

# 1 10-Analýza rozptylu jednoduchého třídění, ANOVA, Jednofaktorová analýza rozptylu

## 1.1 Nová látka

### 1.1.1 Testování homogenity rozptylů u $r$ náhodných výběrů

- homogenita (stejnorodost) rozptylů u většího množství náhodných výběrů je důležitým předpokladem, který musí být splněn, abychom mohli provést tzv. ANOVU - jednofaktorovou analýzu rozptylu (viz dále).
- předpokládejme, že máme  $r \geq 2$  náhodných výběrů
- testujeme nulovou hypotézu  $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_r^2 = \sigma^2$  oproti alternativní hypotéze  $H_1$  : alespoň jedna dvojice rozptylů se liší
- testy rozptylu
  1. Levenův test
    - `levene.test(D,K)` knihovna `lawstat` ;  $D \dots$  vektor dat,  $K \dots$  typ skupiny
    - je založen na analýze rozptylu absolutních hodnot centrovaných pozorování
    - výpočet je založen na 'hraní si' s odhady středních hodnot
  2. Brownův-Forsytův test
    - je modifikací Levenova testu
    - je založen na mediánu (namísto střední hodnoty)
    - při větších rozsazích náhodných výběrů ( $n_i > 20$ ) jej lze použít i na data, které nejsou z normálního rozdělení
    - v Rku ho používat nebudeme, ale je dobré, abyste o něm aspoň slyšeli
  3. Bartlettův test
    - `bartlett.test(D,K)` knihovna `stat`
    - můžeme jej použít, pouze pokud jsou rozsahy všech výběrů větší než 6
    - nelze jej použít, pokud je více náhodných výběrů z výrazně nenormálního rozložení

### 1.1.2 ANOVA - Jednofaktorová analýza rozptylu

- zkoumá závislost intervalové/poměrové proměnné  $X$  na nominální proměnné  $A$ , které má alespoň dvě varianty
- $A \dots$  faktor; varianty  $A \dots$  úrovně faktoru
- závislost  $X$  na  $A$  se projeví tím, že existuje statisticky významný rozdíl v průměrech proměnné  $X$  v náhodných výběrech, které vznikly tříděním podle variant proměnné  $A$ .
- motivační příklady
  - má metoda výuky (faktor  $A$ ) vliv na počet bodů (intervalová proměnná  $X$ ) dosažených studenty v závěrečném testu?

- má typ potravy pračlověka ( $A$ ) vliv na šířku stoliček ( $X$ )?
- má způsob života ( $A$ : na stromu-šplh; na zemi - šplhá málo) vliv na intenzitu svalových úponů na ruku ( $X$ )?
- má pohlaví ( $A$ ) vliv na hmotnost člověka ( $X$ ), nebo na šířku očních ( $X$ )?

• trocha matematiky

- předpokládáme, že faktor  $A$  má  $r \geq 2$  úrovní  $A_1, \dots, A_r$ , přičemž  $i$ -té úrovni odpovídá  $n_i$  pozorování  $X_{i1}, \dots, X_{in_i}$ . Tato pozorování tvoří náhodný výběr z  $N(\mu_i, \sigma^2), i = 1, \dots, r$ . Celkový počet pozorování je  $n = \sum_{i=1}^r n_i$ . Jednotlivé náhodné výběry jsou stochasticky nezávislé.
- !!! Před samotnou ANOVOU musíme vždy ověřit předpoklady normality všech výběrů ( $r$  testů) a homogenity rozptylů (1 hromadný test)
- Tečková anotace

- \* součet hodnot v  $i$ -tém výběru

$$X_{i.} = \sum_{j=1}^{n_i} X_{ij}$$

- \* výběrový průměr v  $i$ -tém výběru

$$M_{i.} = \frac{1}{n_i} X_{i.}$$

- klasický aritmetický průměr dat z  $i$ -té skupiny, jen trochu jinak zapsaný

- \* součet hodnot všech výběrů

$$X_{..} = \sum_{i=1}^r \sum_{j=1}^{n_i} X_{ij}$$

- \* celkový průměr všech  $r$  výběrů

$$M_{..} = \frac{1}{n} X_{..}$$

- klasický aritmetický průměr všech dat

- \* celkový součet čtverců

$$S_T = \sum_{i=1}^r \sum_{j=1}^{n_i} (X_{ij} - M_{..})^2$$

- charakterizuje variabilitu jednotlivých pozorování kolem celkového průměru
- stejný princip jako výběrový rozptyl, akorát ho nedělíme počtem pozorování
- má počet stupňů volnosti  $f_T = n - 1$

- \* skupinový součet čtverců

$$S_A = \sum_{i=1}^r n_i (M_{i.} - M_{..})^2$$

- charakterizuje variabilitu mezi jednotlivými náhodnými výběry
- má počet stupňů volnosti  $f_A = r - 1$

\* reziduální součet čtverců

$$S_E = \sum_{i=1}^r \sum_{j=1}^{n_i} (X_{ij} - M_i.)^2$$

- charakterizuje variabilitu uvnitř jednotlivých výběrů - má počet stupňů volnosti  $f_E = n - r$

- lze dokázat  $S_T = S_A + S_E$ .

