

MA012 Statistika II

4. Testy dobré shody (goodness-of-fit tests)

Ondřej Pokora (pokora@math.muni.cz)

Ústav matematiky a statistiky, Přírodovědecká fakulta, Masarykova univerzita, Brno

(podzim 2015)



Potřebujeme testovat nulovou hypotézu, že náhodný výběr (X_1, \dots, X_n) pochází z konkrétního rozdělení pravděpodobnosti:

- se zadanými parametry, např. $N(10;4)$, $Ex(3,5)$, $Po(2)$, $Bi(10;0,6)$,
- s neznámými parametry, např. N , Ex , Po , Bi ,
- s konkrétně zadanou pravděpodobnostní funkcí, příp. hustotou.

Příklady použití:

- Parametrické testy vyžadují konkrétní typ rozdělení pravděpodobnosti náhodného výběru, např. T-test vyžaduje normalitu. Jejich opomenutí může vést k nesprávným závěrům. Neparametrické (pořadové) testy předpoklad typu rozdělení nemají, ale mají menší sílu.
- ANOVA – normalita
- kontrola kvality – dodržování předepsaného rozdělení pravděpodobnosti
- kontrola generátorů náhodných čísel

Příklady

Příklad 1

Ze souboru rodin s pěti dětmi bylo náhodně vybráno 84 rodin a zjištěn počet chlapců.

počet chlapců	0	1	2	3	4	5
počet rodin	3	10	22	31	14	4

Na asymptotické hladině významnosti 0,05 testujeme hypotézu, že počet chlapců v rodinách s 5 dětmi má binomické rozdělení $Bi(5; 0,5)$.

Příklad 2

Byla sledována doba (v minutách), jakou 70 klientů jisté firmy strávilo čekáním na obsluhu (od vyzvednutí pořadového lístku).

doba čekání	(0; 3]	(3; 6]	(6; 9]	(9; 12]	(12; 15]	(15; 18]	(18; 21]	(21; 24]
počet klientů	14	16	10	9	8	5	3	5

Na asymptotické hladině významnosti 0,05 testujeme hypotézu, že doba čekání má exponenciální rozdělení pravděpodobnosti.

Empirické a teoretické četnosti

Definice 1 (Empirické = pozorované (Observed) četnosti)

Máme n předmětů (X_1, \dots, X_n) , které rozdělujeme do k kategorií A_1, \dots, A_k , přičemž každému z n předmětů odpovídá právě jedna kategorie.

Počty předmětů v jednotlivých kategoriích jsou **empirické četnosti** N_1, \dots, N_k .

kategorie	A_1	A_2	\dots	A_k	součet
empirické četnosti	N_1	N_2	\dots	N_k	n

Definice 2 (Teoretické = očekávané (Expected) četnosti)

Podle testovaného rozdělení pravděpodobnosti spočítáme teoretické pravděpodobnosti jevů, že jednotlivý předmět bude zařazen do kategorie A_j , $p_j = P(X \in A_j)$. Je-li rozdělovaných předmětů celkem n , jsou **teoretické četnosti** v jednotlivých kategoriích rovné $np_j = n_j$.

kategorie	A_1	A_2	\dots	A_k	součet
pravděpodobnosti	p_1	p_2	\dots	p_k	1
teoretické četnosti	np_1	np_2	\dots	np_k	n

Jak porovnáme shodu empirického a teoretického rozdělení pravděpodobnosti?

Testovací statistika

kategorie	A_1	A_2	\dots	A_k	součet
empirické četnosti	N_1	N_2	\dots	N_k	n
teoretické četnosti	np_1	np_2	\dots	np_k	n
pravděpodobnosti	p_1	p_2	\dots	p_k	1

Ideální shoda je, pokud všechny $N_j = np_j$.

Jak zvolit statistiku pro testování shodnosti empirických a teoretických četností?

