nejpoužívanější typy grafů se svými argumenty. Nejedná se o kompletní výčet argumentů, uvedeny jsou pouze ty nejdůležitější. Použitá data jsou uvedena na přiloženém CD.

• `plot(x)` vzhled grafu závisí na povaze vstupních dat. Pro numerický vektor vrací jednoduchý graf s indexy na ose x a hodnotami na ose y, pro matice vrací graf s hodnotami prvního sloupce na ose x a odpovídajícími hodnotami druhého sloupce na ose y (ostatní sloupce jsou ignorovány), pro faktory vykresluje sloupcový graf četností jednotlivých kategorií, pro datové tabulky vykresluje bodový graf závislosti všech proměnných, pro funkce vykresluje hladkou čáru

`plot(x, y)` jestliže `x` a `y` jsou vektory téže délky, funkce vykreslí bodový graf hodnot `y` na pozicích `x`. Stejného výsledku můžeme docílit nahrazením argumentů `x` a `y` buď seznamem, obsahujícím dvě složky `x` a `y`, nebo maticí o dvou sloupcích (viz příkaz `plot(x)`).

Implicitní vzhled grafu `plot(x)` a `plot(x, y)` můžeme upravit pomocí široké škály volitelných argumentů:

`main, sub, type`

`axes, xlim, ylim, xlab, ylab`

`ann, col, bg, pch, cex, lty, lwd` parametry zadávající výpis názvu a popisků os, barvu, barvu pozadí grafu, znaky pro vykreslení bodů a jejich velikost, typ a tloušťku čar. Více informací v odstavci 8.3.

`frame.plot` logická hodnota implicitně nastavená na `TRUE` graf orámuje

`asp` poměr osy y/x

```
> plot(function(x) 2*x^3, xlim=c(-3, 3), ylab="f(x)", main="Graf funkce
+ f(x)=2*x^3")
```

```
> benzen <- c(3.34, 4.76, 4.87, 5.11, 3.89, 4.83, 5.02)
```
sedm měření pro kontrolu obsahu benzenu v ovzduší [mg/m^3], [8]

```
> plot(benzen, pch=8, xlab="cislo pozorovani", ylab="obsah benzenu
+ [mg/m^3]", main="Obsah benzenu v ovzdusi")
```

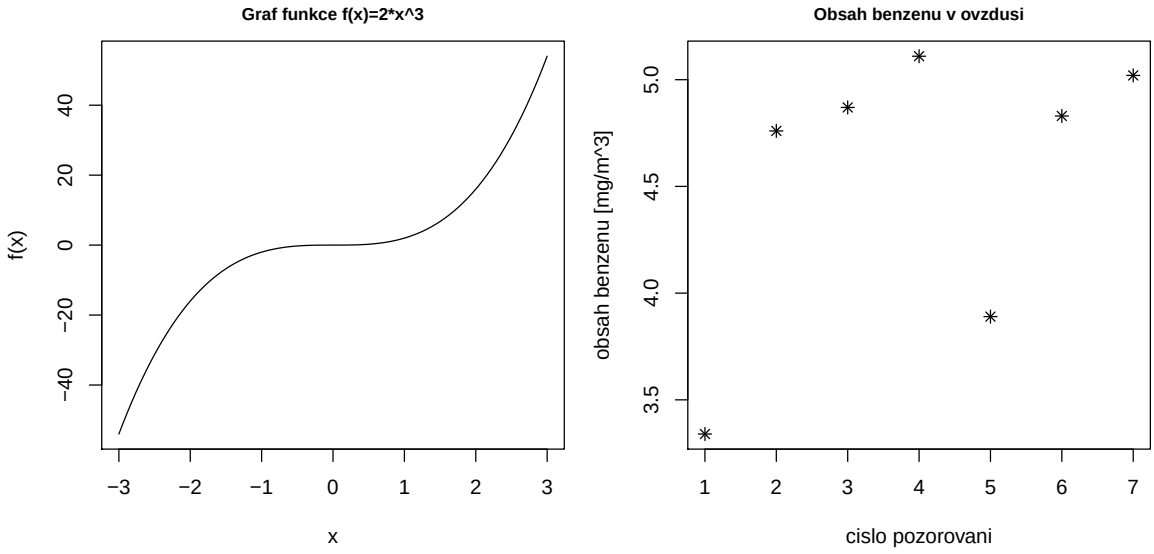

Obr. 8.1. Funkce plot()

```
> plot(benzen, type="p", main="type='p'", ylab="benzen [mg/m^3]")
> plot(benzen, type="l", main="type='l'", ylab="benzen [mg/m^3]")
> plot(benzen, type="b", main="type='b'", ylab="benzen [mg/m^3]")
> plot(benzen, type="c", main="type='c'", ylab="benzen [mg/m^3]")
> plot(benzen, type="o", main="type='o'", ylab="benzen [mg/m^3]")
> plot(benzen, type="h", main="type='h'", ylab="benzen [mg/m^3]")
> plot(benzen, type="s", main="type='s'", ylab="benzen [mg/m^3]")
> plot(benzen, type="S", main="type='S'", ylab="benzen [mg/m^3]")
```

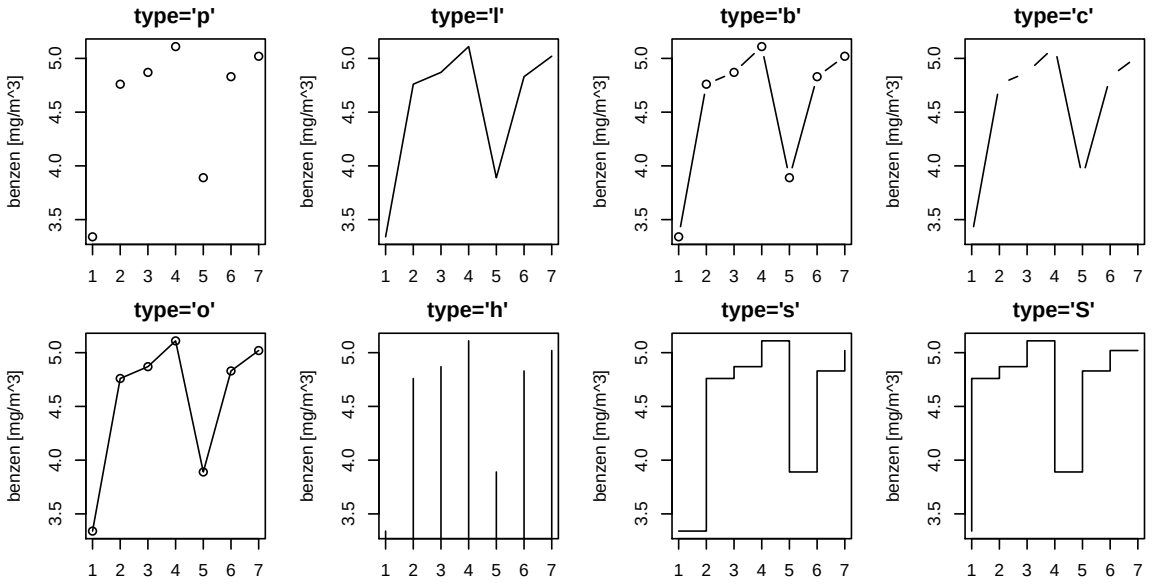

Obr. 8.2. Možné varianty argumentu `type`

• `barplot()` sloupcový graf

`axes, main, sub, xlab, ylab, xlim, ylim`

`beside` lze použít pouze v případě vstupního argumentu typu matice. Implicitní hodnota `beside=FALSE` vykreslí více obdélníků nad sebou, nastavení na hodnotu `TRUE` vedle sebe.

`width` vektor hodnot udávajících šířku vykreslovaných obdélníků na ose x. Jestliže vektor `wide` nedosahuje délky rovné počtu složek argumentu, je použito pravidlo *recycling rule*.

`space` velikost místa pro vynechání mezi jednotlivými sloupci (podíl průměrné šířky sloupce), může se jednat o numerickou hodnotu nebo vektor hodnot. Pro vstupní matici a argument `beside=TRUE` může být argument `space` specifikován vektorem dvou hodnot, první vyjadřuje odestup sloupců ve stejné skupině (ve stejném sloupci), druhý vyjadřuje odestup mezi skupinami. Implicitní nastavení je `space=c(0,1)` pro vstupní matici a argument `beside=TRUE`, pro ostatní možnosti `space=0.2`.

`names.arg` vektor názvů ke každému sloupci nebo skupině sloupců

`legend.text` vektor textových řetězců uvádějící názvy v legendě, má smysl jen pro vstupní matice

`horiz` implicitní hodnota `horiz=FALSE` vykresluje obdélníky vertikálně, argument `horiz=TRUE` horizonatálně

`density` hodnota nebo numerický vektor nastavující hustotu šrafování sloupců

`angle` úhel pro sklon šrafování

```
> load(file="penicilin.dat")
```
načtení potřebného souboru dat, který musí být uložen v aktuálním pracovním adresáři. Data pro porovnání obsahu penicilinu [mg/l] v krvi dvou pacientů, [8]

```
> barplot(penicilin, ylab="obsah penicilinu [mg/l]")
> barplot(penicilin, beside=T, ylab="obsah penicilinu [mg/l]")
> barplot(penicilin, beside=T, ylab="obsah penicilinu [mg/l]",
+ space=c(0.5,1.5), density=c(7,18), angle=c(60,105), col=gray(c(0,
+ 0.6)))
```
funkce `gray` slouží k vykreslení různého stupně šedi (více v odstavci 8.3)

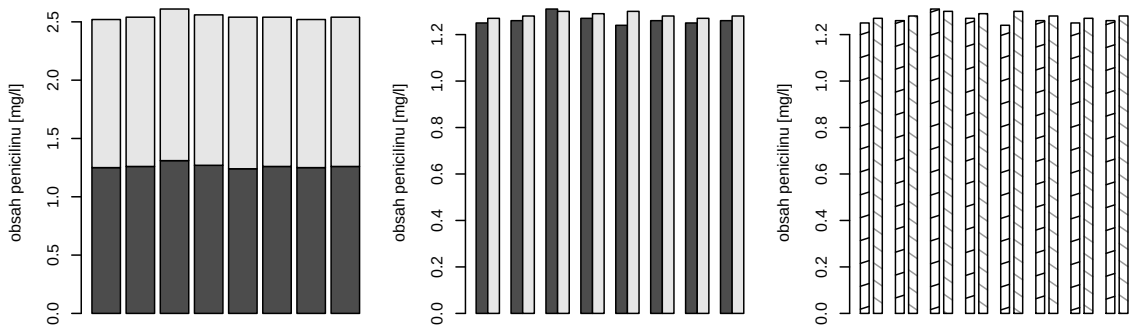

Obr. 8.3. Porovnání obsahu penicilinu v krvi dvou pacientů [mg/l]

```
> load(file="dunaj.dat")
```
načtení datového souboru `dunaj.dat` (kolísání průtoku Dunaje [m^3/s] během roku, [8])

```
> barplot(dunaj, names.arg=c("I", "II", "III", "IV", "V", "VI", "VII",
+ "VIII", "IX", "X", "XI", "XII"), ylab="prutok [m^3/s]",
+ xlab="mesic")
> barplot(dunaj, horiz=T, names.arg=c("I", "II", "III", "IV", "V",
+ "VI", "VII", "VIII", "IX", "X", "XI", "XII"), ylab="prutok
+ [m^3/s]", xlab="mesic")
> barplot(dunaj, width=c(1, 2, 3), density=rep(c(5, 8, 13), times=4),
+ angle=seq(from=30, by=10, length=12), names.arg=c("I", "II", "III",
+ "IV", "V", "VI", "VII", "VIII", "IX", "X", "XI", "XII"), ylab="prutok
+ [m^3/s]", xlab="mesic")
> barplot(dunaj, col=gray(seq(from=0, to=1, length=12)), names.arg=
+ c("I", "II", "III", "IV", "V", "VI", "VII", "VIII", "IX", "X", "XI",
+ "XII"), ylab="prutok [m^3/s]", xlab="mesic")
```

