

Lineárne štatistické modely II

Modely analýzy rozptylu

Stanislav Katina¹

¹Ústav matematiky a statistiky
Přírodovědecká fakulta
Masarykova univerzita

jarný semester 2017
Verzia 12. apríla 2017

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 σ_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 $\mu = \sum_{j=1}^J \mu_j / J$, $\mu_j = \mu + \alpha_j$, $\sum_{j=1}^J n_j \alpha_j = 0$ (**podmienka**

identifikateľnosti zaručuje odhadnuteľnosť μ a α_j), μ je **celková (spoločná) úroveň spoločnej všetkým populáciám** (alebo **celková stredná hodnota**), α_j je **j-ta úroveň faktora A (j-ty efekt faktora A)** a znamená odchyliku strednej hodnoty j-tej populácie od μ . Pre iid chyby ε_{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 $H_1: \text{existuje aspoň jedno } i < j \text{ také, že } \mu_i \neq \mu_j \text{ (} i = 1, 2, \dots, J-1; j = 1, 2, \dots, J \text{)}$.

Ak H_0 platí, potom $\alpha_1 = \alpha_2 = \dots = \alpha_J = 0$, dostaneme submodel, ozn. \mathcal{F}_{H_0} , definovaný ako

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

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

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

Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

Ak H_0 platí,

$$F_W = \frac{\frac{SS_A}{df_A}}{\frac{SS_e}{df_e}} \stackrel{D}{\sim} F_{df_A, df_e},$$

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.

Nech $\hat{\mu} = \bar{Y}_{..} = Y_{..}/n$ je maximálne vieročodný odhad μ , $Y_{..} = \sum_{j=1}^J \sum_{i=1}^{n_j} Y_{ji}$, $\hat{\mu}_j = \bar{Y}_{j.} = Y_{j.}/n_j$ je maximálne vieročodný odhad μ_j , $Y_{j.} = \sum_{i=1}^{n_j} Y_{ji}$, $\hat{\alpha}_j = \bar{Y}_{j.} - \bar{Y}_{..}$. Ak máme využavené triedenie, podmienka identifikateľnosti $\sum_{j=1}^J n_j \alpha_j = 0$ sa redukuje na $\sum_{j=1}^J \alpha_j = 0$.

SS_A je **výberový súčet štvorcov rozdielov medzi súbormi** a je definovaný ako

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

Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

SS_e je **výberový súčet štvorcov rozdielov vnútri súborov** a je definovaný ako

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

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

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

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 $df_T = n - 1$, $df_A = J - 1$, $df_e = n - J$.

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_{obs} a p-hodnota $= \Pr(F_W \geq F_{\text{obs}} | H_0)$.

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

Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rovnakých rozptyloch

Sumy štvorcov sa najčastejšie zapisujú do **ANOVA tabuľky**:

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi	$SS_{A,\text{obs}}$	df_A	$MS_{A,\text{obs}} = SS_{A,\text{obs}}/df_A$
vnútri súborov	$SS_{e,\text{obs}}$	df_e	$MS_{e,\text{obs}} = SS_{e,\text{obs}}/df_e$
celkovo	$SS_{T,\text{obs}}$	df_T	$MS_{e,\text{obs}} = \hat{\sigma}_e^2 = s^2$

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 zapisať 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 ε je n -rozmerný **vektor chýb**. Potom model \mathcal{F}_{H_1} bude mať tvar

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_J \end{pmatrix} = \mathbf{X}\beta + \varepsilon = \begin{pmatrix} \mathbf{1}_{n_1} & \mathbf{1}_{n_1} & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{1}_{n_2} & \mathbf{0} & \mathbf{1}_{n_2} & \dots & \mathbf{0} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \mathbf{1}_{n_J} & \mathbf{0} & \mathbf{0} & \dots & \mathbf{1}_{n_J} \end{pmatrix} \begin{pmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_J \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_J \end{pmatrix},$$

kde $\mathbf{Y}_j = (Y_{j1}, Y_{j2}, \dots, Y_{jn_j})^T$ je n_j -rozmerný vektor, $\mathbf{1}_{n_j}$ je n_j -rozmerný vektor jednotiek a ε_j je n_j -rozmerný vektor chýb. Potom $\mathbf{Y}_j \sim N_{n_j}(\beta_j \mathbf{1}_{n_j}, \sigma_e^2 \mathbf{I}_{n_j \times n_j})$, vektor chýb $\varepsilon_j \sim N_{n_j}(\mathbf{0}_{n_j}, \sigma_e^2 \mathbf{I}_{n_j \times n_j})$, 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. $\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}$. Ďalej, ak nebude uvedené inak, \mathbf{X} bude **matica plánu** s rozmermi $n \times J$ (teda pôvodná matica \mathbf{X} bez prvého stĺpca).

Asymptotické testy o stredných hodnotách

ANOVA model v 

Model \mathcal{F}_{H_0} bude mať tvar

$$\mathbf{Y} = \begin{pmatrix} \mathbf{Y}_1 \\ \mathbf{Y}_2 \\ \vdots \\ \mathbf{Y}_J \end{pmatrix} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \begin{pmatrix} \mathbf{1}_{n_1} \\ \mathbf{1}_{n_2} \\ \vdots \\ \mathbf{1}_{n_J} \end{pmatrix} \mu + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_J \end{pmatrix}.$$

9 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v 

Výstupy funkcie `summary(aov())`:

- ➊ 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]`;
- ➋ realizáciu testovacej štatistiky F_{obs} `summary(MODEL) [[1]] [1, 4]`;
- ➌ p-hodnota `summary(aov()) [[1]] [1, 5]`.

Funkcia `aov()` používa na výpočty funkciu lineárny regresný model `lm()`. Pri priamom použití funkcie `lm()` dostaneme ANOVA tabuľku ako `anova(lm())`. Odmocinu 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.

11 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v 

Argumenty (vstupy) funkcie `aov()`:

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

Výstupy funkcie `aov()`:

- ➊ tabuľky s rozmermi $n \times 3$ obsahujúca odhady $\hat{\mu}$, $\hat{\alpha}_j$ a reziduály ε_{ji} , `projections`;
- ➋ odhady \hat{y}_{ji} `fitted.values`;
- ➌ reziduály ε_{ji} `residuals`.

10 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v 

Príklad (ANOVA F-test)

Majme koncentráciu stroncia 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 stroncia 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	

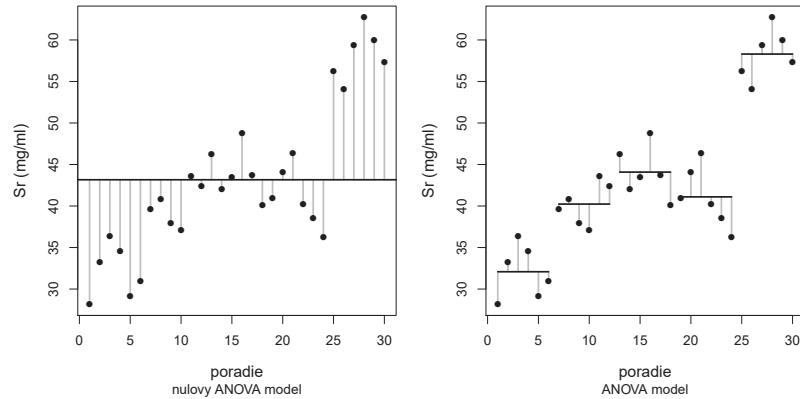
12 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v 



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 rovné – $\bar{y}_1 - \bar{y} = -11.08$, $\bar{y}_2 - \bar{y} = -2.93$, $\bar{y}_3 - \bar{y} = 0.92$, $\bar{y}_4 - \bar{y} = -2.06$ 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	$SS_{T,obs} \doteq 2437.572$	$n - 1 = 29$	

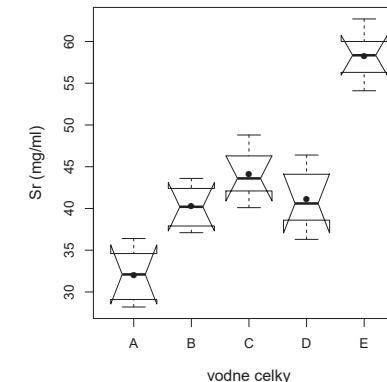
Z ANOVA tabuľky vypočítame $F_W \doteq 56.2$, čo je väčšie ako $F_{J-1,n-J}(\alpha) = F_{4,25}(0.05) \doteq 2.76$ (p-hodnota $\ll 0.05$), t.j. H_0 zamietame na $\alpha = 0.05$.

Príklad (ANOVA F-test)

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

Asymptotické testy o stredných hodnotách

ANOVA model v , funkcia `boxplot()`



Obr.: Krabicové diagramy pre ANOVA model \mathcal{F}_{H_1}

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

```

Asymptotické testy o stredných hodnotách

ANOVA model v 

```
19 StrMOD01 <- aov(ConcStr~VodCelk)
20 summary(StrMOD01) # ANOVA tabulka
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 tabulka
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 ***
```

17 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v 

Pozor, týmto spôsobom dostaneme inú *F*-štatistiku a teda aj inú p-hodnotu !

```
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)$sig)^2 # 9.7652; MSE
65 summary(StrMOD03)$coef # efekty faktora VodCelk (cela tabulka)
66 sqrt((summary(StrMOD03)$sig)^2/K) # 1.27575; odmocnina z (MSe/K)
67 2*pt(summary(StrMOD03)$coeff[2,3],df=K*J-J) # 0.03046675
68 2*pt(-2.294,df=K*J-J) # 0.03046675
```

19 / 100

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
```

18 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v 

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

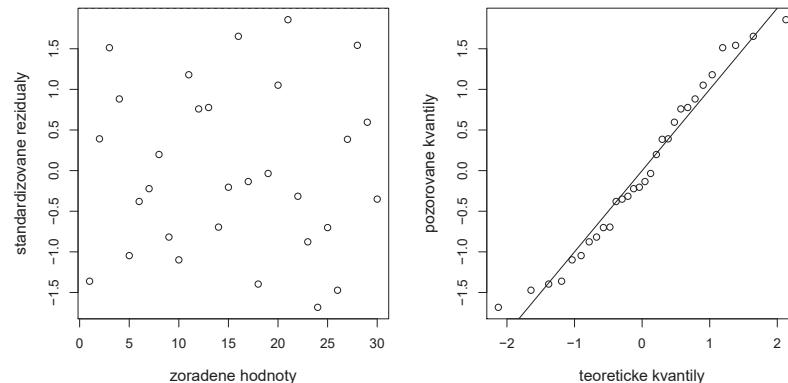
20 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

Regresná diagnostika v funkcia `stdres()` a iné



Obr.: Regresná diagnostika v ANOVA modeli

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania

Vo všeobecnosti však môžeme prepokladať, že H_0 generuje podpriestor s hodnosťou h . Potom definujme $H_0 = \bigcap_{k=1}^h H_{0k}$, 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 μ_J) a ostatné majú byť porovnávané len s touto kontrolou populáciou a nie medzi sebou, potom volíme $h = J - 1$ a zaujímame sa len napr. o rozdiely tvaru $|\bar{y}_j - \bar{y}_{J-1}|$, kde $j = 1, 2, \dots, J-1$. Najprv testujeme H_0 viacvýberovým ANOVA F -testom na hladine významnosti α použitím ANOVA F -štatistiky. Ak H_0 nezamietame, nepokračujeme ďalej. Ak H_0 zamietame, chceme identifikovať, ktorú z hypotéz $\mathbf{a}^\top \boldsymbol{\mu} = \mathbf{a}^\top \boldsymbol{\mu}_0 = 0$, kde $\boldsymbol{\mu} = (\mu_1, \dots, \mu_J)^\top$, 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.

