

6 Číselné charakteristiky náhodných veličin, centrální limitní věta

6.1 Číselné charakteristiky náhodných veličin alespoň ordinálního typu

6.1.1 Charakteristika polohy

Číslo $K_\alpha(X)$ se nazývá α -kvantil náhodné veličiny X , jestliže splňuje nerovnosti: $\Pr(X \leq K_\alpha(X)) \geq \alpha \wedge \Pr(X \geq K_\alpha(X)) \geq 1 - \alpha$. Přitom $\alpha \in (0; 1)$. Jde o teoretický protějšek kvantilu x_α zavedeného v popisné statistice (viz kapitola 3). Pro některá vybraná α jsou názvy kvantilů v počtu pravděpodobnosti stejné jako v popisné statistice. Vzhledem k tomu, že kvantily diskrétních náhodných veličin nejsou určeny jednoznačně, budeme se dále zabývat jen kvantily spojitých náhodných veličin. Pro spojitou náhodnou veličinu X platí: $\alpha = F(K_\alpha(X)) = \int_{-\infty}^{K_\alpha(X)} f(x)dx$.

Označení pro kvantily speciálních rozdělení

- $X \sim N(0, 1) \Rightarrow K_\alpha(X) = u_\alpha$,
- $X \sim t(n) \Rightarrow K_\alpha(X) = t_\alpha(n)$,
- $X \sim \chi^2(n) \Rightarrow K_\alpha(X) = \chi_\alpha^2(n)$,
- $X \sim F(n_1, n_2) \Rightarrow K_\alpha(X) = F_\alpha(n_1, n_2)$.


Převodní vztahy:

- $u_\alpha = -u_{1-\alpha}$,
- $t_\alpha(n) = -t_{1-\alpha}(n)$,
- $F_\alpha(n_1, n_2) = \frac{1}{F_{1-\alpha}(n_2, n_1)}$.

6.1.2 Charakteristika variability

Interkvartilové rozpětí $IQR = K_{0,75}(X) - K_{0,25}(X)$.

Příklad 6.1. Řešený příklad

Pomocí softwaru  zjistíte hodnotu kvantilů (a) $u_{0,85}, u_{0,60}, u_{0,13}$; (b) $t_{0,99}(15), t_{0,28}(143), t_{0,75}(44)$; (c) $\chi_{0,25}^2(80), \chi_{0,64}^2(37), \chi_{0,31}^2(2)$; (d) $F_{0,76}(9; 12), F_{0,11}(15; 40), F_{0,05}(100; 87)$. Všechny vypočítané hodnoty řádně interpretujte.

Řešení příkladu 6.1

Hodnoty α -kvantilů standardizovaného normálního rozdělení, tj. u_α , vypočítáme příkazem `qnorm()`. Vstupním argumentem příkazu bude pouze hodnota α . Vstupní argumenty odpovídající hodnotám parametrů $\mu = 0$ (argument `mean = 0`) a $\sigma = 1$ (argument `sd = 1`) v příkazu specifikovat nemusíme, protože jde o výchozí hodnoty, které jsou ve funkci `qnorm()` automaticky přednastavené.

```
1 qnorm(0.85) # 1,036433
2 qnorm(0.60) # 0,2533471
3 qnorm(0.13) # -1,126391
```

Za předpokladu, že náhodná veličina X pochází ze standardizovaného normálního rozdělení, je 85 % hodnot menších nebo rovných 1,0364, 60 % hodnot je menších nebo rovných 0,2533 a 13 % hodnot je menších nebo rovných $-1,1264$.

Hodnoty α -kvantilů Studentova rozdělení o n stupních volnosti, tj. $t_\alpha(n)$, vypočítáme příkazem `qt()`. Vstupními argumenty příkazu budou hodnota α a počet stupňů volnosti (argument `df`).

```
4 qt(0.99, df = 15) # 2,60248
5 qt(0.28, df = 143) # -0,5842093
6 qt(0.75, df = 44) # 0,6801065
```

Za předpokladu, že náhodná veličina X pochází ze Studentova rozdělení o 15 stupních volnosti, je 99 % hodnot menších nebo rovných 2,6025. Za předpokladu, že náhodná veličina X pochází ze Studentova rozdělení o 143 stupních volnosti, je 28 % hodnot menších nebo rovných $-0,5842$. Za předpokladu, že náhodná veličina X pochází ze Studentova rozdělení o 44 stupních volnosti, je 75 % hodnot menších nebo rovných 0,6801.

Hodnoty α -kvantilů χ^2 rozdělení o n stupních volnosti, tj. $\chi^2_\alpha(n)$, vypočítáme příkazem `qchisq()`. Vstupními argumenty příkazu budou hodnota α a počet stupňů volnosti (argument `df`).

```
7 qchisq(0.25, df = 80) # 71,14451
8 qchisq(0.64, df = 37) # 39,47272
9 qchisq(0.31, df = 2) # 0,7421274
```

Za předpokladu, že náhodná veličina X pochází z χ^2 rozdělení o 80 stupních volnosti, je 25 % hodnot menších nebo rovných 71,1445. Za předpokladu, že náhodná veličina X pochází z χ^2 rozdělení o 37 stupních volnosti, je 64 % hodnot menších nebo rovných 39,4727. Za předpokladu, že náhodná veličina X pochází z χ^2 rozdělení o 2 stupních volnosti, je 31 % hodnot menších nebo rovných 0,7421.

