

## 4 Náhodné veličiny

### 4.1 Diskrétní náhodné veličiny

#### Alternativní rozdělení $\text{Alt}(p)$

- Jeden Bernoulliho pokus  $X$ :
  - $X = 1 \dots$  událost nastala;  $X = 0 \dots$  událost nenastala;
  - $\Pr(X = 1) = p$
  - $\Pr(X = 0) = 1 - p = q$
- Alternativní rozdělení:
  - $X \dots$  výskyt sledované události v jednom Bernoulliho pokusu, přičemž pravděpodobnost nastání události v tomto pokusu je vyjádřena parametrem  $p$ .
  - $X \sim \text{Alt}(p)$ .
  - $\boldsymbol{\theta} = (p)^T$
  - pravděpodobnostní funkce:

$$p(x) = p^x(1 - p)^{1-x} \quad x = 0, 1; \quad (1)$$

- vlastnosti:  $E[X] = p$ ;  $\text{Var}[X] = p(1 - p)$
- $\text{dbinom}(x, 1, p)$ ,  $\text{pbinom}(x, 1, p)$

#### Příklad 4.1. Popis reálné situace pomocí alternativního rozdělení

Mějme datový soubor 09-one-sample-probability-sutmet.txt obsahující údaje o výskytu epigenetického znaku *sutura metopica* na lebkách Ainů z ostrova Hokaido (více informací viz sekce ??). Údaje o výskytu epigenetického znaku jsou také k dispozici v tabulce 1.

Tabulka 1: Údaje o výskytu epigenetického znaku *sutura metopica* na lebkách Ainů z ostrova Hokaido

Populace	Výskyt <i>sutura metopica</i> ( $X$ )		$\Sigma$
	Ano	Ne	
Ainové	6	178	184

Nechť náhodná veličina  $X$  popisuje výskyt epigenetického znaku *sutura metopica* na lebkách Ainů z ostrova Hokaido. Nalezněte rozdělení náhodné veličiny  $X$  a odhadněte hodnoty parametrů tohoto rozdělení.

#### Řešení příkladu 4.1

Nejprve se zamyslíme nad tím, které rozdělení by co nejlépe popisovalo náhodnou veličinu  $X$ . V rámci studie jsme zkoumali lebky  $M = 184$  Ainů, přičemž u každé lebky jsme si zaznamenali, zda byl na ní přítomen výskyt epigenetického znaku *sutura metopica*. Náhodná veličina  $X$  tedy nabývá pouze dvou hodnot, a sice  $X = 0$  v případě, že na lebce nebyl epigenetický znak přítomný, nebo  $X = 1$  v případě, že na lebce byl epigenetický znak přítomný. Proto náhodná veličina  $X$  pochází z alternativního rozdělení, tj.  $X \sim \text{Alt}(p)$ . Zbývá odhadnout hodnotu parametru  $p$  popisující pravděpodobnost výskytu epigenetického znaku *sutura metopica* na lebkách Ainů z ostrova Hokaido.

Odhad parametru  $p$  spočítáme jako podíl počtu výskytů epigenetického znaku *sutura metopica* na lebkách Ainů (viz čitatel vzorce 2, kde  $n$  zastupuje počet výskytů *sutura metopica* (0 nebo 1) a  $m_{\text{observed}}$  uvádí, na kolika lebkách byl nulový počet ( $n = 0$ ) výskytů *sutura metopica*, či na kolika lebkách byl jeden ( $n = 1$ ) výskyt *sutura metopica*) ku celkovému počtu zkoumaných lebek (viz jmenovatel vzorce 2).

$$\hat{p} = \frac{\sum_{n=0}^1 nm_{\text{observed}}}{M} = \frac{0 \times 176 + 1 \times 6}{184} = \frac{6}{184} = 0.0326087 \doteq 0.03261. \quad (2)$$

```
1 M <- 184
2 n <- 0:1
3 m.obs <- c(176, 6)
4 p <- sum(n * m.obs) / M # 0.0326087
```

**Interpretace výsledků:** Náhodnou veličinu  $X$  popisující výskyt epigenetického znaku *sutura metopica* na lebkách Ainů z ostrova Hokaido modelujeme pomocí alternativního rozdělení s parametrem  $p$ , tj.  $X \sim \text{Alt}(p)$ , kde  $p = 0.03261$ . Pravděpodobnost výskytu epigenetického znaku *sutura metopica* u populace Ainů z ostrova Hokaido je 3.26%.

#### Příklad 4.2. Výpočet pravděpodobností za předpokladu alternativního rozdělení

Za předpokladu, že náhodná veličina  $X$  popisující výskyt epigenetického znaku *sutura metopica* u populace Ainů z ostrova Hokaido pochází z alternativního rozdělení a parametrem  $p = 0.03261$ , tj.  $X \sim \text{Alt}(0.03261)$  vypočítejte pravděpodobnost, výskytu epigenetického znaku *sutura metopica* u populace Ainů; (b) pravděpodobnost absence epigenetického znaku *sutura metopica* u populace Ainů; (c) pravděpodobnost nejvýše žádného výskytu epigenetického znaku *sutura metopica*; (d) pravděpodobnost nejvýše jednoho výskytu epigenetického znaku *sutura metopica*.

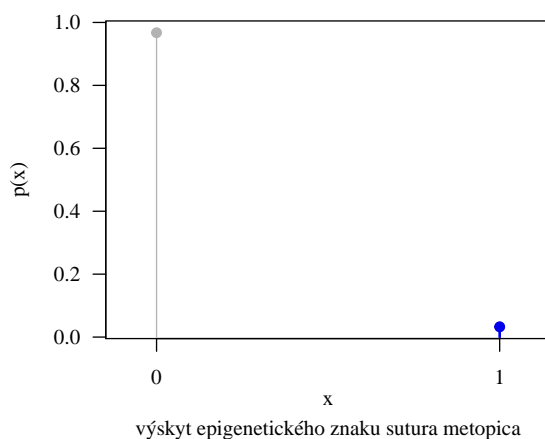
#### Řešení příkladu 4.2

Ze vzorce 1 víme, že pravděpodobnostní funkce alternativního rozdělení má tvar

$$p(x) = p^x(1-p)^{1-x},$$

kde v našem případě  $p = 0.03261$ .

- (a) Začneme výpočtem pravděpodobnosti výskytu epigenetického znaku *sutura metopica* u populace Ainů. Tuto pravděpodobnost si nejprve vizualizujeme (viz obrázek 1).



Obrázek 1: Vizualizace pravděpodobnosti výskytu epigenetického znaku *sutura metopica* u populace Ainů

Z obrázku 1 je krásně viditelné, že naším úkolem je najít hodnotu pravděpodobnostní funkce  $p(x)$  v hodnotě  $x = 1$ .

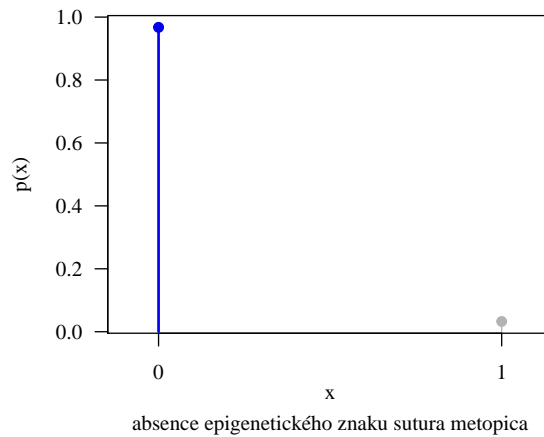
$$\begin{aligned} \Pr(X = 1) &= 0.0326087^1 \times (1 - 0.0326087)^{1-1} = 0.0326087^1 \times 0.9673913^0 = 0.0326087 \times 1 = \\ &= 0.0326087 \doteq 0.03261. \end{aligned}$$

```
5 x <- 1
6 p ^ (x) * (1 - p) ^ (1 - x) # 0.0326087
```

**Interpretace výsledků:** Pravděpodobnost výskytu epigenetického znaku *sutura metopica* v populaci Ainů ostrova Hokaido je 3.26%.

*Poznámka:* Všimněme si, že uvedený výpočet jsme vůbec provádět nemuseli. Pravděpodobnost výskytu epigenetického znaku *sutura metopica* je stejně jako hodnota parametru  $p$ , a to proto, že parametr  $p$  je sám pravděpodobností výskytu epigenetického znaku *sutura metopica*. Výpočet jsme prováděli pouze k procvičení výpočtu pravděpodobnostní funkce  $p(x)$  alternativního rozdělení.

- (b) Nyní se zaměříme na výpočet pravděpodobnosti absence epigenetického znaku *sutura metopica* u populace Ainů. Tuto pravděpodobnost si opět nejprve vizualizujeme (viz obrázek 2).



Obrázek 2: Vizualizace pravděpodobnosti absence epigenetického znaku *sutura metopica* u populace Ainů

Z obrázku 2 je zjevné, že naším úkolem je najít hodnotu pravděpodobnostní funkce  $p(x)$  v hodnotě  $x = 0$ .

$$\begin{aligned} \Pr(X = 0) &= 0.0326087^0 \times (1 - 0.0326087)^{1-0} = 0.0326087^0 \times 0.9673913^1 = 1 \times 0.9673913 = \\ &= 0.9673913 \doteq 0.9674. \end{aligned}$$

```
7 x <- 0
8 p ^ (x) * (1 - p) ^ (1 - x) # 0.9673913
```

**Interpretace výsledků:** Pravděpodobnost absence epigenetického znaku *sutura metopica* v populaci Ainů ostrova Hokaido je 96.74%.

*Poznámka:* Všimněme si, že uvedený výpočet jsme opět vůbec provádět nemuseli. Pravděpodobnost absence epigenetického znaku *sutura metopica* jsme mohli získat přímo, odečtením pravděpodobnosti výskytu epigenetického znaku *sutura metopica*  $p$  od hodnoty 1, tj.  $1 - p = 1 - 0.0326087 = 0.9673913$ . Výpočet jsme prováděli pouze k procvičení výpočtu pravděpodobnostní funkce  $p(x)$  alternativního rozdělení.

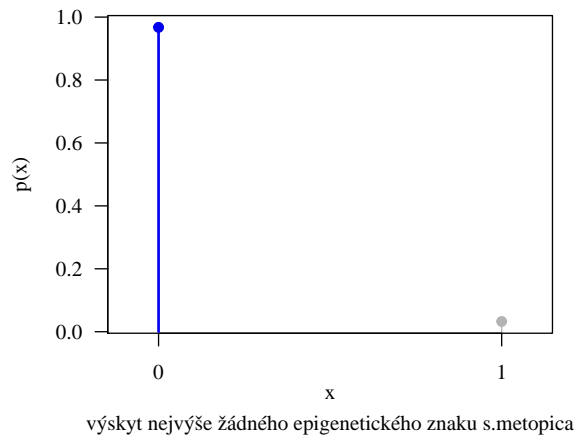
- (c) Nyní se zaměříme na výpočet nejvýše žádného výskytu epigenetického znaku *sutura metopica* u populace Ainů. Nejvýše žádný výskyt znamená, že náhodná veličina  $X$  nabývá nejvýše hodnoty 0, tj. ze zadání máme za úkol vypočítat  $\Pr(X \leq 0)$ , tedy hodnotu distribuční funkce  $F(x)$  v hodnotě  $x = 0$ . Tuto pravděpodobnost si nejprve vizualizujeme (viz obrázek 3).

