

Poslední úprava dokumentu: 11. března 2025.

---

## Tvorba podmnožiny dat, zkoumání tvaru rozdělení (šikmost, špičatost, histogram), klasická definice pravděpodobnosti, výpočet $EX$ a $var(X)$

---

Spust'te RStudio, otevřete si nový skript, uložte si ho a nastavte pracovní adresář.

### Rozcvička

Připomeňte si, jak lze použít R jako kalkulačku, a spočítejte následující výrazy:

$$\left(\frac{1}{2}\right)^{10}, \quad \exp(-5), \quad 5!, \quad \frac{5^3}{3!}, \quad \binom{6}{2}.$$

```
(1/2)^(10)
exp(-5)
factorial(5)
5^3/factorial(3)
choose(6,2)
```

### Data

Na dnešním cvičení využijeme datovou tabulku `iris`, která je k dispozici v R-kové knihovně `datasets`. Data získáte pomocí těchto příkazů:

```
install.packages("datasets")
library(datasets)
View(iris)
```

Tato data byla nasbírána Edgarem Andersonem v roce 1935 a obsahují naměřené údaje o třech druzích kosatců (`iris setosa`, `iris versicolor` a `iris virginica`). Naměřeny byly tyto veličiny:

- ✧ `Sepal.Length` (délka lístku kalicha v cm)
- ✧ `Sepal.Width` (šířka lístku kalicha v cm)
- ✧ `Petal.Length` (délka okvětního lístku v cm)
- ✧ `Petal.Width` (šířka okvětního lístku v cm)
- ✧ `Species` (druh kosatce)

# 1 Vytvoření podmnožiny dat

Někdy je potřeba zpracovávat pouze podmnožinu dat, jež splňuje nějakou podmínku (např. zajíma nás pouze určitý druh kosatce, nebo pouze jedinci s kališním lístkem delším než nějaký limit apod.) Bude proto potřeba umět vybrat si z dat podmnožinu splňující určitou podmínku a poté tuto podmnožinu uložit.

- 1) Zjistíme, kteří jedinci odpovídají odrůdě „virginica“:

```
which(iris$Species == "virginica")
```

- 2) Řekněme, že dále budeme chtít pracovat pouze s jedinci odrůdy virginica. Vytvořenou podmnožinu si můžeme uložit do datové tabulky `Virginica`.

```
Virginica <- subset(iris, Species == "virginica")
```

Poznámka: V případě, že máte data připojená (tj. provedli jste příkaz `attach(iris)`) a chcete podmnožinu původních dat ukládat a dále s ní pracovat, doporučuji opět odpojit přístup k proměnným původních dat, tj. proveďte `detach(iris)` (vyhněte se tak možným nedorozumněním plynoucím ze shodných názvů proměnných ve dvou datech – původních a podmnožiny).

- 3) Tuto podmnožinu si dále můžeme uložit (ale není to nutné, nebudeme ji v budoucnu potřebovat) pomocí známého příkazu:

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



- 4) Sami si můžete zkusit vytvořit nebo se alespoň podívat (nemusíte výsledky nikam ukládat) na následující podmnožiny:

- (a) Jedinci odrůdy *virginica* a *versicolor* (obě odrůdy dohromady).
- (b) Jedinci, kteří mají okvětní lístek delší než 5 cm.
- (c) Jedinci odrůdy *setosa*, kteří mají kališní lístek kratší než 5 cm.
- (d) Jedinci s okvětním lístkem délky 5 - 6 cm.

**Nápověda:** Ke specifikaci jednotlivých podmnožin si vybírejte z následujících logických výrazů (Subset expression):

- ✧ `Species == "setosa"`
- ✧ `Petal.Length > 5`
- ✧ `Species != "setosa"`
- ✧ `!(Petal.Length <= 5)`
- ✧ `Petal.Length <= 5 | Petal.Length >= 6`
- ✧ `Petal.Length > 5 & Petal.Length < 6`
- ✧ `!(Petal.Length > 5 & Petal.Length < 6)`
- ✧ `Species == "setosa" & Sepal.Length < 5`

**Poznámka:** Jestliže s vytvořenou podmnožinou neplánujete dále pracovat (tj. jenom vás zajímá, jak vypadá), není potřeba provádět dokola `detach(Sleep)`, `attach(Sleep)`.

Nadále již v datech `iris` nebudeme provádět žádné úpravy. Pro větší pohodlí si proto připojme všechny proměnné této datové tabulky:

```
attach(iris)
```

## 2 Šikmost a špičatost aneb tvar rozdělení kvantitativního znaku

Kromě charakteristik polohy a variability se může hodit vědět více o tvaru rozdělení dané kvantitativní veličiny (tj. mít představu, které hodnoty se objevují více a které méně často). K tomu lze využít následující charakteristiky.

### Histogram

Histogram graficky znázorňuje četnosti jednotlivých hodnot v datech. Reálnou osu rozdělí na malé intervaly vhodné délky a zaznamenává, kolik hodnot z dat se nachází v jakém intervalu. Tuto četnost pak znázorní výškou příslušného sloupce.

