

## 4 Diskrétní náhodné veličiny

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

- Bernoulliho pokusy  $X_1, \dots, X_N$ :
  - $X_i = 1 \dots$  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 pokusu, 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:
$$p(x) = \binom{N}{x} p^x (1-p)^{N-x} \quad x = 0, 1, \dots, N;$$
  - vlastnosti:  $E[X] = Np$ ;  $\text{Var}[X] = Np(1-p)$
  - `dbinom(x, N, p)`, `pbinom(x, N, p)`

**Dataset: Počet chlapců v rodinách s 12 dětmi**

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  $N = 12$  dětmi byla pozorována početnost chlapců. Údaje ze studie jsou uvedeny v následující tabulce.

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

**Příklad 4.1. Výpočet parametru  $p$  binomického rozdělení**

Předpokládejme, že náhodná veličina  $X$  popisující počet chlapců v rodinách s dvanácti dětmi pochází z binomického rozdělení s parametrem  $N = 12$ . Vypočítejte odhad pravděpodobnosti výskytu chlapců v rodinách s dvanácti dětmi.

**Řešení příkladu 4.1**

Pravděpodobnost  $p$  výskytu chlapců v rodinách s dvanácti dětmi odhadneme pomocí vzorce

$$\hat{p} = \frac{\text{počet narozených chlapců}}{\text{celkový počet narozených dětí}} = \frac{\sum_{n=0}^N nm_{\text{observed}}}{NM}. \quad (4.1)$$

```
1 N <- 12
2 n <- 0:N
3 m.obs <- c(3, 24, 104, 286, 670, 1033, 1343, 1112, 829, 478, 181, 45, 7)
4 M <- sum(m.obs)
5 p <- sum(n * m.obs) / (N * M)
6 (p <- round(p, 4))
```

[1] 0.5192

7

**Interpretace výsledků:** Pravděpodobnost výskytu chlapců v rodinách s dvanácti dětmi je ..... (%).

★

**Příklad 4.2. Pozorované a očekávané početnosti v binomickém rozdělení**

Za předpokladu, že počet chlapců v rodinách s dvanácti dětmi pochází z binomického rozdělení s parametry  $N = \dots$  a  $p = \dots$  odhadněte očekávané početnosti chlapců v rodinách s dvanácti dětmi a porovnejte je s pozorovanými početnostmi.

**Řešení příkladu 4.2**

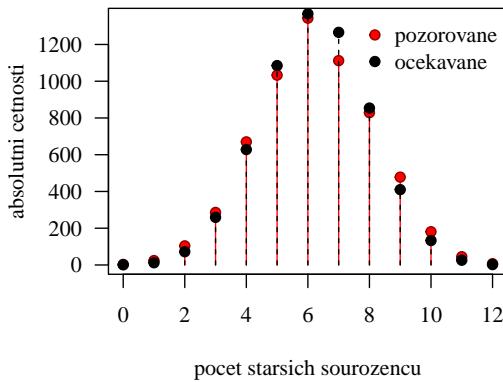
```

8 m.exp <- round(dbinom(0:12, 12, p) * 6115)
9 tab <- data.frame(rbind(m.obs, m.exp))
10 names(tab) <- 0:12
11 tab
12
13
14
```

	0	1	2	3	4	5	6	7	8	9	10	11	12
m.obs	3	24	104	286	670	1033	1343	1112	829	478	181	45	7
m.exp	1	12	72	259	628	1085	1367	1266	854	410	133	26	2

```

15 par(mar = c(4, 4, 1, 1), family = 'Times')
16 plot(0:12, m.obs, type = 'h', col = 'red',
17       xlab = 'pocet starsich sourozencu', ylab = 'absolutni ctnosti', las = 1)
18 points(0:12, m.obs, pch = 21, col = 'darkred', bg = 'red')
19 lines(0:12, m.exp, type = 'h', lty = 2, col = 'black')
20 points(0:12, m.exp, pch = 21, col = 'black', bg = 'black')
21 legend('topright', pch = c(21, 21), col = c('darkred', 'black'), pt.bg = c('red', 'black'),
22         legend = c('pozorovane', 'ocekavane'), bty = 'n')
```