Z obrázku 3 je zjevné, že naším úkolem bude finálně opět nalezení hodnoty pravděpodobnostní funkce  $p(x)$  v hodnotě  $x = 0$ . K pochopení toho, jak jsme se z distribuční funkce  $F(x)$  dostali k pravděpodobnostní funkci  $p(x)$  stačí, když si uvědomíme, že nejvýše žádný výskyt *sutura metopica* znamená prostě žádný výskyt *sutura metopica*, protože nic menšího než to, že se epigenetický znak na lebce nevyskytuje, neexistuje. Tj.  $\Pr(X \leq 0) = \Pr(X = 0)$ .

$$\Pr(X \leq 0) = \Pr(X = 0) = 0.9673913 \doteq 0.9674.$$

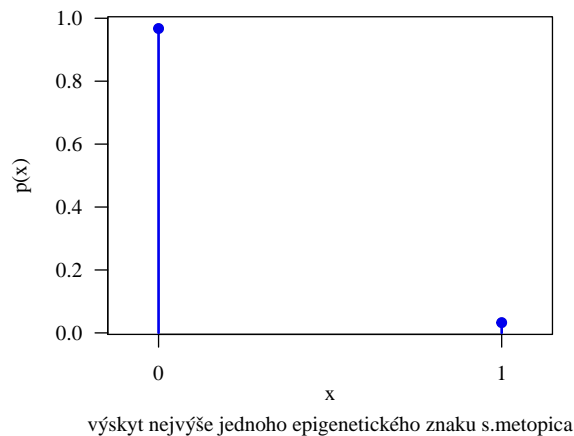
```
9 x <- 0
10 p ^ (x) * (1 - p) ^ (1 - x) # 0.9673913
```

**Interpretace výsledků:** Pravděpodobnost nejvýše žádného výskytu epigenetického znaku *sutura metopica* v populaci Ainů ostrova Hokaido je 96.74%.



Obrázek 3: Vizualizace pravděpodobnosti nejvýše žádného výskytu epigenetického znaku *sutura metopica* u populace Ainů

- (d) Nakonec se zaměříme na výpočet nejvýše jednoho výskytu epigenetického znaku *sutura metopica* u populace Ainů. Nejvýše jeden výskyt znamená, že náhodná veličina  $X$  nabývá nejvýše hodnoty 1, tj. ze zadání máme za úkol vypočítat  $\Pr(X \leq 1)$ , tj. hodnotu distribuční funkce  $F(x)$  v hodnotě  $x = 1$ . Tuto pravděpodobnost si nejprve vizualizujeme (viz obrázek 4).



Obrázek 4: Vizualizace pravděpodobnosti nejvýše jednoho výskytu epigenetického znaku *sutura metopica* u populace Ainů

Z obrázku 4 je zřejmé, že  $\Pr(X \leq 1) = \Pr(X = 0) + \Pr(X = 1)$ .

$$\Pr(X \leq 1) = \Pr(X = 0) + \Pr(X = 1) = 0.9673913 + 0.0326087 = 1.$$

```
11 x <- 0:1
12 sum(p ^ (x) * (1 - p) ^ (1 - x)) # 1
```

**Interpretace výsledků:** Pravděpodobnost nejvýše jednoho výskytu epigenetického znaku *sutura metopica* v populaci Ainů ostrova Hokaido je 100.00%.

*Poznámka:* K pochopení toho, že výsledná pravděpodobnost nejvýše jednoho výskytu epigenetického znaku *sutura metopica* v populaci Ainů vyšla rovna 100%, stačí, když si uvědomíme, že jiná situace, než výskyt

žádného nebo jednoho epigenetického znaku *sutura metopica* na lebce nastat nemůže. Tedy pokud prozkoumáme lebku, je 100% jisté, že se na ní *sutura metopica* buď vůbec nevyskytne, nebo vyskytne právě jednou. Celkově je tedy jisté, že se na lebce epigenetický znak *sutura metopica* vyskytne nejvýše jednou.

### Příklad 4.3. Graf pravděpodobnostní funkce a distribuční funkce alternativního rozdělení

Zaměřte se nyní blíže na tvar alternativního rozdělení  $\text{Alt}(0.03261)$ . Nakreslete graf pravděpodobnostní funkce  $p(x)$  a graf distribuční funkce  $F(x)$  tohoto rozdělení.

#### Řešení příkladu 4.3

Začneme s vykreslením grafu pravděpodobnostní funkce  $p(x)$ . Do proměnné `px` nejprve vložíme hodnoty pravděpodobnostní funkce alternativního rozdělení  $p(x) = \Pr(X = x)$  pro  $x = 0, 1$ , které vypočítáme analogicky, jako v předchozím příkladu 4.2. Samotný graf potom vykreslíme příkazem `plot()` s argumentem `type = 'h'`, který zajistí vykreslení vertikálních čar v hodnotách 0 a 1 na ose  $x$  a s délkou odpovídající hodnotám pravděpodobnostní funkce  $p(x)$ ,  $x = 0, 1$ . Argumentem `xlab = ""` v rámci příkazu `plot()` zamezíme vypsání popisku osy  $x$ . Dále do grafu doplníme body (`points()`) ve výšce hodnot funkce  $p(x)$ . Popisek osy  $x$  vykreslíme samostatně příkazem `mtext()` na pozici pod graf (`side = 1`) na řádek 2.1 (`line`). Nakonec do grafu doplníme druhý popisek uvádějící hodnotu parametru  $p$ . Text popisku vygenerujeme pomocí kombinace funkcí `bquote()` a `paste()`. Uvnitř funkce `paste()` je vložena syntaxe popisku `p == .(round(p, 4))`, která nejprve vypíše písmeno  $p$ , následně znaménko rovnosti, a nakonec vyhodnocení proměnné `p` zaokrouhlené na čtyři desetinná místa, tj. 0.03261.

```

13 x    <- 0 : 1
14 p    <- 6 / 184
15 px   <- p ^ x * (1 - p) ^ (1 - x)
16 plot(x, px, type = 'h', ylab = 'p(x)', xlab = '', las = 1)
17 points(x, px, col = 'blue2', pch = 19)
18 mtext('x', side = 1, line = 2.1)
19 mtext(bquote(paste(p == .(round(p, 4))))), side = 1, line = 3.2)


```

Prvním krokem pro vykreslení grafu distribuční funkce  $F(x)$  je vytvoření vektoru  $Fx$  s hodnotami distribuční funkce alternativního rozdělení  $F(x) = \Pr(X \leq x)$  pro  $x = 0, 1$ . Z předchozího příkladu 4.2 již víme, že  $\Pr(X \leq 0) = 0.9673913$  a  $\Pr(X \leq 1) = 1$ . Konstrukci grafu zahájíme vykreslením prázdného grafu (příkaz `plot()` s argumentem `type = 'n'`) s rozsahem měřítka osy  $x$  od -1 do 2 (`xlim`) a rozsahem měřítka osy  $y$  od 0 do 1 (`ylim`). Argumentem `xlab = ""` potlačíme vypsání popisku osy  $x$ . Dále do grafu dokreslíme horizontální úsečky délky 1 začínající vždy v bodě  $[x, F(x)]$  a končící v bodě  $[x+1, F(x)]$ . K tomu použijeme funkci `segments()`, u níž povinně specifikujeme čtyři parametry `x0`, `x1`, `y0`, `y1` určující postupně  $x$ -ovou souřadnici počátečního bodu,  $x$ -ovou souřadnici konečného bodu,  $y$ -ovou souřadnici počátečního bodu a  $y$ -ovou souřadnici konečného bodu. Pokud za argumenty `x0`, `x1`, `y0`, `y1` dosadíme vektory obsahující všechny  $x$ -ové, resp.  $y$ -ové souřadnice počátečních, resp. konečných bodů, vykreslí se všechny horizontální úsečky najednou. Příkazem `arrows()` dokreslíme do grafu horizontální šipku umístěnou vlevo dole a směřující doleva, s počátečním bodem  $[0, 0]$  a koncovým bodem  $[-1, 0]$ . Argumentem `length` zmenšíme velikost zobáčku šipky. Opětovným použitím příkazu `arrows()` vykreslíme nyní horizontální šipku umístěnou vpravo nahoře, směřující doprava s počátečním bodem  $[1, 1]$  a koncovým bodem  $[2, 1]$ . Následně do grafu dokreslíme body značící skok z hodnoty  $F(x)$  do hodnoty  $F(x + 1)$ . Na levém konci každé úsečky vykreslíme bod (`points()`, `pch = 19`) se souřadnicí  $[x, F(x)]$  s modrým okrajem a modrým vnitřkem (`col`) značící, že levý krajní bod každé úsečky má hodnotu distribuční funkce  $F(x)$ . Oproti tomu, na pravém konci každé úsečky vykreslíme bod (`points()`, `pch = 21`) se souřadnicí  $[x, F(x-1)]$  s černým okrajem (`bg`) a bílým vnitřkem (`col`) značící, že pravý krajní bod každé úsečky nepatří mezi body s hodnotou distribuční funkce  $F(x)$ . Nakonec dvojnásobným využitím příkazu `mtext()` doplníme do grafu popisek osy  $x$  a popisek s hodnotou parametru  $p$ .

```

20 Fx <- c(1 - p, 1)
21 plot(x, Fx, xlab = '', ylab = 'F(x)',
22       xlim = c(-1, 2), ylim = c(0, 1), type = 'n', las = 1)
23 segments(x, Fx, x + 1, Fx) # vodorovne cary
24 arrows(0, 0, -1, 0, length = 0.1) # dolni sipka
25 arrows(N, 1, 2, 1, length = 0.1) # horni sipka
26 points(x, Fx, col = 'blue2', pch = 19) # plne body
27 points(x, c(0, Fx[1 : N]), pch = 21, bg = 'white', col = 'black') # prazdne body
28 mtext('x', side = 1, line = 2.1)
29 mtext(bquote(paste(p == .(round(p, 4))))), side = 1, line = 3.2)

```



Obrázek 5: Pravděpodobnostní funkce (vlevo) a distribuční funkce (vpravo) alternativního rozdělení Alt(0.03261)

#### Příklad 4.4. Popis reálné situace pomocí alternativního rozdělení

Mějme datový soubor `08-one-sample-probability-sexratio.txt` obsahující údaje o pohlaví novorozenců (proměnná `sex`; `m` – chlapec, `f` – děvče) narozených v krajské nemocnici v průběhu jednoho roku (Alánová, 2008), více informací viz sekce ??). Nechtě náhodná veličina  $X$  popisuje narození děvčete. Nalezněte rozdělení náhodné veličiny  $X$  a odhadněte hodnoty parametrů tohoto rozdělení.