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 α . Možeme 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 ε_{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

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

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

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – matica kontrastov \mathbf{A}

Pre $H_{0ij} : \mu_i = \mu_j, i < j$ ($i = 1, 2, \dots, J-1; j = 1, 2, \dots, J$), bude **vektor (základných) kontrastov** \mathbf{a}_k mať na i -tom mieste 1, na j -tom mieste -1, ostatné sú nuly, napr.

$$\mathbf{a}_1 = (1, -1, 0, \dots, 0)^\top, \mathbf{a}_2 = (0, 1, -1, \dots, 0)^\top, \dots, \mathbf{a}_{J-1} = (0, 0, \dots, 1, -1)^\top,$$

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

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

kde $\mathbf{a}_k, k = 1, 2, \dots, h = J - 1$, sú riadky matice \mathbf{A} .

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – matica kontrastov \mathbf{A}

Preznačme $(J + 1)$ -rozmerný vektor $\beta = (\mu, \alpha^T)^T$, kde $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_J)^T$ na J -rozmerný vektor $\beta = \mu$. Označme \mathbf{A} bez prvého stĺpca ako \mathbf{A} , t.j. ide o maticu $(J - 1) \times J$. Potom $H_0 : \mathbf{A}\beta = \mathbf{a}_0 = \mathbf{0}$ oproti $H_1 : \mathbf{A}\beta \neq \mathbf{a}_0 = \mathbf{0}$. Napr.

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

Ďalším príkladom matice kontrastov \mathbf{A} je

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

V sa matica \mathbf{A}^T označuje ako `contr.sum(J)`.

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – matica kontrastov \mathbf{A}

Matica kontrastov \mathbf{A} môže byť definovaná aj ako matica kontrastov pre rozdiely $\mu_1 - \mu_j$, t.j.

$$\mathbf{A}^T = \begin{pmatrix} 0 & 0 & 0 & \dots & 0 \\ 1 & 0 & 0 & \dots & 0 \\ 0 & 1 & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{pmatrix}.$$

V sa matica \mathbf{A}^T označuje ako `contr.treatment(J)`. **Nie je to matica skutočných kontrastov**. Prvý element β zodpovedá pôvodnej základnej strednej hodnote μ_1 a je nulový ($\beta_1 = \mu_1 - \mu_1$), ostatné úrovne sú $\beta_2 = \mu_2 - \mu_1 = \alpha_2 - \alpha_1, \dots, \beta_J = \mu_J - \mu_1 = \alpha_J - \alpha_1$. **Pozor, ide o kódovanie v a β vyšše nezodpovedá nami zavedenej β na slajde 24.**

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – matica kontrastov \mathbf{A}

Ďalším príkladom matice kontrastov \mathbf{A} je

$$\mathbf{A}^T = \begin{pmatrix} -1 & -1 & -1 & \dots & -1 \\ 1 & -1 & -1 & \dots & -1 \\ 0 & 2 & -1 & \dots & -1 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & J-1 \end{pmatrix}, \mathbf{A}\beta = \begin{pmatrix} -\alpha_1 + \alpha_2 \\ -\alpha_1 - \alpha_2 + 2\alpha_3 \\ \vdots \\ -\alpha_1 - \dots - \alpha_{J-1} + (J-1)\alpha_J \end{pmatrix}.$$

V sa matica \mathbf{A}^T označuje ako `contr.helmert(J)`, t.j. **Helmertova matica**. Pre Helmertove kontrasty potom pre $j = 1, 2, \dots, J-1$ platí

$$\frac{1}{j(j+1)} \left(j\alpha_{j+1} - \sum_{t=1}^j \alpha_t \right) = \frac{1}{j+1} \left(\alpha_{j+1} - \frac{1}{j} \sum_{t=1}^j \alpha_t \right) = \frac{1}{j+1} \left(\mu_{j+1} - \frac{1}{j} \sum_{t=1}^j \mu_t \right).$$

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – matica kontrastov \mathbf{A}

Preznačme $\mathbf{A}^T = \mathbf{A}_*$ a $\mathbf{A}^T = (\mathbf{a}_0, \mathbf{A}_*)$, kde \mathbf{a}_0 je tzv. **(jednoduchý priemerujúci vektor**, kde $\mathbf{a}_0^T \mathbf{1}_J = 1$. Platí $\tilde{\beta} = \mathbf{A}\beta$, kde $\mathbf{A}\beta$ je J -rozmerný vektor. $\mathbf{A}^{-1}\tilde{\beta} = \beta$, kde $\mathbf{A}^{-1} = \mathbf{B}$. Matica $\tilde{\mathbf{X}} = \mathbf{X}\mathbf{B}$ je nová matica plánu a $\tilde{\beta}$ sú nové regresné koeficienty s prvým stĺpcom pre **intercept** β_0 , kde $\tilde{\beta} = (\beta_0, \tilde{\beta}_*)^T$. Nulová hypotéza $\mu_1 = \mu_2 = \dots = \mu_J$ je pravdivá vtedy a len vtedy, keď $\tilde{\beta}_* = \mathbf{0}_{J-1}$. Nech $\mathbf{B} = (\mathbf{1}_J, \mathbf{B}_*)$, kde $J \times (J-1)$ nesingulárna (regulárna) matica \mathbf{B}_* sa nazýva **kódovacia matica (coding matrix)**. nesprávne pomenováva pojmom matica kontrastu `contrasts()` práve tieto matice \mathbf{B}_* . Platí nasledovné $(\mathbf{A}_*^T \mathbf{A}_*)^{-1} \mathbf{A}_*^T = \mathbf{B}_*$. a naviac $\mathbf{B}_* \tilde{\beta}_* = \alpha$. Napr. pre Helmertove kontrasty $\mathbf{A}_*^T \mathbf{A}_*$ má na diagonále prvky $j(j+1) = j^2 + j$ a $\tilde{\beta}_j = j\alpha_{j+1} - \sum_{t=1}^j \alpha_t$.

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – matica kontrastov \mathbf{A}

Nech $\mathbf{D} = \text{diag}(n_1, n_2, \dots, n_J) = \mathbf{X}^T \mathbf{X}$ a $\mathbf{n} = (n_1, n_2, \dots, n_J)^T$.

$$\mathbf{a}^T \hat{\beta} \sim N\left(\mathbf{a}^T \boldsymbol{\beta}, \sigma_e^2 \mathbf{a}^T \mathbf{D}^{-1} \mathbf{a}\right), \mathbf{a}^T \hat{\beta} \sim N\left(\sum_{j=1}^J \mathbf{a}_j \alpha_j, \sigma_e^2 \sum_{j=1}^J \frac{\mathbf{a}_j^2}{n_j}\right)$$

Nech $\mathbf{A}^T = (\mathbf{1}_J, \mathbf{A}_*)$. Potom

$$\widehat{\text{Var}}[\hat{\beta}] = \widehat{\sigma}_e^2 \left(\mathbf{A}^T \mathbf{D} \mathbf{A} \right)^{-1} = \sigma_e^2 \left(\begin{matrix} n & \mathbf{1}_J^T \mathbf{D} \mathbf{A}_* \\ \mathbf{A}_*^T \mathbf{D} \mathbf{1}_J & \mathbf{A}_*^T \mathbf{D} \mathbf{A}_* \end{matrix} \right)^{-1} = \widehat{\sigma}_e^2 \left(\begin{matrix} n & \mathbf{n}^T \mathbf{A}_* \\ \mathbf{A}_*^T \mathbf{n} & \mathbf{A}_*^T \mathbf{D} \mathbf{A}_* \end{matrix} \right)^{-1}$$

Ak ide o **ortogonálne kontrasty**, potom $\mathbf{A}_*^T \mathbf{1}_J = \mathbf{0}$ a $\mathbf{A}_*^T \mathbf{A}_*$ je diagonálna. Ak $n_j = K$, potom $\mathbf{n} = K \mathbf{1}_J$ a $\mathbf{D} = K \mathbf{I}$.

Model \mathcal{F}_{H_1} v tvare $\mathbf{Y} = \mathbf{X} \boldsymbol{\beta} + \boldsymbol{\epsilon}$ sme prepísali (**reparametrizovali**) do tvaru

$\mathbf{Y} = \tilde{\mathbf{X}} \tilde{\boldsymbol{\beta}} + \boldsymbol{\epsilon}$, kde

$$\mathbf{X} \boldsymbol{\beta} = \tilde{\mathbf{X}} \tilde{\boldsymbol{\beta}} \text{ a } \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T = \tilde{\mathbf{X}} (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T.$$

Príklad (Matice kontrastov)

Aplikujte vyššie spomínané matice kontrastov na ANOVA model pre dátá koncentrácia stronca pomocou funkcie `contrasts()` a `aov()`.

29/100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v R – matica kontrastov \mathbf{A}

$$\mathbf{A}^T = \begin{pmatrix} 1/5 & 1 & 0 & 0 & 0 \\ 1/5 & 0 & 1 & 0 & 0 \\ 1/5 & 0 & 0 & 1 & 0 \\ 1/5 & 0 & 0 & 0 & 1 \\ 1/5 & -1 & -1 & -1 & -1 \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_J \end{pmatrix}, \mathbf{A} \boldsymbol{\beta} = \begin{pmatrix} \mu \\ \mu_1 - \mu_5 \\ \mu_2 - \mu_5 \\ \mu_3 - \mu_5 \\ \mu_4 - \mu_5 \end{pmatrix}.$$

```

88 | tA <- rbind(diag(4), rep(-1,4)) # ekviv. contr.sum(5)
89 | tA <- cbind(rep(1/5,5),tA)
90 | B <- solve(t(tA)); Bstar <- B[,2:5]
91 | contrasts(VodCelk) <- Bstar
92 | StrMOD02 <- aov(ConcStr~ VodCelk)
93 | summary.lm(StrMOD02)
94 | # Estimate Std. Error t value Pr(>|t|)
95 | # (Intercept) 43.1600 0.5705 75.649 < 2e-16 ***
96 | # VodCelk1 -26.2167 1.8042 -14.531 1.07e-13 ***
97 | # VodCelk2 -18.0667 1.8042 -10.014 3.12e-10 ***
98 | # VodCelk3 -14.2167 1.8042 -7.880 3.09e-08 ***
99 | # VodCelk4 -17.2000 1.8042 -9.533 8.34e-10 ***
100 | tA <- contr.sum(5); t(tA) %*% PRIEM.ConcStr
101 | # -26.21667 -18.06667 -14.21667 -17.2

```

31/100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v R – matica kontrastov \mathbf{A}

$$\mathbf{A}^T = \begin{pmatrix} 1/5 & -1 & -1 & -1 & -1 \\ 1/5 & 1 & 0 & 0 & 0 \\ 1/5 & 0 & 1 & 0 & 0 \\ 1/5 & 0 & 0 & 1 & 0 \\ 1/5 & 0 & 0 & 0 & 1 \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_J \end{pmatrix}, \mathbf{A} \boldsymbol{\beta} = \begin{pmatrix} \mu \\ \mu_2 - \mu_1 \\ \mu_3 - \mu_1 \\ \mu_4 - \mu_1 \\ \mu_5 - \mu_1 \end{pmatrix}.$$

```

75 | tA <- rbind(rep(-1,4), diag(4))
76 | tA <- cbind(rep(1/5,5),tA)
77 | B <- solve(t(tA))
78 | Bstar <- B[,2:5]
79 | contrasts(VodCelk) <- Bstar
80 | StrMOD02 <- aov(ConcStr~ VodCelk)
81 | summary.lm(StrMOD02)
82 | # Estimate Std. Error t value Pr(>|t|)
83 | # (Intercept) 43.1600 0.5705 75.649 < 2e-16 ***
84 | # VodCelk1 8.1500 1.8042 4.517 0.00013 ***
85 | # VodCelk2 12.0000 1.8042 6.651 5.72e-07 ***
86 | # VodCelk3 9.0167 1.8042 4.998 3.75e-05 ***
87 | # VodCelk4 26.2167 1.8042 14.531 1.07e-13 ***