### Příklad 4.3. Výpočet pravděpodobností za předpokladu binomického rozdělení

Za předpokladu, že náhodná veličina  $X$  popisující počet chlapců v rodinách s dvanácti dětmi pochází z binomického rozdělení s parametry  $N = \dots$  a  $p = \dots$  vypočítejte pravděpodobnost, že v rodině s dvanácti dětmi bude

- právě devět chlapců,
- nejvýše čtyři chlapci,
- alespoň osm chlapců,
- čtyři, pět, šest, nebo sedm chlapců.

### Řešení příkladu 4.3

```

23 N <- 12
24 p <- 0.5192
25 round(dbinom(9, N, p), 4)
26
[1] 0.067
27 round(pbinom(4, N, p), 4)
28
[1] 0.1589
29 round(1 - pbinom(7, N, p), 4)
30
[1] 0.2331
31 #round(sum(dbinom(8 : 12, N, p)), 4)
32 round(sum(dbinom(4 : 7, N, p)), 4)
33
[1] 0.7108
```

```
34 #round(pbinom(7, N, pii) - pbinom(3, N, p), 4)
```

**Interpretace výsledků:** Pravděpodobnost, že v rodině bude právě devět chlapců, je .....%. Pravděpodobnost, že v rodině budou nejvýše čtyři chlapci, je .....%. Pravděpodobnost, že v rodině bude alespoň osm chlapců, je .....%. Pravděpodobnost, že v rodině bude čtyři, pět, šest, nebo sedm chlapců, je .....%.

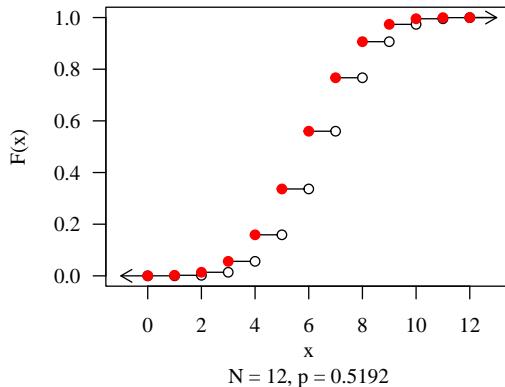
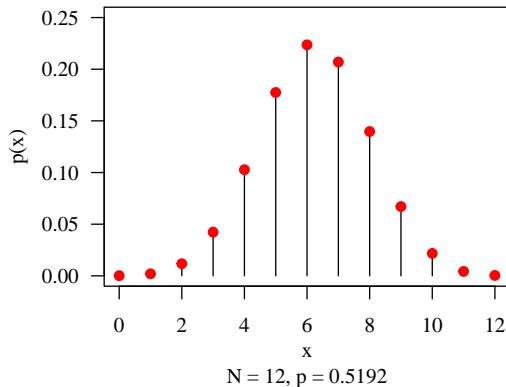


#### Příklad 4.4. Graf pravděpodobnostní a distribuční funkce binomického rozdělení

Nakreslete graf pravděpodobnostní funkce a graf distribuční funkce binomického rozdělení  $\text{Bin}(N, p)$ , kde  $N = 12$  a  $p = 0.5192$ .

