

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

Výsledky:

Ad a) Odhad parametru lambda je 0,1122. Nejsou splněny podmínky dobré aproximace, proto poslední tři intervaly sloučíme do jednoho. Testová statistika $K = 6,6178$, $W = \langle 9,4877, \infty \rangle$, tedy na asymptotické hladině významnosti 0,05 nelze zamítnout hypotézu, že doba obsluhy se řídí exponenciálním rozložením.

Ad b) $m = 8,9143$, $s^2 = 41,1447$, testová statistika $K = 35,7265$, 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 $\alpha = 0.05$.

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 přijíždějících 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 přijíždějících vlaků za 1 h se řídí Poissonovým rozložením, a to a) testem dobré shody, b) jednoduchým testem Poissonova rozložení.

Výsledky:

Ad a) Odhad parametru $\lambda = 2,3$. Nejsou splněny podmínky dobré aproximace, proto poslední dvě varianty sloučíme do jedné. Testová statistika $K = 9,5892$, $W = \langle 11,0705, \infty \rangle$, tedy na asymptotické hladině významnosti 0,05 nelze zamítnout hypotézu, že počet vlaků přijíždějících za 1 h se řídí Poissonovým rozložením.

Ad b) $m = 2,3$, $s^2 = 2,121448$, testová statistika $K = 331,1304$, 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_pois.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_pois:

[zamitnuti,K,p,lambda]=tds_pois(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 vytvoříme matici X:

$X = [x_j\ n_j]$;

Zavoláme funkci darling:

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

Dostaneme výsledek:

zamitnuti=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.

Výsledky:

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

Testová statistika: $K = 3,1538$

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 $H_1: \lambda < 3$.

p-hodnota = 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.

Výsledky:

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

Testová statistika = 0,9078, kritický obor: $W = (-\infty, -1,96) \cup (1,96, \infty)$

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]