Testovací statistika

kategorie	A_1	A_2	\dots	A_k	součet
empirické četnosti	N_1	N_2	\dots	N_k	n
teoretické četnosti	$n p_1$	$n p_2$	\dots	$n p_k$	n
pravděpodobnosti	p_1	p_2	\dots	p_k	1

Ideální shoda je, pokud všechny $N_j = n p_j$.

Jak zvolit statistiku pro testování shodnosti empirických a teoretických četností?

1 $N_1 - n p_1, \dots, N_k - n p_k$

2 $\sum_{j=1}^k (N_j - n p_j)$

3 $\sum_{j=1}^k |N_j - n p_j|, \quad \sum_{j=1}^k (N_j - n p_j)^2$

4 $\sum_{j=1}^k \frac{(N_j - n p_j)^2}{p_j}, \quad \frac{1}{n} \sum_{j=1}^k \frac{(N_j - n p_j)^2}{p_j}$

Multinomické rozdělení pravděpodobnosti

Definice 3 (Multinomické rozdělení pravděpodobnosti)

Máme n (X_1, \dots, X_n) předmětů k různých kategorií A_1, \dots, A_k .

Pravděpodobnost, že náhodně zvolený předmět X patří do kategorie A_j je rovna

$$p_j = P(X \in A_j) \in (0; 1), \quad j = 1, \dots, k, \quad \text{přičemž} \quad \sum_{j=1}^k p_j = 1.$$

Počty (náhodné) předmětů v jednotlivých kategoriích označíme

$$N_j = |\{X_i \in A_j, i = 1, \dots, n\}|, \quad j = 1, \dots, k, \quad \text{přičemž} \quad \sum_{j=1}^k N_j = n.$$

Sdružené rozdělení pravděpodobnosti vektoru (N_1, \dots, N_k) je **multinomické**,

$$(N_1, \dots, N_k) \sim M(n; p_1, \dots, p_k).$$

Jedná se o diskrétní rozdělení se simultánní pravděpodobnostní funkcí

$$P(N_1 = n_1, \dots, N_k = n_k) = \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k},$$

pro $n_j = 0, 1, \dots, n$ a $n_1 + \dots + n_k = n$.

Multinomické rozdělení pravděpodobnosti

Náhodný počet N_j předmětů v kategorii A_j má binomické rozdělení. Proč?

Věta 4

Pro $(N_1, \dots, N_k) \sim M(n; p_1, \dots, p_k)$ platí:

$$N_j \sim \text{Bi}(n, p_j), \quad \text{EX}_j = n p_j, \quad \text{DX}_j = n p_j(1 - p_j), \quad i = 1, \dots, k.$$

Moivreova-Laplaceova centrální limitní věta říká, že:

$$n \rightarrow \infty \implies U_j = \frac{N_j - n p_j}{\sqrt{n p_j(1 - p_j)}} \sim N(0; 1).$$

My však použijeme odlišné transformace:

$$Y_j = \frac{N_j - n p_j}{\sqrt{n p_j}}$$

Jakou střední hodnotu, rozptyl a asymptotické rozdělení pravděpodobnosti má Y_j ?

Úprava testovací statistiky

$$Y_j = \frac{N_j - n p_j}{\sqrt{n p_j}} = \sqrt{1 - p_j} U_j \stackrel{as.}{\approx} N(0; 1 - p_j)$$

Upravujeme testovací statistiku:

$$\begin{aligned} K &= \sum_{j=1}^k Y_j^2 = \sum_{j=1}^k \frac{(N_j - n p_j)^2}{n p_j} = \sum_{j=1}^k \frac{N_j^2}{n p_j} - 2 \sum_{j=1}^k \frac{N_j n p_j}{n p_j} + \sum_{j=1}^k \frac{n^2 p_j^2}{n p_j} = \\ &= \sum_{j=1}^k \frac{N_j^2}{n p_j} - 2 \underbrace{\sum_{j=1}^k N_j}_n + n \underbrace{\sum_{j=1}^k p_j}_1 = \sum_{j=1}^k \frac{N_j^2}{n p_j} - n \end{aligned}$$

Statistiku K lze zapsat jako součet kvadrátů k nezávislých náhodných veličin s normálním rozdělením, přičemž je dána jedna vazebná podmínka ($\sum_{j=1}^k N_j = n$).