#### Řešení příkladu 4.4

```
35 N <- 12
36 x <- 0 : N
37 p <- 0.5192
38 px <- dbinom(x, N, p)
39 Fx <- pbinom(x, N, p)
40
41 par(mar = c(4, 4, 1, 1), family = 'Times')
42 plot(x, px, type = 'h', ylim = c(0, 0.25), xlab = '', ylab = 'p(x)', las = 1)
43 mtext('x', side = 1, line = 2)
44 mtext('N = 12, p = 0.5192', side = 1, line = 3)
45 points(x, px, col = 'red', pch = 19)
46
47 plot(x, Fx, xlab = '', type = 'n', xlim = c(-1, 13), ylim = c(0, 1),
48 ylab = 'F(x)', las = 1)
49 segments(x, Fx, x + 1, Fx) # vodorovne cary
50 arrows(0, 0, -1, 0, length = 0.1) # dolni sipka
51 arrows(N, 1, 13, 1, length = 0.1) # horni sipka
52 points(x, c(0, Fx[1:N]), pch = 21, col = 'black', bg = 'white') # prazdne body
53 points(x, Fx, pch = 19, col = 'red') # plne body
54 mtext('x', side = 1, line = 2)
55 mtext('N = 12, p = 0.5192', side = 1, line = 3)
```



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

- $X \dots$  výskyt sledované události v **jednom** Bernoulliho pokusu, přičemž pravděpodobnost nastání události v tomto pokusu je vyjádřena parametrem  $p$ .
  - speciální případ binomického rozdělení, kde  $N = 1$ , tj.  $X \sim \text{Alt}(p) \simeq X \sim \text{Bin}(1, p)$
  - $X \sim \text{Alt}(p)$ .
  - $\theta = (p)^T$
  - pravděpodobnostní funkce
- $$p(x) = p^x(1-p)^{1-x} \quad x = 0, 1; \quad (4.2)$$
- vlastnosti:  $E[X] = p$ ;  $\text{Var}[X] = p(1-p)$
  - `dbinom(x, 1, p)`, `pbinom(x, 1, p)`

#### Dataset: 09-one-sample-probability-sutmet.txt

Datový soubor 09-one-sample-probability-sutmet.txt obsahuje údaje o výskytu epigenetického znaku *sutura metopica* na lebkách Ainů z ostrova Hokaido. Údaje o výskytu epigenetického znaku jsou 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

#### Příklad 4.5. Popis reálné situace pomocí alternativního rozdělení

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 4.5

Náhodná veličina  $X$  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. Náhodná veličina  $X$  tedy pochází z ..... rozdělení, tj.  $X \sim \dots$ . Odhad parametru  $p$  spočítáme jako podíl počtu výskytů epigenetického znaku *sutura metopica* na lebkách Ainů ku celkovému počtu zkoumaných lebek.

```
56 p <- 6 / 184
57 round(p, 4)
```

```
[1] 0.0326
```

58

**Interpretace výsledků:** Výskyt epigenetického znaku *sutura metopica* na lebkách Ainů z ostrova Hokaido pochází z ..... rozdělení s parametrem  $p = \dots$ . Pravděpodobnost výskytu epigenetického znaku *sutura metopica* u populace Ainů je .....%.

★

#### Příklad 4.6. Výpočet pravděpodobnosti 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  $p = \dots$ , vypočítejte

- pravděpodobnost výskytu epigenetického znaku *sutura metopica* u populace Ainů
- pravděpodobnost absence epigenetického znaku *sutura metopica* u populace Ainů
- pravděpodobnost nejvýše žádného výskytu epigenetického znaku *sutura metopica*
- pravděpodobnost nejvýše jednoho výskytu epigenetického znaku *sutura metopica*.

#### Řešení příkladu 4.6

```
59 x <- 1
60 p ^ (x) * (1 - p) ^ (1 - x) # 0.0326087
61 dbinom(1, 1, p)
62
63 x <- 0
64 p ^ (x) * (1 - p) ^ (1 - x) # 0.9673913
65 dbinom(0, 1, p)
66
67 x <- 0
68 p ^ (x) * (1 - p) ^ (1 - x) # 0.9673913
69 pbinom(0, 1, p)
70
71 x <- 0:1
72 sum(p ^ (x) * (1 - p) ^ (1 - x)) # 1
73 pbinom(1, 1, p)
```