```

30/100 Stanislav Katina Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v R – matica kontrastov \mathbf{A}

$$\mathbf{A}^T = \begin{pmatrix} 1/5 & 1 & 0 & 0 & 0 \\ 1/5 & -1 & 1 & 0 & 0 \\ 1/5 & 0 & -1 & 1 & 0 \\ 1/5 & 0 & 0 & -1 & 1 \\ 1/5 & 0 & 0 & 0 & -1 \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_J \end{pmatrix}, \mathbf{A} \boldsymbol{\beta} = \begin{pmatrix} \mu \\ \mu_1 - \mu_2 \\ \mu_2 - \mu_3 \\ \mu_3 - \mu_4 \\ \mu_4 - \mu_5 \end{pmatrix}.$$

```

102 | tA <- matrix(c(1,-1,0,0,0,0,1,-1,0,0,0,0,1,-1,0,0,0,0,1,-1),5,4)
103 | tA <- cbind(rep(1/5,5),tA)
104 | B <- solve(t(tA))
105 | Bstar <- B[,2:5]
106 | contrasts(VodCelk) <- Bstar
107 | StrMOD02 <- aov(ConcStr~ VodCelk)
108 | summary.lm(StrMOD02)
109 | # Estimate Std. Error t value Pr(>|t|)
110 | # (Intercept) 43.1600 0.5705 75.649 < 2e-16 ***
111 | # VodCelk1 -8.1500 1.8042 -4.517 0.00013 ***
112 | # VodCelk2 -3.8500 1.8042 -2.134 0.04284 *
113 | # VodCelk3 2.9833 1.8042 1.654 0.11072
114 | # VodCelk4 -17.2000 1.8042 -9.533 8.34e-10 ***

```

32/100 Stanislav Katina Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v – matica kontrastov A

```

115 tA <- contr.helmert(5)
116 tA <- cbind(rep(1/5,5),tA)
117 B <- solve(t(tA))
118 Bstar <- B[,2:5]
119 contrasts(VodCelk) <- Bstar
120 StrMOD02 <- aov(ConcStr~ VodCelk)
121 summary.lm(StrMOD02)
122 # Estimate Std. Error t value Pr(>|t|)
123 # (Intercept) 43.1600 0.5705 75.649 < 2e-16 ***
124 # VodCelk1 8.1500 1.8042 4.517 0.00013 ***
125 # VodCelk2 15.8500 3.1249 5.072 3.09e-05 ***
126 # VodCelk3 6.9000 4.4193 1.561 0.13102
127 # VodCelk4 75.7000 5.7053 13.268 8.09e-13 ***
128 tA <- contr.helmert(5)
129 t(tA) %*% PRIEM.ConcStr
130 # 8.15 15.85 6.9 75.7
131
132 # Poznamky
133 sqrt(MSe.obs/6) # sqrt(9.7652/6)=1.275748 (StrMOD03)
134 sqrt(MSe.obs*(1/6+1/6)) # sqrt(3.255067)=1.80418
135 sqrt(MSe.obs*(1/30)) # sqrt(0.3255067)=0.5705319

```

33 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

ANOVA model v – matica kontrastov A

Asymptotické testy o stredných hodnotách

ANOVA model v – matica kontrastov A

Nesprávny postup (dosadzujeme maticu kontrastov namiesto jej inverzie):

```

136 contrasts(VodCelk) <- contr.treatment(5)
137 StrMOD02 <- aov(ConcStr~ VodCelk)
138 summary.lm(StrMOD02)
139 # Estimate Std. Error t value Pr(>|t|)
140 # (Intercept) 32.083 1.276 25.149 < 2e-16 ***
141 # VodCelk2 8.150 1.804 4.517 0.00013 ***
142 # VodCelk3 12.000 1.804 6.651 5.72e-07 ***
143 # VodCelk4 9.017 1.804 4.998 3.75e-05 ***
144 # VodCelk5 26.217 1.804 14.531 1.07e-13 ***
145 contrasts(VodCelk) <- contr.sum(5)
146 StrMOD02 <- aov(ConcStr~ VodCelk)
147 summary.lm(StrMOD02) # odhady su prve styri urovne alfa
148 # Estimate Std. Error t value Pr(>|t|)
149 # (Intercept) 43.1600 0.5705 75.649 < 2e-16 ***
150 # VodCelk1 -11.0767 1.1411 -9.707 5.82e-10 ***
151 # VodCelk2 -2.9267 1.1411 -2.565 0.0167 *
152 # VodCelk3 0.9233 1.1411 0.809 0.4260
153 # VodCelk4 -2.0600 1.1411 -1.805 0.0831 .
154 round(PRIEM.str,4)
155 # A B C D E
156 # -11.0767 -2.9267 0.9233 -2.0600 15.1400

```

34 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – testovacie štatistiky

Nesprávny postup (dosadzujeme maticu kontrastov namiesto jej inverzie):

```

157 contrasts(VodCelk) <- contr.helmert(5)
158 StrMOD02 <- aov(ConcStr~ VodCelk)
159 summary.lm(StrMOD02) # dostaneme skutočne Helmertove kontrasty
160 # Estimate Std. Error t value Pr(>|t|)
161 # (Intercept) 43.1600 0.5705 75.649 < 2e-16 ***
162 # VodCelk1 4.0750 0.9021 4.517 0.00013 ***
163 # VodCelk2 2.6417 0.5208 5.072 3.09e-05 ***
164 # VodCelk3 0.5750 0.3683 1.561 0.13102
165 # VodCelk4 3.7850 0.2853 13.268 8.09e-13 ***
166 ## dostaneme skutočne Helmertove kontrasty
167 ## Preco?
168 tA <- contr.helmert(5)
169 solve(t(tA) %*% tA) %*% t(tA) %*% PRIEM.str
170 # 4.075 2.641667 0.575 3.785

```

35 / 100

Stanislav Katina

Lineárne štatistické modely II

36 / 100

Stanislav Katina

Lineárne štatistické modely II

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

$Var[\sum_{j=1}^J a_j \bar{Y}_j] = \sigma_e^2 \sum_{j=1}^J \frac{a_j^2}{n_j}$. 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 σ_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 $(n_j - 1)S_j^2/\sigma_e^2 \sim \chi_{n_j-1}^2$. Kedže 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

$$T_a = \frac{\mathbf{a}^T \hat{\mu} - \mathbf{a}^T \mu_0}{\sqrt{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}}} = \frac{\sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0}}{\sqrt{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}} \stackrel{D}{\sim} t_{n-J},$$

kde je matica plánu \mathbf{X} použitá bez prvého stĺpca (charakterizujúceho celkovú strednú hodnotu μ) a má preto rozmery $n \times J$. Realizáciou T_a je t_a , p-hodnota $= 2 \Pr(T_a \geq |t_a| | H_0)$ 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 – Scheffého metóda

Označme

$$T_a^2 = \frac{(\mathbf{a}^T \hat{\mu} - \mathbf{a}^T \mu_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} = \frac{\left(\sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0} \right)^2}{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}} = \frac{\left(\sum_{j=1}^J a_j (\bar{Y}_{j\cdot} - \mu_{j0}) \right)^2}{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}}.$$

Potom

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

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

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

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 – Scheffého metóda

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

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

Scheffé ukázal, že

$$F_a = \frac{(\mathbf{a}^T \hat{\mu} - \mathbf{a}^T \mu_0)^2}{S^2 \mathbf{a}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}} = \frac{\left(\sum_{j=1}^J a_j \bar{Y}_{j\cdot} - \sum_{j=1}^J a_j \mu_{j0} \right)^2}{S^2 \sum_{j=1}^J \frac{a_j^2}{n_j}} \stackrel{D}{\sim} (J - 1)F_{J-1, n-J},$$

kde H_0 zamietame, ak $F_a \geq (J - 1)F_{J-1, n-J}(\alpha)$, 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_a^2 , t.j. zamietame H_0 v ANOVA F - teste. F_a sa nazýva **Waldova testovacia štatistika**, často nazývaná aj **Scheffého štatistika** a test **viacvýberový Scheffého test nulovosti všetkých kontrastov**. Realizáciou F_a je $F_{a,\text{obs}}$ a (ajustovaná) p-hodnota $= \Pr(F_a \geq F_{a,\text{obs}} | H_0)$.

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Scheffého metóda

Waldove simultánne $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Scheffého 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 Scheffého typu oproti IS Fisherovho typu, t.j. keďže garantujeme simultánny koeficient spoľahlivosti $1 - \alpha$, simultánne IS Scheffého 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 Scheffého testy majú menšiu silu ako t -testy.

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

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

Príklad (Metódy mnohonásobného porovnávania)

Majme koncentráciu stronca Sr (mg/ml) v piatich vodných celkoch. (1) po náhľade na dátu vhodne zadefinujte kontrasty a aplikujte na ne Scheffého metódou; (2) použite Tukeyho HSD metódou (T_{HSD} štatistiku), vypočítajte adjustované p-hodnoty, simultánne 95% empirické IS Tukeyho typu pre všetky párové porovnania rozdielov stredných hodnôt a zobrazte ich graficky.

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania – Tukeyho HSD metóda

Tukey ukázal, že

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

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

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

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 v – Scheffého metóda

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

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

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

$$\bullet \quad \mathbf{a}_1 = (0, \frac{1}{3}, \frac{1}{3}, \frac{1}{3}, -1)^T, \mathbf{a}_1^T \hat{\boldsymbol{\mu}} \doteq -16.5, s^2 \mathbf{a}_1^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_1 = 1.47^2, \\ \sqrt{F_{a_1,obs}} \doteq 11.20,$$

$$\bullet \quad \mathbf{a}_2 = (1, -\frac{1}{3}, -\frac{1}{3}, -\frac{1}{3}, 0)^T, \mathbf{a}_2^T \hat{\boldsymbol{\mu}} \doteq -9.7, s^2 \mathbf{a}_2^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_2 = 1.47^2, \\ \sqrt{F_{a_2,obs}} \doteq 6.60,$$

$$\bullet \quad \mathbf{a}_3 = (\frac{1}{2}, -\frac{1}{3}, -\frac{1}{3}, -\frac{1}{3}, \frac{1}{2})^T, \mathbf{a}_3^T \hat{\boldsymbol{\mu}} \doteq 3.4, s^2 \mathbf{a}_3^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{a}_3 = 1.16^2, \\ \sqrt{F_{a_3,obs}} \doteq 2.91.$$

Scheffého kritická hodnota je rovná

$$\sqrt{(J-1) F_{J-1,n-J}(\alpha)} = \sqrt{4 F_{4,25}(0.05)} \doteq 1.34. \text{ Potom } H_{0k} : \mathbf{a}_k^T \boldsymbol{\mu} = 0 \text{ oproti } H_{1k} : \mathbf{a}_k^T \boldsymbol{\mu} \neq 0 \text{ zamietame, ak } k = 1, 2, 3.$$