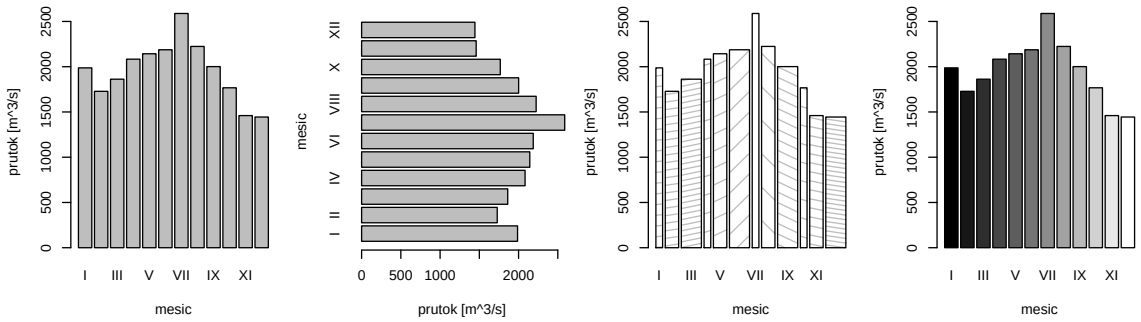

Obr. 8.4. Kolísání průtoku Dunaje během roku [m^3/s]

• `hist(x)` histogram pro numerický vektor

`breaks` argument šířky intervalů, implicitní nastavení je `breaks="Sturges"`, která šířku intervalů počítá Sturgesovým pravidlem: $\log_2 n + 1$, [18], dalšími možnostmi jsou `breaks="Scott"` (Scottovo pravidlo: $3.5 \cdot \hat{\sigma} \cdot n^{-1/3}$, [18]) nebo `breaks="FD"` (Freedman a Diaconis: $2 \cdot IQR \cdot n^{-1/3}$, [18]), n udává počet hodnot vektoru, $\hat{\sigma}$ je odhadem směrodatné odchylky a IQR značí interkvantilové rozpětí

`freq` implicitní nastavení `freq=TRUE` vykresluje absolutní četnosti, nastavení na hodnotu `freq=FALSE` vykresluje relativní četnosti

`right` pro implicitní hodnotu `right=TRUE` jsou intervaly zprava uzavřené, zleva otevřené, pro hodnotu `right=FALSE` je tomu naopak

`labels` pro hodnotu `labels=TRUE` vypisuje nad sloupce absolutní/relativní četnosti

`density, angle` stejně jako u `barplot()`

`axes, main, sub, xlim, ylim, xlab, ylab`

Funkce `hist()` má k dispozici i výstupní hodnoty:

`breaks` hodnoty hranic intervalů

`counts` absolutní četnosti pro každý interval

`density` hustota pravděpodobnosti pro jednotlivé intervaly

`intensities` shodné s `density`

`mids` středy intervalů

`xname` název objektu v argumentu

`equidist` logická hodnota stejné délky všech intervalů

```
> load(file="obili.dat")
```
načtení souboru dat (sklizňová ztráta obilí [g/m^3], [8])

```
> hist(obili, breaks="Sturges", main="breaks='Sturges'")
> hist(obili, breaks="Scott", main="breaks='Scott'")
> hist(obili, breaks="FD", main="breaks='FD'")
```

Obr. 8.5. Sklizňová ztráta obilí [g/mˆ3], argumenty šířky intervalů

```
> hist(obili, main="")
> hist(obili, freq=F, main="")
> hist(obili, labels=T, main="")
```

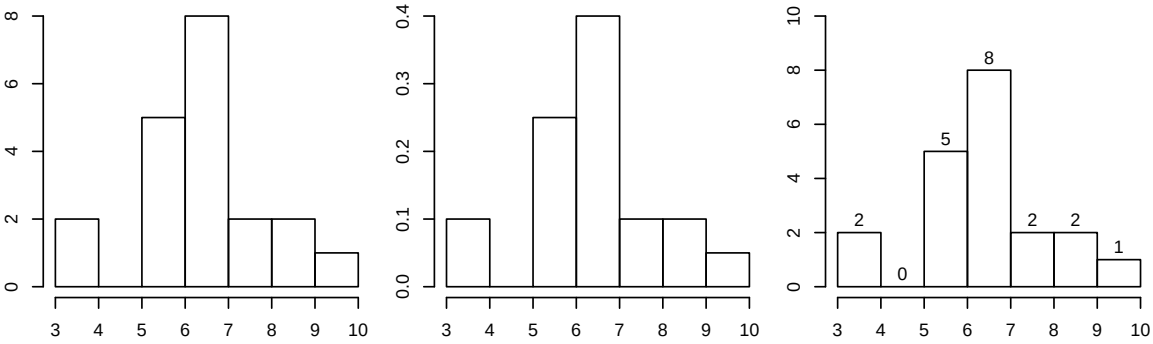

Obr. 8.6. Sklizňová ztráta obilí [g/mˆ3], zobrazení absolutních a relativních četností

```
> (hist(obili))    výstupní hodnoty
$breaks
[1]  3   4   5   6   7   8   9   10
$counts
[1]  2   0   5   8   2   2   1
$intensities
[1]  0.09999998   0.00000000   0.25000000   0.40000000   0.10000000
+ 0.10000000   0.05000000
$density
[1]  0.09999998   0.00000000   0.25000000   0.40000000   0.10000000
+ 0.10000000   0.05000000
```

```
$mids
[1]  3.5   4.5   5.5   6.5   7.5   8.5   9.5
$xname
[1]  "obili"
$equidist
[1]  TRUE
$attr(,"class")
[1]  "histogram"
```

- `pie()` koláčový graf pro vektor nezáporných celých čísel
  `labels` vektor textových hodnot vyjadřující názvy jednotlivých dílů grafu
  `edges` numerická hodnota udávající počet vrcholů polygonu
  `clockwise` logická hodnota vykreslení po (`TRUE`) nebo proti (`FALSE`, implicitní nastavení) směru hodinových ručiček
  `init.angle` počáteční úhel pro natočení grafu
  `density, angle`

```
> kralici <- c(3, 4, 2, 5, 3)
> pie(kralici, angle=30, labels=c("lokalita
+ 1", "lokalita 2", "lokalita 3", "lokalita 4", "lokalita 5"),
+ col=gray(seq(from=0, to=1, length=5)))
> pie(kralici, edges=5, col=gray(seq(from=0, to=1, length=5)))
> pie(kralici, clockwise=F, init.angle=90, col=gray(seq(from=0, to=1,
+ length=5)))
```

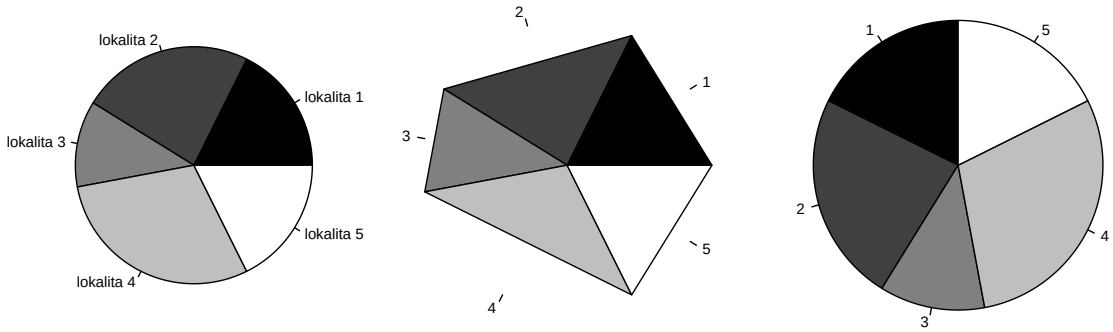

Obr. 8.7. Počet chycených králíků v jednotlivých lokalitách lesa, [8]

• `boxplot()` krabicový graf

`range` vymezuje rozpětí "fousků" grafu, pro kladné `range` se "fousky" rozpínají do vzdálenosti `range` $\cdot IQR$ (interkvartilová odchylka), pro `range=0` se rozpínají od minimální po maximální hodnotu, implicitní nastavení `range=1.5`

`notch` implicitní nastavení `notch=FALSE`, pro `notch=TRUE` zobrazuje výřezy po stranách "krabice" (výřezy odpovídají hodnotám $\frac{\pm 1.58 \cdot IQR}{\sqrt{n}}$)

`outline` implicitní nastavení `outline=TRUE` zobrazuje odlehlé hodnoty, hodnota `FALSE` odlehlé hodnoty nezobrazuje

`names` vektor textových řetězců pro názvy jednotlivých krabicových grafů

`horizontal` pro hodnotu `horizontal=TRUE` vykresluje grafy horizontálně

`pars` seznam parametrů k volbě vzhledu krabicového grafu (velikosti "krabic", hodnoty "fousků" a extrémů, typy, šířky a barvy čar, velikosti bodů atd.), více pomocí příkazu `help(bxp)`

Příkazem `(boxplot())` získáme výstupní hodnoty:

`stats` matice, jejíž sloupce obsahují informaci o hodnotách dolního "fousu", dolní části krabice, mediánu, horní části krabice a horním "fousu".[1]

`n` vektor počtu pozorování každé skupiny

`conf` matice, jejíž sloupce obsahují horní a dolní extrémy výřezů (notch)

`out` odlehlé hodnoty

`group` vektor stejné délky jako `out`, jehož prvky uvádějí, do které skupiny patří odlehlé hodnoty

`names` vektor názvů skupin

```
> load(file="dusicnany.dat")
```
načtení datového souboru (obsah dusičnanů ve studniční vodě, [8])

```
> boxplot(dusicnany)
> boxplot(dusicnany, range=0)
> boxplot(dusicnany, notch=TRUE, outline=FALSE)
```

```
> load(file="kyslik.dat")
```
načtení datového souboru (porovnání dvou metod stanovení obsahu kyslíku ve vodě [mg/l], [8])

```
> boxplot(kyslik, names=c("metoda A", "metoda B"), horizontal=TRUE,
+ las=1, xlab="obsah kysliku [mg/l]")
```

[1] Záměrně jsou uvedeny pojmy jako dolní "fous", dolní část krabice, horní část krabice, horní "fous", protože implicitní nastavení (dolní hradba, dolní kvartil, horní kvartil, horní hradba) může být uživatelem změněno pomocí argumentů `range` a `pars` na jiné hodnoty.

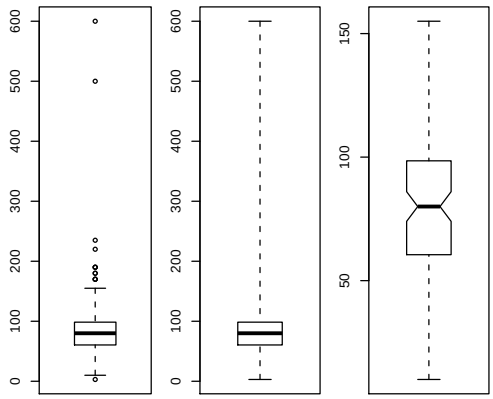

Obr. 8.8. Obsah dusičnanů ve studniční vodě [mg/l]

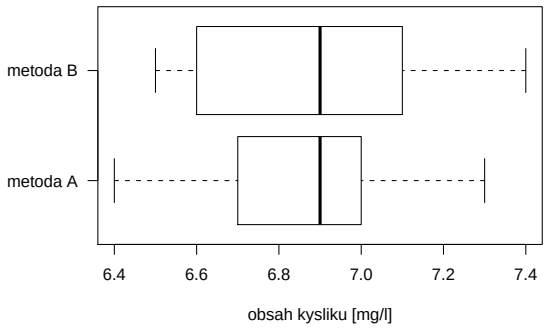

Obr. 8.9. Porovnání dvou metod stanovení obsahu kyslíku ve vodě [mg/l]

```
> (boxplot(kyslik))    výstpní hodnoty
$stats
       [,1]  [,2]
 [1,]   6.4   6.5
 [2,]   6.7   6.6
 [3,]   6.9   6.9
 [4,]   7.0   7.1
 [5,]   7.3   7.4

$n
[1]  30   30

$conf
          [,1]      [,2]
 [1,]  6.81346  6.755766
 [2,]  6.98654  7.044234

$out
numeric(0)

$group
numeric(0)
```

• `stripchart()` pro numerické vektory, seznamy a tabulky dat vykresluje diagram rozptýlení, používá se pro jednoduché zobrazení dat

`method` způsob zobrazení shodných dat, implicitní nastavení `method="overplot"` způsobuje překrývání shodných dat, `method="jitter"` zobrazuje náhodně kolem osy

`y` a `method="stack"` skládá nad sebe

`jitter` v případě volby `method="jitter"` můžeme argumentem `jitter` nastavit šířku vykreslování kolem osy `y`

`offset` v případě volby `method="stack"` argument udává rozestup mezi jednotlivými vykreslenými body

`vertical` pro hodnotu `vertical=TRUE` vykresluje vertikálně

`group.names` textový řetězec názvů skupin zobrazovaný po bocích grafu (při vykreslení více grafů)

