

Výberové skúmanie

Štatistická indukcia



Osnova prednášky

- Cieľ výberového skúmania
- Druhy výberov
- 2 úlohy výberového skúmania
- Intervaly spoľahlivosti
 - pre strednú hodnotu základného súboru
 - pre relatívnu početnosť základného súboru

Typy súborov

- **základný súbor** (rozsah N prvkov – štatistických jednotiek alebo nekonečný)
- **výberový súbor** (rozsah n prvkov – štatistických jednotiek)
 - je vytvorený výberom zo základného súboru,
 - reprezentatívnosť! – každá n -tica náhodných jednotiek má rovnakú pravdepodobnosť, že bude vybraná

Cieľ výberového zisťovania

- na základe informácií, získaných vo výberovom súbore urobiť úsudky o stave a správaní sa javu (javov) v celom základnom súbore.

Druhy výberov

technika výberu závisí od cieľa zisťovania

náhodný výber

- jednoduchý (prstý) - losovanie
- oblastný – do skupín, náhodný výber v skupinách
- skupinový – náhodný výber skupín, všetky prvky
- systematický – náhodne prvá jednotka, krok
- viacstupňový – náhodne skupiny, náhodne jednotky

nenáhodný výber

- zámerný (expertný) – názor odborníka
- konvenčný – podľa zoznamu, prvých napr. 10
- kvótny - kvóty
- samovýber – ankety v časopisoch
- náhodilý – náhodné stretnutie

Náhodný výber

s rozsahom n je n -tica nezávislých náhodných premenných $\mathbf{X} = (X_1, X_2, \dots, X_n)^T$ s rovnakým rozdelením.

Zistené (pozorované) údaje $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$, hodnoty náhodných premenných, sú **realizáciou náhodného výberu**.

Z výberových dát sa počítajú **výberové charakteristiky** (tzv. **štatistiky**), ktoré sú tiež náhodnými premennými: výberový priemer, výberová smerodajná odchýlka, výberová relatívna početnosť a iné.

Niektoré výberové štatistiky a parametre základného súboru

odhad parametra – náhodná premenná $\hat{\theta}(X)$	parameter základného súboru θ
\bar{X} - výberový priemer	μ - stredná hodnota základného súboru
S_1^2 - výberový rozptyl	σ^2 - rozptyl základného súboru
S_1 - výberová smerodajná odchýlka	σ - smerodajná odchýlka základného súboru
P - výberový podiel	π - relatívna početnosť základného súboru
b - výberový regresný koeficient	β - regresný koeficient základného súboru
r - výberový koeficient korelácie	ρ - koeficient korelácie základného súboru

Získané údaje z výberového súboru je možné využiť

- pre **odhad parametra základného súboru** a to dvoma spôsobmi:
 - bodový odhad,
 - intervalový odhad (prostredníctvom konštrukcie intervalu spoľahlivosti),
- na **testovanie štatistických hypotéz**, teda predpokladov o hodnotách parametrov základného súboru, prípadne viacerých základných súborov alebo o ich rozdelení.

Vlastnosti odhadov

- konzistentnosť: $\lim_{n \rightarrow \infty} P(|\hat{\theta}_n(X) - \theta| < \varepsilon) = 1$ pre $\varepsilon > 0$
- neskreslenosť (nevychýlenosť): $E[\hat{\theta}_n(X)] = \theta$
- asymptotická neskreslenosť: $\lim_{n \rightarrow \infty} (E[\hat{\theta}_n(X)] - \theta) = 0$
- výdatnosť, efektívnosť – zo všetkých odhadov najmenší rozptyl

Intervaly spoľahlivosti pre parametre základného súboru

Interval spoľahlivosti pre strednú hodnotu (Confidence Interval For Mean)

$$U = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N[0;1]$$

- $E(\bar{X}) = \mu$
- $D(\bar{X}) = \sigma^2/n$

$$P(-u_{1-\frac{\alpha}{2}} \leq U \leq u_{1-\frac{\alpha}{2}}) = 1 - \alpha$$

$$P\left(\bar{X} - u_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \leq \mu \leq \bar{X} + u_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

$$\left(\bar{X} - u_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}; \bar{X} + u_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}\right)$$

$$\Delta = u_{1-\alpha/2} \cdot \frac{\sigma}{\sqrt{n}}$$

je **prípustná chyba odhadu**, z ktorej vyplýva, že rozsah výberového súboru $n = \frac{u_{1-\alpha/2}^2 \cdot \sigma^2}{\Delta^2}$