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v – Scheffého metóda

```

171 K <- 6; J <- 5
172 X <- model.matrix(StrMOD03)
173 a1 <- c(0,1/3,1/3,1/3,-1)
174 a2 <- c(1,-1/3,-1/3,-1/3,0)
175 a3 <- c(1/2,-1/3,-1/3,-1/3,1/2)
176 matA <- rbind(a1,a2,a3)
177 t(a1) * %*% PRIEM.ConcStr # -16.49444
178 t(a2) * %*% PRIEM.ConcStr # -9.722222
179 t(a3) * %*% PRIEM.ConcStr # 3.386111
180 MSE.obs <- (summary(StrMOD03)$sig)^2
181 rozptyl.a1 <- MSE.obs*t(a1) * %*% solve(t(X) * %*% X) * %*% a1 # 2.17=1.47^2
182 rozptyl.a2 <- MSE.obs*t(a2) * %*% solve(t(X) * %*% X) * %*% a2 # 2.17=1.47^2
183 rozptyl.a3 <- MSE.obs*t(a3) * %*% solve(t(X) * %*% X) * %*% a3 # 1.36=1.16^2
184 kh.F <- sqrt((J-1) * (1-pf(0.95,J-1,K*J-J))) # 1.344368
185 abs(t(a1) * %*% PRIEM.ConcStr) / sqrt(rozptyl.a1) # 11.19704
186 abs(t(a2) * %*% PRIEM.ConcStr) / sqrt(rozptyl.a2) # 6.599807
187 abs(t(a3) * %*% PRIEM.ConcStr) / sqrt(rozptyl.a3) # 2.907548
188 IS.a1 <- t(a1) * %*% PRIEM.ConcStr + c(-1,1)*kh.F*sqrt(rozptyl.a1) #
-18.47484 -14.51405
189 IS.a2 <- t(a2) * %*% PRIEM.ConcStr + c(-1,1)*kh.F*sqrt(rozptyl.a2) #
-11.702620 -7.741825
190 IS.a3 <- t(a3) * %*% PRIEM.ConcStr + c(-1,1)*kh.F*sqrt(rozptyl.a3) #
1.820470 4.951753

```

45 / 100

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

47 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v – Tukeyho HSD metóda

```

192 # Tukeyho HSD metoda pre vybrany kontrast B-A
193 a.AB <- c(-1,1,0,0,0)
194 cit.AB <- sum(a.AB * PRIEM.ConcStr) # 8.15
195 MSE.obs <- (summary(StrMOD03)$sig)^2 # 9.7652
196 menov.AB <- sqrt(MSE.obs / 2 * sum(a.AB^2 / K)) # 1.275748
197 tLSD.AB <- citatel.AB / menovatelia.AB # 6.388408
198 qtukey(0.95, J, K * J - J) # 4.153363
199 p.hodn <- 1 - ptukey(tLSD.AB, J, K * J - J) # 0.001129311
200 IS.AB <- citatel.AB + c(-1, 1) * qtukey(0.95, J, K * J - J) * menov.AB
201 # 2.851355 13.448645
202 mp.Tukey <- TukeyHSD(aov(ConcStr ~ VodCelk), ordered = FALSE) # tab.
203 mp.Tukey$VodCelk

```

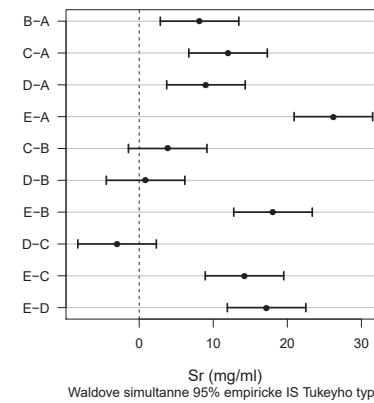
46 / 100

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

48 / 100

Stanislav Katina

Lineárne štatistické modely II

Asymptotické testy o stredných hodnotách

Párové porovnávania

Nech CHPD znamená **chyba prvého druhu** (testu jednej H_0). Potom

$$\Pr(\text{CHPD}) = \Pr(\text{zamietni } H_0 | H_0 \text{ neplatí}) \leq \alpha.$$

Definícia (chyba porovnávania α_c)

Chyba porovnávania (*comparison-wise error*, CWER) α_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.

Definícia (experimentálna chyba α_e)

Experimentálna chyba (*experiment-wise error*, EWER) α_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 α .

Asymptotické testy o stredných hodnotách

Párové porovnávania

Zamerajme sa na hodnotenie **zovšeobecnenej pravdepodobnosti CHPD** v podobe

- 1 **pravdepodobnosti najmenej jednej CHPD**, kde V je počet zamietnutých pravdivých H_{0k} (*family-wise error rate*, FWER: metódy napr. Fisherova LSD metóda, Tukeyho HSD metóda, Scheffého metóda, Bonferroniho metóda, Šidákova metóda, Holmova metóda, Hochbergova metóda); $\text{FWER} = \Pr(V \geq 1)$; **FWER adjustované (upravené) p-hodnoty** sú definované nasledovne

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

- 2 **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. Benjamini-Hochbergova metóda, Benjamini-Yekutieliho metóda); **FDR adjustované p-hodnoty** sú definované nasledovne

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

Asymptotické testy o stredných hodnotách

Párové porovnávania

Z definícií vyplýva, že $\Pr(\text{CHPD})$ jedného testu je rovná α_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 α_e je pravdepodobnosť, že nastane aspoň jedna CHPD medzi všetkými h nezávislými párovými porovnávaniami, môžeme ju definovať nasledovne

$$\alpha = \alpha_e = \Pr(V \geq 1) = 1 - \Pr(V = 0) = 1 - \alpha_c^h (1 - \alpha_c)^h = 1 - (1 - \alpha_c)^h.$$

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

Tabuľka: Experimentálna chyba α_e ako funkcia α_c a h

α_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

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. **Šidákova metóda** sú založené na princípe zmenšenia argumentu $\alpha/2$ kritickej hodnoty t -rozdelenia s $n - J$ stupňami volnosti (obojstranný test) na základe Bonferroniho, resp. Šidákovej nerovnosti,

$$\Pr(\bigcup_{k=1}^h A_k) \leq \sum_{k=1}^h \Pr(A_k), \quad \Pr(\bigcup_{k=1}^h A_k) \leq 1 - \alpha, \text{ resp.}$$

$$\Pr(\bigcap_{k=1}^h A_k) \geq \prod_{k=1}^h \Pr(A_k), \quad \Pr(\bigcap_{k=1}^h A_k) \geq 1 - \alpha, \text{ na } \alpha/(2h), \text{ resp.}$$

$$\frac{1 - (1 - \alpha)^{1/h}}{2}, \quad \text{kde } A_k \text{ je najaká udalosť. V druhej nerovnosti platí rovnosť ak sú } A_k \text{ nezávislé.}$$

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

$$(1 - \alpha)^{1/h} < 1 - \alpha/h \text{ pre všetky } \alpha > 0, h > 1, \text{ teda}$$
$$t_{n-J}(\alpha/h) > t_{n-J}(1 - (1 - \alpha)^{1/h}). \text{ Rozdiel je ale zanedbateľný.}$$

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

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

Asymptotické testy o stredných hodnotách

Párové porovnávania

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 α , t.j. ak sú všetky hypotézy pravdivé, pravdepodobnosť identifikácie, že niektorá z nich je nepravdivá, nie je viac ako α , pretože α 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 nastať situácia, že niektorá z vyššie spomenutých metód zamietne nejakú hypotézu. Práve pre túto vlastnosť je experimentálna chyba menšia ako α . Ale ak ANOVA F -test zamietá nulovú hypotézu, potom Scheffého metóda bude zamieťať H_0 aspoň pre jeden kontrast.

Asymptotické testy o stredných hodnotách

Párové porovnávania

Pre Šídákovu nerovnosť

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

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

Asymptotické testy o stredných hodnotách

Párové porovnávania

Adjustované hladiny významnosti α_k sú definované nasledovne

- Bonferroniho $\alpha_k = \frac{\alpha}{2h}$,
- Šídákove $\alpha_k = \frac{1 - (1 - \alpha)^{1/h}}{2}$,

Argument $\alpha/2$ kritickej hodnoty $t_{n-J}(\alpha/2)$ sa substituuje α_k . Potom budú **Waldove simultánne** $100 \times (1 - \alpha)\%$ empirické intervaly spoľahlivosti Fisherovho 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 $\tilde{p}_k = \min\{hp_k, 1\}$,
- Šídákove $\tilde{p}_k = 1 - (1 - p_k)^h$,

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, napr. Bonferronioho `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 α_j , použijeme vstupné argumenty `y-mean(y)` a `x-1` (argument `x-1` znamená model bez interceptu μ).

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

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

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v 

Príklad (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.test()` a (3) `lm()`. Ak je H_0 zamietnutá na $\alpha = 0.05$, potom vypočítajte adjustované p-hodnoty a Waldove simultánne 95% empirické IS Fisherovho typu pre všetky párové porovnania rozdielov stredných hodnôt Bonferronioho metódou.

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 $i \neq j$ ($i, j = 1, 2, \dots, J$) taká, že $\sigma_i^2 \neq \sigma_j^2$ a zároveň σ_j^2 sú neznáme. Potom F_W štatistika nemá F rozdelenie s $J - 1$ a $n - J$ stupňami volnosti a musí byť modifikovaná nasledovne (Welch 1951)

$$F_W = \frac{\frac{1}{J-1} \sum_{j=1}^J \widehat{w}_j \left(\bar{Y}_{j\cdot} - \bar{Y}_{..}^{(w)} \right)^2}{1 + 2 \sum_{j=1}^{J-2} \sum_{j=1}^J \frac{(1-\widehat{h}_j)^2}{n_j - 1}} = \frac{\sum_{j=1}^J \widehat{w}_j \left(\bar{Y}_{j\cdot} - \bar{Y}_{..}^{(w)} \right)^2}{J - 1 + 2 \sum_{j=1}^{J-2} \sum_{j=1}^J \frac{(1-\widehat{h}_j)^2}{n_j - 1}} \stackrel{D}{\sim} F_{J-1, df_{w_1}},$$

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

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

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

Príklad (homogenita vs nehomogenita rozptylov)

Čomu je rovné (A) $\bar{Y}_{..}^{(w)}$, (B) df_{w_1} a (C) F_W ak sú rozptyly homogénne?

Asymptotické testy o stredných hodnotách

Jednofaktorový ANOVA model s fixnými efektami pri rôznych rozptyloch

F_W sa nazýva **Fisherova testovacia štatistiká** (alebo presnejšie **Welchova ANOVA F -štatistiká**) 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_{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

$$s^2 = \frac{\sum_{j=1}^J (n_j - 1) s_j^2}{\sum_{j=1}^J (n_j - 1)} = \frac{\sum_{j=1}^J (n_j - 1) s_j^2}{n - J}, \text{ kde } s_j^2 = \frac{1}{n_j - 1} \sum_{i=1}^{n_j} (y_{ji} - \bar{y}_{j.})^2.$$

Potom $\mathbf{Y}_j \sim N_{n_j}(\beta_j \mathbf{1}_{n_j}, \Sigma_j)$, kde $\Sigma_j = \sigma_j^2 \mathbf{I}_{n_j \times n_j}$, vektor chýb $\varepsilon_j \sim N_{n_j}(\mathbf{0}, \Sigma_j)$, vektor parametrov $\hat{\beta} \sim N_J(\beta, (\mathbf{X}^T \Sigma^{-1} \mathbf{X})^{-1})$, kde $\Sigma = \text{diag}(\sigma_1^2, \sigma_2^2, \dots, \sigma_J^2)$ a maximálne vieročodný odhad $\hat{\beta}$ vypočítame pomocou **váženej metódy najmenších štvorcov**, t.j. $\hat{\beta} = (\mathbf{X}^T \Sigma^{-1} \mathbf{X})^{-1} \mathbf{X}^T \Sigma^{-1} \mathbf{Y}$. Pozor, \mathbf{X} je matica plánu s rozmermi $n \times J$ (t.j. blokovo diagonálna matica jednotiek s blokmi $\mathbf{1}_{n_j}$).

