

Testování generátorů náhodných čísel

Při použití generátoru pseudonáhodných čísel v praxi je důležité ověřit, zda získaná posloupnost čísel má vlastnosti náhodného výběru ze zadaného rozložení:

- typ rozložení
- náhodnost
- nezávislost.

Obecné zásady pro testování:

- ověřovaná posloupnost musí být dostatečně rozsáhlá
- závěry se provádějí až po prozkoumání většího počtu posloupností
- testované posloupnosti by měly mít různé výchozí hodnoty.

1. Testy shody rozložení

a) Kolmogorovův – Smirnovův test

Test je založen na porovnání teoretické a empirické distribuční funkce. Velké odchylky mezi těmito dvěma funkcemi budou svědčit o tom, že rozdíl mezi modelovými a vygenerovanými hodnotami není způsoben pouze náhodnými vlivy.

Nechť X_1, \dots, X_n je náhodný výběr ze spojitého rozložení s distribuční funkcí $\Phi(x)$.

Výběrovou distribuční funkci označíme $F_n(x)$, tj. pro $\forall x \in \mathbb{R} : F_n(x) = \frac{1}{n} \text{card}\{i; X_i \leq x\}$.

Na hladině významnosti α testujeme nulovou hypotézu

$H_0: \Phi(x) = F_n(x)$ pro $\forall x \in \mathbb{R}$

proti alternativě

$H_1: \Phi(x) \neq F_n(x)$ pro aspoň jednu hodnotu x .

Testová statistika má tvar: $D_n = \max_{x \in \mathbb{R}} |\Phi(x) - F_n(x)|$.

Nulovou hypotézu zamítáme na hladině významnosti α , když $D_n > D_{n,\alpha}$, kde $D_{n,\alpha}$ je tabelovaná kritická hodnota.

Pro větší n lze kritickou hodnotu aproximovat výrazem $D_{n,\alpha} \approx \sqrt{\frac{1}{2n} \ln \frac{2}{\alpha}}$.

Upozornění: Při testování generátorů pseudonáhodných čísel přesně známe parametry rozložení, z něhož čísla generujeme, tudíž v K-S testu nemusíme používat modifikované kritické hodnoty.

V MATLABu provádí K-S test funkce `kstest.m`.

Příklad 1.: Bylo vygenerováno 10 000 pseudonáhodných čísel z $Rs(0,1)$. Vygenerované hodnoty byly roztrženy do 10 ekvidistantních třídících intervalů. Máme k dispozici jejich meze (u_j, u_{j+1}) a absolutní četnosti n_j :

| (u_j, u_{j+1}) | n_j |
|------------------|-------|
| $(0; 0,1)$ | 985 |
| $(0,1; 0,2)$ | 1029 |
| $(0,2; 0,3)$ | 1005 |
| $(0,3; 0,4)$ | 1005 |
| $(0,4; 0,5)$ | 1002 |
| $(0,5; 0,6)$ | 970 |
| $(0,6; 0,7)$ | 1028 |
| $(0,7; 0,8)$ | 1032 |
| $(0,8; 0,9)$ | 960 |
| $(0,9; 1)$ | 984 |

Na hladině významnosti 0,05 ověřte K-S testem, že tyto hodnoty skutečně pocházejí z rozložení $Rs(0,1)$.

Řešení: Tabulku absolutních četností doplníme o hodnoty teoretické a výběrové distribuční funkce a vypočteme absolutní hodnoty jejich rozdílů. Největší z těchto absolutních hodnot porovnáme s kritickou hodnotou a pak rozhodneme o nulové hypotéze.

| $(u_j, u_{j+1}]$ | n_j | N_j | $\Phi(x)$ | $F_{10000}(x)$ | $ \Phi(x) - F_{10000}(x) $ |
|------------------|-------|-------|-----------|----------------|----------------------------|
| (0;0,1) | 985 | 985 | 0,1 | 0,0985 | 0,0015 |
| (0,1;0,2) | 1029 | 2014 | 0,2 | 0,2014 | 0,0014 |
| (0,2;0,3) | 1005 | 3019 | 0,3 | 0,3019 | 0,0019 |
| (0,3;0,4) | 1005 | 4024 | 0,4 | 0,4024 | 0,0024 |
| (0,4;0,5) | 1002 | 5026 | 0,5 | 0,5026 | 0,0026 |
| (0,5;0,6) | 970 | 5996 | 0,6 | 0,5996 | 0,0004 |
| (0,6;0,7) | 1028 | 7024 | 0,7 | 0,7024 | 0,0024 |
| (0,7;0,8) | 1032 | 8056 | 0,8 | 0,8056 | 0,0056 |
| (0,8;0,9) | 960 | 9016 | 0,9 | 0,9016 | 0,0016 |
| (0,9;1) | 984 | 10000 | 1 | 1 | 0 |

