

Statistická inference I

Téma 2: Poissonův model

Veronika Bendová

bendova.veroonika@gmail.com

Poissonovo rozdělení Poiss(λ)

- 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), rpois(M, lambda)

- **Dataset 2: 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.

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

Příklad 2.1. Výpočet očekávaných početností za předpokadu Poissonova modelu

Vezměte údaje z **datasetu 2**. Vypočítejte očekávané početnosti výskytu úrazů u dělníků v továrně za předpokladu, že početnosti úrazů X mají Poissonovo rozdělení $\text{Poiss}(\lambda)$ s parametrem

$$\hat{\lambda} = \frac{\sum_{n=0}^N nm_{observed}}{\sum_{n=0}^N m_{observed}}. \quad (2.1)$$

Řešení příkladu 2.1

```

1 n <- ... # posloupnost 0, 1, ..., 5
2 m.obs <- ... # posloupnost m.obs, tj. 447, 132, ..., 2
3 M <- sum(...) # celkovy pocet vsech jednotek M (soucet vsech cisel v m.obs)
4 lambda <- sum(...) / sum(...) # odhad parametru lambda podle vzorce 2.1

```

[1] 0.4652

5

```

6 m.exp <- round(c(dpois(...), 1 - sum(dpois(...))) * ...) # vektor ocek. abs. cetnosti

```

0	1	2	3	4	5
406	189	44	7	1	0

7
8

```

9 sum(...) # kontrolni soucet ocek. abs. cetnosti m.exp

```

[1] 647

10

Odhad parametru λ , tj. $\hat{\lambda} = 0.4652$. Tabulka očekávaných početností $m_{expected}$ je


n	0	1	2	3	4	≥ 5	\sum
$m_{observed}$	447	132	42	21	3	2	647
$m_{expected}$	406	189	44	7	1	0	647

Příklad 2.2. Overdispersion a underdispersion v Poissonově modelu

V předchozím příkladu 2.1 jsme stanovili očekávané početnosti výskytu úrazů u dělníků v továrně. Do jednoho grafu zaneste nyní hodnoty pozorovaných početností $m_{observed}$ a hodnoty očekávaných početností $m_{expected}$. Pozorované a očekávané početnosti od sebe barevně odlište. Na základě výsledného grafu stanovte, zda došlo k overdisperzi nebo underdisperzi. Závěr podložte srovnáním rozptylu vypočítaného z pozorovaných dat s rozptylem vypočítaným z očekávaných dat.

Řešení příkladu 2.2

```
11 par(mar = c(...)) # okraje grafu 3, 4, 1, 1
12 plot(n, m.exp, type = 'h', col = ..., xlab = ..., ylab = ..., las = 1,
13       axes = F) # graf s vertikálnimi cervenymi carami ocek. abs. ctnosti m.exp
14 box(bty = 'o') # ramecek okolo grafu
15 axis(1, 0:5, labels = c(0:4, '5+')) # osa x
16 axis(2, las = ...) # osa y
17 points(n, m.exp, pch = 21, col = ...,
18         bg = rgb(1, 0, 0, 0.2)) # cervene body abs. ocek. ctnosti m.exp
19 lines(n, m.obs, type = ..., col = ...,
20       lty = 4) # modre vertikalni cary pozor. abs. ctnosti m.obs
21 points(..., ..., pch = ..., col = ...,
22         bg = rgb(...)) # modre body pozor. abs. ctnosti m.obs
23 mtext(..., side = 1, line = 2.1) # popisek osy x
24 legend('topright', pch = c(..., ...), col = c(..., ...),
25        pt.bg = c(rgb(...), rgb(...)),
26        legend = c(expression(...), expression(...)), bty = 'n') # legenda
```



Obrázek: Porovnání pozorovaných a očekávaných početností v Poissonově modelu

Oproti očekávaným početnostem jsou pozorované početnosti krajních případů vyšší a naopak pozorované početnosti nejčastějších případů (0, 1) jsou nižší. Tato situace ukazuje na vyšší rozptyl pozorovaných početností než očekávaných. Jde tedy o disperzi.

```

27 observed <- rep(...) # vektor pozor. dat: 0, ..., 0, 1, ..., 5, 5
28 expected <- ... # vektor ocek. dat: 0, ..., 0, 1, ..., 1, ..., 4
29 Var.obs <- ... # odhad rozptylu na zaklade pozor. dat
30 Var.exp <- ... # odhad rozptylu na zaklade ocek. dat
31 tab <- data.frame(...) # tabulka vysledku

