

Cvičení 5 - Příklady na testování exponenciálního a Poissonova rozložení

I. Test dobré shody

H_0 : náhodný výběr X_1, \dots, X_n pochází z rozložení s distribuční funkcí $\Phi(x)$.

Testová statistika $K = \sum_{j=1}^r \frac{(n_j - np_j)^2}{np_j} \approx \chi^2(r-p-1)$, když H_0 platí.

Přitom:

r je počet variant resp. počet třídících intervalů veličiny X ,

p je počet odhadovaných parametrů daného rozložení,

n_j je absolutní četnost j -tého třídícího intervalu pro veličinu X resp. j -té varianty veličiny X ,

np_j je teoretická četnost j -tého třídícího intervalu pro veličinu X resp. j -té varianty veličiny X .

Platí-li nulová hypotéza, pak $p_j = \Phi(u_{j+1}) - \Phi(u_j)$ resp. $p_j = \Phi(x_{[j]}) - \lim_{x \rightarrow x_{[j]}^-} \Phi(x) = P(X = x_{[j]})$.

Kritický obor: $W = \langle \chi^2_{1-\alpha}(r-p-1), \infty \rangle$. Jestliže $K \in W$, H_0 zamítáme na asymptotické hladině významnosti α .

Aproximace se považuje za vyhovující, když $np_j \geq 5$, $j = 1, \dots, r$.

Při nesplnění podmínky $np_j \geq 5$, $j = 1, \dots, r$ je třeba některé intervaly resp. varianty slučovat.

II. Jednoduchý test exponenciálního rozložení (Darlingův test)

H_0 : náhodný výběr X_1, \dots, X_n pochází z exponenciálního rozložení.

Testová statistika $K = \frac{(n-1)S^2}{M^2} \approx \chi^2(n-1)$, když H_0 platí.

Přitom M je výběrový průměr a S^2 je výběrový rozptyl daného náhodného výběru.

Kritický obor: $W = \langle 0, \chi^2_{\alpha/2}(n-1) \rangle \cup \langle \chi^2_{1-\alpha/2}(n-1), \infty \rangle$.

Jestliže $K \in W$, H_0 zamítáme na asymptotické hladině významnosti α .

III. Jednoduchý test Poissonova rozložení

H_0 : náhodný výběr X_1, \dots, X_n pochází z Poissonova rozložení.

Testová statistika $K = \frac{(n-1)S^2}{M} \approx \chi^2(n-1)$, když H_0 platí.

Kritický obor: $W = \langle 0, \chi^2_{\alpha/2}(n-1) \rangle \cup \langle \chi^2_{1-\alpha/2}(n-1), \infty \rangle$.

Jestliže $K \in W$, H_0 zamítáme na asymptotické hladině významnosti α .

IV. Test hypotézy o střední hodnotě Poissonova rozložení

$H_0: \lambda = \lambda_0$ proti $H_1: \lambda \neq \lambda_0$. Testová statistika: $T_0 = \sum_{i=1}^n X_i \sim \text{Po}(n\lambda_0)$ za platnosti H_0 .

p -hodnota = $2 \min\{\Phi(t_0), 1 - \Phi(t_0)\}$, kde $\Phi(t_0)$ je hodnota distribuční funkce rozložení $\text{Po}(n\lambda_0)$.

Je-li $p \leq \alpha$, H_0 zamítáme na hladině významnosti α ve prospěch H_1 .

V. Test hypotézy o shodě středních hodnot dvou Poissonových rozložení

$H_0: \lambda_1 = \lambda_2$ proti $H_1: \lambda_1 \neq \lambda_2$. Předpokládá se splnění podmínky $\lambda_i > 9$, $i = 1, 2$.

Testová statistika: $T_0 = \frac{M_1 - M_2}{\sqrt{\frac{M_1}{n_1} + \frac{M_2}{n_2}}} \approx N(0,1)$, když H_0 platí

p -hodnota = $2 \min\{\Phi(t_0), 1 - \Phi(t_0)\}$, kde $\Phi(t_0)$ je hodnota distribuční funkce rozložení $N(0,1)$.