Největší rozdíl v absolutní hodnotě je 0,0056. To je realizace testové statistiky, kterou porovnáme

s aproximací kritické hodnoty počítané podle vzorce $D_{n,\alpha} \approx \sqrt{\frac{1}{2n} \ln \frac{2}{\alpha}}$:

$$D_{10000;0,05} \approx \sqrt{\frac{1}{2 \cdot 10000} \ln \frac{2}{0,05}} = 0,0136.$$

Jelikož testová statistika je menší než kritická hodnota, nelze na hladině významnosti 0,05 zamítnout hypotézu, že vygenerovaná data pocházejí z rozložení $Rs(0,1)$.

Kolmogorovův - Smirnovův test pro rozložení $R_s(0,1)$ v MATLABu

Vygenerujeme $n = 10000$ realizací z $R_s(0,1)$:

```
n=10000;
```

```
realizace=unifrnd(0,1,n,1);
```

Vypočteme hodnoty distribuční funkce rozložení $R_s(0,1)$ v bodech vygenerovaných realizací:

```
Fi=unifcdf(realizace,0,1);
```

Zavoláme funkci `kstest`:

```
[h,p,ksstat,cv]=kstest(realizace,[realizace,Fi])
```

Vstupní parametry:

`realizace` ... sloupcový vektor realizací

`[realizace,Fi]` ... matice $n \times 2$ obsahující vektor realizací a vektor hodnot distribuční funkce rozložení $R_s(0,1)$

Výstupní parametry:

`h` ... nabývá hodnoty 0, když nulovou hypotézu nezamítáme na hladině významnosti 0,05 a hodnoty 1, když zamítáme na hladině významnosti 0,05

`p` ... p-hodnota

`ksstat` ... hodnota testové statistiky

`cv` ... kritická hodnota

b) Test χ^2 dobré shody

Testujeme hypotézu, která tvrdí, že náhodný výběr X_1, \dots, X_n pochází z rozložení s distribuční funkcí $\Phi(x)$.

Spojité případ: Je-li distribuční funkce spojitá, pak data rozdělíme do r třídících intervalů (u_j, u_{j+1}) , $j = 1, \dots, r$. Zjistíme absolutní četnost n_j j -tého třídícího intervalu a vypočteme pravděpodobnost p_j , že náhodná veličina X s distribuční funkcí $\Phi(x)$ se bude realizovat v j -tém třídícím intervalu. Platí-li nulová hypotéza, pak $p_j = \Phi(u_{j+1}) - \Phi(u_j)$.

Diskrétní případ: Má-li distribuční funkce nejvýše spočetně mnoho bodů nespojitosti, pak místo třídících intervalů použijeme varianty $x_{[j]}$, $j = 1, \dots, r$. Pro variantu $x_{[j]}$ zjistíme absolutní četnost n_j a vypočteme pravděpodobnost p_j , že náhodná veličina X s distribuční funkcí $\Phi(x)$ se bude realizovat variantou $x_{[j]}$. Platí-li nulová hypotéza, pak $p_j = \Phi(x_{[j]}) - \lim_{x \rightarrow x_{[j]}^-} \Phi(x) = P(X = x_{[j]})$.

Provedení testu pro diskrétní i spojitý případ

Testová statistika: $K = \sum_{j=1}^r \frac{(n_j - np_j)^2}{np_j}$. Platí-li nulová hypotéza, pak $K \approx \chi^2(r-1-p)$, kde

p je počet odhadovaných parametrů daného rozložení. (Např. pro normální rozložení $p = 2$, protože z dat odhadujeme střední hodnotu a rozptyl.)

Nulovou hypotézu zamítáme na asymptotické hladině významnosti α , když testová statistika $K \geq \chi^2_{1-\alpha}(r-1-p)$.

