

## Asymptotické testy o stredných hodnotách

Homogenita a nehomogenita rozptylov

# Lineárne štatistické modely II

## Modely analýzy rozptylu

Stanislav Katina<sup>1</sup>

<sup>1</sup>Ústav matematiky a statistiky  
Přírodovědecká fakulta  
Masarykova univerzita

jarný semester 2016  
Verzia 1. júna 2016

Nech  $Y_{ji} \sim N(\mu_j, \sigma_j^2)$ , kde  $j = 1, 2, \dots, J$  a  $i = 1, 2, \dots, n_j$ , sú nezávislé náhodné premenné. Budeme rozlišovať dve situácie

1.  $Y_{ji} \sim N(\mu_j, \sigma_j^2)$ , kde  $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma_e^2$  (**homogenita rozptylov**),  $\sigma_j^2$  sú neznáme a
2.  $Y_{ji} \sim N(\mu_j, \sigma_j^2)$ , kde existuje aspoň jedna dvojica  $i \neq j$  taká, že  $\sigma_i^2 \neq \sigma_j^2$  (**nhomogenita rozptylov**),  $\sigma_j^2$  sú neznáme.

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

Nech  $Y_{ji} \sim N(\mu_j, \sigma_j^2)$ , kde  $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma_e^2$  a zároveň  $\sigma_j^2$  sú neznáme. Majme **jednofaktorový model analýzy rozptylu (ANOVA) s fixnými (pevnými) efektami**, ozn.  $\mathcal{F}_{H_1}$ , definovaný ako

$$Y_{ji} = \mu_j + \varepsilon_{ji} = \mu + \alpha_j + \varepsilon_{ji},$$

kde  $\mu = \sum_{j=1}^J \mu_j / J$ ,  $\mu_j = \mu + \alpha_j$ ,  $\sum_{j=1}^J \alpha_j = 0$ ,  $\mu$  je **celková (spoločná) úroveň spoločnej všetkým populáciám** (alebo **celková stredná hodnota**),  $\alpha_j$  je  $j$ -ta úroveň faktora A ( $j$ -ty efekt faktora A) a znamená odchýlku strednej hodnoty  $j$ -tej populácie od  $\mu$ . Pre chyby  $\varepsilon_{ji}$  platí  $\varepsilon_{ji} \sim N(0, \sigma_e^2)$ . Model  $Y_{ji} \sim N(\mu + \alpha_j, \sigma_e^2)$  sa nazýva aj **model podmieneného normálneho rozdelenia**.

Majme dvojicu hypotéz  $H_0: \mu_1 = \mu_2 = \dots = \mu_J = \mu$  oproti  $H_1: \text{existuje aspoň jedno } i < j \text{ také, že } \mu_i \neq \mu_j$ . Ak  $H_0$  platí, potom  $\alpha_1 = \alpha_2 = \dots = \alpha_J = 0$ , dostaneme submodel, ozn.  $\mathcal{F}_{H_0}$ , definovaný ako

$$Y_{ji} = \mu + \varepsilon_{ji}.$$

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

Ak  $H_0$  platí, potom

$$F_W = \frac{\frac{SS_A}{J-1}}{\frac{SS_e}{n-J}} \stackrel{\mathcal{D}}{\sim} F_{J-1, n-J},$$

kde  $df_A = J - 1$ ,  $df_e = (n - 1) - (J - 1) = n - J$  sú stupne voľnosti,  $n = \sum_{j=1}^J n_j$  je celkový rozsah,  $n_j$  sú rozsahy jednotlivých výberov,  $SS_A$  je **výberový súčet štvorcov rozdielov medzi súbormi** a je definovaný ako

$$SS_A = \sum_{j=1}^J n_j (\bar{Y}_{j\cdot} - \bar{Y}_{..})^2 = \sum_{j=1}^J \frac{Y_{j\cdot}^2}{n_j} - \frac{1}{n} Y_{..}^2,$$

$\hat{\mu} = \bar{Y}_{..} = Y_{..}/n$  je maximálne vieročodný odhad  $\mu$ ,  $Y_{..} = \sum_{j=1}^J \sum_{i=1}^{n_j} Y_{ji}$ ,  $\hat{\mu}_j = \bar{Y}_{j\cdot} = Y_{j\cdot}/n_j$  je maximálne vieročodný odhad  $\mu_j$ ,  $Y_{j\cdot} = \sum_{i=1}^{n_j} Y_{ji}$ ,  $SS_e$  je **výberový súčet štvorcov rozdielov vnútri súborov** a je definovaný ako

$$SS_e = \sum_{j=1}^J \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_{j\cdot})^2 = \sum_{j=1}^J \sum_{i=1}^{n_j} Y_{ji}^2 - \sum_{j=1}^J \frac{Y_{j\cdot}^2}{n_j}.$$

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

Súčet  $SS_A$  a  $SS_e$  sa rovná  $SS_T$ , čo je **celkový výberový súčet štvorcov rozdielov** a je definovaný ako

$$SS_T = \sum_{j=1}^J \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_{..})^2 = \sum_{j=1}^J \sum_{i=1}^{n_j} Y_{ji}^2 - \frac{1}{n} Y_{..}^2,$$

Rovnosti  $SS_T = SS_A + SS_e$  hovoríme aj **rozklad celkovej sumy štvorcov**. Pre stupne voľnosti potom platí  $df_T = df_A + df_e$ , kde  $df_T = n - 1$ . Sumy štvorcov sa najčastejšie zapisujú do **ANOVA tabuľky**:

zdroj variability	suma štvorcov	$df$	priemerné štvorce
medzi súbormi	$SS_{A,obs}$	$J - 1$	$MS_{A,obs} = SS_{A,obs} / (J - 1)$
vnútri súborov	$SS_{e,obs}$	$n - J$	$MS_{e,obs} = SS_{e,obs} / (n - J) = \hat{\sigma}_e^2 = s^2$
celkovo	$SS_{T,obs}$	$n - 1$	

## Asymptotické testy o stredných hodnotách

Maticový zápis modelu  $\mathcal{F}_{H_1}$  a  $\mathcal{F}_{H_0}$

Modely  $\mathcal{F}_{H_1}$  a  $\mathcal{F}_{H_0}$  sú lineárnymi regresnými modelmi a môžeme ich všeobecne zapísť v tvare  $\mathbf{Y} = \mathbf{X}\beta + \varepsilon$ , kde  $\mathbf{Y}$  je  $n$ -rozmerný náhodný vektor,  $\mathbf{X}$  je **matica plánu** s rozmermi  $n \times (J+1)$  a  $\varepsilon$  je  $n$ -rozmerný **vektor chýb**. Potom model  $\mathcal{F}_{H_1}$  bude mať tvar

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_J \end{pmatrix} = \mathbf{X}\beta + \varepsilon = \begin{pmatrix} \mathbf{1}_1 & \mathbf{1}_1 & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{1}_2 & \mathbf{0} & \mathbf{1}_2 & \dots & \mathbf{0} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \mathbf{1}_J & \mathbf{0} & \mathbf{0} & \dots & \mathbf{1}_J \end{pmatrix} \begin{pmatrix} \mu \\ \alpha_1 \\ \vdots \\ \alpha_J \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_J \end{pmatrix},$$

kde  $\mathbf{Y}_j = (Y_{j1}, Y_{j2}, \dots, Y_{jn_j})^T$  je  $n_j$ -rozmerný vektor,  $\mathbf{1}_j$  je  $n_j$ -rozmerný vektor jednotiek a  $\varepsilon_j$  je  $n_j$ -rozmerný vektor chýb. Potom  $\mathbf{Y}_j \sim N_{n_j}(\mathbf{X}\beta, \sigma_e^2 \mathbf{I}_{n_j \times n_j})$ , vektor chýb  $\varepsilon_j \sim N_{n_j}(\mathbf{0}, \sigma_e^2 \mathbf{I}_{n_j \times n_j})$ , vektor parametrov  $\hat{\beta} \sim N_{J+1}(\beta, \sigma_e^2 (\mathbf{X}^T \mathbf{X})^{-1})$ , kde maximálne viero hodný odhad  $\hat{\beta}$  vypočítame pomocou **metódy najmenších štvorcov**, t.j.  $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$ .

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

$F_W$  sa nazýva **Fisherova testovacia štatistika** (alebo **ANOVA F-štatistika**) a test **viacvýberový F-test o rovnosti stredných hodnôt**  $\mu_1, \mu_2, \dots, \mu_J$  (alebo **ANOVA F-test**). Realizáciou  $F_W$  je  $F_{\text{obs}}$  a p-hodnota  $= \Pr(F_W \geq F_{\text{obs}} | H_0)$ .