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

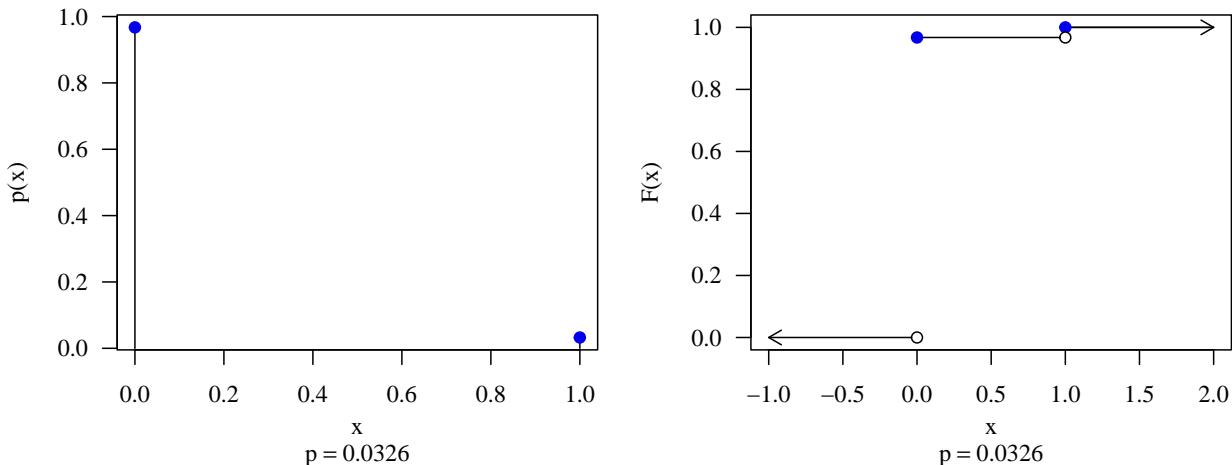
#### Příklad 4.7. Graf pravděpodobnostní funkce a distribuční funkce alternativního rozdělení

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 4.7

```
74 N <- 1
75 x <- 0:1
76 px <- dbinom(0:1, 1, p)
77 Fx <- pbinom(0:1, 1, p)
78
79 par(mar = c(4, 4, 1, 1), family = 'Times')
80 # Graf pravdepodobnostni funkce
81 plot(x, px, type = 'h', ylab = 'p(x)', xlab = '', las = 1)
82 points(x, px, col = 'blue2', pch = 19)
83 mtext('x', side = 1, line = 2.1)
84 mtext(bquote(p == .(round(p, 4))), side = 1, line = 3.2)
85
86 # Graf distribucni funkce
87 plot(x, Fx, xlab = '', ylab = 'F(x)',
88       xlim = c(-1, 2), ylim = c(0, 1), type = 'n', las = 1)
89 segments(x, Fx, x + 1, Fx) # vodorovne cary
90 arrows(0, 0, -1, 0, length = 0.1) # dolni sipka
91 arrows(N, 1, 2, 1, length = 0.1) # horni sipka
92 points(x, Fx, col = 'blue2', pch = 19) # plne body
93 points(x, c(0, Fx[1 : N]), pch = 21, bg = 'white', col = 'black') # prazdne body
94 mtext('x', side = 1, line = 2.1)
95 mtext(bquote(p == .(round(p, 4))), side = 1, line = 3.2)
```





Obrázek 1: Pravděpodobnostní funkce (vlevo) a distribuční funkce (vpravo) alternativního rozdělení  $\text{Alt}(0.03261)$

## 4.2 Poissonovo rozdělení $\text{Poiss}(\lambda)$

- $X$  ... počet událostí, které nastanou v jednotkovém časovém intervalu, přičemž k událostem dochází náhodně, jednotlivě a vzájemně nezávisle. Střední počet těchto událostí je vyjádřen parametrem  $\lambda > 0$ .
  - $X \sim \text{Poiss}(\lambda)$
  - $\theta = \lambda$
  - 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 4.8. Výpočet parametru $\lambda$ Poissonova rozdělení

Načtete datový soubor 17-anova-newborns-2.txt a odstraňte z něj neznámá pozorování. Zaměřte se na znak  $X =$ 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 4.8