Je-li $p \leq \alpha$, H_0 zamítáme na hladině významnosti α ve prospěch H_1 .

VI. Test hypotézy o střední hodnotě exponenciálního rozložení

$H_0: 1/\lambda = 1/\lambda_0$ proti $H_1: 1/\lambda \neq 1/\lambda_0$. Testová statistika: $T_0 = \sum_{i=1}^n X_i \sim \text{Er}(n, \lambda_0)$, když H_0 platí.

p-hodnota = $2 \min\{\Phi(t_0), 1-\Phi(t_0)\}$, kde $\Phi(t_0)$ je hodnota distribuční funkce rozložení $\text{Er}(n, \lambda_0)$.
Je-li $p \leq \alpha$, H_0 zamítáme na hladině významnosti α ve prospěch H_1 .

Příklad 1.: V systému hromadné obsluhy byla sledována doba obsluhy 70 zákazníků (v min).
Výsledky jsou uvedeny v tabulce rozložení četností:

Doba obsluhy	Počet zákazníků
(0, 3]	14
(3,6]	16
(6,9]	10
(9,12]	9
(12,15]	8
(15,18]	5
(18,21]	3
(21,24]	5

Na asymptotické hladině významnosti 0,05 testujte hypotézu, že daný náhodný výběr pochází z exponenciálního rozložení. Použijte:

- test dobré shody,
- Darlingův test exponenciálního rozložení

Řešení:

Testujeme H_0 : náhodný výběr X_1, \dots, X_{70} pochází z $\text{Ex}(\lambda)$ proti H_1 : non H_0 .

Ad a) Odhadneme parametr λ :

$$\hat{\lambda} = \frac{1}{m} = \frac{1}{\frac{1}{n} \sum_{j=0}^r n_j x_{[j]}} = \frac{1}{\frac{1}{70} (14 \cdot 1,5 + 16 \cdot 4,5 + \dots + 5 \cdot 22,5)} = 0,1122$$

Pravděpodobnost, že náhodná veličina s rozložením $\text{Ex}(\lambda)$, kde $\lambda = 0,1122$ se bude realizovat v intervalu (u_j, u_{j+1}) je $p_j = \Phi(u_{j+1}) - \Phi(u_j)$, $j = 1, \dots, r-1$, $p_r = 1 - \Phi(u_r)$ (součet p_j musí být 1, tedy horní mez posledního třídícího intervalu klademe ∞), kde $\Phi(x) = 1 - e^{-\lambda x}$. Střed posledního třídícího intervalu bude ve stejné vzdálenosti od u_r jako je střed předposledního třídícího intervalu.

Výpočty potřebné pro stanovení testové statistiky K uspořádáme do tabulky.

(u_j, u_{j+1})	$x_{[j]}$	n_j	p_j	np_j
(0, 3]	1,5	14	0,2858	20,0033
(3,6]	4,5	16	0,2041	14,2871
(6,9]	7,5	10	0,1458	10,2044
(9,12]	10,5	9	0,1041	7,2884
(12,15]	13,5	8	0,0744	5,2056
(15,18]	16,5	5	0,0531	3,7181
(18,21]	19,5	3	0,0378	2,6556
(21, 24]	22,5	5	0,0271	1,8967

Podmínky dobré aproximace nejsou splněny, sloučíme tedy intervaly (15,18] až (21,24] .

(u_j, u_{j+1})	$x_{[j]}$	n_j	p_j	np_j	$(n_j - np_j)^2 / np_j$
(0, 3]	1,5	14	0,2818	20,0033	1,8017
(3,6]	4,5	16	0,2041	14,2871	0,2054
(6,9]	7,5	10	0,1458	10,2044	0,0041
(9,12]	10,5	9	0,1041	7,2884	0,4020
(12,15]	13,5	8	0,0744	5,2056	1,5000
(15,24]	19,5	13	0,1181	8,2704	2,7047

$K = 1,8017 + \dots + 2,7047 = 6,6178$, $r = 6$, $p = 1$, $r - p - 1 = 4$, $\chi^2_{0,95}(4) = 9,4877$.