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

Závažnost rozdílu mezi pozorovanými četnostmi a teoretickými četnostmi lze pro

každý index j orientačně posoudit porovnáním vypočítaného sčítance $\frac{(n_j - np_j)^2}{np_j}$

s hodnotou 3,84 (to je kvantil $\chi^2_{0,95}(1)$). Jestliže některý sčítanec převýší tuto hodnotu, lze předpokládat, že odchylka od modelu se nachází právě v této oblasti hodnot.

χ^2 test dobré shody v MATLABu provádí funkce `chi2gof.m`

Příklad 2.: Na hladině významnosti 0,05 ověřte χ^2 testem dobré shody, zda data z příkladu 1 pocházejí z rozložení $Rs(0,1)$.

Řešení: Tabulku absolutních četností doplníme o pravděpodobnosti p_j , teoretické četnosti np_j a jednotlivé

sčítance $\frac{(n_j - np_j)^2}{np_j}$ vstupující do testové statistiky K .

| (u_j, u_{j+1}) | n_j | p_j | np_j | $\frac{(n_j - np_j)^2}{np_j}$ |
|------------------|-------|-------|--------|-------------------------------|
| $(0;0,1)$ | 985 | 0,1 | 1000 | 0,225 |
| $(0,1;0,2)$ | 1029 | 0,1 | 1000 | 0,841 |
| $(0,2;0,3)$ | 1005 | 0,1 | 1000 | 0,025 |
| $(0,3;0,4)$ | 1005 | 0,1 | 1000 | 0,025 |
| $(0,4;0,5)$ | 1002 | 0,1 | 1000 | 0,004 |
| $(0,5;0,6)$ | 970 | 0,1 | 1000 | 0,900 |
| $(0,6;0,7)$ | 1028 | 0,1 | 1000 | 0,784 |
| $(0,7;0,8)$ | 1032 | 0,1 | 1000 | 1,024 |
| $(0,8;0,9)$ | 960 | 0,1 | 1000 | 1,600 |
| $(0,9;1)$ | 984 | 0,1 | 1000 | 0,256 |

Testová statistika:

$$K = \sum_{j=1}^r \frac{(n_j - np_j)^2}{np_j} = 0,225 + 0,841 + \dots + 0,256 = 5,684$$

Kritický obor: $W = \langle \chi^2_{0,95}(9), \infty \rangle = \langle 16,919; \infty \rangle$

Protože se testová statistika nerealizuje v kritickém oboru, nemůžeme na hladině významnosti 0,05 zamítnout hypotézu, že data pocházejí z rozložení $Rs(0,1)$.

Test dobré shody pro rozložení $R_s(0,1)$ v MATLABu

Funkce `chi2gof.m` implicitně třídí data do 10 intervalů.

```
[h,p] = chi2gof(realizace, 'cdf', @unifcdf)
```

Vstupní parametry:

`realizace` ... sloupcový vektor realizací

`'cdf'` ... parametr, který dává funkci na vědomí, že bude použita distribuční funkce nějakého rozložení

`@unifcdf` ... označení distribuční funkce rovnoměrného spojitého rozložení

Výstupní parametry:

`h` ... nabývá hodnoty 0, když nulovou hypotézu nezamítáme na hladině významnosti 0,05 a hodnoty 1, když zamítáme na hladině významnosti 0,05

`p` ... p-hodnota

2. Testy náhodnosti

Nechť x_1, \dots, x_n je posloupnost navzájem různých čísel generovaných ze spojitého rozložení (jsou-li dvě sousední hodnoty stejné, jednu vyškrtáme). Na hladině významnosti α testujeme nulovou hypotézu H_0 : posloupnost je náhodná proti alternativě H_1 : posloupnost není náhodná.

a) Test založený na bodech zvratu

Tento test zkoumá, zda kolísání hodnot podle velikosti se v dané posloupnosti mění dostatečně rychle. Není vhodný pro testování existence trendu, protože vychází pouze z lokálních vlastností posloupnosti.

Číslo x_i se nazývá **bodem zvratu**, když obě sousední čísla jsou současně buď větší než x_i nebo menší než x_i , tj. platí-li buď $x_{i-1} > x_i < x_{i+1}$ nebo $x_{i-1} < x_i > x_{i+1}$.