**Interpretácia:** Úlohu môžeme interpretovať tak, že stredná hodnota  $\mu_j$  náhodnej veličiny  $Y_{ji}$  závisí na **faktore A**, čo je premenná v nominálnej škále. Jednotlivým **úrovniám** (hladinám) tejto premennej zodpovedajú **fixné efekty**  $\alpha_j = \mu_j - \mu$ . Úrovne premennej volí experimentátor, sú teda nenáhodné, dopredu dané (fixné). Potom chápeme  $\alpha_j$  ako neznáme parametre, ktorých maximálne viero hodný odhad definujeme ako  $\hat{\alpha}_j = \bar{Y}_j - \bar{Y}_{..}$ . Samotné rozhodovanie o  $H_0$  bude založené na porovnaní priemerných súm štvorcov  $SS_{A,obs}/df_A$  a  $SS_{e,obs}/df_e$ . Väčšie rozdiely  $\bar{Y}_j$  a  $\bar{Y}_{..}$  (v absolútnej hodnote) sa prejavia vo väčšej hodnote štatistiky  $SS_{A,obs}$ . Štatistika  $SS_{e,obs}$  zasa umožňuje odhadnúť rozptyl  $\sigma_e^2$  a súčasne dáva mieru pre hodnotenie veľkosti variability medzi súbormi.

## Asymptotické testy o stredných hodnotách

ANOVA model v 

Model  $\mathcal{F}_{H_0}$  bude mať tvar

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_J \end{pmatrix} = \mathbf{X}\beta + \varepsilon = \begin{pmatrix} \mathbf{1}_1 \\ \mathbf{1}_2 \\ \vdots \\ \mathbf{1}_J \end{pmatrix} \mu + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_J \end{pmatrix}.$$

# Asymptotické testy o stredných hodnotách

ANOVA model v 

Argumenty (vstupy) funkcie `aov()`:

1. ANOVA model formula v podobe  $y \sim x$ ;
2. dátová tabuľka data;
3. nastavenie výstupu v podobe tabuľky s rozmermi  $n \times 3$  obsahujúcej odhady  $\hat{\mu}$ ,  $\hat{\alpha}_j$  a reziduály (chyby)  $\epsilon_{ji}$ , `projections=FALSE` (prednastavené);

Výstupy funkcie `aov()`:

1. tabuľky s rozmermi  $n \times 3$  obsahujúca odhady  $\hat{\mu}$ ,  $\hat{\alpha}_j$  a reziduály  $\epsilon_{ji}$ , `projections`;
2. odhady  $\hat{y}_{ji}$  `fitted.values`;
3. reziduály  $\epsilon_{ji}$  `residuals`.

# Asymptotické testy o stredných hodnotách

ANOVA model v 

Výstupy funkcie `summary(aov())`:

1. ANOVA tabuľka, kde
  - stupne voľnosti  $df_A$  a  $df_e$  `summary(MODEL)[[1]][,1]`,
  - sumy štvorcov  $SS_{A,obs}$  a  $SS_{e,obs}$  `summary(MODEL)[[1]][,2]`,
  - priemerné štvorce  $MS_{A,obs}$  a  $MS_{e,obs}$  `summary(MODEL)[[1]][,3]`;
2. realizáciu testovacej štatistiky  $F_{obs}$  `summary(MODEL)[[1]][1,4]`;
3. p-hodnota `summary(aov())[1][1,5]`.

Funkcia `aov()` používa na výpočty funkciu lineárny regresný model `lm()`. Pri priamom použití fukcie `lm()` dostaneme ANOVA tabuľku ako `anova(lm())`. Odmcinu z rozptylu  $\hat{\sigma}_e^2$  dostaneme pomocou `summary(lm())$sig`. Alternatívne je možné použiť funkciu `oneway.test()`, ktorej vstupom je ANOVA model formula v podobe  $y \sim x$ , dátová tabuľka data a nastavenie rovnosti rozptylov `var.equal=TRUE`. Výstupom sú realizácia testovacej štatistiky  $F_{obs}$ , stupne voľnosti  $df_A$  a  $df_e$  a p-hodnota.

# Asymptotické testy o stredných hodnotách

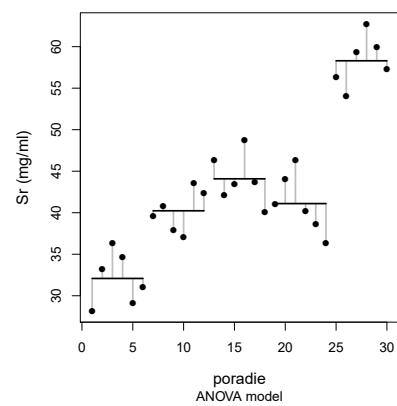
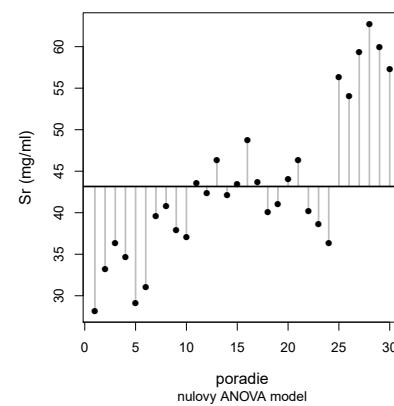
ANOVA model v 

## Example (ANOVA F-test)

Majme koncentráciu stronca Sr (mg/ml) v piatich vodných celkoch (pozri tabuľku). Otestujte rovnosť stredných hodnôt ANOVA F-testom pomocou funkcií (1) `aov()` (2) `oneway.test()` a (3) `lm()`.

Tabuľka: Koncentrácia stronca Sr (mg/ml) v piatich vodných celkoch

A (1)	B (2)	C (3)	D (4)	E (5)
28.2	39.6	46.3	41.0	56.3
33.2	40.8	42.1	44.1	54.1
36.4	37.9	43.5	46.4	59.4
34.6	37.1	48.8	40.2	62.7
29.1	43.6	43.7	38.6	60.0
31.0	42.4	40.1	36.3	57.3



Obr.: Rozptylové grafy ANOVA modelov –  $\mathcal{F}_{H_0}$  (vľavo) a  $\mathcal{F}_{H_1}$  (vpravo)

## Asymptotické testy o stredných hodnotách

ANOVA model v 

Celkový aritmetický priemer je rovný  $\bar{y} = 43.16$ . Aritmetické priemery koncentrácií Sr v jednotlivých vodných celkoch sú nasledovné:  $\bar{y}_1 = 32.08$ ,  $\bar{y}_2 = 40.23$ ,  $\bar{y}_3 = 44.08$ ,  $\bar{y}_4 = 41.10$  a  $\bar{y}_5 = 58.30$ , pre  $n_j = 6$ ,  $j = 1, 2, \dots, 6$ . Centrované aritmetické priemery sú rovne –  $\bar{y}_1 - \bar{y} = -11.08$ ,  $\bar{y}_2 - \bar{y} = -2.93$ ,  $\bar{y}_3 - \bar{y} = 0.92$ ,  $\bar{y}_4 - \bar{y} = -2.06$  a  $\bar{y}_5 - \bar{y} = 15.14$ . Pre aritmetické priemery platí  $\bar{y}_1 < \bar{y}_2 < \bar{y}_4 < \bar{y}_3 < \bar{y}_5$ . ANOVA tabuľka je nasledovná

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi	$SS_{A,obs} \doteq 2193.442$	$J - 1 = 4$	$MS_{A,obs} \doteq 548.361$
vnútri súborov	$SS_{e,obs} \doteq 244.130$	$n - J = 25$	$MS_{e,obs} \doteq 9.765$
celkovo	$SS_{T,obs} \doteq 2437.572$	$n - 1 = 29$	

Z ANOVA tabuľky vypočítame  $F_W \doteq 56.2$ , čo je väčšie ako  $F_{J-1, n-J}(\alpha) = F_{4, 25}(0.05) \doteq 2.76$  (p-hodnota  $\ll 0.05$ ), t.j.  $H_0$  zamietame na  $\alpha = 0.05$ .

