

## 5. Testování exponenciálního a Poissonova rozložení

### 5.1. Věta (test dobré shody – viz přednáška 2)

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

$H_1$ : non  $H_0$

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

$r$  ... počet třídících intervalů  $(u_j, u_{j+1})$  ve spojitém případě resp. počet variant  $x_{[j]}$  v diskrétním případě.

$n_j$  ... absolutní četnost  $j$ -tého třídícího intervalu resp.  $j$ -té varianty.

$p_j$  ... pravděpodobnost, že náhodná veličina  $X$  s distribuční funkcí  $\Phi(x)$  se bude realizovat v  $j$ -tém třídícím intervalu resp.  $j$ -tou variantou.

$p$  ... počet odhadovaných parametrů testovaného rozložení.

Kritický obor:  $W = \langle \chi^2_{1-\alpha}(r - p - 1), \infty \rangle$

$K \in W \Rightarrow H_0$  zamítáme na asymptotické hladině významnosti  $\alpha$ .

Podmínky dobré aproximace:  $np_j \geq 5, j = 1, \dots, r$ . Při nesplnění těchto podmínek se doporučuje slučování některých třídících intervalů resp. variant.

**5.2. Příklad:** Byla zjišťována doba životnosti 45 součástek (v hodinách). Ze získaných údajů byl vypočten výběrový průměr  $m = 99,93$  h a výběrový rozptyl  $s^2 = 7328,9$  h<sup>2</sup>. Máme k dispozici roztríděné údaje:

Doba životnosti	Počet součástek
(0,50)	15
(50,100)	14
(100,150)	6
(150,200)	5
(200,250)	2
(250,300)	1
(300,350)	1
(350,400)	1

Na asymptotické hladině významnosti 0,05 testujte hypotézu, že doba životnosti se řídí exponenciálním rozložením.

**Řešení:**  $\hat{\lambda} = \frac{1}{m} = \frac{1}{99,93}$ , testujeme  $H_0: X_1, \dots, X_{45} \sim \text{Ex}\left(\frac{1}{99,93}\right)$  proti  $H_1: \text{non } H_0$ . Počítáme

pravděpodobnosti  $p_j = \int_{u_j}^{u_{j+1}} \frac{1}{99,93} e^{-\frac{x}{99,93}} dx, j = 1, 2, \dots, 8$

j	$(u_j, u_{j+1})$	$n_j$	$p_j$	$np_j = 45p_j$
1	$(0, 50)$	15	0,3937	17,72
2	$(50, 100)$	14	0,2387	10,74
3	$(100, 150)$	6	0,1447	6,51
4	$(150, 200)$	5	0,0878	3,95
5	$(200, 250)$	2	0,0532	2,39
6	$(250, 300)$	1	0,0323	1,45
7	$(300, 350)$	1	0,0196	0,88
8	$(350, 400)$	1	0,0119	0,53

Vidíme, že pro  $j = 4, \dots, 8$  nejsou splněny podmínky dobré aproximace. Posledních 5 intervalů tedy sloučíme do jednoho.

Dostaneme novou tabulku

$j$	$(u_j, u_{j+1})$	$n_j$	$p_j$	$np_j = 45p_j$
1	$(0, 50)$	15	0,3937	17,7157
2	$(50, 100)$	14	0,2387	10,7413
3	$(100, 150)$	6	0,1447	6,5127
4	$(150, 400)$	10	0,2046	9,2084

Testová statistika:

$$K = \sum_{j=1}^r \frac{(n_j - np_j)^2}{np_j} = \frac{(15 - 17,7157)^2}{17,7157} + \frac{(14 - 10,7413)^2}{10,7413} + \frac{(6 - 6,5127)^2}{6,5127} + \frac{(10 - 9,2084)^2}{9,2084} = 1,5133$$

Kritický obor:  $W = \langle \chi^2_{1-\alpha}(r-p-1), \infty \rangle = \langle \chi^2_{0,95}(4-1-1), \infty \rangle = \langle 5,9915, \infty \rangle$