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

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

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

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

Stupeň voľnosti df_w sa pri intervaloch spoľahlivosti často substituujú Welch-Satterthwaitovými **efektívnymi stupňami voľnosti** zadefinovanými nasledovne (Welch 1947, Satterthwaite 1946)

$$df_w = \frac{\left(\sum_{j=1}^J \frac{s_j^2}{n_j} \right)^2}{\sum_{j=1}^J \frac{\left(\frac{s_j^2}{n_j} \right)^2}{n_j - 1}}.$$

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 Fisherovho typu**) ako

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

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

$$\begin{aligned} & \left(\mathbf{a}^T \hat{\mu} - \sqrt{(J-1)F_{J-1, df_w}(\alpha)} \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}}, \right. \\ & \quad \left. \mathbf{a}^T \hat{\mu} + \sqrt{(J-1)F_{J-1, df_w}(\alpha)} \sqrt{\mathbf{a}^T (\mathbf{X}^T \mathbf{S}^{-1} \mathbf{X})^{-1} \mathbf{a}} \right), \end{aligned}$$

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

Asymptotické testy o stredných hodnotách

ANOVA model v

Funkcia `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`.

Príklad (ANOVA F -test a Tukeyho HSD metóda)

Naprogramujte v (A) ANOVA F -test za predpokladu nerovnosti rozptylov a (B) Tukeyho HSD metódu za predpokladu nerovnosti rozptylov.

Asymptotické testy o stredných hodnotách

Metódy mnohonásobného porovnávania v – Scheffého a Tukeyho HSD metóda

Príklad (Metódy mnohonásobného porovnávania)

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

Pozn.: Ide o identický príklad ako za predpokladu rovnosti rozptylov.

Asymptotické testy o stredných hodnotách

Test pomerom vierohtodnosti o rovnosti stredných hodnôt

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

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

Vieme, že **testovacia štatistika pomerom vierohtodnosti**

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

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

Asymptotické testy o stredných hodnotách

Test pomerom vierohtodnosti o rovnosti stredných hodnôt

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

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

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

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

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

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

Asymptotické testy o stredných hodnotách

Test pomerom vierohtodnosti 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 $j = 1, 2, \dots, J$, $\boldsymbol{\theta} = (\mu_1, \mu_2, \dots, \mu_J, \sigma_1^2, \sigma_2^2, \dots, \sigma_J^2)^T$. Logaritmus funkcie vierohtodnosti má tvar

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

MLE $\boldsymbol{\theta}$ je rovný $\hat{\boldsymbol{\theta}} = (\hat{\mu}_1, \hat{\mu}_2, \dots, \hat{\mu}_J, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \dots, \hat{\sigma}_J^2)^T$, 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. $\Theta_1 = \{\boldsymbol{\theta} : \sigma_i^2 \neq \sigma_j^2 \neq \sigma^2; i < j, i = 1, 2, \dots, J-1; j = 2, 3, \dots, J\}$ pre aspoň jedno i a j .

Asymptotické testy o stredných hodnotách

Test pomerom vieročnosti 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 vieročnosti bude potom rovný

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

Vieme, že **testovacia štatistika pomerom vieročnosti**

$U_{LR} = -2 \ln(\lambda(\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_J)) \stackrel{D}{\sim} \chi_{J-1}^2$. 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 vieročnosti o homogenite rozptylov v

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

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

Výstupy funkcie `bartlett.test()`:

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

Príklad (Test pomerom vieročnosti o homogenite rozptylov)

Naprogramujte v testom pomerom vieročnosti o homogenite rozptylov.

Príklad (Test homogeneity rozptylov)

Majme koncentráciu stronca Sr (mg/ml) v piatich vodných celkoch. Otestujte homogenitu rozptylov (A) testom pomerom vieročnosti a (B) Bartlettovou modifikáciou testu pomerom vieročnosti.

Asymptotické testy o stredných hodnotách

Bartlettova modifikácia testu pomerom vieročnosti o homogenite rozptylov

Bartlett (1937) modifikoval testovaciu štatistiku pomerom vieročnosti nasledovne

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

kde

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

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 χ_{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

Dvojfaktorový ANOVA model s fixnými efektami

Nech $Y_{ijk} \sim N(\mu_{ij}, \sigma_{ij}^2)$, kde $i = 1, 2, \dots, I, j = 1, 2, \dots, J$ a

$k = 1, 2, \dots, n_{ij}$, sú nezávislé náhodné premenné. Budeme rozlišovať dve situácie

- ❶ $Y_{ijk} \sim N(\mu_{ij}, \sigma_{ij}^2)$, kde $\sigma_{11}^2 = \sigma_{12}^2 = \dots = \sigma_{IJ}^2 = \sigma_e^2$ (**homogenita rozptylov**), σ_{ij}^2 sú neznáme a
- ❷ $Y_{ijk} \sim N(\mu_{ij}, \sigma_{ij}^2)$, kde existuje aspoň jedna dvojica rozptylov, ktoré sa nerovnajú (**nehomogenita rozptylov**), σ_{ij}^2 sú neznáme.

V špeciálnom prípade $n_{ij} = K$, t.j. ide o situáciu, kde sú všetky rozsahy homogénne.

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami

Nech $Y_{ijk} \sim N(\mu_{ij}, \sigma_{ij}^2)$, kde $\sigma_{11}^2 = \sigma_{12}^2 = \dots = \sigma_{IJ}^2 = \sigma_e^2$ a zároveň σ_{ij}^2 sú neznáme. Majme **dvojfaktorový model analýzy rozptylu (ANOVA) s fixnými (pevnými) efektami**, ozn. \mathcal{F}_{H_1} , definovaný ako

$$Y_{ijk} = \mu_{ij} + \varepsilon_{ijk} = \mu + \alpha_i + \beta_j + \varepsilon_{ijk},$$

kde $\mu = \sum_{i=1}^I \sum_{j=1}^J \mu_{ij} / (IJ)$, $\mu_{i\cdot} = \mu + \alpha_i$, $\mu_{\cdot j} = \mu + \beta_j$, $\sum_{i=1}^I n_i \alpha_i = 0$, $\sum_{j=1}^J n_j \beta_j = 0$, μ je **celková (spoločná) úroveň spoločnej všetkým populáciám** (alebo **celková stredná hodnota**), α_i je *i*-ta úroveň faktora A (*i*-ty efekt faktora A) a znamená odchýlku strednej hodnoty *i*-tej populácie od μ , β_j je *j*-ta úroveň faktora B (*j*-ty efekt faktora B) a znamená odchýlku strednej hodnoty *j*-tej populácie od μ . Pre chyby ε_{ijk} platí $\varepsilon_{ijk} \sim N(0, \sigma_e^2)$. Model $Y_{ijk} \sim N(\mu + \alpha_i + \beta_j, \sigma_e^2)$ sa nazýva aj **model podmieneného normálneho rozdelenia**.

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami

Nech $\hat{\mu}_{i\cdot} = \bar{Y}_{i\cdot..} = Y_{i\cdot..} / (JK)$, $\hat{\mu}_{\cdot j} = \bar{Y}_{\cdot j..} = Y_{\cdot j..} / (IK)$, $\hat{\mu} = \bar{Y}_{...} = \frac{Y_{...}}{IJK}$, $Y_{...} = \sum_{j=1}^J Y_{\cdot j..} = \sum_{i=1}^I Y_{i\cdot..}$, $Y_{i\cdot..} = \sum_{k=1}^K \sum_{j=1}^J Y_{ijk}$, $Y_{\cdot j..} = \sum_{k=1}^K \sum_{i=1}^I Y_{ijk}$, $\forall i, j$. Ďalej dostaneme $\hat{\mu}_{ij\cdot} = \bar{Y}_{ij\cdot..} = \frac{Y_{ij\cdot..}}{K}$, $Y_{ij\cdot..} = \sum_{k=1}^K Y_{ijk}$. Potom $\hat{\alpha}_i = \hat{\mu}_{i\cdot} - \hat{\mu}$, $\hat{\beta}_j = \hat{\mu}_{\cdot j} - \hat{\mu}$.

SS_A je **výberový súčet štvorcov rozdielov medzi súbormi faktora A** a je definovaný ako

$$SS_A = JK \sum_{i=1}^I \left(\bar{Y}_{i\cdot..} - \bar{Y}_{...} \right)^2 = \sum_{i=1}^I \frac{Y_{i\cdot..}^2}{JK} - \frac{Y_{...}^2}{IJK},$$

SS_B je **výberový súčet štvorcov rozdielov medzi súbormi faktora B** a je definovaný ako

$$SS_B = IK \sum_{j=1}^J \left(\bar{Y}_{\cdot j..} - \bar{Y}_{...} \right)^2 = \sum_{j=1}^J \frac{Y_{\cdot j..}^2}{IK} - \frac{Y_{...}^2}{IJK},$$

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami

Majme dvojicu hypotéz $H_0: \alpha_1 = \alpha_2 = \dots = \alpha_I = 0$ oproti $H_1: \text{existuje aspoň jedno } i < j \ (i = 1, 2, \dots, J-1; j = 1, 2, \dots, J)$ také, že $\alpha_i \neq \alpha_j$. Ak H_0 platí,

$$F_{W,A} = \frac{\frac{SS_A}{df_A}}{\frac{SS_e}{df_e}} \stackrel{\mathcal{D}}{\sim} F_{df_A, df_e},$$

kde $df_A = I - 1$, $df_e = n - I - J + 1$ sú stupne voľnosti,

$n = \sum_{i=1}^I \sum_{j=1}^J n_{ij}$ (za platnosť homogenity rozsahov $n = IJK$) je celkový rozsah, n_{ij} sú rozsahy jednotlivých výberov.

Majme ďalšiu dvojicu hypotéz $H_0: \beta_1 = \beta_2 = \dots = \beta_J = 0$ oproti $H_1: \text{existuje aspoň jedno } i < j \ (i = 1, 2, \dots, J-1; j = 1, 2, \dots, J)$ také, že $\beta_i \neq \beta_j$. Ak H_0 platí,

$$F_{W,B} = \frac{\frac{SS_B}{df_B}}{\frac{SS_e}{df_e}} \stackrel{\mathcal{D}}{\sim} F_{df_B, df_e},$$

kde $df_B = J - 1$.

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami

SS_e je **výberový súčet štvorcov rozdielov vnútri súborov** a je definovaný ako

$$\begin{aligned} SS_e &= \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K \left(Y_{ijk} - \bar{Y}_{i\cdot..} - \bar{Y}_{\cdot j..} + \bar{Y}_{...} \right)^2 \\ &= \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K Y_{ijk}^2 - \sum_{i=1}^I \frac{Y_{i\cdot..}^2}{JK} - \sum_{j=1}^J \frac{Y_{\cdot j..}^2}{IK} + \frac{Y_{...}^2}{IJK}. \end{aligned}$$

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

$$SS_T = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K \left(Y_{ijk} - \bar{Y}_{...} \right)^2 = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K Y_{ijk}^2 - \frac{Y_{...}^2}{IJK}.$$

Rovnosti $SS_T = SS_A + SS_B + SS_e$ hovoríme aj **rozklad celkovej sumy štvorcov**. Pre stupne voľnosti potom platí $df_T = df_A + df_B + df_e$, kde $df_T = n - 1$, $df_A = I - 1$, $df_B = J - 1$, $df_e = n - I - J + 1$.

