

## **Parametrické úlohy o jednom a dvou výběrech z alternativního rozložení**

### **Osnova:**

Případ jednoho náhodného výběru

- asymptotické rozložení statistiky odvozené z výběrového průměru alternativního rozložení
- vzorec pro meze intervalu spolehlivosti pro parametr alternativního rozložení
- testování hypotézy o parametru alternativního rozložení

Případ dvou nezávislých náhodných výběrů

- asymptotické rozložení statistiky odvozené z výběrových průměrů dvou nezávislých alternativních rozložení
- vzorec pro meze intervalu spolehlivosti pro rozdíl parametrů dvou alternativních rozložení
- testování hypotézy o rozdílu parametrů dvou alternativních rozložení

**Případ jednoho náhodného výběru:** S náhodným výběrem rozsahu  $n$  z alternativního rozložení se setkáváme v situaci, kdy provádíme  $n$  opakovaných nezávislých pokusů a v každém z těchto pokusů sledujeme nastoupení úspěchu. Pravděpodobnost úspěchu je pro všechny pokusy stejná. Náhodná veličina  $X_i$  nabude hodnoty 1, pokud v  $i$ -tém pokusu nastal úspěch a hodnoty 0, pokud v  $i$ -tém pokusu úspěch nenastal,  $i = 1, 2, \dots, n$ . Realizací náhodného výběru  $X_1, \dots, X_n$  je tedy posloupnost 0 a 1.

### Opakování:

**Alternativní rozložení:** Náhodná veličina  $X$  udává počet úspěchů v jednom pokusu, přičemž pravděpodobnost úspěchu je  $\vartheta$ . Píšeme  $X \sim A(\vartheta)$ .

$$\pi(x) = \begin{cases} 1 - \vartheta & \text{pro } x = 0 \\ \vartheta & \text{pro } x = 1 \\ 0 & \text{jinak} \end{cases} \quad \text{neboli} \quad \pi(x) = \begin{cases} \vartheta^x (1 - \vartheta)^{1-x} & \text{pro } x = 0, 1 \\ 0 & \text{jinak} \end{cases}$$

**Binomické rozložení:** Náhodná veličina  $X$  udává počet úspěchů v posloupnosti  $n$  nezávislých opakovaných pokusů, přičemž pravděpodobnost úspěchu je v každém pokusu  $\vartheta$ . Píšeme  $X \sim Bi(n, \vartheta)$ .

$$\pi(x) = \begin{cases} \binom{n}{x} \vartheta^x (1 - \vartheta)^{n-x} & \text{pro } x = 0, \dots, n \\ 0 & \text{jinak} \end{cases}$$

$$E(X) = n\vartheta, D(X) = n\vartheta(1-\vartheta)$$

(Alternativní rozložení je speciálním případem binomického rozložení pro  $n = 1$ .

Jsou-li  $X_1, \dots, X_n$  stochasticky nezávislé náhodné veličiny,  $X_i \sim A(\vartheta), i = 1, \dots, n$ , pak  $X = \sum_{i=1}^n X_i \sim Bi(n, \vartheta)$ .

### **Centrální limitní věta:**

Jsou-li náhodné veličiny  $X_1, \dots, X_n$  stochasticky nezávislé a všechny mají stejné rozložení se střední hodnotou  $\mu$

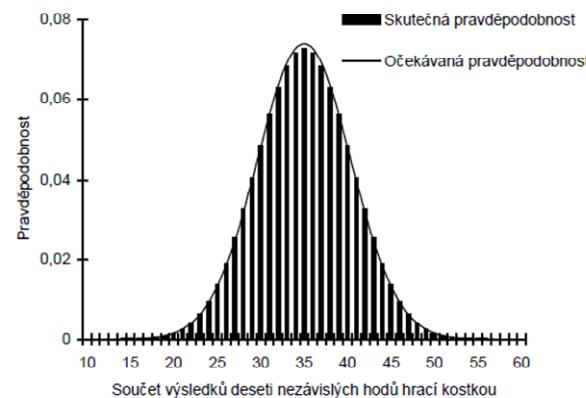
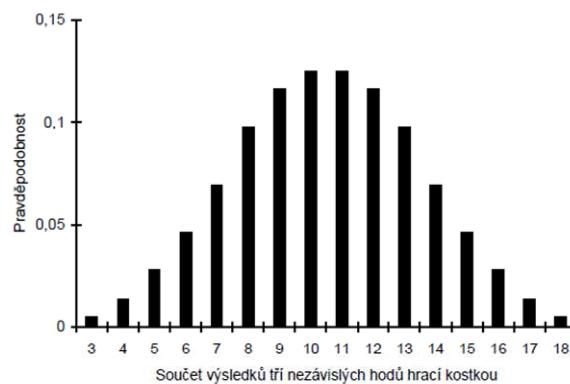
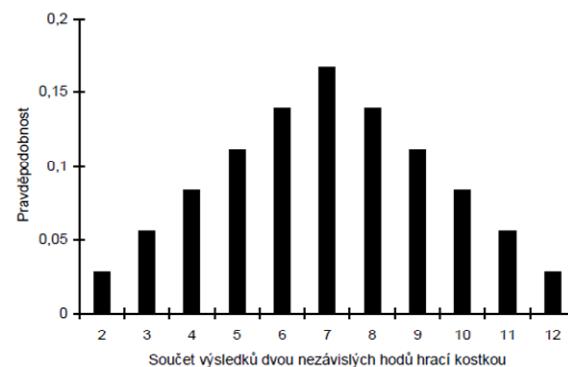
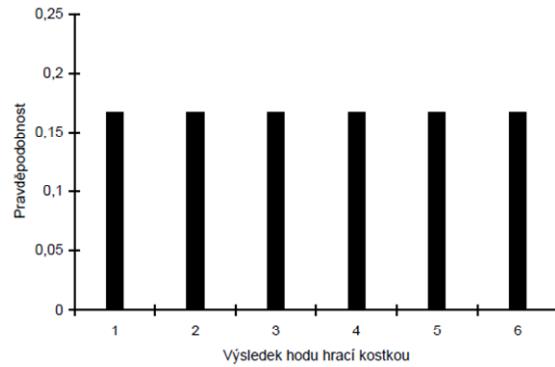
a rozptylem  $\sigma^2$ , pak pro velká  $n$  ( $n \geq 30$ ) lze rozložení součtu  $\sum_{i=1}^n X_i$  approximovat normálním rozložením  $N(n\mu, n\sigma^2)$ .

