

Cvičení 6.: Parametrické úlohy o jednom výběru a dvou nezávislých výběrech z alternativního rozložení

Úkol 1.: Vlastnosti výběrového průměru z alternativního rozložení

Mezi americkými voliči 60% osob volí republikány a 40% demokraty. Jaká je pravděpodobnost, že v náhodném výběru 100 amerických voličů budou voliči republikánů v menšině? Výpočet proveďte jak přesně, tak pomocí aproximace normálním rozložením.

Návod:

X_1, \dots, X_{100} je náhodný výběr z $A(0,6)$, $X_i = 1$, když i -tá osoba volí republikány, $X_i = 0$ jinak, $i = 1, \dots, 100$. Zavedeme statistiku $Y_{100} = X_1 + \dots + X_{100}$, $Y_{100} \sim \text{Bi}(100; 0,6)$ (viz skripta Teorie pravděpodobnosti a matematická statistika, sbírka příkladů, příklad 8.10.), $E(Y_{100}) = n \cdot p = 100 \cdot 0,6 = 60$, $D(Y_{100}) = n \cdot p \cdot (1-p) = 100 \cdot 0,6 \cdot 0,4 = 24$. Označme $\Phi_{100}(y)$

distribuční funkci náhodné veličiny Y_{100} , $\Phi_{100}(y) = \sum_{k=0}^y \binom{100}{k} 0,6^k 0,4^{100-k}$.

Přesný výpočet: $P(Y_{100} < 50) = P(Y_{100} \leq 49) = \Phi_{100}(49) = 0,016761686$.

Vytvoříme datový soubor o jedné proměnné a o jednom případě. Do Dlouhého jména této proměnné napíšeme =IBinom(49;0,6;100). Funkce IBinom(x;p;n) počítá hodnotu distribuční funkce rozložení $\text{Bi}(n,p)$ v bodě x .


Přibližný výpočet: užijeme důsledek Moivreovy - Laplaceovy integrální věty (viz skripta Základní statistické metody, věta 6.3.1.1.). Nejdříve ověříme splnění podmínky dobré aproximace $n \cdot p \cdot (1-p) = 100 \cdot 0,6 \cdot 0,4 = 24 > 9$. Podmínka je splněna.

$P(Y_{100} < 50) = P(Y_{100} \leq 49) \approx \Phi(49)$, kde $\Phi(49)$ je hodnota distribuční funkce rozložení $N(60; 24)$ v bodě 49.


Vytvoříme datový soubor o jedné proměnné a o jednom případě. Do Dlouhého jména této proměnné napíšeme =INormal(49;60;sqrt(24)).

Zjistíme, že $\Phi(49) = 0,012372$.

Přesný výpočet



Aproximativní výpočet



Úkol 2.: Asymptotický interval spolehlivosti pro parametr p alternativního rozložení

Může politická strana, pro niž se v předvolebním průzkumu vyslovilo 60 z 1000 dotázaných osob, očekávat se spolehlivostí aspoň 0,95, že by v této době ve volbách překročila 5% hranici pro vstup do parlamentu?

Návod:

Zavedeme náhodné veličiny X_1, \dots, X_{1000} , přičemž $X_i = 1$, když i -tá osoba se vysloví pro danou politickou stranu a $X_i = 0$ jinak, $i = 1, \dots, 1000$. Tyto náhodné veličiny tvoří náhodný výběr z rozložení $A(p)$. V tomto případě $n = 1000$, $m = 60/1000 = 0,06$, $\alpha = 0,05$, $u_{1-\alpha} = u_{0,95} = 1,645$.

Ověření podmínky $n \cdot p \cdot (1-p) > 9$: parametr p neznáme, musíme ho nahradit výběrovým průměrem. Pak $1000 \cdot 0,06 \cdot 0,94 = 56,4 > 9$.

95% levostranný interval spolehlivosti pro p je

$\left(\frac{\bar{m} - m_0}{\sqrt{\frac{m_0(1-m_0)}{n}}} ; \infty \right) \left(\frac{0,06 - \frac{0,06}{1000}}{\sqrt{\frac{0,06(1-0,06)}{1000}}} ; u_{0,95} \right)$ (viz skripta Základní statistické metody, důsledek 6.3.2.2.)

Postup ve STATISTICE:

1. možnost: Vytvoříme datový soubor o jedné proměnné a o jednom případě. Do Dlouhého jména této proměnné napíšeme $=0,06 - \sqrt{0,06 \cdot 0,94/1000} \cdot VNormal(0,95;0;1)$. Vyjde 0,047647.

2. možnost: Statistika – Analýza síly testu – Odhad intervalu – Jeden podíl, Z, Chí-kvadrát test – OK – Pozorovaný podíl p: 0,06, Velik. Vzorku (N): 1000, Spolehlivost: 0,9 – Vypočítat. Dostaneme 0,0476.

S pravděpodobností přibližně 0,95 tedy $\hat{Q} > 0,047647$. Protože tento interval zahrnuje i hodnoty nižší než 0,05, nelze vyloučit, že strana získá méně než 5% hlasů.