Asymptotické testy o stredných hodnotách

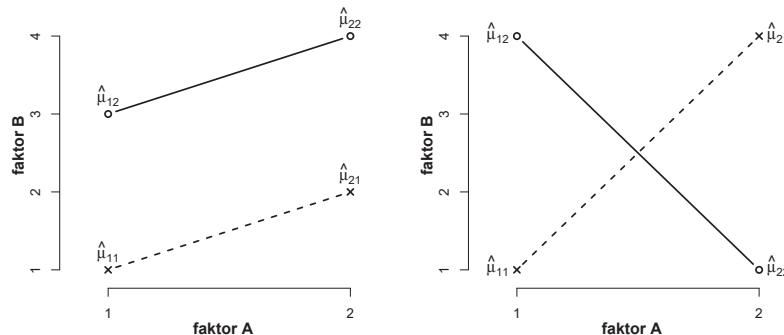
Dvojfaktorový ANOVA model s fixnými efektami

Sumy štvorcov sa najčastejšie zapisujú do **ANOVA tabuľky**:

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi A	$SS_{A,obs}$	df_A	$MS_A = SS_{A,obs}/df_A$
medzi súbormi B	$SS_{B,obs}$	df_B	$MS_B = SS_{B,obs}/df_B$
vnútri súborov	$SS_{e,obs}$	df_e	$MS_e = SS_{e,obs}/df_e$
celkovo	$SS_{T,obs}$	df_T	
	$MS_{e,obs} = \hat{\sigma}_e^2 = s^2$		

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami s interakciou



Obr.: Grafické znázornenie interakcie faktora A a B

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami s interakciou

Nech $Y_{ijk} \sim N(\mu_{ij}, \sigma_{ij}^2)$, kde $\sigma_{11}^2 = \sigma_{12}^2 = \dots = \sigma_{IJ}^2 = \sigma_e^2$ a zároveň σ_{ij}^2 sú neznáme. Majme **dvojfaktorový model analýzy rozptylu (ANOVA) s fixnými (pevnými) efektami s interakciou**, ozn. \mathcal{F}_{H_1} , definovaný ako

$$Y_{ijk} = \mu_{ij} + \varepsilon_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk},$$

kde $\mu = \sum_{i=1}^I \sum_{j=1}^J \mu_{ij}/(IJ)$, $\mu_i = \mu + \alpha_i$, $\mu_j = \mu + \beta_j$, $\gamma_{ij} = (\alpha\beta)_{ij}$, $\sum_{i=1}^I n_i \alpha_i = 0$, $\sum_{j=1}^J n_j \beta_j = 0$, $\sum_{i=1}^I n_i (\alpha\beta)_{ij} = \sum_{j=1}^J n_j (\alpha\beta)_{ij} = 0$, μ je celková (spoločná) úroveň spoločnej všetkým populáciám (alebo celková stredná hodnota), α_i je i -ta úroveň faktora A (i -ty efekt faktora A) a znamená odchýlku strednej hodnoty i -tej populácie od μ , β_j je j -ta úroveň faktora B (j -ty efekt faktora B) a znamená odchýlku strednej hodnoty j -tej populácie od μ , $(\alpha\beta)_{ij}$ je ij -ta úroveň interakcie faktora A a faktora B. Pre chyby ε_{ijk} platí $\varepsilon_{ijk} \sim N(0, \sigma_e^2)$. Model $Y_{ijk} \sim N(\mu + \alpha_i + \beta_j + (\alpha\beta)_{ij}, \sigma_e^2)$ sa nazýva aj **model podmieneného normálneho rozdelenia**.

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami s interakciou

Majme dvojicu hypotéz $H_0 : (\alpha\beta)_{ij} = 0$ pre $\forall i, j$ oproti H_1 : existuje aspoň jedno i, j ($i = 1, 2, \dots, I$; $j = 1, 2, \dots, J$) také, že $(\alpha\beta)_{ij} \neq 0$. Ak H_0 platí,

$$F_{W,AB} = \frac{\frac{SS_{AB}}{df_{AB}}}{\frac{SS_e}{df_e}} \stackrel{\mathcal{D}}{\sim} F_{df_{AB}, df_e},$$

kde $df_{AB} = (I - 1)(J - 1)$, $df_e = n - IJ$ sú stupne voľnosti.

Nech $\widehat{(\alpha\beta)}_{ij} = \hat{\mu}_{ij} - \hat{\mu}_i - \hat{\mu}_j + \hat{\mu}$.

SS_{AB} je **výberový súčet štvorcov pre interakciu faktora A a B** a je definovaný ako

$$\begin{aligned} SS_{AB} &= K \sum_{i=1}^I \sum_{j=1}^J \left(\bar{Y}_{ij} - \bar{Y}_{i..} - \bar{Y}_{.j} + \bar{Y}_{...} \right)^2 \\ &= \sum_{i=1}^I \sum_{j=1}^J \frac{Y_{ij}^2}{K} - \sum_{i=1}^I \frac{Y_{i..}^2}{JK} - \sum_{j=1}^J \frac{Y_{.j}^2}{IK} + \frac{Y_{...}^2}{IJK}. \end{aligned}$$

Asymptotické testy o stredných hodnotách

Dvojfaktorový ANOVA model s fixnými efektami s interakciou

SS_e je **výberový súčet štvorcov rozdielov vnútri súborov** a je definovaný ako

$$SS_e = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (Y_{ijk} - \bar{Y}_{ij\cdot})^2 = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K Y_{ijk}^2 - \frac{\sum_{i=1}^I \sum_{j=1}^J Y_{ij\cdot}^2}{K}.$$

Rovnosti $SS_T = SS_A + SS_B + SS_{AB} + SS_e$ hovoríme aj **rozklad celkovej sumy štvorcov**. Pre stupne voľnosti potom platí
 $df_T = df_A + df_B + df_{AB} + df_e$, kde $df_T = n - 1$, $df_A = I - 1$, $df_B = J - 1$,
 $df_{AB} = (I - 1)(J - 1)$, $df_e = n - IJ$.

Sumy štvorcov sa najčastejšie zapisujú do **ANOVA tabuľky**:

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi A	$SS_{A,obs}$	df_A	$MS_A = SS_{A,obs}/df_A$
medzi súbormi B	$SS_{B,obs}$	df_B	$MS_B = SS_{B,obs}/df_B$
interakcia AB	$SS_{AB,obs}$	df_{AB}	$MS_{AB} = SS_{AB,obs}/df_{AB}$
vnútri súborov	$SS_{e,obs}$	df_e	$MS_e = SS_{e,obs}/df_e$
celkovo	$SS_{T,obs}$	df_T	
$MS_{e,obs} = \hat{\sigma}_e^2 = s^2$			

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami

Majme ďalšiu dvojicu hypotéz $H_0 : \beta_{j,i} = 0$ pre $\forall i, j$ oproti H_1 : existuje aspoň jedno i, j také, že $\beta_{j,i} \neq 0$. Ak H_0 platí,

$$F_{W,B:A} = \frac{\frac{SS_{B,A}}{df_{B,A}}}{\frac{SS_e}{df_e}} \stackrel{\mathcal{D}}{\sim} F_{df_{B,A}, df_e},$$

kde $df_{B,A} = I(J - 1)$.

$SS_{B,A}$ je **výberový súčet štvorcov rozdielov pre vnorený faktor B : A** a je definovaný ako

$$SS_{B,A} = K \sum_{i=1}^I \sum_{j=1}^J (\bar{Y}_{ij\cdot} - \bar{Y}_{i..})^2 = \sum_{i=1}^I \sum_{j=1}^J \frac{Y_{ij\cdot}^2}{K} - \frac{Y_{i..}^2}{JK}.$$

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami

Nech $Y_{ijk} \sim N(\mu_{ij}, \sigma_{ij}^2)$, kde $\sigma_{11}^2 = \sigma_{12}^2 = \dots = \sigma_{IJ}^2 = \sigma_e^2$ a zároveň σ_{ij}^2 sú neznáme. Majme **hierarchický model analýzy rozptylu (ANOVA) s fixnými (pevnými) efektami**, ozn. \mathcal{F}_{H_1} , definovaný ako

$$Y_{ijk} = \mu_{ij} + \varepsilon_{ijk} = \mu + \alpha_i + \beta_{j,i} + \varepsilon_{ijk},$$

kde $\mu = \sum_{i=1}^I \sum_{j=1}^J \mu_{ij}/(IJ)$, $\mu_{i\cdot} = \mu + \alpha_i$, $\mu_{j\cdot i} = \mu + \beta_{j,i}$, $\sum_{i=1}^I n_i \alpha_i = 0$, $\sum_{i=1}^I \sum_{j=1}^J n_{ij} \beta_{j,i} = 0$, μ je **celková (spoločná) úroveň spoločná všetkým populáciám** (alebo **celková stredná hodnota**), α_i je *i*-ta **úroveň faktora A** (*i*-ty **efekt faktora A**) a znamená odchýlku strednej hodnoty *i*-tej populácie od μ , $\beta_{j,i} = \beta_{j|i}$ je *j*-ta **úroveň faktora B** (*j*-ty **efekt faktora B**) **vnorená do i-tej úrovne faktora A**. Pre chyby ε_{ijk} platí $\varepsilon_{ijk} \sim N(0, \sigma_e^2)$. Model $Y_{ijk} \sim N(\mu + \alpha_i + \beta_{j,i}, \sigma_e^2)$ sa nazýva aj **model podmieneného normálneho rozdelenia**.

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami

SS_e je **výberový súčet štvorcov rozdielov vnútri súborov** a je definovaný ako

$$SS_e = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (Y_{ijk} - \bar{Y}_{ij\cdot})^2 = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K Y_{ijk}^2 - \sum_{i=1}^I \sum_{j=1}^J \frac{Y_{ij\cdot}^2}{K}.$$

Súčet SS_A , $SS_{B,A}$ a SS_e sa rovná SS_T . Rovnosti $SS_T = SS_A + SS_{B,A} + SS_e$ hovoríme aj **rozklad celkovej sumy štvorcov**. Pre stupne voľnosti potom platí $df_T = df_A + df_{B,A} + df_e$, kde $df_T = n - 1$, $df_A = I - 1$, $df_{B,A} = I(J - 1)$, $df_e = n - IJ$.

Sumy štvorcov sa najčastejšie zapisujú do **ANOVA tabuľky**:

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi A	$SS_{A,obs}$	df_A	$MS_A = SS_{A,obs}/df_A$
medzi súbormi B : A	$SS_{B,A,obs}$	$df_{B,A}$	$MS_{B,A} = SS_{B,A,obs}/df_{B,A}$
vnútri súborov	$SS_{e,obs}$	df_e	$MS_e = SS_{e,obs}/df_e$
celkovo	$SS_{T,obs}$	df_T	
$MS_{e,obs} = \hat{\sigma}_e^2 = s^2$			

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami

V praxi môže nastať situácia, že máme rôzne počty podtried B , t.j. $j = 1, 2, \dots, b_i$ úrovňí v rámci triedy A_i , teda $b = \sum_{i=1}^I b_i$ a nevyvážený model, kedy máme namiesto K pozorovaní v každej podtriede n_{ij} pozorovaní, teda $n = \sum_{i=1}^I n_i = \sum_{i=1}^I \sum_{j=1}^J n_{ij}$, $n_i = \sum_{j=1}^J n_{ij}$.

SS_A je **výberový súčet štvorcov rozdielov medzi súbormi faktora A** a je definovaný ako

$$SS_A = \sum_{i=1}^I n_i (\bar{Y}_{i..} - \bar{Y}_{...})^2 = \sum_{i=1}^I \frac{Y_{i..}^2}{n_i} - \frac{Y_{...}^2}{n}.$$

$SS_{B:A}$ je **výberový súčet štvorcov rozdielov pre vnorený faktor $B : A$** a je definovaný ako

$$SS_{B:A} = \sum_{i=1}^I \sum_{j=1}^J n_{ij} (\bar{Y}_{ij.} - \bar{Y}_{i..})^2 = \sum_{i=1}^I \sum_{j=1}^J \frac{Y_{ij.}^2}{n_{ij}} - \frac{Y_{i..}^2}{n_i}.$$

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami

Sumy štvorcov sa najčastejšie zapisujú do **ANOVA tabuľky**:

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi A	$SS_{A,obs}$	df_A	$MS_A = SS_{A,obs}/df_A$
medzi súbormi $B : A$	$SS_{B:A,obs}$	$df_{B:A}$	$MS_{B:A} = SS_{B:A,obs}/df_{B:A}$
vnútri súborov	$SS_{e,obs}$	df_e	$MS_e = SS_{e,obs}/df_e$
celkovo	$SS_{T,obs}$	df_T	
	$MS_{e,obs} = \hat{\sigma}_e^2 = s^2$		

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami

SS_e je **výberový súčet štvorcov rozdielov vnútri súborov** a je definovaný ako

$$SS_e = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{ij.})^2 = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} Y_{ijk}^2 - \sum_{i=1}^I \sum_{j=1}^J \frac{Y_{ij.}^2}{n_{ij}}.$$

Súčet SS_A , $SS_{B:A}$ a SS_e sa rovná SS_T , čo je **celkový výberový súčet štvorcov rozdielov** a je definovaný ako

$$SS_T = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{...})^2 = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} Y_{ijk}^2 - \frac{Y_{...}^2}{n}.$$

Pre stupne voľnosti potom platí $df_T = df_A + df_{B:A} + df_e$, kde $df_T = n - 1$, $df_A = I - 1$, $df_{B:A} = b - I$, $df_e = n - b$.