$K \notin W \Rightarrow H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

**5.3. Poznámka:** V MATLABu se test dobré shody pro exponenciální rozložení provádí pomocí funkce `tds_exp.m`.

```

function [zमितनुति,K,p,lambda]=tds_exp(uj,nj,alfa)
% test dobre shody k overeni exponencialniho rozlozeni
% syntaxe: [zमितनुति,K,p,lambda]=tds_exp(uj,nj,alfa)
% vstupni parametry:
% uj ... sloupcovy vektor s mezemi tridicich intervalu
% nj ... sloupcovy vektor absolutnich cetnosti tridicich intervalu
% alfa ... hladina vyznamnosti testu
% vystupni parametry:
% zमितनुति ... =0, kdyz H0 nezमितame
%          =1, kdyz H0 zमितame
% K ... hodnota testove statistiky
% p ... p-hodnota testu
% lambda ... odhad parametru exponencialniho rozlozeni
delka=size(uj);
delka=delka(:,1);
dti=diff(uj/2);
xj=[uj(1:delka-1)+dti];
n=sum(nj);
lambda=n/(nj'*xj);
npj=[n*diff(expcdf(uj,1/lambda))];
%test podminek dobre aproximace....hodnota 1 pro poruseni
if sum(npj<5)>0
    poruchy_podminek=(npj<5)'
    error('Nejsou splneny podminky dobre aproximace.')
end;
K=sum((nj-npj).^2./npj);
kvantil=chi2inv(1-alfa,size(nj,1)-2);
p=1-chi2cdf(K,size(nj,1)-2);
zमितनुति=(p<alfa);

```

Při řešení pomocí funkce `tds_exp.m` zohledníme, že při původním třídění do 8 intervalů nebyly splněny podmínky dobré aproximace a budeme pracovat se 4 intervaly.

Zadáme vektor mezí:

```
uj=[0;50;100;150;400];
```

vektor pozorovaných četností:

```
nj=[15;14;6;10];
```

a hladinu významnosti:

```
alfa=0.05;
```

Zavoláme funkci `tds_exp`:

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

Dostaneme výsledek:

```
zamitnuti=0, K=1.4068, p=0.4949, lambda=0.0091
```

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

**5.4. Příklad:** Sledujeme rozložení počtu pacientů, kteří během 75 dnů přijdou na zubní pohotovost. Osmihodinovou pracovní dobu rozdělíme do půlhodinových intervalů a v každém intervalu zjistíme počet příchozích pacientů (máme  $16 \times 75 = 1200$  intervalů).

Počet pacientů	0	1	2	3	4	5	6	7	8 a víc
četnost	79	188	282	275	196	114	45	10	11

Na asymptotické hladině významnosti 0,05 testujte hypotézu, že počet příchozích pacientů během půl hodiny se řídí Poissonovým rozložením.

### Řešení:

$$\hat{\lambda} = m = \frac{1}{1200} (79 \cdot 0 + 188 \cdot 1 + 282 \cdot 2 + 275 \cdot 3 + 196 \cdot 4 + 114 \cdot 5 + 45 \cdot 6 + 10 \cdot 7 + 11 \cdot 8) = 2,7992,$$

testujeme  $H_0: X_1, \dots, X_{1200} \sim \text{Po}(2,7992)$  proti  $H_1: \text{non } H_0$ . Počítáme pravděpodobnosti

$$p_j = \frac{2,7992^j}{j!} e^{-2,7992}, j = 0, 1, \dots, 7, p_8 = 1 - \sum_{j=0}^7 p_j.$$

j	0	1	2	3	4	5	6	7	8
$n_j$	79	188	282	275	196	114	45	10	11
$np_j$	73,0329	204,4313	286,1186	266,9646	186,8195	104,5878	48,7931	19,5114	9,7406

Podmínky dobré aproximace jsou splněny.

Testová statistika:

$$K = \sum_{j=1}^r \frac{(n_j - np_j)^2}{np_j} = \frac{(79 - 73,0329)^2}{73,0329} + \frac{(188 - 204,4313)^2}{204,4313} + \dots + \frac{(11 - 9,7406)^2}{9,7406} = 8,5019$$

$$\text{Kritický obor: } W = \langle \chi^2_{1-\alpha}(r - p - 1), \infty \rangle = \langle \chi^2_{0,95}(9 - 1 - 1), \infty \rangle = \langle 14,067, \infty \rangle$$

$K \notin W \Rightarrow H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

**5.5. Poznámka:** V MATLABu se test dobré shody pro Poissonovo rozložení provádí pomocí funkce `tds_poiss.m`.



```

function [zamitnuti,K,p,lambda]=tds_poiss(xj,nj,alfa)
% test dobre shody k overeni Poissonova rozlozeni
% syntaxe: [zamitnuti,K,p,lambda]=tds_poiss(xj,nj,alfa)
% vstupni parametry:
% xj ... sloupcovy vektor variant sledovane veliciny
% nj ... sloupcovy vektor absolutnich cetnosti variant
% alfa ... hladina vyznamnosti testu
% vystupni parametry>
% zamitnuti ... =0, kdyz H0 nezamitame
%           =1, kdyz H0 zamitame
% K ... hodnota testove statistiky
% p ... p-hodnota testu
% lambda ... odhad parametru Poissonova rozlozeni
n=sum(nj);
r=size(xj,1);
lambda=sum(nj*xj)/n;
pj=poisspdf(xj(1:r-1),lambda);
pj=[pj;1-sum(pj)];
npj=n*pj;
%test podminek dobre aproximace....hodnota 1 pro poruseni
if sum(npj<5)>0
    poruchy_podminek=(npj<5)'
    error('Nejsou splneny podminky dobre aproximace.')
end;
K=sum((nj-npj).^2./npj);
kvantil=chi2inv(1-alfa,size(nj,1)-2);
p=1-chi2cdf(K,size(nj,1)-2);
zamitnuti=(p<alfa);

```

Příklad vyřešíme pomocí funkce `tds_poiss.m`.