Úkol 3: Testování hypotézy o parametru Q alternativního rozložení

Určitá cestovní kancelář organizuje zahraniční zájezdy podle individuálních přání zákazníků. Z několika minulých let ví, že 30% všech takto organizovaných zájezdů má za cíl zemi X. Po zhoršení politických podmínek v této zemi se cestovní kancelář obává, že se zájem o tuto zemi mezi zákazníky sníží. Ze 150 náhodně vybraných zákazníků v tomto roce má 38 za cíl právě zemi X. Potvrzují nejnovější data pokles zájmu o tuto zemi? Volte hladinu významnosti 0,05.

Návod:

Máme náhodný výběr X_1, \dots, X_{150} z rozložení $A(0,3)$. Testujeme $H_0: Q = 0,3$ proti levostranné alternativě $H_1: Q < 0,3$. V tomto případě je testovým kritériem statistika

$$T_0 = \frac{\sum_{i=1}^n X_i}{\sqrt{\frac{Q_0(1-Q_0)}{n}}}, \text{ která v případě platnosti nulové hypotézy má asymptoticky rozložení } N(0,1)$$

(viz skripta Základní statistické metody, věta 6.3.3.1.). Musíme ověřit splnění podmínky $n \cdot Q_0(1-Q_0) > 9$: $150 \cdot 0,3 \cdot 0,7 = 31,5 > 9$. Vypočteme realizaci testového kritéria:

$$\frac{\bar{x} - Q_0}{\sqrt{\frac{Q_0(1-Q_0)}{n}}} = \frac{\frac{38}{150} - 0,3}{\sqrt{\frac{0,3 \cdot 0,7}{150}}} = -0,47. \text{ Kritický obor: } W = \{ \bar{x} < -1,4 \}$$

Protože testové kritérium nepatří do kritického oboru, H_0 nezamítáme na asymptotické hladině významnosti 0,05. S rizikem omylu nejvýše 5% tedy naše data neprokázala pokles zájmu zákazníků cestovní kanceláře o zemi X.

Postup ve STATISTICE:

Asymptotický způsob: Vytvoříme datový soubor o dvou proměnných (nazveme je t_0 a kvantil) a jednom případě. Vypočteme realizaci testového kritéria tak, že do Dlouhého jména proměnné t_0 napíšeme

$$=(38/150-0,3)/\sqrt{0,3 \cdot 0,7/150}$$

Do Dlouhého jména proměnné kvantil napíšeme

$$=VNormal(0,95;0;1)$$

Tím získáme kvantil $u_{0,95}$.

		1	2
		t0	kvant
	1	-1,2472	1,644

Jelikož realizace testového kritéria $t_0 = -1,24721913$ nepatří do kritického oboru $W_{\alpha} = 1,448$, H_0 nezamítáme na asymptotické hladině významnosti 0,05.

Přibližný způsob: Do nového datového souboru o jedné proměnné X a 150 případech uložíme 38 jedniček (indikují zájem o danou zemi) a 112 nul (indikují nezájem o danou zemi).
Statistika – Základní statistiky a tabulky – t-test, samost. vzorek – OK – Proměnné X – OK,
Test všech průměrů vůči 0,3 – Výpočet.

Promě	t test průměru vůči referenční konstantě (hodnotě)							
	Prům	Sm.od	N	Sm.chy	Referenční konstar	t	Sv	p
X	0,253	0,436	150	0,035	0,300	-1,30976	14	0,1923

Hodnota testové statistiky je při tomto přibližném způsobu -1,30976. Odpovídající p-hodnota je 0,1923, ovšem to je p-hodnota pro oboustranný test. Tuto p-hodnotu tedy musíme dělit dvěma a dostaneme 0,0961. Na asymptotické hladině významnosti 0,05 nelze zamítnout hypotézu, že zájem o danou zemi se nezměnil.

Úkol 4.: Asymptotický interval spolehlivosti pro parametrickou funkci Q

Při výstupní kontrole bylo náhodně vybráno 150 výrobků vyrobených na ranní směně a rovněž 150 výrobků vyrobených na odpolední směně. U ranní směny bylo zjištěno 16 zmetků a u odpolední 12 zmetků. Sestrojte 95% asymptotického interval spolehlivosti pro rozdíl pravděpodobností vyrobení zmetku v obou směnách.

Návod: Zavedeme náhodnou veličinu X_{1i} , která bude nabývat hodnoty 1, když i -tý výrobek z ranní směny je zmetek, 0 jinak, $i = 1, \dots, 150$. Náhodné veličiny $X_{1,1}, \dots, X_{1,150}$ tvoří náhodný výběr z rozložení $A_{1,Q}$. Dále zavedeme náhodnou veličinu X_{2i} , která bude nabývat hodnoty 1, když i -tý výrobek z odpolední směny je zmetek, 0 jinak, $i = 1, \dots, 150$. Náhodné veličiny $X_{2,1}, \dots, X_{2,150}$ tvoří náhodný výběr z rozložení $A_{2,Q}$.

$n_1 = 150, n_2 = 150, m_1 = 16/150 = 0,1067, m_2 = 12/150 = 0,08$.