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami – príklad tuk v mlieku

Príklad (Tuk v mlieku)

Sledujeme percento tuku v mlieku dcér pochádzajúcich od rôznych býkov a matiek, kde percento tuku budeme označovať ako Y_{ijk} (upravené podľa Grofík a Flák 1990). Býci budú predstavovať faktor A (tu $A_i, i = 1, 2, 3$), matky budú predstavovať faktor B (tu $B_{ij}, j = 1, 2, 3$), matky sú pripravené býkom $A_i, j_1 = 3, j_2 = 2, j_3 = 3$. Testujte $H_0 : \beta_{j:i} = 0$ pre $\forall i, j$ oproti H_1 : existuje aspoň jedno i, j také, že $\beta_{j:i} \neq 0$, t.j., že stredné hodnoty percenta tuku v mlieku dcér rôznych matiek od rovnakého otca sa nelisia.

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami – príklad tuk v mlieku

A_i	A_1			A_2			A_3		
B_{ij}	B_{11}	B_{12}	B_{13}	B_{21}	B_{22}	B_{31}	B_{32}	B_{33}	
Y_{ijk}	4.20	4.05	4.15	3.90	4.20	4.15	4.00	3.95	
	4.05	4.15	4.25	3.95	4.15	4.05	4.10	4.10	
	4.00	4.10	4.20	4.10	3.95	4.20	4.15	4.00	
	4.10	4.25	4.25	4.00	4.00	4.00	3.95	3.85	
	4.05	4.10	4.10		4.05		4.00		
	4.15								
n_{ij}	6	5	5	4	5	4	5	4	
n_i	16			9	13				
$\bar{Y}_{ij \cdot}$	24.52	20.65	20.95	15.95	20.35	16.40	20.20	15.90	
$\bar{Y}_{ij \cdot}$	4.09	4.13	4.19	3.99	4.07	4.10	4.04	3.98	
$\bar{Y}_{i \cdot \cdot}$	66.12			36.30		52.50			
$\bar{Y}_{\cdot \cdot \cdot}$	154.92								
S_{ij}	0.078	0.076	0.065	0.085	0.104	0.091	0.082	0.104	

Asymptotické testy o stredných hodnotách

Kroneckerov súčin a jeho vlastnosti

Kroneckerov súčin. Nech \mathbf{A} je matica $m \times n$, a \mathbf{B} je matica $p \times q$. Potom $\mathbf{A} \otimes \mathbf{B}$ je matica $mp \times nq$, ktorej (i,j) -ty blok je rovný $a_{ij}\mathbf{B}$, teda

$$\mathbf{A} \otimes \mathbf{B} = \begin{pmatrix} a_{11}\mathbf{B} & a_{12}\mathbf{B} & \dots & a_{1n}\mathbf{B} \\ a_{21}\mathbf{B} & a_{22}\mathbf{B} & \dots & a_{2n}\mathbf{B} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1}\mathbf{B} & a_{m2}\mathbf{B} & \dots & a_{mn}\mathbf{B} \end{pmatrix}$$

Pre Kroneckerov súčin platí

$$\mathbf{0} \otimes \mathbf{A} = \mathbf{A} \otimes \mathbf{0}$$

$$(\mathbf{A}_1 + \mathbf{A}_2) \otimes \mathbf{B} = (\mathbf{A}_1 \otimes \mathbf{B}) + (\mathbf{A}_2 \otimes \mathbf{B})$$

$$\mathbf{A} \otimes (\mathbf{B}_1 + \mathbf{B}_2) = (\mathbf{A} \otimes \mathbf{B}_1) + (\mathbf{A} \otimes \mathbf{B}_2)$$

$$c\mathbf{A} \otimes d\mathbf{B} = cd(\mathbf{A} \otimes \mathbf{B})$$

$$\mathbf{A}_1 \mathbf{A}_2 \otimes \mathbf{B}_1 \mathbf{B}_2 = (\mathbf{A}_1 \otimes \mathbf{B}_1)(\mathbf{A}_2 \otimes \mathbf{B}_2)$$

$$(\mathbf{A} \otimes \mathbf{B})^{-1} = \mathbf{A}^{-1} \otimes \mathbf{B}^{-1}, \text{ ak inverzie existujú}$$

$$(\mathbf{A} \otimes \mathbf{B})^T = \mathbf{A}^T \otimes \mathbf{B}^T$$

$$(\mathbf{A}, \mathbf{B}) \otimes \mathbf{C} = (\mathbf{A} \otimes \mathbf{C}, \mathbf{B} \otimes \mathbf{C})$$

Asymptotické testy o stredných hodnotách

Hierarchický ANOVA model s fixnými efektami – príklad tuk v mlieku

ANOVA tabuľka:

zdroj variability	suma štvorcov	df	priemerné štvorce
medzi súbormi A	$SS_{A,\text{obs}} = 0.0855$	$df_A = 2$	$MS_A = 0.0429$
medzi súbormi B : A	$SS_{B:A,\text{obs}} = 0.0756$	$df_{B:A} = 5$	$MS_{B:A} = 0.0151$
vnútri súborov	$SS_e,\text{obs} = 0.2197$	$df_e = 30$	$MS_e = \hat{\sigma}_e^2 = 0.0073$
celkovo	$SS_T,\text{obs} = 0.3810$	$df_T = 37$	

$$F_{W,B:A,\text{obs}} = \frac{\frac{SS_{B:A}}{df_{B:A}}}{\frac{SS_e}{df_e}} = \frac{\frac{0.0756}{5}}{\frac{0.2197}{30}} = \frac{0.0151}{0.0073} = 2.0635$$

$$F_{df_{B:A}, df_e}(\alpha) = F_{5,30}(0.05) = 2.5335$$

p-hodnota = 0.098.

Asymptotické testy o stredných hodnotách

Kroneckerov súčin v jednofaktorovom ANOVA modeli

Model \mathcal{F}_{H_1} má tvar

$$\mathbf{Y} = \mathbf{X}\beta + \varepsilon, \text{ kde } \mathbf{X} = \begin{pmatrix} \mathbf{1}_K & \mathbf{1}_K & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{1}_K & \mathbf{0} & \mathbf{1}_K & \dots & \mathbf{0} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ \mathbf{1}_K & \mathbf{0} & \mathbf{0} & \dots & \mathbf{1}_K \end{pmatrix}, \beta = \begin{pmatrix} \mu \\ \alpha_1 \\ \alpha_2 \\ \vdots \\ \alpha_J \end{pmatrix}, \varepsilon = \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_J \end{pmatrix}.$$

Model \mathcal{F}_{H_1} zapísaný pomocou Kroneckerovho súčinu má tvar

$$\mathbf{Y} = (\mathbf{1}_J \otimes \mathbf{1}_K)\mu + (\mathbf{I}_{J \times J} \otimes \mathbf{1}_K)\alpha + \varepsilon = (\mathbf{1}_J \otimes \mathbf{1}_K, \mathbf{I}_{J \times J} \otimes \mathbf{1}_K)\beta + \varepsilon.$$

Nech $\mu = (\mu_1, \mu_2, \dots, \mu_J)^T$ a $\beta = (\mu, \alpha^T)^T$. Zápis vektora μ pomocou Kroneckerovho súčinu je nasledovný

$$\mu = (\mathbf{1}_J \otimes 1, \mathbf{I}_{J \times J} \otimes 1)\beta.$$

Vieme, že $\mathbf{A}^{-1} = \mathbf{B}$ a $\mathbf{B}\tilde{\beta} = \beta$. Potom platí nasledovné

$$\mu = (\mathbf{1}_J \otimes 1, \mathbf{I}_{J \times J} \otimes 1) \left(\begin{pmatrix} (\mathbf{1} \otimes \mathbf{1})\mu \\ (\mathbf{B} \otimes 1)\tilde{\beta} \end{pmatrix} \right) = (\mathbf{1}_J \otimes 1, \mathbf{B} \otimes 1)\tilde{\beta}.$$

Asymptotické testy o stredných hodnotách

Kroneckerov súčin v dvojfaktorovom ANOVA modeli bez interakcie

Preznačme vektor parametrov faktora $A = A_1$ na $\alpha = \alpha_1$ a vektor parametrov faktora $B = A_2$ na $\beta = \alpha_2$. Potom $\beta = (\mu, \alpha_1^T, \alpha_2^T)^T$. Nech $\mu = (\mu_{11}, \mu_{12}, \dots, \mu_{1I}, \mu_{21}, \dots, \mu_{2J})^T$. Zápis vektora μ pomocou Kroneckerovo súčinu je nasledovný

$$\mu = (\mathbf{1}_I \otimes \mathbf{1}_J, \mathbf{I}_{I \times I} \otimes \mathbf{1}_J, \mathbf{I}_{J \times J} \otimes \mathbf{1}_I) \beta.$$

Nech matica kontrastov pre faktor A_j je \mathbf{A}_j a jej inverzia $\mathbf{A}_j^{-1} = \mathbf{B}_j$, $j = 1, 2$. Potom platí nasledovné

$$\begin{aligned}\mu &= (\mathbf{1}_I \otimes \mathbf{1}_J, \mathbf{I}_{I \times I} \otimes \mathbf{1}_J, \mathbf{I}_{J \times J} \otimes \mathbf{1}_I) \begin{pmatrix} (1 \otimes 1)\mu \\ (\mathbf{B}_1 \otimes 1)\tilde{\alpha}_1 \\ (1 \otimes \mathbf{B}_2)\tilde{\alpha}_2 \end{pmatrix} \\ &= (\mathbf{1}_I \otimes \mathbf{1}_J, \mathbf{B}_1 \otimes \mathbf{1}_J, \mathbf{1}_I \otimes \mathbf{B}_2)\tilde{\beta}.\end{aligned}$$

Asymptotické testy o stredných hodnotách

Testovanie submodelov v ANOVA – súhrn modelov

Majme nasledovné modely

Model $\mathcal{F}_F : Y_{ijk} = \mu + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk}$,

Model $\mathcal{F}_{AB} : Y_{ijk} = \mu + \alpha_i + \beta_j + \varepsilon_{ijk}$,

Model $\mathcal{F}_B : Y_{ijk} = \mu + \beta_j + \varepsilon_{ijk}$,

Model $\mathcal{F}_A : Y_{ijk} = \mu + \alpha_i + \varepsilon_{ijk}$,

Model $\mathcal{F}_N : Y_{ijk} = \mu + \varepsilon_{ijk}$,

kde dolný index F znamená **plný model** (angl. *full*) a **N nulový model** (angl. *null*). Z vyššie uvedeného zoznamu modelov vždy bude pri testovaní nejakej H_0 oproti H_1 jeden model \mathcal{F}_{H_0} a druhý \mathcal{F}_{H_1} . Ak sú modely **vyvážené**, t.j. $n_{ij} = K$, potom je situácia jednoduchá. Obe postupnosti testovania:

- 1 $\mathcal{F}_F \rightarrow \mathcal{F}_{AB} \rightarrow \mathcal{F}_B \rightarrow \mathcal{F}_N$ a
- 2 $\mathcal{F}_F \rightarrow \mathcal{F}_{AB} \rightarrow \mathcal{F}_A \rightarrow \mathcal{F}_N$,

sa líšia len zámenou I a J v SS. Ak je **model nevyvážený**, dostaneme výsledok pre každú postupnosť modelov iný.