Zadáme vektor variant:

```
xj=[0:8]';
```

vektor pozorovaných četností:

```
nj=[79;188;282;275;196;114;45;10;11];
```

a hladinu významnosti:

```
alfa=0.05;
```

Zavoláme funkci `tds_poiss`:

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

Dostaneme výsledek:

```
zamitnuti=0, K=8.5019, p=0.2904, lambda=2.7992
```

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

### 5.6. Věta: Darlingův (jednoduchý) test exponenciálního rozložení

Testujeme hypotézu, která tvrdí, že náhodný výběr  $X_1, \dots, X_n$  pochází z exponenciálního rozložení. Označme  $M$  výběrový průměr a  $S^2$  výběrový rozptyl tohoto náhodného výběru. Víme, že střední hodnota náhodné veličiny  $X \sim \text{Ex}(\lambda)$  je  $E(X) = 1/\lambda$  a rozptyl je  $D(X) = 1/\lambda^2$ .

Test založíme na statistice  $K = \frac{(n-1)S^2}{M^2}$ , která se v případě platnosti  $H_0$  asymptoticky řídí rozložením  $\chi^2(n-1)$ .

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  $\alpha$ .

### 5.7. Příklad: Pro data z příkladu 5.2. proveďte na hladině významnosti 0,05 Darlingův test.

**Řešení:**  $n = 45$ ,  $m = 99,93$  h,  $s^2 = 7328,9$  h<sup>2</sup>

Testová statistika:  $K = \frac{(n-1)S^2}{M^2} = \frac{44 \cdot 7328,91}{99,93^2} = 32,2924$

Kritický obor:

$$W = \langle 0, \chi^2_{\alpha/2}(n-1) \rangle \cup \langle \chi^2_{1-\alpha/2}(n-1), \infty \rangle = \langle 0, \chi^2_{0,025}(44) \rangle \cup \langle \chi^2_{0,975}(44), \infty \rangle = \langle 0, 27,575 \rangle \cup \langle 64,202, \infty \rangle$$

Protože se testová statistika nerealizuje v kritickém oboru, hypotézu o exponenciálním rozložení nezamítáme na asymptotické hladině významnosti 0,05.

### 5.8. Věta: Jednoduchý test Poissonova rozložení

Testujeme hypotézu, která tvrdí, že náhodný výběr  $X_1, \dots, X_n$  pochází z Poissonova rozložení. Označme  $M$  výběrový průměr a  $S^2$  výběrový rozptyl tohoto náhodného výběru. Víme, že střední hodnota náhodné veličiny  $X \sim \text{Po}(\lambda)$  je  $E(X) = \lambda$  a rozptyl je  $D(X) = \lambda$ .

Test založíme na statistice  $K = \frac{(n-1)S^2}{M}$ , která se v případě platnosti  $H_0$  asymptoticky řídí rozložením  $\chi^2(n-1)$ .

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  $\alpha$ .

**5.9. Příklad:** Pro data z příkladu 5.4. proveďte na hladině významnosti 0,05 jednoduchý test Poissonova rozložení.

**Řešení:** Nejprve musíme vypočítat realizaci výběrového průměru a výběrového rozptylu:

$$\hat{\lambda} = m = \frac{1}{1200} (79 \cdot 0 + 188 \cdot 1 + 282 \cdot 2 + 275 \cdot 3 + 196 \cdot 4 + 114 \cdot 5 + 45 \cdot 6 + 10 \cdot 7 + 11 \cdot 8) = 2,7992$$

$$s^2 = \frac{1}{1199} [79 \cdot (0 - 2,7992)^2 + 188 \cdot (1 - 2,7992)^2 + \dots + 11 \cdot (8 - 2,7992)^2] = 2,6594$$

$$K = \frac{(n-1)S^2}{M} = \frac{1199 \cdot 2,6594}{2,7882} = 1139,1$$

$$\text{Kritický obor: } W = \langle 0, \chi^2_{\alpha/2}(n-1) \rangle \cup \langle \chi^2_{1-\alpha/2}(n-1), \infty \rangle = \langle 0; 1104,93 \rangle \cup \langle 1296,86; \infty \rangle$$