$K \notin W = \langle 9,4877, \infty \rangle \Rightarrow$ na asymptotické hladině významnosti 0,05 nelze zamítnout hypotézu, že doba obsluhy se řídí exponenciálním rozložením.

Ad b)

$$m = \frac{1}{70} (14 \cdot 1,5 + 16 \cdot 4,5 + \dots + 5 \cdot 22,5) = 8,9143$$

$$s^2 = \frac{1}{69} [19 \cdot (1,5 - 8,9143)^2 + 16 \cdot (4,5 - 8,9143)^2 + \dots + 5 \cdot (22,5 - 8,9143)^2] = 41,1447$$

$$\text{Testová statistika: } K = \frac{(n-1)S^2}{M^2} = \frac{69 \cdot 41,1447}{8,9143^2} = 35,7265.$$

$$\text{Kritický obor: } W = \langle 0, \chi^2_{0,025}(69) \rangle \cup \langle \chi^2_{0,975}(69), \infty \rangle = \langle 0; 47,9242 \rangle \cup \langle 93,8565, \infty \rangle.$$

H_0 zamítáme na asymptotické hladině významnosti 0,05.

Řešení pomocí MATLABu:

Ad a)

Úkol vyřešíme pomocí funkce `tds_exp.m`. Přitom již zohledníme, že při původním třídění do 8 intervalů nebyly splněny podmínky dobré aproximace a budeme pracovat se 6 intervaly.

Zadáme vektor mezí `uj = [0 3 6 9 12 15 24]'`, vektor pozorovaných četností

`nj = [14 16 10 9 8 13]'` a hladinu významnosti `alfa=0.05`.

Zavoláme funkci `tds_exp`:

```
[zamitnuti,K,p,lambda]=tds_exp(uj,nj,alfa)
```

Dostaneme výsledek:

```
zamitnuti=0, K=6.6178, p=0.1575, lambda=0.1122
```

Protože p -hodnota je větší než hladina významnosti 0,05, H_0 nezamítáme na asymptotické hladině významnosti 0,05.

Ad b)

Použijeme funkci `darling.m`.

Zadáme vstupní vektor středů původních třídících intervalů společně s absolutními četnostmi třídících intervalů:

```
X = [1.5 14; 4.5 16; 7.5 10; 10.5 9; 13.5 8; 16.5 5; 19.5 3; 22.5 5]
```

Zavoláme funkci `darling`:

```
[zamitnuti,K,p,lambda]=darling(X)
```

Dostaneme výsledek:

```
zamitnuti=1, K=35.7265, p=6.1430e-004, lambda=0.1122
```

Darlingův test zamítá hypotézu o exponenciálním rozložení na asymptotické hladině významnosti 0,05.

Příklad 2.: Na jistém nádraží byl sledován počet příjezdějících vlaků za 1 h. Pozorování bylo prováděno celkem 15 dnů (tj. 360 h) a výsledky jsou uvedeny v tabulce:

Počet vlaků za 1 hodinu	0	1	2	3	4	5	6	7 a víc
četnost	27	93	103	58	50	21	6	2

Na asymptotické hladině významnosti 0,05 testujte hypotézu, že počet příjezdějících vlaků za 1 h se řídí Poissonovým rozložením, a to a) testem dobré shody, b) jednoduchým testem Poissonova rozložení.

Řešení:

Testujeme H_0 : náhodný výběr X_1, \dots, X_{360} pochází z $Po(\lambda)$ proti H_1 : non H_0 .