### 1.1.3 Testování hypotéz o shodě středních hodnot

- na hladině významnosti  $\alpha$  testujeme nulovou hypotézu, která tvrdí že všechny střední hodnoty jsou stejné  $H_0 : \mu_1 = \dots = \mu_r$ , proti alternativní hypotéze  $H_1 : \text{Alespoň jedna dvojice středních hodnot se významně liší.}$
- jiná definice nulové a alternativní hypotézy (z pohledu faktoru  $A$ ):  $H_0$ : Vliv faktoru  $A$  není významný;  $H_1$ : Vliv faktoru  $A$  je významný.
- Testovací statistika má tvar

$$F_A = \frac{S_A/f_A}{S_E/f_E} \sim F(r-1, n-r). \quad (1)$$

- $H_0$  zamítáme na hladině významnosti  $\alpha$ , pokud  $F_A \in \langle F_{1-\alpha}(r-1, n-r), \infty \rangle$
- případně  $H_0$  zamítáme na hladině významnosti  $\alpha$ , pokud  $p$ -hodnota  $< \alpha$  (testování  $H_0$  přes  $p$ -hodnotu jsme na hodině nedělali).
- výsledky výpočtů lze zapsat do přehledné tabulky:

Zdroj variability	součet čtverců	stupně volnosti	průměrný čtverec	$F_A$
skupiny	$S_A$	$f_A = r - 1$	$S_A/f_A$	$\frac{S_A/f_A}{S_E/f_E}$
reziduální	$S_E$	$f_E = n - r$	$S_E/f_E$	-
celkový	$S_T$	$f_T = n - 1$	-	-

### 1.1.4 Post-hoc metody mnohonásobného porovnávání

- zamítneme-li nulovou hypotézu o shodě středních hodnot, chceme zjistit, která dvojice středních hodnot se významně liší na hladině významnosti  $\alpha$
- 2 metody: *Tukeyova*, *Scheffého*
- Tukeyova metoda
  - \* používá se, mají-li všechny výběry týž rozsah (tento rozsah značíme  $p$ )
  - \* rovnost středních hodnot  $\mu_l = \mu_k$  zamítneme na hladině významnosti  $\alpha$ , pokud

$$|M_k. - M_l.| \geq q_{1-\alpha}(r, n-r) \frac{S_*}{\sqrt{p}}, \quad (2)$$

kde kvantily  $q_{1-\alpha}$  najdeme ve statistických tabulkách a  $S_*$  je z minulé hodiny známý vážený průměr výběrových rozptylů. Lze jej ale zjednodušeně vypočítat podle vzorce  $S_*^2 = \frac{S_E}{f_E}$ .

\* existuje i modifikace Tukeyovy metody pro nesterjné rozsahy výběřů tzv. *Tukey HSD metoda*

– Scheffého metoda

\* používá se, pokud nejsou rozsahy všech výběřů stejné

\* rovnost středních hodnot  $\mu_k$  a  $\mu_l$  zamítneme na hladině významnosti  $\alpha$ , když

$$|M_k. - M_l.| \geq S_* \sqrt{(r-1) \left( \frac{1}{n_k} + \frac{1}{n_l} \right) F_{1-\alpha}(r-1, n-r)}. \quad (3)$$

\*  $S_*^2 = \frac{S_E}{f_E}$

\* metody mnohonásobného porovnávání jsou slabší, než ANOVA, proto se může stát, že ANOVOU zamítneme  $H_0$  o shodě středních hodnot ale metody mnohonásobného porovnávání u žádné dvojice významný rozdíl nenajdou.

\* dochází tomu tehdy, když p-hodnota pro ANOVU je jen o málo nižší než zvolená hladina významnosti

• POSTUP TESTOVÁNÍ ANOVY:

1. ověření normality

– Q-Q plot + test (Shapiro, Lillie, Ad)

– slabé porušení nevadí, anova na to není příliš citlivá

2. ověření rozptylu

– krabicový graf - je šířka krabic stejná?; + test (Levenův, Bartlettův)

– na slabé porušení homogenity rozptylu není anova příliš citlivá

3. testování shody středních hodnot

4. dojde-li k zamítnutí  $H_0$  o shodě středních hodnot, použijeme *post-hoc metody* (Tukeyova, Scheffého)

• Zajímavost k testování homogenity rozptylů:

Parametr  $\sigma^2$  není znám a je třeba testovat hypotézu  $H_0 : \mu_1 = \dots = \mu_r$ . Na první pohled by se zdálo, že tento problém lze snadno převést na testování dvou nezávislých výběřů, a to tak, že vytvoříme dvojice souborů a na každou dvojici aplikujeme dvouvýběřový t-test na hladině významnosti  $\alpha$ . Jestliže alespoň jedna dvojice dá signifikantní výsledek (tedy zamítáme hypotézu o shodnosti středních hodnot vybrané dvojice), zdá se, že můžeme zamítnout hypotézu  $H_0$ . A současně hned vidíme, které dvojice se od sebe signifikantně liší. Tento postup však nesplňuje podmínku, že pravděpodobnost chyby prvního druhu má být  $\alpha$ . Je-li totiž nulová hypotéza správná, pak každý t-test dá signifikantní výsledek, tj. zamítne hypotézu o shodě středních hodnot, s pravděpodobností  $\alpha$ . My však chceme  $H_0$  zamítnout, když alespoň jeden ze všech testů dá signifikantní výsledek. Takže pravděpodobnost zamítnutí  $H_0$ , je-li správná, bude při  $I \geq 3$  větší než  $\alpha$ .