#### Řešení příkladu 4.4

Nejprve načteme datový soubor (`read.delim()`) a vypíšeme první tři řádky tabulky (`head()`). Následně z datové tabulky vybereme pomocí dolarové syntaxe sloupec obsahující údaje o pohlaví (`data$sex`) a odstraníme z něj případná chybějící pozorování (`na.omit()`). Nakonec zjistíme rozsah náhodného výběru (`length()`) a počet narozených dívek a chlapců (`table()`).

```
30 data <- read.delim('00-Data//08-one-sample-probability-sexratio.txt')
31 head(data, n = 3)
```

```
sex
1  m
2  m
3  f
```

32  
33  
34  
35

```
36 sex <- na.omit(data$sex)
37 length(sex) # 1403
```

```
[1] 1403
```

38

```
39 table(sex)
```

```
sex
f  m
674 729
```

40  
41  
42

Datový soubor obsahuje údaje o pohlaví  $M = 1403$  novorozenců. Celkem se v krajské nemocnici za jeden rok narodilo 674 děvčat a 729 chlapců.

Za předpokladu, že náhodná veličina  $X$  popisuje narození děvčete, nabývá tato veličina pouze dvou hodnot, a sice  $X = 1$  v případě, že se narodilo děvče (`sex == 'f'`), nebo  $X = 0$  v případě, že se narodil chlapec (`sex == 'm'`). Náhodná veličina  $X$  tedy pochází z alternativního rozdělení, tj.  $X \sim \text{Alt}(p)$ . Zbývá odhadnout hodnotu parametru  $p$  popisující pravděpodobnost narození děvčete. Odhad parametru  $p$  spočítáme jako podíl počtu narozených dívek ku celkovému počtu narozených dětí  $M$ .

$$\hat{p} = \frac{\sum_{n=0}^1 nm_{\text{observed}}}{M} = \frac{0 \times 729 + 1 \times 674}{1403} = \frac{674}{1403} = 0.4803991 \doteq 0.4804. \quad (3)$$

```
43 n <- 0:1
44 m.obs <- c(729, 674)
45 M <- sum(m.obs)
46 p <- sum(n * m.obs) / M # 0.4803991
```

**Interpretace výsledků:** Náhodnou veličinu  $X$  popisující narození děvčete modelujeme pomocí alternativního rozdělení s parametrem  $p$ , tj.  $X \sim \text{Alt}(p)$ , kde  $p = 0.4804$ . Pravděpodobnost narození děvčete je 48.04%.



### Příklad 4.5. Výpočet pravděpodobností za předpokladu alternativního rozdělení

Za předpokladu, že náhodná veličina  $X$  popisující narození děvčete pochází z alternativního rozdělení a parametrem  $p = 0.4804$ , tj.  $X \sim \text{Alt}(0.4804)$  vypočítejte pravděpodobnost narození děvčete; (b) pravděpodobnost narození chlapce; (c) pravděpodobnost narození děvčete nebo chlapce.


### Řešení příkladu 4.5

Ze vzorce 1 víme, že pravděpodobnostní funkce alternativního rozdělení má tvar

$$p(x) = p^x(1 - p)^{1-x},$$

kde v našem případě  $p = 0.4804$ .

- (a) Začneme výpočtem pravděpodobnosti narození děvčete. Tuto pravděpodobnost si nejprve vizualizujeme (viz obrázek 6).



Obrázek 6: Vizualizace pravděpodobnosti narození děvčete

Z obrázku 6 je krásně viditelné, že naším úkolem je najít hodnotu pravděpodobnostní funkce  $p(x)$  v hodnotě  $x = 1$ .


$$\begin{aligned} \Pr(X = 1) &= 0.4803991^1 \times (1 - 0.4803991)^{1-1} = 0.4803991^1 \times 0.5196009^0 = 0.4803991 \times 1 = \\ &= 0.4803991 \doteq 0.4804. \end{aligned}$$

```
47 x <- 1
48 p ^ (x) * (1 - p) ^ (1 - x) # 0.4803991
```

**Interpretace výsledků:** Pravděpodobnost narození děvčete je 48.04%.

*Poznámka:* Uvedený výpočet jsme vůbec provádět nemuseli. Pravděpodobnost narození děvčete je stejná jako hodnota parametru  $p$ , neboť parametr  $p$  je sám pravděpodobností narození děvčete. Výpočet jsme prováděli pouze k procvičení výpočtu pravděpodobnostní funkce  $p(x)$  alternativního rozdělení.

- (b) Nyní se zaměříme na výpočet pravděpodobnosti narození chlapce. Tuto pravděpodobnost si opět nejprve vizualizujeme (viz obrázek 7). Vzhledem k tomu, že náhodná veličina  $X$  popisuje narození děvčete, odpovídá narození chlapce situaci, kdy náhodná veličina  $X = 0$ .



Obrázek 7: Vizualizace pravděpodobnosti narození chlapce

Z obrázku 7 je zřejmé, že naším úkolem je najít hodnotu pravděpodobnostní funkce  $p(x)$  v hodnotě  $x = 0$ .

$$\begin{aligned} \Pr(X = 0) &= 0.4803991^0 \times (1 - 0.4803991)^{1-0} = 0.4803991^0 \times 0.5196009^1 = 1 \times 0.5196009 = \\ &= 0.5196009 \doteq 0.5196009. \end{aligned}$$

```
49 x <- 0
50 p ^ (x) * (1 - p) ^ (1 - x) # 0.5196009
```

**Interpretace výsledků:** Pravděpodobnost narození chlapce je 51.96%.

*Poznámka:* Uvedený výpočet jsme opět provádět nemuseli. Z podstaty věci je zřejmé, že chlapec se narodil v případě, že se nenarodilo děvče. Proto pravděpodobnost narození chlapce lze vypočítat triviálně odečtením pravděpodobnosti narození děvčete od jedničky, tj.  $1 - 0.4803991 = 0.5196009$ . Podrobný výpočet jsme prováděli za účelem procvičení výpočtu pravděpodobnosti pomocí pravděpodobnostní funkce  $p(x)$ .

- (c) Nakonec se zaměříme na výpočet pravděpodobnosti narození děvčete nebo chlapce. Narození chlapce odpovídá situaci, kdy náhodná veličina  $X = 0$ , narození děvčete odpovídá situaci, kdy náhodná veličina  $X = 1$ . Výpočet pravděpodobnosti narození děvčete nebo chlapce tedy odpovídá pravděpodobnosti  $\Pr(X \leq 1)$ , což je hodnota distribuční funkce  $F(x)$  v hodnotě  $x = 1$ . Tuto pravděpodobnost si nejprve vizualizujeme (viz obrázek 8).

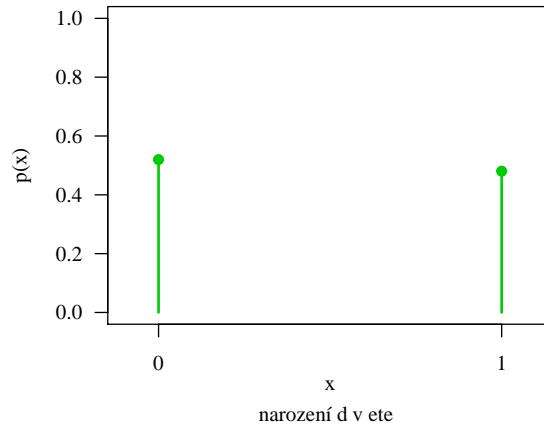
Z obrázku 8 je zřejmé, že pravděpodobnost narození děvčete nebo chlapce odpovídá součtu pravděpodobnosti narození chlapce a pravděpodobnosti narození děvčete, tj.  $\Pr(X \leq 1) = \Pr(X = 0) + \Pr(X = 1)$ .

$$\Pr(X \leq 1) = \Pr(X = 0) + \Pr(X = 1) = 0.5196009 + 0.4803991 = 1.$$

```
51 x <- 0:1
52 sum(p ^ (x) * (1 - p) ^ (1 - x)) # 1
```

**Interpretace výsledků:** Pravděpodobnost narození děvčete nebo chlapce je 100.00%.

*Poznámka:* Výsledná 100% pravděpodobnost narození děvčete nebo chlapce nás asi příliš nepřekvapí. Je zřejmé, že narodí-li se nový jedinec je jisté, že to bude buď chlapec nebo děvče.



Obrázek 8: Vizualizace pravděpodobnosti narození děvčete nebo chlapce

#### Příklad 4.6. Graf pravděpodobnostní funkce a distribuční funkce alternativního rozdělení

Zaměřte se nyní blíže na tvar alternativního rozdělení  $\text{Alt}(0.4804)$ . Nakreslete graf pravděpodobnostní funkce  $p(x)$  a graf distribuční funkce  $F(x)$  tohoto rozdělení.

#### Řešení příkladu 4.6

Začneme s vykreslením grafu pravděpodobnostní funkce  $p(x)$ . Do proměnné `px` nejprve vložíme hodnoty pravděpodobnostní funkce alternativního rozdělení  $p(x)$ , které vypočítáme analogicky, jako v předchozím příkladu 4.5. Základ grafu pravděpodobnostní funkce  $p(x)$  v podobě vertikálních čar s výškami odpovídajícími hodnotám  $p(x)$  v hodnotách  $x = 0, 1$  vykreslíme příkazem `plot()` s argumentem `type = 'h'`. V rámci příkazu `plot()` opět zakázeme vypsání popisku osy  $x$  (`xlab = ''`). Dále do grafu doplníme body (`points()`) ve výšce hodnot funkce  $p(x)$ . Nakonec do grafu doplníme popisek osy  $x$  a pod něj popisek uvádějící hodnotu parametru  $p$  (`mtext()`). Text popisku s hodnotou parametru  $p$  zaokrouhlenou na 4 desetinná místa (`round()`) vygenerujeme pomocí kombinace příkazů `bquote()` a `paste()`.

```

53 x <- 0 : 1
54 p <- 674 / 1403
55 px <- p ^ x * (1 - p) ^ (1 - x)
56 plot(x, px, type = 'h', ylab = 'p(x)', xlab = '', las = 1, ylim = c(0, 1))
57 points(x, px, col = 'green3', pch = 19)
58 mtext('x', side = 1, line = 2.1)
59 mtext(bquote(paste(p == .(round(p, 4)))), side = 1, line = 3.2)


