

Aplikovaná statistika I

Téma 4: Diskrétní náhodné veličiny

Veronika Bendová

bendova.veroonika@gmail.com

Úvod a motivace

- motivace: reálná situace (data) → popíšeme ji nějakým známým rozdělením → z dat odhadneme parametry rozdělení → stanovíme nové závěry na základě vlastností rozdělení
- různé typy dat → různé typy rozdělení
 - diskrétní data → diskrétní rozdělení
 - binomické rozdělení ... $\text{Bin}(N, p)$
 - alternativní rozdělení ... $\text{Alt}(p)$
 - Poissonovo rozdělení ... $\text{Poiss}(\lambda)$
 - spojité data → spojité rozdělení
 - normální rozdělení ... $N(\mu, \sigma^2)$
 - standardizované normální $N(0, 1)$
 - dvouzměrné normální $N_2(\mu, \Sigma)$
 - + (spojitá) rozdělení testovacích statistik
 - Pearsonovo chi-kvadrátové rozdělení ... $\chi^2(n)$
 - Studentovo t -rozdělení ... $t(n)$
 - Fisherovo-Snedecorovo F -rozdělení ... $F(n_1, n_2)$

Základy pravděpodobnosti


- experiment → založen na *náhodném pokusu*
 - porodní hmotnost: náhodný pokus = zvážení 1 novorozence
 - vzdělání matky: náhodný pokus = dotaz na jednu matku
 - číslo na kostce: náhodný pokus = hod kostkou
- základní prostor Ω = množina všech možných výsledků
 - porodní hmotnost: $0 - \infty$; $0 - 6\,000$ g
 - počet starších sourozenců: 0, 1, 2, 3, 4, 5, 6, 7, 8, 9 a více
 - kostka ... 1–6
- jev = výsledek náhodného pokusu
 - hodila jsem kostkou → nastal jev: (a) padla 5; (b) padlo liché číslo; (c) padlo číslo ≤ 2
 - zvážila jsem novorozence → nastal jev: (a) vážil 2 654 g; (b) vážil více než 2 500 g, apod.
- pravděpodobnost
 - vyjadřuje, jak velká je naděje, že nějaký jev nastane
 - $\Pr(A) = \Pr(\text{nastal jev } A)$
 - $\Pr(A) \in \langle 0; 1 \rangle$; resp. $\langle 0\%; 100\% \rangle$
 - příklad: hod kostkou
 - $\Pr(\text{padne 1}) = 1/6 \dots 16.7\%$
 - $\Pr(\text{padne liché číslo}) = 1/2 \dots 50\%$
 - $\Pr(\text{padne 3, 4, 5 nebo 6}) = 2/3 \dots 66.67\%$
 - $\Pr(\text{padne 7}) = 0 \dots 0\%$

Náhodné veličiny

- víc než výsledek nás často zajímají jeho číselné interpretace
- náhodná veličina X = pravidlo, které zobrazuje základní prostor možných výsledků do množiny reálných čísel
- i -tá realizace náh. veličiny X se značí x_i
 - X ... počet puntíků na vrchní straně kostky: $x_1 = 4, x_2 = 1 \dots$
 - Y ... dokončené vzdělání; $y_1 = 1$ (ZŠ), $y_2 = 3$ (SŠm) ...
 - Y ... počet starších sourozenců $y_1 = 0, y_2 = 2 \dots$
 - X ... porodní hmotnost v g; $x_1 = 3470, x_2 = 3240 \dots$
 - Y ... největší šířka mozkovny v mm; $y_1 = 145, y_2 = 139 \dots$
- dva typy náhodných veličin
 - diskrétní náhodné veličiny
 - spojité náhodné veličiny