Za platnosti hypotézy shody empirického a teoretického rozdělení pravděpodobnosti má statistika K rozdělení χ^2 s $(k - 1)$ stupni volnosti:

$$K = \sum_{j=1}^k Y_j^2 \stackrel{as.}{\approx} \chi^2(k - 1), \quad EK = k - 1$$

Test dobré shody

Věta 5 (Pearsonův test dobré shody)

Testovací statistika pro test dobré shody

$$K = \sum_{j=1}^k Y_j^2 = \sum_{j=1}^k \frac{(N_j - n p_j)^2}{n p_j} = \sum_{j=1}^k \frac{N_j^2}{n p_j} - n$$

má asymptotické rozdělení pravděpodobnosti $K \stackrel{as.}{\sim} \chi^2(k-1)$. Hypotézu o shodě empirického a teoretického rozdělení pravděpodobnosti zamítáme, pokud $K \geq \chi_{1-\alpha}^2(k-1)$.

Uvedený test je asymptotický a lze jej proto provádět jen při dostatečně velkém rozsahu náhodného výběru. Často se uvádí

podmínka dobré aproximace

Musí platit: $n p_j \geq 5 q, \quad j = 1, \dots, k,$

kde $q = 1$, anebo $q = \frac{|\{j : n p_j < 5\}|}{k}$ (Yarnoldovo kritérium).

Při nesplnění této podmínky je nutné kategorie A_j upravit – vhodně slučovat.

Test dobré shody v diskrétním rozdělení

- 1 Stanovíme kategorie A_1, \dots, A_k odpovídající všem možným jednotlivým výsledkům t_1, \dots, t_k uvažované diskrétní náhodné veličiny.
- 2 Pro jednotlivé kategorie spočítáme empirické četnosti

$$N_j = |\{X_i = t_j\}|$$

a teoretické četnosti pomocí pravděpodobnostní fce teoretického rozdělení,

$$n p_j = n P(X = t_j).$$

Lze příp. využít i distribuční fce: $n p_j = n \left[F(t_j) - \lim_{t \rightarrow t_j^-} F(t) \right]$.

- 3 Ověříme podmínku dobré aproximace (Yarnoldovo kritérium), příp. upravíme kategorie jejich vhodným sloučením a podmínku znovu ověříme.
- 4 Spočítáme hodnotu testovací statistiky K .
- 5 Pokud $K \geq \chi_{1-\alpha}^2(k-1)$, zamítneme shodu empirického a teoretického rozdělení pravděpodobnosti. Číslo k je počet kategorií.

Řešení Příkladu 1


četnosti

	t.j	N.j	p.j	n.j
1	0	3	0.03125	2.625
2	1	10	0.15625	13.125
3	2	22	0.31250	26.250
4	3	31	0.31250	26.250
5	4	14	0.15625	13.125
6	5	4	0.03125	2.625

Yarnoldovo kritérium

```
q <- sum (n * p.j < 5) / k  
[1] 0.3333333
```

```
n * p.j >= 5 * q  
[1] TRUE TRUE TRUE TRUE TRUE  
TRUE
```



Řešení Příkladu 1

test dobré shody

```
K <- sum (N.j^2 / (n * p.j)) - n
```

```
[1] 3.12381
```

```
qchisq (0.95, df = k - 1)
```

```
[1] 12.59159
```

```
K >= qchisq (0.95, df = k - 1)
```

```
[1] FALSE
```

```
1 - pchisq (K, df = k - 1)
```

```
[1] 0.6809048
```

```
chisq.test (N.j, p = p.j)
```

```
Chi-squared test for given probabilities
```

```
data: N.j
```

```
X-squared = 3.1238, df = 5, p-value = 0.6809
```


Řešení Příkladu 1

podmínka dobré aproximace

```
n * p.j >= 5  
[1] FALSE TRUE TRUE TRUE  
     TRUE FALSE
```