13/56

Stanislav Katina Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

ANOVA model v 

```

19 StrMOD01 <- aov(ConcStr~VodCelk)
20 summary(StrMOD01) # ANOVA tabuľka
21 #          Df Sum Sq Mean Sq F value    Pr(>F)
22 # VodCelk     4 2193.44  548.36  56.155 3.948e-12 ***
23 # Residuals   25 244.13   9.77
24 oneway.test(ConcStr~VodCelk, var.equal=TRUE) # vysl ANOVA F-testu
25 #      One-way analysis of means
26 # data: ConcStr and VodCelk
27 # F = 56.1546, num df = 4, denom df = 25, p-value = 3.948e-12
28 ## identicky ako
29 StrMOD02 <- lm(ConcStr~VodCelk)
30 anova(StrMOD02) # ANOVA tabuľka
31 # Analysis of Variance Table
32 # Response: ConcStr
33 #          Df Sum Sq Mean Sq F value    Pr(>F)
34 # VodCelk     4 2193.44  548.36  56.155 3.948e-12 ***

```

15/56

Stanislav Katina Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

ANOVA model v 

```

1 K <- 6
2 J <- 5
3 VodCelk <- factor(rep(LETTERS[1:J], rep(K,J)))
4 ConcStr.1 <- c(28.2, 33.2, 36.4, 34.6, 29.1, 31.0)
5 ConcStr.2 <- c(39.6, 40.8, 37.9, 37.1, 43.6, 42.4)
6 ConcStr.3 <- c(46.3, 42.1, 43.5, 48.8, 43.7, 40.1)
7 ConcStr.4 <- c(41.0, 44.1, 46.4, 40.2, 38.6, 36.3)
8 ConcStr.5 <- c(56.3, 54.1, 59.4, 62.7, 60.0, 57.3)
9 ConcStr <- c(ConcStr.1, ConcStr.2, ConcStr.3, ConcStr.4, ConcStr.5)
10 mean(ConcStr) # 43.16
11 PRIEM.ConcStr <- tapply(ConcStr, VodCelk, mean)
12 round(PRIEM.ConcStr, 2)
13 #      A      B      C      D      E
14 # 32.08 40.23 44.08 41.10 58.30
15 PRIEM.str <- tapply(ConcStr-mean(ConcStr), VodCelk, mean)
16 round(PRIEM.str, 2)
17 #      A      B      C      D      E
18 # -11.08  -2.93   0.92  -2.06 15.14

```

14/56

Stanislav Katina Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

ANOVA model v 

```

35 summary(StrMOD02) # vysledky ANOVA F-testu
36 # Residuals:
37 #      Min      1Q   Median      3Q      Max
38 # -4.8000 -2.2500 -0.4833  2.2042  5.3000
39 #Coefficients:
40 #              Estimate Std. Error t value Pr(>|t|)
41 #(Intercept) 32.083      1.276  25.149 < 2e-16 ***
42 #VodCelkB     8.150      1.804   4.517  0.00013 ***
43 #VodCelkC    12.000      1.804   6.651 5.72e-07 ***
44 #VodCelkD     9.017      1.804   4.998 3.75e-05 ***
45 #VodCelkE    26.217      1.804  14.531 1.07e-13 ***
46 #Residual standard error: 3.125 on 25 degrees of freedom
47 #Multiple R-squared:  0.8998, Adjusted R-squared:  0.8838
48 #F-statistic: 56.15 on 4 and 25 DF,  p-value: 3.948e-12

```

16/56

Stanislav Katina Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

ANOVA model v 

```

49 StrMOD03 <- lm(ConcStr-mean(ConcStr) ~ VodCelk-1)
50 summary(StrMOD03)
51 # Residuals:
52 #   Min    1Q Median    3Q   Max
53 # -4.8000 -2.2500 -0.4833  2.2042  5.3000
54 # Coefficients:
55 #             Estimate Std. Error t value Pr(>|t|)
56 # VodCelkA -11.0767    1.2757 -8.682 5.12e-09 ***
57 # VodCelkB -2.9267    1.2757 -2.294  0.0305 *
58 # VodCelkC  0.9233    1.2757  0.724  0.4759
59 # VodCelkD -2.0600    1.2757 -1.615  0.1189
60 # VodCelkE 15.1400    1.2757 11.868 9.11e-12 ***
61 # Residual standard error: 3.125 on 25 degrees of freedom
62 # Multiple R-Squared:  0.8998, Adjusted R-squared:  0.8798
63 # F-statistic: 44.92 on 5 and 25 DF, p-value: 1.068e-11
64 summary(StrMOD03)$coef # efekty faktora VodCelk (cela tabulka)
65 sqrt((summary(StrMOD03)$sig)^2/K) # 1.27575; odmocnina z (MSe/K)
66 2*pt(summary(StrMOD03)$coeff[2,3],df=K*J-J) # 0.03046675
67 2*pt(-2.294,df=K*J-J) # 0.03046675

```

17 / 56

Stanislav Katina

Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

ANOVA model v 

```

68 anova(StrMOD03) # ANOVA tabuľka
69 #Analysis of Variance Table
70 #Response: ConcStr - mean(ConcStr)
71 #           Df Sum Sq Mean Sq F value    Pr(>F)
72 #VodCelk      5 2193.44  438.69 44.924 1.068e-11 ***
73 #Residuals  25  244.13     9.77

```

18 / 56

Stanislav Katina

Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania

Ak ANOVA  $F$ -test zamietne  $H_0$ , potom je potrebné zistiť, ktoré rozdiely dvojíc stredných hodnôt sú štatisticky signifikantné na nominálnej hladine významnosti  $\alpha$ . Môžeme tak urobiť pomocou **post-hoc testov**. Základným predpokladom ich použitia je, rovnako ako pre ANOVA model, splnenie podmienky homogenity rozptylov a normality  $Y_{ji}$  a chýb  $\varepsilon_{ji}$ . Ekvivalentnou  $H_0$  je nasledovná hypotéza  $H_0 : \mu_i = \mu_j$  pre  $\forall i, j; i < j$ . Prepíšme  $H_0$  do všeobecnejšieho tvaru

$$H_0 : \sum_{j=1}^J a_j \mu_j = \sum_{j=1}^J a_j \mu_{0j} \text{ oproti } \sum_{j=1}^J a_j \mu_j \neq \sum_{j=1}^J a_j \mu_{0j} \text{ pre nejaké } \mathbf{a} = (a_1, a_2, \dots, a_J)^T \in \mathcal{A},$$

kde  $\mathcal{A} = \{\mathbf{a} : \sum_{j=1}^J a_j = 0\}$  a  $\mathbf{a}$  je **vektor kontrastov**.

19 / 56

Stanislav Katina

Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania

Všeobecnosti však môžeme prepokladať, že  $H_0$  generuje podpriestor s hodnosťou  $h$ . Potom definujeme  $H_0 = \cap_{k=1}^h H_{0k}$ , kde  $h = \binom{J}{2} = J(J-1)/2$ , ak ide o všetky párové porovnania.

V prípade, že  $J$ -ta z porovnavaných populácií je **kontrolná** (charakterizovaná  $\mu_J$ ) a ostatné majú byť porovávané len s touto kontrolnou populáciou a nie medzi sebou, potom volíme  $h = J-1$  a zaujímame sa len napr. o rozdiely tvaru  $|\bar{y}_j - \bar{y}_J|$ , kde  $j = 1, 2, \dots, J-1$ . Najprv testujeme  $H_0$  viacvýberovým ANOVA  $F$ -testom na hladine významnosti  $\alpha$  použitím ANOVA  $F$ -statistiky. Ak  $H_0$  nezamietame, nepokračujeme ďalej. Ak  $H_0$  zamietame, chceme identifikovať, ktorú z hypotéz  $\mathbf{a}^T \boldsymbol{\mu} = \mathbf{a}^T \boldsymbol{\mu}_0 = 0$ , kde  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_J)^T$ , zamietame (pre fixné  $\mathbf{a}$ ). Počet hypotéz  $h$  poznáme vopred, ale množiny  $\mathcal{H}_0 = \{k : H_{0k} = 0\}$  a  $\mathcal{H}_1 = \{k : H_{0k} = 1\}$ , t.j. množiny nezamietnutých a zamietnutých nulových hypotéz z množiny všetkých nulových hypotéz  $\mathcal{H} = \mathcal{H}_0 \cup \mathcal{H}_1 = \{1, 2, \dots, h\}$ , kde  $h = h_0 + h_1$ ,  $h_0 = \text{card } \{\mathcal{H}_0\}$  a  $h_1 = \text{card } \{\mathcal{H}_1\}$ , dopredu nepoznáme.

20 / 56

Stanislav Katina

Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania

Pre  $H_{0,ij} : \mu_i = \mu_j, i < j$ , bude vektor kontrastov  $\mathbf{a}_k$  mať na  $i$ -tom mieste  $-1$ , na  $j$ -tom mieste  $1$ , ostatné sú nuly, napr.

$\mathbf{a}_1 = (1, -1, 0, \dots, 0)^T, \mathbf{a}_2 = (0, 1, -1, \dots, 0)^T, \dots, \mathbf{a}_{J-1} = (0, 0, \dots, 1, -1)^T$ , z čoho vyplýva, že

$$\mathbf{a}_1 \Rightarrow \mu_1 = \mu_2, \mathbf{a}_2 \Rightarrow \mu_2 = \mu_3, \dots, \mathbf{a}_{J-1} \Rightarrow \mu_{J-1} = \mu_J,$$

čo implikuje  $\mu_1 = \mu_2 = \dots = \mu_J = \mu$ . V maticovej podobe dostaneme

$$\mathbf{A} = \begin{pmatrix} 0 & 1 & -1 & 0 & \dots & 0 \\ 0 & 0 & 1 & -1 & \dots & 0 \\ 0 & \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 & -1 \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \mu \\ \alpha_1 \\ \vdots \\ \alpha_J \end{pmatrix}, \mathbf{A}\boldsymbol{\beta} = \begin{pmatrix} \alpha_1 - \alpha_2 \\ \alpha_2 - \alpha_3 \\ \vdots \\ \alpha_{J-1} - \alpha_J \end{pmatrix}.$$

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania

Ekvivalentne

$$\mathbf{A} = \begin{pmatrix} 1 & -1 & 0 & \dots & 0 \\ 0 & 1 & -1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 & -1 \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_J \end{pmatrix}, \mathbf{A}\boldsymbol{\beta} = \begin{pmatrix} \mu_1 - \mu_2 \\ \mu_2 - \mu_3 \\ \vdots \\ \mu_{J-1} - \mu_J \end{pmatrix}.$$

Potom môžeme ekvivalentne písť  $H_0 : \mathbf{A}\boldsymbol{\beta} = \mathbf{a}_0 = \mathbf{0}$  oproti  $H_1 : \mathbf{A}\boldsymbol{\beta} \neq \mathbf{a}_0 = \mathbf{0}$ .