`at` numerický vektor udávající pozici pro vykreslení bodů

```
> load(file="cekani.dat")
```
načtení datového souboru (doba čekání na zákazníka [min], [8])

```
> stripchart(cekani, method="overplot", main="method = 'overplot'",
+ cex=1)
> stripchart(cekani, method="jitter", main="method = 'jitter'", cex=1,
+ pch=1)
> stripchart(cekani, method="stack", main="method = 'stack'", cex=1.5,
+ pch=20, offset=0.4, at=0)
```
argument `cex` udává velikost znaků, `pch` typ znázorňovaných bodů, více viz odstavec 8.3

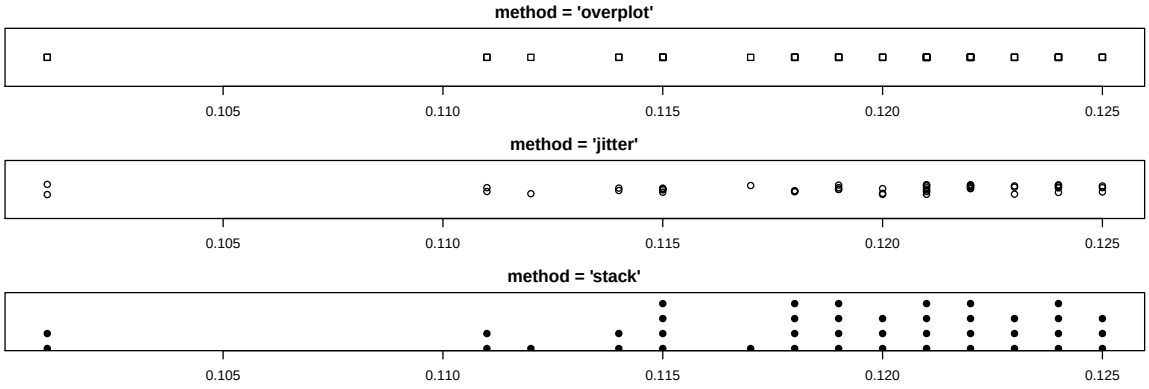

Obr. 8.10. Doba čekání na zákazníka [min]

• `matplot()` vykreslení více datových řad do jednoho grafu. Vzhled grafu lze měnit níže uvedenými argumenty, implicitní vykreslení je pomocí číslic

`matplot(x)` pro vstupní matici `x` tvoří každou datovou řadu jeden sloupec matice

`matplot(x, y)` pro dvě vstupní matice stejných rozměrů udávají shodné pozice souřadnice bodů, datové řady opět tvoří sloupce matic. Lze vykreslit i pro vstupní vektor `x` stejné délky jako počet řádků matice `y`

`type, main, xlab, ylab, xlim, ylim`

`lty, lwd, pch, col, cex` viz odstavec 8.3

```
> load(file="smes.dat")
```
načtení datového souboru (vliv krmné směsi na přírůstek zvířat, [8])

```
> matplot(smes, main="matplot(x)", ylab="prirustek [kg]", type=c("b",
+ "b"), lty=c(2,3), pch=c(15, 16), col=c(2,4))
> legend(7, 29, c("smes 1", "smes 2"), lty=c(2,3), pch=c(15, 16),
+ col=c(2,4))
```
funkce pro zobrazení legendy, více viz odstavec 8.2

```
> time <- seq(from=1962, to=1978, length=17)
> load(file="chmel.dat")
```
načtení datového souboru (vývoz a sklizeň chmele v ČSSR v letech 1962 až 1978, [8])

```
> matplot(time, chmel, main="matplot(x,y)", ylab="chmel [tis. tun]")
> legend(time[1], 12, c("vyvoz", "sklizen"), pch=c("1","2"), col=1:2)
```

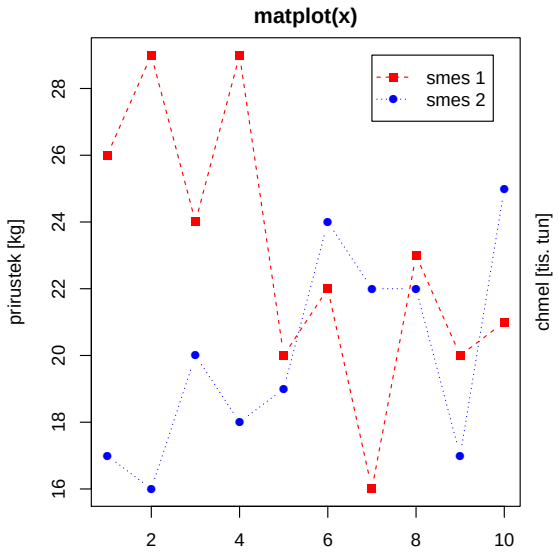

Obr. 8.11. Vliv krmné směsi na přírůstek zvířat [kg], [8]

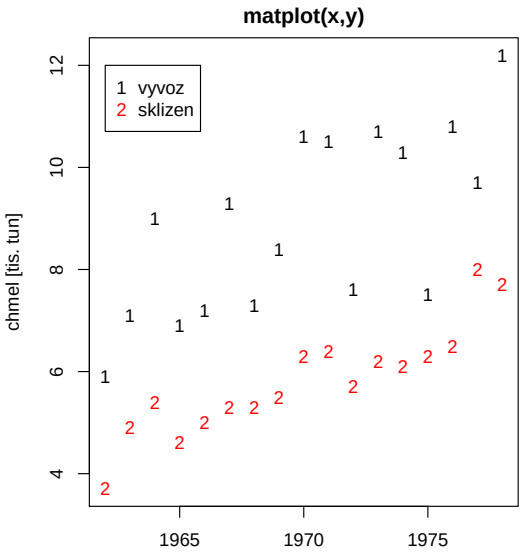

Obr. 8.12. Vývoz a sklizeň chmele v ČSSR v letech 1962 až 1978

• `qqnorm(), qqline()` grafy pro ověřování normality dat. `qqnorm()` vykresluje normální kvantil-kvantilový graf (Q-Q plot), `qqline()` navíc přidá do již existujícího grafu přímku odpovídající normálnímu rozložení, jedná se o low-lewel funkci

```
> qqnorm(rnorm(70))
> qqnorm(rnorm(70))
> qqline(rnorm(70), col=gray(0.5))
```
funkce `gray` slouží k vykreslení různé stupně šedi (více v odstavci 8.3)

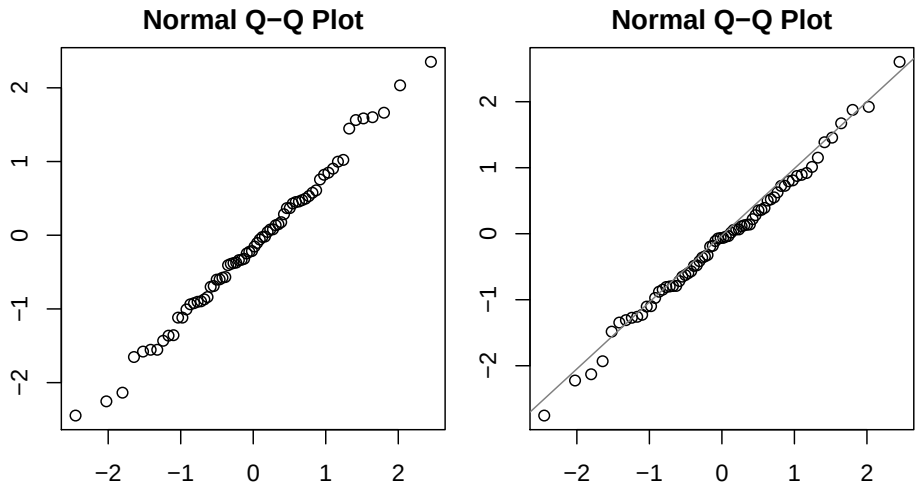

Obr. 8.13. Q-Q plot pro výběr z normálního rozložení

• `curve()` vykreslí křivku
  `from, to` interval pro vykreslení funkce

• `image()` vytvoří mřížku s obdélníky různého stupně šedi, slouží k zobrazení 3-dimenzionálních nebo prostorových dat

```
> curve(sin(5*x), from=-30, to=30, main="curve()")
> x <- seq(-1.5*pi, 1.5*pi, length=50)
> y <- seq(-1.5*pi, 1.5*pi, length=50)
> z <- sin(x) %*% t(sin(y))
> image(x, y, z, col=gray(seq(from=0, to=1, length=80)), main="image()")
```

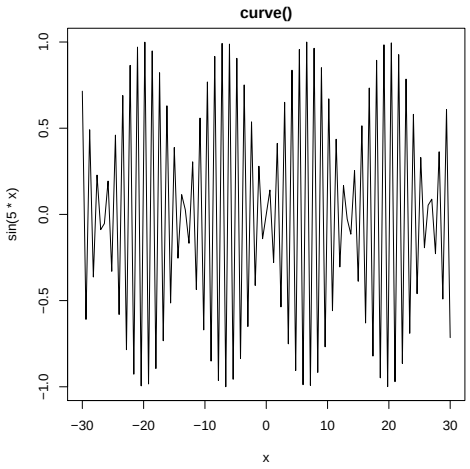

Obr. 8.14. Funkce `curve()`

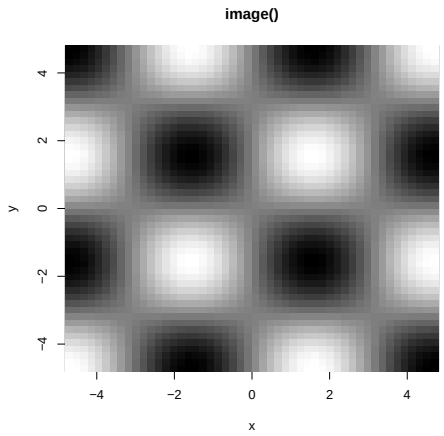

Obr. 8.15. Funkce `image()`

• `persp(x, y, z)` slouží k vykreslení 3D grafu
`xlim, ylim, zlim` intervaly pro vykreslování hodnot na osách x, y a z
`main, sub, col`
`theta` úhel pro otočení grafu v horizontálním smyslu
`phi` úhel pro otočení grafu ve vertikálním smyslu
`shade` stínování
`ticktype` typ os, `ticktype="simple"` (implicitní nastavení) vykreslí pouze šipky souběžné s osami grafu, šipky indikují směr nárůstu hodnot, `ticktype="detailed"` zobrazuje i měřítko os (počet značek na ose udává argument `nticks`)

`border` implicitní nastavení `NULL` vykresluje křivky, barvu vykreslovaných křivek můžeme měnit pomocí argumentu `col` nebo funkce `gray()`, nastavení `border=NA` vykreslení křivek zabraňuje

```
> persp(x, y, z)
> persp(x, y, z, ticktype="detailed", nticks=5, phi=270, xlab="osa x",
+ ylab="osa y", zlab="osa z")
> persp(x, y, z, ticktype="detailed", nticks=5, phi=30, theta=55,
+ shade=0.5, xlab="osa x", ylab="osa y", zlab="osa z")
> persp(x, y, z, shade=0.5, phi=30, theta=55, border=NA, axes=F)
```

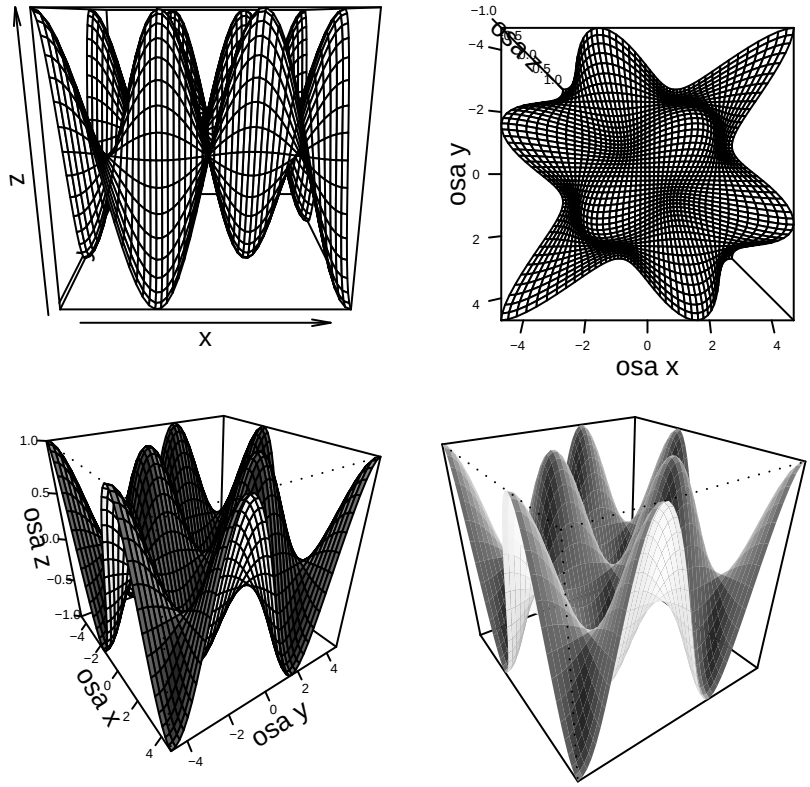

Obr. 8.16. Funkce `persp()`

Funkce `contour()` a `filled.contour()` slouží k podobnému zobrazení jako funkce `image()`.

```
> contour(x, y, z, main="contour()")
> filled.contour(x, y, z, main="filled.contour()")
```