četnosti ve sloučených kategoriích

	t.j2	N.j2	p.j2	n.j2
1	0-1	13	0.1875	15.75
2	2	22	0.3125	26.25
3	3	31	0.3125	26.25
4	4-5	18	0.1875	15.75



```
n * p.j2 >= 5  
[1] TRUE TRUE TRUE TRUE
```

Řešení Příkladu 1

test dobré shody

```
K <- sum (N.j2^2 / (n * p.j2)) - n  
[1] 2.349206
```

```
qchisq (0.95, df = k2 - 1)  
[1] 7.814728
```

```
K >= qchisq (0.95, df = k2 - 1)  
[1] FALSE
```

Na asymptotické hladině významnosti 0,05 nezamítáme nulovou hypotézu, že počet chlapců v rodinách s 5 dětmi má rozdělení $Bi(5; 0,5)$.

Test dobré shody ve spojitém rozdělení

- 1 Stanovíme kategorie A_1, \dots, A_k jako třídící intervaly

$$A_j = (t_{j-1}, t_j], \quad j = 1, \dots, k,$$

pokrývající celou množinu výsledků teoretického rozdělení pravděpodobnosti tak, aby v každém intervalu ležel dostatečný počet hodnot z náhodného výběru (X_1, \dots, X_n) . Pro malá n se můžeme volit $k \approx \sqrt{n}$ z konstrukce histogramu, pro $n > 80$ se doporučuje až $k \approx 15 \left(\frac{n}{100}\right)^{2/5}$ kategorií.

- 2 Pro jednotlivé kategorie spočítáme empirické četnosti

$$N_j = |\{t_{j-1} < X_i \leq t_j\}|$$

a pomocí distribuční funkce F teoretického rozdělení pak teoretické četnosti

$$np_j = nP(t_{j-1} < X \leq t_j) = n[F(t_j) - F(t_{j-1})].$$

- 3 Ověříme podmínku dobré aproximace (Yarnoldovo kritérium), příp. upravíme – sloučíme některé intervaly a podmínku znovu ověříme.
- 4 Spočítáme hodnotu testovací statistiky K .
- 5 Pokud $K \geq \chi_{1-\alpha}^2(k-1)$, zamítneme shodu empirického a teoretického rozdělení pravděpodobnosti. Číslo k je počet použitých intervalů.

Test dobré shody při neznámých parametrech

V případě, že testujeme shodu rozdělení pravděpodobnosti náhodného výběru X_1, \dots, X_n s teoretickým rozdělením pravděpodobnosti s neznámými parametry, používáme tzv. **modifikovanou metodu minimálního χ^2** .

Modifikovaná metoda minimálního χ^2

Označíme-li neznámé parametry $\theta = (\theta_1, \dots, \theta_m)$, řešíme soustavu rovnic

$$\sum_{j=1}^k \frac{N_j - n p_j(\theta)}{p_j(\theta)} \frac{\partial p_j(\theta)}{\partial \theta_i} = 0, \quad i = 1, \dots, m.$$

Věta 6 (Pearsonův test dobré shody při neznámých parametrech)

Testovací statistika K pro test dobré shody má v případě m parametrů odhadnutých z náhodného výběru asymptotické rozdělení pravděpodobnosti $K \stackrel{as.}{\sim} \chi^2(k - 1 - m)$. Hypotézu o shodě empirického a teoretického rozdělení pravděpodobnosti zamítáme, pokud


$$K \geq \chi_{1-\alpha}^2(k - 1 - m).$$

Počet stupňů volnosti se tedy snižuje o počet odhadnutých parametrů.