- 1) Nakresleme histogram šířky kališního lístku (uvažujme všechny odrůdy dohromady)

```
hist(Sepal.Width)
hist(Sepal.Width, breaks = 12) # lze nastavit počet intervalů
```

- 2) Histogram je vlastně odhadem hustoty daného rozdělení. Chceme-li ho porovnat s křivkou této hustoty, je vhodné ho přeškálovat tak, aby jeho plocha byla 1 (tak jako u hustoty). To se provede pomocí argumentu `prob=TRUE`. Tvar histogramu pak zůstane stejný, ale změní se měřítko na  $y$ -ové ose.

```
hist(Sepal.Width, prob=TRUE)
```

✧ Histogram si lze dále vylepšit pomocí známých grafických argumentů:

```
hist(Sepal.Width, prob=TRUE, col="slateblue",
     xlab="šířka kališního lístku", ylab="Hustota", main="Kosatec (3 odrůdy)")
```

Pro porovnání lze pak do histogramu přidat hustotu normálního rozdělení, jehož parametry odhadneme z dat

```
curve(dnorm(x, mean(Sepal.Width), sd(Sepal.Width)), col="red", add=TRUE)
```

### Šikmost a špičatost

Skutečné teoretické rozdělení daného znaku (např. šířky kališního lístku) samozřejmě neznáme, a neznáme tudíž ani jeho skutečnou šikmost a špičatost. Můžeme si je ale odhadnout pomocí jejich výběrových protějšků - výběrové šikmosti a špičatosti.

- 3) Spočteme **výběrovou šikmost a špičatost** pro šířku kališního lístku (`Sepal.Width`).  
Pro připomenutí:

$$a_3 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^3 \quad (\text{výběrová šikmost}),$$
$$a_4 = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{s_x} \right)^4 - 3 \quad (\text{výběrová špičatost}).$$

✧ Veličiny

$$z_i = \frac{x_i - \bar{x}}{s_x} \quad (i = 1, \dots, n)$$

se někdy nazývají  $z$ -skóry a v R je lze získat pomocí funkce `scale`. Výběrovou šikmost a špičatost proto snadno spočteme pomocí následujících příkazů:

```
mean(scale(Sepal.Width)^3)      # šikmost
mean(scale(Sepal.Width)^4) - 3  # špicatost
```



✧ Jakých hodnot (přibližně) by výběrová šikmost a špicatost měla nabývat, jestliže bychom mohli předpokládat normalitu rozdělení šířky kališních lístků?



✧ Je hodnota výběrové šikmosti v souladu s tvarem histogramu pro šířku kališního lístku z předchozí části?

### 3 Klasická definice pravděpodobnosti

**Náhodný pokus** je pokus konaný za přesně definovaných podmínek, jehož výsledek je předem nejistý (např. hod kostkou). Nejjemněji rozlišované možné výsledky náhodného pokusu, které se vzájemně vylučují (nemohou nastat dva současně) a jeden vždy musí nastat, se nazývají **elementární jevy** (např. pro hod kostkou je množina elementárních jevů rovna  $\{1, 2, 3, 4, 5, 6\}$ ). Množina všech elementárních jevů daného pokusu se obvykle značí písmenem  $\Omega$ . **Náhodný jev**  $A$  je pak libovolné tvrzení o výsledku náhodného pokusu. Náhodné jevy značíme zpravidla velkými písmeny ze začátku abecedy. Korektně pak můžeme náhodný jev  $A$  popsat tak, že vyjmenujeme, ze kterých elementárních jevů se skládá, tj. vyjmenujeme všechny elementární jevy, které jsou příznivé jevu  $A$  (jev  $A$ , že na kostce padne sudé číslo, se skládá z elementárních jevů  $\{2, 4, 6\}$ ).

Jsou-li všechny elementární jevy stejně pravděpodobné (což je příklad třeba spravedlivé kostky, kde všechny stěny mají pravděpodobnost  $1/6$ ), pak pravděpodobnost jevu  $A$ , který je složen z  $m_A$  elementárních jevů, spočítáme jednoduše jako

$$P(A) = \frac{m_A}{m},$$

kde  $m$  je celkový počet všech elementárních jevů (tj. celkový počet prvků množiny  $\Omega$ ). Tímto vzorečkem se dříve pravděpodobnost definovala, a tak dnes říkáme, že jde o tzv. **klasickou definici pravděpodobnosti**. Například pro jev  $A$ , že na kostce padne sudé číslo je  $m_A = 3$  a  $m = 6$ , a tudíž  $P(A) = \frac{3}{6} = \frac{1}{2}$ .

- 1) Kolika způsoby si může 15 studentů *Základů biostatistiky* sednout k 15 počítačům v učebně B5? Jaká je pravděpodobnost, že si sednou (v učebně zleva doprava) přesně v pořadí, v jakém jsou uvedeni v prezenční listině?