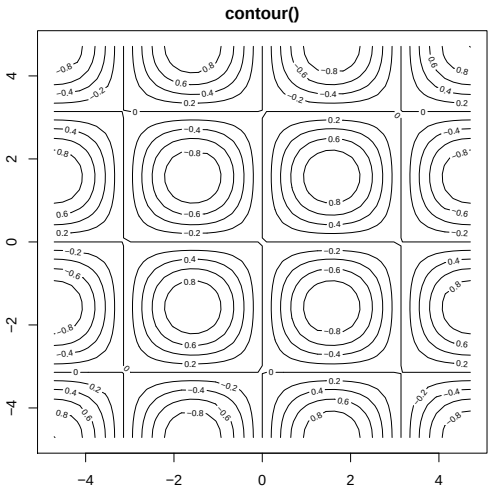

Obr. 8.17. Funkce `contour()`

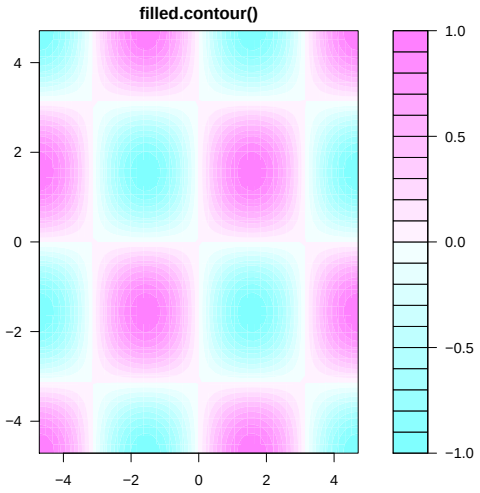

Obr. 8.18. Funkce `filled.contour()`

Velký výběr dalších 3D grafů nabízí balíčky `misc3d`, `scatterplot3d` a `lattice`.

• `symbols()` na dané souřadnice vykreslí symboly - kružnice, čtverce, trojúhelníky, hvězdičky, více informací viz `help(symbols)`

Další tvary pro vykreslení: `rect()` (vykresluje obdélníkovou oblast), `polygon()` (mnohoúhelníky), `arrows()` (šipky), `rug()` ("rohož" s rozestupem).

8.2 Low-level funkce

Někdy se stává, že grafické funkce nevykreslují přesný typ grafu, jaký bychom si přáli. V těchto případech je dobré použít tzv. low-level funkce. Pomocí nich vytváříme celý graf po samostatných částech přidáním dalších informací (body, čáry, text, ...) do již existujícího grafu.

Nejpoužívanější funkce pro tvorbu low-level grafiky (pro význam argumentů `bg`, `cex`, `col`, `lty`, `lwd` a `pch` viz odstavec 8.3):

• `points(x, y, type, pch, col, bg, cex, lwd, ...)` dle nastavení argumentů vykreslí body daných tvarů a barev na souřadnice `x`, `y`

• `lines(x, y, type, lty, lwd, ...)` vykreslí lomenou čáru mezi body danými souřadnicemi `x` a `y`
• `segments(x0, y0, x1, y1, col, lty, lwd, ...)` vykreslí úsečky mezi dvěma body o souřadnicích [`x0`, `y0`], [`x1`, `y1`]
• `abline(a, b, ...)` vykreslí přímku se směrnicí `b` a průsečíkem s osou y `a`
• `abline(h, ...)` vykreslí vodorovné úsečky přes celou šířku grafu, `h` udává hodnoty na ose y
• `abline(v, ...)` vykreslí svislé úsečky, `v` udává hodnoty na ose x

• `legend(x, y, legend, ...)` na souřadnice `x` a `y` vytiskne legendu (vektor textových řetězců). Funkce má velké množství volitelných argumentů (viz `help(legend)`)
• `title(main, sub, xlab, ylab, ...` vypíše název, podtitulek, popisky os
• `grid(nx, ny)` vykreslí mřížku, `nx` a `ny` udávají počet vertikálních a horizontálních čar, implicitní nastavení k vykreslování mřížky (`col="lightgray", lty="dotted", lwd=par("lwd")`) lze samozřejmě libovolně měnit
• `axis(side, at, labels, tick, lty, lwd, col, ...)` vykreslí osu, umožňuje nastavit značky a popisky libovolně pro jednotlivé osy

`side`	přirozené číslo specifikující stranu grafu, na které má být osa vykreslena (1 - dole, 2 - vlevo, 3 - nahoře, 4 - vpravo)
`at`	body, ve kterých mají být vykreslovány značky pro měřítko
`labels`	názvy pro jednotlivé značky
`tick`	logická hodnota pro vykreslování značek

• `text(x, y, labels, ...)` vypíše textový řetězec `labels` do grafu na pozici [`x`, `y`]
• `mtext(text, side, ...)` vypíše textový řetězec `text` na okraj grafu (`side`)

8.3 Funkce `par()`

Funkce `par()` slouží k nastavení a změnám parametrů aktuálního grafu. Nastavení parametrů pomocí funkce `par()` mění hodnoty parametrů nastálo – ve všech dalších voláních libovolné grafické funkce až do doby zavření grafického okna nebo nastavení parametrů na nové hodnoty. S otevřením nového grafického okna jsou všechna předchozí nastavení ignorována.

Text

`adj`	zarovnání textu pro název grafu a popisky os, 0 - zarovnat vlevo, 1 - zarovnat vpravo, 0.5 - zarovnat horizontálně na střed
`ann`	implicitní hodnota `ann=TRUE` vypisuje anotace (název a popisky os), hodnota `FALSE` je potlačuje
`cex`	relativní velikost znaků (1 - normální velikost, 2 - dvojnásobná), `cex.main` nastaví velikost znaků pro název grafu, `cex.sub` pro podtitulek, `cex.axis`, `cex.lab` pro velikost písma popisků a názvů os

Barva

`bg` barva pozadí grafu

`col` barva bodů, obrysů bodů nebo spojnice. Barva může být vyjádřena přirozeným číslem nebo textovým řetězcem. Pro barvu os použijeme příkaz `col.axis`, pro popisky os `col.lab`, pro titulek a podtitulek grafu `col.main` a `col.sub`. Základní barvy jsou uvedeny v Tab. 8.1, podrobnější seznam barev o 657 položkách dostaneme příkazem `colors()`, funkcí `gray()` s argumenty od 0 do 1 získáme různé stupně šedi

barva	numerická hodnota	textový řetězec
bílá	0	`"white"`
černá	1	`"black"`
červená	2	`"red"`
zelená	3	`"green"`
modrá	4	`"blue"`
modrozelená	5	`"cyan"`
fialová	6	`"magenta"`
žlutá	7	`"yellow"`
šedá	8	`"gray"`

Tab. 8.1. Barvy bodů

Graf

`pty` textový řetězec specifikující tvar grafické oblasti, `"s"` čtvercová, `"m"` maximální

`mfcol` 2-prvkový vektor tvaru `c(pocet_radku, pocet_sloupcu)` rozdělující graf na odpovídající počet podgrafů, jednotlivé grafy jsou řazeny po sloupcích

`mfrow` stejně jako `mfcol`, grafy jsou řazeny po řádcích

Osy

`las` numerická hodnota pro otočení popisků os:
0 - x vodorovně, y svisle
1 - x i y vodorovně
2 - x svisle, y vodorovně
3 - x i y svisle

Body, čáry

`lty` numerická hodnota udávající typ čáry, jednotlivé typy s odpovídající hodnotou jsou uvedeny na Obr. 8.19

`lwd` numerická hodnota pro šířku čáry, standardní `lwd=1`

`pch` numerická hodnota pro znak vykreslovaných bodů, jednotlivé znaky s hodnotami `1` – `20` jsou uvedeny na Obr. 8.26. Pro hodnoty `21` – `25` jsou vykresleny znaky s hodnotou `1`, `0`, `5`, `2`, `6` (v tomto pořadí) s volitelnou barvou výplně `bg` a barvou hranice `col`. Hodnoty `26` – `31` nejsou definovány, hodnotám `32` – `255` odpovídají znaky ASCII tabulky. Je možno použít i jakékoliv textové řetězce, vypisuje se však vždy jen první znak.

Obr. 8.19. Typy čar (argument `lty`)

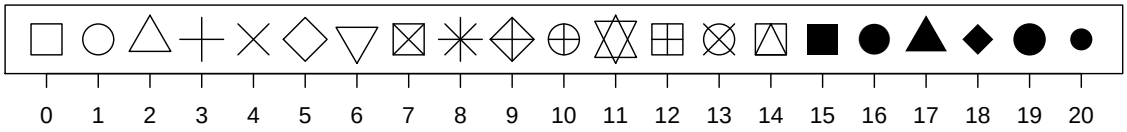

Obr. 8.20. Typy bodů (argument `pch`)

8.4 Další užitečné funkce

K otevření dalšího grafického okna slouží příkaz `dev.new()` nebo `windows()` (pouze v systému Windows). Příkaz `dev.new()` můžeme použít i s numerickým argumentem `which`, prostřednictvím něhož lze příkazy `dev.set(which)` a `dev.off(which)` dané okno aktivovat, popř. zavřít. Příkaz `graphics.off()` zavře všechna grafická okna.

Ukládat grafy lze v menu *File* → *Save as* výběrem požadovaného formátu. Alternativou je použít některého z příkazů:

```
pdf(file, width, height)
postscript(file, width, height)
png(file, width, height)
jpeg(file, width, height)
```

`file` textový řetězec pro název souboru
`width` šířka grafu v palcích
`height` výška grafu v palcích

```
> pdf(file="Nil.pdf")
> plot(Nile, main="Rocni prutoky reky Nil")
```

vykreslení objektu `Nile` (vestavěná proměnná)

```
> dev.off()
null device
          1
```

Příkazem `recordPlot()` lze grafy ukládat i jako objekty. Zpětně lze takto uložený graf zobrazit (a upravovat) příkazem `replayPlot()` nebo zavoláním názvu objektu.

```
> plot(Nile, main="Rocni prutoky reky Nil")
> Nil <- recordPlot
```

uložení grafu do proměnné `Nil`

```
> replayPlot(Nil)
```

zobrazení grafu

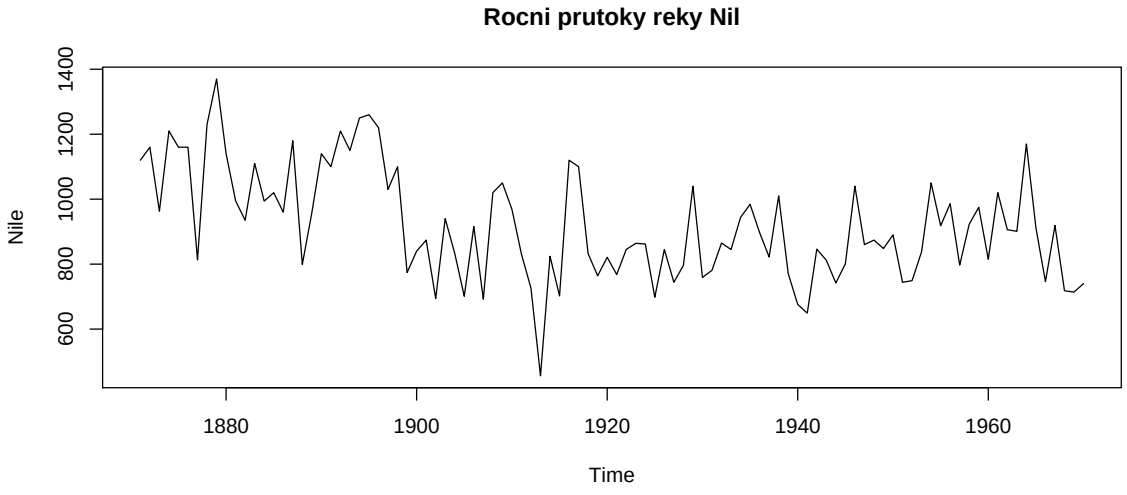

Obr. 8.21. Roční průtoky řeky Nil

Funkce `layout()` umožňuje vytvářet složený graf obsahující několik grafů různých rozměrů, přičemž mohou zabírat i více řádků či sloupců.