Hodnoty α -kvantilů Fisherova-Snedecorova rozdělení o n_1 a n_2 stupních volnosti, tj. $F_\alpha(n_1, n_2)$, vypočítáme příkazem `qf()`. Vstupními argumenty příkazu budou hodnota α , počet stupňů volnosti n_1 (argument `df1`) a počet stupňů volnosti n_2 (argument `df2`).

```
10 qf(0.76, df1 = 9, df2 = 12) # 1,535992
11 qf(0.11, df1 = 15, df2 = 40) # 0,5563822
12 qf(0.05, df1 = 100, df2 = 87) # 0,7114649
```

Za předpokladu, že náhodná veličina X pochází z Fisherova-Snedecorova rozdělení o 9 a 12 stupních volnosti, je 76 % hodnot menších nebo rovných 1,5360. Za předpokladu, že náhodná veličina X pochází z Fisherova-Snedecorova rozdělení o 15 a 40 stupních volnosti, je 11 % hodnot menších nebo rovných 0,5564. Za předpokladu, že náhodná veličina X pochází z Fisherova-Snedecorova rozdělení o 100 a 87 stupních volnosti, je 5 % hodnot menších nebo rovných 0,7115. ★

Příklad 6.2. Řešený příklad

Pomocí softwaru \mathbb{R} (a) zjistěte hodnoty kvantilů $u_{0,10}$, $u_{0,90}$ a ověřte, že platí vztah $u_{0,10} = -u_{0,90}$; (b) zjistěte hodnoty kvantilů $t_{0,65}(18)$, $t_{0,35}(18)$ a ověřte, že platí vztah $t_{0,65}(18) = -t_{0,35}(18)$; (c) zjistěte hodnoty kvantilů $F_{0,48}(13; 1)$, $F_{0,52}(1; 13)$ a ověřte, že platí vztah $F_{0,48}(13; 1) = \frac{1}{F_{0,52}(1; 13)}$.

Řešení příkladu 6.2

Hodnoty α -kvantilů standardizovaného normálního rozdělení, tj. u_α , vypočítáme příkazem `qnorm()`.

```
13 qnorm(0.10) # -1,281552
14 qnorm(0.90) # 1,281552
```

Kvantil $u_{0,10} = -1,2816$, kvantil $u_{0,90} = 1,2816$. Vidíme tedy, že rovnost $u_{0,10} = -u_{0,90}$ platí.

Hodnoty α -kvantilů Studentova rozdělení o n stupních volnosti, tj. $t_\alpha(n)$, vypočítáme příkazem `qt()`.

```
15 qt(0.65, df = 18) # 0,3915326
16 qt(0.35, df = 18) # -0,3915326
```

Kvantil $t_{0,65}(18) = 0,3915$, kvantil $t_{0,35}(18) = -0,3915$. Vidíme tedy, že rovnost $t_{0,65}(18) = -t_{0,35}(18)$ platí.

Hodnoty α -kvantilů Fisherova-Snedecorova rozdělení o n_1 a n_2 stupních volnosti, tj. $F_\alpha(n_1, n_2)$, vypočítáme příkazem `qf()`.

```
17 qf(0.48, df1 = 13, df2 = 1) # 1,891045
18 qf(0.52, df1 = 1, df2 = 13) # 0,5288082
19 1 / qf(0.52, df1 = 1, df2 = 13) # 1,891045
```

Kvantil $F_{0,48}(13; 1) = 1,8910$, kvantil $F_{0,52}(1; 13) = 0,5288$, hodnota $\frac{1}{F_{0,52}(1; 13)} = \frac{1}{0,5288} = 1,8910$. Vidíme tedy, že rovnost $F_{0,48}(13; 1) = \frac{1}{F_{0,52}(1; 13)}$ platí. ★

Příklad 6.3. Neřešený příklad

Pomocí softwaru \mathbb{R} zjistěte hodnotu kvantilů (a) $u_{0,21}$, $u_{0,92}$, $u_{0,50}$; (b) $t_{0,14}(136)$, $t_{0,47}(9)$, $t_{0,26}(62)$; (c) $\chi_{0,38}^2(12)$, $\chi_{0,07}^2(70)$, $\chi_{0,66}^2(425)$; (d) $F_{0,83}(83; 83)$, $F_{0,59}(10; 7)$, $F_{0,14}(140; 79)$. Všechny vypočítané hodnoty řádně interpretujte. **Výsledky:** (a) $u_{0,21} = -0,8064$, $u_{0,92} = 1,4051$, $u_{0,50} = 0,0000$; (b) $t_{0,14}(136) = -1,0846$, $t_{0,47}(9) = -0,0774$, $t_{0,26}(62) = -0,6470$; (c) $\chi_{0,38}^2(12) = 9,9540$, $\chi_{0,07}^2(70) = 53,3893$, $\chi_{0,66}^2(425) = 436,4614$; (d) $F_{0,83}(83; 83) = 1,2340$, $F_{0,59}(10; 7) = 1,2147$, $F_{0,14}(140; 79) = 0,8106$. ★