```

	Var.obs	Var.exp
1	0.6919002	0.4690953

32
33


Hodnota rozptylu získaného z pozorovaných dat vyšla 0.6919, hodnota rozptylu získaného z očekávaných dat vyšla 0.4691. Vidíme, že hodnoty rozptylů i směrodatných odchylek se liší již v pozici na prvním desetinném místě. Hodnota rozptylu vypočítaného z pozorovaných dat je přibližně 1.5-krát vyšší než hodnota rozptylu vypočítaného z očekávaných dat.

Příklad 2.3. Graf pravděpodobnostní a distribuční funkce Poissonova modelu

V příkladu 2.1 jsme odhadli hodnotu parametru λ Poissonova rozdělení $\text{Poiss}(\lambda)$ jako $\hat{\lambda} = 0.4652$.

Nakreslete graf pravděpodobnostní a distribuční funkce Poissonova rozdělení $\text{Poiss}(\lambda)$, kde $\lambda = 0.4652$, v hodnotách $x = 0, 1, 2, 3, 4$ a $x \geq 5$.

Řešení příkladu 2.3



Obrázek: Pravděpodobnostní a distribuční funkce Poissonova modelu

Příklad 2.4. Výpočet pravděpodobností na základě Poissonova modelu

Za předpokladu, že náhodná veličina X , udávající počet úrazů u dělníků v továrně, pochází z Poissonova rozdělení, tj. $X \sim \text{Poiss}(\lambda)$, s parametrem $\lambda = 0.4652$, vypočítejte pravděpodobnost, že u náhodně vybraného dělníka dojde během jednoho roku k (a) nula úrazům; (b) třem nebo čtyřem úrazům; (c) nejvýše dvěma úrazům; (d) alespoň jednomu úrazu.

Řešení příkladu 2.4

(a)

```
34 lambda <- ... # hodnota parametru lambda  
35 dpois(...) # vypocet pravdepodobnosti
```

```
[1] 0.6280095
```

36

(b)

```
37 sum(dpois(...)) # vypocet pravdepodobnosti - prvni zpusob  
38 ppois(...) - ppois(...) # vypocet pravdepodobnosti - druhy zpusob
```

```
[1] 0.01176292
```

39

(c)

```
40 ppois(..., # vypocet pravdepodobnosti
```

```
[1] 0.9881136
```

41

(d)

```
42 1 - ppois(..., # vypocet pravdepodobnosti
```

```
[1] 0.3719905
```

43

Pravděpodobnost, že u vybraného dělníka nedojde během roku k žádnému úrazu, je 62.80 %.

Pravděpodobnost, že u vybraného dělníka dojde během roku k třem nebo čtyřem úrazům, je 1.18 %.

Pravděpodobnost, že u vybraného dělníka dojde během roku k nejvýše dvěma úrazům, je 98.81 %.

Pravděpodobnost, že u vybraného dělníka dojde během roku k alespoň jednomu úrazu, je 37.20 %.

Příklad 2.5. Střední hodnota a rozptyl náhodné veličiny z Poissonova modelu

Za předpokladu, že náhodná veličina X , udávající počet úrazů u dělníků v továrně, pochází z Poissonova rozdělení, tj. $X \sim \text{Poiss}(\lambda)$, s parametrem $\lambda = 0.4652$, vypočítejte střední hodnotu $E[X]$ a rozptyl $\text{Var}[X]$ náhodné veličiny X . Střední hodnotu a rozptyl porovnejte s jejich odhady vypočítanými na (a) základě očekávaných dat; (b) na základě pozorovaných dat (viz příklad 2.1).