$H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

**5.10. Poznámka:** Darlingův test i jednoduchý test Poissonova rozložení můžeme v MATLABu provést pomocí funkce `darling.m`.

```

function [zamitnuti,K,p,lambda]=darling(X,distrib,alfa)
% TEST K OVERENI EXPONENCIALNIHO A POISSONOVA ROZLOZENI
% function [zamitnuti,K,p,lambda]=darling(X,ROZLOZENI,ALFA)
% X muze byt n-vektor pozorovanych velicin, jejichz rozdeleni overujeme;
%   - pro souhrnne zadana data je X tvaru (r x 2), kde prvni sloupec
%     obsahuje jednotlivy varianty a druhy sloupec cetnosti;
%   - pro vypoctene statistiky je X=[n,m,s2], kde n=pocet pozorovani,
%     m=vyberovy prumer a s2=vyberovy rozptyl
% ROZLOZENI je 'exp' pro overeni exponencialniho rozlozeni (implicitni)
%   nebo 'poiss' pro overeni Poissonova rozlozeni
% ALFA je hladina vyznamnosti testu (implicitne 0.05)
%
% vystup: zamitnuti=1 => ZAMITAME hypotezu o shode rozdeleni
%   zamitnuti=0 => hypotezu o shode rozdeleni NEZAMITAME
%   K = hodnota testoveho kriteria
%   p = p-hodnota testu
%   lambda = odhadnuty parametr rozdeleni

% (c) Ondrej Petrik, 10.03.2010

if (nargin==1) distrib='exp'; end
if (nargin<3) alfa=0.05; end

[a,b]=size(X);
if(a<b) X=X';[a,b]=size(X); end
if(a==3&&b==1) n=X(1); m=X(2); s2=X(3);
elseif(b==1&&a~3) m=mean(X); n=a; s2=var(X);
else vaha=X(:,2); n=sum(vaha);
     s2=var(X(:,1),vaha)*n/(n-1); m=X(:,1)*vaha/n;
end

lambda=m;
if strcmp(distrib,'exp')lambda=1/m; m=m^2; disp('Darlinguv test exponencialniho rozlozeni');
else disp('Jednoduchy test Poissonova rozlozeni');
end
K=(n-1)*s2/m;
p=2*min(chi2cdf(K,n-1),1-chi2cdf(K,n-1));
zamitnuti=(p<alfa);

```

Příklady 5.7 a 5.9 vyřešíme pomocí funkce `darling.m`.

**Řešení příkladu 5.7:** Známe údaje o době životnosti 45 součástek, údaje jsou roztrženy do 8 třídících intervalů:  $(0,50):15$ ,  $(50,100):14$ ,  $(100,150):6$ ,  $(150,200):5$ ,  $(200,250):2$ ,  $(250,300):1$ ,  $(300,350):1$ ,  $(350,400):1$

Zadáme vstupní vektor středů třídících intervalů společně s absolutními četnostmi třídících intervalů:  
 $X = [25\ 15; 75\ 14; 125\ 6; 175\ 5; 225\ 2; 275\ 1; 325\ 1; 375\ 1]$ ;

Zavoláme funkci `darling`:

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

Dostaneme výsledek:

`zamitnuti=0`, `K=31.6619`, `p=0.1644`, `lambda=0.0101`

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

**Řešení příkladu 5.9:** Sledujeme rozložení počtu pacientů, kteří během 75 dnů přijdou na zubní pohotovost. Osmihodinovou pracovní dobu rozdělíme do půlhodinových intervalů a v každém intervalu zjistíme počet příchozích pacientů (máme  $16 \times 75 = 1200$  intervalů).

Počet pacientů	0	1	2	3	4	5	6	7	8 a víc
četnost	79	188	282	275	196	114	45	10	11

Zadáme vektor variant  $x_j = [0:8]'$  a vektor pozorovaných četností  $n_j = [79 \ 188 \ 282 \ 275 \ 196 \ 114 \ 45 \ 10 \ 11]'$  a utvoříme matici  $X$ :  $X = [x_j \ n_j]$ ;

Zavoláme funkci darling:

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

Dostaneme výsledek:

zomitnuti=0, K=331.1304, p=0.2187, lambda=2.7992

Jednoduchý test Poissonova rozložení nezamítá hypotézu o Poissonově rozložení na asymptotické hladině významnosti 0,05.