```

Dále se zaměříme na vykreslení grafu distribuční funkce  $F(x)$ . Do proměnné `Fx` nejprve vložíme hodnoty distribuční funkce  $F(x)$  náhodné veličiny  $X$  popisující narození děvčete, tj.  $F(x) = \Pr(X \leq x)$  pro  $x = 0, 1$ . Analogicky jako v příkladu 4.3 platí i zde, že  $\Pr(X \leq 0) = \Pr(X = 0)$ , tj. pravděpodobnost, že se v jednom pokusu narodí nejvýše nula děvčat odpovídá pravděpodobnosti, že se v jednom pokusu nenarodí žádné děvče, (což odpovídá situaci, že se narodí chlapec). Dále  $\Pr(X \leq 1) = 1$  (viz předchozí příklad 4.5, (c)). Konstrukci grafu zahájíme vykreslením prázdného okna bez popisku osy  $x$  s rozsahem měřítka osy  $x$  od -1 do 2 a rozsahem měřítka osy  $y$  od 0 do 1 (příkaz `plot()` s argumentem `type = 'n'` a s vhodnou specifikací argumentů `xlab`, `xlim` a `ylim`). Následně do grafu dokreslíme horizontální úsečky délky 1 začínající vždy v bodě  $[x, F(x)]$  a končící v bodě  $[x+1, F(x)]$  (`segments()`). Dále do grafu dokreslíme horizontální šipku umístěnou vlevo dole a směřující doleva, s počátečním bodem  $[0, 0]$  a koncovým bodem  $[-1, 0]$  a horizontální šipku umístěnou vpravo nahoře, směřující doprava s počátečním bodem  $[1, 1]$  a koncovým bodem  $[2, 1]$  (`arrows()`). Následně na levý konec každé úsečky vykreslíme zelený plný bod se souřadnicí  $[x, F(x)]$  (příkaz `points()` s argumentem `pch = 19`) značící, že levý krajní bod každé úsečky má hodnotu distribuční funkce  $F(x)$ , a na pravý konec každé úsečky vykreslíme bod se souřadnicí  $[x, F(x-1)]$  s černým okrajem a bílým vnitřkem (příkaz `points()` s argumentem `pch = 21`) značící, že pravý krajní bod každé úsečky nepatří mezi body s hodnotou distribuční funkce  $F(x)$ . Nakonec dvojnásobným využitím příkazu `mtext()` doplníme do grafu popisek osy  $x$  a popisek s hodnotou parametru  $p$ .

```

60 Fx <- c(1 - p, 1)
61 plot(x, Fx, xlab = '', ylab = 'F(x)',
62      xlim = c(-1, 2), ylim = c(0, 1), type = 'n', las = 1)
63 segments(x, Fx, x + 1, Fx) # vodorovne cary
64 arrows(0, 0, -1, 0, length = 0.1) # dolni sipka
65 arrows(N, 1, 2, 1, length = 0.1) # horni sipka
66 points(x, Fx, col = 'green3', pch = 19) # plne body
67 points(x, c(0, Fx[1 : N]), pch = 21, bg = 'white', col = 'black') # prazdne body
68 mtext('x', side = 1, line = 2.1)
69 mtext(bquote(paste(p == .(round(p, 4))))), side = 1, line = 3.2)

```



Obrázek 9: Pravděpodobnostní funkce (vlevo) a distribuční funkce (vpravo) alternativního rozdělení Alt(0.4804)

## Binomické rozdělení $\text{Bin}(N, p)$

- $N$  Bernoulliho pokusů  $X_1, \dots, X_N$ :

- $X_i = 1 \dots$  událost nastala;  $X_i = 0 \dots$  událost nenastala;  $i = 1, \dots, N$ .
- $\Pr(X_i = 1) = p$
- $\Pr(X_i = 0) = 1 - p = q$

- Binomické rozdělení:

- $X \dots$  počet událostí v posloupnosti  $N$  nezávislých Bernoulliho pokusů, přičemž pravděpodobnost nastání události v každém pokusu je vyjádřena parametrem  $p$ .
- $\sum_{i=1}^N X_i = X \sim \text{Bin}(N, p)$ .
- $\theta = (N, p)$
- pravděpodobnostní funkce:

$$p(x) = \binom{N}{x} p^x (1-p)^{N-x} \quad x = 0, 1, \dots, N; \quad (4)$$

- vlastnosti:  $E[X] = Np$ ;  $\text{Var}[X] = Np(1-p)$
- $\text{dbinom}(x, N, p)$ ,  $\text{pbinom}(x, N, p)$

### Příklad 4.7. Popis reálné situace pomocí binomického rozdělení

V rámci studie poměru pohlaví u lidí z roku 1889 bylo na základě záznamů z nemocnic v Sasku zaznamenáno rozdělení počtu chlapců v čtrnáctičlenných rodinách. Mezi  $M = 6115$  rodinami s 12 dětmi byla pozorována početnost narozených chlapců. Údaje ze studie jsou uvedeny v tabulce 2. Více informací o datovém souboru a studii viz sekce ??.

Tabulka 2: Počet chlapců v 6115 rodinách s dvanácti dětmi

$n$	0	1	2	3	4	5	6	7	8	9	10	11	12	$\Sigma$
$m_{\text{observed}}$	3	24	104	286	670	1033	1343	1112	829	478	181	45	7	6115

Nechť náhodná veličina  $X$  popisuje počet chlapců v rodinách s dvanácti dětmi. Nalezněte rozdělení náhodné veličiny  $X$  a odhadněte hodnoty parametrů tohoto rozdělení.

### Řešení příkladu 4.7

Nejprve se zaměříme na nalezení rozdělení, který co nejlépe popisuje náhodnou veličinu  $X$ . Protože počet chlapců v rodině je vždy celé číslo, náhodná veličina  $X$  popisující počet chlapců v rodině je diskrétní náhodná veličina. Rozdělení náhodné veličiny  $X$  musíme tedy hledat mezi diskrétními rozděleními. Dále si uvědomme, že v rámci jedné rodiny máme celkem  $N = 12$  Bernoulliho pokusů  $X_i$ ,  $i = 1, \dots, 12$ , přičemž sledovanou událostí v jednom Bernoulliho pokusu je narození chlapce. Při narození každého z dvanácti dětí tedy buď událost nastala (narodil se chlapec;  $X_i = 1$ ,  $i = 1, \dots, 12$ ) nebo událost nenastala (narodilo se děvče;  $X_i = 0$ ,  $i = 1, \dots, 12$ ). Na základě všech výše uvedených indicií budeme o náhodné veličině  $X$  předpokládat, že pochází z binomického rozdělení, tj.  $X \sim (N, p)$ , kde  $N = 12$ . Zbývá odhadnout hodnotu parametru  $p$ .

Odhad parametru  $p$ , tj. odhad pravděpodobnosti narození chlapce v jednom náhodném pokusu, spočítáme jako podíl součtu všech chlapců v rodinách s dvanácti dětmi (viz čítec vzorce 5) ku celkovému počtu všech dětí v těchto rodinách (viz jmenovatel vzorce 5).

$$\hat{p} = \frac{\sum_{n=0}^N n m_{\text{observed}}}{NM} = \frac{0 \times 3 + 1 \times 24 + \dots + 11 \times 45 + 12 \times 7}{12 \times 6115} = \frac{38100}{73380} = 0.519215 \doteq 0.5192. \quad (5)$$

```

70 M      <- 6115
71 N      <- 12
72 n      <- 0 : N
73 m.obs  <- c(3, 24, 104, 286, 670, 1033, 1343, 1112, 829, 478, 181, 45, 7)
74 p      <- sum(n * m.obs) / (N * M)
75 round(p, 4)

```

76

```
[1] 0.5192
```

**Interpretace výsledků:** Náhodnou veličinu  $X$  popisující počet chlapců v rodinách s dvanácti dětmi modelujeme pomocí binomického rozdělení s parametry  $N$  a  $p$ , tj.  $X \sim \text{Bin}(N, p)$ , kde  $N = 12$  a  $p = 0.5192$ . Pravděpodobnost narození chlapce v rodinách s dvanácti dětmi je 51.92%.

#### Příklad 4.8. Porovnání pozorovaných a očekávaných početností binomického rozdělení

Na základě výše uvedené úvahy popisujeme počet chlapců v rodině s dvanácti dětmi pomocí binomického modelu  $\text{Bin}(12, 0.5192)$ . Nyní ověříme, zda jsme k popisu reálné situace zvolili vhodné rozdělení. Za předpokladu, že náhodná veličina  $X$  popisující počet chlapců v rodinách s dvanácti dětmi pochází z binomického rozdělení  $\text{Bin}(12, 0.5192)$ , odhadněte očekávané početnosti chlapců v těchto rodinách a porovnejte je s pozorovanými početnostmi.

#### Řešení příkladu 4.8

Za předpokladu, že  $X \sim \text{Bin}(12, 0.5192)$  stanovíme pravděpodobnosti, že se v rodině s dvanácti dětmi nenarodí žádný chlapec, narodí právě jeden chlapec, právě dva chlapci, atd. Výsledné pravděpodobnosti vynásobíme počtem rodin, tj. číslem 6115, čímž zjistíme, v kolika rodinách se za předpokladu  $X \sim \text{Bin}(12, 0.5192)$  nenarodí žádný chlapec, narodí jeden chlapec, narodí dva chlapci, atd. K vypočítání těchto pravděpodobností použijeme pravděpodobnostní funkci  $p(x)$ , kde  $x = 0, 1, \dots, 12$ . Hodnoty pravděpodobnostní funkce binomického rozdělení stanovíme příkazem `dbinom()`, kde prvním argumentem jsou hodnoty  $x = 0, 1, \dots, 12$ , druhý argument `size = 12` odpovídá počtu pokusů  $N$  a třetí argument `prob = 0.5192` odpovídá pravděpodobnosti  $p$  výskytu události v jednom pokusu. Vektor získaných pravděpodobností vynásobíme počtem rodin  $M = 6115$  a zaokrouhlíme na nula desetinných míst (`round()`). Pomocí příkazů `data.frame()` a `rbind()` vytvoříme tabulku pozorovaných a očekávaných četností.

```

77 p.exp  <- dbinom(0:12, size = N, prob = p)
78 m.exp  <- round(p.exp * 6115)
79 tab   <- data.frame(rbind(pozorovane = m.obs, ocekavane = m.exp))
80 names(tab) <- 0:12
81 tab

```

	0	1	2	3	4	5	6	7	8	9	10	11	12
pozorovane	3	24	104	286	670	1033	1343	1112	829	478	181	45	7
ocekavane	1	12	72	258	628	1085	1367	1266	854	410	133	26	2

82

83

84


Pozorované a očekávané četnosti porovnáme také graficky. Pomocí příkazu `plot()` s argumentem `type = 'h'` vykreslíme graf obsahující horizontální čáry červené barvy odpovídající pozorovaným četnostem `m.obs`. Příkazem `points()` doplníme do grafu červené body ve výšce pozorovaných četností. Příkazem `lines()` s argumentem `type = 'h'` vykreslíme přerušované horizontální čáry černé barvy odpovídající očekávaným četnostem `m.exp`. Příkazem `points()` doplníme do grafu černé body ve výšce očekávaných četností. Nakonec do grafu přidáme legendu funkcí `legend()`.

```

85 plot(0:12, m.obs, type = 'h', col = 'red', las = 1, ylim = c(0, 1400),
86      ylab = 'absolutní četnosti', xlab = 'počet starších sourozenců')
87 points(0:12, m.obs, pch = 19, col = 'red')
88 lines(0:12 + 0.2, m.exp, type = 'h', lty = 2)
89 points(0:12 + 0.2, m.exp, pch = 19)
90 legend('topright', pch = 19, col = c('red', 'black'),
91      legend = c('pozorované', 'očekávané'), bty = 'n')

```

Z obrázku 10 je zřejmé, že zvolené binomické rozdělení popisuje počet chlapců v rodině s 12 dětmi velmi dobře. Červené body reprezentující pozorované četnosti se drží blízko černých bodů reprezentující očekávané četnosti. Největší rozdíl nastává v počtu rodin se sedmi chlapci, kde pozorujeme o 154 méně rodin, než by teoreticky mělo být. Jde však o jedinou výraznější odchylku, která vzhledem k reálným datům není nikterak závažná.



Obrázek 10: Porovnání pozorovaných a očekávaných početností v binomickém modelu  $\text{Bin}(12, 0.5192)$

**Interpretace výsledků:** Z tabulky pozorovaných a očekávaných četností a na základě grafické vizualizace soudíme, že zvolené binomické rozdělení  $\text{Bin}(12, 0.5192)$  je vhodné k popisu počtu chlapců v rodině s dvanácti dětmi.