Zkráceně píšeme  $\sum_{i=1}^n X_i \approx N(n\mu, n\sigma^2)$ .

Pokud součet  $\sum_{i=1}^n X_i$  standardizujeme, tj. vytvoříme náhodnou veličinu  $U_n = \frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}}$ , pak rozložení této náhodné veličiny lze approximovat standardizovaným normálním rozložením. Zkráceně píšeme  $U_n \approx N(0,1)$

Normální rozložení je tedy rozložením limitním, k němuž se blíží všechna rozložení, proto hraje velmi důležitou roli v počtu pravděpodobnosti a matematické statistice.

## Ilustrace centrální limitní věty – opakování hody kostkou



## Asymptotické rozložení statistiky odvozené z výběrového průměru

Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozložení  $A(\vartheta)$  a nechť je splněna podmínka  $n\vartheta(1-\vartheta) > 9$ .

Pak statistika  $U = \frac{M - \vartheta}{\sqrt{\frac{\vartheta(1-\vartheta)}{n}}}$  konverguje v distribuci k náhodné veličině se standardizovaným normálním rozložením.

(Říkáme, že  $U$  má asymptoticky rozložení  $N(0,1)$  a píšeme  $U \approx N(0,1)$ .)

### Vysvětlení:

Protože  $X_1, \dots, X_n$  je náhodný výběr z rozložení  $A(\vartheta)$ , bude mít statistika  $Y_n = \sum_{i=1}^n X_i$  (výběrový úhrn) rozložení  $Bi(n, \vartheta)$ .

$Y_n$  má střední hodnotu  $E(Y_n) = n\vartheta$  a rozptyl  $D(Y_n) = n\vartheta(1-\vartheta)$ . Podle centrální limitní věty se standardizovaná statistika  $U = \frac{Y_n - n\vartheta}{\sqrt{n\vartheta(1-\vartheta)}}$  asymptoticky řídí standardizovaným normálním rozložením  $N(0,1)$ . Pokud čitatele i jmenovatele podělíme n,

$$\text{dostaneme vyjádření: } U = \frac{\frac{Y_n - \vartheta}{n}}{\sqrt{\frac{n\vartheta(1-\vartheta)}{n^2}}} = \frac{\frac{1}{n} \sum_{i=1}^n X_i - \vartheta}{\sqrt{\frac{\vartheta(1-\vartheta)}{n}}} = \frac{M - \vartheta}{\sqrt{\frac{\vartheta(1-\vartheta)}{n}}} \approx N(0,1)$$

### Vzorec pro meze 100(1- $\alpha$ )% asymptotického empirického intervalu spolehlivosti pro parametr $\vartheta$

Meze 100(1- $\alpha$ )% asymptotického empirického intervalu spolehlivosti pro parametr  $\vartheta$  jsou:

$$d = m - \sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2}, h = m + \sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2}.$$

#### Vysvětlení:

Pokud rozptyl  $D(M) = \frac{\vartheta(1-\vartheta)}{n}$  nahradíme odhadem  $\frac{M(1-M)}{n}$ , konvergence náhodné veličiny  $U$  k veličině s rozložením  $N(0,1)$  se neporuší. Tedy

$$\begin{aligned} \forall \vartheta \in \Xi : 1 - \alpha &\leq P\left(-u_{1-\alpha/2} < \frac{M - \vartheta}{\sqrt{\frac{M(1-M)}{n}}} < u_{1-\alpha/2}\right) = \\ &= P\left(M - \sqrt{\frac{M(1-M)}{n}} u_{1-\alpha/2} < \vartheta < M + \sqrt{\frac{M(1-M)}{n}} u_{1-\alpha/2}\right) \end{aligned}$$

### Příklad:

Náhodně bylo vybráno 100 osob a zjištěno, že 34 z nich nakupuje v internetových obchodech. Najděte 95% asymptotický interval spolehlivosti pro pravděpodobnost, že náhodně vybraná osoba nakupuje v internetových obchodech.