Konstrukce testové statistiky:

Označme Y celkový počet bodů zvratu v posloupnosti x_1, \dots, x_n . Platí-li H_0 , pak statistika Y má

asymptoticky normální rozložení se střední hodnotou $E(Y) = \frac{2(n-2)}{3}$ a rozptylem $D(Y) = \frac{16n-29}{90}$,

tedy standardizovaná statistika
$$U = \frac{Y - \frac{2(n-2)}{3}}{\sqrt{\frac{16n-29}{90}}} \approx N(0,1)$$
.

Kritický obor: $W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$


Pokud $U \in W$, nulovou hypotézu zamítáme na asymptotické hladině významnosti α .

Příklad 3: Bylo vygenerováno 28 pseudonáhodných čísel z $Rs(0,1)$:

0,39 0,94 0,17 0,16 0,80 0,63 0,59 0,92 0,16 0,51 0,39 0,16 0,67 0,03 0,67 0,73 0,67 0,80 0,27
0,75 0,58 0,86 0,49 0,43 0,86 0,08 0,66 0,60

Pomocí testu založeného na bodech zvratu ověřte na hladině významnosti 0,05 hypotézu, že tato posloupnost je náhodná.

Řešení:



Celkem zjistíme $Y = 21$ bodů zvratu.

$$U = \frac{Y - \frac{2(n-2)}{3}}{\sqrt{\frac{16n-29}{90}}} = \frac{21 - \frac{2(28-2)}{3}}{\sqrt{\frac{16 \cdot 28 - 29}{90}}} = 1,699$$

Testová statistika:

$$\text{Kritický obor: } W = (-\infty, -u_{0,975}) \cup (u_{0,975}, \infty) = (-\infty, -1,96) \cup (1,96, \infty).$$

Protože testová statistika s nerealizuje v kritickém oboru, nelze na hladině významnosti 0,05 zamítnout hypotézu, že daná posloupnost je náhodná.

Výpočet v MATLABu:

Test založený na bodech zvratu je prováděn pomocí funkce body_zvratu.m:

```
function [H,P,U]=body_zvratu(x,alfa)
% funkce testuje nahodnost posloupnosti pomoci bodu zvratu
% syntaxe: [H,P,U]=body_zvratu(x,alfa)
% vystupni parametry:
% H ... vysledek testu: 1 ... H0 zamitame, 0 ... H0 ... nezamitame
% P ... vypocitana p-hodnota
% U ... realizace testove statistiky
% vstupni parametry:
% x ... sloupcovy vektor hodnot testovane posloupnosti
% alfa ... hladina vyznamnosti
n=size(x,1);
Y=0;
for i=2:n-1
    if ((x(i)>x(i-1))&(x(i)>x(i+1)))|((x(i)<x(i-1))&(x(i)<x(i+1)))
        Y=Y+1;
    end
end;
U=(Y-(2*n-4)/3)/sqrt((16*n-29)/90);
P=2*min(normcdf(U,0,1),1-normcdf(U,0,1));
if P<=alfa
    H=1;
end
if P>alfa
    H=0;
end
```

Použijeme-li tuto funkci na data z příkladu 3, dostaneme výsledky:

```
[H,P,U]=body_zvratu(x,alfa)
```

H =

0

P =

0.0893

U =

1.6994

Protože p-hodnota je 0,0893, nemůžeme na hladině významnosti 0,05 zamítnout hypotézu o náhodnosti dané posloupnosti.

b) Test znamének diferencí

Tento test zkoumá, zda posloupnost neobsahuje dlouhé řady čísel jdoucích za sebou vzestupně nebo sestupně. Používá se k ověření existence trendu.

Test je založen na počtu kladných 1. diferencí dané posloupnosti, tj. na počtu bodů růstu. Číslo x_i se nazývá **bodem růstu**, když $x_i < x_{i+1}$.

Konstrukce testové statistiky: Označme Y celkový počet bodů růstu v posloupnosti x_1, \dots, x_n .

Platí-li H_0 , pak statistika Y má asymptoticky normální rozložení se střední hodnotou


$$E(Y) = \frac{n-1}{2} \text{ a rozptylem } D(Y) = \frac{n+1}{12}, \text{ tedy standardizovaná statistika } U = \frac{Y - \frac{n-1}{2}}{\sqrt{\frac{n+1}{12}}} \approx N(0,1).$$

$$\text{Kritický obor: } W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$$

Pokud $U \in W$, nulovou hypotézu zamítáme na asymptotické hladině významnosti α .