### Příklad 4.9. Výpočet pravděpodobností za předpokladu binomického rozdělení

Za předpokladu, že náhodná veličina  $X$  popisující počet chlapců v rodinách s dvanácti dětmi pochází z binomického rozdělení  $\text{Bin}(12, 0.5192)$  vypočítejte pravděpodobnost, že v rodině s dvanácti dětmi bude (a) právě devět chlapců; (b) nejvýše čtyři chlapci; (c) alespoň osm chlapců; (d) čtyři, pět, šest, nebo sedm chlapců.


#### Řešení příkladu 4.9

Ze vzorce 4 víme, že pravděpodobnostní funkce binomického rozdělení má tvar

$$p(x) = \binom{N}{x} p^x (1-p)^{N-x},$$

kde v našem případě  $N = 12$  a  $p = 0.5192$ .

- (a) Začneme výpočtem pravděpodobnosti, že v rodině s dvanácti dětmi bude právě devět chlapců. Tuto pravděpodobnost si nejprve vizualizujeme (viz obrázek 11).





Obrázek 11: Vizualizace pravděpodobnosti, že v rodině s dvanácti dětmi bude právě devět chlapců

Z obrázku 11 je krásně viditelné, že naším úkolem je najít hodnotu pravděpodobnostní funkce  $p(x)$  v hodnotě  $x = 9$ .

$$\begin{aligned} \Pr(X = 9) &= \binom{12}{9} \times 0.5192^9 \times (1 - 0.5192)^{12-9} = 220 \times 0.5192^9 \times 0.4808^3 \\ &= 0.06703911 \doteq 0.0670. \end{aligned}$$

*Poznámka:* Pro zopakování uvádíme, že člen ve tvaru  $\binom{n}{k}$  (čteme *n nad k*) je tzv. *kombinační číslo*. Každé kombinační číslo je možné vyjádřit ve tvaru  $\binom{n}{k} = \frac{n!}{k!(n-k)!}$ , kde pro  $n!$  (čteme *n faktorial*) platí, že  $n! = n \times (n-1) \times (n-2) \times \dots \times 2 \times 1$ . Zde na ukázkou uvádíme konkrétně výpočet kombinačního čísla  $\binom{12}{9}$ . Tj.

$$\binom{12}{9} = \frac{12!}{9!(12-9)!} = \frac{12!}{9! \times 3!} = \frac{12 \times 11 \times \dots \times 2 \times 1}{(9 \times 8 \times \dots \times 2 \times 1) \times (3 \times 2 \times 1)} = \frac{12 \times 11 \times 10}{3 \times 2 \times 1} = \frac{1320}{6} = 220.$$

Kombinační číslo lze vypočítat pomocí softwaru  prostřednictvím funkce `choose()`. Pravděpodobnost, že v rodině s dvanácti dětmi bude právě devět chlapců můžeme tedy přímo vypočítat pomocí softwaru  přepisem vzorce 4.

```
92 N <- 12
93 p <- 0.5192
94 x <- 9
95 choose(N, x) * p ^ x * (1 - p) ^ (N - x) # 0.06703911
```




K přímému výpočtu hodnoty pravděpodobnostní funkce  $p(x)$  binomického rozdělení můžeme použít funkci `dbinom()` implementovanou v softwaru  $\mathbb{R}$ . Prvním argumentem funkce bude hodnota  $x = 9$ , druhým argumentem počet pokusů  $N$  a třetím argumentem pravděpodobnost narození chlapce  $p$ .

```
96 dbinom(9, N, p) # 0.06703911
```

**Interpretace výsledků:** Pravděpodobnost, že v rodině s dvanácti dětmi bude právě devět chlapců, je 6.70%.

- (b) Nyní se zaměříme na výpočet pravděpodobnosti, že v rodině s dvanácti dětmi budou nejvýše čtyři chlapci. Situaci si opět nejprve vizualizujeme (viz obrázek 12).



Obrázek 12: Vizualizace pravděpodobnosti, že v rodině s dvanácti dětmi budou nejvýše čtyři chlapci

Z obrázku 12 je zřejmé, že tentokrát hledáme hodnotu distribuční funkce  $F(x)$  v hodnotě  $x = 4$ . Zároveň vidíme, že tuto hodnotu můžeme také vypočítat jako součet pravděpodobností funkcí  $p(x)$  v hodnotách  $x = 0, 1, 2, 3$  a 4.

$$\begin{aligned}
 \Pr(X \leq 4) &= \sum_{i=0}^4 \Pr(X = i) = \Pr(X = 0) + \Pr(X = 1) + \Pr(X = 2) + \Pr(X = 3) + \Pr(X = 4) \\
 &= \binom{12}{0} \times 0.5192^0 \times (1 - 0.5192)^{12-0} + \binom{12}{1} \times 0.5192^1 \times (1 - 0.5192)^{12-1} + \\
 &\quad + \binom{12}{2} \times 0.5192^2 \times (1 - 0.5192)^{12-2} + \binom{12}{3} \times 0.5192^3 \times (1 - 0.5192)^{12-3} + \\
 &\quad + \binom{12}{4} \times 0.5192^4 \times (1 - 0.5192)^{12-4} = \\
 &= 1 \times 0.5192^0 \times 0.4808^{12} + 12 \times 0.5192^1 \times 0.4808^{11} + 66 \times 0.5192^2 \times 0.4808^{10} + \\
 &\quad + 220 \times 0.5192^3 \times 0.4808^9 + 495 \times 0.5192^4 \times 0.4808^8 = \\
 &= 0.0001526067 + 0.001977539 + 0.01174513 + 0.04227726 + 0.1027211 = \\
 &= 0.1588736 \doteq 0.1589.
 \end{aligned}$$

Pravděpodobnost, že v rodině s dvanácti dětmi budou nejvýše čtyři chlaci můžeme vypočítat pomocí softwaru  $\mathbb{R}$  a to buď ručním přepisem,

```
97 x <- 0:4
98 sum(choose(N, x) * p ^ x * (1 - p) ^ (N - x)) # 0.1588736
```

nebo pomocí již známé funkce `dbinom()`, prostřednictvím které vypočítáme hodnoty pravděpodobnostních funkcí  $p(x)$  v hodnotách  $x = 0, 1, 2, 3$  a 4, jež následně sečteme příkazem `sum()`,

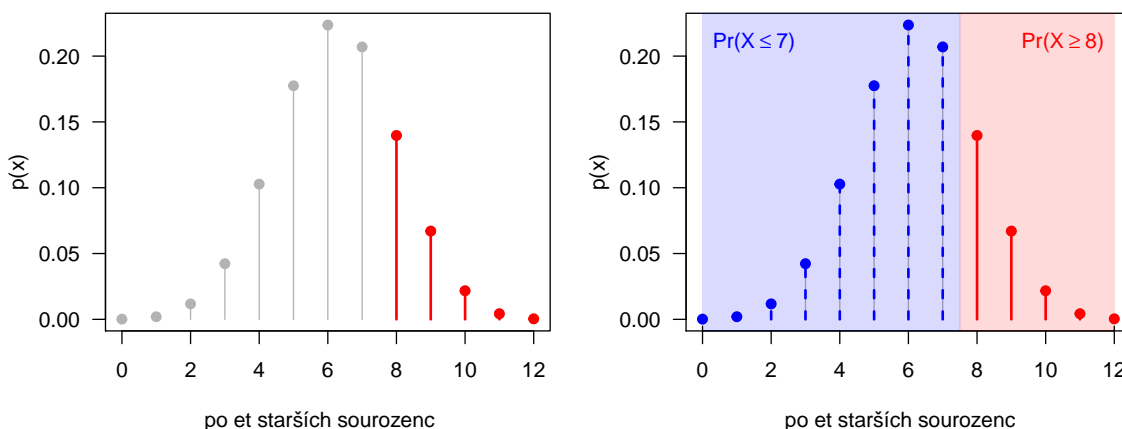
99 `sum(dbinom(0:4, N, p)) # 0.1588736`

nebo pomocí příkazu `pbinom()`, který vrátí přímo hodnotu distribuční funkce  $\Pr(X \leq 4)$ . Prvním argumentem funkce bude hodnota  $x = 4$ , druhým argumentem bude počet pokusů  $N$  a třetím argumentem pravděpodobnost narození chlapce  $p$ .

100 `pbinom(4, N, p) # 0.1588736`

**Interpretace výsledků:** Pravděpodobnost, že v rodině s dvanácti dětmi budou nejvýše čtyři chlapci, je 15.89%.

- (c) Pravděpodobnost, že v rodině s dvanácti dětmi bude alespoň osm chlapců můžeme vypočítat buď přímo jako součet pravděpodobnostních funkcí  $p(x)$  v hodnotách  $x = 8, 9, 10, 11$  a  $12$  (viz obrázek 13 vlevo), nebo můžeme využít vlastnosti komplementarity, tj.  $\Pr(X \geq x) = 1 - \Pr(X < x) = 1 - \Pr(X \leq x - 1)$  (viz obrázek 13 vpravo).



Obrázek 13: Vizualizace pravděpodobnosti, že v rodině s dvanácti dětmi bude alespoň osm chlapců (vlevo); vizualizace výpočtu pomocí komplementarity (vpravo)

$$\begin{aligned}
 \Pr(X \geq 8) &= \Pr(X = 8) + \Pr(X = 9) + \Pr(X = 10) + \Pr(X = 11) + \Pr(X = 12) = \\
 &= \binom{12}{8} \times 0.5192^8 \times (1 - 0.5192)^{12-8} + \dots + \binom{12}{12} \times 0.5192^{12} \times (1 - 0.5192)^{12-12} = \\
 &= 495 \times 0.5192^8 \times (1 - 0.5192)^4 + \dots + 1 \times 0.5192^{12} \times (1 - 0.5192)^0 = \\
 &= 0.2330869 \doteq 0.2331.
 \end{aligned}$$

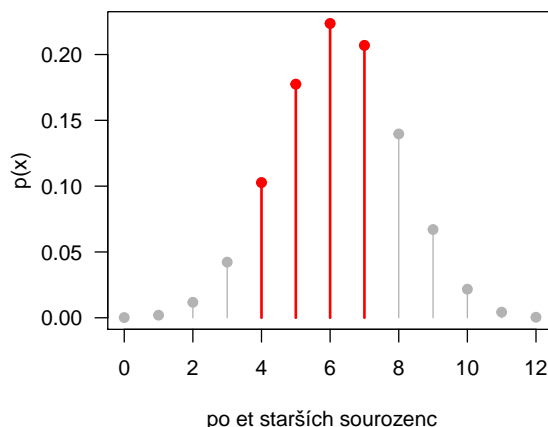
$$\begin{aligned}
 \Pr(X \geq 8) &= 1 - \Pr(X < 8) = 1 - \Pr(X \leq 7) \\
 &= 1 - \left( \sum_{i=0}^7 \Pr(X = i) \right) = 1 - (\Pr(X = 0) + \dots + \Pr(X = 7)) \\
 &= 1 - \left( \binom{12}{0} \times 0.5192^0 \times (1 - 0.5192)^{12-0} + \dots + \binom{12}{7} \times 0.5192^7 \times (1 - 0.5192)^{12-7} \right) \\
 &= 1 - (1 \times 0.5192^0 \times 0.4808^{12} + \dots + 792 \times 0.5192^7 \times 0.4808^5) \\
 &= 1 - 0.7669131 = 0.2330869 \doteq 0.2331.
 \end{aligned}$$