Pre nejaký vektor  $\mathbf{a}$  je stredná hodnota  $E[\sum_{j=1}^J a_j \bar{Y}_{j\cdot}] = \sum_{j=1}^J a_j \mu_j$  a rozptyl

$$Var[\sum_{j=1}^J a_j \bar{Y}_{j\cdot}] = \sigma_e^2 \sum_{j=1}^J \frac{a_j^2}{n_j}. \text{ Potom}$$

$$Z_W = \frac{\sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0}}{\sqrt{\sigma_e^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}} \stackrel{D}{\sim} N(0, 1).$$

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Fisherova LSD metóda

Rozptyl  $\sigma_e^2$  nepoznáme a musíme ho odhadnúť. Výberový rozptyl v  $j$ -tej populácii je rovný  $S_j^2 = \frac{1}{n_j-1} \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_{j\cdot})^2$ , kde  $j = 1, 2, \dots, J$ , sú nezávislé. Potom platí  $(n_j - 1)S_j^2 / \sigma_e^2 \sim \chi_{n_j-1}^2$ . Keďže v modeloch  $\mathcal{F}_{H_0}$  a  $\mathcal{F}_{H_1}$  predpokladáme rovnosť rozptylov, potom môžeme písť  $\hat{\sigma}_e^2$  ako  $s^2 = \frac{1}{n-J} \sum_{j=1}^J (n_j - 1)S_j^2 = \frac{1}{n-J} \sum_{j=1}^J \sum_{i=1}^{n_j} (Y_{ji} - \bar{Y}_{j\cdot})^2 = \frac{1}{n-J} SS_{e,\text{obs}}$ , kde  $n - J = \sum_{j=1}^J (n_j - 1)$ . Potom  $(n - J)S^2 / \sigma_e^2 \sim \chi_{n-J}^2$ . Navyše  $S^2$  je nezávislé na  $\bar{Y}_{j\cdot}$ , a teda môžeme písť

$$T_a = \frac{\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0}{\sqrt{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}} = \frac{\sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0}}{\sqrt{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}} \stackrel{D}{\sim} t_{n-J},$$

kde je matica plánu  $\mathbf{X}$  použitá bez prvého stĺpca (charakterizujúceho celkovú strednú hodnotu  $\mu$ ) a má preto rozmeru  $n \times J$ . Realizáciou  $T_a$  je  $t_a$ , p-hodnota  $= \Pr(T_a \geq |t_a| | H_0)$  a  $H_0$  zamietame, ak  $|t_a| \geq t_{n-J}(\alpha/2)$ ;  $t_{n-J}(\alpha/2)$  je kritická hodnota  $t$  rozdelenia s  $n - J$  stupňami voľnosti.

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Fisherova LSD metóda

$T_a = T_{LSD}$  je **Waldova testovacia štatistika**, často nazývaná aj **Fisherova LSD štatistika** (z angl. *least significant difference*, t.j. najmenší signifikantný rozdiel). Test **viacvýberový Fisherov LSD test o lineárnom kontraste**  $\sum_{j=1}^J a_j \mu_j$ .

Potom môžeme definovať **Waldov 100 \times (1 - \alpha)\% empirický IS pre nejakú lineárnu kombináciu**  $\sum_{j=1}^J a_j \mu_j$  (nazývaný aj **empirický IS Fisherovho typu**) ako

$$\left( \sum_{j=1}^J a_j \bar{Y}_{j\cdot} - t_{n-J}(\alpha/2) \sqrt{s^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}, \sum_{j=1}^J a_j \bar{Y}_{j\cdot} + t_{n-J}(\alpha/2) \sqrt{s^2 \sum_{j=1}^J \frac{a_j^2}{n_j}} \right).$$

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Scheffeho metóda

Označme

$$T_{\mathbf{a}}^2 = \frac{(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} = \frac{\left( \sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0} \right)^2}{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}} = \frac{\left( \sum_{j=1}^J a_j (\bar{Y}_{j\cdot} - \mu_{j0}) \right)^2}{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}.$$

Potom

$$\sup_{\mathbf{a}: \sum_{j=1}^J a_j = 0} T_{\mathbf{a}}^2 = \frac{\sum_{j=1}^J n_j \left( (\bar{Y}_{j\cdot} - \bar{Y}_{..}) - (\mu_{j0} - \mu) \right)^2}{S^2} = (J-1)F_W,$$

kde  $\bar{Y}_{..} = \sum_{j=1}^J n_j \bar{Y}_{j\cdot} / \sum_{j=1}^J n_j$  a  $\mu = \sum_{j=1}^J n_j \mu_{j0} / \sum_{j=1}^J n_j$ . Navyše

$$\sup_{\mathbf{a}: \sum_{j=1}^J a_j = 0} T_{\mathbf{a}}^2 \stackrel{D}{\sim} (J-1)F_{J-1,n-J}.$$

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Scheffeho metóda

Čitateľ a menovateľ  $(J-1)F_W$  sú nezávislé. Tiež platí  $S^2 \sim \sigma_e^2 \chi_{n-J}^2 / (n-J)$  a

$$1/\sigma_e^2 \left( \sum_{j=1}^J n_j \left( (\bar{Y}_{j\cdot} - \bar{Y}_{..}) - (\mu_{j0} - \mu) \right)^2 \right) \sim \chi_{J-1}^2.$$

Scheffe ukázal, že

$$F_{\mathbf{a}} = \frac{(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} = \frac{(\sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0})^2}{S^2 \sum_{j=1}^J a_j^2 / n_j} \stackrel{D}{\sim} (J-1)F_{J-1,n-J},$$

kde  $H_0$  zamietame, ak  $F_{\mathbf{a}} \geq (J-1)F_{J-1,n-J}(\alpha)$ , kde  $F_{J-1,n-J}(\alpha)$  je kritická hodnota  $F$  rozdelenia s  $J-1$  a  $n-J$  stupňami voľnosti. Je potrebné zdôrazniť, že  $H_0$  musí platiť pre všetky kontrasty  $\mathbf{a}$  simultánne a  $H_0$  zamietame, ak zamietame hypotézu o supréme  $T_{\mathbf{a}}^2$ , t.j. zamietame  $H_0$  v ANOVA  $F$ -teste.  $F_{\mathbf{a}}$  sa nazýva **Waldova testovacia štatistika**, často nazývaná aj **Scheffeho štatistika** a test **viacvýberový Scheffeho test nulovosti všetkých kontrastov**. Realizáciou  $F_{\mathbf{a}}$  je  $F_{\mathbf{a},\text{obs}}$  a (ajustovaná) p-hodnota =  $\Pr(F_{\mathbf{a}} \geq F_{\mathbf{a},\text{obs}} | H_0)$ .

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Scheffeho metóda

**Waldove simultánne**  $100 \times (1-\alpha)\%$  **empirické intervaly spoľahlivosti Scheffeho typu** definujeme ako

$$\left( \mathbf{a}^T \hat{\boldsymbol{\mu}} - \sqrt{(J-1)F_{J-1,n-J}(\alpha)} \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}, \right.$$

$$\left. \mathbf{a}^T \hat{\boldsymbol{\mu}} + \sqrt{(J-1)F_{J-1,n-J}(\alpha)} \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \right),$$

kde pravdepodobnosť pokrycia všetkých IS (simultánne) je rovná  $1-\alpha$ . Za simultánnu inferenciu (t.j. testovanie  $H_{0k}$ ) platíme dĺžku simultánnych IS Scheffeho typu oproti IS Fisherovho typu, t.j. keďže garantujeme simultánny koeficient spoľahlivosti  $1-\alpha$ , simultánne IS Scheffeho typu môžu byť dosť široké (platí  $t_{n-J}(\alpha/2) \leq \sqrt{(J-1)F_{J-1,n-J}(\alpha)}$ ). Z čoho vyplýva, že Scheffeho testy majú menšiu silu ako  $t$ -testy.