Řešení Příkladu 2

Odhad parametru: $\hat{\lambda} = \frac{1}{\bar{X}}$

doba čekání



	A. j	N. j	p. j	n. j
1	(0; 3]	14	0.28576159	20.003311
2	(3; 6]	16	0.20410190	14.287133
3	(6; 9]	10	0.14577742	10.204419
4	(9; 12]	9	0.10411983	7.288388
5	(12; 15]	8	0.07436638	5.205647
6	(15; 18]	5	0.05311533	3.718073
7	(18; 21]	3	0.03793701	2.655591
8	(21; 24]	5	0.02709607	1.896725
9	> 24	0	0.06772447	4.740713

Řešení Příkladu 2

podmínka dobré aproximace, Yarnoldovo kritérium

```
n * p.j >= 5
[1] TRUE TRUE TRUE TRUE TRUE FALSE FALSE FALSE FALSE


q <- sum (n * p.j < 5) / k
[1] 0.4444444

n * p.j >= 5 * q
[1] TRUE TRUE TRUE TRUE TRUE TRUE TRUE FALSE TRUE
```

Podmínky nejsou splněny. Pro splnění podmínky dobré aproximace by bylo potřeba sloučit poslední 2 dvojice kategorií. Pro splnění Yarnoldova kritéria postačí sloučit poslední dvě kategorie.

Řešení Příkladu 2

doba čekání



	A. j2	N. j2	p. j2	n. j2
1	(0; 3]	14	0.28576159	20.003311
2	(3; 6]	16	0.20410190	14.287133
3	(6; 9]	10	0.14577742	10.204419
4	(9; 12]	9	0.10411983	7.288388
5	(12; 15]	8	0.07436638	5.205647
6	(15; 18]	5	0.05311533	3.718073
7	(18; 21]	3	0.03793701	2.655591
8	> 21	5	0.09482054	6.637438

Řešení Příkladu 2

Yarnoldovo kritérium po sloučení kategorií

```
q <- sum (n * p.j2 < 5) / k2  
[1] 0.25
```

```
n * p.j2 >= 5 * q  
[1] TRUE TRUE TRUE TRUE TRUE TRUE TRUE TRUE
```

test dobré shody ($df = k - 1 - m = 8 - 1 - 1 = 6$)

```
K <- sum (N.j2^2 / (n * p.j2)) - n  
[1] 4.803687
```

```
qchisq (0.95, df = k2 - 1 - 1)  
[1] 12.59159
```

```
K >= qchisq (0.95, df = k2 - 1 - 1)  
[1] FALSE
```

Nezamítáme nulovou hypotézu o exponenciálním rozdělení dob čekání.

Test Poissonova rozdělení pravděpodobnosti

Nechť (X_1, \dots, X_n) je náhodný výběr z Poissonova rozdělení pravděpodobnosti $Po(\lambda)$ s neznámým parametrem λ .

$$X \sim Po(\lambda) \implies EX = \lambda, \quad DX = \lambda.$$

V Poissonově rozdělení je tedy střední hodnota rovna rozptylu.
Na této typické vlastnosti je založena jednoduchá testovací statistika.

Věta 7 (Jednoduchý test Poissonova rozdělení pravděpodobnosti)

Testovací statistika

$$Q = (n-1) \frac{S^2}{\bar{X}} \stackrel{as.}{\sim} \chi^2(n-1)$$

*má v případě Poissonova rozdělení pravděpodobnosti náhodného výběru (X_1, \dots, X_n) asymptotické rozdělení pravděpodobnosti $\chi^2(n-1)$.
Hypotézu o shodě empirického rozdělení s Poissonovým rozdělením pravděpodobnosti zamítáme, pokud*

$$Q \leq \chi_{\alpha/2}^2(n-1) \quad \text{nebo} \quad Q \geq \chi_{1-\alpha/2}^2(n-1).$$

Test exponenciálního rozdělení pravděpodobnosti

Nechť (X_1, \dots, X_n) je náhodný výběr z exponenciálního rozdělení pravděpodobnosti $Ex(\lambda)$ s neznámým parametrem λ .

$$X \sim Ex(\lambda) \implies EX = \frac{1}{\lambda}, \quad DX = \frac{1}{\lambda^2}.$$

V exponenciálním rozdělení je tedy rozptyl rovný kvadrátu střední hodnoty. Na této typické vlastnosti je založena jednoduchá testovací statistika.