Příklad 4.: Na hladině významnosti 0,05 testujte pomocí testu znamének diferencí hypotézu, že data z příkladu 3 jsou náhodná.

Řešení:



Celkem zjistíme $Y = 12$ bodů růstu.

$$U = \frac{Y - \frac{n-1}{2}}{\sqrt{\frac{n+1}{12}}} = \frac{12 - \frac{28-1}{2}}{\sqrt{\frac{28+1}{12}}} = -0,9649$$

Testová statistika:

$$\text{Kritický obor: } W = (-\infty, -u_{0,975}) \cup (u_{0,975}, \infty) = (-\infty, -1,96) \cup (1,96, \infty).$$

Protože testová statistika s nerealizuje v kritickém oboru, nelze na hladině významnosti 0,05 zamítnout hypotézu, že daná posloupnost je náhodná.

Výpočet v MATLABu:

Test znamének diferencí je prováděn pomocí funkce znamenka_diferenci.m:

```
function [H,P,U]=znamenka_diferenci(x,alfa)
% funkce testuje nahodnost posloupnosti pomoci znamenek diferenci
% syntaxe: [H,P,U]=znamenka_diferenci(x,alfa)
% vystupni parametry:
% H ... vysledek testu: 1 ... H0 zamitame, 0 ... H0 ... nezamitame
% P ... vypocitana p-hodnota
% U ... realizace testove statistiky
% vstupni parametry:
% x ... sloupcovy vektor hodnot testovane posloupnosti
% alfa ... hladina vyznamnosti
n=size(x,1);
Y=0;
for i=1:n-1
    if x(i)<x(i+1)
        Y=Y+1;
    end
end;
U=(Y-(n-1)/2)/sqrt((n+1)/12);
P=2*min(normcdf(U,0,1),1-normcdf(U,0,1));
if P<=alfa
    H=1;
end
if P>alfa
    H=0;
end
```


Použijeme-li tuto funkci na data z příkladu 3, dostaneme výsledky:

```
[H,P,U]=znamenska_diferenci(x,alfa)
```

```
H =
```

```
    0
```

```
P =
```

```
    0.3346
```

```
U =
```

```
   -0.9649
```

Protože p-hodnota je 0,3346, nemůžeme na hladině významnosti 0,05 zamítnout hypotézu o náhodnosti dané posloupnosti.

c) Test založený na Spearmanově koeficientu

Tento test zkoumá, zda velikost generované hodnoty nezávisí na pořadí, v němž bylo číslo generováno (např. zda na počátku generované posloupnosti nejsou soustředěny nízké hodnoty a na konci vysoké).

Na základě generované posloupnosti x_1, \dots, x_n utvoříme dvojice $(1, x_1), \dots, (n, x_n)$. Předpokládáme, že tyto dvojice pocházejí z dvourozměrného rozložení s teoretickým Spearmanovým koeficientem pořadové korelace ρ_S .

Na hladině významnosti α testujeme nulovou hypotézu $H_0: \rho_S = 0$ proti $H_1: \rho_S \neq 0$.

Označme R_i pořadí hodnoty x_i v dané posloupnosti. Vypočteme Spearmanův koeficient pořadové korelace:

$$r_S = 1 - \frac{6}{n(n^2 - 1)} \sum_{i=1}^n (i - R_i)^2 .$$

Nulovou hypotézu zamítáme na hladině významnosti α ve prospěch

alternativy, když $|r_S| \geq r_{S,1-\alpha/2}(n)$, kde $r_{S,1-\alpha/2}(n)$ je kritická hodnota, kterou pro $\alpha = 0,05$ a $n \leq 30$ najdeme v tabulkách.

Kritické hodnoty pro Spearmanův koeficient pořadové korelace pro $n = 5, 6, \dots, 30$, $\alpha = 0,05$