Příklad 6.4. Neřešený příklad

Pomocí softwaru \mathbb{R} (a) zjistěte hodnoty kvantilů $u_{0,76}$, $u_{0,24}$ a ověřte, že platí vztah $u_{0,76} = -u_{0,24}$; (b) zjistěte hodnoty kvantilů $t_{0,04}(315)$, $t_{0,96}(315)$ a ověřte, že platí vztah $t_{0,04}(315) = -t_{0,96}(315)$; (c) zjistěte hodnoty kvantilů $F_{0,31}(180; 248)$, $F_{0,69}(248; 180)$ a ověřte, že platí vztah $F_{0,31}(180; 248) = \frac{1}{F_{0,69}(248; 180)}$.

Výsledky: (a) $u_{0,76} = 0,7063$, $u_{0,24} = -0,7063$, rovnost platí; (b) $t_{0,04}(315) = -1,7564$, $t_{0,96}(315) = 1,7564$, rovnost platí; (c) $F_{0,31}(180; 248) = 0,9325$, $F_{0,69}(248; 180) = 1,0724$, $\frac{1}{F_{0,69}(248; 180)} = 0,9325$, rovnost platí. ★

6.2 Číselné charakteristiky náhodných veličin intervalového a poměrového typu

6.2.1 Charakteristika polohy

Předpokládejme, že $p(x)$ je pravděpodobnostní funkce náhodné veličiny X (v případě, že X je diskrétní náhodná veličina) a $f(x)$ je hustota náhodné veličiny X (v případě, že X je spojitá náhodná veličina).

$$\text{Střední hodnota } E(X) = \begin{cases} \sum_{x=-\infty}^{\infty} xp(x), \\ \int_{-\infty}^{\infty} xf(x)dx, \end{cases}$$

pokud je suma, resp. integrál na pravé straně rovnosti konečný nebo absolutně konverguje. Jinak střední hodnota neexistuje.

6.2.2 Charakteristika variability

$$\text{Rozptyl } D(X) = E([X - E(X)]^2) = E(X^2) - [E(X)]^2 = \begin{cases} \sum_{x=-\infty}^{\infty} x^2p(x) - [\sum_{x=-\infty}^{\infty} xp(x)]^2, \\ \int_{-\infty}^{\infty} x^2f(x)dx - [\int_{-\infty}^{\infty} xf(x)dx]^2, \end{cases}$$

pokud střední hodnoty $E(X^2)$ a $E(X)$ existují.

Směrodatná odchylka: $\sqrt{D(X)}$. Centrovaná náhodná veličina: $Z = X - E(X)$. Standardizovaná náhodná veličina: $U = \frac{X - E(X)}{\sqrt{D(X)}}$. Pro centrovanou a standardizovanou náhodnou veličinu platí: $E(Z) = 0$, $D(Z) = D(X)$, $E(U) = 0$, $D(U) = 1$. Pro konstantu k platí: $E(k) = k$, $D(k) = 0$.

Střední hodnoty a rozptyly vybraných diskrétních a spojitých rozdělení

- $X \sim A(\vartheta) \Rightarrow E(X) = \vartheta$, $D(X) = \vartheta(1 - \vartheta)$,
- $X \sim \text{Bi}(n, \vartheta) \Rightarrow E(X) = n\vartheta$, $D(X) = n\vartheta(1 - \vartheta)$,
- $X \sim \text{Hg}(N, M, k) \Rightarrow E(X) = \frac{Mk}{N}$, $D(X) = \frac{Mk}{N} \left(1 - \frac{M}{N}\right) \frac{N-k}{N-1}$,
- $X \sim \text{Po}(\lambda) \Rightarrow E(X) = \lambda$, $D(X) = \lambda$,
- $X \sim N(\mu, \sigma^2) \Rightarrow E(X) = \mu$, $D(X) = \sigma^2$.

6.2.3 Charakteristika společné variability dvou náhodných veličin

Předpokládejme, že $p(x, y)$ je simultánní pravděpodobnostní funkce náhodného vektoru $(X, Y)^T$, $p_x(x)$ je pravděpodobnostní funkce náhodné veličiny X a $p_y(y)$ je pravděpodobnostní funkce náhodné veličiny Y (v případě, že X a Y jsou diskrétní náhodné veličiny). Dále předpokládejme, že $f(x, y)$ je simultánní hustota náhodného vektoru $(X, Y)^T$, $f_x(x)$ je hustota náhodné veličiny X a $f_y(y)$ je hustota náhodné veličiny Y (v případě, že X a Y jsou spojité náhodné veličiny). Kovariance

$$\begin{aligned} C(X, Y) &= E([X - E(X)][Y - E(Y)]) \\ &= E(XY) - E(X)E(Y) \\ &= \begin{cases} \sum_{x=-\infty}^{\infty} \sum_{y=-\infty}^{\infty} xy p(x, y) - \sum_{x=-\infty}^{\infty} xp_x(x) \sum_{y=-\infty}^{\infty} yp_y(y), \\ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} xy f(x, y) dx dy - \int_{-\infty}^{\infty} xf_x(x) dx \int_{-\infty}^{\infty} yf_y(y) dy, \end{cases} \end{aligned}$$

pokud střední hodnoty $E(XY)$, $E(X)$ a $E(Y)$ existují. Je-li $C(X, Y) > 0$, resp. < 0 , znamená to, že mezi náhodnými veličinami X a Y existuje určitý stupeň přímé, resp. nepřímé lineární závislosti. Je-li $C(X, Y) = 0$, pak řekneme, že náhodné veličiny X a Y jsou nekorelované, a znamená to, že mezi nimi není žádný lineární vztah.