Věta 8 (Jednoduchý test exponenciálního rozdělení pravděpodobnosti)

Testovací statistika

$$Q = (n - 1) \frac{S^2}{\bar{X}^2} \stackrel{as.}{\sim} \chi^2(n - 1)$$

má v případě exponenciálního rozdělení pravděpodobnosti náhodného výběru (X_1, \dots, X_n) asymptotické rozdělení pravděpodobnosti $\chi^2(n - 1)$.

Hypotézu o shodě empirického rozdělení s exponenciálním rozdělením pravděpodobnosti zamítáme, pokud

$$Q \leq \chi_{\alpha/2}^2(n - 1) \quad \text{nebo} \quad Q \geq \chi_{1-\alpha/2}^2(n - 1).$$

Řešení Příkladu 2

jednoduchý test exponenciálního rozdělení

```
X <- rep (prumer.j, N.j)
Q <- (n-1) * var (X) / (mean (X))^2
[1] 35.72647
```

```
q1 = qchisq (0.025, n-1)
q2 = qchisq (0.975, n-1)
[1] 47.92416 93.85647
```

```
Q <= q1 | Q >= q2
[1] TRUE
```

Nulovou hypotézu o exponenciálním rozdělení dob čekání jednoduchým testem zamítáme na hladině významnosti 0,05.

Empirická distribuční funkce


Definice 9 (Empirická distribuční funkce (ECDF))

Nechť (X_1, \dots, X_m) je náhodný výběr. Funkce

$$\hat{F}(x) = \frac{1}{m} |\{i : X_i \leq x\}| = \frac{1}{m} \sum_{i=1}^m \zeta_i(x), \quad \text{kde } \zeta_i = \begin{cases} 1, & X_i \leq x \\ 0, & X_i > x \end{cases},$$

se nazývá **empirická distribuční funkce**.

Empirická distribuční funkce je schodovitá, zprava spojitá funkce.



Kolmogorovův-Smirnovův test

Porovnáváme dva stochasticky nezávislé náhodné výběry

- (X_1, \dots, X_m) rozsahu m z rozdělení psti. s distribuční funkcí $F(x)$,
- (Y_1, \dots, Y_n) rozsahu n z rozdělení psti. s distribuční funkcí $G(y)$.

z rozdělení pravděpodobnosti spojitého typu.

Testujeme hypotézu, že distribuční funkce těchto dvou rozdělení jsou shodné (mediánem i tvarem), tj. že všech $m + n$ náhodných veličin pochází ze stejného rozdělení, proti alternativě rozdílných distribučních funkcí (v jakémkoliv smyslu),

$$H_0 : F = G$$

$$H_1 : F \neq G.$$


Lze ukázat, že s rostoucím rozsahem m náhodného výběru se empirická distribuční funkce blíží ke skutečné distribuční funkci, z níž náhodný výběr pochází.

Nechť $\hat{F}(x)$ je empirická distribuční funkce X -ového výběru a $\hat{G}(y)$ je empirická distribuční funkce Y -ového výběru. Označíme

$$D = \sup \left\{ \left| \hat{F}(x) - \hat{G}(x) \right| ; x \in \mathbb{R} \right\}.$$

Jaký geometrický význam má testovací statistika D ?

Kolmogorovův-Smirnovův test



Věta 10 (Dvouvýběrový Kolmogorovův-Smirnovův test)

Hypotézu H_0 zamítáme, pokud

$$D \geq D_\alpha(m, n), \quad \text{resp. pokud } m + n > 35 \text{ a } D \geq \sqrt{\frac{m+n}{2mn} \ln \frac{2}{\alpha}}.$$

Číslo $D_\alpha(m, n)$ je tabelovaná kritická hodnota K-S testu.