$1 - \alpha$ je **spoľahlivosť odhadu** t.j. pravdepodobnosť, že interval pokrýva skutočnú hodnotu parametra základného súboru. t. z. $(1 - \alpha)$ – percent intervalov skonštruovaných na základe náhodných výberov s rovnakým rozsahom, pokrýva skutočnú hodnotu parametra

α je **riziko odhadu**, t.j. pravdepodobnosť, že interval spoľahlivosti nepokrýva skutočnú hodnotu parametra základného súboru

- ak σ ZS nepoznáme

$$T = \frac{\bar{X} - \mu}{\frac{S_1}{\sqrt{n}}} \sim t(n-1)$$

$$P(-t_{1-\frac{\alpha}{2};n-1} \leq T \leq t_{1-\frac{\alpha}{2};n-1}) = 1 - \alpha$$

$$P\left(\bar{X} - t_{1-\frac{\alpha}{2};n-1} \cdot \frac{S_1}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{1-\frac{\alpha}{2};n-1} \cdot \frac{S_1}{\sqrt{n}}\right) = 1 - \alpha$$

$$\left(\bar{X} - t_{1-\frac{\alpha}{2};n-1} \cdot \frac{S_1}{\sqrt{n}}; \bar{X} + t_{1-\frac{\alpha}{2};n-1} \cdot \frac{S_1}{\sqrt{n}}\right)$$


Jednostranné intervaly spoľahlivosti pre **strednú hodnotu:**

■ ľavostranné	■ pravostranné
$\left(\bar{X} - u_{1-\alpha} \cdot \frac{\sigma}{\sqrt{n}}; +\infty\right)$	$\left(-\infty; \bar{X} + u_{1-\alpha} \cdot \frac{\sigma}{\sqrt{n}}\right)$
$\left(\bar{X} - t_{1-\alpha;n-1} \cdot \frac{S_1}{\sqrt{n}}; +\infty\right)$	$\left(-\infty; \bar{X} + t_{1-\alpha;n-1} \cdot \frac{S_1}{\sqrt{n}}\right)$

Pozn.: prevodník na hľadanie kritickej hodnoty t – rozdelenia:

$t_{1-\frac{\alpha}{2};v}$ sa v Exceli hľadá ako $t_{\alpha,v}$

$t_{1-\alpha,v}$ sa v Exceli hľadá ako $t_{2\alpha,v}$



Interval spoľahlivosti pre **relatívnu početnosť**

Ak pravdepodobnosť nastatia javu A v základnom súbore je π , potom náhodná premenná

$$P = \frac{X}{n}$$

kde X je počet nastatia javu A má binomické rozdelenie, pričom platí $E(X) = n\pi$ a $D(X) = n\pi(1-\pi)$, ak platí

$n > \frac{9}{\pi \cdot (1-\pi)}$, môžeme uvažovať **normálne** rozdelenie tejto

náhodnej premennej a vytvoriť normovanú premennú

v tvare

$$U = \frac{P - \pi}{\sqrt{\frac{\pi(1-\pi)}{n}}}$$

Keďže platí

$$P(-u_{1-\frac{\alpha}{2}} \leq U \leq u_{1-\frac{\alpha}{2}}) = 1 - \alpha$$

potom interval spoľahlivosti pre **relatívnu početnosť** základného súboru má za podmienky

$$n > \frac{9}{p \cdot (1-p)}$$

nasledovný tvar:

$$\left(p - u_{1-\frac{\alpha}{2}} \sqrt{\frac{p \cdot (1-p)}{n}}; p + u_{1-\frac{\alpha}{2}} \sqrt{\frac{p \cdot (1-p)}{n}}\right)$$

resp. v prípade jednostranných intervalových odhadov

$$\left(-\infty; p + u_{1-\alpha} \sqrt{\frac{p \cdot (1-p)}{n}}\right) \text{ a } \left(p - u_{1-\alpha} \sqrt{\frac{p \cdot (1-p)}{n}}; +\infty\right)$$

Prípustná chyba odhadu

v prípade obojstranného **intervalu spoľahlivosti pre relatívnu početnosť** má tvar:

$$\Delta = u_{1-\frac{\alpha}{2}} \sqrt{\frac{p \cdot (1-p)}{n}}$$