Jediným povinným argumentem funkce je matice, jejíž počet řádků a sloupců a jejich číselné hodnoty určují pořadí zaplňování jednotlivých "boxů" grafy. Příkaz `layout(matrix(c(1, 0, 3, 2), 2, 2, byrow=TRUE))` vytvoří graf se čtyřmi boxy, přičemž pozice $[1, 1]$ bude obsazena jako první, dále budou obsazovány pozice $[2, 2]$ a $[2, 1]$, pro nulovou hodnotu zůstává pozice prázdná (pozice $[1, 2]$).

Argumenty `heights` a `widths` jsou používány ke specifikaci výšek a šířek boxů. Šablonu s jednotlivými boxy si můžeme prohlédnout příkazem `layout.show(n)` (Obr. 8.22), kde `n` udává počet vykreslovaných grafů.

```
> layout(matrix(c(1, 0, 3, 2), 2, byrow=T), widths=c(3, 1), heights=c(1,
+ 3))
> layout.show(3)    (Obr. 8.22)
> load(file="pary.dat")    načtení datového souboru (závislost výšky 169 manželských párů, [8]). Soubor obsahuje proměnnou pary typu seznam se složkami muz, zena, muzhist a zenahist
> attach(pary)
> layout(matrix(c(1, 0, 3, 2), 2, byrow=T), widths=c(3, 1), heights=c(1,
+ 3))
> par(mar=c(0, 3.5, 1, 1))    funkce mar slouží pro nastavení okrajů grafu
> barplot(muzhist, axes=F, space=0)
> par(mar=c(3.5, 0, 1, 1))
> barplot(zenahist, axes=F, space=0, horiz=T)
> par(mar=c(4.3, 4, 1, 1))
> plot(muz, zena, xlab="muz [mm]", ylab="zena [mm]")
```

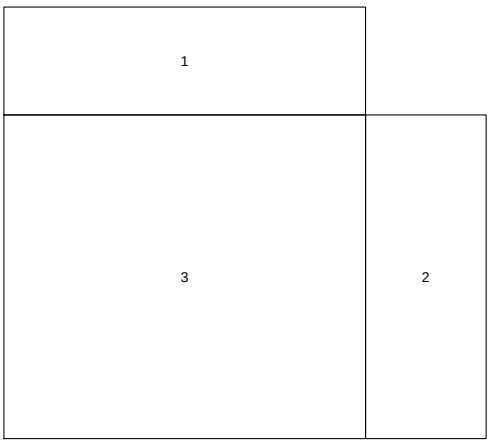

Obr. 8.22. Šablona s boxy

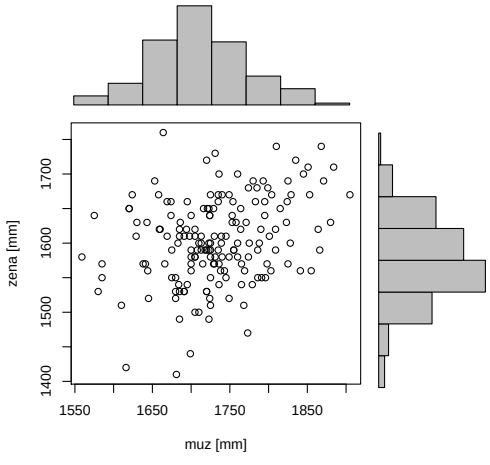

Obr. 8.23. Závislost výšky 169 manželských párů

Funkce `split.screen()` slouží k dělení grafického prostředí na libovolný počet částí. Např. příkazem `split.screen(c(2,2))` rozdělíme prostředí na čtyři části, na něž můžeme odkazovat příkazy `screen(1)`, ..., `screen(4)` a pomocí těchto příkazů dané podgrafy vytvářet nebo měnit. Každá část přitom může být znovu rozdělena pomocí funkce `split.screen(c(,), screen)`.

Poznámka. Rozdělení grafu na jednotlivé podgrafy můžeme dosáhnout i pomocí argumentů `mfcol` a `mfrow` funkce `par()` (viz odstavec 8.3).

MATLAB používá k rozdělení grafu na více částí funkci `subplot`.

```
> load(file="etnika.dat")
```
načtení datového souboru (počet souhlasných reakcí na deset otázek zástupcům čtyř etnik, [8])

```
> popisx <- rownames(etnika)
> split.screen(c(1,3))
```
vytvoří prázdné grafické okno, navíc je výstupem i vektor hodnot odkazující na jednotlivé podgrafy, šablona okna s boxy viz Obr. 8.24

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

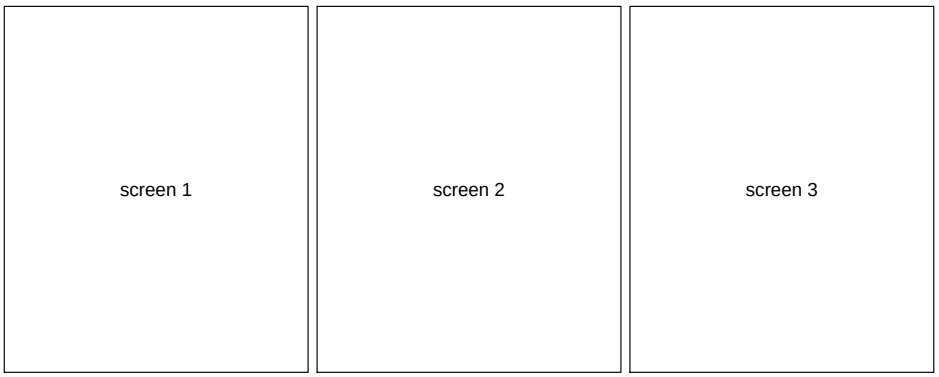

Obr. 8.24. Šablona okna s boxy pro příkaz `split.screen(c(1,3))`

```
> screen(1)
```
aktivace levého boxu pro vykreslení podgrafu

```
> barplot(etnika[,1], main="etnikum 1", names.arg=popisx, las=3)
> screen(2)
> barplot(etnika[,2], main="etnikum 2", names.arg=popisx, las=3)
> split.screen(c(2,1), screen=3)
```
rozdělení pravého boxu na 2 další boxy, aktuální šablona s boxy viz Obr. 8.25

```
[1] 4 5
```

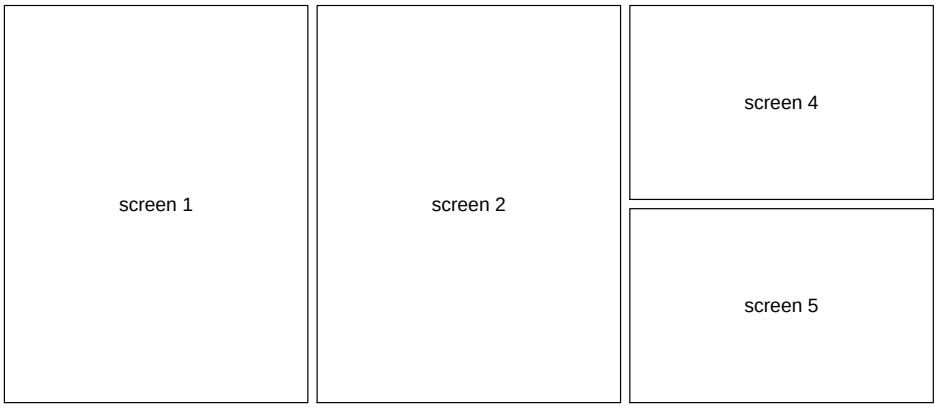

Obr. 8.25. Šablona okna s boxy pro příkaz `split.screen(c(2,1), screen=3)`

```
> screen(4)
> barplot(etnika[,3], main="etnikum 3", names.arg=popisx, las=3)
> screen(5)
> barplot(etnika[,4], main="etnikum 4", names.arg=popisx, las=3)
```

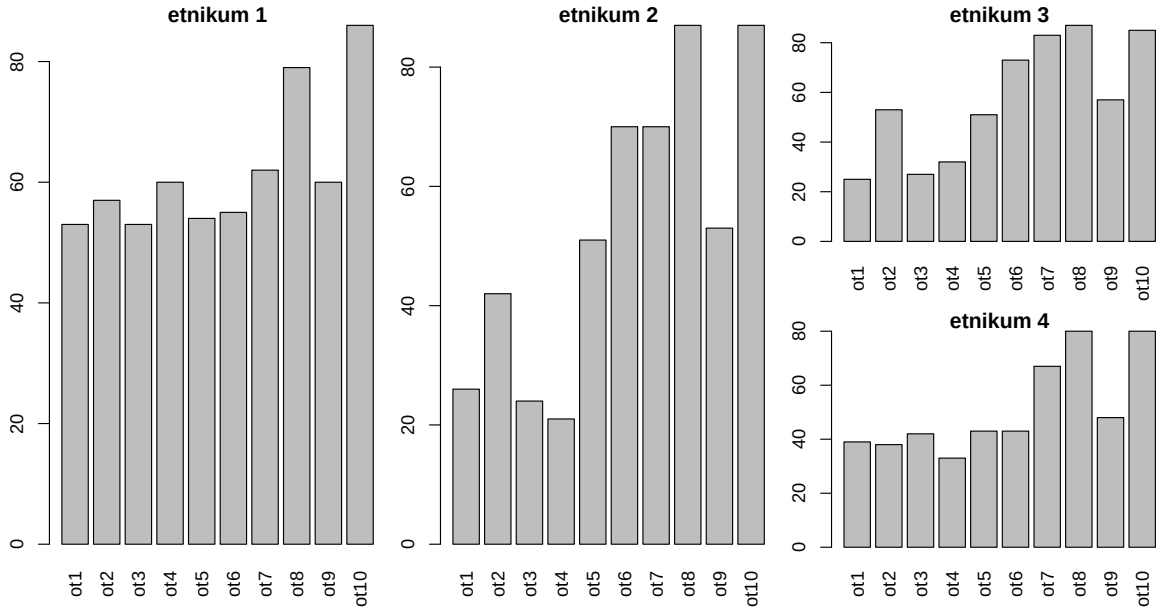

Obr. 8.26. Počet souhlasných reakcí na deset otázek zástupcům čtyř etnik.

Interaktivní funkce `locator()` umožňuje vybrat pozici pro umístění grafických prvků (např. legendy, popisků os, ...). Funkce `locator()` čeká, než uživatel zvolí levým tlačítkem myši místo, následně vypíše jeho souřadnice. Argument `n` udává počet bodů, u kterých chceme tímto způsobem zjistit souřadnice.

Kapitola 9

Programování v R

Programy v jazyce R, které si uživatel může sám vytvořit, lze rozdělit do dvou skupin - dávkové soubory a funkce. V následujících odstavcích si uvedeme hlavní rozdíly mezi nimi a způsoby, jak lze tyto programy vytvořit.

Hlavním rozdílem funkcí a dávkových souborů je ten, že objekty definované uvnitř funkce nejsou k dispozici v pracovním prostoru. U dávkových souborů nezáleží na tom, z jakého adresáře jsou volány, objekty definované uvnitř dávky jsou v pracovním prostoru stále k dispozici. Dalším rozdílem je ten, že funkce pracují se vstupními proměnnými, dávkové soubory nikoliv.

Funkce
Každá funkce v R, ať vestavěná nebo definovaná uživatelem, je tvaru
`nazev <- function(argumenty){telo}`
kde `nazev` udává název funkce, `argumenty` je čárkami oddělená posloupnost vstupních argumentů a `telo` obsahuje posloupnost příkazů, které musí být uzavřeny ve složených závorkách { } (pouze v případě jediného příkazu mohou být složené závorky vynechány).

Funkce lze vytvářet přímo v příkazové řádce, při tvorbě složitějších zdrojových kódů je vhodnější místo příkazové řádky používat editory. Jazyk R má k dispozici zabudovaný vlastní editor, který najdeme v menu *File* → *New script*. Možné je rovněž používat editory jako PSPad nebo WinEdt s číslovanými řádky, kontrolou syntaxe apod. Takto vytvořené funkce ukládáme do souboru s koncovkou `.R`.

V případě, že je funkce vytvořena přímo v příkazové řádce, spouští se zavoláním svého názvu `nazev` s argumenty uvedenými v kulatých závorkách. V případě, že je vytvořena v textovém editoru, je třeba nejdříve funkcí `source()` načíst soubor, ve kterém je uložena. Argumentem funkce `source()` je textový řetězec obsahující celý název souboru (i s koncovkou `.R`) nebo cestu k němu. Následně se spouští zavoláním názvu funkce `nazev` s argumenty uvedenými v kulatých závorkách.