Pravděpodobnost, že v rodině s dvanácti dětmi bude alespoň osm chlapců můžeme vypočítat pomocí softwaru  $\mathbb{R}$ , a to buď přímým součtem pravděpodobnostních funkcí  $p(x)$  v hodnotách  $x = 8, 9, 10, 11$  a  $12$ , nebo odečtením hodnot pravděpodobnostních funkcí  $p(x)$  v hodnotách  $x = 0, 1, 2, 3, 4, 5, 6$  a  $7$  od celku, nebo odečtením hodnoty distribuční funkce  $\Pr(X \leq 7)$  od celku.

```
101 sum(dbinom(8:12, N, p)) # 0.2330869
102 1 - sum(dbinom(0:7, N, p)) # 0.2330869
103 1 - pbinom(7, N, p) # 0.2330869
```

**Interpretace výsledků:** Pravděpodobnost, že v rodině s dvanácti dětmi bude alespoň osm chlapců, je 23.31%.

- (d) Nakonec vypočítáme pravděpodobnost, že v rodině s dvanácti dětmi bude čtyři pět, šest nebo sedm chlapců (vizualizace situace viz obrázek 14)



Obrázek 14: Vizualizace pravděpodobnosti, že v rodině s dvanácti dětmi bude čtyři, pět, šest nebo sedm chlapců

Pravděpodobnost, že v rodině s dvanácti dětmi bude čtyři pět, šest nebo sedm chlapců vypočítáme přímým součtem hodnot pravděpodobnostní funkce  $p(x)$  v hodnotách  $x = 4, 5, 6$  a  $7$ .

$$\begin{aligned}
 \Pr(4 \leq X \leq 7) &= \sum_{i=4}^7 \Pr(X = i) = \Pr(X = 4) + \Pr(X = 5) + \Pr(X = 6) + \Pr(X = 7) \\
 &= \binom{12}{4} \times 0.5192^4 \times (1 - 0.5192)^{12-4} + \dots + \binom{12}{7} \times 0.5192^7 \times (1 - 0.5192)^{12-7} \quad (6) \\
 &= 495 \times 0.5192^4 \times 0.4808^8 + \dots + 792 \times 0.5192^7 \times 0.4808^5 \\
 &= 0.7107605 \doteq 0.7108.
 \end{aligned}$$

K výpočtu pravděpodobnosti  $\Pr(4 \leq X \leq 7)$  můžeme tentokrát použít buď funkci `dbinom()`, která vede na výpočet analogický výpočtu 6, tj.

```
104 sum(dbinom(4 : 7, N, p)) # 0.7107605
```

nebo využít vztahu

$$\Pr(4 \leq X \leq 7) = \Pr(X \leq 7) - \Pr(X < 4) = \Pr(X \leq 7) - \Pr(X \leq 3)$$

a vypočítat  $\Pr(4 \leq X \leq 7)$  pomocí příkazu

```
105 pbinom(7, N, p) - pbinom(3, N, p) # 0.7107605
```

Vidíme, že oba postupy vedou ke stejnému výsledku.

**Interpretace výsledků:** Pravděpodobnost, že v rodině s dvanácti dětmi bude čtyři, pět, šest, nebo sedm chlapců, je 71.08%.

#### Příklad 4.10. Graf pravděpodobnostní funkce a distribuční funkce binomického rozdělení

Zaměřte se nyní blíže na tvar binomického rozdělení  $\text{Bin}(12, 0.5192)$ . Nakreslete graf pravděpodobnostní funkce  $p(x)$  a graf distribuční funkce  $F(x)$  tohoto rozdělení.

#### Řešení příkladu 4.10

Začneme s vykreslením grafu pravděpodobnostní funkce  $p(x)$ . Do proměnné  $px$  nejprve vložíme hodnoty pravděpodobnostní funkce binomického rozdělení  $p(x) = \Pr(X = x)$  pro  $x = 0, 1, \dots, 12$ , které vypočítáme příkazem `dbinom()`. Na prvním místě ve funkci `dbinom()` budou hodnoty  $x$ , na druhém místě počet pokusů  $N$  a na třetím místě pravděpodobnost nastání události  $p$  v jednom pokusu. Samotný graf potom vykreslíme příkazem `plot()` s argumentem `type = 'h'`, který zajistí vykreslení vertikálních čar v hodnotách 0–12 na ose  $x$  a s délkou odpovídající hodnotám pravděpodobnostní funkce  $p(x)$ ,  $x = 0, \dots, 12$ . Argumentem `xlab = ''` v rámci příkazu `plot()` zamezíme vypsání popisku osy  $x$ . Dále do grafu doplníme body (`points()`) ve výšce hodnot funkce  $p(x)$ . Popisek osy  $x$  vykreslíme samostatně příkazem `mtext()` na pozici pod graf (`side = 1`) na řádek 2.1 (`line`). Nakonec do grafu doplníme druhý popisek uvádějící hodnoty parametrů  $N$  a  $p$ . Text popisku vygenerujeme pomocí kombinace funkcí `bquote()` a `paste()`. Uvnitř funkce `paste()` je vložena syntaxe popisku skládající se ze tří částí oddělených čárkami. První část, tj. `N==.(N)`, vypíše písmeno  $N$ , znaménko rovnosti a vyhodnocení proměnné  $N$ , tj. 12, druhá část, tj. `';`, vypíše středník a třetí část `p==.(p)` vypíše písmeno  $p$ , znaménko rovnosti a vyhodnocení proměnné  $p$ , tj. 0.5192.

```
106 N <- 12
107 x <- 0 : N
108 p <- 0.5192
109 px <- dbinom(x, N, p)
110 plot(x, px, type = 'h', ylim = c(0, 0.25), ylab = 'p(x)', xlab = '', las = 1)
111 points(x, px, col = 'red', pch = 19)
112 mtext('x', side = 1, line = 2.1)
113 mtext(bquote(paste(N==.(N), '; ', p==.(p))), side = 1, line = 3.2)
```


První krokem pro vykreslení grafu distribuční funkce  $F(x)$  je vytvoření vektoru  $Fx$  s hodnotami distribuční funkce binomického rozdělení  $F(x) = \Pr(X \leq x)$  pro  $x = 0, 1, \dots, 12$ , které vypočítáme příkazem `pbinom()`. Prvním argumentem funkce budou hodnoty  $x$ , druhým počet pokusů  $N$  a třetím pravděpodobnost nastání události  $p$  v jednom pokusu. Konstrukci grafu zahájíme vykreslením prázdného grafu (příkaz `plot()` s argumentem `type = 'n'`) s rozsahem měřítka osy  $x$  od  $-1$  do  $N + 1$  (`xlim`) a rozsahem měřítka osy  $y$  od 0 do 1 (`ylim`). Argumentem `xlab = ''` potlačíme vypsání popisku osy  $x$ . Nyní do grafu dokreslíme horizontální úsečky délky 1 začínající vždy v bodě  $[x, F(x)]$  a končící v bodě  $[x+1, F(x)]$ . Příkazem `arrows()` dokreslíme do grafu horizontální šipku umístěnou vlevo dole a směřující doleva, s počátečním bodem  $[0, 0]$  a koncovým bodem  $[-1, 0]$ . Argumentem `length` zmenšíme velikost zobáčku šipky. Opětovným použitím příkazu `arrows()` vykreslíme nyní horizontální šipku umístěnou vpravo nahoře, směřující doprava s počátečním bodem  $[N, 1]$  a koncovým bodem  $[N+1, 1]$ . Následně do grafu dokreslíme body značící skok z hodnoty  $F(x)$  do hodnoty  $F(x+1)$ . Na levém konci každé úsečky vykreslíme bod (`points()`, `pch = 19`) se souřadnicí  $[x, F(x)]$  s červeným okrajem a červeným vnitřkem (`col`) značící, že levý krajní bod každé úsečky má hodnotu distribuční funkce  $F(x)$ . Oproti tomu, na pravém konci každé úsečky vykreslíme bod (`points()`, `pch = 21`) se souřadnicí  $[x, F(x-1)]$  s černým okrajem (`bg`) a bílým vnitřkem (`col`) značící, že pravý krajní bod každé úsečky nepatří mezi body s hodnotou distribuční funkce  $F(x)$ . Nakonec dvojnásobným využitím příkazu `mtext()` doplníme do grafu popisek osy  $x$  a popisek s hodnotami parametrů  $N$  a  $p$ .

```
114 Fx <- pbinom(x, N, p)
115 plot(x, Fx, type = 'n', xlab = '', ylab = 'F(x)',
116      xlim = c(-1, N + 1), ylim = c(0, 1), las = 1)
117 segments(x, Fx, x + 1, Fx) # vodorovne cary
118 arrows(0, 0, -1, 0, length = 0.1) # sipka vlevo dole
119 arrows(N, 1, N + 1, 1, length = 0.1) # sipka vpravo dole
120 points(x, Fx, col = 'red', pch = 19) # plne body
121 points(x, c(0, Fx[1 : N]), pch = 21, bg = 'white', col = 'black') # prazdne body
```

```

122 mtext('x', side = 1, line = 2.1)
123 mtext(bquote(paste(N==.(N), ', ', p==.(p))), side = 1, line = 3.2)

```



Obrázek 15: Pravděpodobnostní funkce (vlevo) a distribuční funkce (vpravo) binomického modelu  $\text{Bin}(12, 0.5192)$

#### Příklad 4.11. Výpočet pravděpodobností za předpokladu binomického modelu

Předpokládejme, že pravděpodobnost výskytu dermatoglyfického vzoru *vír* na palci pravé ruky u mužů české populace  $p = 0.533$ . Jaká je pravděpodobnost, že ve vybraném vzorku 10 mužů bude výskyt dermatoglyfického vzoru *vír* na palci pravé ruky (a) právě u pěti mužů; (b) alespoň u 6 mužů; (c) nejvýše u dvou mužů; (d) u šesti, sedmi nebo osmi mužů.

#### Řešení příkladu 4.11

[1] 0.2408

124

[1] 0.4604

125

[1] 0.035

126

[1] 0.4423


127

**Interpretace výsledků:** Pravděpodobnost výskytu dermatoglyfického vzoru *vír* na palci pravé ruky u právě pěti mužů z deseti je 24.08%. Pravděpodobnost výskytu vzoru *vír* na palci pravé ruky u alespoň šesti mužů z deseti je 46.04%. Pravděpodobnost výskytu vzoru *vír* na palci pravé ruky u nejvýše dvou mužů z deseti je 3.50%. Pravděpodobnost výskytu vzoru *vír* na palci pravé ruky u šesti, sedmi nebo osmi mužů z deseti je 44.23%.

#### Příklad 4.12. Graf pravděpodobnostní a distribuční funkce binomického modelu

Nakreslete graf pravděpodobnostní funkce a distribuční funkce náhodné veličiny  $X \sim \text{Bin}(10, 0.533)$ .