Řešení příkladu 2.5

```
44 E.X <- ... # vypoct stredni hodnoty E[X] rozdeleni Poiss(lambda)
45 Var.X <- ... # vypoct rozptylu Var[X] rozdeleni Poiss(lambda)
46
47 expected <- rep(...) # vektor ocek. dat: 0, ..., 0, ..., 4, 4, 4, 5, 5
48 E.exp <- mean(...) # odhad stredni hodnoty na zaklade ocek. dat
49 Var.exp <- var(...) # odhad rozptylu na zaklade ocek. dat
50
51 observed <- ... # vektor pozor. dat: 0, ..., 0, ..., 4
52 E.obs <- ... # odhad stredni hodnoty na zaklade pozor. dat
53 Var.obs <- ... # odhad rozptylu na zaklade pozor. dat
54
55 (tab <- data.frame(E.X, Var.X, ...)) # tabulka vysledku
```

	E.X	Var.X	E.exp	Var.exp	E.obs	Var.obs
1	0.4652	0.4652	0.4667697	0.4690953	0.4652241	0.6919002

56

57

Střední hodnota počtu úrazů dělníků v továrně je 0.4652 s rozptylem 0.4652, odhad střední hodnoty počtu úrazů dělníků v továrně vypočítaný na základě očekávaných hodnot je 0.4668 s rozptylem 0.4691. Odhad střední hodnoty počtu úrazů dělníků v továrně vypočítaný na základě pozorovaných dat je 0.4652 s rozptylem 0.6919.

Příklad 2.6. Simulační studie: Součet náhodných veličin z Poissonova modelu

Věta 1: Nechť X_1, X_2, \dots, X_n , jsou vzájemně nezávislé náhodné veličiny pocházenící z Poissonova rozdělení, tj. $X_i \sim \text{Poiss}(\lambda_i)$, $i = 1, \dots, n$. Potom náhodná veličina $X = \sum_{i=1}^n X_i \sim \text{Poiss}(\sum_{i=1}^n \lambda_i)$.

Na základě simulační studie ověřte platnost věty 1. Vygenerujte tři nezávislé náhodné veličiny $X_i \sim \text{Poiss}(\lambda_i)$, $i = 1, 2, 3$, kde $\lambda_1 = 10$, $\lambda_2 = 20$, $\lambda_3 = 50$. Pomocí simulační studie ($M = 1000$) ukažte, že $\sum_{i=1}^3 X_i \sim \text{Poiss}(\lambda_1 + \lambda_2 + \lambda_3)$. Součty $M = 1000$ náhodných veličin zobrazte pomocí histogramu (hranice třídicích intervalů nastavte tak, aby šířka každého intervalu byla rovná 10) a superponujte jej hodnotami pravděpodobnostní funkce Poissonova rozdělení s parametrem $\lambda = \lambda_1 + \lambda_2 + \lambda_3$. Hodnoty pravděpodobnostní funkce vykreslete vždy ve středu každého třídicího intervalu.


Řešení příkladu 2.6

```
58 M <- ... # pocet simulaci M
59 lambda1 <- ... # parametr lambda1
60 lambda2 <- ... # parametr lambda2
61 lambda3 <- ... # parametr lambda3
```

```

62 X <- replicate(M, sum(rpois(1, lambda1), rpois(1, lambda2), rpois(1, lambda3)))
63   # 1000 souctu nah. velicin X1 + X2 + X3, kde X1 ~ Poiss(lambda1), ...
64 b <- seq(...) # hranice tridicich intervalu; posl. od 45 do 115 po kroku 10
65 centr <- seq(...) # stredy tridicich intervalu; posl. od 40 do 110 po kroku 10
66 y <- dpois(...) # pstni fce rozd. Poiss(lam1 + lam2 + lam3) ve stredech trid.int.
67
68 par(mar = ...) # nastaveni okraju 3, 4, 1, 1
69 hist(X, prob = ..., axes = ..., breaks = ..., density = ...,
70   col = ..., ylim = c(0, max(y) + 0.005), main = ...,
71   xlab = ..., ylab = ...) # histogram nah. vyberu X (v rel. skale)
72 box(...) # ramecek okolo grafu
73 axis(..., centr) # osa x
74 axis(...) # osa y
75 points(...) # cerne plne body
76 lines(...) # vertikalni cerne cary
77 mtext(...) # popisek osy x
78 legend(..., fill = c(...), density = c(...),
79   legend = c(...), bty = ...) # legenda

```



Obrázek: Porovnání rozdělení součtu $\sum_{i=1}^3 X_i$, kde $X_i \sim \text{Poiss}(\lambda_i)$, $i = 1, 2, 3$, s rozdělením $\text{Poiss}(\lambda_1 + \lambda_2 + \lambda_3)$

Příklad 2.7. Aproximace binomického modelu Poissonovým modelem

Poissonův model $\text{Poiss}(\lambda)$ je limitním případem binomického modelu $\text{Bin}(N, p)$, tj. pro $N \rightarrow \infty$, $p \rightarrow 0$, $Np \rightarrow \lambda$ platí

$$X \sim \text{Bin}(N, p) \rightarrow X \sim \text{Poiss}(\lambda).$$

Ovod'te vztah approximace binomického modelu Poissonovým rozdělením.