Ad a) Nejprve odhadneme parametr λ Poissonova rozložení:

$$\hat{\lambda} = m = \frac{1}{n} \sum_{j=0}^r n_j x_{[j]} = \frac{1}{360} (27 \cdot 0 + 93 \cdot 1 + \dots + 2 \cdot 7) = 2,3$$

Pravděpodobnost, že náhodná veličina s rozložením $Po(\lambda)$, kde $\lambda = 2,3$ bude nabývat hodnot

$$0, 1, \dots, 7 \text{ a víc je } p_j = \frac{\lambda^j}{j!} e^{-\lambda} = \frac{2,3^j}{j!} e^{-2,3}, j = 0, 1, \dots, 6, p_7 = 1 - (p_0 + p_1 + \dots + p_6).$$

Výpočty potřebné pro stanovení testové statistiky K uspořádáme do tabulky:

j	n_j	p_j	np_j
0	27	0,1003	36,0932
1	93	0,2306	83,0143
2	103	0,2652	95,4665
3	58	0,2033	73,1910
4	50	0,1169	43,0848
5	21	0,0538	19,3590
6	6	0,0216	7,4210
7 a víc	2	0,0094	3,3703

Podmínky dobré aproximace nejsou splněny, sloučíme tedy varianty 6 a 7 a víc.

j	n_j	p_j	np_j	$(n_j - np_j)^2 / np_j$
0	27	0,1003	36,0932	2,2909
1	93	0,2306	83,0143	1,2012
2	103	0,2652	95,4665	0,5945
3	58	0,2033	73,1910	3,1529
4	50	0,1169	43,0848	1,4887
5	21	0,0538	19,3590	0,1391
6 a víc	8	0,0300	10,7912	0,7220

$K = 2,2909 + 1,2012 + \dots + 0,7220 = 9,5892$, $r = 7$, $p = 1$, $r - p - 1 = 5$, $\chi^2_{0,95}(5) = 11,0705$.
Protože $9,5892 < 11,0705$, H_0 nezamítáme na asymptotické hladině významnosti 0,05.

Ad b)

$$m = \frac{1}{360} (27 \cdot 0 + 93 \cdot 1 + \dots + 2 \cdot 7) = 2,3$$

$$s^2 = \frac{1}{359} [27 \cdot (0 - 2,3)^2 + 93 \cdot (1 - 2,3)^2 + \dots + 2 \cdot (7 - 2,3)^2] = 2,121448$$

$$\text{Testová statistika: } K = \frac{(n-1)S^2}{M} = \frac{359 \cdot 2,121448}{2,3} = 331,1304,$$

$$\text{Kritický obor: } W = \langle 0, \chi^2_{0,025}(359) \rangle \cup \langle \chi^2_{0,975}(359), \infty \rangle = \langle 0; 308,4 \rangle \cup \langle 413,4; \infty \rangle$$

H_0 nezamítáme na asymptotické hladině významnosti 0,05.

Řešení pomocí MATLABu:

Ad a) Použijeme funkci `tds_poiss.m`. Opět zohledníme, že při původním zadání nebyly splněny podmínky dobré aproximace a použijeme tedy jenom 7 variant.

Zadáme vektor variant $x_j = [0:6]'$ a vektor pozorovaných četností $n_j = [27 \ 93 \ 103 \ 58 \ 50 \ 21 \ 8]'$.

Zavoláme funkci `tds_poiss`:

```
[zamitnuti,K,p,lambda]=tds_poiss(xj,nj,alfa)
```

Dostaneme výsledek:

```
zamitnuti=0, K=9.6033, p=0.0873, lambda=2.2944
```

H_0 tedy nezamítáme na asymptotické hladině významnosti 0,05.

Ad b) Použijeme funkci `darling.m`.

Zadáme vstupní vektor variant $x_j=[0:7]'$ společně s absolutními četnostmi těchto variant $n_j=[27\ 93\ 103\ 58\ 50\ 21\ 6\ 2]'$ a utvoříme matici X:

$X = [x_j\ n_j]$;

Zavoláme funkci darling:

$[zamidnuti, K, p, lambda] = \text{darling}(X, 'poiss')$

Dostaneme výsledek:

$zamidnuti=0, K=331.1304, p=0.2968, lambda=2.3$

Příklad 3.: Ve firmě mají kopírku, která se v průměru porouchá 3x za týden. Přestěhovali ji do vyššího podlaží, kde je hůře přístupná. Během následujících šesti týdnů zaznamenali tyto počty poruch: 3, 4, 2, 1, 1, 2. Na hladině významnosti 0,05 testujte hypotézu, že

a) počty poruch kopírky po přestěhování mají Poissonovo rozložení (použijte jednoduchý test Poissonova rozložení),

b) střední hodnota počtu poruch kopírky po přestěhování je nižší než před přestěhováním.