Upozornění: Z nekorelovanosti obecně nevyplývá stochastická nezávislost, avšak ze stochastické nezávislosti plyne nekorelovanost.

6.2.4 Charakteristika těsnosti lineárního vztahu dvou náhodných veličin

Koeficient korelace

$$\begin{aligned} R(X, Y) &= \begin{cases} E\left(\frac{X-E(X)}{\sqrt{D(X)}} \frac{Y-E(Y)}{\sqrt{D(Y)}}\right) & \text{pro } \sqrt{D(X)}\sqrt{D(Y)} > 0, \\ 0 & \text{jinak,} \end{cases} \\ &= \begin{cases} \frac{C(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}} & \text{pro } \sqrt{D(X)}\sqrt{D(Y)} > 0, \\ 0 & \text{jinak.} \end{cases} \end{aligned}$$

Cauchyho-Schwarzova-Bunjakovského nerovnost: $|R(X, Y)| \leq 1$, přičemž rovnost nastane tehdy a jen tehdy, když mezi veličinami X a Y existuje s pravděpodobností 1 úplná lineární závislost, tj. existují konstanty a, b , pro které $\Pr(Y = a + bX) = 1$.

Příklad 6.5. Řešený příklad

Načtěte datový soubor `30-fiances-single-marital-status.csv` obsahující hodnoty simultánní pravděpodobnostní funkce věku v letech u svobodných snoubenců (věk v letech u ženicha, věk v letech u nevěsty) vstupujících do manželství v roce 2019 na území České republiky. Za předpokladu, že náhodná veličina X popisuje věk v letech u svobodného ženicha a náhodná veličina Y popisuje věk v letech u svobodné nevěsty, (a) vypočítejte střední hodnotu a směrodatnou odchylku náhodné veličiny X , resp. Y ; (b) vypočítejte kovarianci a koeficient korelace. Všechny vypočítané hodnoty řádně interpretujte.

Poznámka: Datový soubor `30-fiances-single-marital-status.csv` obsahuje kompletní údaje o všech sňatcích uskutečněných na území České republiky v roce 2019 a o věku v letech u každého ženicha i u každé nevěsty, kteří byli v roce 2019 sezdáni. V tomto případě tedy nepočítáme odhady, ale přímo hodnoty $E(X)$, $E(Y)$, $\sqrt{D(X)}$, $\sqrt{D(Y)}$, $C(X, Y)$ a $R(X, Y)$. V praxi však většinou máme pouze reprezentativní vzorek populace, na jehož základě střední hodnoty, rozptyly, kovarianci a koeficient korelace pouze odhadujeme. V takovém případě bychom počítali odhady $\widehat{E(X)}$, $\widehat{E(Y)}$, $\sqrt{\widehat{D(X)}}$, $\sqrt{\widehat{D(Y)}}$, $\widehat{C(X, Y)}$ a $\widehat{R(X, Y)}$ náhodných veličin X a Y .

Řešení příkladu 6.5

Datový soubor načteme příkazem `read.delim()` s argumentem `row.names = 1`, specifikujícím, že hodnoty vložené v prvním sloupci mají být vnímány jako názvy řádků načtené tabulky. Sloupce tabulky pojmenujeme stejně jako

řádky, protože věk u ženicha i u nevěsty je rozdělen do stejných věkových kategorií. Datovou tabulku si následně zobrazíme. Příkazem `format()` s argumentem `scientific = F` nastavíme, aby se čísla v tabulce zobrazila v klasickém desetinném zápise (formát 0.0003) namísto v přednastaveném vědeckém zápise čísel (formát 3×10^{-4}). Převod na desetinný zápis čísel provádíme pouze pro lepší přehlednost vypsané tabulky. Poznamenejme, že v rádcích tabulky je uveden věk u ženicha, ve sloupcích věk u nevěsty (viz kapitola 13, sekce 13.20).

```
20 data <- read.delim("30-fiances-single-marital-status.csv", sep = ",", dec = ".",
    row.names = 1)
21 names(data) <- row.names(data)
22 format(data, scientific = F)
```