Řešení příkladu 2.7

$$\begin{aligned} \binom{N}{x} p^x (1-p)^{N-x} &= \frac{N!}{x!(N-x)!} p^x (1-p)^N (1-p)^{-x} \frac{N^x}{N^x} = \\ &= \frac{(Np)^x}{x!} \left(1 - \frac{Np}{N}\right)^N (1-p)^{-x} \frac{N!}{(N-x)! N^x} = \\ &= \frac{\lambda^x}{x!} e^{-\lambda}, \end{aligned}$$

protože $\lim_{Np \rightarrow \lambda} (Np)^x = \lambda^x$, $\lim_{Np \rightarrow \lambda, N \rightarrow \infty} \left(1 - \frac{Np}{N}\right)^N = e^{-\lambda}$, $\lim_{p \rightarrow 0} (1-p)^{-x} = 1$,

$$\lim_{N \rightarrow \infty} \frac{N!}{(N-x)! N^x} = 1.$$

Příklad 2.8. Aproximace binomického modelu Poissonovým modelem

Jak jsme si ukázali v příkladu 2.7, Poissonovo rozdělení je limitním případem binomického rozdělení pro $N \rightarrow \infty$, $p \rightarrow 0$ a $Np \rightarrow \lambda$. Pomocí simulační studie ověříme toho tvrzení. Vygenerujte pseudonáhodná čísla X (četnosti úspěchů) opakovaná M -krát ($M = 1000$) z $\text{Bin}(N, p)$, kde $N = 10$ a $p = 0.2$. Vykreslete histogram vygenerovaných pseudonáhodných čísel a superponujte jej hodnotami očekávaných početností za předpokladu $X \sim \text{Poiss}(\lambda)$, kde $\lambda = Np = 5 \times 0.2 = 1$.


1. Pomocí animace ukažte, jak se s $p \rightarrow 0$ zlepšuje approximace binomického rozdělení Poissonovým rozdělením. Hodnotu parametru N zvolte pevně $N = 10$ a za p dosazujte hodnoty 0.8, 0.75, 0.7, ..., 0.05.
2. Pomocí animace ukažte, jak se s $N \rightarrow \infty$ zlepšuje approximace binomického rozdělení Poissonovým rozdělením. Hodnotu parametru p zvolte pevně $p = 0.2$ a za hodnoty parametru N dosazujte $N = 3, 4, 5, \dots, 23, 24, 25, 30, 40, 50$.

Řešení příkladu 2.8

```

80 a.poiss <- function(N, p){
81   # N <- 10, p <- 0.2
82   X <- rbinom(..., size = N, prob = p) # 1000 pseudonahodnych cisel z rozd. Bin(N, p)
83   lambda <- ... # vyjadreni parametru lambda pomocí parametru N a p
84   px.pois <- dpois(..., lambda) # pstni fce Poiss(lambda) v hodnotach 0, 1, ..., N
85   par(..., oma = c(0, 0, 0, 0)) # nastaveni okraju 4, 4, 1, 1
86   hist(X, prob = TRUE, breaks = seq(-0.5, max(X) + 0.5, by = 1), density = ...,
87         col = "lightblue", ylim = c(0, 0.6), las = 1, main = ...,
88         xlab = "x", ylab = "p(x)") # histogram nah. vyberu X (v rel. skale)
89   box() # ramecek okolo grafu
90   points(px.pois) # cerne plne body; pstni fce Poiss(lambda)
91   lines(..., lty = 2) # cerne verikalni cary; pstni fce Poiss(lambda)
92   mtext("N = 10; p = 0.2", side = 1, pos = 1, font = 2) # popisek osy x
93   mtext("Poisson distribution approximation", side = 1, pos = 1, font = 2) # druhý popisek osy x: N = ..., p = ...
94   legend(..., fill = c("lightblue", "black"), density = c(...),
95          legend = c("simulovane", "ocekavane"), bty = "l") # legenda
96 }
97 a.poiss(N = 10, p = 0.2) # kontrola funkcnosti fce a.poiss()