✧ Množina  $\Omega$  je tvořena všemi permutacemi, které lze vytvořit z 15 prvků (studentů). Celkový počet těchto permutací je  $m = 15!$ . V R to spočítáme jako

```
factorial(15)
```

✧ Uspořádání, které vyhovuje prezenční listině, je pouze jediné. Tedy počet příznivých uspořádání je  $m_A = 1$ , a tudíž pravděpodobnost této jediné permutace je dle klasické definice pravděpodobnosti rovna

```
1/factorial(15)
```



- 2) Kolika způsoby si může sednout do posluchárny o 170 židlích 170 studentů?

✧ Vyjde vám nějaké ohromné číslo, protože faktoriál se zvětšuje velkou rychlostí.

- 3) Kolika způsoby si může sednout do posluchárny o 171 židlích 171 studentů?

✧ Zde už je odpověď **Inf** (= *infinity*, nekonečno). I R má své limity...

- 4) S jakou pravděpodobností vyhrajete ve Sportce 1. cenu s jedním vsazeným sloupcem?

✧ Ve Sportce se tipuje 6 ze 49 čísel. Vyhrát první cenu znamená uhodnout všech šest čísel.

✧ Princip losování přitom zaručuje, že každá šestice čísel má stejnou pravděpodobnost. Množina  $\Omega$  je tedy tvořena všemi šesticemi, které lze vytvořit ze 49 čísel. Těchto šestic je  $\binom{49}{6}$ , což v  $\mathbb{R}$  vypočteme jako

$$\text{choose}(49, 6)$$

✧ Počet příznivých jevů, tj. počet šestic, na něž připadne první cena, je roven 1. Proto pravděpodobnost výhry první ceny je dle klasické definice pravděpodobnosti rovna

$$1 / \text{choose}(49, 6)$$

5) S jakou pravděpodobností vyhraje ve Sportce 1. pořadí s úplně vyplněným tiketem (10 sloupců), jestliže v každém sloupci máte uvedenu jinou kombinaci vsazených čísel?

$$10 / \text{choose}(49, 6)$$



6) Házíme dvěma kostkami. S jakou pravděpodobností bude:

✧ součet obou hodnot roven 10?

✧ součet obou hodnot roven alespoň 10?

## 4 Výpočet střední hodnoty a rozptylu z definice

Připomeňte si vzorec pro výpočet střední hodnoty diskrétní náhodné veličiny (např. *NVR*, str. 3, vzorec (1)).

### Příklad

Náhodná veličina  $X$  nabývá pouze hodnot 2, 3, 5 a to s pravděpodobnostmi

$$P(X = 2) = 0.6 \qquad P(X = 3) = 0.3 \qquad P(X = 5) = 0.1.$$

Vypočtete střední hodnotu a rozptyl této náhodné veličiny.

✧ **střední hodnotu** vypočteme z definice jako

$$\begin{aligned} E X &= 2 \cdot P(X = 2) + 3 \cdot P(X = 3) + 5 \cdot P(X = 5) \\ &= 2 \cdot 0.6 + 3 \cdot 0.3 + 5 \cdot 0.1 = 2.6 \end{aligned}$$

✧ **rozptyl** můžeme také vypočítat z definice (viz např. *NVR*, str. 4, vzorec (2))

$$\begin{aligned} \text{var } X &= E(X - E X)^2 \\ &= (2 - E X)^2 \cdot P(X = 2) + (3 - E X)^2 \cdot P(X = 3) + (5 - E X)^2 \cdot P(X = 5) \\ &= (2 - 2.6)^2 \cdot 0.6 + (3 - 2.6)^2 \cdot 0.3 + (5 - 2.6)^2 \cdot 0.1 \\ &= 0.84 \end{aligned}$$

✧ Někdy je výhodnější vypočítat rozptyl podle vzorečku

$$\text{var } X = E(X^2) - (E X)^2$$

K tomu je potřeba si vypočítat  $E(X^2)$  (tzv. druhý moment veličiny  $X$ ), což uděláme opět z definice střední hodnoty (tentokrát jde o střední hodnotu  $X^2$ )

$$\begin{aligned} E(X^2) &= 2^2 \cdot P(X = 2) + 3^2 \cdot P(X = 3) + 5^2 \cdot P(X = 5) \\ &= 4 \cdot 0.6 + 9 \cdot 0.3 + 25 \cdot 0.1 = 7.6 \end{aligned}$$

a pak dosadit

$$\text{var } X = E(X^2) - (E X)^2 = 7.6 - (2.6)^2 = 0.84.$$

### Příklad - samostatná práce



Náhodná veličina  $X$  nabývá pouze hodnot 0 a 1, a to s pravděpodobnostmi

$$P(X = 0) = 0.8$$

$$P(X = 1) = c.$$

Určete hodnotu  $c$  a spočtěte  $E X$ .

## 5 Konec práce

Než zavřete všechna okna, nezapomeňte si uložit poslední změny ve skriptovém souboru:

**File** ➔ **Save**