

Poslední úprava dokumentu: 28. února 2024.

Popisná statistika pro jednu proměnnou

Rozcvička



Vytvořte si libovolný vektor o pěti hodnotách a spočítejte průměr a směrodatnou odchylku.

1 Úvod

- 1) Spust'te **RStudio** z nabídky.
- 2) Nastavte si pracovní adresář.

✧ Bud' v Menu nahoře:

Session ➔ **Set Working Directory** ➔ **Choose Directory ...**

a vyberte složku **biostat**, kterou jste si vytvořili minule.

✧ Nebo příkazem:

```
setwd("popis_cesty/biostat")
```

- 3) Otevřete si nový skriptový soubor

✧ Bud' v Menu nahoře:

File ➔ **New File** ➔ **R Script**

✧ nebo kliknutím na ikonku papíru se zeleným plus vlevo nahoře a zvolením **R Script**,

✧ nebo klávesovou zkratkou **Ctrl+Shift+N**.

Nebo použijte skript z minula:

✧ V Menu nahoře:

File ➔ **Open File**

a vyberte příslušný soubor.

- 4) Pokud jste se rozhodli pro vytvoření nového skriptového souboru, nezapomeňte si ho uložit:

✧ **File** ➔ **Save as...**

✧ nebo kliknutím na symbol diskety,

✧ nebo klávesovou zkratkou **Ctrl+S**.

- 5) Nemáte-li z minula uložen datový soubor **Deti23** v **R** formátu (soubor **Deti23.RData**), vytvořte si ho dle návodu v předchozím pracovním listu "Seznámení s R". Máte-li data již načtena, můžete tento i další krok přeskočit a přejít rovnou k bodu 7).

6) Načtěte data `Deti23` do RStudio:

✧ Bud' v Menu nahoře:

File ➔ **Open file...**

a potvrdit soubor `Deti23.RData` ze složky `biostat\data`.

Do you want to load the R data file into the global environment?

Yes

✧ Nebo příkazem:

```
load("data/Deti23.RData")
```

7) Prohlédněte si data a ujistěte se, že jsou správně načtena. Data si můžete zobrazit buď poklepaním na jejich název v pravém horním okně, nebo příkazem

```
View(Deti23)
```

8) Zajistěte si přímý přístup k jednotlivým proměnným datového souboru `Deti23`. Ze skriptového okna spusťte příkaz:

```
attach(Deti23)
```

2 Jedna kvantitativní proměnná

2.1 Numerické hodnoty popisných statistik



- 1) Připomeňte si z přednášky pojmy: průměr, směrodatná odchylka, medián, dolní a horní kvartil, kvantily. Uměli byste je pro konkrétní data vypočítat ručně pomocí kalkulačky?
- 2) Spočtete výše uvedené popisné statistiky pro věk matek.

```
summary(vekMatky)           # prumer a nektere "dulezite" kvantily

mean(vekMatky)              # vyberovy prumer
sd(vekMatky)                # vyberova smerodatna odchylka
var(vekMatky)               # vyberovy rozptyl
median(vekMatky)            # median
min(vekMatky)               # minimum
max(vekMatky)               # maximum
quantile(vekMatky, prob=c(0, 0.25, 0.50, 0.75, 1.00))
                             # vybrane kvantily
length(vekMatky)            # delka vektoru (pocet pozorovani)
```

3) Zkusme zcela ručně (dle „vzorečku“ z přednášky) spočítat medián pro věk otce.

✧ Bude potřeba seřadit pozorované věky otců. Toho lze docílit příkazem:

```
sort(vekOtce)
```

✧ Zde máme 23 pozorování. Kolikáté pozorování v seřazené posloupnosti věků je tedy mediánem?

✧ Jak by se určil medián, kdybychom měli sudý počet pozorování?



4) Základní popisné statistiky pro všechny proměnné datového souboru lze získat následujícím příkazem:

`summary(Deti23)`

✧ Povšimněte si jiného tvaru výstupu u proměnné `Pohlavi`. Jedná se o kvalitativní proměnnou, kterými se budeme zabývat v některém z příštích cvičení.

✧ Doporučuji po každém načtení dat spočítat vždy tyto statistiky a alespoň rychlým pohledem si je prohlédnout. Odhalíte tak hrubé chyby vzniklé při přepisu dat, nebo případné problémy s načtením dat.

2.2 Grafické znázornění popisných statistik

- 1) Mnohé popisné statistiky kvantitativní proměnné lze přehledně znázornit pomocí krabičkového grafu. Nakresleme krabičkový graf pro věk matky.

`boxplot(vekMatky)`

Příkaz lze modifikovat a zkrášlovat obrázek.