Ověření podmínek $n_1 Q (1-Q) > 9$ a $n_2 Q (1-Q) > 9$: Parametry Q a Q neznáme, nahradíme je odhady m_1 a m_2 : $16 \cdot (1-16/150) = 14,29 > 9, 12 \cdot (1-12/150) = 11,04 > 9$.

Meze 100(1- α)% asymptotického empirického intervalu spolehlivosti pro parametrickou funkci Q jsou:

$$d = \frac{m_1(1 - \frac{\alpha}{2}) + m_2(1 - \frac{\alpha}{2})}{n_1 + n_2} = \frac{16 \cdot \frac{1}{2} + 12 \cdot \frac{1}{2}}{150 + 150} = 0,143$$

$$h = \frac{m_1(1 + \frac{\alpha}{2}) + m_2(1 + \frac{\alpha}{2})}{n_1 + n_2} = \frac{16 \cdot \frac{3}{2} + 12 \cdot \frac{3}{2}}{150 + 150} = 0,192$$

Zjistili jsme tedy, že s pravděpodobností přibližně 0,95: $-0,039 < Q < 0,092$.

Postup ve STATISTICE:

Otevřeme nový datový soubor se dvěma proměnnými d a h a o jednom případě. Do Dlouhého jména proměnné d napíšeme:

$$=16/150-12/150-\text{sqrt}((16/150)*(134/150)/150+(12/150)*(138/150)/150)*\text{VNormal}(0,975;0;1)$$

Do Dlouhého jména proměnné h napíšeme:

$$=16/150-$$

$$12/150+\text{sqrt}((16/150)*(134/150)/150+(12/150)*(138/150)/150)*\text{VNormal}(0,975;0;1)$$

Dostaneme tabulku

	d	h
1	-0,039	0,092

S pravděpodobností přibližně 0,95 se rozdíl pravděpodobností vyrobení zmetku na ranní a odpolední směně nachází v intervalu (-0,039; 0,092).

Úkol 5.: Testování hypotézy o parametrické funkci Q

Pro údaje z úkolu 4 testujte na asymptotické hladině významnosti 0,05 hypotézu, že pravděpodobnost vyrobení zmetků v obou směních je táž.

Postup ve STATISTICE:

Statistiky – Základní statistiky a tabulky – Testy rozdílů: r, %, průměry – OK – vybereme Rozdíl mezi dvěma poměry – do políčka P 1 napíšeme 0,1067, do políčka N1 napíšeme 150, do políčka P 2 napíšeme 0,08, do políčka N2 napíšeme 150 – Výpočet. Dostaneme p-hodnotu 0,4274, tedy nezamítáme nulovou hypotézu na hladině významnosti 0,05.

Testy rozdílů: r, %, průměry: Tabulka4

Poslat/tisknout výsledky každ. výpočtu do okna protokolu Storno

Rozdíl mezi dvěma korelačními koeficienty

r1: 0,00 N1: 10 p: 1,0000 Jednostr. Výpočet
r2: 0,00 N2: 10 Oboustr.

Rozdíl mezi dvěma průměry (normální rozdělení)

Pr1: 0,25333 SmOd1: 0,43637 N1: 150 p: 0,0961 Výpočet
Pr2: 0,3 SmOd2: 1, N2: 10 Jednostr.
 Výběrový průměr vs. střední hodnota Oboustr.

Rozdíl mezi dvěma poměry

P 1: 0,10670 N1: 150 p: 0,4274 Jednostr. Výpočet
P 2: 0,08000 N2: 150 Oboustr.

Úkol k samostatnému řešení: Přírůstky cen akcií na burze (v %) u 10 náhodně vybraných společností dosáhly těchto hodnot: 10, 16, 5, 10, 12, 8, 4, 6, 5, 4. Sestrojte 95% asymptotický empirický interval spolehlivosti pro pravděpodobnost, že přírůstek ceny akcie překročí 8,5%.
Výsledek: $0,096 < Q < 0,704$ s pravděpodobností aspoň 0,95.

Znamená to, že pravděpodobnost, že přírůstek ceny akcie překročí 8,5%, je aspoň 9,6% a nanejvýš 70,4% (při spolehlivosti 95%.)

Úkol k samostatnému řešení: Z 28 studentek oboru národní hospodářství mělo z matematiky trojku 17 studentek, zatímco z 20 studentek oboru informatika mělo z matematiky trojku jen 6 studentek. Na asymptotické hladině významnosti 0,05 testujte hypotézu, že pravděpodobnost získání trojky z matematiky je obě skupiny studentek stejná.

Výsledek: Testová statistika se realizuje hodnotou $t_0 = 2,100009$, kritický obor je

$W_{\infty} = \left(-\sqrt{\frac{196}{196}}, \sqrt{\frac{196}{196}} \right)$. Protože $t_0 \notin W_{\infty}$, zamítáme nulovou hypotézu na asymptotické hladině významnosti 0,05.

Použijeme-li v systému STATISTICA aplikaci Testy rozdílů, dostaneme p-hodnotu 0,0358, tedy na asymptotické hladině významnosti 0,05 zamítáme nulovou hypotézu.