Kolmogorovův-Smirnovův test

Můžeme také testovat hypotézu, že distribuční funkce F , z níž pochází náhodný výběr (X_1, \dots, X_n) je rovna jedné konkrétně zvolené distribuční funkci F_0 , např. $N(10;4)$, $Ex(3,5)$, $Po(2)$, $Bi(10;0,6)$,

$$H_0 : F = F_0$$

$$H_1 : F \neq F_0.$$

Označíme

$$D = \sup \left\{ \left| \widehat{F}(x) - F_0(x) \right| ; x \in \mathbb{R} \right\}.$$

Věta 11 (Jednovýběrový Kolmogorovův-Smirnovův test)

Hypotézu H_0 zamítáme, pokud

$$D \geq D_\alpha(n), \quad \text{resp. pokud } n \geq 30 \text{ a } D \geq \sqrt{\frac{1}{2n} \ln \frac{2}{\alpha}}.$$

Číslo $D_\alpha(n)$ je tabelovaná kritická hodnota jednovýběrového K-S testu.

Lillieforsova varianta K-S testu normality

Testujeme hypotézu, že náhodný výběr (X_1, \dots, X_n) pochází z normálního rozdělení $N(\mu, \sigma^2)$ s neznámými parametry.

Nejprve odhadneme parametry $\hat{\mu} = \bar{X}$, $\hat{\sigma} = \sqrt{S^2}$. Test je založen na statistice

$$D = \sup \left\{ \left| \hat{F}(x) - \Phi \left(\frac{x - \hat{\mu}}{\hat{\sigma}} \right) \right|; x \in \mathbb{R} \right\},$$

kde Φ značí distribuční funkci $N(0; 1)$ rozdělení.

Věta 12 (test normality)

Hypotézu o tom, že náhodný výběr (X_1, \dots, X_n) pochází rozdělení $N(\mu, \sigma^2)$ zamítáme, pokud

$$D \geq D_\alpha(n).$$

Číslo $D_\alpha(n)$ je tabelovaná kritická hodnota Lillieforsova testu.

Testy normality (v R)

D'Agostinův test (založený na šikmosti a špičatosti)	<code>agostino.test(X)</code>	*
Jarqueův-Beraův test (založený na šikmosti a špičatosti)	<code>jarque.test(X)</code>	*
Andersonův-Darlingův test (založený na transformaci na rovnoměrné rozdělení)	<code>ad.test(X)</code>	*
Lillieforsův test (varianta Kolmogorovova-Smirnovova testu)	<code>lillie.test(X)</code>	*
Cramérův-von Misesův test (alternativa Kolmogorovova-Smirnovova testu)	<code>cvm.test(X)</code>	*
test dobré shody (odhady μ, σ^2 modifikovanou metodou minimálního χ^2)	<code>pearson.test(X)</code>	*
Shapiroův-Wilkův test	<code>shapirotest(X)</code>	
Kolmogorovův-Smirnovův test (μ, σ^2 známé)	<code>ks.test(X, "pnorm", mean=, sd=)</code>	
Q-Q plot s kvantily normálního rozdělení	<code>qqnorm(X), qqline(X)</code>	
N-P plot		
* <code>library(moments)</code> ,	* <code>library(nortest)</code>	

- empirické a teoretické četnosti, jejich porovnání
- test dobré shody, využití, výpočet testovací statistiky
- úprava stupňů volnosti testu dobré shody při odhadnutých parametrech
- volba kategorií pro diskrétní a pro spojitě náhodné veličiny
- jednoduché testy pro Poissonovo a exponenciální rozdělení pravděpodobnosti
- Kolmogorovův-Smirnovův test, význam testovací statistiky, Lillieforsův test normality
- přehled testů normality

K zamyšlení (nebo simulaci v R)

Máme náhodný výběr (X_1, \dots, X_n) z nějakého libovolně zvoleného rozdělení pravděpodobnosti (např. $N(0; 1)$, $Ex(2, 5)$, apod.) s distribuční funkcí $F(x)$. Provedeme transformaci $Y_i = F(X_i)$. Jaké rozdělení pravděpodobnosti odpovídá transformovanému náhodnému vektoru (Y_1, \dots, Y_n) ?