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Tukeyho HSD metóda

Tukey ukázal, že

$$\sup_{\mathbf{a}: \sum_{j=1}^J a_j = 0} T_{\mathbf{a}} = \frac{\bar{Y}_{\max\cdot} - \bar{Y}_{\min\cdot}}{S \sqrt{\frac{1}{2} \left( \frac{1}{n_{\max} \bar{Y}_{\max\cdot}} + \frac{1}{n_{\min} \bar{Y}_{\min\cdot}} \right)}} \stackrel{D}{\sim} q_{J,n-J},$$

kde  $\bar{Y}_{\max\cdot} = \max_{\forall j} \bar{Y}_{j\cdot}$  a jemu prislúchajúci rozsah  $n_{\max}$ ,  $\bar{Y}_{\min\cdot} = \min_{\forall j} \bar{Y}_{j\cdot}$  a jemu prislúchajúci rozsah  $n_{\min}$ . Potom

$$F_{\mathbf{a}} = \frac{(\mathbf{a}^T \hat{\boldsymbol{\mu}} - \mathbf{a}^T \boldsymbol{\mu}_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \stackrel{D}{\sim} \frac{1}{2} q_{J,n-J}^2,$$

kde  $H_0$  zamietame, ak  $F_{\mathbf{a}} \geq \frac{1}{2} q_{J,n-J}^2(\alpha)$ , kde  $q_{J,n-J}(\alpha)$  je kritická hodnota **studentizovaného rozpätia** s  $J$  a  $n-J$  stupňami voľnosti. Je potrebné opäť zdôrazniť, že  $H_0$  musí platiť pre všetky kontrasty  $\mathbf{a}$  simultánne a  $H_0$  zamietame, ak zamietame hypotézu o supréme  $T_{\mathbf{a}}$ .

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Tukeyho HSD metóda

$F_a$  sa nazýva **Waldova testovacia štatistika**, často nazývaná aj **Tukeyho HSD štatistika** (alebo **Tukey-Kramerova štatistika**; HSD z angl. *honest significant difference*, t.j. skutočný signifikantný rozdiel) a test **viacvýberový Tukeyho HSD test nulovosti všetkých kontrastov**. Realizáciou  $F_a$  je  $F_{a,obs}$  a (adjustovaná) p-hodnota =  $\Pr(F_a \geq F_{a,obs} | H_0)$ .

**Waldove simultánne**  $100 \times (1 - \alpha)\%$  **empirické intervaly spoľahlivosti Tukeyho typu** definujeme ako

$$\left( \mathbf{a}^T \hat{\boldsymbol{\mu}} - q_{J,n-J}(\alpha) \sqrt{\frac{1}{2} \hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \hat{\boldsymbol{\mu}} + q_{J,n-J}(\alpha) \sqrt{\frac{1}{2} \hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \right).$$

29 / 56

Stanislav Katina

Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

### Example (Metódy mnohonásobného porovnávania)

Majme koncentráciu stronca Sr (mg/ml) v piatich vodných celkoch. Otestujte rovnosť stredných hodnôt ANOVA F-testom pomocou funkcií (1) `aov()` (2) `oneway.t.test()` a (3) `lm()`. Ak je  $H_0$  zamietnutá na  $\alpha = 0.05$ , potom použite (1) Tukeyho HSD metódu ( $T_{HSD}$  štatistiku), vypočítajte adjustované p-hodnoty, simultánne 95% empirické IS Tukeyho typu pre všetky párové porovnania rozdielov stredných hodnôt a zobrazte ich graficky. (2) Po náhľade na dátá vhodne zadefinujte kontrasty a aplikujte na ne Scheffeho metódu.

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

```

74 # Tukeyho HSD metoda pre vybrany kontrast B-A
75 a.AB <- c(-1,1,0,0,0)
76 citatel.AB <- sum(a.AB*PRIEM.ConcStr) # 8.15
77 sigmasq.e.hat <- (summary(StrMOD03)$sig)^2 # 9.7652
78 menovatel.AB <- sqrt(sigmasq.e.hat/2*sum(a.AB^2/K)) # 1.275748
79 tLSD.AB <- citatel.AB/menovatel.AB # 6.388408
80 qtukey(0.95,J,K*J-J) # 4.153363
81 p.hodn <- 1-ptukey(tLSD.AB,J,K*J-J) # 0.001129311
82 IS.AB <- citatel.AB+c(-1,1)*qtukey(0.95,J,K*J-J)*menovatel.AB
83 # 2.851355 13.448645
84 mp.Tukey <- TukeyHSD(aov(ConcStr~VodCelk), ordered=FALSE) # tab.
85 mp.Tukey$VodCelk

```

31 / 56

Stanislav Katina

Lineárne štatistické modely II

30 / 56

Stanislav Katina

Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

**Tabuľka:** Výsledky Tukey HSD metódy – rozdiely aritmetických priemerov  $\bar{y}_i - \bar{y}_j$ , dolná a horná hranica Waldových simultánnych 95% empirických IS Tukeyho typu pre  $\mu_i - \mu_j$  (DH a HH), adjustované p-hodnoty  $\tilde{p}_k$

	$\bar{y}_i - \bar{y}_j$	DH	HH	$\tilde{p}_k$
B-A	8.15	2.85	13.45	0.00112931
C-A	12.00	6.70	17.30	0.00000534
D-A	9.02	3.72	14.32	0.00033392
E-A	26.22	20.92	31.52	<0.00000001
C-B	3.85	-1.45	9.15	0.23762175
D-B	0.87	-4.43	6.17	0.98848032
E-B	18.07	12.77	23.37	<0.00000001
D-C	-2.98	-8.28	2.32	0.47910996
E-C	14.22	8.92	19.52	0.00000029
E-D	17.20	11.90	22.50	0.00000001

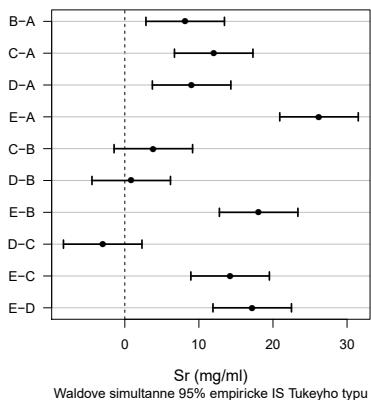
32 / 56

Stanislav Katina

Lineárne štatistické modely II

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 



Obr.: Waldove simultánne 95% empirické IS Tukeyho typu pre rozdiely stredných hodnôt

## Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

Po náhľade na dátu použijeme nasledovné tri vektorov kontrastov  $\mathbf{a}_k$ , ním prisúľchajúce odhady efektov  $\mathbf{a}_k^T \hat{\mu} = \sum_{j=1}^J a_{kj} \bar{y}_j$ , ich rozptyly

$$s^2 \mathbf{a}_k^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_k = s^2 \sum_{j=1}^J a_{kj}^2 / n_j \text{ a Scheffeho testovacie štatistiky}$$

$$\sqrt{(J-1)F} = |\mathbf{a}_k^T \hat{\mu}| / \sqrt{s^2 \mathbf{a}_k^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_k}, \text{ kde } k = 1, 2 \text{ a } 3:$$

- ▶  $\mathbf{a}_1 = (0, \frac{1}{3}, \frac{1}{3}, \frac{1}{3}, -1)^T$ ,  $\mathbf{a}_1^T \hat{\mu} \doteq -9.7$ ,  $s^2 \mathbf{a}_1^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_1 = 1.47^2$ ,  $\sqrt{4F} \doteq 11.20$ ,

- ▶  $\mathbf{a}_2 = (1, -\frac{1}{3}, -\frac{1}{3}, -\frac{1}{3}, 0)^T$ ,  $\mathbf{a}_2^T \hat{\mu} \doteq -16.5$ ,  $s^2 \mathbf{a}_2^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_2 = 1.47^2$ ,  $\sqrt{4F} \doteq 6.60$ ,

- ▶  $\mathbf{a}_3 = (\frac{1}{2}, -\frac{1}{3}, -\frac{1}{3}, -\frac{1}{3}, \frac{1}{2})^T$ ,  $\mathbf{a}_3^T \hat{\mu} \doteq 3.4$ ,  $s^2 \mathbf{a}_3^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_3 = 1.16^2$ ,  $\sqrt{4F} \doteq 2.93$ .

Scheffeho kritická hodnota je rovná

$$\sqrt{(J-1) F_{J-1, n-J}(\alpha)} = \sqrt{4F_{4, 25}(0.05)} \doteq 3.32. \text{ Potom } H_{0k} : \mathbf{a}_k^T \mu = 0 \text{ oproti } H_{1k} : \mathbf{a}_k^T \mu \neq 0 \text{ zamietame, ak } k = 1, 2, \text{ a nezamietame, ak } k = 3.$$

## Asymptotické testy o stredných hodnotách

Párové porovnávania

### Definition (chyba porovnávania $\alpha_c$ )

**Chyba porovnávania** (comparison-wise error, CWER)  $\alpha_c$  je pravdepodobnosť zamietnutia práve jednej  $H_{0k}$ , keď táto  $H_{0k}$  je pravdivá, t.j. ide o pravdepodobnosť, že nastane práve jedna CHPD v jednom párovom porovnaní.

### Definition (experimentálna chyba $\alpha_e$ )

**Experimentálna chyba** (experiment-wise error, EWER)  $\alpha_e$  je pravdepodobnosť zamietnutia aspoň jednej  $H_{0k}$ , keď všetky  $H_{0k}$  sú pravdivé, t.j. ide o pravdepodobnosť, že nastane aspoň jedna CHPD medzi všetkými  $h$  nezávislými párovými porovnávaniami. Táto chyba je kontrolovaná na nominálnej hladine významnosti  $\alpha$ .

