

11. Porovnání empirického a teoretického rozložení

11.1. Motivace

11.2. Popis Kolmogorovova – Smirnovova testu a jeho Lilieforsovy varianty

11.3. Příklad: Jsou dány hodnoty 10, 12, 8, 9, 16. Pomocí Lilieforsovy varianty K- S testu ověřte na hladině významnosti 0,05, zda tato data pocházejí z normálního rozložení.

Řešení: Odhadem střední hodnoty je výběrový průměr $m = 11$, odhadem rozptylu je výběrový rozptyl $s^2 = 10$. Uspořádaný náhodný výběr je (8, 9, 10, 12, 16). Vypočteme hodnoty výběrové distribuční funkce:

$$x < 8 : F_5(x) = 0, 8 \leq x < 9 : F_5(x) = \frac{1}{5} = 0,2, 9 \leq x < 10 : F_5(x) = \frac{2}{5} = 0,4,$$

$$10 \leq x < 12 : F_5(x) = \frac{3}{5} = 0,6, 12 \leq x < 16 : F_5(x) = \frac{4}{5} = 0,8, x \geq 16 : F_5(x) = 1$$

Hodnoty teoretické distribuční funkce $\Phi_T(x)$ v bodech 8, 9, 10, 12, 16:

$$\Phi_T(8) = \Phi\left(\frac{8-11}{\sqrt{10}}\right) = \Phi(-0,95) = 1 - \Phi(0,95) = 1 - 0,82894 = 0,17106$$

$$\Phi_T(9) = \Phi\left(\frac{9-11}{\sqrt{10}}\right) = \Phi(-0,63) = 1 - \Phi(0,63) = 1 - 0,73565 = 0,26435$$

$$\Phi_T(10) = \Phi\left(\frac{10-11}{\sqrt{10}}\right) = \Phi(-0,32) = 1 - \Phi(0,32) = 1 - 0,62552 = 0,37448$$

$$\Phi_T(12) = \Phi\left(\frac{12-11}{\sqrt{10}}\right) = \Phi(0,32) = 0,62552$$

$$\Phi_T(16) = \Phi\left(\frac{16-11}{\sqrt{10}}\right) = \Phi(1,58) = 0,94295$$

(Φ je distribuční funkce rozložení $N(0,1)$.)

Rozdíly mezi výběrovou distribuční funkcí $F_5(x)$ a teoretickou distribuční funkcí $\Phi_T(x)$:

$$d_1 = 0,2 - 0,17106 = 0,02894; d_2 = 0,4 - 0,26435 = 0,13565; d_3 = 0,6 - 0,37448 = 0,22552;$$

$$d_4 = 0,8 - 0,62552 = 0,17448; d_5 = 1 - 0,94295 = 0,05705.$$

Testová statistika: $D_5 = 0,22552$, modifikovaná kritická hodnota pro $n = 5$, $\alpha = 0,05$ je 0,343. Protože $0,22552 < 0,343$, hypotézu o normalitě nezamítáme na hladině významnosti 0,05.

11.4. Popis Shapirova – Wilkova testu

11.5. Poznámka: Další testy normality

11.6. Popis testu dobré shody v diskrétním a spojitém případě

11.7. Příklad: Byl zjišťován počet poruch určitého zařízení za 100 hodin provozu ve 150 disjunktních 100 h intervalech. Výsledky měření:

Počet poruch za 100 hodin provozu 0 1 2 3 4 a víc

Absolutní četnost 52 48 36 10 4

Na asymptotické hladině významnosti 0,05 testujte hypotézu, že náhodný výběr X_1, \dots, X_{150} pochází z rozložení $Po(1,2)$.

Řešení:

Pravděpodobnost, že náhodná veličina s rozložením $Po(\lambda)$, kde $\lambda = 1,2$ bude nabývat hodnot

$$p_0, \dots, p_4 \text{ a víc je } p_j = \frac{\lambda^j}{j!} e^{-\lambda} = \frac{1,2^j}{j!} e^{-1,2}, j = 0, 1, 2, 3, p_4 = 1 - (p_0 + p_1 + p_2 + p_3).$$

Výpočty potřebné pro stanovení testové statistiky K uspořádáme do tabulky.

j	n_j	p_j	np_j	$\frac{(n_j - np_j)^2}{np_j}$
0	52	0,301	150.0,301=45,15	1,039
1	48	0,361	150.0,361=54,15	0,698
2	36	0,217	150.0,217=32,55	0,366
3	10	0,087	150.0,087=13,05	0,713
4	4	0,034	150.0,034=5,1	0,237

$K = 1,039 + 0,698 + 0,713 + 0,237 = 3,053$, $r = 5$, $\chi^2_{0,95}(4) = 9,488$. Protože $3,053 < 9,488$, nulovou hypotézu nezamítáme na asymptotické hladině významnosti 0,05.

11.8. Příklad (test dobré shody pro spojité rozložení): Byl pořizen náhodný výběr rozsahu $n = 100$. Jeho číselné realizace byly rozříděny do 5 ekvidistantních třídicích intervalů o délce 0,04, přičemž dolní mez prvního třídicího intervalu je 3,92. Absolutní četnosti jednotlivých třídicích intervalů jsou: 11, 20, 44, 19, 6.

