

# 11 Analýza rozptylu jednoduchého třídění, ANOVA, Jednofaktorová analýza rozptylu

## Testování normality

- Normalita = první předpoklad k provedení ANOVY
- testy normality
  - Shapirův-Wilkův ... `shapiro.test()`
  - Lillie-Forsův ... `lillie.test()`
  - Anderson-Darlingův test ... `ad.test()`,

## Testování homogeneity rozptylů u $r$ náhodných výběrů

- homogenita = stejnorodost rozptylů
  - druhý předpoklad k provedení ANOVY
  - máme  $r \geq 2$  náhodných výběrů
  - testujeme  $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_r^2 = \sigma^2$  oproti  $H_1$  : alespoň jedna dvojice rozptylů se liší
1. Levenův test
    - testovací statistika založena na odhadech středních hodnot
    - `levene.test(y, group, location='mean')` knihovna `lawstat`
      - \* `y` ... vektor dat
      - \* `group` ... typ skupiny
      - \* `location='mean'`
  2. Brownův-Forsytův test
    - je modifikací Levenova testu
    - testovací statistika založena na mediánech
    - → při větších rozsazích náhodných výběrů ( $n_i > 20$ ) jej lze použít i na data, která nejsou z normálního rozdělení
    - `levene.test(y, group, location='median')` z knihovny `lawstat`
      - \* `y` ... vektor dat
      - \* `group` ... typ skupiny
      - \* `location='median'`
  3. Bartlettův test
    - `bartlett.test(y, g)` knihovna `stat`
    - používáme, pouze pokud jsou rozsahy všech výběrů  $\geq 6$

## ANOVA - Jednofaktorová analýza rozptylu

- zkoumá závislost intervalové proměnné  $X$  na nominální proměnné  $A$
- $A \dots faktor$ ; varianty  $A \dots$  úrovně faktoru
- motivační příklady
  - má metoda výuky ( $A$ ) vliv na počet bodů ( $X$ ) v závěrečném testu?
  - má typ potravy pračlověka ( $A$ ) vliv na šířku stoliček ( $X$ )?
- trocha matematiky
  - předpokládáme, že faktor  $A$  má  $r \geq 2$  úrovní  $A_1, \dots, A_r$ , přičemž  $i$ -té úrovni odpovídá  $n_i$  pozorování  $X_{i1}, \dots, X_{in_i}$ . Každý výběr  $A_i \sim N(\mu_i, \sigma^2)$ .
  - Celkový počet pozorování je  $n = \sum_{i=1}^r n_i$ .
  - Tečková anotace
    - \* součet hodnot v  $i$ -tém výběru
    - $$X_{i\cdot} = \sum_{j=1}^{n_i} X_{ij}$$
    - \* výběrový průměr v  $i$ -tém výběru
    - $$M_{i\cdot} = \frac{1}{n_i} X_{i\cdot}$$
    - klasický aritmetický průměr dat z  $i$ -té skupiny
    - \* součet hodnot všech výběrů
    - $$X_{\cdot\cdot} = \sum_{i=1}^r \sum_{j=1}^{n_i} X_{ij}$$
    - \* celkový průměr všech  $r$  výběrů
    - $$M_{\cdot\cdot} = \frac{1}{n} X_{\cdot\cdot}$$
    - klasický aritmetický průměr všech dat
    - \* celkový součet čtverců
    - $$S_T = \sum_{i=1}^r \sum_{j=1}^{n_i} (X_{ij} - M_{\cdot\cdot})^2$$
    - charakterizuje variabilitu jednotlivých pozorování kolem celkového průměru
    - počet stupňů volnosti:  $f_T = n - 1$
    - \* skupinový součet čtverců
    - $$S_A = \sum_{i=1}^r n_i (M_{i\cdot} - M_{\cdot\cdot})^2$$
    - charakterizuje variabilitu mezi jednotlivými náhodnými výběry
    - počet stupňů volnosti:  $f_A = r - 1$

- \* reziduální součet čtverců

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

- charakterizuje variabilitu uvnitř jednotlivých výběrů

- počet stupňů volnosti:  $f_E = n - r$

- \*  $S_T = S_A + S_E$ .

### Testování hypotéz 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 má tvar

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

- $F_A \in \langle F_{1-\alpha}(r-1, n-r), \infty \rangle \rightarrow H_0$  zamítáme na hl. význ.  $\alpha$
- nebo:  $p$ -hodnota <  $\alpha \rightarrow H_0$  zamítáme na hl. význ.  $\alpha$
- přehledná tabulka výpočtů:

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	$S_T$	$f_T = n - 1$	-	-

### 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
  - rovnost středních hodnot  $\mu_k$  a  $\mu_l$  zamítne na hladině významnosti  $\alpha$ , když

$$|M_{k\cdot} - M_{l\cdot}| \geq S_* \sqrt{(r-1) \left( \frac{1}{n_k} + \frac{1}{n_l} \right) F_{1-\alpha}(r-1, n-r)}.$$

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

- funkce `Scheffe(X, group, names, alpha)` z RSkriptu `AS-funkce.R`.

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

- POSTUP TESTOVÁNÍ ANOVY:
  1. ověření normality
  2. ověření rozptylu
  3. testování shody středních hodnot
  4. dojde-li k zamítnutí  $H_0$  o shodě středních hodnot, použijeme *post-hoc metody*
- Poznámka: Mírné porušení normality nebo shody rozptylů ANOVĚ zas tak moc nevadí