## Asymptotické testy o stredných hodnotách

Párové porovnávania

Z definícií vyplýva, že  $\Pr(\text{CHPD})$  jedného testu je rovná  $\alpha_c$  a pravdepodobnosť správneho rozhodnutia je  $1 - \alpha_c$ . Za predpokladu, že máme  $h$  nezávislých párových porovnávaní, bude mať náhodná premenná  $V$  (počet CHPD) binomické rozdelenie, t.j.  $V \sim \text{Bin}(h, \alpha_c)$ . Keďže  $\alpha_e$  je pravdepodobnosť, že nastane aspoň jedna CHPD medzi všetkými  $h$  nezávislými párovými porovnávaniami, môžeme ju definovať nasledovne

$$\alpha = \alpha_e = \Pr(V \geq 1) = 1 - \Pr(V = 0) = 1 - \binom{J}{2} \alpha_c^0 (1 - \alpha_c)^h = 1 - (1 - \alpha_c)^h.$$

Z tejto rovnosti vyplýva, že ak sa počet párových porovnávaní zväčšuje,  $\alpha_e$  sa blíži k jednotke (pozri tabuľku). Ak  $h = 1$  (dvojvýberový prípad), potom  $\alpha = \alpha_e = \alpha_c$ .

Tabuľka: Experimentálna chyba  $\alpha_e$  ako funkcia  $\alpha_c$  a  $h$

$\alpha_c/h$	2	5	10	20	50
0.01	0.0199	0.0490	0.0956	0.1821	0.3950
0.05	0.0975	0.2262	0.4013	0.6415	0.9231
0.10	0.1900	0.4095	0.6513	0.8784	0.9948

## Asymptotické testy o stredných hodnotách

### Párové porovnávania

Zamerajme sa na hodnotenie zovšeobecnenej pravdepodobnosti CHPD v podobe

- pravdepodobnosti najmenej jednej CHPD**, kde  $V$  je počet zamietnutých pravdivých  $H_{0k}$  (*family-wise error rate*, FWER: metódy napr. Fisher1935 LSD, Tukey1949, Tukey1953, Tukey1991 HSD, Scheffé1953, Bonferroni1936, Sidak1967, Holm1979, Hochberg1988);  $\text{FWER} = \Pr(V \geq 1)$ ; **FWER adjustované (upravené) p-hodnoty** sú definované nasledovne

$$\tilde{p}_k = \inf \{\alpha : H_{0k} \text{ zamietame na FWER} = \alpha\};$$

- očakávanej hodnoty podielu CHPD medzi zamietnutými hypotézami**,  $\text{FDR} = E[V/R]$ , ak  $R > 0$  alebo 0, ak  $R = 0$ , kde  $R$  je počet zamietnutých pravdivých a nepravdivých  $H_0$ ,  $\text{FDP} = V/R$  (*false discovery rate*, FDR, *false discovery proportion*, FDP: metódy napr. BenjaminiHochberg1995, BenjaminiYekutieli2001); **FDR adjustované p-hodnoty** sú definované nasledovne

$$\tilde{p}_k = \inf \{\alpha : H_{0k} \text{ zamietame na FDR} = \alpha\};$$

## Asymptotické testy o stredných hodnotách

### Párové porovnávania

Kontrola FWER a FDR znamená nasledovné:  $\text{FWER} \leq \alpha$  a  $\Pr(\text{FDP} > \gamma) \leq \alpha$ , kde  $\gamma, \alpha \in (0, 1)$ .

Aby bolo možné robiť simultánnu inferenciu, je potrebné modifikovať kritickú hodnotu  $t_{n-J}(\alpha/2)$  rozdelenia Fisherovej LSD štatistiky pomocou substitúcie  $\alpha/2$  použitím jedno- a viackrokových metód. **(Jednokroková) Bonferroniho**, resp. **Šídákova metóda** sú založené na princípe zmenšenia argumentu  $\alpha/2$  kritickej hodnoty  $t$ -rozdelenia s  $n - J$  stupňami voľnosti (obojsstranný test) na základe Bonferroniho, resp. Šídákovej nerovnosti,  
 $\Pr(\cup_{k=1}^h A_k) \leq \sum_{k=1}^h \Pr(A_k)$ ,  $\Pr(\cup_{k=1}^h A_k) \leq 1 - \alpha$ , resp.  
 $\Pr(\cap_{k=1}^h A_k) \geq \prod_{k=1}^h \Pr(A_k)$ ,  $\Pr(\cap_{k=1}^h A_k) \geq 1 - \alpha$ , na  $\alpha/(2h)$ , resp.  
 $1 - (1 - \alpha/2)^{1/h}$ , kde  $A_k$  je najaká udalosť.

## Asymptotické testy o stredných hodnotách

### Párové porovnávania

Bonferroniho metóda je *konzervatívnejšia* ako Šídákova (vedie ku menšiemu počtu zamietnutí, t.j. kritické hodnoty sú väčšie), lebo platí  $(1 - \alpha)^{1/h} < 1 - \alpha/h$  pre všetky  $\alpha > 0, h > 1$ , teda  $t_{n-J}(\alpha/h) > t_{n-J}(1 - (1 - \alpha)^{1/h})$ . Rozdiel je ale zanedbateľný.

V súvislosti s kontrolou FWER a adjustovanými p-hodnotami platí pre Bonferroniho nerovnosť

$$\begin{aligned} \text{FWER} &= \Pr(V > 0) = \Pr\left(\cup_{k=1}^h (\tilde{P}_k \leq \alpha)\right) \leq \sum_{k=1}^{h_0} \Pr\left(\tilde{P}_k \leq \alpha\right) \\ &\leq \sum_{k=1}^{h_0} \frac{\alpha}{h} = h_0 \frac{\alpha}{h} \leq \alpha. \end{aligned}$$

## Asymptotické testy o stredných hodnotách

### Párové porovnávania

Pre Šídákovu nerovnosť

$$\begin{aligned} \Pr(V = 0) &= \Pr\left(\cap_{k=1}^h (\tilde{P}_k \geq \alpha)\right) = \prod_{k=1}^{h_0} \Pr\left(\tilde{P}_k \geq \alpha\right) \\ &= \prod_{k=1}^{h_0} \Pr\left(P_k \geq 1 - (1 - \alpha)^{1/h}\right) = 1 - (1 - \alpha)^{h_0/h}, \end{aligned}$$

z ktorej vyplýva, že  $\text{FWER} = \Pr(V > 0) = 1 - \Pr(V = 0) = (1 - \alpha)^{h_0/h} \leq \alpha$ .

Ak použijeme vyššie uvedené postupy na  $h$  párových porovnaní, potom pravdepodobnosť, že aspoň raz chybne zamietneme jednu z rovností  $\mu_i = \mu_j$ , ktorá platí, nie je väčšia ako  $\alpha$ . Ak ide o využavené triedenie, kde  $n_1 = n_2 = \dots = n_J$ , potom je táto pravdepodobnosť presne rovná  $\alpha$ . T.j. ak sú všetky hypotézy pravdivé, pravdepodobnosť identifikácie, že niektorá z nich je nepravdivá, nie je viac ako  $\alpha$ , pretože  $\alpha$  je pravdepodobnosť zamietnutia ANOVA  $F$ -testu. Taktiež ANOVA  $F$ -test je test všetkých  $\mathbf{a}_k^T \boldsymbol{\mu} = 0$ ,  $k = 1, 2, \dots, h$ , a ak je tento test zamietnutý, ešte nemusí nastáť situácia, že niektorá z vyššie spomenutých metód nezamietne nejakú hypotézu. Práve pre túto vlastnosť je experimentálna chyba menšia ako  $\alpha$ . Ale ak ANOVA  $F$ -test zamieta nulovú hypotézu, potom Scheffeho metóda bude zamietať  $H_0$  aspoň pre jeden kontrast.

# Asymptotické testy o stredných hodnotách

Párové porovnávania

**Adjustované hladiny významnosti**  $\alpha_k$  sú definované nasledovne

- ▶ Bonferroniho  $\alpha_k = \alpha/h$ ,
- ▶ Šidákove  $\alpha_k = 1 - (1 - \alpha)^{1/h}$ ,

Argument  $\alpha/2$  kritickej hodnoty  $t_{n-J}(\alpha/2)$  sa substituuje  $\alpha_k$ . Potom budú **Waldove simultánne**  $100 \times (1 - \alpha)\%$  **empirické intervaly spoľahlivosti Fisherovo typu** definované nasledovne

$$\left( \mathbf{a}^T \hat{\boldsymbol{\mu}} - t_{n-J}(\alpha_k) \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \hat{\boldsymbol{\mu}} + t_{n-J}(\alpha_k) \sqrt{\hat{\sigma}_e^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} \right).$$

**Adjustované p-hodnoty**  $p_k$  sú definované nasledovne

- ▶ Bonferroniho  $\tilde{p}_k = \min \{hp_k, 1\}$ ,
- ▶ Šidákove  $\tilde{p}_k = 1 - (1 - p_k)^h$ ,

# Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

## Example (Metódy mnohonásobného porovnávania)

Majme koncentráciu stroncia Sr (mg/ml) v piatich vodných celkoch. Otestujte rovnosť stredných hodnôt ANOVA F-testom pomocou funkcií (1) `aov()` (2) `oneway.test()` a (3) `lm()`. Ak je  $H_0$  zamietnutá na  $\alpha = 0.05$ , potom vypočítajte adjustované p-hodnoty a Waldove simultánne 95% empirické IS Fisherovo typu pre všetky párové porovnania rozdielov stredných hodnôt Bonferroniho metódou.