### Řešení:

Zavedeme náhodné veličiny  $X_1, \dots, X_{100}$ , přičemž  $X_i = 1$ , když i-tá osoba nakupuje v internetových obchodech a  $X_i = 0$  jinak,  $i = 1, \dots, 100$ . Tyto náhodné veličiny tvoří náhodný výběr z rozložení  $A(\vartheta)$ .

$$n = 100, m = 34/100, \alpha = 0,05, u_{1-\alpha/2} = u_{0,975} = 1,96.$$

Ověření podmínky  $n\vartheta(1-\vartheta) > 9$ : parametr  $\vartheta$  neznáme, musíme ho nahradit výběrovým průměrem. Pak  $100 \cdot 0,34 \cdot 0,66 = 22,44 > 9$ .

$$d = 0,34 - \sqrt{\frac{0,34(1-0,34)}{100}}1,96 = 0,2472, h = 0,34 + \sqrt{\frac{0,34(1-0,34)}{100}}1,96 = 0,4328.$$

S pravděpodobností přibližně 0,95 tedy  $0,2472 < \vartheta < 0,4328$ . Znamená to, že s pravděpodobností přibližně 95% je v uvažované populaci nejméně 24,7% a nejvíce 43,3% osob, které nakupují v internetových obchodech.

## Výpočet pomocí systému STATISTICA:

Použijeme modul Analýza síly testu

Statistiky – Analýza síly testu – Odhad intervalu – Jeden podíl, Z, Chí-kvadrát test – OK – Pozorovaný podíl p: 0,34, Velikost vzorku: 100, Spolehlivost: 0,95 – Vypočítat.

Dostaneme tabulku:

	Hodnota
Podíl vzorku p	0,3400
Velikost vz. ve skup. (N)	100,0000
Interval spolehlivosti	0,9500
Meze spolehlivosti:	
Pí (přesně):	
Dolní mez	0,2482
Horní mez	0,4415
Pí (přibližně):	
Dolní mez	0,2501
Horní mez	0,4423
Pí (původ.):	
Dolní mez	0,2472
Horní mez	0,4328

Zajímá nás výsledek uvedený v dolní části tabulky, tj. Pí (původ.). Zjišťujeme, že s pravděpodobností aspoň 0,95 se pravděpodobnost nákupu v internetových obchodech bude pohybovat v mezích 0,2472 až 0,4328.

**Příklad:** Kolik osob musíme vybrat, abychom podíl modrookých osob v populaci odhadli se spolehlivostí 90% a šířka intervalu spolehlivosti byla nanejvýš a) 0,06, b) 0,01?

**Řešení:**

Šířka  $100(1-\alpha)\%$  asymptotického empirického intervalu spolehlivosti pro parametr  $\vartheta$ :

$$h - d = m + \sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2} - \left( m - \sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2} \right) = 2\sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2}$$

$$\text{Požadujeme, aby } h - d \leq \Delta, \text{ tedy } 2\sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2} \leq \Delta. \text{ Odtud vyjádříme } n \geq \frac{4m(1-m)u_{1-\alpha/2}^2}{\Delta^2}.$$

Předpokládejme, že nemáme žádné předběžné informace o podílu modrookých osob v populaci. Musíme tedy zvolit takové  $m$ , aby šířka intervalu spolehlivosti byla maximální. Maximalizujeme výraz  $m(1-m) = m - m^2$ . Derivujeme podle  $m$  a položíme rovno 0:  $1 - 2m = 0 \Rightarrow m = \frac{1}{2}$ . V tomto případě volíme relativní četnost  $m = 0,5$ .

$$\text{ad a)} n \geq \frac{4m(1-m)u_{1-\alpha/2}^2}{\Delta^2} = \frac{4 \cdot 0,5 \cdot 0,5 \cdot u_{0,95}^2}{0,06^2} = \frac{4 \cdot 0,5 \cdot 0,5 \cdot 1,645^2}{0,06^2} = 751,67$$

Uvedenou podmítku tedy splníme, když vybereme aspoň 752 osob.

$$\text{ad b)} n \geq \frac{4m(1-m)u_{1-\alpha/2}^2}{\Delta^2} = \frac{4 \cdot 0,5 \cdot 0,5 \cdot u_{0,95}^2}{0,01^2} = \frac{4 \cdot 0,5 \cdot 0,5 \cdot 1,645^2}{0,01^2} = 27060,25$$

Chceme-li dosáhnout podstatně užšího intervalu spolehlivosti, musíme vybrat aspoň 27 061 osob.