**5.11. Poznámka:** Pro výpočet kvantilů Pearsonova chí-kvadrát rozložení pro počet stupňů

volnosti nad 30 můžeme použít aproximační vzorec:  $\chi^2_{\alpha}(n) \approx \frac{1}{2} \left( u_{\alpha} + \sqrt{2n-1} \right)^2$ . Pro kvantily z příkladu 5.9. dostáváme:

$$\chi^2_{0,025}(1199) \approx \frac{1}{2} \left( u_{0,025} + \sqrt{2 \cdot 1199 - 1} \right)^2 = \frac{1}{2} \left( -1,96 + \sqrt{2397} \right)^2 = 1104,46$$

$$\chi^2_{0,975}(1199) \approx \frac{1}{2} \left( u_{0,975} + \sqrt{2 \cdot 1199 - 1} \right)^2 = \frac{1}{2} \left( 1,96 + \sqrt{2397} \right)^2 = 1296,42$$

**5.12. Poznámka:** Pro vizuální posouzení, zda naše data pocházejí z exponenciálního rozložení, lze také použít P-P graf.

Způsob konstrukce: spočteme standardizované hodnoty  $z_i = \frac{x_i - m}{s}$ ,  $i = 1, \dots, n$  a uspořádáme je podle velikosti  $z_{(1)} \leq \dots \leq z_{(n)}$ . Na vodorovnou osu vyneseme hodnoty distribuční funkce exponenciálního rozložení  $\Phi(z_{(i)}) = 1 - e^{-\lambda z_{(i)}}$ ,  $i = 1, \dots, n$  a na svislou osu hodnoty empirické distribuční funkce  $F_n(z_{(i)}) = \frac{i}{n}$ ,  $i = 1, \dots, n$ . Pokud se body  $(\Phi(z_{(i)}), F(z_{(i)}))$  řadí kolem hlavní diagonály čtverce  $[0,1] \times [0,1]$ , lze soudit, že data pocházejí z exponenciálního rozložení.

### 5.13. Testování hypotéz o parametru $\lambda$ Poissonova rozložení

Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozložení  $Po(\lambda)$  a  $\lambda_0 > 0$  je konstanta. Na hladině významnosti  $\alpha$  testujeme  $H_0: \lambda = \lambda_0$  proti  $H_1: \lambda \neq \lambda_0$  (resp. proti  $H_1: \lambda < \lambda_0$  resp.  $H_1: \lambda > \lambda_0$ )

Stanovíme testovou statistiku  $T_0 = \sum_{i=1}^n X_i$ , která se za platnosti  $H_0$  řídí rozložením  $Po(n\lambda_0)$ .

Vypočteme p-hodnotu:

$p = \Phi(t_0)$  pro levostrannou alternativu (v MATLABu:  $p = \text{poisscdf}(t_0, \text{lambda})$ ),

$p = 1 - \Phi(t_0)$  pro pravostrannou alternativu (v MATLABu:  $p = 1 - \text{poisscdf}(t_0, \text{lambda})$ ),

$p = 2 \min\{\Phi(t_0), 1 - \Phi(t_0)\}$  pro oboustrannou alternativu

(v MATLABu:  $p = 2 * \min(\text{poisscdf}(t_0, \text{lambda}), 1 - \text{poisscdf}(t_0, \text{lambda}))$ ).

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

(Parametr lambda ve funkci poisscdf se vypočítá jako  $n\lambda_0$ .)

**Upozornění:** Je-li  $n\lambda_0 \geq 30$ , lze využít aproximaci rozložení výběrového úhrnu  $\sum_{i=1}^n X_i$  rozložením  $N(n\lambda_0, n\lambda_0)$  a následně ho standardizovat.

Testová statistika  $T_0 = \frac{\sum_{i=1}^n X_i - n\lambda_0}{\sqrt{n\lambda_0}}$  má za platnosti  $H_0$  asymptoticky rozložení  $N(0,1)$ .

### 5.14. Příklad na levostrannou alternativu

Je známo, že u jisté značky auta se vyskytne porucha průměrně 3x za dva roky. Předpokládáme, že počet poruch se řídí Poissonovým rozložením. Výrobce uvedl na trh nový model, o němž tvrdí, že je méně poruchový. U 10 náhodně vybraných nových modelů bylo zjištěno celkem 8 poruch během jednoho roku. Na hladině významnosti 0,05 ověřte tvrzení výrobce.

**Řešení:**  $Y$  – počet poruch starého modelu auta během roku,  $Y \sim \text{Po}(\lambda_0)$ , kde  $\lambda_0 = 1,5$ .