| n | $r_{S;0,975}$ | $r_{S;0,95}$ |
|----|---------------|--------------|
| 5 | 0,9 | 0,8 |
| 6 | 0,8286 | 0,7714 |
| 7 | 0,745 | 0,6786 |
| 8 | 0,6905 | 0,5952 |
| 9 | 0,6833 | 0,5833 |
| 10 | 0,6364 | 0,5515 |
| 11 | 0,6091 | 0,5273 |
| 12 | 0,5804 | 0,4965 |
| 13 | 0,5549 | 0,478 |
| 14 | 0,5341 | 0,4293 |
| 15 | 0,5179 | 0,4429 |
| 16 | 0,5 | 0,4265 |
| 17 | 0,4853 | 0,4118 |
| 18 | 0,4716 | 0,3994 |
| 19 | 0,4579 | 0,3895 |
| 20 | 0,4451 | 0,3789 |
| 21 | 0,4351 | 0,3688 |
| 22 | 0,4241 | 0,3597 |
| 23 | 0,415 | 0,3518 |
| 24 | 0,4061 | 0,3435 |
| 25 | 0,3977 | 0,3362 |
| 26 | 0,3894 | 0,3299 |
| 27 | 0,3822 | 0,3236 |
| 28 | 0,3749 | 0,3175 |
| 29 | 0,3685 | 0,3113 |
| 30 | 0,362 | 0,3059 |

Příklad 5: Pro data z příkladu 3 testujte na hladině významnosti 0,05 hypotézu, že velikost generované hodnoty nezávisí na pořadí. Výpočet proveďte pomocí MATLABu.

Řešení: Ve statistickém toolboxu MATLABu je implementována funkce `tiedrank(x)`, která pro daný vektor x poskytne vektor pořadí, přičemž pro skupinky stejných hodnot spočítá průměrné pořadí.

Postup výpočtu:

Do proměnné x vložíme dané hodnoty.

Utvoříme vektor $y=[1:28]'$;

Pomocí funkce `tiedrank` zjistíme vektor pořadí: $R=\text{tiedrank}(x)$;

Pomocí funkce `corrcoef` spočteme koeficient korelace a odpovídající p -hodnotu: $[rs,p]=\text{corrcoef}(y,R)$

Dostaneme

| | | | | | |
|--------|--------|--|--------|--------|--|
| $r =$ | | | $p =$ | | |
| 1.0000 | 0.0729 | | 1.0000 | 0.7124 | |
| 0.0729 | 1.0000 | | 0.7124 | 1.0000 | |

Velikost Spearmanova koeficientu ($rs = 0,0729$) svědčí o velmi slabé přímé pořadové závislosti, která je na hladině 0,05 nevýznamná ($p = 0,7124$).

Asymptotické varianty testu

$n > 20$:

lze použít testovou statistiku $T_0 = \frac{r_s \sqrt{n-2}}{\sqrt{1-r_s^2}}$, která se v případě platnosti nulové hypotézy asymptoticky

řídí rozložením $t(n-2)$.

Kritický obor: $W = (-\infty, -t_{1-\alpha/2}(n-2)) \cup (t_{1-\alpha/2}(n-2), \infty)$

Hypotézu, že velikost generovaných hodnot nezávisí na pořadí, zamítáme na asymptotické hladině významnosti α , když $t_0 \in W$.

$n > 30$:

lze použít testovou statistiku $r_s \sqrt{n-1}$. Platí-li H_0 , pak $r_s \sqrt{n-1} \approx N(0, 1)$. Nulovou hypotézu tedy zamítáme na asymptotické hladině významnosti α ve prospěch alternativy, když

$r_s \sqrt{n-1} \in (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$.

3. Testy nezávislosti

a) Test založený na koeficientu autokorelace

Tímto testem ověřujeme, zda existuje lineární závislost mezi sousedními nebo i vzdálenějšími členy posloupnosti x_1, \dots, x_n .

Pro $k < n$ je výběrový koeficient autokorelace k -tého řádu r_k definován jako výběrový Pearsonův koeficient korelace dvojic $(x_1, x_{k+1}), \dots, (x_{n-k}, x_n)$, o nichž předpokládáme, že pocházejí z dvourozměrného rozložení s koeficientem korelace ρ_k .

Je-li $k = 1$, počítá se koeficient korelace mezi sousedními členy generované posloupnosti. Není vhodné počítat koeficienty autokorelace pro $k > n/4$.

Posloupnost koeficientů autokorelace r_1, r_2, \dots se nazývá korelogram.

Na hladině významnosti α testujeme nulovou hypotézu $H_0: \rho_k = 0$ proti $H_1: \rho_k \neq 0$.

Testová statistika $T_0 = r_k \sqrt{n-k}$ se v případě platnosti nulové hypotézy asymptoticky řídí rozložením $N(0,1)$.