```




Obrázek: Aproximace binomického rozdělení Poissonovým rozdělením; $N = 10$, $p = 0.2$

```

98 p <- seq(...) # posl. parametru p; od 0.8 do 0.01 po kroku -0.05
99 library(animation) # nacteni knihovny animation
100 oopts <- ani.options() # ulozeni hodnot defaultniho nastaveni parametru animace
101 ani.record(reset = T) # vymazani neaktualnich grafu z pameti Rka
102
103 saveLatex( # vygeneruje animaci
104   for(i in 1:length(p)){ # cyklus; prochazi i od 1 az po delku vektoru p
105     a.poiss(N = 10, p[i]) # provede fci a.poiss() pro kazdou hodnotu posl. p
106     ani.record(reset = F) # uchova vsechny grafy od zacatku cyklu v pameti
107   },
108   latex.filename = 'aprox-bin-poiss-p.tex', # nazev .tex (i .pdf) souboru
109   img.name = 'Rplot-aprox-bin-poiss-p') # nazev vygenerovanych obrazku
110   # (za uvedeny nazev se vzdy pripoji cislo obrazku)

```




Obrázek: Aproximace binomického rozdělení Poissonovým rozdělením pro $p \rightarrow 0$

```

111 N <- c(3:25, 30, 40, 50) # posl. parametru N; 3, 4, ..., 25, 30, 40, 50
112 oopts <- ... # ulozeni hodnot defaultniho nastaveni parametru animace
113 ani.record(...) # vymazani neaktualnich grafu z pameti Rka
114 saveLatex(
115   for(i in 1:length(N)){
116     a.poiss(...) # provede fci a.poiss() pro kazdou hodnotu posl. N (p = 0.2)
117     ani.record(...) # uchova vsechny grafy od zacatku cyklu v pameti
118   },
119   latex.filename = 'aprox-bin-poiss-N.tex',
120   img.name = 'Rplot-aprox-bin-poiss-N')

```



Obrázek: Aproximace binomického rozdělení Poissonovým rozdělením pro $N \rightarrow \infty$

- **Dataset 3: 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+	\sum
$m_{observed}$	109	65	22	3	1	0	200

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

Příklad 2.9. Výpočet očekávaných početností za předpokladu Poissonova modelu

Vezměte údaje z **datasetu 3**. Vypočítejte očekávané početnosti výskytu smrtelných úrazů způsobených kopnutím koněm za předpokladu, že početnosti úrazů X mají Poissonovo rozdělení $\text{Poiss}(\lambda)$ s parametrem

$$\hat{\lambda} = \frac{\sum_{n=0}^N nm_{observed}}{\sum_{n=0}^N m_{observed}}. \quad (2.2)$$

Řešení příkladu 2.9


Odhad parametru λ , tj. $\hat{\lambda} = 0.61$. Tabulka očekávaných početností $m_{expected}$ je

n	0	1	2	3	4	≥ 5	\sum
$m_{expected}$	109	66	20	4	1	0	200

Příklad 2.10. Overdispersion a underdispersion v Poissonově modelu

V předchozím příkladu 2.9 jsme stanovili očekávané početnosti výskytu smrtelných úrazů v pruských armádních jednotkách. Do jednoho grafu zaneste hodnoty pozorovaných početností $m_{observed}$ a hodnoty očekávaných početností $m_{expected}$. Pozorované a očekávané početnosti od sebe barevně odlište. Na základě výsledného grafu stanovte, zda došlo k overdisperzi nebo underdisperzi. Závěr podložte srovnáním rozptylu vypočítaného z pozorovaných dat s rozptylem vypočítaným z očekávaných dat.

Řešení příkladu 2.10



Obrázek: Porovnání pozorovaných a očekávaných početností v Poissonově modelu

Z tabulky očekávaných početností a z grafu vidíme, že očekávané početnosti se od pozorovaných příliš neliší. V tomto případě tedy nedochází ani k overdisperzi, ani k underdisperzi. Naše tvrzení podpoříme srovnáním rozptylu vypočítaného z porozovaných dat s rozptylem vypočítaným z očekávaných dat.

Var. obs	Var. exp
1 0.6109548	0.621005

121
122

Hodnota rozptylu získaného z pozorovaných dat vyšla 0.6110, hodnota rozptylu získaného z očekávaných dat vyšla 0.6210. Vidíme, že hodnoty rozptylů se liší v pozici na druhém desetinném místě, hodnoty směrodatných odchylek se liší v pozici na třetím desetinném místě.