**Modifikace:** Předpokládejme, že v populaci je nanejvýš 30% modrookých osob. Pak relativní četnost  $m = 0,3$ .

$$\text{ad a)} \quad n \geq \frac{4m(1-m)u_{1-\alpha/2}^2}{\Delta^2} = \frac{4 \cdot 0,3 \cdot 0,7 \cdot u_{0,95}^2}{0,06^2} = \frac{4 \cdot 0,3 \cdot 0,7 \cdot 1,645^2}{0,06^2} = 631,41$$

V tomto případě stačí vybrat 632 osob.

Ve srovnání s předešlým případem vidíme, že rozsah výběru skutečně klesl.

ad b)

$$n \geq \frac{4m(1-m)u_{1-\alpha/2}^2}{\Delta^2} = \frac{4 \cdot 0,3 \cdot 0,7 \cdot u_{0,95}^2}{0,01^2} = \frac{4 \cdot 0,3 \cdot 0,7 \cdot 1,645^2}{0,01^2} = 22730,61$$

V tomto případě musíme vybrat aspoň 22 731 osob.

## Testování hypotézy o parametru $\vartheta$

Nechť  $X_1, \dots, X_n$  je náhodný výběr z rozložení  $A(\vartheta)$  a nechť je splněna podmínka  $n\vartheta(1-\vartheta) > 9$ .

Na asymptotické hladině významnosti  $\alpha$  testujeme hypotézu

$H_0: \vartheta = c$  proti alternativě  $H_1: \vartheta \neq c$  (resp.  $H_1: \vartheta < c$  resp.  $H_1: \vartheta > c$ ).

Testovým kritériem je statistika  $T_0 = \frac{M - c}{\sqrt{\frac{c(1-c)}{n}}}$ , která v případě platnosti nulové hypotézy má asymptoticky rozložení  $N(0,1)$ .

Kritický obor má tvar  $W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$  (resp.  $W = (-\infty, -u_{1-\alpha})$  resp.  $W = (u_{1-\alpha}, \infty)$ ).

(Testování hypotézy o parametru  $\vartheta$  lze samozřejmě provést i pomocí 100(1- $\alpha$ )% asymptotického intervalu spolehlivosti nebo pomocí p-hodnoty.)

**Příklad:** Podél zmetků při výrobě určité součástky činí  $\vartheta = 0,01$ . Bylo náhodně vybráno 1000 výrobků a zjistilo se, že mezi nimi je 16 zmetků. Na asymptotické hladině významnosti 0,05 testujte hypotézu  $H_0: \vartheta = 0,01$  proti oboustranné alternativě  $H_1: \vartheta \neq 0,01$ .

### Řešení:

Zavedeme náhodné veličiny  $X_1, \dots, X_{1000}$ , přičemž  $X_i = 1$ , když i-tý výrobek byl zmetek a  $X_i = 0$  jinak,  $i = 1, \dots, 1000$ . Tyto náhodné veličiny tvoří náhodný výběr z rozložení  $A(\vartheta)$ .

Testujeme hypotézu  $H_0: \vartheta = 0,01$  proti alternativě  $H_1: \vartheta \neq 0,01$ .

$$\text{Známe: } n = 1000, m = \frac{16}{1000} = 0,016, c = 0,01, \alpha = 0,05, u_{1-\alpha/2} = u_{0,975} = 1,96$$

Ověření podmínky  $m\vartheta(1-\vartheta) > 9 : 1000 \cdot 0,01 \cdot 0,99 = 9,9 > 9$ .

#### a) Testování pomocí kritického oboru:

$$\text{Realizace testového kritéria: } t_0 = \frac{m - c}{\sqrt{\frac{c \cdot (1-c)}{n}}} = \frac{0,016 - 0,01}{\sqrt{\frac{0,01 \cdot 0,99}{1000}}} = 1,907.$$

Kritický obor:  $W = (-\infty, -u_{0,975}) \cup (u_{0,975}, \infty) = (-\infty, -1,96) \cup (1,96, \infty)$ . Protože  $1,907 \notin W$ ,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

#### b) Testování pomocí intervalu spolehlivosti

$$d = m - \sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2} = 0,016 - \sqrt{\frac{0,016 \cdot 0,984}{1000}} 1,96 = 0,0082$$

$$h = m + \sqrt{\frac{m(1-m)}{n}} u_{1-\alpha/2} = 0,016 + \sqrt{\frac{0,016 \cdot 0,984}{1000}} 1,96 = 0,0238$$

Protože číslo  $c = 0,01$  leží v intervalu 0,0082 až 0,0238,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