	17-19	20-24	25-29	30-34	35-39	40-44	45-49	50-54	55-59	60-64
17-19	0.0010	0.0007	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
20-24	0.0051	0.0435	0.0182	0.0033	0.0005	0.0002	0.0000	0.0000	0.0000	0.0000
25-29	0.0024	0.0777	0.2238	0.0410	0.0050	0.0007	0.0001	0.0000	0.0000	0.0000
30-34	0.0008	0.0248	0.1553	0.1283	0.0187	0.0027	0.0003	0.0000	0.0000	0.0000
35-39	0.0002	0.0061	0.0411	0.0677	0.0364	0.0071	0.0007	0.0000	0.0000	0.0000
40-44	0.0000	0.0017	0.0089	0.0197	0.0209	0.0125	0.0013	0.0002	0.0001	0.0000
45-49	0.0000	0.0003	0.0015	0.0034	0.0039	0.0054	0.0014	0.0001	0.0001	0.0000
50-54	0.0000	0.0001	0.0003	0.0005	0.0007	0.0009	0.0006	0.0003	0.0001	0.0000
55-59	0.0000	0.0000	0.0001	0.0001	0.0002	0.0003	0.0001	0.0002	0.0001	0.0000
60-64	0.0000	0.0000	0.0000	0.0000	0.0001	0.0001	0.0000	0.0001	0.0001	0.0001

23
24
25
26
27
28
29
30
31
32
33

Střední hodnotu náhodné veličiny X vypočítáme pomocí vzorce $E(X) = \sum_{x=-\infty}^{\infty} xp_x(x)$, kde x je vektor středů třídících intervalů věkových kategorií u ženicha, tj. posloupnost hodnot 18, 22, 27, 32, 37, 42, 47, 52, 57, 62, a $p_x(x)$ je pravděpodobnostní funkce náhodné veličiny X . Hodnoty funkce $p_x(x)$ získáme jako řádkové součty v tabulce `data` příkazem `apply()`. Rozptyl náhodné veličiny X vypočítáme přepisem vzorce $D(X) = \sum_{x=-\infty}^{\infty} x^2 p_x(x) - [\sum_{x=-\infty}^{\infty} xp_x(x)]^2$. Směrodatnou odchylku získáme odmocněním rozptylu $D(X)$.

```
34 x <- c(18, 22, 27, 32, 37, 42, 47, 52, 57, 62)
35 px <- apply(data, MARGIN = 1, FUN = sum)
36 EX <- sum(x * px) # 31,3168
37 DX <- sum(x ^ 2 * px) - (sum(x * px)) ^ 2 # 32,40604
38 sqrt(DX) # 5,69263
```

Střední hodnota věku u svobodného ženicha je 31,32 let se směrodatnou odchylkou 5,69 let.

Střední hodnotu náhodné veličiny Y vypočítáme pomocí vzorce $E(Y) = \sum_{y=-\infty}^{\infty} yp_y(y)$, kde y je vektor středů třídících intervalů věkových kategorií u nevěsty, shodou okolností opět posloupnost hodnot 18, 22, 27, 32, 37, 42, 47, 52, 57, 62, a $p_y(y)$ je pravděpodobnostní funkce náhodné veličiny Y . Hodnoty funkce $p_y(y)$ získáme jako sloupcové součty v tabulce `data`. Rozptyl náhodné veličiny Y vypočítáme přepisem vzorce $D(Y) = \sum_{y=-\infty}^{\infty} y^2 p_y(y) - [\sum_{y=-\infty}^{\infty} yp_y(y)]^2$. Odmocněním rozptylu $D(Y)$ získáme směrodatnou odchylku.

```
39 y <- c(18, 22, 27, 32, 37, 42, 47, 52, 57, 62)
40 py <- apply(data, MARGIN = 2, FUN = sum)
41 EY <- sum(y * py) # 28,9035
42 DY <- sum(y ^ 2 * py) - (sum(y * py)) ^ 2 # 25,92119
43 sqrt(DY) # 5,091285
```

Střední hodnota věku u svobodné nevěsty je 28,90 let se směrodatnou odchylkou 5,09 let.

Kovarianci mezi náhodnými veličinami X a Y vypočítáme pomocí vzorce $C(X, Y) = \sum_{x=-\infty}^{\infty} \sum_{y=-\infty}^{\infty} xyp(x, y) - \sum_{x=-\infty}^{\infty} xp_x(x) \sum_{y=-\infty}^{\infty} yp_y(y)$, kde x , resp. y je vektor středů třídících intervalů věkových kategorií u ženicha, resp. u nevěsty, $p_x(x)$, resp. $p_y(y)$ je pravděpodobnostní funkce náhodné veličiny X , resp. Y a $p(x, y)$ je simultánní pravděpodobnostní funkce náhodného vektoru $(X, Y)^T$. Hodnoty funkce $p(x, y)$ máme vloženy v proměnné `data`. Matici součinů xy všech kombinací středů třídících intervalů náhodných veličin X a Y vypočítáme pomocí operátoru maticového násobení `%*%` (viz kapitola 3). Koeficient korelace dopočítáme přepisem vzorce $R(X, Y) = \frac{C(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}}$.

```

44 pxy <- data
45 xy <- x %>% t(y)
46 CXY <- sum(xy * pxy) - sum(x * px) * sum(y * py) # 17,94097
47 RXY <- CXY / (sqrt(DX) * sqrt(DY)) # 0,6190212