Při volání funkce bez názvů argumentů musí být jednotlivé argumenty uvedeny přesně v tom pořadí, v jakém byly definovány. V opačném případě můžeme použít přiřazení `nazev_argumentu=hodnota`, popř. názvy argumentů můžeme zkracovat, jestliže zkratka nemůže znamenat žádný jiný argument. Hodnoty argumentů mohou mít definovány své implicitní hodnoty – ty lze příkazem `nazev_argumentu=implicitni_hodnota` nastavit v seznamu argumentů při definování funkce. Při volání funkce pak tyto argumenty mohou být vynechány a bude jim přidělena hodnota `implicitni_hodnota`.

Výstupní hodnoty získáme pomocí funkce `return()`, pouze k výpisu hodnot se používá funkce `print()`. V případě jediného výstupního objektu je tento objektu uváděn do argumentu funkce `return()`, v případě více výstupních objektů musí být seskupeny do seznamu.

Jazyk R rovněž umožňuje definování nových binárních operátorů (např. `%in%`). K odlišení od funkcí musí být jejich název ve tvaru `"%nazev%"`.

```
> kvadr <- function(a, b, c){
+ obsah <- 2*(a*b + b*c + c*a)
+ objem <- a*b*c
+ return(list(obsah=obsah, objem=objem))}
> vystup <- kvadr(1, 2, 3)
> vystup
$obsah
[1]  22

$objem
[1]  6
```

Dávkové soubory

Jedná se o posloupnost příkazů, která může využívat již definovaných objektů z pracovního prostoru. Zpravidla se vytváří v libovolném textovém editoru, název souboru musí mít příponu `.R` (např. `davka.R`). Dávkové soubory se spouští funkcí `source` s názvem dávkového souboru (nebo cestou k němu) uvedeným jako textový řetězec (např. `source("davka.R")`).

```
> a <- 1; b <- 2; c <- 3
> source("kvadr.R")    spuštění dávky kvadr.R
> obsah
[1]  2
> objem
[1]  6
```

Násilné ukončení běžící dávky nebo funkce se provádí příkazem `Q`.

V průběhu funkce nebo dávky se občas může stát, že se potřebujeme dostat zpět do pracovního prostoru, např. vypracování zadaných úkolů (viz cvičení) a následně dále pokračovat v běhu funkce či dávky. To lze příkazem `browser()`, k odlišení funkce či dávky a prostředí pracovního prostoru se prompt změní na `Browse[1]>`. Od této chvíle se nacházíme v pracovním prostoru, kde můžeme zadávat libovolné příkazy. Zpět se dostaneme příkazem `c` nebo klávesou ENTER.

MATLAB místo příkazu `browser()` používá `keyboard`, objevuje se prompt `K>>` a k návratu zpět do dávkového souboru používá příkaz `return`.

9.1 Lokální a globální proměnné

V jazyce R není nezbytně nutné deklarovat proměnné uvnitř funkce. Při vyhodnocování funkce R používá pravidlo *lexical scoping*, které rozhodne, zda je objekt lokální nebo globální proměnnou.

```
> funkce1 <- function(){print(x)}
> x <- 3
> funkce1()
```

Objekt `x` není definován uvnitř funkce `funkce1()`, proto R hledá v uzavřeném[1] prostředí objekt s názvem `x` a vytiskne jeho hodnotu. V případě, že by objekt `x` nebyl nalezen ani v globálním prostředí, zobrazilo by se chybové hlášení `Error in print(x) : object 'x' not found` a vyhodnocování funkce by tímto bylo u konce.

```
[1]  3
```

MATLAB by v případě, kdy objekt `x` není definován uvnitř funkce `funkce1()`, dával chybové hlášení, protože proměnná `x` je považována za lokální v prostředí, ve kterém byla definována (v tomto případě ve workspace).

```
> funkce2 <- function(){x <- 1; print(x)}
> x <- 3
> funkce2()
[1]  1
> x
```

Jestliže je `x` použito jako název objektu uvnitř funkce, hodnota `x` v globálním prostředí nebude změněna.

```
[1]  3
```

Chceme-li mít k dispozici i v globálním prostředí přiřazení provedená uvnitř funkce,

[1] To, že jde o uzavřené prostředí, je důležité. V našem příkladu jsou dvě prostředí: globální a prostředí funkce `funkce1()`. Kdyby zde byla tři a více vnořených prostředí, hledání objektu by probíhalo postupně od daného prostředí, přes jednotlivá uzavřená prostředí až ke globálnímu.

musíme použít operátoru `<<-` nebo funkce `assign` s argumentem `envir=.GlobalEnv`.

```
> funkce3 <- function(){x <- 2; print(x)}
> x    přesvědčíme se, že objekt x není definován
Error: object 'x' not found
> funkce3()
[1]  2
> x    objekt x opravdu není v globálním prostředí definován, je definován pouze v pro-
středí funkce funkce3
Error: object 'x' not found
```

Rozdíl při použití operátoru pro globální přiřazení:

```
> funkce4 <- function(){assign("x", 2, envir=.GlobalEnv); print(x)}
> x
Error: object 'x' not found
> funkce4()
[1]  2
> x
[1]  2
```

9.2 Podmíněné příkazy

Do této chvíle jsme sestavovali programy, které vyhodnocovaly pouze jednoduché příkazy nebo jejich posloupnosti uzavřené ve složených závorkách. Často ovšem potřebujeme provést sérii příkazů až na základě výsledku nějaké podmínky/nějakých podmínek.

`if (podminka) {prikaz}`
provede `prikaz` v případě, že `podminka` je vyhodnocena jako `TRUE`. V případě vyhodnocení podmínky jako `FALSE` se žádné příkazy neprovedou.

```
> x <- 5
> if (x > 3) {"Podminka splnena."}
[1]  "Podminka splnena."
```

`if (podminka) {prikaz1}`
`else {prikaz2}`
V případě vyhodnocení podmínky `podminka` jako `TRUE` je proveden `prikaz1`, v opačném případě je proveden `prikaz2`.

```
> if (x > 3) {"Podminka splnena."}
+ else {"Podminka nesplnena."}
[1]  "Podminka splnena."
```

Podmínka vrací buď hodnotu `TRUE` nebo `FALSE`. Jestliže podmínka vrací logický vektor o více než jednom prvku, jako výsledek vyhodnocení podmínky je ovšem brán pouze jeho první prvek. Součástí výstupu je i hlášení:

```
> x <- c(-2, 0, 3, 1)
> if (x > 0) {"vetsi nez 0"}
+ else {"mensi nebo rovno 0"}
[1]  "mensi nebo rovno 0"
 Warning message:
In if (x > 0) { :
the condition has length > 1 and only the first element will be used
```

MATLAB by v tomto případě vyhodnotil podmínku vracející vektor o hodnotách `TRUE` jako `TRUE`, v případě jediné hodnoty `FALSE` jako `FALSE`.

Alternativou k příkazu `if - else` může být příkaz
`ifelse(podminka, prikaz1, prikaz2)`,
která v případě podmínky vyhodnocené jako `TRUE` provede příkaz `prikaz1`, v opačném případě provede `prikaz2`.

```
> ifelse(x > 3, "Podminka splnena.", "Podminka nesplnena.")
[1]  "Podminka splnena."
```

```
if (podminka1) {prikaz1}
else if (podminka2) {prikaz2}
else if (podminka3) {prikaz3}
else {prikaz4}
```

Vysvětlení těchto podmíněných příkazů je zachyceno na Obr. 9.1.

```
> x <- 3
> if (x == 1) {"cervena - stat!"}
+ else if (x == 2) {"oranzova - pripravit se"}
+ else if (x == 3) {"zelena - muzeme jet"}
+ else {"zadna jina barva na semaforu neexistuje"}
[1]  "zelena - muzeme jet"
```

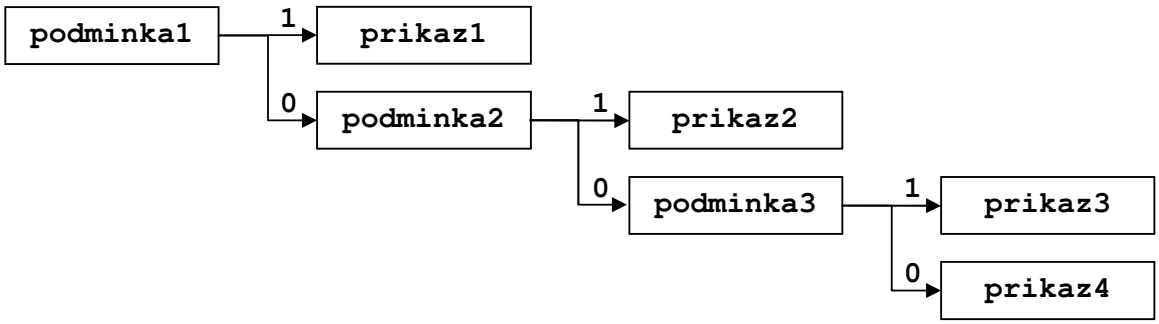

Obr. 9.1. Diagram vysvětlující příkaz `if - else if - else`

Příkaz
`switch(vyraz, prikazy, prikazy_jine)`
slouží také k větvení programu. Jestliže `vyraz` je celé číslo, na výstupu je vrácena hodnota odpovídajícího prvku `prikazy`. Pokud nedojde ke spojení hodnoty `vyraz` s prvkem `prikazy`, funkce vrací hodnotu `NULL`.
Pro textový řetězec musí být název `vyraz` použit ke spojení s příslušným prvkem posloupnosti `prikazy`. Pokud nedojde ke spojení s některým z prvků posloupnosti `prikazy`, můžeme definovat `prikazy_jine`, které budou v tomto případě provedeny. `prikazy_jine` můžeme definovat pouze pro `vyraz` typu textový řetězec.
Syntaxe příkazu bude názornější z následujících příkladů:

```
> switch(2, "vyborne", "velmi dobre", "dobre", "uspokojive",
+ "dostatecne", "nedostatecne")
[1]  "velmi dobre"
> switch(7, "vyborne", "velmi dobre", "dobre", "uspokojive",
+ "dostatecne", "nedostatecne")
[1]  NULL
> switch("vyborne", vyborne="znamka A", velmi_dobre="znamka
+ B", dobre="znamka C", uspokojive="znamka D", dostatecne="znamka E",
+ neuspokojive="znamka F", "znamka neexistuje")
[1]  "znamka A"
> switch("chvalitebne", vyborne="znamka A",
+ velmi_dobre="znamka B", dobre="znamka C", uspokojive="znamka D",
+ dostatecne="znamka E", neuspokojive="znamka F", "znamka neexistuje")
[1]  "znamka neexistuje"
```

9.3 Příkazy cyklů

Někdy potřebujeme opakovaně vyhodnocovat příkaz nebo skupinu příkazů. Je třeba si dát pozor na správnou definici konce cyklu, v opačném případě může dojít k zacyklení. Mezi nejznámější příkazy cyklů patří funkce `for`, `while` a `repeat`.

`for (promenna in vyraz) {prikaz}`
Provede sérii příkazů `prikaz`, `promenna` označuje indexační proměnnou, `vyraz` může být vektor nebo seznam, pro jehož každou složku je `prikaz` vyhodnocen. Cyklus `for` je vhodné používat tehdy, když předem víme, kolik opakování chceme provést.

```
> for (i in 1:5) {cat("pruchod cyklem", i, "\n")}
```
[2] funkce `cat()` zřetězí a vytiskne své argumenty

```
pruchod cyklem 1
pruchod cyklem 2
pruchod cyklem 3
pruchod cyklem 4
pruchod cyklem 5
```

Někdy ovšem předem nevíme, kolikrát bude třeba cyklus opakovat, a počet opakování závisí na splnění určité podmínky. V těchto případech použijeme cyklus `while`:
`while (podminka) {prikaz}`
Stejně jako u výrazu `if`, `podminka` je výraz, který po vyhodnocení vrací logickou hodnotu `TRUE` nebo `FALSE`. V případě splnění podmínky `podminka` cyklus provede `prikaz`.

```
> i <- 1
> while (i %in% c(1:5)) {print(i); i <- i + 1}
[1]  1
[1]  2
[1]  3
[1]  4
[1]  5
```

Cyklus `repeat` opakuje vyhodnocování příkazů `prikaz` do té doby, dokud nedosáhne konce. Pro ukončení se používá příkaz `break`, který je součástí posloupnosti příkazů `prikaz`. Syntaxe vypadá následovně:
`repeat {prikaz}`

Poznámka. Příkaz `break` lze použít i pro ukončení cyklů `for` a `while`.