#### c) Testování pomocí p-hodnoty

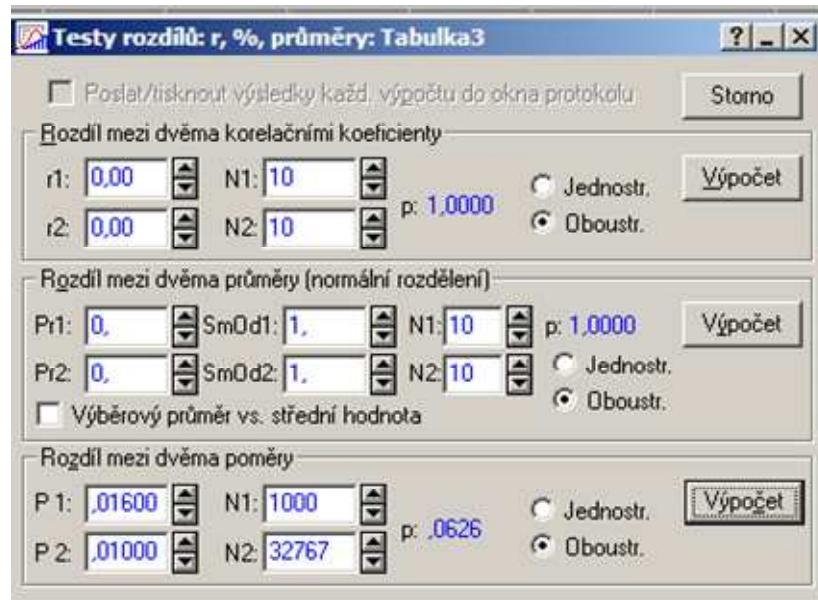
Protože testujeme nulovou hypotézu proti oboustranné alternativě, vypočteme p-hodnotu podle vzorce:

$$p = 2 \min\{ \Phi(1,907), 1 - \Phi(1,907) \} = 2 \min\{ 0,97104, 1 - 0,97104 \} = 0,05792.$$

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

### Výpočet pomocí systému STATISTICA (pouze přibližný):

Statistiky – Základní statistiky a tabulky – Testy rozdílů: r, %, průměry – OK – vybereme Rozdíl mezi dvěma poměry – do políčka P 1 napíšeme 0,016, do políčka N1 napíšeme 1000, do políčka P 2 napíšeme 0,01, do políčka N2 napíšeme 32767 (větší hodnotu systém neumožní) - Výpočet. Dostaneme p-hodnotu 0,0626, tedy nezamítáme nulovou hypotézu na hladině významnosti 0,05.



**Příklad:** Nový léčebný postup považujeme za úspěšný, pokud po jeho ukončení bude dosaženo zlepšení zdravotního stavu u alespoň 50% zúčastněných pacientů. Nová terapie byla vyzkoušena u 40 pacientů a ke zlepšení došlo u 24 osob, tj. u 60%. Je možné na asymptotické hladině významnosti 0,05 zamítнуть hypotézu, že tato terapie nedosahuje úspěšnosti aspoň 50%?

**Řešení:**

Zavedeme náhodné veličiny  $X_1, \dots, X_{40}$ , přičemž

$X_i = 1$ , když terapie u i-tého pacienta byla úspěšná a

$X_i = 0$  jinak,

$i = 1, \dots, 40$ .

Tyto náhodné veličiny tvoří náhodný výběr z rozložení  $A(\vartheta)$ .

Testujeme hypotézu  $H_0: \vartheta \leq 0,5$  proti pravostranné alternativě  $H_1: \vartheta > 0,5$ .

$$\text{Známe: } n = 40, m = \frac{24}{40} = 0,6, c = 0,5, \alpha = 0,05, u_{1-\alpha} = u_{0,95} = 1,645$$

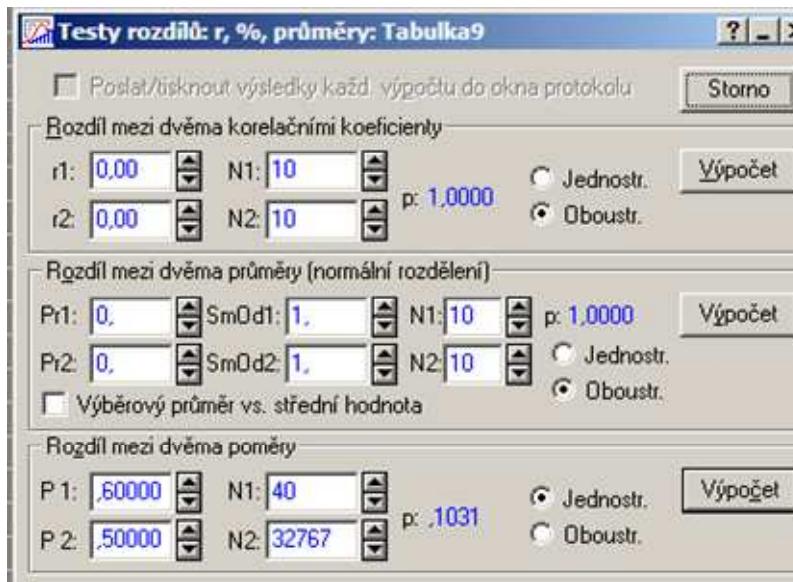
$$\text{Ověření podmínky: } n\vartheta(1-\vartheta) > 9 : 40 \cdot 0,6 \cdot 0,4 = 9,6 > 9.$$

$$\text{Realizace testového kritéria: } t_0 = \frac{m - c}{\sqrt{\frac{c \cdot (1-c)}{n}}} = \frac{0,6 - 0,5}{\sqrt{\frac{0,5 \cdot 0,5}{40}}} = 1,2649.$$

$$\text{Kritický obor: } W = \langle u_{1-\alpha}, \infty \rangle = \langle u_{0,95}, \infty \rangle = \langle 1,645, \infty \rangle.$$

