

## 9 Jednofaktorová analýza rozptylu – ANOVA

### 9.1 Testování normality

- Shapirův-Wilkův test ... `shapiro.test()`
- Lillie-Forsův test ... `lillie.test()`
- Anderson-Darlingův test ... `ad.test()`,

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

- máme  $r \geq 2$  náhodných výběrů
- $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_r^2 = \sigma^2$
- $H_1$  : alespoň jedna dvojice rozptylů se liší
  1. Levenův test
    - testovací statistika založena na odhadech středních hodnot
    - `levene.test(y, group, location='mean')` knihovna `lawstat`
  2. Brownův-Forsytův test
    - testovací statistika založena na mediánech
    - používáme, když výběry nejsou normálně rozdělené, ale rozsahy výběrů  $n_i > 20$
    - `levene.test(y, group, location='median')` z knihovny `lawstat`
  3. Bartlettův test
    - `bartlett.test(y, g)` knihovna `stat`
    - používáme, pokud jsou rozsahy všech výběrů  $\geq 6$

ANOVA funguje dobře i při mírném porušení předpokladu normality nebo shody rozptylů.

### 9.3 ANOVA - Jednofaktorová analýza rozptylu

- zkoumá závislost intervalové proměnné  $X$  na nominální proměnné  $A$
- $A$  ... faktor; varianty  $A$  ... úrovně faktoru  $A$
- Má typ potravy pračlověka ( $A$ ) vliv na šířku stoliček ( $X$ )?
- Faktor  $A$  má  $r \geq 2$  úrovně  $A_1, \dots, A_r$ , přičemž  $i$ -té úrovni odpovídá  $n_i$  pozorování  $X_{i1}, \dots, X_{in_i}$ . Každý výběr  $A_i \sim N(\mu_i, \sigma^2)$ .
- důležité pojmy
  - $\mathbf{n} = \sum_{i=1}^r n_i$  ... celkový počet pozorování,  $\mathbf{r}$  ... počet úrovní faktoru  $A$
  - **celkový součet čtverců  $S_T$** 
    - \* charakterizuje variabilitu jednotlivých pozorování kolem celkového průměru
    - \* počet stupňů volnosti:  $\mathbf{f}_T = \mathbf{n} - \mathbf{1}$

- skupinový součet čtverců  $S_A$ 
  - \* charakterizuje variabilitu mezi jednotlivými náhodnými výběry
  - \* počet stupňů volnosti:  $f_A = r - 1$
- reziduální součet čtverců  $S_E$ 
  - \* charakterizuje variabilitu uvnitř jednotlivých výběrů
  - \* počet stupňů volnosti:  $f_E = n - r$
- $S_T = S_A + S_E$ .
- $f_T = f_A + f_E$ .

### Testování hypotézy o shodě středních hodnot

- $H_0 : \mu_1 = \dots = \mu_r$ ; střední hodnoty všech výběrů jsou stejné
- $H_1 : \mu_i \neq \mu_j$  pro nějaké  $i, j$ ; alespoň jedna dvojice středních hodnot se liší.
- Testovací statistika

$$T_0 = F_A = \frac{S_A/f_A}{S_E/f_E} \sim F(r - 1, n - r).$$

- kritický obor  $W = \langle F_{1-\alpha}(r - 1, n - r), \infty \rangle$
- $p$ -hodnota =  $\Pr(T_0 > t_0) = 1 - \text{pf}(F_A, r-1, n-r) = 1 - \text{pf}(F_A, f_A, f_E)$
- přehledná tabulka výpočtů:

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

## 9.4 Post-hoc metody mnohonásobného porovnávání

- zamítneme-li nulovou hypotézu o shodě středních hodnot, chceme zjistit, která dvojice středních hodnot se od sebe významně liší
- Scheffého metoda
  - vhodná i v případě, že rozsahy všech výběrů nejsou stejné
  - hypotézu  $H_0 : \mu_k = \mu_l$  o rovnosti středních hodnot zamítneme na hl. významnosti  $\alpha$ , když

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

- funkce `Scheffe(X, group, names, alpha)` z RSkriptu AS-funkce.R.
- metody mnohonásobného porovnávání jsou slabší než ANOVA. Může se stát, že ANOVA zamítne  $H_0$  o shodě středních hodnot ale Scheffého metoda u žádné dvojice významný rozdíl nenajde.