$X$  – počet poruch nového modelu auta během roku,  $X \sim \text{Po}(\lambda)$ . Na hladině významnosti  $\alpha = 0,05$  testujeme  $H_0: \lambda = 1,5$  proti  $H_1: \lambda < 1,5$ . Pořídíme náhodný výběr rozsahu 10 z rozložení  $\text{Po}(\lambda)$ ,

kde bylo zjištěno, že realizace testové statistiky  $t_0 = \sum_{i=1}^{10} x_i = 8$ . Testová statistika  $T_0 = \sum_{i=1}^{10} X_i$  se za platnosti  $H_0$  řídí rozložením  $\text{Po}(15)$ . Vypočteme p-hodnotu pro levostrannou alternativu:

$$p = \Phi(t_0) = \sum_{k=0}^8 \frac{15^k}{k!} e^{-15} = \text{poisscdf}(8,15) = 0,0374$$

Protože  $0,0374 \leq 0,05$ ,  $H_0$  zamítáme na hladině významnosti 0,05. S rizikem omylu nejvýše 5 % jsme prokázali, že tvrzení výrobce automobilů je pravdivé.

I když není splněna podmínka dobré aproximace ( $n\lambda_0 = 10 \cdot 1,5 = 15 < 30$ ), pokusíme se využít

testovou statistiku  $T_0 = \frac{\sum_{i=1}^n X_i - n\lambda_0}{\sqrt{n\lambda_0}}$ . Její realizace je  $t_0 = \frac{8-15}{\sqrt{15}} = -1,8074$ ,

p-hodnota =  $\Phi(-1,8074) = 0,0354$ .

Protože  $0,0354 \leq 0,05$ ,  $H_0$  zamítáme na asymptotické hladině významnosti 0,05.

### 5.15. Příklad na pravostrannou alternativu

Na jistém úseku silnice byla dlouhodobě omezena rychlost na 50 km/h. V této době zde byly zaznamenány počty dopravních nehod v jednotlivých měsících roku:

měsíc	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII
počet nehod	2	2	1	0	0	2	3	2	2	1	1	1

Po zrušení omezení rychlosti se na tomto úseku opět zaznamenávaly počty nehod:

měsíc	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII
počet nehod	3	2	1	1	0	2	3	4	4	0	2	2

Za předpokladu, že počty nehod se řídí Poissonovým rozložením, testujte na hladině významnosti 0,05 hypotézu, že zrušení omezení rychlosti vedlo ke zvýšení počtu nehod.

**Řešení:**  $Y$  – počet nehod za měsíc v době omezení rychlosti,  $Y \sim \text{Po}(\lambda_0)$ , kde  $\lambda_0 = 17/12$ .

$X$  – počet nehod za měsíc v době zrušení omezení rychlosti,  $X \sim \text{Po}(\lambda)$ . Na hladině významnosti 0,05

testujeme  $H_0: \lambda = 17/12$  proti  $H_1: \lambda > 17/12$ . Pořídíme náhodný výběr rozsahu 12 z rozložení  $\text{Po}(\lambda)$ , kde bylo

zjištěno, že realizace testové statistiky  $t_0 = \sum_{i=1}^{12} x_i = 24$ . Testová statistika  $T_0 = \sum_{i=1}^{12} X_i$  se za platnosti  $H_0$

řídí rozložením  $\text{Po}(17)$ . Vypočteme p-hodnotu pro pravostrannou alternativu:

$$p = 1 - \Phi(t_0) = 1 - \sum_{k=0}^{24} \frac{17^k}{k!} e^{-17} = 1 - \text{poisscdf}(24, 17) = 0,0406$$

Protože  $0,0406 \leq 0,05$ ,  $H_0$  zamítáme na hladině významnosti 0,05. S rizikem omylu nejvýše 5 % se prokázalo, že zrušení omezení rychlosti vedlo ke zvýšení počtu nehod.

### 5.16. Příklad na oboustrannou alternativu

Zákazníci jisté specializované prodejny si za týden stěžují v průměru 5,5x na kvalitu zboží. Lze předpokládat, že počet stížností má Poissonovo rozložení. Majitel prodejny změnil dodavatele zboží a po této změně zjistil, že v následujících osmi týdnech byl celkový počet stížností na kvalitu zboží roven 32. Na hladině významnosti 0,05 testujte hypotézu, že změna dodavatele měla vliv na průměrný počet stížností za týden.

**Řešení:**  $Y$  – počet stížností za týden před změnou dodavatele,  $Y \sim \text{Po}(\lambda_0)$ , kde  $\lambda_0 = 5,5$ .