Protože  $1,2649 \notin W$ ,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

## Výpočet pomocí systému STATISTICA:



Vypočtená p-hodnota jednostranného testu je 0,1031, tedy větší než asymptotická hladina významnosti 0,05.  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

**Případ dvou nezávislých výběrů z alternativních rozložení:** Provádíme opakovaně nezávisle  $n_1$ -krát jeden náhodný pokus a nezávisle na tom  $n_2$ -krát druhý náhodný pokus. V první sérii pokusů sledujeme nějaký jev, který v každém pokusu může nastat s pravděpodobností  $\vartheta_1$  a ve druhé sérii pokusů sledujeme nějaký jiný jev, jehož pravděpodobnost nastoupení je  $\vartheta_2$ . Parametry  $\vartheta_1$ ,  $\vartheta_2$  neznáme. Naším úkolem bude konstruovat interval spolehlivosti pro parametrickou funkci  $\vartheta_1 - \vartheta_2$  nebo testovat hypotézu o této parametrické funkci, a to pomocí dvou nezávislých náhodných výběrů z alternativních rozložení  $A(\vartheta_1)$ ,  $A(\vartheta_2)$ .

### Asymptotické rozložení statistiky odvozené ze dvou výběrových průměrů alternativních rozložení

Nechť  $X_{11}, \dots, X_{1n_1}$  je náhodný výběr z alternativního rozložení  $A(\vartheta_1)$  a  $X_{21}, \dots, X_{2n_2}$  je na něm nezávislý náhodný výběr alternativního rozložení  $A(\vartheta_2)$  a nechť jsou splněny podmínky  $n_1\vartheta_1(1-\vartheta_1) > 9$  a  $n_2\vartheta_2(1-\vartheta_2) > 9$ . Označme  $M_1, M_2$  výběrové průměry.

$$\text{Pak statistika } U = \frac{M_1 - M_2 - (\vartheta_1 - \vartheta_2)}{\sqrt{\frac{\vartheta_1(1-\vartheta_1)}{n_1} + \frac{\vartheta_2(1-\vartheta_2)}{n_2}}} \approx N(0,1).$$

**Vysvětlení:** Analogicky jako v případě jednoho náhodného výběru z alternativního rozložení.

### Vzorec pro meze 100(1- $\alpha$ )% asymptotického empirického intervalu spolehlivosti pro parametrickou funkci $\vartheta_1 - \vartheta_2$ .

Meze 100(1- $\alpha$ )% asymptotického empirického intervalu spolehlivosti pro  $\vartheta_1 - \vartheta_2$  jsou:

$$d = m_1 - m_2 - \sqrt{\frac{m_1(1-m_1)}{n_1} + \frac{m_2(1-m_2)}{n_2}} u_{1-\alpha/2}, \quad h = m_1 - m_2 + \sqrt{\frac{m_1(1-m_1)}{n_1} + \frac{m_2(1-m_2)}{n_2}} u_{1-\alpha/2}$$

**Vysvětlení:** Pokud rozptyl  $D(M_i) = \frac{\vartheta_i(1-\vartheta_i)}{n_i}$  nahradíme odhadem  $\frac{M_i(1-M_i)}{n_i}$ ,  $i = 1, 2$ , konvergence náhodné veličiny  $U$  k veličině s rozložením  $N(0,1)$  se neporuší. Tedy

$$\begin{aligned} \forall \vartheta_1 - \vartheta_2 \in \Xi : 1 - \alpha &\leq P\left(-u_{1-\alpha/2} < \frac{M_1 - M_2 - (\vartheta_1 - \vartheta_2)}{\sqrt{\frac{M_1(1-M_1)}{n_1} + \frac{M_2(1-M_2)}{n_2}}} < u_{1-\alpha/2}\right) = \\ &P(M_1 - M_2 - \sqrt{\frac{M_1(1-M_1)}{n_1} + \frac{M_2(1-M_2)}{n_2}} u_{1-\alpha/2} < \vartheta_1 - \vartheta_2 < M_1 - M_2 + \sqrt{\frac{M_1(1-M_1)}{n_1} + \frac{M_2(1-M_2)}{n_2}} u_{1-\alpha/2}) \end{aligned}$$

**Příklad:** Management supermarketu vyhlásil týden slev a sledoval, zda toto vyhlášení má vliv na podíl větších nákupů (nad 500 Kč). Na základě náhodného výběru 200 zákazníků v týdnu bez slev bylo zjištěno 97 velkých nákupů, zatímco v týdnu se slevou z 300 náhodně vybraných zákazníků učinilo velký nákup 162 zákazníků. Sestrojte 95% asymptotický interval spolehlivosti pro rozdíl pravděpodobností uskutečnění většího nákupu v týdnu bez slevy a v týdnu se slevou.