```

Kovariance mezi náhodnými veličinami X a Y nabývá hodnoty 17,94 let². Mezi věkem u svobodného ženicha a věkem u svobodné nevěsty existuje význačný stupeň přímé lineární závislosti ($R(X, Y) = 0,62$; stupeň míry závislosti viz kapitola 3, tabulka 3.2). ★

Příklad 6.6. Neřešený příklad

Načtete datový soubor 29-live-births.csv obsahující hodnoty simultánní pravděpodobnostní funkce věku v letech u matky v roce 2019 a počtu jejích živě narozených potomků do téhož roku na území České republiky. Za předpokladu, že náhodná veličina X popisuje věk v letech u matky a náhodná veličina Y popisuje počet živě narozených potomků, (a) vypočítejte střední hodnotu a směrodatnou odchylku náhodné veličiny X , resp. Y ; (b) vypočítejte kovarianci a koeficient korelace. Všechny vypočítané hodnoty řádně interpretujte.

Poznámka: Datový soubor 29-live-births.csv obsahuje kompletní údaje o věku v letech a o počtu živě narozených potomků u každé matky žijící na území České republiky v roce 2019. V tomto případě tedy znovu nepočítáme odhady středních hodnot, směrodatných odchylek, kovariance a koeficientu korelace náhodných veličin X a Y , ale přímo hodnoty $E(X)$, $E(Y)$, $\sqrt{D(X)}$, $\sqrt{D(Y)}$, $C(X, Y)$ a $R(X, Y)$.

Výsledky: (a) $E(X) = 30,41$, $\sqrt{D(X)} = 5,41$, $E(Y) = 1,73$, $\sqrt{D(Y)} = 0,90$; (b) $C(X, Y) = 1,49$, $R(X, Y) = 0,31$, mírný stupeň přímé lineární závislosti. ★

6.3 Centrální limitní věta

X_1, \dots, X_n jsou stochasticky nezávislé náhodné veličiny se stejným rozdělením se střední hodnotou μ a rozptylem σ^2 . Pak pro velká n ($n \geq 30$) lze rozdělení součtu $\sum_{i=1}^n X_i$ aproximovat normálním rozdělením $N(n\mu, n\sigma^2)$. Zkráceně píšeme $\sum_{i=1}^n X_i \approx N(n\mu, n\sigma^2)$. Standardizací tohoto součtu vytvoříme náhodnou veličinu $U_n = \frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \approx N(0, 1)$.

Důsledek: Moivreova-Laplaceova věta

X_1, \dots, X_n jsou stochasticky nezávislé náhodné veličiny, $X_i \sim A(\vartheta)$, $i = 1, 2, \dots, n$. Pak $Z_n = \sum_{i=1}^n X_i \sim \text{Bi}(n, \vartheta)$ a za splnění podmínek dobré aproximace $\frac{1}{n+1} < \vartheta < \frac{n}{n+1}$ a $n\vartheta(1-\vartheta) > 9$ platí, že $U = \frac{Z_n - n\vartheta}{\sqrt{n\vartheta(1-\vartheta)}} \approx N(0, 1)$.

Vzorec aproximace: $\Pr(Z_n \leq z) \approx \Phi\left(\frac{z - n\vartheta}{\sqrt{n\vartheta(1-\vartheta)}}\right) = \Phi(u)$, kde $\Phi(u)$ je distribuční funkce rozdělení $N(0, 1)$ v bodě $u = \frac{z - n\vartheta}{\sqrt{n\vartheta(1-\vartheta)}}$.

Příklad 6.7. Řešený příklad

Pravděpodobnost výskytu dermatoglyfického vzoru *vír* u mužů z populace Valmíkis je $p_m = 0,4780$ (Rajendra Rao, 1972), pravděpodobnost výskytu dermatoglyfického vzoru *vír* u žen z populace Valmíkis je $p_f = 0,3500$ (Mrunalini Devi, 1972). Za předpokladu, že náhodná veličina X popisuje výskyt dermatoglyfického vzoru *vír* u jednoho muže z populace Valmíkis, vypočítejte pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vír* vyskytne (a) vícekrát než kterýkoli jiný vzor; (b) nejvýše u 575 mužů; (c) alespoň u 360 a nejvýše u 560 mužů. Zadané pravděpodobnosti vypočítejte (i) pomocí vhodného rozdělení; (ii) přibližně na základě aproximace tohoto rozdělení pomocí Moivreovy-Laplaceovy věty. Výsledky vzájemně porovnejte.

Řešení příkladu 6.7

Počet mužů s dermatoglyfickým vzorem *vír* v náhodném výběru 1200 mužů z populace Valmíkis je diskrétní znak, k jeho popisu tedy použijeme diskrétní náhodnou veličinu. Výskyt vzoru *vír* byl zkoumán v 1200 Bernoulliho pokusech X_1, \dots, X_{1200} , přičemž v každém pokusu mohlo dojít k nastání sledované události ($X_i = 1$; výskyt vzoru *vír*), nebo k nenastání sledované události ($X_i = 0$; výskyt libovolného jiného vzoru). Počet mužů se vzorem *vír* v náhodném

výběru 1200 mužů potom popisuje náhodná veličina $Z_{1200} = \sum_{i=1}^{1200} X_i$, která asymptoticky pochází z binomického rozdělení s parametry $n = 1200$ a $\vartheta = 0,4780$. Zadané pravděpodobnosti (a), (b) a (c) tedy vypočítáme pomocí binomického rozdělení.

Pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vír* vyskytne vícekrát než kterýkoli jiný vzor, odpovídá pravděpodobnosti, že se vzor *vír* vyskytne alespoň u 601 mužů, tj. $\Pr(Z_{1200} \geq 601)$. Tuto pravděpodobnost vypočítáme tak, že od jedné odečteme pravděpodobnost, že se vzor *vír* vyskytne nejvýše u 600 mužů, což odpovídá hodnotě distribuční funkce $F(z)$ rozdělení $\text{Bi}(1200; 0,4780)$ v bodě $z = 600$. Výpočet provedeme pomocí funkce `pbinom()`.

```
48 theta <- 0.4780; n <- 1200
49 1 - pbinom(q = 600, size = n, prob = theta) # 0,06007658
```

Pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vír* vyskytne nejvýše u 575 mužů, tj. $\Pr(Z_{1200} \leq 575)$, odpovídá hodnotě distribuční funkce $F(z)$ v bodě $z = 575$. Tuto hodnotu vypočítáme příkazem `pbinom()`.

```
50 pbinom(q = 575, size = n, prob = theta) # 0,5438802
```

Pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vír* vyskytne alespoň u 360 a nejvýše u 560 mužů, tj. $\Pr(360 \leq Z_{1200} \leq 560)$, vypočítáme tak, že od pravděpodobnosti, že se vzor *vír* vyskytne nejvýše u 560 mužů, odečteme pravděpodobnost, že se vzor *vír* vyskytne nejvýše u 359 mužů. Obě pravděpodobnosti jsou hodnotami distribuční funkce $F(z)$ v bodě $z = 560$, resp. v bodě $z = 359$ a vypočítáme je příkazem `pbinom()`.

```
51 pbinom(q = 560, size = n, prob = theta) - pbinom(q = 359, size = n, prob = theta) #
    0,2245673
```

Pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vír* vyskytne vícekrát než kterýkoli jiný vzor, je 0,0601 (6,01 %). Pravděpodobnost, že v náhodném výběru se vzor *vír* vyskytne nejvýše u 575 mužů, je 0,5439 (54,39 %). Pravděpodobnost, že v náhodném výběru se vzor *vír* vyskytne alespoň u 360 a nejvýše u 560 mužů, je 0,2246 (22,46 %).

Nyní si zadané pravděpodobnosti (a), (b) a (c) vypočítáme přibližně s využitím Moivreovy-Laplaceovy věty pomocí standardizovaného normálního rozdělení. Nejprve je třeba ověřit splnění podmínek dobré aproximace. První podmínka dobré aproximace je splněna, neboť

$$\frac{1}{n+1} < \vartheta < \frac{n}{n+1}$$

$$\frac{1}{1200+1} < 0,4780 < \frac{1200}{1200+1}$$

$$0,0008326 < 0,4780 < 0,9992.$$

```
52 1 / (n + 1) # 0,0008326395
53 n / (n + 1) # 0,9991674
```

Rovněž druhá podmínka dobré aproximace je splněna, neboť $n\vartheta(1-\vartheta) = 1200 \times 0,4780 \times (1-0,4780) = 299,4192 > 9$.

```
54 n * theta * (1 - theta) # 299,4192
```

Podle Moivreovy-Laplaceovy věty, pokud náhodná veličina $Z_n = \sum_{i=1}^n X_i \sim \text{Bi}(n, \vartheta)$, potom náhodná veličina $U = \frac{Z_n - n\vartheta}{\sqrt{n\vartheta(1-\vartheta)}} \approx N(0, 1)$. V našem případě náhodná veličina $Z_{1200} = \sum_{i=1}^{1200} X_i \sim \text{Bi}(1200; 0,4780)$, a tedy náhodná veličina $U = \frac{Z_{1200} - 1200 \times 0,4780}{\sqrt{1200 \times 0,4780 \times (1-0,4780)}} = \frac{Z_{1200} - 573,6}{17,3037} \approx N(0, 1)$. Tohoto poznatku využijeme při přibližném výpočtu zadaných pravděpodobností (a), (b) a (c).