Asymptotické testy o stredných hodnotách

Kroneckerov súčin v dvojfaktorovom ANOVA modeli s interakciou

Preznačme vektor parametrov faktora $A = A_1$ na $\alpha = \alpha_1$ a vektor parametrov faktora $B = A_2$ na $\beta = \alpha_2, \gamma = \alpha_{12}$. Potom $\beta = (\mu, \alpha_1^T, \alpha_2^T, \alpha_{12}^T)^T$. Nech $\mu = (\mu_{11}, \mu_{12}, \dots, \mu_{1I}, \mu_{21}, \dots, \mu_{2J})^T$. Zápis vektora μ pomocou Kroneckerovo súčinu je nasledovný

$$\mu = (\mathbf{1}_I \otimes \mathbf{1}_J, \mathbf{I}_{I \times I} \otimes \mathbf{1}_J, \mathbf{I}_{J \times J} \otimes \mathbf{1}_I, \mathbf{I}_{I \times I} \otimes \mathbf{I}_{J \times J}) \beta.$$

Nech matica kontrastov pre faktor A_j je \mathbf{A}_j a jej inverzia $\mathbf{A}_j^{-1} = \mathbf{B}_j$, $j = 1, 2$. Nech matica kontrastov pre interakciu A_{12} je \mathbf{A}_{12} a jej inverzia $\mathbf{A}_{12}^{-1} = \mathbf{B}_{12}$. Potom platí nasledovné

$$\begin{aligned}\mu &= (\mathbf{1}_I \otimes \mathbf{1}_J, \mathbf{I}_{I \times I} \otimes \mathbf{1}_J, \mathbf{I}_{J \times J} \otimes \mathbf{1}_I, \mathbf{I}_{I \times I} \otimes \mathbf{I}_{J \times J}) \begin{pmatrix} (1 \otimes 1)\mu \\ (\mathbf{B}_1 \otimes 1)\tilde{\alpha}_1 \\ (1 \otimes \mathbf{B}_2)\tilde{\alpha}_2 \\ (\mathbf{B}_1 \otimes \mathbf{B}_2)\tilde{\alpha}_{12} \end{pmatrix} \\ &= (\mathbf{1}_I \otimes \mathbf{1}_J, \mathbf{B}_1 \otimes \mathbf{1}_J, \mathbf{1}_I \otimes \mathbf{B}_2, \mathbf{B}_1 \otimes \mathbf{B}_2)\tilde{\beta}.\end{aligned}$$

Asymptotické testy o stredných hodnotách

Testovanie submodelov v ANOVA – sumy štvorcov

Majme nasledovné výberové sumy štvorcov v tzv. **R-notácii**

$$\mathcal{R}(\mathbf{1}, \mathbf{A}, \mathbf{B}, \mathbf{AB}) = (\mathbf{Y} - \hat{\mu})^T (\mathbf{Y} - \hat{\mu}) = SS_e = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{ij.})^2$$

$$\mathcal{R}(\mathbf{1}, \mathbf{A}, \mathbf{B}) = (\mathbf{Y} - \hat{\mu}_{AB})^T (\mathbf{Y} - \hat{\mu}_{AB}) = SS_{AB} = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{i..} - \bar{Y}_{j..} + \bar{Y}...)^2$$

$$\mathcal{R}(\mathbf{1}, \mathbf{B}) = (\mathbf{Y} - \hat{\mu}_B)^T (\mathbf{Y} - \hat{\mu}_B) = SS_B = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{.j.})^2$$

$$\mathcal{R}(\mathbf{1}, \mathbf{A}) = (\mathbf{Y} - \hat{\mu}_A)^T (\mathbf{Y} - \hat{\mu}_A) = SS_A = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}_{i..})^2$$

$$\mathcal{R}(\mathbf{1}) = (\mathbf{Y} - \hat{\mu}_0)^T (\mathbf{Y} - \hat{\mu}_0) = SS_T = \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^{n_{ij}} (Y_{ijk} - \bar{Y}...)^2$$

Modely prislúchajúce daným výberovým sumám štvorcov sú v poradí $\mathcal{M} = \mathcal{M}_F, \mathcal{M}_{AB}, \mathcal{M}_B, \mathcal{M}_A$ a $\mathcal{M}_0 = \mathcal{M}_N$.

Asymptotické testy o stredných hodnotách

Testovanie submodelov v ANOVA – rozdiely súm štvorcov a tri typy rozkladov

Majme nasledovné sumy výberové štvorcov v tzv. **redukovanej R-notácií**

$$\mathcal{R}(AB|1, A, B) = \mathcal{R}(1, A, B) - \mathcal{R}(1, A, B, AB) = (\hat{\mu} - \hat{\mu}_{AB})^T (\hat{\mu} - \hat{\mu}_{AB}) = SS_{AB} - SS_e$$

$$\mathcal{R}(A|1, B) = \mathcal{R}(1, B) - \mathcal{R}(1, A, B) = (\hat{\mu}_{AB} - \hat{\mu}_B)^T (\hat{\mu}_{AB} - \hat{\mu}_B) = SS_B - SS_{AB}$$

$$\mathcal{R}(B|1, A) = \mathcal{R}(1, A) - \mathcal{R}(1, A, B) = (\hat{\mu}_{AB} - \hat{\mu}_A)^T (\hat{\mu}_{AB} - \hat{\mu}_A) = SS_A - SS_{AB}$$

$$\mathcal{R}(B|1) = \mathcal{R}(1) - \mathcal{R}(1, B) = (\hat{\mu}_B - \hat{\mu}_0)^T (\hat{\mu}_B - \hat{\mu}_0) = SS_T - SS_B$$

$$\mathcal{R}(A|1) = \mathcal{R}(1) - \mathcal{R}(1, A) = (\hat{\mu}_A - \hat{\mu}_0)^T (\hat{\mu}_A - \hat{\mu}_0) = SS_T - SS_A$$

$$\mathcal{R}(B|1, A, AB) = \mathcal{R}(1, A, AB) - \mathcal{R}(1, A, B, AB)$$

$$\mathcal{R}(A|1, B, AB) = \mathcal{R}(1, B, AB) - \mathcal{R}(1, A, B, AB)$$

ANOVA tabuľku potom vytvárame pre tri rôzne rozklady sumy štvorcov (angl. *ANOVA Type I*, *ANOVA Type II*, *ANOVA Type III*)

	Rozklad typu I	Rozklad typu II	Rozklad typu III
AB	$\mathcal{R}(AB 1, A, B)$	$\mathcal{R}(AB 1, A, B)$	$\mathcal{R}(AB 1, A, B)$
B	$\mathcal{R}(B 1, A)$	$\mathcal{R}(B 1, A)$	$\mathcal{R}(B 1, A, B, AB)$
A	$\mathcal{R}(A 1)$	$\mathcal{R}(A 1, B)$	$\mathcal{R}(A 1, A, B, AB)$

Asymptotické testy o stredných hodnotách

Literatúra

- Azalini, A., 1996: *Statistical inference based on likelihood*. Boca Raton: Chapman & Hall/CRC Press
- Casella, G., Berger, R.L., 2002: *Statistical Inference*. Pacific Grove: Duxbury Press
- Fisher, R.A., 1935: *The Design of Experiments*. London: Macmillan
- Fox, J. 2016: *Applied Regression Analysis and Generalised Linear Models*. Los Angeles: Sage
- Grofík, R., Flák, P. 1990: *Štatistické modely v poľnohospodárstve*. Bratislava: Príroda
- Katina, S., Králik, M., Hupková, A., 2015: *Aplikovaná štatistická inferencia I. Biologická antropológia očami matematickej štatistiky*. Brno: Masarykova univerzita
- Kirk, R.E., 1982: *Experimental Design: Procedures for the Behavioral Sciences*. Belmont: Wadsworth
- Scheffé, 1953: *The Analysis of Variance*. Hoboken: John Wiley Sons
- Zvára, K., 2008: *Regresie*. Praha: Matfyzpress

Asymptotické testy o stredných hodnotách

Testovanie submodelov v ANOVA – submodel vs nadmodel, nulové hypotézy

Testujeme nasledovné **submodely** voči **nadmodelom**

	Rozklad typu I	Rozklad typu II	Rozklad typu III
AB	$\mathcal{F}_{AB} \text{ vs } \mathcal{F}_F$	$\mathcal{F}_{AB} \text{ vs } \mathcal{F}_F$	$\mathcal{F}_{AB} \text{ vs } \mathcal{F}_F$
B	$\mathcal{F}_A \text{ vs } \mathcal{F}_{AB}$	$\mathcal{F}_A \text{ vs } \mathcal{F}_{AB}$	$\mathcal{F}_{F-A} \text{ vs } \mathcal{F}_F$
A	$\mathcal{F}_N \text{ vs } \mathcal{F}_A$	$\mathcal{F}_B \text{ vs } \mathcal{F}_{AB}$	$\mathcal{F}_{F-B} \text{ vs } \mathcal{F}_F$

kde

$$\text{Model } \mathcal{F}_{F-A} : Y_{ijk} = \mu + \beta_j + (\alpha\beta)_{ij} + \varepsilon_{ijk},$$

$$\text{Model } \mathcal{F}_{F-B} : Y_{ijk} = \mu + \alpha_i + (\alpha\beta)_{ij} + \varepsilon_{ijk}.$$

Testujeme nasledovné **nulové hypotézy**

	Rozklad typu I	Rozklad typu II	Rozklad typu III
AB	$(\alpha\beta)_{ij} = 0 \text{ pre } \forall i, j$	$(\alpha\beta)_{ij} = 0 \text{ pre } \forall i, j$	$(\alpha\beta)_{ij} = 0 \text{ pre } \forall i, j$
B	$\beta_j = 0 \text{ pre } \forall j$	$\beta_j = 0 \text{ pre } \forall j$	$\beta_j = 0 \text{ pre } \forall j$
A	$\alpha_i = 0 \text{ pre } \forall i$	$\alpha_i = 0 \text{ pre } \forall i$	$\alpha_i = 0 \text{ pre } \forall i$

Ide teda o testy rovnakých nulových hypotéz, ktoré testujeme pomocou rôznych súm štvorcov, t.j. na testovanie používame rôzne submodely a nadmodely.

Asymptotické testy o stredných hodnotách

Literatúra

- Bartlett, M.S. 1937: Properties of sufficiency and statistical tests. *Proceedings of the Royal Statistical Society, Series A* 160: 268–282
- Bonferroni, C.E., 1936: *Teoria statistica delle classi e calcolo delle probabilità*. Firenze: Libreria Internazionale Seeber
- Fisher, R.A., 1936, 1971: The use of multiple measurements in taxonomic problems. *Annals of Eugenics* 7: 179–188
- Satterthwaite, F.E., 1946: An Approximate Distribution of Estimates of Variance Components. *Biometrics Bulletin* 2,6: 110–114
- Šidák, Z., 1967: Rectangular Confidence Regions for the Means of Multivariate Normal Distributions. *Journal of the American Statistical Association* 62(318): 626–633
- Tukey, J.W., 1949: Comparing Individual Means in the Analysis of Variance. *Biometrics* 5(2): 99–114
- Tukey, J.W., 1953: The problem of multiple comparisons. Unpublished manuscript. In *The Collected Works of John W. Tukey VIII. Multiple Comparisons: 1948–1983*. New York: Chapman & Hall
- Welch, B.L., 1947: The generalization of Student's problem when several different population variances are involved. *Biometrika* 34(1–2): 28–35