### Řešení:

Zavedeme náhodnou veličinu  $X_{1i}$ , která bude nabývat hodnoty 1, když v týdnu bez slevy i-tý náhodně vybraný zákazník uskuteční větší nákup a hodnoty 0 jinak,  $i = 1, \dots, 200$ . Náhodné veličiny  $X_{1,1}, \dots, X_{1,200}$  tvoří náhodný výběr z rozložení  $A(\vartheta_1)$ . Dále zavedeme náhodnou veličinu  $X_{2i}$ , která bude nabývat hodnoty 1, když v týdnu se slevou i-tý náhodně vybraný zákazník uskuteční větší nákup a hodnoty 0 jinak,  $i = 1, \dots, 300$ . Náhodné veličiny  $X_{2,1}, \dots, X_{2,300}$  tvoří náhodný výběr z rozložení  $A(\vartheta_2)$ .

$$n_1 = 200, n_2 = 300, m_1 = 97/200 = 0,485, m_2 = 162/300 = 0,54.$$

Ověření podmínek  $n_1 \vartheta_1 (1 - \vartheta_1) > 9$  a  $n_2 \vartheta_2 (1 - \vartheta_2) > 9$ : Parametry  $\vartheta_1$  a  $\vartheta_2$  neznáme, nahradíme je odhady  $m_1$  a  $m_2$ , tedy  $97.(1-97/200) = 49,955 > 9$ ,  $162.(1-162/300) = 74,52 > 9$ .

Meze  $100(1-\alpha)\%$  asymptotického empirického intervalu spolehlivosti pro parametrickou funkci  $\vartheta_1 - \vartheta_2$  jsou:

$$d = m_1 - m_2 - \sqrt{\frac{m_1(1-m_1)}{n_1} + \frac{m_2(1-m_2)}{n_2}} u_{1-\alpha/2} = \frac{97}{200} - \frac{162}{300} - \sqrt{\frac{\frac{97}{200}(1-\frac{97}{200})}{200} + \frac{\frac{162}{300}(1-\frac{162}{300})}{300}} 1,96 = -0,1443$$

$$h = m_1 - m_2 + \sqrt{\frac{m_1(1-m_1)}{n_1} + \frac{m_2(1-m_2)}{n_2}} u_{1-\alpha/2} = \frac{97}{200} - \frac{162}{300} + \sqrt{\frac{\frac{97}{200}(1-\frac{97}{200})}{200} + \frac{\frac{162}{300}(1-\frac{162}{300})}{300}} 1,96 = 0,0343$$

Zjistili jsme tedy, že s pravděpodobností přibližně 0,95:  $-0,1443 < \vartheta_1 - \vartheta_2 < 0,0343$ .

## Testování hypotézy o parametrické funkci $\vartheta_1 - \vartheta_2$

Nechť  $X_{11}, \dots, X_{1n_1}$  je náhodný výběr z alternativního rozložení  $A(\vartheta_1)$  a  $X_{21}, \dots, X_{2n_2}$  je na něm nezávislý náhodný výběr alternativního rozložení  $A(\vartheta_2)$  a nechť jsou splněny podmínky  $n_1\vartheta_1(1-\vartheta_1) > 9$  a  $n_2\vartheta_2(1-\vartheta_2) > 9$ . Na asymptotické hladině významnosti  $\alpha$  testujeme nulovou hypotézu  $H_0: \vartheta_1 - \vartheta_2 = c$  proti alternativě  $H_1: \vartheta_1 - \vartheta_2 \neq c$  (resp.  $H_1: \vartheta_1 - \vartheta_2 < c$  resp.  $H_1: \vartheta_1 - \vartheta_2 > c$ ).

Testovým kritériem je statistika

$$T_0 = \frac{M_1 - M_2 - c}{\sqrt{\frac{M_1(1-M_1)}{n_1} + \frac{M_2(1-M_2)}{n_2}}}, \text{ která v případě platnosti nulové hypotézy má asymptoticky rozložení } N(0,1).$$

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

(resp.  $W = (-\infty, -u_{1-\alpha})$  resp.  $W = (u_{1-\alpha}, \infty)$ ).

(Testování hypotézy o parametrické funkci  $\vartheta_1 - \vartheta_2$  lze provést též pomocí 100(1- $\alpha$ )% asymptotického intervalu spolehlivosti nebo pomocí p-hodnoty.)

### Poznámka: Postup při testování hypotézy $\vartheta_1 - \vartheta_2 = 0$

Je-li  $c = 0$ , pak označme  $M_* = \frac{n_1 M_1 + n_2 M_2}{n_1 + n_2}$  vážený průměr výběrových průměrů. Jako testová statistika slouží

$$T_0 = \frac{M_1 - M_2}{\sqrt{M_* (1 - M_*) \left( \frac{1}{n_1} + \frac{1}{n_2} \right)}}, \text{ která v případě platnosti nulové hypotézy má asymptoticky rozložení } N(0,1).$$

Kritický obor má tvar  $W = (-\infty, -u_{1-\alpha/2}) \cup (u_{1-\alpha/2}, \infty)$  (resp.  $W = (-\infty, -u_{1-\alpha})$  resp.  $W = (u_{1-\alpha}, \infty)$ ).