# Asymptotické testy o stredných hodnotách

Mnohonásobné porovnávania v 

## Mnohonásobné porovnávania v

Na Tukeyho HSD metódu použijeme funkciu

`TukeyHSD(aov(), ordered=FALSE)`, kde argument `ordered` ponechá pôvodné poradie hypotéz  $H_{0k}$ . Výstupom je tabuľka obsahujúca odhady rozdielov stredných hodnôt  $\bar{Y}_{i.} - \bar{Y}_{j.}$ , dolné a horné hranice Waldových simultánnych  $100 \times (1 - \alpha)\%$  empirických IS Tukeyho typu a adjustované p-hodnoty  $\tilde{p}_k$ . Na jednokrokové a viackrokové metódy (výpočet adjustovaných p-hodnôt) použijeme funkciu

`pairwise.t.test(y, x, p.adjust="metoda", pool.sd=TRUE)`, kde argument `pool.sd=TRUE` predstavuje použitie  $\hat{\sigma}_e^2$  a argument `p.adjust="metoda"` špecifikuje metódu nasledovne

1. Bonferroniho `p.adjust="bonferroni"`.

Funkcia `lm()` má prednastavené kontrasty párových porovnaní s prvou populáciou,  $\alpha_j - \alpha_1$ , kde  $J > 1$ , kedy použijeme vstupné argumenty `y` a `x`. Pokiaľ by sme chceli testovať nulovosť jednotlivých  $\alpha_j$ , použijeme vstupné argumenty `y-mean(y)` a `x-1` (argument `x-1` znamená model bez interceptu  $\mu$ ).

# Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

```
86 | # parove porovnavania
87 | mp.Bonf <- pairwise.t.test(ConcStr,VodCelk,
88 |                               p.adjust="bonferroni",pool.sd=TRUE)
```

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rôznych rozptyloch

Nech  $Y_{ji}(\mu_j, \sigma_j^2)$ , kde existuje aspoň jedna dvojica  $i \neq j$  taká, že  $\sigma_i^2 \neq \sigma_j^2$  a zároveň  $\sigma_j^2$  sú neznáme. Potom  $F_W$  štatistika nemá  $F$  rozdelenie s  $J - 1$  a  $n - J$  stupňami voľnosti a musí byť modifikovaná nasledovne

$$F_W = \frac{\sum_{j=1}^J \widehat{w}_j \left( \bar{Y}_{..} - \bar{Y}_{..}^{(w)} \right)^2}{J - 1 + \frac{J-2}{J+1} \sum_{j=1}^J \frac{(1-\widehat{n}_j)^2}{n_j - 1}} \stackrel{D}{\sim} F_{J-1, df_w}$$

$\widehat{w}_j = n_j / s_j^2$ ,  $\widehat{n}_j = \frac{\widehat{w}_j}{\sum_{i=1}^J \widehat{w}_i}$ ,  $j = 1, 2, \dots, J$  a  $\widehat{\mu} = \bar{Y}_{..}^{(w)} = \sum_{j=1}^J \widehat{h}_j \bar{Y}_{..}$ . Počet stupňov voľnosti

$$df_{w_1} = \frac{J^2 - 1}{3 \sum_{j=1}^J \frac{(1-\widehat{n}_j)^2}{n_j - 1}},$$

čo zaokrúhlime na najbližšie nižšie celé číslo, t.j.  $df_w = \lfloor df_{w_1} \rfloor$ .

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rôznych rozptyloch

$F_W$  sa nazýva **Fisherova testovacia štatistika** (alebo presnejšie **Welchova ANOVA  $F$ -štatistika**) a test viacvýberový  $F$ -test s **Welchovou aproximáciou stupňov voľnosti o rovnosti stredných hodnôt**

$\mu_1, \mu_2, \dots, \mu_J$  (alebo **Welchov ANOVA  $F$ -test**). Realizáciou  $F_W$  je  $F_{\text{obs}}$  a p-hodnota  $= \Pr(F_W \geq F_{\text{obs}} | H_0)$ . Na porovnanie ANOVA modelu pri rôznych rozptyloch s ANOVA modelom pri rovnakých rozptyloch  $-s^2$  definujeme ako vážený priemer výberových rozptylov  $s_j^2$ ,  $j = 1, 2, \dots, J$ , teda

$$s^2 = \frac{\sum_{j=1}^J (n_j - 1) s_j^2}{\sum_{j=1}^J (n_j - 1)} = \frac{\sum_{j=1}^J (n_j - 1) s_j^2}{n - J}.$$

Potom  $\mathbf{Y}_j \sim N_{n_j}(\mathbf{X}\boldsymbol{\beta}, \boldsymbol{\Sigma}_j)$ , kde  $\boldsymbol{\Sigma}_j = \sigma_j^2 \mathbf{I}_{n_j \times n_j}$ , vektor chýb  $\boldsymbol{\varepsilon}_j \sim N_{n_j}(\mathbf{0}, \boldsymbol{\Sigma}_j)$ , vektor parametrov  $\widehat{\boldsymbol{\beta}} \sim N_{J+1}(\boldsymbol{\beta}, (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1})$ , kde  $\boldsymbol{\Sigma} = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_J^2)$  a maximálne vierohodný odhad  $\widehat{\boldsymbol{\beta}}$  vypočítame pomocou **zovšeobecnenej metódy najmenších štvorcov**, t.j.  $\widehat{\boldsymbol{\beta}} = (\mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{X})^{-1} \mathbf{X}^T \boldsymbol{\Sigma}^{-1} \mathbf{Y}$ .

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rôznych rozptyloch

**Waldov**  $100 \times (1 - \alpha)\%$  **empirický IS pre nejakú lineárnu kombináciu**  $\sum_{j=1}^J a_j \mu_j$  (nazývaný aj **empirický IS Fisherovo typu**) ako

$$\left( \sum_{j=1}^J a_j \bar{Y}_{..} - t_{df_w}(\alpha/2) \sqrt{\sum_{j=1}^J \frac{a_j^2 s_j^2}{n_j}}, \sum_{j=1}^J a_j \bar{Y}_{..} + t_{df_w}(\alpha/2) \sqrt{\sum_{j=1}^J \frac{a_j^2 s_j^2}{n_j}} \right).$$

**Waldove simultánne**  $100 \times (1 - \alpha)\%$  **empirické intervaly spoľahlivosti Scheffeho typu** definujeme ako

$$\left( \mathbf{a}^T \widehat{\boldsymbol{\mu}} - \sqrt{(J-1)F_{J-1, df_w}(\alpha)} \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \widehat{\boldsymbol{\mu}} + \sqrt{(J-1)F_{J-1, df_w}(\alpha)} \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}} \right),$$

kde  $\widehat{\boldsymbol{\Sigma}} = \mathbf{S} = \text{diag}(s_1^2, s_2^2, \dots, s_J^2)$ .

## Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rôznych rozptyloch

**Waldove simultánne**  $100 \times (1 - \alpha)\%$  **empirické intervaly spoľahlivosti Tukeyho typu** definujeme ako

$$\left( \mathbf{a}^T \widehat{\boldsymbol{\mu}} - q_{J, df_w}(\alpha) \sqrt{\frac{1}{2} \mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \widehat{\boldsymbol{\mu}} + q_{J, df_w}(\alpha) \sqrt{\frac{1}{2} \mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}} \right).$$

**Waldove simultánne**  $100 \times (1 - \alpha)\%$  **empirické intervaly spoľahlivosti Fisherovo typu** definované nasledovne

$$\left( \mathbf{a}^T \widehat{\boldsymbol{\mu}} - t_{df_w}(\alpha_k) \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}}, \mathbf{a}^T \widehat{\boldsymbol{\mu}} + t_{df_w}(\alpha_k) \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}} \right).$$

## Asymptotické testy o stredných hodnotách

ANOVA model v 

Funkciu `oneway.test()` je možné použiť aj v prípade, že rozptyly nie sú rovnaké, ak nastavíme argument `var.equal=FALSE`.

### Mnohonásobné porovnávania v

Na jednokrokové a viackrokové metódy (výpočet adjustovaných p-hodnôt) použijeme podobne ako predtým funkciu

`pairwise.t.test(y, x, p.adjust="metoda")`, avšak argument `pool.sd=FALSE`.