Kritický obor: $W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$

Pokud $T_0 \in W$, nulovou hypotézu zamítáme na asymptotické hladině významnosti α , tedy hodnoty generované posloupnosti po k členech nelze považovat za lineárně nezávislé.

Příklad 6: Pro data z příkladu 3 testujte na hladině významnosti 0,05 hypotézu, že mezi nimi neexistuje autokorelace 1. až 7. řádu.

Řešení:

Tabulka pro výpočet koeficientů autokorelace 1. až 7. řádu

| | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 |
|---|------|--------|--------|--------|--------|--------|--------|--------|
| | X(i) | X(i+1) | X(i+2) | X(i+3) | X(i+4) | X(i+5) | X(i+6) | X(i+7) |
| 1 | 0,39 | 0,94 | 0,17 | 0,16 | 0,8 | 0,63 | 0,59 | 0,92 |
| 2 | 0,94 | 0,17 | 0,16 | 0,8 | 0,63 | 0,59 | 0,92 | 0,16 |
| 3 | 0,17 | 0,16 | 0,8 | 0,63 | 0,59 | 0,92 | 0,16 | 0,51 |
| 4 | 0,16 | 0,8 | 0,63 | 0,59 | 0,92 | 0,16 | 0,51 | 0,39 |
| 5 | 0,8 | 0,63 | 0,59 | 0,92 | 0,16 | 0,51 | 0,39 | 0,16 |
| 6 | 0,63 | 0,59 | 0,92 | 0,16 | 0,51 | 0,39 | 0,16 | 0,67 |
| 7 | 0,59 | 0,92 | 0,16 | 0,51 | 0,39 | 0,16 | 0,67 | 0,03 |
| 8 | 0,92 | 0,16 | 0,51 | 0,39 | 0,16 | 0,67 | 0,03 | 0,67 |
| 9 | 0,16 | 0,51 | 0,39 | 0,16 | 0,67 | 0,03 | 0,67 | 0,73 |
| 0 | 0,51 | 0,39 | 0,16 | 0,67 | 0,03 | 0,67 | 0,73 | 0,67 |
| 1 | 0,39 | 0,16 | 0,67 | 0,03 | 0,67 | 0,73 | 0,67 | 0,8 |
| 2 | 0,16 | 0,67 | 0,03 | 0,67 | 0,73 | 0,67 | 0,8 | 0,27 |
| 3 | 0,67 | 0,03 | 0,67 | 0,73 | 0,67 | 0,8 | 0,27 | 0,75 |
| 4 | 0,03 | 0,67 | 0,73 | 0,67 | 0,8 | 0,27 | 0,75 | 0,58 |
| 5 | 0,67 | 0,73 | 0,67 | 0,8 | 0,27 | 0,75 | 0,58 | 0,86 |
| 6 | 0,73 | 0,67 | 0,8 | 0,27 | 0,75 | 0,58 | 0,86 | 0,49 |
| 7 | 0,67 | 0,8 | 0,27 | 0,75 | 0,58 | 0,86 | 0,49 | 0,43 |
| 8 | 0,8 | 0,27 | 0,75 | 0,58 | 0,86 | 0,49 | 0,43 | 0,86 |
| 9 | 0,27 | 0,75 | 0,58 | 0,86 | 0,49 | 0,43 | 0,86 | 0,08 |
| 0 | 0,75 | 0,58 | 0,86 | 0,49 | 0,43 | 0,86 | 0,08 | 0,66 |
| 1 | 0,58 | 0,86 | 0,49 | 0,43 | 0,86 | 0,08 | 0,66 | 0,6 |
| 2 | 0,86 | 0,49 | 0,43 | 0,86 | 0,08 | 0,66 | 0,6 | |
| 3 | 0,49 | 0,43 | 0,86 | 0,08 | 0,66 | 0,6 | | |
| 4 | 0,43 | 0,86 | 0,08 | 0,66 | 0,6 | | | |
| 5 | 0,86 | 0,08 | 0,66 | 0,6 | | | | |
| 6 | 0,08 | 0,66 | 0,6 | | | | | |
| 7 | 0,66 | 0,6 | | | | | | |
| 8 | 0,6 | | | | | | | |