Přibližná pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vír* vyskytne vícekrát než kterýkoli jiný vzor, tj. alespoň u 601 mužů, vypočítáme tak, že od jedné odečteme přibližnou pravděpodobnost, že se vzor *vír* vyskytne nejvýše u 601 mužů, která odpovídá hodnotě distribuční funkce $\Phi(u)$ rozdělení $N(0, 1)$ v bodě $u = \frac{601-573,6}{17,3037} = 1,5835$. Výpočet provedeme pomocí funkce `pnorm()`.

```
55 u <- (601 - n * theta) / sqrt(n * theta * (1 - theta)) # 1,583473
56 1 - pnorm(q = u, mean = 0, sd = 1) # 0,05665682
```

Přibližná pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vir* vyskytne nejvýše u 575 mužů, odpovídá hodnotě distribuční funkce $\Phi(u)$ rozdělení $N(0, 1)$ v bodě $u = \frac{575-573,6}{17,3037} = 0,0809$. Tuto hodnotu vypočítáme příkazem `pnorm()`.

```
57 u <- (575 - n * theta) / sqrt(n * theta * (1 - theta)) # 0,08090739
58 pnorm(q = u, mean = 0, sd = 1) # 0,5322422
```

Přibližná pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vir* vyskytne alespoň u 360 a nejvýše u 560 mužů, vypočítáme tak, že od přibližné pravděpodobnosti, že se vzor *vir* vyskytne nejvýše u 560 mužů, odečteme přibližnou pravděpodobnost, že se vzor *vir* vyskytne nejvýše u 360 mužů. Obě pravděpodobnosti jsou hodnotami distribuční funkce $\Phi(u)$ rozdělení $N(0, 1)$ v bodě $u = \frac{560-573,6}{17,3037} = -0,7860$, resp. v bodě $u = \frac{360-573,6}{17,3037} = -12,3442$ a vypočítáme je příkazem `pnorm()`.

```
59 u1 <- (560 - n * theta) / sqrt(n * theta * (1 - theta)) # -0,7859575
60 u2 <- (360 - n * theta) / sqrt(n * theta * (1 - theta)) # -12,34416
61 pnorm(q = u1, mean = 0, sd = 1) - pnorm(q = u2, mean = 0, sd = 1) # 0,2159462
```

Přibližná pravděpodobnost, že v náhodném výběru 1200 mužů z populace Valmíkis se vzor *vir* vyskytne vícekrát než kterýkoli jiný vzor, je 0,0567 (5,67%). Přibližná pravděpodobnost, že v náhodném výběru se vzor *vir* vyskytne nejvýše u 575 mužů, je 0,5322 (53,22%). Přibližná pravděpodobnost, že v náhodném výběru se vzor *vir* vyskytne alespoň u 360 a nejvýše u 560 mužů, je 0,2159 (21,59%).

Přibližné výsledky si vzájemně porovnáme s výsledky vypočítanými pomocí asymptotického rozdělení (viz tabulka 6.1).

Tabulka 6.1: Výsledné pravděpodobnosti výskytu dermatoglyfického vzoru *vir* v náhodném výběru 1200 mužů z populace Valmíkis vypočítané (i) pomocí asymptotického rozdělení; (ii) na základě aproximace tohoto rozdělení pomocí Moivreovy-Laplaceovy věty

	výpočet pomocí asymptotického rozdělení	přibližný výpočet
(a)	0.0601	0.0567
(b)	0.5439	0.5322
(c)	0.2246	0.2159

Z tabulky 6.1 vidíme, že pravděpodobnosti vypočítané pomocí asymptotického rozdělení se od přibližných pravděpodobností vypočítaných za předpokladu standardizovaného normálního rozdělení s využitím Moivreovy-Laplaceovy věty liší v hodnotách na druhém desetinném místě. Výsledky přibližného výpočtu jsou dostatečně blízké výsledkům získaným pomocí asymptotického rozdělení. ★

Příklad 6.8. Neřešený příklad

Pravděpodobnost výskytu epigenetického znaku *sutura metopica* v moderní japonské populaci je $p_j = 0,0910$ (Mouri, 1976). Za předpokladu, že náhodná veličina X popisuje výskyt epigenetického znaku *sutura metopica* u jednoho jedince z moderní japonské populace, vypočítejte pravděpodobnost, že v náhodném výběru 9000 jedinců z moderní japonské populace se epigenetický znak *sutura metopica* vyskytne (a) nejvýše u desetiný jedinců; (b) alespoň u 850 a nejvýše u 1012 jedinců; (c) alespoň u 825 jedinců. Zadané pravděpodobnosti vypočítejte (i) pomocí vhodného rozdělení; (ii) přibližně na základě aproximace tohoto rozdělení pomocí Moivreovy-Laplaceovy věty. Výsledky vzájemně porovnejte.

Výsledky: $Z_{9000} \sim \text{Bi}(9000; 0,0910)$; (i-a) $\Pr(Z_{9000} \leq 900) = 0,9984$; (i-b) $\Pr(850 \leq Z_{9000} \leq 1012) = 0,1321$; (i-c) $\Pr(Z_{9000} \geq 825) = 0,4183$; první podmínka dobré aproximace je splněna ($0,0001111 < 0,0910 < 0,9999$), druhá podmínka dobré aproximace je splněna ($744,471 > 9$), $U = \frac{Z_{9000}-819}{27,285} \approx N(0, 1)$; (ii-a) $\Pr(Z_{9000} \leq 900) \approx 0,9985$; (ii-b) $\Pr(850 \leq Z_{9000} \leq 1012) \approx 0,1279$; (ii-c) $\Pr(Z_{9000} \geq 825) \approx 0,4130$; výsledky přibližného výpočtu jsou dostatečně blízké výsledkům získaným pomocí asymptotického rozdělení (liší se v hodnotách na druhém až čtvrtém desetinném místě). ★