Testová statistika  $T_0$  vznikne standardizací statistiky  $M_1 - M_2$ , kde neznámé parametry  $\vartheta_1, \vartheta_2$  nahradíme společným odhadem  $M_*$ .

**Příklad:** Pro údaje z příkladu o slevách v supermarketu testujte na asymptotické hladině významnosti 0,05 hypotézu, že týden se slevami nezvýší pravděpodobnost uskutečnění většího nákupu.

**Řešení:**

Testujeme hypotézu  $H_0: \vartheta_1 - \vartheta_2 = 0$  proti levostranné alternativě  $H_1: \vartheta_1 - \vartheta_2 < 0$  na asymptotické hladině významnosti 0,05.

$$n_1 = 200, n_2 = 300, m_1 = 97/200, m_2 = 162/300, m_* = (97 + 162)/500 = 0,518.$$

Podmínky dobré approximace byly ověřeny v předešlém příkladu.

**Testování pomocí intervalu spolehlivosti:**

Pro levostrannou alternativu používáme pravostranný interval spolehlivosti:

$$h = m_1 - m_2 + \sqrt{\frac{m_1(1-m_1)}{n_1} + \frac{m_2(1-m_2)}{n_2}} u_{1-\alpha} = \frac{97}{200} - \frac{162}{300} + \sqrt{\frac{\frac{97}{200}(1-\frac{97}{200})}{200} + \frac{\frac{162}{300}(1-\frac{162}{300})}{300}} 1,645 = 0,02$$

Protože číslo  $c = 0$  je obsaženo v intervalu  $(-\infty; 0,02)$ ,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

**Testování pomocí kritického oboru:**

Realizace testového kritéria:

$$t_0 = \frac{m_1 - m_2}{\sqrt{m_*(1-m_*)(\frac{1}{n_1} + \frac{1}{n_2})}} = \frac{\frac{97}{200} - \frac{162}{300}}{\sqrt{0,518(1-0,518)(\frac{1}{200} + \frac{1}{300})}} = -1,2058.$$

Kritický obor je  $W = (-\infty, -u_{1-\alpha}) = (-\infty, -u_{0,95}) = (-\infty, -1,645)$ . Protože testové kritérium nepatří do kritického oboru,  $H_0$  nezamítáme na asymptotické hladině významnosti 0,05.

**Testování pomocí p-hodnoty:**

Pro levostrannou alternativu se p-hodnota počítá podle vzorce  $p = P(T_0 \leq t_0)$ :

$$p = P(T_0 \leq -1,2058) = \Phi(-1,2058) = 1 - \Phi(1,2058) = 1 - 0,8861 = 0,1139$$

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

## Výpočet pomocí systému STATISTICA:

Statistiky – Základní statistiky a tabulky – Testy rozdílů: r, %, průměry – OK – vybereme Rozdíl mezi dvěma poměry – do políčka P 1 napíšeme 0,485, do políčka N1 napíšeme 200, do políčka P 2 napíšeme 0,54, do políčka N2 napíšeme 300 – zaškrtneme Jednostr. - Výpočet. Dostaneme p-hodnotu 0,1142, tedy nezamítáme nulovou hypotézu na hladině významnosti 0,05.

Testy rozdílů: r, %, průměry: tram\_bus

Poslat/tisknout výsledky každ. výpočtu do okna protokolu

Rozdíl mezi dvěma korelačními koeficienty

r1:  N1:  p:   Jednostr.

r2:  N2:   Oboustr.

Rozdíl mezi dvěma průměry (normální rozdělení)

Pr1:  SmOd1:  N1:  p:

Pr2:  SmOd2:  N2:   Jednostr.  Oboustr.

Výběrový průměr vs. střední hodnota

Rozdíl mezi dvěma poměry

P 1:  N1:  p:   Jednostr.

P 2:  N2:   Oboustr.

Test hypotézy o shodě podílů  $\vartheta_1$  a  $\vartheta_2$ :

Systém STATISTICA počítá jednostrannou p-hodnotu (ozn. *softw. p*) jako  $P(T_0 > |t_0|)$ , proto kromě typu alternativy záleží i na znaménku realizace testového kritéria. Skutečnou p-hodnotu (ozn. *skut. p*) tedy počítáme podle následující tabulky:

$\textcircled{1} \quad t_0 > 0$ , levostranná alternativa $\textit{skut. p} = \textit{softw. p}$	$\textcircled{3} \quad t_0 < 0$ , levostranná alternativa $\textit{skut. p} = 1 - \textit{softw. p}$
$\textcircled{2} \quad t_0 > 0$ , pravostranná alternativa $\textit{skut. p} = 1 - \textit{softw. p}$	$\textcircled{4} \quad t_0 < 0$ , pravostranná alternativa $\textit{skut. p} = \textit{softw. p}$