[2] výraz `"\n"` způsobí přechod na nový řádek

```
> i <- 0
> repeat{
+ print(i)
+ i <- i + 1
+ if (i == 5) {break}}
[1]  0
[1]  1
[1]  2
[1]  3
[1]  4
```

9.4 Skupiny funkcí `apply()`

Do této skupiny patří funkce `apply()`, `lapply()`, `sapply()` a `tapply()`. Společnou vlastností všech těchto funkcí je schopnost aplikovat funkci na vybrané části struktury bez použití cyklu, což má výhody v přehlednosti i rychlosti výpočtu.

Funkce `apply()` se používá pro vektory, matice a pole. Funkce požaduje tři argumenty: název pole a jeho dimenze, na kterých má být provedena požadovaná operace. Její název je třetím argumentem funkce. Jestliže u matic druhý argument nabývá hodnoty 1, operace se provádí po řádcích, v případě hodnoty 2 po sloupcích, u polí vyšší hodnoty odkazují na další dimenze.

```
> ar <- array(1:8, c(2,2,2))
, , 1

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

, , 2

     [,1] [,2]
[1,]    5    7
[2,]    6    8
> apply(ar, 1, sum)
[1] 16 20
> apply(ar, 2, sum)
[1] 14 22
> apply(ar, 3, sum)
[1] 10 26
```

Obě funkce `lapply()` i `sapply()` provádí výpočet určité funkce v jednotlivých složkách seznamu jako prvního argumentu. Druhým argumentem je název funkce, která má být provedena. Tyto příkazy se liší pouze výstupem - zatímco `lapply()` vrací seznam o stejném počtu složek jako vstupní seznam, funkce `sapply()` se snaží výsledek zjednodušit do vektoru nebo matice.

```
> (l <- list(1:5, 5:14))
[[1]]
[1]  1   2   3   4   5

[[2]]
[1]  5   6   7   8   9   10   11   12   13   14
> lapply(l, range)
[[1]]
[1]  1   5

[[2]]
[1]  5   14
> sapply(l, range)
      [,1]  [,2]
 [1,]    1     5
 [2,]    5    14
```

Funkce `tapply()` aplikuje požadovanou funkci na roztříděná data v tabulce dat. Argument `INDEX` specifikuje seznam položek pro roztřídění.

```
> (tabulka <- data.frame(id=c(1:6), skupina=c(1, 2, 2, 1, 2, 1),
+ hodnota=runif(6, 2, 4)))
   id  skupina   hodnota
1   1        1  3.238305
2   2        2  2.502754
3   3        2  3.939131
4   4        1  3.524773
5   5        2  3.731300
6   6        1  3.836787
> tapply(tabulka$hodnota, INDEX=tabulka$skupina, mean)
        1         2
3.533288  3.391061
```

Kapitola 10

Základy statistického zpracování dat

Jazyk R je programovací jazyk zaměřený především na statistickou analýzu dat a jejich grafické zobrazení. Poskytuje kompletní sadu statistických tabulek a řadu funkcí pro statistické zpracování dat.

Některé základní funkce jsou uvedeny v odstavci 6.4. V této kapitole si uvedeme pouze základní příkazy z této oblasti.

10.1 Pravděpodobnostní rozložení

Práce s rozloženími pravděpodobností se realizuje pomocí čtveřice funkcí. Jednotlivé funkce jsou schopny vyhodnotit distribuční funkci ($P(X < x)$), hustotu pravděpodobnosti, kvantilovou funkci ($P(X \leq x) > q$). K dispozici jsou rovněž generátory náhodných čísel jednotlivých rozložení. Následující tabulka zobrazuje přehled nejčastěji používaných rozložení a jejich odpovídající výše zmiňované funkce.

rozložení	hustota pravděpodobnosti	distribuční funkce	kvantilová funkce	generátor náhodných čísel
beta	`dbeta`	`pbeta`	`qbeta`	`rbeta`
binomické	`dbinom`	`pbinom`	`qbinom`	`rbinom`
chi-kvadrát	`dchisq`	`pchisq`	`qchisq`	`rchisq`
exponenciální	`dexp`	`pexp`	`qexp`	`rexp`
F-rozdělení	`df`	`pf`	`qf`	`rf`
gamma	`dgamma`	`pgamma`	`qgamma`	`rgamma`

Pokračování na další straně

rozložení	hustota pravděpodobnosti	distribuční funkce	kvantilová funkce	generátor náhodných čísel
geometrické	`dgeom`	`pgeom`	`qgeom`	`rgeom`
hypergeometrické	`dhyper`	`phyper`	`qhyper`	`rhyper`
lognormální	`dlnorm`	`plnorm`	`qlnorm`	`rlnorm`
negativně binomické	`dnbinom`	`pnbinom`	`qnbinom`	`rnbinom`
normální	`dnorm`	`pnorm`	`qnorm`	`rnorm`
Poissonovo	`dpois`	`ppois`	`qpois`	`rpois`
Studentovo	`dt`	`pt`	`qt`	`rt`
rovnoměrně spojité	`dunif`	`punif`	`qunif`	`runif`
Weibullovo	`dweibull`	`pweibull`	`qweibull`	`rweibull`

Tab. 10.1. Tabulka pravděpodobnostních rozložení

10.2 Testy statistických hypotéz

Častým předpokladem pro testování hypotéz je předpoklad o **normalitě rozložení**:

`shapiro.test(x)` provede Shapirův-Wilkův test normality. Argument `x` udává vstupní vektor. Testujeme nulovou hypotézu H_0: Zkoumaná data pochází ze základního souboru s normálním rozložením. Výstupem je hodnota testové statistiky `H` a p-hodnota `p-value`.

`ks.test(x, y)` provede Kolmogorovův-Smirnovův test shody rozložení. Argument `x` je numerický vektor, argument `y` je textový řetězec udávající název příkazu pro distribuční funkci testovaného rozložení (pro normální rozložení `y="pnorm"`). Testujeme nulovou hypotézu H_0: Zkoumaná data odpovídají danému teoretickému rozložení. Pro numerický vektor y funkce provede dvouvýběrový test s nulovou hypotézou, že `x` a `y` pochází ze stejného spojitého rozložení. Výstupem je hodnota testové statistiky `D` a p-hodnota `p-value`.

```
> load(file="obsah.leciva.dat")
```
načtení souboru s daty – obsah [mg/l] léčiva v krvi náhodně vybraných pacientů, [8]

```
> shapiro.test(obsah.leciva)

        Shapiro-Wilk normality test

data: obsah.leciva
W = 0.9832, p-value = 0.6937
```

```
> load(file="len.dat")
```
načtení souboru s daty – porovnání hmotnosti stonku lnu [kg] ze dvou pozemků, [8]

```
> ks.test(x=len[,1], y=len[,2])

        Two-sample Kolmogorov-Smirnov test

data: len[, 1] and len[, 2]
D = 0.25, p-value = 0.5596
alternative hypothesis: two-sided

Warning message:
In ks.test(x = len[, 1], y = len[, 2]) :
cannot compute correct p-values with ties
```

Poznámka. Funkce `ks.test` pro soubory malých rozsahů navíc vrací i varovné hlášení. Více viz `help(ks.test)`.

Pro testování **homogenity rozptylů** je zabudována funkce `var.test(x, y, ratio=1, alternative, conf.level)`. Argumenty `x` a `y` udávají vstupní vektory pro porovnání vzájemné variability, `ratio` (implicitní nastavení `ratio=1`) stanovuje poměr variabilit daných pozorování. Předpokladem je normalita obou zkoumaných souborů, testujeme nulovou hypotézu H_0: Poměr variabilit zkoumaných souborů je v poměru `ratio`. Argument `alternative` udává typ alternativy (`"two.sided"` pro oboustrannou alternativu, `"less"` pro pravostrannou a `"greater"` pro levostrannou alternativu). Argument `conf.level` udává spolehlivost testu. Výstupem je hodnota testového kritéria `F`, počet stupňů volnosti čitatele `num df` a jmenovatele `denom df`, p-hodnota `p-value`, konfidenční interval spolehlivosti a vypočtený poměr `ratio of variances`.

```
> var.test(x=len[,1], y=len[,2])

        F test to compare two variances

data: len[, 1] and len[, 2]
F = 0.9896, num df = 19, denom df = 19, p-value = 0.982
alternative hypothesis: true ratio of variances is not equal to 1
95 percent confidence interval:
  0.3916888 2.5001319
sample estimates:
ratio of variances
         0.9895826
```

K **testování hypotézy o středních hodnotách** použijeme:
`t.test(x, y, alternative, mu, var.equal, conf.level)` Argumenty `x` a `y` jsou vstupní vektory pro porovnání středních hodnot (v případě jednoho výběru je implicitní nastavení `y=NULL`), `mu` je numerická hodnota uvádějící testovanou střední hodnotu, popř. jejich rozdíl u dvou výběrů. Důležitým argumentem je `var.equal`, který uvádí, zda se jedná o test výběrů s rovnými (`TRUE`) nebo různými (`FALSE`) rozptyly.

Výstupem je hodnota testového kritéria `t`, počet stupňů volnosti `df`, p-hodnota `p-value`, interval spolehlivosti a odhad střední hodnoty/středních hodnot.

```
> t.test(x=len[,1], y=len[,2], var.equal=TRUE)

        Two Sample t-test

data: len[, 1] and len[, 2]
t = 0.8607, df = 38, p-value = 0.3948
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
  -2.899901 7.189901
sample estimates:
mean of x mean of y
   48.115     45.970
```

Jednofaktorová ANOVA (analýza rozptylu) se zabývá posouzením vlivu jednoho faktoru na sledovanou proměnnou nebo porovnáním výsledků z různých zdrojů. Testujeme nulovou hypotézu H_0: Střední hodnoty jednotlivých výběrů jsou shodné proti alternativě H_1: Alespoň jedna dvojice středních hodnot se liší:
`anova(object)` Argument `object` je objekt obsahující výsledky regresního modelu (např. `lm` nebo `glm`).
Nejjednodušším regresním modelem je lineální model: `lm(formula)`,
kde `formula` je objekt typu 'formula': tyto objekty mohou být pomocí operátoru $\sim$ využívány pro uchování symbolického předpisu vztahu mezi několika proměnnými. Výraz `y` $\sim$ `x` vyjadřuje závislost proměnné `y` (vysvětlovaná, závisle proměnná) na proměnné `x` (vysvětlující, nezávisle proměnná).

Výstupem je ANOVA tabulka obsahující počet stupňů volnosti `Df`, součet čtverců `Sum Sq`, průměrné čtverce `Mean Sq`, hodnotu testové statistiky `F value` a p-hodnotu `Pr(>F)`. V případě zamítnutí nulové hypotézy je třeba provést vícenásobná porovnání, abychom zjistili, mezi kterými úrovněmi faktoru nabývají střední hodnoty zkoumané veličiny statisticky významných rozdílů.
Tukeyova metoda: `TukeyHSD(aov(formula))`, kde `aov(formula)` provede analýzu rozptylu. Výstupem Tukeyovy metody je tabulka poskytující informace o porovnání

úrovní faktoru: rozdíl středních hodnot `diff`, dolní a horní mez intervalu spolehlivosti `lwr`, `upr` a p-hodnotu `p adj`.

```
> load(file="krev.dat")
```
načtení datového souboru – závislost obsahu celkového cholesterolu v krvi [mg/100 ml] na denní spotřebě tuku [g], [8]

```
> anova(lm(krev[,2]   krev[,1]))
Analysis of Variance Table

Response: krev[, 2]
          Df Sum Sq Mean Sq F value    Pr(>F)
krev[, 1]  1  56368   56368  64.498 2.319e-07 ***
Residuals 18  15731     874
---
Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1
```

10.3 Grafická zobrazení

Grafický výstup ke statistice neodmyslitelně patří. V Kapitole 8 jsme se již seznámili s mnoha typy grafů, které jsou často využívány ve statistice (`barplot, hist, pie, boxplot, stripchart, qqnorm, qqline`). Zde si stručně ukážeme další typy grafů:

• `pairs()` matice xy grafů v jednom okně, na vstup matice, faktor, nebo tabulka dat. Graf se často využívá při základní analýze závislosti proměnných

```
> load(file="petrzel.R")
```
načtení datového souboru – závislosti faktorů ovlivňující výnosnost petržele, [8]

`panel=panel.smooth` přidá vyhlazovací křivku

```
> pairs(petrzel, panel=panel.smooth)
> title('pairs()')
```