Řešení:

Ad a) Testujeme H_0 : náhodný výběr X_1, \dots, X_6 pochází z $Po(\lambda)$ proti H_1 : non H_0 .

$$m = \frac{1}{6}(3 + 4 + 2 + 1 + 1 + 2) = \frac{13}{6} = 2,1667$$

$$s^2 = \frac{1}{5} \left[\left(3 - \frac{13}{6}\right)^2 + \dots + \left(2 - \frac{13}{6}\right)^2 \right] = 1,3667$$

$$\text{Testová statistika: } K = \frac{(n-1)S^2}{M} = \frac{5 \cdot 1,3667}{2,1667} = 3,1538$$

$$\text{Kritický obor: } W = \langle 0, \chi^2_{0,025}(5) \rangle \cup \langle \chi^2_{0,975}(5), \infty \rangle = \langle 0; 0,8312 \rangle \cup \langle 12,8325; \infty \rangle$$

H_0 nezamítáme na asymptotické hladině významnosti 0,05.

Ad b) Testujeme $H_0: \lambda = 3$ proti $H_1: \lambda < 3$.

Známe $n = 6, m = 13/6, \lambda_0 = 3, \alpha = 0,05, n\lambda_0 = 18$

Realizace testové statistiky: $t_0 = 3+4+2+1+1+2 = 13$

p-hodnota = $\Phi(13) = \text{poisscdf}(13,18) = 0,1426$

Na hladině významnosti 0,05 nezamítáme nulovou hypotézu.

Příklad 4.: Adam si zaznamenával počty e-mailů, které mu přišly během týdne, bylo jich 126. Jeho přítelkyni Barboře přišlo za týden 112 e-mailů. Za předpokladu, že počty e-mailů se řídí Poissonovým rozložením, na asymptotické hladině významnosti 0,05 testujte hypotézu, že střední hodnota počtu e-mailů, které dostane Adam za den, je stejná jako střední hodnota počtu e-mailů, které dostane Barbora za den.

Řešení:

Testujeme $H_0: \lambda_1 = \lambda_2$ proti $H_1: \lambda_1 \neq \lambda_2$. Realizace testové statistiky:

$$t_0 = \frac{m_1 - m_2}{\sqrt{\frac{m_1}{n_1} + \frac{m_2}{n_2}}} = \frac{\frac{126}{7} - \frac{112}{7}}{\sqrt{\frac{126}{7} + \frac{112}{7}}} = \frac{18 - 16}{\sqrt{34}} = 0,9075$$

$$\text{Kritický obor: } W = (-\infty, -1,96) \cup \langle 1,96, \infty \rangle$$

H_0 nezamítáme na asymptotické hladině významnosti 0,05.

Příklady k samostatnému řešení:

1. Máme k dispozici 10 údajů o době mezi poruchami určitého zařízení (v hodinách):

14 25 196 205 64 237 162 84 121 38

Na hladině významnosti 0,05 rozhodněte pomocí Darlingova testu, zda lze rozložení doby do poruchy považovat za exponenciální. [Nulovou hypotézu nezamítáme na hladině významnosti 0,05, p-hodnota = 0,2546]

2. Česká obchodní inspekce provedla šetření ve 22 sběrnách druhotných surovin. Zjišťovala počet závad, které se v jednotlivých sběrnách vyskytly. Výsledky jsou uvedeny v tabulce:

Počet závad	0	1	2	3
Počet sběrů	7	5	4	6

Na hladině významnosti 0,05 rozhodněte pomocí a) testu dobré shody (ověřte splnění podmínek dobré aproximace), b) jednoduchého testu, zda lze rozložení počtu závad považovat za Poissonovo. [Nulovou hypotézu nezamítáme na hladině významnosti 0,05, a) p-hodnota = 0,1125, b) p-hodnota = 0,7732]