Výběrový průměr se realizoval hodnotou $m = 4,02$ a výběrová směrodatná odchylka hodnotou $s = 0,04$.

Na asymptotické hladině významnosti 0,05 testujte hypotézu, že náhodný výběr pochází z normálního rozložení.

Řešení:

Výpočty potřebné pro stanovení testové statistiky K uspořádáme do tabulky.

Přitom symbolem Φ značíme distribuční funkci rozložení $N(\mu, \sigma^2)$, kde $\mu = 4,02$ a $\sigma = 0,04$.

(u_j, u_{j+1})	n_j	$p_j = \Phi(u_{j+1}) - \Phi(u_j)$	np_j	$(n_j - np_j)^2$	$\frac{(n_j - np_j)^2}{np_j}$
(3,92, 3,96)	11	0,060598	6,0598	24,4060	4,0276
(3,96, 4,00)	20	0,241730	24,1730	17,4142	0,7204
(4,00, 4,04)	44	0,382925	38,2925	32,5756	0,8507
(4,04, 4,08)	19	0,241730	24,1730	26,7608	1,1070
(4,08, 4,12)	6	0,060598	6,0598	0,0036	0,0006

$$K = 4,0276 + 0,7204 + 0,8507 + 1,1070 + 0,0006 = 6,7063$$

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

Protože testová statistika se realizuje v kritickém oboru, hypotézu o normalitě zamítáme na asymptotické hladině významnosti 0,05.

11.9. Poznámka: Použití testu dobré shody na data, jejichž rozložení je určeno intuitivně nebo na základě zkušenosti

11.10. Příklad: Ve svých pokusech pozoroval J.G. Mendel 10 rostlin hrachu a na každé z nich počet žlutých a zelených semen. Výsledky pokusu:

č.rostliny	1	2	3	4	5	6	7	8	9	10
počet žlutých	25	32	14	70	24	20	32	44	50	44
počet zelených	11	7	5	27	13	6	13	9	14	18
celkem	36	39	19	97	37	26	45	53	64	62

Z genetických modelů vyplývá, že pravděpodobnost výskytu žlutého semene by měla být 0,75 a zeleného 0,25. Na asymptotické hladině významnosti 0,05 testujte hypotézu, že výsledky Mendelových pokusů se shodují s modelem.

Řešení:

Výpočty potřebné pro stanovení testové statistiky K uspořádáme do tabulky.

j	n_j	p_j	np_j	$\frac{(n_j - np_j)^2}{np_j}$
1	25	0,75	36.0,75=27	0,148148
2	32	0,75	39.0,75=29,25	0,258547
⋮	⋮	⋮	⋮	⋮
10	44	0,75	62.0,75=46,5	0,134409

$K = 0,148148 + 0,258547 + \dots + 0,134409 = 1,797495$, $r = 10$, $\chi^2_{0,95}(9) = 16,9$.

Protože $1,797495 < 16,9$, nulovou hypotézu nezamítáme na asymptotické hladině významnosti 0,05.

11.11. Poznámka: Jednoduchý test Poissonova rozložení

11.12. Příklad: Studujeme rozložení počtu pacientů, kteří během 75 dnů přijdou na pohotovost. Osmihodinovou pracovní dobu rozdělíme do půlhodinových intervalů a v každém intervalu zjistíme počet příchozích pacientů:

Počet pacientů	Pozorovaná četnost
0	79
1	188
2	282
3	275
4	196
5	114
6	45
7	10
8	7
9	3
10	1

Na asymptotické hladině významnosti 0,05 testujte hypotézu, že daný náhodný výběr pochází z Poissonova rozložení. Použijte jednoduchý test Poissonova rozložení.

Řešení:

Nejprve musíme vypočítat realizaci výběrového průměru a výběrového rozptylu:

$$m = \frac{1}{1200} (0 \cdot 79 + 1 \cdot 188 + \dots + 10 \cdot 1) = 2,80\bar{3}$$

$$s^2 = \frac{1}{1199} [79 \cdot (0 - 2,80\bar{3})^2 + 188 \cdot (1 - 2,80\bar{3})^2 + \dots + 1 \cdot (10 - 2,80\bar{3})^2] = 2,708579$$

$$K = \frac{(n-1)S^2}{M} = \frac{1199 \cdot 2,708579}{2,80\bar{3}} = 1158,579,$$

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

H_0 nezamítáme na asymptotické hladině významnosti 0,05.

11.13. Poznámka: Jednoduchý test exponenciálního rozložení

11.14. Příklad: Byla zkoumána doba životnosti 45 součástek (v hodinách). Zjistili jsme, že průměrná doba životnosti činila $m = 99,93$ h a rozptyl $s^2 = 7328,91$ h². Na asymptotické hladině významnosti 0,05 testujte hypotézu, že daný náhodný výběr pochází z exponenciálního rozložení.

Řešení:

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

Kritický obor:

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

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