Střední hodnotu počtu starších sourozenců odhadneme pomocí vzorce

$$\lambda = \frac{\text{počet starších sourozenců}}{\text{počet novorozeneců}} = \frac{\sum_{i=1}^N x_i}{N}. \quad (4.3)$$

```
96 data <- read.delim('00-Data//17-anova-newborns-2.txt')
97 data <- na.omit(data)
98 prch <- data$prch.N
99 N <- length(prch) # 1381
100 (lambda <- sum(prch) / N) # 0.9427951
```

[1] 0.9427951 101

**Interpetace výsledků:** Střední hodnota počtu starších sourozenců novorozeneců v datovém souboru  $\lambda = \dots$  ★

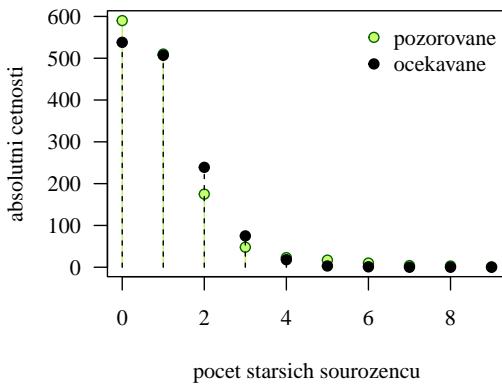
### Příklad 4.9. Porovnání pozorovaných a očekávaných početností v Poissonově rozdělení

Za předpokladu, že počet starších sourozenců novorozeneců pochází z Poissonova rozdělení s parametrem  $\lambda = \dots$

..... odhadněte očekávané početnosti starších sourozenců a porovnejte je s pozorovanými početnostmi.

### Řešení příkladu 4.9

```
102 m.obs <- data.frame(table(prch))$Freq
103 m.exp <- round(c(dpois(0:8, lambda), 1 - ppois(8, lambda)) * N)
104 tab <- data.frame(rbind(m.obs, m.exp))
105 names(tab) <- 0:9
106 tab
107
108      0   1   2   3   4   5   6   7   8   9
109 m.obs 590 510 175 48 23 17 10 4 3 1
109 m.exp 538 507 239 75 18 3 1 0 0 0
110
111 par(mar = c(4, 4, 1, 1), family = 'Times')
112 plot(0:9, m.obs, type = 'h', col = 'darkolivegreen2',
113       xlab = 'pocet starsich sourozencu', ylab = 'absolutni ctnosti', las = 1)
114 points(0:9, m.exp, pch = 21, col = 'darkgreen', bg = 'darkolivegreen1')
115 lines(0:9, m.exp, type = 'h', lty = 2, col = 'black')
116 points(0:9, m.exp, pch = 21, col = 'black', bg = 'black')
117 legend('topright', pch = c(21, 21), col = c('darkgreen', 'black'), pt.bg = c('darkolivegreen1', 'black'),
118           legend = c('pozorovane', 'ocekavane'), bty = 'n')
```



Obrázek 2: Porovnání pozorovaných a očekávaných početností v Poissonově rozdělení



### Příklad 4.10. Výpočet pravděpodobností za předpokladu Poissonova rozdělení

Za předpokladu, že data pochází z Poissonova rozdělení s parametrem  $\lambda = \dots$  určete pravděpodobnost, novorozenec má

- dva, tři nebo čtyři starší sourozence,
- alespoň čtyři starší sourozence,
- nejvýše dva starší sourozence,
- právě jednoho staršího sourozence.

### Řešení příkladu 4.10

```
118 sum(dpois(2:4, lambda))
119 [1] 0.2403526
120 1 - ppois(3, lambda)
121 [1] 0.01567936
122 ppois(2, lambda)
```

[1] 0.9299142

123

124 dpois(1, lambda)

[1] 0.3672541

125

**Interpretace výsledů:** Pravděpodobnost, že novorozeneč má dva, tři nebo čtyři starší sourozence je .....%.

Pravděpodobnost, že novorozeneč má alespoň čtyři starší sourozence je .....%.