$X$  – počet stížností za týden po změně dodavatele,  $X \sim \text{Po}(\lambda)$ . Na hladině významnosti 0,05 testujeme  $H_0: \lambda = 5,5$  proti  $H_1: \lambda \neq 5,5$ . Pořídíme náhodný výběr rozsahu 8 z rozložení  $\text{Po}(\lambda)$ , kde

bylo zjištěno, že realizace testové statistiky  $t_0 = \sum_{i=1}^8 x_i = 32$ . Testová statistika  $T_0 = \sum_{i=1}^8 X_i$  se za platnosti  $H_0$  řídí rozložením  $\text{Po}(44)$ . Vypočteme p-hodnotu pro oboustrannou alternativu:

$$p = 2 \min(\Phi(t_0), 1 - \Phi(t_0)) = 2 \min\left(\sum_{k=0}^{32} \frac{44^k}{k!} e^{-44}, 1 - \sum_{k=0}^{32} \frac{44^k}{k!} e^{-44}\right) =$$

$$= 2 \min(\text{poisscdf}(32, 44), 1 - \text{poisscdf}(32, 44)) = 2 \min(0,0365; 1 - 0,0365) = 0,0731$$

Protože  $0,0731 > 0,05$ ,  $H_0$  nezamítáme na hladině významnosti 0,05. Nepodařilo se prokázat, že by změna dodavatele měla vliv na průměrný počet stížností za týden.

### 5.17. Testování shody parametrů dvou Poissonových rozložení

Nechť  $X_1, \dots, X_{n_1}$  je náhodný výběr z rozložení  $Po(\lambda_1)$  a  $Y_1, \dots, Y_{n_2}$  je na něm nezávislý náhodný výběr z rozložení  $Po(\lambda_2)$ . Předpokládáme, že  $\lambda_i > 9$ ,  $i = 1, 2$ . Na asymptotické hladině významnosti  $\alpha$  testujeme  $H_0: \lambda_1 = \lambda_2$  proti  $H_1: \lambda_1 \neq \lambda_2$  (resp. proti  $H_1: \lambda_1 < \lambda_2$  resp.  $H_1: \lambda_1 > \lambda_2$ ). Označme  $M_1, M_2$  výběrové průměry obou výběrů.

Testová statistika  $T_0 = \frac{M_1 - M_2}{\sqrt{\frac{M_1}{n_1} + \frac{M_2}{n_2}}}$  se za platnosti  $H_0$  asymptoticky řídí rozložením  $N(0,1)$ .

Vypočteme realizaci  $t_0$  testové statistiky a stanovíme kritický obor  $W$ .

$W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$  pro oboustrannou alternativu,

$W = (-\infty, -u_{1-\alpha})$  pro levostrannou alternativu,

$W = (u_{1-\alpha}, \infty)$  pro pravostrannou alternativu.

Pokud  $t_0 \in W$ ,  $H_0$  zamítáme na asymptotické hladině významnosti  $\alpha$  a přijímáme  $H_1$ .

Můžeme též vypočítat p-hodnotu:

$p = 2 \min\{\Phi(t_0), 1 - \Phi(t_0)\}$  pro oboustrannou alternativu

(v MATLABu:  $p = 2 * \min(\text{normcdf}(t_0, 0, 1), 1 - \text{normcdf}(t_0, 0, 1))$ ).

$p = \Phi(t_0)$  pro levostrannou alternativu (v MATLABu:  $p = \text{normcdf}(t_0, 0, 1)$ ),

$p = 1 - \Phi(t_0)$  pro pravostrannou alternativu (v MATLABu:  $p = 1 - \text{normcdf}(t_0, 0, 1)$ ),

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

### 5.18. Příklad na oboustrannou alternativu

Po dobu 40 dnů jsou sledovány počty zákazníků na dvou pobočkách České pošty, označme je A a B. Na pobočku A přišlo 4800 zákazníků, na pobočku B přišlo 5120 zákazníků. Za předpokladu, že počty zákazníků se řídí Poissonovým rozložením, na asymptotické hladině významnosti 0,05 testujte hypotézu, že střední hodnoty denního počtu zákazníků na těchto dvou pobočkách se neliší.

**Řešení:**  $X$  – denní počet zákazníků na pobočce A,  $X \sim \text{Po}(\lambda_1)$ ,  $X_1, \dots, X_{40}$  je náhodný výběr

z  $\text{Po}(\lambda_1)$ , kde  $\lambda_1$  odhadneme realizací výběrového průměru  $m_1 = \frac{4800}{40} = 120$ .

$Y$  – denní počet zákazníků na pobočce B,  $Y \sim \text{Po}(\lambda_2)$ ,  $Y_1, \dots, Y_{40}$  je náhodný výběr z  $\text{Po}(\lambda_2)$ , kde

$\lambda_2$  odhadneme realizací výběrového průměru  $m_2 = \frac{5120}{40} = 128$ . Oba odhady jsou větší než 9.

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

$$t_0 = \frac{m_1 - m_2}{\sqrt{\frac{m_1}{n_1} + \frac{m_2}{n_2}}} = \frac{120 - 128}{\sqrt{\frac{120}{40} + \frac{128}{40}}} = -3,2129. \text{ Kritický obor: } W = (-\infty, -1,96) \cup (1,96, \infty).$$

Protože  $t_0 \in W$ ,  $H_0$  zamítáme na asymptotické hladině významnosti 0,05.