### Example (Tukeyho HSD metóda)

Naprogramujte v  Tukeyho HSD metódu za predpokladu nerovnosti rozptylov.

## Asymptotické testy o stredných hodnotách

Test pomerom viero hodnosti o rovnosti stredných hodnôt

Nech  $Y_j \sim N(\mu_j, \sigma^2)$ , kde  $j = 1, 2, \dots, J$  a  $\sigma^2$  je neznáma. Logaritmus funkcie viero hodnosti má tvar

$$l(\theta | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \mu_j)^2,$$

kde  $n = \sum_{j=1}^J n_j$ . MLE  $\theta$  je rovný  $\hat{\theta} = (\hat{\mu}_1, \hat{\mu}_2, \dots, \hat{\mu}_J, \hat{\sigma}^2)^T$ , kde

$$\hat{\mu}_j = \bar{y}_j, \hat{\sigma}^2 = \frac{1}{n} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2,$$

t.j.  $\Theta_1 = \{\theta : \mu_i \neq \mu_j; i < j, i = 1, 2, \dots, J-1; j = 2, 3, \dots, J\}$  pre aspoň jedno  $i$  a  $j$ . Za platnosti  $H_0$  je  $\hat{\theta}_0 = (\hat{\mu}, \hat{\mu}, \dots, \hat{\mu}, \hat{\sigma}_0^2)^T$  platí

$$\bar{x} = \hat{\mu} = \frac{1}{n} \sum_{j=1}^J \sum_{i=1}^{n_j} y_{ji}, \hat{\sigma}_0^2 = \frac{1}{n} \sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \hat{\mu})^2.$$

## Asymptotické testy o stredných hodnotách

### Test pomerom viero hodnosti o rovnosti stredných hodnôt

Tiež platí  $\Theta_0 = \{\theta : \mu_1 = \mu_2 = \dots = \mu_J = \mu\}$ . Potom  $-1$  krát prirodzený logaritmus pomeru viero hodnosti bude rovný

$$-\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J)) = \frac{n}{2} \ln\left(\frac{\hat{\sigma}_0^2}{\tilde{\sigma}^2}\right)$$

### Vieme, že testovacia štatistika pomerom viero hodnosti

$U_{LR} = -2 \ln(\lambda(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_J)) \stackrel{D}{\sim} \chi_{J-1}^2$ , kde  $H_0$  bude zamietnutá pre veľké hodnoty podielu  $\frac{\hat{\sigma}_0^2}{\tilde{\sigma}^2}$ . Dá sa ukázať, že  $-\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J))$  je rastúcou funkciou  $F_{obs}$ . Úpravou podielu  $\hat{\sigma}_0^2/\tilde{\sigma}^2$  dostaneme

$$\begin{aligned} -\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J)) &= \frac{n}{2} \ln\left(\frac{\sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} \pm \bar{y}_j - \hat{\mu})^2}{\sum_{j=1}^J \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2}\right) \\ &= \frac{n}{2} \ln\left(1 + \frac{J-1}{n-J} F_{obs}\right). \end{aligned}$$

Potom môžeme  $U_{LR}$  prepísat

$$u_{LR} = n \ln\left(1 + \frac{J-1}{n-J} F_{obs}\right).$$

## Asymptotické testy o stredných hodnotách

### Test pomerom viero hodnosti o homogenite rozptylov

Hypotézy definujeme nasledovne  $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma^2$  oproti  $H_1 : \sigma_i^2 \neq \sigma_j^2 \neq \sigma^2$  pre aspoň jedno  $i < j, i = 1, 2, \dots, J-1; j = 2, 3, \dots, J$ .

Nech  $Y_j \sim N(\mu_j, \sigma_j^2)$ , kde  $j = 1, 2, \dots, J$ ,  $\theta = (\mu_1, \mu_2, \dots, \mu_J, \sigma_1^2, \sigma_2^2, \dots, \sigma_J^2)^T$ . Logaritmus funkcie viero hodnosti má tvar

$$l(\theta | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) = -\sum_{j=1}^J \frac{n_j}{2} \ln(2\pi\sigma_j^2) - \sum_{j=1}^J \frac{1}{2\sigma_j^2} \left( \sum_{i=1}^{n_j} (y_{ji} - \mu_j)^2 \right).$$

MLE  $\theta$  je rovný  $\hat{\theta} = (\hat{\mu}_1, \hat{\mu}_2, \dots, \hat{\mu}_J, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \dots, \hat{\sigma}_J^2)^T$ , kde

$$\hat{\mu}_j = \bar{y}_j, \hat{\sigma}_j^2 = \frac{1}{n_j} \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_j)^2,$$

t.j.  $\Theta_1 = \{\theta : \sigma_i^2 \neq \sigma_j^2 \neq \sigma^2; i < j, i = 1, 2, \dots, J-1; j = 2, 3, \dots, J\}$  pre aspoň jedno  $i$  a  $j$ .

## Asymptotické testy o stredných hodnotách

Test pomerom vierošodnosti o homogenite rozptylov

Za platnosti  $H_0$  je  $\theta_0 = (\hat{\mu}_1, \hat{\mu}_2, \dots, \hat{\mu}_J, \tilde{\sigma}^2, \tilde{\sigma}^2, \dots, \tilde{\sigma}^2)^T$ , kde

$$\tilde{\sigma}^2 = \frac{\sum_{j=1}^J n_j \hat{\sigma}_j^2}{\sum_{j=1}^J n_j},$$

t.j.  $\Theta_0 = \{\theta : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_J^2 = \sigma^2\}$ . Potom  $-1$  krát prirodzený logaritmus pomeru vierošodnosti bude potom rovný

$$\begin{aligned} -\ln(\lambda(\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J)) &= I(\hat{\theta} | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) - I(\theta_0 | \mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_J) \\ &= \frac{1}{2} \sum_{j=1}^J n_j \ln \left( \frac{\sum_{j=1}^J n_j \hat{\sigma}_j^2}{\hat{\sigma}_j^2 \sum_{j=1}^J n_j} \right) = \frac{1}{2} \sum_{j=1}^J n_j \ln \left( \frac{\tilde{\sigma}^2}{\hat{\sigma}_j^2} \right). \end{aligned}$$

Vieme, že **testovacia štatistika pomerom vierošodnosti**

$U_{LR} = -2 \ln(\lambda(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_J)) \stackrel{D}{\sim} \chi_{J-1}^2$ . Realizáciou  $U_{LR}$  je  $u_{LR}$ .  
Potom p-hodnota =  $\Pr(U_{LR} \geq u_{LR} | H_0)$ .

## Asymptotické testy o stredných hodnotách

Bartlettova modifikácia testu pomerom vierošodnosti o homogenite rozptylov 

Argumenty (vstupy) funkcie `bartlett.test()`:

1. `x` – objekt `lm(y~x)` alebo len vektor pozorovaní `y`;
2. `g` – vektor príslušnosti do skup in `x`, ak (1) je vektor pozorovaní `y`, inak nie je potrebné tento argument uvádzat;
3. `formula` v podobe `y~x`, ak nie je uvedené (1) a (2);
4. `data` v podobe dátovej tabuľky, ak (1) až (3) používajú stĺpce z dátovej tabuľky.

Výstupy funkcie `bartlett.test()`:

1. `statistic` – Bartlettova štatistika  $U_{LR}^{(alt)}$ ;
2. `df` – stupňe voľnosti  $J - 1$ ;
3. `p.value` – p-hodnota.

## Asymptotické testy o stredných hodnotách

Bartlettova modifikácia testu pomerom vierošodnosti o homogenite rozptylov

Bartlett (1937) modifikoval testovaciu štatistiku pomerom vierošodnosti nasledovne

$$U_B = \frac{U_{LR}^{(alt)}}{C} \stackrel{D}{\sim} \chi_{J-1}^2,$$

kde

$$U_{LR}^{(alt)} = \sum_{j=1}^J (n_j - 1) \ln \left( \frac{\tilde{S}^2}{S_j^2} \right), \tilde{S}^2 = \frac{\sum_{j=1}^J (n_j - 1) S_j^2}{\sum_{j=1}^J (n_j - 1)},$$

$S_j^2$  sú výberové rozptyly a

$$C = 1 + \frac{1}{3(J-1)} \left( \sum_{j=1}^J \frac{1}{n_j - 1} - \frac{1}{\sum_{j=1}^J (n_j - 1)} \right).$$

$U_B$  konverguje ku  $\chi_{J-1}^2$  rozdeleniu rýchlejšie ako  $U_{LR}$ . Realizáciou  $U_B$  je  $u_B$ .  
Potom p-hodnota =  $\Pr(U_B \geq u_B | H_0)$ .

## Asymptotické testy o stredných hodnotách

Literatúra

KATINA, Stanislav, Miroslav KRÁLIK a Adéla HUPKOVÁ. **Aplikovaná štatistická inferencia I. Biologická antropológia očami matematickej štatistiky**. 1. vyd. Brno: Masarykova univerzita, 2015. 320 s. ISBN 978-80-210-7752-2.