Pravděpodobnost, že novorozeneč má nejvýše dva starší sourozence je .....%.

Pravděpodobnost, že novorozeneč má jednoho staršího sourozence je .....%.



### Příklad 4.11. Graf pravděpodobnostní a distribuční funkce Poissonova rozdělení

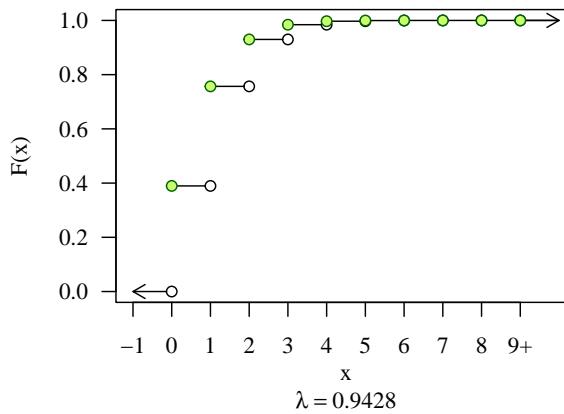
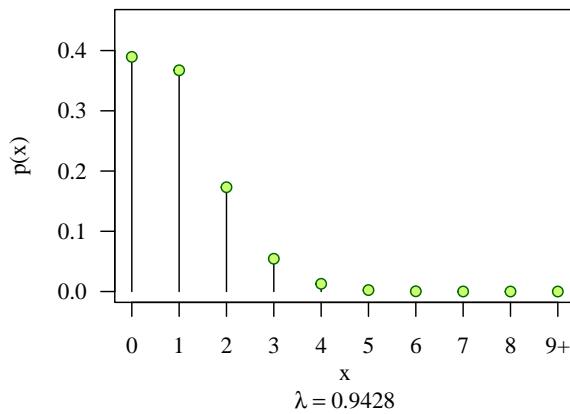
Nakreslete graf pravděpodobnostní a distribuční funkce Poissonova rozdělení Poiss(0.9428) v hodnotách  $x = 0, 1, 2, 3, 4, 5, 6, 7, 8$ , a  $x \geq 9$ .

#### Řešení příkladu 4.11

```

126 N <- 9
127 x <- 0:N
128 px <- c(dpois(0:8, lambda), 1 - sum(dpois(0:8, lambda)) )
129 Fx <- c(ppois(0:8, lambda), 1)
130
131 par(mar = c(5, 4, 1, 1), family = 'Times')
132 plot(x, px, type = 'h', ylim = c(0, 0.45), xlab = '', ylab = 'p(x)', axes = F)
133 points(x, px, pch = 21, col = 'darkgreen', bg = 'darkolivegreen1')
134 box(bty = 'o')
135 axis(1, 0:9, c(0:8, '9+'))
136 axis(2, las = 1)
137 mtext('x', side = 1, line = 2)
138 mtext(bquote(paste(lambda == 0.9428)), side = 1, line = 3)
139
140 plot(x, Fx, type = 'n', xlim = c(-1, N + 1), ylim = c(0, 1),
141       xlab = '', ylab = 'F(x)', axes = F)
142 box(bty = 'o')
143 axis(1, -1:9, c(-1:8, '9+'))
144 axis(2, las = 1)
145 segments(x, Fx, x + 1, Fx) # vodorovné čary
146 arrows(0, 0, -1, 0, length = 0.1) # dolní šipka
147 arrows(9, 1, 10, 1, length = 0.1) # horní šipka
148 points(x, c(0, Fx[1:9]), pch = 21, col = 'black', bg = 'white', cex = 1) # prázdné body
149 points(x, Fx, pch = 21, col = 'darkgreen', bg = 'darkolivegreen1') # plné body
150 mtext('x', side = 1, line = 2)
151 mtext(bquote(paste(lambda == 0.9428)), side = 1, line = 3)

```



Obrázek 3: Pravděpodobnostní a distribuční funkce Poissonova rozdělení