#### Řešení příkladu 4.12



Obrázek 16: Pravděpodobnostní funkce (vlevo) a distribuční funkce (vpravo) binomického modelu  $\text{Bin}(10, 0.533)$

### Poissonovo rozdělení $Po(\lambda)$

- $X$  ... počet událostí, které nastanou v jednotkovém časovém intervalu, přičemž k událostem dochází náhodně, jednotlivě a vzájemně nezávisle. Střední počet těchto událostí je vyjádřen parametrem  $\lambda > 0$ .
- $X \sim Po(\lambda)$
- $\theta = \lambda$
- pravděpodobnostní funkce:

$$p(x) = \frac{\lambda^x}{x!} e^{-\lambda} \quad x = 0, 1, \dots;$$

- vlastnosti:  $E[X] = \lambda$ ;  $\text{Var}[X] = \lambda$
- `dpois(x, lambda)`, `ppois(x, lambda)`

### Příklad 4.13. Výpočet parametru $\lambda$ Poissonova modelu

Načtete datový soubor 17-anova-newborns.txt a odstraňte z něj neznámá pozorování. Zaměřte se na znak  $X = \text{počet starších sourozenců}$  novorozence. Za předpokladu, že náhodná veličina  $X$  popisující počet starších sourozenců novorozence pochází z Poissonova rozdělení parametrem  $\lambda$  odhadněte střední hodnotu počtu starších sourozenců  $\lambda$ .

#### Řešení příkladu 4.13

Střední hodnotu počtu starších sourozenců odhadneme pomocí vzorce

$$\lambda = \frac{\text{počet starších sourozenců}}{\text{počet novorozenců}} = \frac{\sum_{i=1}^N x_i}{N}. \quad (7)$$

[1] 0.9428365

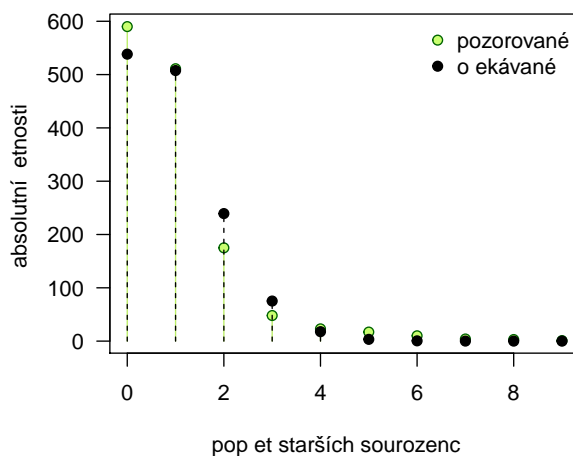
128

**Interpretace výsledků:** Střední hodnota počtu starších sourozenců novorozenců v datovém souboru  $\lambda = 0.9428$

### Příklad 4.14. Porovnání pozorovaných a očekávaných početností v Poissonově modelu

Za předpokladu, že počet starších sourozenců novorozenců pochází z Poissonova rozdělení s parametrem  $\lambda = 0.9428$  odhadněte očekávané početnosti starších sourozenců a porovnejte je s pozorovanými početnostmi.

#### Řešení příkladu 4.14



Obrázek 17: Porovnání pozorovaných a očekávaných početností v Poissonově modelu

### Příklad 4.15. Výpočet pravděpodobností za předpokladu Poissonova modelu

Vraťem se nyní k příkladu 4.13. Za předpokladu, že data pochází z Poissonova rozdělení s parametrem  $\lambda = 0.9428$  určete pravděpodobnost, novorozenec má (a) dva, tři nebo čtyři starší sourozence; (b) alespoň čtyři starší sourozence; (c) nejvýše dva starší sourozence; (d) právě jednoho starší sourozence.

#### Řešení příkladu 4.15

[1] 0.2403672

129

[1] 0.01568161

130

[1] 0.9299071

131

[1] 0.367255

132




**Interpretace výsledů:** Pravděpodobnost, že novorozenec bude mít dva, tři nebo čtyři starší sourozence je 24.04%. Pravděpodobnost, že novorozenec bude alespoň čtyři starší sourozence je 1.57%. Pravděpodobnost, novorozenec bude mít nejvýše dva starší sourozence je 92.99%. Pravděpodobnost, že novorozenec bude mít jednoho staršího sourozence je 36.73%.

**Příklad 4.16. Graf pravděpodobnostní a distribuční funkce Poissonova modelu**

Nakreslete graf pravděpodobnostní a distribuční funkce Poissonova rozdělení  $Po(0.9428)$  v hodnotách  $x = 0, 1, 2, 3, 4, 5, 6, 7, 8$ , a  $x \geq 9$ .

**Řešení příkladu 4.16**



Obrázek 18: Pravděpodobnostní a distribuční funkce Poissonova modelu

## Dataset 6: Pruské armádní jednotky

V rámci studie z roku 1898 byly zpracovávány počty smrtelných úrazů v pruských armádních jednotkách způsobené kopnutím koněm. Údaje o smrtelných úrazech po kopnutí koněm by zaznamenávány po dobu dvaceti let u deseti armádních jednotek. Počty úrazů v každé jednotce za jeden rok jsou uvedeny v následující tabulce.

$n$	0	1	2	3	4	5+	$\Sigma$
$m_{observed}$	109	65	22	3	1	0	200

Rozsah náhodného výběru je  $M = 200$  (10 jednotek  $\times$  20 let).

### Příklad 4.17. Výpočet parametru $\lambda$ Poissonova modelu

VeźmĚte ůdaje z datasetu 7. PĚdpokládejme, ůe nĚhodnĚ velićina  $X$  popisujćící poćet smrtelnĚch ůrazů v pruskĚch armĚdnĚch jednotkĚch způsobenĚch kopnutĚm konĚm pochĚzĚ z Poissonova rozdĚlení se stĚdnĚ hodnotou  $\lambda$ . OdhadnĚte stĚdnĚ hodnotu poćtu smrtelnĚch ůrazů  $\lambda$ .

#### Řešení pĚkladu 4.17

StĚdnĚ hodnotu poćtu smrtelnĚch ůrazů v pruskĚch armĚdnĚch jednotkĚch způsobenĚm kopnutĚm konĚm odhadneme pomocí vzorce

$$\lambda = \frac{\sum_{n=0}^N n m_{observed}}{\sum_{n=0}^N m_{observed}}. \quad (8)$$

[1] 0.61

133

**Interpretace vĚsledků:** StĚdnĚ hodnota vĚskytu smrtelnĚch ůrazů způsobenĚch kopnutĚm konĚm je  $\lambda = 0.61$ .

### Příklad 4.18. Výpoćet pravdĚpodobnostĚ za pĚdpokladu Poissonova modelu

Vraťem se nynĚ k pĚkladu 4.17. Za pĚdpokladu, ůe data pochĚzĚ z Poissonova rozdĚlení s parametrem  $\lambda = 0.61$  urćete pravdĚpodobnost, ůe v pruskĚch armĚdnĚch jednotkĚch dojde k (a) nejvĚyšĚ dvĚma smrtelnĚm ůrazům; (b) ůĚdnĚmu smrtelnĚmu ůrazu; (c) alespoň jednomu smrtelnĚmu ůrazu; (d) pĚvĚ jednomu smrtelnĚmu ůrazu.

#### Řešení pĚkladu 4.18

[1] 0.9758853

134

[1] 0.5433509

135

[1] 0.1252051

136

[1] 0.331444


137

**Interpretace vĚsledů:** PravdĚpodobnost, ůe v pruskĚch armĚdnĚch jednotkĚch dojde k nejvĚyšĚ dvĚma smrtelnĚm ůrazům způsobenĚch kopnutĚm konĚm je 97.59%. PravdĚpodobnost, ůe v pruskĚch armĚdnĚch jednotkĚch nedojde k ůĚdnĚmu smrtelnĚmu ůrazu způsobenĚmu kopnutĚm konĚm je 54.34%. PravdĚpodobnost, ůe v pruskĚch armĚdnĚch jednotkĚch dojde k alespoň jednomu smrtelnĚmu ůrazu způsobenĚmu kopnutĚm konĚm je 12.52%. PravdĚpodobnost, ůe v pruskĚch armĚdnĚch jednotkĚch dojde k pĚvĚ jednomu smrtelnĚmu ůrazu způsobenĚmu kopnutĚm konĚm je 33.14%.

### Příklad 4.19. Graf pravdĚpodobnostnĚ a distribućnĚ funkce Poissonova modelu

Nakreslete graf pravdĚpodobnostnĚ a distribućnĚ funkce Poissonova rozdĚlení  $Po(0.61)$  v hodnotĚch  $x = 0, 1, 2, 3, 4$  a  $x \geq 5$ .

#### Řešení pĚkladu 4.19



Obrázek 19: Pravděpodobnostní a distribuční funkce Poissonova modelu

$n$	0	1	2	3	4	$\geq 5$	$\sum$
$m_{observed}$	447	132	42	21	3	2	647

### Dataset 7: Dělníci v továrně

V rámci studie počtu úrazů v továrnách byl zaznamenán počet úrazů u každého dělníka v jedné vybrané továrně během roku 1920. Celkový počet dělníků zahrnutých do studie  $M = 647$ . Údaje ze studie jsou uvedeny v následující tabulce.

#### Příklad 4.20. Výpočet parametru $\lambda$ Poissonova modelu

Veźměte ůdaje z datasetu 7. Pědpokládejme, ůe nĀhodnĀ veliĀina  $X$  popisujĀcĀ poĀet ůrazů u dělnĀků v továrně pochĀzĀ z Poissonova rozdělení se stědnĀ hodnotou  $\lambda$ . Odhadněte stědnĀ hodnotu poĀtu ůrazů u dělnĀků v továrně  $\lambda$ .

#### Řešení pěkladu 4.20

StědnĀ hodnotu poĀtu ůrazů dělnĀků v továrně za jeden rok odhadneme pomocĀ vzorce

$$\hat{\lambda} = \frac{\sum_{n=0}^N n m_{observed}}{\sum_{n=0}^N m_{observed}}. \quad (9)$$

[1] 0.4652

138

**Interpretace věsledků:** StědnĀ hodnota poĀtu ůrazů u dělnĀků v továrně během jednoho roku je  $\lambda = 0.4652$ .

#### Pěklad 4.21. Graf pravděpodobnostnĀ a distribuĀnĀ funkce Poissonova modelu

Nakreslete graf pravděpodobnostnĀ a distribuĀnĀ funkce Poissonova rozdělení  $Po(0.4652)$  v hodnotĀch  $x = 0, 1, 2, 3, 4$  a  $x \geq 5$ .

#### Řešení pěkladu 4.21


#### Pěklad 4.22. VěpoĀet pravděpodobnostĀ na zĀkladě Poissonova modelu

Za pědpokladu, ůe nĀhodnĀ veliĀina  $X$ , udĀvajĀcĀ poĀet ůrazů u dělnĀků v továrně, pochĀzĀ z Poissonova rozdělení s parametrem  $\lambda = 0.4652$ , tj.  $X \sim Po(\lambda)$  vypoĀětějte pravděpodobnost, ůe u nĀhodně vybraněho dělnĀka dojde během jednoho roku k (a) nula ůrazům; (b) těm nebo Ātyěem ůrazům; (c) nejvěŝe dvěma ůrazům; (d) alespoĀ jednomu ůrazu.