Korelogram a hodnoty testových statistik

| i | 1 | 2 | 3 | 4 | 5 |
|---|---------|-----|----------|----------|------------|
| | r_i | n-i | T_0 | kvantil | rozhodnutí |
| 1 | -0,3235 | 27 | -1,68096 | 1,959964 | nezamítáme |
| 2 | 0,0523 | 26 | 0,266679 | 1,959964 | nezamítáme |
| 3 | 0,1708 | 25 | 0,854 | 1,959964 | nezamítáme |
| 4 | -0,4572 | 24 | -2,23981 | 1,959964 | zamítáme |
| 5 | 0,3121 | 23 | 1,496779 | 1,959964 | nezamítáme |
| 6 | -0,2657 | 22 | -1,24624 | 1,959964 | nezamítáme |
| 7 | 0,0285 | 21 | 0,130603 | 1,959964 | nezamítáme |

Závěr: V testovaných datech byla na hladině významnosti 0,05 prokázána autokorelace 4. řádu.

b) Cochranův test

Na hladině významnosti 0,05 testujeme nulovou hypotézu

$H_0: \rho_1 = \rho_2 = \dots = \rho_k = 0$ (tj. všechny koeficienty autokorelace až do řádu k jsou nulové)
proti alternativě

$H_1: \rho_i \neq 0$ pro aspoň jeden index i .

Testová statistika:

$$Q = n \sum_{i=1}^k r_i^2$$

Platí-li nulová hypotéza, Q se asymptoticky řídí rozložením $\chi^2(k)$.

H_0 tedy zamítáme na asymptotické hladině významnosti α , když $Q \geq \chi^2_{1-\alpha}(k)$.

Cochranův test má význam zvláště v případě, kdy jeden z autokorelačních koeficientů je významný (přitom může být významný pouze nahodile) a ostatní významné nejsou.

Příklad 7: Pro data z příkladu 3 proveďte na hladině významnosti Cochranův test.

Řešení: Připomeňme, že koeficienty autokorelace byly

| | | | | | | | |
|-------|---------|--------|--------|---------|--------|---------|--------|
| r_i | -0,3235 | 0,0523 | 0,1708 | -0,4572 | 0,3121 | -0,2657 | 0,0285 |
|-------|---------|--------|--------|---------|--------|---------|--------|

Po dosazení do vzorce pro testovou statistiku dostaneme $Q = 14,4034$.

Odpovídající kvantil: $\chi^2_{1-\alpha}(k) = \chi^2_{0,95}(7) = 14,067$.

Protože $Q \geq 14,067$, H_0 zamítáme na asymptotické hladině významnosti 0,05.

Výpočet v MATLABu:

Cochranův test je prováděn pomocí funkce Cochran.m:

```
function [Q,chi,h,p]=Cochran(x,rad,alpha)
% funkce provadi Cochranuv test autokorelace
% vstupni parametry: x - vektor realizaci
% rad - nejvyssi rad autokorelace
% alpha - hladina vyznamnosti
% vystupni parametry:
% Q - hodnota testove statistiky
% chi - kriticka hodnota
% h zamitnuti (1)/nezamitnuti (0) nulove hypotezy
% p-hodnota testu
n=size(x,1);
if rad>n/4
    error('Rad autokorelace je prilis velky')
end;
Q=0;
for i=1:rad
    [r,p]=corrcoef(x(1:n-i),x(i+1:n));Q=Q+r(1,2)^2;
end;
Q=n*Q;chi=chi2inv((1-alpha),rad);
if Q<chi
    h=0;
else
    h=1;
end;
p=1-chi2cdf(Q,rad);
```

Pro Cochranův test lze použít i funkci autokorelace.m, která navíc poskytne korelogram

```
function [T,Q,P,h]=autokorelace(x,k,alfa)
% funkce testuje lineární nezávislost mezi členy posloupnosti
% Autor: Petr Mareška, 2015
% syntaxe: [T,Q,P,h]=autokorelace(x,k,alfa)
% vstupní parametry:
% x...vektor realizací
% k...maximální řád koeficientu autokorelace
% alfa...volitelný parametr, hladina významnosti pro Cochranův test, implicitně alfa=0.05
% výstupní parametry:
% T...tabulka obsahující korelogram a výsledky testu hypotézy  $H_0: \rho_k=0$ 
% Q...hodnota testové statistiky Cochranova testu
% P ... p-hodnota Cochranova testu
% h...výsledek testu:  $H=0$  nezamítáme hyp., že všechny koeficienty autokorelace jsou nula
%            $H=1$  zamítáme hypotézu
```