Diskrétní náhodné veličiny

- ze své podstaty nabývají převážně celých hodnot
 - počet sourozenců: 0, 3, 2, ...; novorozenec nemůže mít 2.4 sourozence
 - hod kostkou: padne 1, 2, 3, 4, 5, 6; nemůže padnout 3.5
 - $\Pr(X = 4) = \dots$
 - $\Pr(X \leq 4) = \dots$
 - $\Pr(X > 4) = \Pr(X \geq 5) = \dots$
 - $\Pr(3 < X \leq 5) = \dots$
- pravděpodobnostní funkce $p(x)$
 - $p(x) = \Pr(X = x)$
 - pravděpodobnostní funkce pro případ hodu kostkou



- nezáporná: $\Pr(x) \geq 0$; normovaná: $\sum_{i=1}^{\infty} \Pr(X = x_i) = 1$

- distribuční funkce $F(x)$
 - $F(x) = \Pr(X \leq x)$
 - distribuční funkce pro případ hodou kostkou



- komplementarita: $\Pr(X > x) = 1 - \Pr(X \leq x) = 1 - F(x)$

Binomické rozdělení

- Bernoulliho pokusy X_1, \dots, X_N
 - $X_i = 1 \dots$ událost nastala; $X_i = 0 \dots$ událost nenastala; $i = 1, \dots, N$
 - $\Pr(X_i = 1) = p$
 - $\Pr(X_i = 0) = 1 - p$
- Binomické rozdělení
 - $X \dots$ počet událostí v posloupnosti N nezávislých Bernoulliho pokusů, přičemž pravděpodobnost nastání události v každém pokusu je vyjádřena parametrem p
 - počet chlapců v rodině s 12 dětmi
 - celkový počet prstů (na obou rukou), na nichž se alespoň jednou objevil vzír
 - $\sum_{i=1}^N X_i = X \sim \text{Bin}(N, p)$
 - $\theta = (N, p)$
 - 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
$m_{observed}$	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

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

```
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) # 0.519215
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
```

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
m.exp	1	12	72	259	628	1085	1367	1266	854	410	133	26

11
12
13

```

14 par(mar = c(4, 4, 1, 1))
15 plot(0:12, m.obs, type = 'h', col = 'red', xlab = '',
16       ylab = 'absolutni cetnosti', las = 1)
17 lines(0:12, m.exp, type = 'h', lty = 2, col = 'black')
18 points(0:12, m.obs, pch = 21, col = 'darkred', bg = 'red')
19 points(0:12, m.exp, pch = 21, col = 'black', bg = 'black')
20 mtext('pocet starsich sourozencu', side = 1, line = 2.4)
21 legend('topright', pch = c(21, 21), col = c('darkred', 'black'),
22         pt.bg = c('red', 'black'), legend = c('pozorovane', 'ocekavane'),
23         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 (a) právě devět chlapců, (b) nejvýše čtyři chlapci, (c) alespoň osm chlapců, (d) čtyři, pět, šest, nebo sedm chlapců.

Řešení příkladu 4.3

(a) pravděpodobnost, že v rodině s 12 dětmi bude právě devět chlapců

```
24 N <- 12  
25 p <- 0.5192  
26 dbinom(9, N, p) # 0.06703911
```

(b) pravděpodobnost, že v rodině s 12 dětmi budou nejvýše čtyři chlapci

```
27 sum(dbinom(0:4, N, p)) # 0.1588736  
28 pbinom(4, N, p) # 0.1588736
```

(c) pravděpodobnost, že v rodině s 12 dětmi bude alespoň osm chlapců

```
29  1 - pbinom(7, N, p) # 0.2330869  
30  sum(dbinom(8:12, N, p)) # 0.2330869
```

(d) pravděpodobnost, že v rodině s 12 dětmi bude čtyři, pět, šest, nebo sedm chlapců

```
31  sum(dbinom(4:7, N, p)) # 0.7107605  
32  pbinom(7, N, p) - pbinom(3, N, p) # 0.7107605
```



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