#### Řešení pěkladu 4.22

[1] 0.628

139



Obrázek 20: Pravděpodobnostní a distribuční funkce Poissonova modelu

[1] 0.0118

140

[1] 0.9881

141

[1] 0.372

142

**interpretace výsledků:** Pravděpodobnost, že u vybraného dělníka nedojde během roku k žádnému úrazu, je 0.6280. Pravděpodobnost, že u vybraného dělníka dojde během roku k třem nebo čtyřem úrazům, je 0.0118. Pravděpodobnost, že u vybraného dělníka dojde během roku k nejvýše dvěma úrazům, je 0.9881. Pravděpodobnost, že u vybraného dělníka dojde během roku k alespoň jednomu úrazu, je 0.3720.

## 4.2 Spojité rozdělení

### Normální rozdělení $N(\mu, \sigma^2)$

- $X_1, \dots, X_n \dots$  nezávislé náhodné veličiny
- Normální rozdělení

- $X \sim N(\mu, \sigma^2)$
- $\theta = (\mu, \sigma^2)^T$
- hustota

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left\{-\frac{(x-\mu)^2}{2\sigma^2}\right\}, \quad x \in \mathbb{R}.$$

- vlastnosti  $E[X] = \mu$ ;  $\text{Var}[X] = \sigma^2$
- `dnorm(x, mu, sigma)`, `pnorm(x, mu, sigma)`, `rnorm(M, mu, sigma)`, `qnorm(alpha, mu, sigma)`

- Standardizované normální rozdělení

- $X \sim N(0, 1)$
- $\theta = (0, 1)^T$
- hustota

$$f(x) = \phi(x) = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{x^2}{2}\right\}, \quad x \in \mathbb{R}.$$

- vlastnosti  $E[X] = 0$ ;  $\text{Var}[X] = 1$

–  $\text{dnorm}(x)$ ,  $\text{pnorm}(x)$ ,  $\text{rnorm}(M)$ ,  $\text{qnorm}(\alpha)$

• Vlastnosti normálního rozdělení

– **Věta 1:** Necht'  $X_1, \dots, X_n$  jsou nezávislé náhodné veličiny z normálního rozdělení  $N(\mu, \sigma^2)$ . Potom náhodná veličina  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \sim N\left(\mu, \frac{\sigma^2}{n}\right)$ .

#### Příklad 4.23. Výpočet pravděpodobností na základě normálního modelu

Na základě datového souboru obsahujícího osteometrická data klíční kosti (clavicula) anglického souboru dokumentovaných skeletů (Parsons, 1916) byla odhadnuta střední hodnota a směrodatná odchylka délky pravé klavikuly u mužů. Střední hodnota  $\mu = 151.74$  mm, směrodatná odchylka  $s = 11$  mm (viz příklad ??). Za předpokladu, že data pochází z normálního rozdělení vypočítejte, jaká je pravděpodobnost, že délka pravé klavikuly u mužů bude (a) rovná 150 mm; (b) menší než 140 mm; (c) větší než 160 mm; (d) v rozmezí 140–160 mm.

#### Řešení příkladu 4.23

[1] 0

143

[1] 0.1429243

144

[1] 0.2263537

145

[1] 0.630722



146

**Interpretace výsledků:** Pravděpodobnost, že délka pravé klavikuly u mužů bude rovná 150 mm je 0%, protože data pochází z normálního rozdělení, což je spojitý typ rozdělení a proto  $\Pr(X = 150) = 0$ . Pravděpodobnost, že délka pravé klavikuly u mužů bude menší než 140 mm je 14.29%. Pravděpodobnost, že délka pravé klavikuly u mužů bude větší než 160 mm je 12.34%. Pravděpodobnost, že délka pravé klavikuly u mužů bude v rozmezí 140–160 mm je 22.64%.

#### Příklad 4.24. Graf hustoty a distribuční funkce normálního modelu

Vraťme se k příkladu 4.23. Nakreslete graf hustoty a distribuční funkce náhodné veličiny  $X \sim N(151.74, 11)$ .

#### Řešení příkladu 4.24



#### Příklad 4.25. Výpočet pravděpodobností na základě normálního modelu

Na základě datového souboru obsahujícího údaje o porodní hmotnosti novorozenců v jedné okresní nemocnici za období jednoho roku (Alánová, 2008) byla odhadnuta střední hodnota a směrodatná odchylka porodní hmotnosti novorozenců. Střední hodnota  $\mu = 3078.94$  g, směrodatná odchylka  $s = 697$  g (viz příklad ??). Za předpokladu, že data pochází z normálního rozdělení vypočítejte, jaká je pravděpodobnost, že porodní hmotnost novorozence bude

(a) menší než 3800 g; (b) v rozmezí 2500–4200 g; (c) větší než 4000 g; (d) rovná 2100 g.

### Řešení příkladu 4.25

[1] 0.8495533	147
[1] 0.743032	148
[1] 0.09317345	149
[1] 0	150

**Interpretace výsledků:** Pravděpodobnost, že porodní hmotnost novorozenců bude menší než 3800 g je 84.96%. Pravděpodobnost, že porodní hmotnost novorozenců bude v rozmezí 2500–4200 mm je 74.30%. Pravděpodobnost, že porodní hmotnost novorozenců bude větší než 4000 mm je 9.32%. Pravděpodobnost, že porodní hmotnost novorozenců bude rovná 2100 g je 0%, protože data pochází z normálního rozdělení, což je spojitý typ rozdělení a proto  $\Pr(X = 2100) = 0$ .

### Příklad 4.26. Výpočet pravděpodobností na základě standardizovaného normálního modelu

Vraťme se nyní k předchozímu příkladu 4.25. Za předpokladu, že porodní hmotnost novorozenců pochází z normálního rozdělení  $N(3078.94, 697^2)$  vypočítejte pravděpodobnost, že porodní hmotnost novorozence bude (a) menší než 3800 g; (b) v rozmezí 2000–3000 g; (c) větší než 4000 g, (d) rovná 2100 g. Řešení provedte přes standardizaci náhodné veličiny  $X$ .

### Řešení příkladu 4.26



[1] 0.8495533	151
[1] 0.743032	152
[1] 0.09317345	153
[1] 0	154

**Interpretace výsledků:** Pravděpodobnost, že porodní hmotnost novorozenců bude menší než 3800 g je 84.96%. Pravděpodobnost, že porodní hmotnost novorozenců bude v rozmezí 2500–4200 mm je 74.30%. Pravděpodobnost, že porodní hmotnost novorozenců bude větší než 4000 mm je 9.32%. Pravděpodobnost, že porodní hmotnost novorozenců bude rovná 2100 g je 0%, protože data pochází z normálního rozdělení, což je spojitý typ rozdělení a proto  $\Pr(X = 2100) = 0$ .

### Příklad 4.27. Graf hustoty a distribuční funkce normálního modelu

Vraťme se k příkladu 4.25. Nakreslete graf hustoty a distribuční funkce náhodné veličiny  $X \sim N(3078.94, 697)$ .

### Řešení příkladu 4.27



### 4.3 Aproximace binomického modelu normálním modelem

- Normální rozdělení je limitním rozdělením binomického rozdělení  $\text{Bin}(N, p)$ , tedy pro  $N \rightarrow \infty$ ,  $p \rightarrow 0.5$ :

$$X \sim \text{Bin}(N, p) \rightarrow X \sim N(\mu, \sigma^2),$$

kde  $\mu = Np$  a  $\sigma^2 = Np(1 - p)$ .

- Haldova podmínka: Necht'  $X \sim \text{Bin}(N, p)$  a platí, že  $Np > 5$  a  $N(1 - p) > 5$ . Potom rozdělení náhodné proměnné  $X$  můžeme aproximovat normálním rozdělením  $X \sim N(Np, Np(1 - p))$ .

#### Příklad 4.28. Aproximace binomického modelu normálním modelem

Předpokládejme, že pravděpodobnost výskytu dermatoglyfického vzoru *vír* na palci pravé ruky u mužů české populace  $p = 0.533$ .

1. Jaká je pravděpodobnost, že ve vybraném vzorku 10 mužů bude výskyt dermatoglyfického vzoru *vír* na palci pravé ruky (a) alespoň u sedmi mužů; (b) nejvýše u pěti mužů; (c) u šesti, sedmi nebo osmi mužů.
2. Jaká je pravděpodobnost, že ve vybraném vzorku 100 mužů bude výskyt dermatoglyfického vzoru *vír* na palci pravé ruky (a) alespoň u 56; (b) nejvýše u 53 mužů; (c) u 60–85 mužů.
3. Jaká je pravděpodobnost, že ve vybraném vzorku 300 mužů bude výskyt dermatoglyfického vzoru *vír* na palci pravé ruky (a) alespoň u 164 mužů; (b) nejvýše u 160 mužů; (c) u 170–175.

Požadované pravděpodobnosti vypočítejte exaktně na základě binomického rozdělení a aproximačně na základě normálního rozdělení. Výsledné hodnoty navzájem porovnejte.

#### Řešení příkladu 4.28

	alespon 7	nejvyse 5	8-9	
binomicke	0.2313	0.5396	0.0801	155
normalni	0.3355	0.4172	0.1349	156
				157

	alespon 56	nejvyse 53	60-85	
binomicke	0.3304	0.5151	0.1067	158
normalni	0.3666	0.4760	0.1266	159
				160

	alespon 164	nejvyse 160	170-175	
binomicke	0.3389	0.5272	0.0980	161
normalni	0.3599	0.5046	0.1059	162
				163

**Interpretace výsledků:** Pravděpodobnost výskytu dermatoglyfického vzoru *vír* alespoň u sedmi mužů z deseti je 23.13% (resp. 33.55%). Pravděpodobnost, výskytu vzoru *vír* nejvýše u pěti mužů z deseti je 53.96% (resp. 41.72%). Pravděpodobnost, výskytu vzoru *vír* u osmi nebo devíti mužů z deseti je 8.01% (resp. 13.49%).

Pravděpodobnost výskytu dermatoglyfického vzoru *vír* alespoň u 56 mužů ze sta je 33.04% (resp. 36.66%). Pravděpodobnost výskytu vzoru *vír* nejvýše u 53 mužů ze sta je 51.51% (resp. 47.60%). Pravděpodobnost výskytu vzoru *vír* u 60–85 mužů ze sta je 10.67% (resp. 12.66%).


Pravděpodobnost výskytu dermatoglyfického vzoru *vír* alespoň u 164 mužů z 300 je 33.89% (resp. 35.99%). Pravděpodobnost výskytu vzoru *vír* nejvýše u 160 mužů z 300 je 52.72% (resp. 50.46%). Pravděpodobnost výskytu vzoru *vír* u 170–175 mužů z 300 je 9.80% (resp. 10.59%).



### Příklad 4.29. Aproximace binomického modelu normálním modelem

Předpokládejme, že pravděpodobnost výskytu dermatoglyfického vzoru *vír* na palci pravé ruky u mužů české populace  $p = 0.533$ . Pro  $N = 10$ ,  $N = 100$  a  $N = 1000$  vykreslete graf pravděpodobnostní funkce binomického rozdělení a aproximujte jej křivkou funkce hustoty normálního rozdělení. Hodnoty obou funkcí porovnejte.

### Řešení příkladu 4.29



Obrázek 21: Aproximace binomického modelu normálním modelem