• `dotchart()` vykreslí bodový graf dat, osa y zobrazuje indexy dat, osa x zobrazuje jejich hodnoty, na vstup vektor nebo matice

`labels` popisky k ose y

• `sunflowerplot()` slunečnicový graf, jedná se o bodový graf, ve kterém se počet překrývajících bodů zobrazuje "okvětními lístky"

`number` počet opakování v daném bodě

`digits` počet desetinných míst, na než je možné považovat shodu v případě blízkosti bodů

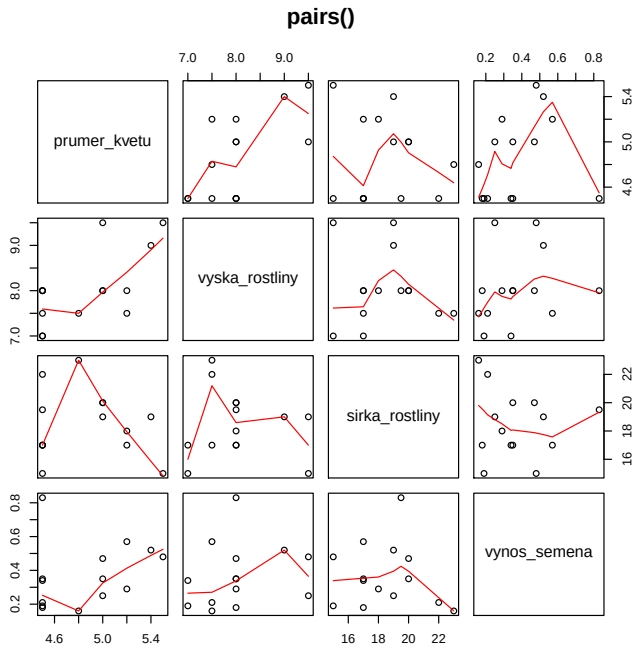

Obr. 10.1. Funkce `pairs()`

`rotate` `rotate=TRUE` náhodně rotuje okvětní lístky, aby se zabránilo překryvům
`size, seg.col, seg.lwd` délka, barva a tloušťka "okvětních lístků"

- `spineplot()` speciální sloupcový graf pro 2-rozměrná data
- `mosaicplot()` mozaikový graf, používá se pro zobrazení vztahů v kontingenčních tabulkách

```
> popis <- rep(NA, times=100)
```
příprava na popis osy y

```
> popis[c(1, seq(from=10, by=10, to=100))] <- c(1871, seq(from=1880,
+ by=10, to=1970))
> dotchart(Nile, main="dotchart()", labels=popis, xlab="Rocni prutok
+ reky Nil", ylab="Rok")
```
bodový graf ročních průtoků řeky Nil (vestavěná proměnná)

```
> load(file="vino.dat")
```
načtení datového souboru (obsah alkoholu jednotlivých vzorků vína tří kategorií, [8])

```
> sunflowerplot(vino, digits=2, axes=F, frame.plot=T, xlab="druh vina",
+ ylab="obsah alkoholu", main="sunflowerplot()", xlim=c(0, 4),
+ ylim=c(10.5, 14.5), seg.col=1)
> axis(1, las=1, at=c(1,2,3), labels=c(LETTERS[1:3]))
```
nastavení popisů os

```
> axis(2, las=1, at=c(11:14), labels=c(11:14))
> load(file="osoby.dat")
```
načtení datového souboru (zastoupení mužů a žen na dvou lokalitách, [8])
```
> spineplot(osoby, xlab = "lokalita", ylab="procentualni zastoupeni",
+ main="spineplot()")
> load(file="reklama.dat")
```
načtení datového souboru (vliv reklamy a dne v týdnu na počet kusů prodaného zboží, [8])
```
> mosaicplot(reklama, xlab="den v tydnu", ylab="druh reklamy",
+ main="mosaicplot()")
```

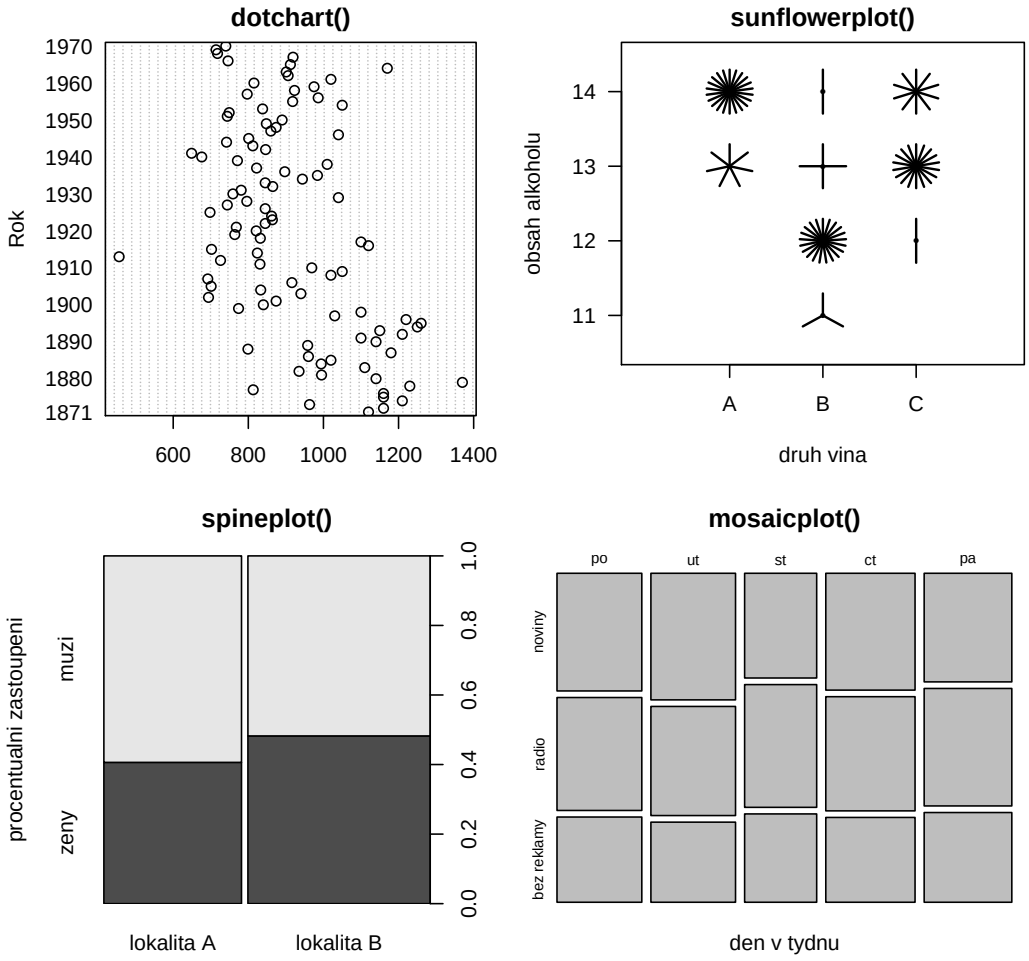

Obr. 10.2. Funkce `dotchart()`, `sunflowerplot()`, `spineplot()` a `mosaicplot()`

Mezi další používané grafy patří např. `assocplot()`, `fourfoldplot()`, `stars()`, `coplot()`, `cdplot()`, `matplot()` ....

Seznam použité literatury

[1] BÍNA, V., KOMÁREK, A., KOMÁRKOVÁ, L. *Jak na jazyk R: instalace a základní příkazy.* [online] 2006. 18 s. [cit. květen 2010]. Dostupné z WWW: <http://www.karlin.mff.cuni.cz/~komarek/Rko/Rmanual2.pdf>

[2] CRAWLEY, M. J. *Statistics: An Introduction Using R, Vectors And Logical Arithmetic.* [online] 30 s. [cit. květen 2010]. Dostupné z WWW: <http://osiris.sunderland.ac.uk/~cs0her/Statistics/Crawley/R2Calculations.pdf>

[3] DROZD, P. *Cvičení z biostatistiky: Základy práce se softwarem R.* [online] Ostrava: 2007. 111 s. ISBN 978-80-7368-433-4. [cit. květen 2010]. Dostupné z WWW: <http://cran.r-project.org/doc/contrib/CviceniR1.pdf>

[4] GUNDERSEN, V. B. *R for MATLAB Users* [online]. 2007 [cit. květen 2010]. Dostupné z WWW: <http://mathesaurus.sourceforge.net/octave-r.html>

[5] HIEBELER, D. *MATLAB/R Reference.* [online] 52 s. [cit. květen 2010]. Dostupné z WWW: <http://www.math.umaine.edu/~hiebeler/comp/matlabR.pdf>

[6] KLEIBER, Christian, ZEILEIS, Achim. *Applied Econometrics with R.* New York: Springer 2008. 221 s. ISBN 978-0-387-77316-2

[7] KOLÁČEK, Jan, ZELINKA, Jiří. *Jak pracovat s MATLABem.* [online] 40 s. [cit. květen 2010]. Dostupné z WWW: <http://www.math.muni.cz/~kolacek/vyuka/vypsyst/navod.pdf>

[8] MELOUN, Milan, MILITKÝ, Jiří. *Kompendium statistického zpracování dat: Metody a řešené úlohy včetně CD.* 1. vydání. Praha: Academia, 2002. 764 s. ISBN 80-200-1008-4

[9] PARADIS, Emmanuel. *R for Beginners.* [online] 2002. 58 s. [cit. květen 2010]. Dostupné z WWW: <http://www.karlin.mff.cuni.cz/~kulich/vyuka/Rdoc/rdebuts_en.pdf>

[10] R Developement Core Team. *Writing R Extensions*. [online] 2009. 155 s. ISBN 3-900051-11-9 [cit. květen 2010]. Dostupné z WWW: <http://cran.r-project.org/doc/manuals/R-exts.pdf>

[11] SCOTT, Theresa A. *An Introduction to R*. [online]. 2004. 52 s. [cit. květen 2010]. Dostupné z WWW: <http://www.karlin.mff.cuni.cz/~kulich/vyuka/Rdoc/RLectureTScott.pdf>

[12] SCOTT, Theresa A. *An Introduction To The Fundamentals & Functionality Of The R Programming Language: Part I: An Overview*. [online] 69 s. [cit. květen 2010]. Dostupné z WWW: <http://biostat.mc.vanderbilt.edu/wiki/pub/Main/TheresaScott/Scott.IntroToR.I.pdf>

[13] SCOTT, Theresa A. *An Introduction To The Fundamentals & Functionality Of The R Programming Language: Part II: The Nuts and Bolts*. [online] 101 s. [cit. květen 2010]. Dostupné z WWW: <http://biostat.mc.vanderbilt.edu/wiki/pub/Main/TheresaScott/Scott.IntroToR.II.pdf>

[14] SCOTT, Theresa A. *An Introduction To The Fundamentals & Functionality Of The R Programming Language: Section I: Some Language Essentials*. [online] 44 s. [cit. květen 2010]. Dostupné z WWW: <http://www.webpages.uidaho.edu/~brian/R_Scott_intro.pdf>

[15] SPECTOR, Phil. *Data Manipulation with R*. New York: Springer, 2008. 147 s. ISBN 978-0-387-74730-9

[16] VAVRČÍK, H. *Statistická analýza dat v aplikaci R*. [online][cit. květen 2010]. Dostupné z WWW: <http://wood.mendelu.cz/cz/sections/FEM/?q=book/export/html/49>

[17] VENABLES, W. K., SMITH, D. M. and the R Development Core Team. *An Introduction to R.*[online] 100 s. ISBN 3-900051-12-7. [cit. květen 2010]. Dostupné z WWW: <http://cran.r-project.org/doc/manuals/R-intro.pdf>

[18] VENABLES, W. N., RIPLEY, B. D. *Modern Applied Statistics with S-Plus*. 2. upravené vydání. New York: Springer-Verlag, 1994. 462 s. ISBN 0-384-94350-1

[19] *The R Project for Statistical Computing.* [online][cit. květen 2010]. Dostupné z WWW: <http://r-project.org/>

---

[20] RYBIČKA, Jiří. *LaTeX pro začátečníky*. 3. vydání. Brno: Konvoj, 2003. 238 s. ISBN 80-7302-049-1

[21] SYSEL, Petr, RAJMIC, Pavel. [online][cit. květen 2010]. Dostupné z WWW: <http://latex.feec.vutbr.cz/cz/latex/diskuze/>

[22] The University Of Tennessee. [online][cit. květen 2010]. Dostupné z WWW: <http://www.utm.edu/departments/cens/engineering/Images/matlab_logo_000.gif>