`boxplot(vekMatky, ylab="Vek matky", col="steelblue")`

`boxplot(vekMatky, xlab="Vek matky", col="sandybrown", horizontal=TRUE)`



- 2) Samostatně nakreslete krabičkový graf pro věk otce. V grafu se objeví jedno odlehlé pozorování



- 3) Samostatně spočtete popisné statistiky pro váhu a délku dítěte.



- 4) Samostatně nakreslete krabičkové grafy pro váhu a délku dítěte.

- 5) Připomeňme, že

`dobaPlnolet = vekMatky - 18`

`delka.m = delka/100`

✧ **Vliv posunutí:** Jaký je vztah mezi popisnými statistikami pro proměnné `vekMatky` a `dobaPlnolet`?

✧ **Vliv změny měřítka:** Jaký je vztah mezi popisnými statistikami pro proměnné `delka` a `delka.m`?

3 Jedna kvalitativní proměnná

3.1 Tabulka absolutních a relativních četností

- 1) Spočítejte základní popisné statistiky pro proměnnou `hcd` (počet onemocnění horních cest dýchacích během prvního roku života).

`summary(Deti23$hcd)`

- 2) Veličina `hcd` je sice kvantitativní, ale nabývá pouze celočíselných hodnot 0–9. Podívejme se, kolikrát se která hodnota vyskytuje. Ze skriptového okna spusťte příkaz

`table(Deti23$hcd)`

3.2 Tvorba factorů

- 3) Z pohledu R je veličina `hcd` kvantitativní/číselná (těm se v R říká `numeric` nebo `integer`). Zkuste

```
class(Deti23$hcd)
```

Někdy se ale může hodit z ní udělat veličinu kategoriální (těm se v R říká `factor`), jejíž kategorie budou dány počtem onemocnění.

✧ Bud'

```
Deti23 <- transform(Deti23, fhcd = factor(hcd))
```

✧ nebo

```
Deti23$fhcd <- as.factor(Deti23$hcd)
```

✧ Že se skutečně jedná o factorovou proměnnou si můžete ověřit pomocí:

```
class(Deti23$fhcd)
```

- 4) Řekněme, že nás ale takto jemné dělení nemocnosti nezajímá a stačí nám rozlišovat děti pouze na *nikdy* nemocné (`hcd = 0`), *jednou* nemocné (`hcd = 1`) a *opakovaně* nemocné (`hcd > 1`). Jinými slovy, chceme z proměnné `hcd` vytvořit kvalitativní proměnnou o třech úrovních *nikdy/jednou/opakovaně*.

✧ Vytvořme nyní proměnnou `fhcd3`, jež bude `factorem` vytvořeným z `hcd` výše popsaným způsobem.

```
pom.hcd3 <- 0*(Deti23$hcd == 0) + 1*(Deti23$hcd == 1) + 2*(Deti23$hcd > 1)
Deti23 <- transform(Deti23, fhcd3 = factor(pom.hcd3,
labels=c("nikdy", "jednou", "opakovane")))
```

- 5) Spočtěme nyní absolutní a relativní četnosti jednotlivých úrovní `fhcd3`.

```
table(Deti23$fhcd3)
prop.table(table(Deti23$fhcd3))
round(prop.table(table(Deti23$fhcd3)) * 100, 2)
```

3.3 Grafické zobrazení absolutních a relativních četností

- 1) Zobrazme absolutní četnosti pomocí sloupcového grafu.

```
barplot(table(Deti23$fhcd3), xlab="Nemocnost", ylab="Cetnost",
col=terrain.colors(3))
```

- 2) Zobrazme relativní četnosti pomocí sloupcového grafu.

```
barplot(prop.table(table(Deti23$fhcd3)),
xlab="Nemocnost", ylab="Relativni cetnost", col=topo.colors(3))
```

- 3) Zobrazme relativní četnosti pomocí koláčového grafu.

```
pie(table(Deti23$fhcd3), main="Nemocnost", col=heat.colors(3))
```

4 Samostatná práce



1) Vytvořte novou proměnnou nazvanou `fporadi2`, jež bude odlišovat prvorozence od ostatních dětí. Jednotlivé kategorie si vhodně označte.



2) Spočítejte absolutní a relativní četnosti prvorozenců a dětí, jež mají sourozence.



3) Graficky znázorněte absolutní a relativní četnosti prvorozenců a dětí, jež mají sourozence.

5 Konec práce

Rozšířený datový soubor `Deti23` (s novými proměnnými `fhcd3` a `fporadi2`) uložte na síťovém disku ve svém adresáři v R formátu jako soubor `Deti23.RData` (tj. přepište dřívější `Deti23.RData` novou verzí) do podsložky `data`.

```
save(Deti23, file = "data/Deti23.RData")
```