### 5.19. Testování hypotéz o střední hodnotě $1/\lambda$ exponenciálního rozložení

Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozložení  $Ex(\lambda)$  a  $\lambda_0 > 0$  je konstanta. Na hladině významnosti  $\alpha$  testujeme  $H_0: 1/\lambda = 1/\lambda_0$  proti  $H_1: 1/\lambda \neq 1/\lambda_0$  (resp. proti  $H_1: 1/\lambda < 1/\lambda_0$  resp.  $H_1: 1/\lambda > 1/\lambda_0$ )

Stanovíme testovou statistiku  $T_0 = \sum_{i=1}^n X_i$ , která se za platnosti  $H_0$  řídí rozložením  $Er(n, \lambda_0)$ .

Vypočteme p-hodnotu:

$p = \Phi(t_0)$  pro levostrannou alternativu (v MATLABu:  $p = \text{gamcdf}(t_0, n, 1/\lambda_0)$ ),

$p = 1 - \Phi(t_0)$  pro pravostrannou alternativu (v MATLABu:  $p = 1 - \text{gamcdf}(t_0, n, 1/\lambda_0)$ ),

$p = 2 \min\{\Phi(t_0), 1 - \Phi(t_0)\}$  pro oboustrannou alternativu

(v MATLABu:  $p = 2 * \min(\text{gamcdf}(t_0, n, 1/\lambda_0), 1 - \text{gamcdf}(t_0, n, 1/\lambda_0))$ ).

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

**Upozornění:** Je-li  $n/\lambda \geq 30$ , lze využít aproximaci rozložení standardizovaného výběrového průměru rozložením  $N(0, 1)$ .

Testová statistika  $T_0 = \frac{M - 1/\lambda_0}{\sqrt{1/n\lambda_0^2}}$  má za platnosti  $H_0$  asymptoticky rozložení  $N(0,1)$ .

### 5.20. Příklad na pravostrannou alternativu

Je známo, že životnost baterií vyrobených z materiálu A se řídí exponenciálním rozložením se střední hodnotou 3 týdny. Výrobce je přesvědčen, že baterie vyrobené z materiálu B budou mít větší střední hodnotu doby životnosti. Ukázalo se, že průměrná doba životnosti 10 náhodně vybraných baterií vyrobených z materiálu B byla 4,5 týdne. Na hladině významnosti 0,05 ověřte tvrzení výrobce.

**Řešení:** Časová jednotka = 1 týden.

$Y$  – doba životnosti baterií vyrobených z materiálu A,  $Y \sim \text{Ex}(\lambda_0)$ , kde  $\lambda_0 = 1/3$ .

$X$  - doba životnosti baterií vyrobených z materiálu B,  $X \sim \text{Ex}(\lambda)$ . Na hladině významnosti 0,05 testujeme

$H_0: \lambda = 1/3$  proti  $H_1: \lambda > 1/3$ . Pořídíme náhodný výběr rozsahu 10 z rozložení  $\text{Ex}(\lambda)$ , kde bylo

zjištěno, že realizace testové statistiky  $t_0 = \sum_{i=1}^{10} x_i = 45$ . Testová statistika  $T_0 = \sum_{i=1}^{10} X_i$  se za

platnosti  $H_0$  řídí rozložením  $\text{Er}(10, 1/3)$ . Vypočteme p-hodnotu pro pravostrannou alternativu:

$$p = 1 - \Phi(t_0) = 1 - \int_0^{45} \frac{\left(\frac{x}{3}\right)^9}{9!} \cdot \frac{1}{3} e^{-\frac{x}{3}} dx = 1 - \text{gamcdf}(45, 10, 3) = 0,0699$$

Protože  $0,0699 > 0,05$ ,  $H_0$  nezamítáme na hladině významnosti 0,05. Nepodařilo se prokázat, že použití materiálu B by vedlo ke zvýšení střední hodnoty životnosti baterií.

Protože je splněna podmínka dobré aproximace ( $\frac{n}{\lambda} = 10 \cdot 3 = 30$ ), můžeme využít testovou statistiku  $T_0 = \frac{M - 1/\lambda_0}{\sqrt{1/n\lambda_0^2}}$ . Její realizace je  $t_0 = \frac{4,5 - 3}{\sqrt{9/10}} = 1,5811$ , p-hodnota =  $1 - \Phi(1,5811) = 0,0569$ .

Protože  $0,0569 > 0,05$ ,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

**5.21. Poznámka:** Máme-li dva nezávislé náhodné výběry z exponenciálních rozložení, pak pro test hypotézy o shodě středních hodnot těchto dvou rozložení lze za splnění podmínek dobré aproximace použít postup popsany v 5.17.