```
33 x <- 0:N  
34 px <- dbinom(x, N, p)  
35 par(mar = c(4, 4, 1, 1))  
36 plot(x, px, type = 'h', ylim = c(0, 0.25), xlab = '', ylab = 'p(x)', las = 1)  
37 points(x, px, col = 'red', pch = 19)  
38 mtext('x', side = 1, line = 2)  
39 mtext('N = 12, p = 0.5192', side = 1, line = 3)
```



Poissonovo rozdělení

- 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 $\lambda > 0$
 - počet starších sourozenců
 - počet úmrtí v důsledku kopnutí koněm v Pruských armádních jednotkách
 - počet revizních operací kolenního koubu
- $X \sim \text{Poiss}(\lambda)$
- $\theta = \lambda$
- 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 4.5. Výpočet parametru λ 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 λ odhadněte střední hodnotu počtu starších sourozenců λ .

Řešení příkladu 4.5

Střední hodnotu počtu starších sourozenců odhadneme pomocí vzorce

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

```
40 data <- read.delim('17-anova-newborns-2.txt')
41 data <- na.omit(data)
42 prch <- data$prch.N
43 N <- length(prch) # 1381
44 (lambda <- sum(prch) / N) # 0.9427951
```

```
[1] 0.9427951
```

45

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

Příklad 4.6. Porovnání pozorovaných a očekávaných početností v Poissonově rozdělení

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


Řešení příkladu 4.6

```
46 m.obs <- data.frame(table(prch))$Freq
47 m.exp <- round(c(dpois(0:9, lambda)) * N)
48 tab <- data.frame(rbind(m.obs, m.exp))
49 names(tab) <- 0:9
```

	0	1	2	3	4	5	6	7	8	9
m.obs	590	510	175	48	23	17	10	4	3	1
m.exp	538	507	239	75	18	3	1	0	0	0

```
50
51
52
53 par(mar = c(4, 4, 1, 1))
54 plot(0:9, m.obs, type = 'h', ...) # zelene vertikalni cary
55 lines(0:9, m.exp, ...) # cerne vert. cary
56 points(0:9, m.obs, ...) # zelene body
57 points(0:9, m.exp, ...) # cerne body
58 mtext(...) # popisek osy x
59 legend(...) # doplneni legendy
```

50
51
52



Příklad 4.7. Výpočet pravděpodobností za předpokladu Poissonova rozdělení

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

určete pravděpodobnost, novorozenec má (a) dva, tři nebo čtyři starší sourozence; (b) alespoň čtyři starší sourozence; (c) nejvýše dva starší sourozence; (d) právě jednoho staršího sourozence.

Řešení příkladu 4.7

(a) pravděpodobnost, že novorozenec má dva, tři nebo čtyři starší sourozence

```
60 sum(dpois(...))
61 ppois(...) - ppois(...)
```

(b) pravděpodobnost, že novorozenec má alespoň čtyři starší sourozence

```
62 1 - ppois(...)
```

(c) pravděpodobnost, že novorozenec má nejvýše dva starší sourozence

```
63 ppois(...)
```

```
64 sum(dpois(...))
```

(d) pravděpodobnost, že novorozenec má právě jednoho staršího sourozence

```
65 dpois(...)
```

Interpretace výsledů: Pravděpodobnost, že novorozenec má dva, tři nebo čtyři starší sourozence je%. Pravděpodobnost, že novorozenec má alespoň čtyři starší sourozence je%. Pravděpodobnost, že novorozenec má nejvýše dva starší sourozence je%. Pravděpodobnost, že novorozenec má jednoho staršího sourozence je%.

Příklad 4.8. Graf pravděpodobnostní a distribuční funkce Poissonova rozdělení

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

Řešení příkladu 4.8

```
66 N <- 9
67 x <- 0:N
68 px <- dpois(x, lambda) # pslni fce rozdeleni Poiss(lambda) v hodnotach x
69 par(..., # nastaveni okraju 5, 4, 1, 1
70 plot(x, px, type = ..., ylim = c(0, 0.45), ...) # zelene vertikalni cary
71 points(x, px, ...) # zelene body
72 box(...) # ramecek okolo grafu
73 mtext(..., # popisek osy x
74 mtext(bquote(paste(lambda == 0.9428)), side = 1, line = 3) # druhý popisek osy x
```

