

UP

Univerzita Palackého
v Olomouci

Analýza rozptylu

Chemometrie I (ACH/CHEX1)

(c) David MILDE, 2023

1

UP

Univerzita Palackého
v Olomouci

Úvod

- Analýza rozptylu (aj. Analysis of Variance – **ANOVA**) je pokročilá statistická metoda popsaná počátkem 20. stol. R. A. Fisherem.
- ANOVA je statistická metoda používaná k porovnání průměrů několika (více než dvou) základních souborů.
 - Název metody je matoucí. Metoda se nepoužívá k porovnání rozptylů ale průměrů.
 - Název analýza rozptylu vyplývá ze skutečnosti, že určení, zda jsou či nejsou mezi průměry několika základních souborů rozdíly, se zakládá na analýze různých forem rozptylu spojeného s náhodnými výběry.
 - Používá se buď jako samostatná technika, nebo jako postup, umožňující analýzu zdrojů variability v lineární regresi. **Příklady použití:**
 - k porovnání středních hodnot více než 2 souborů, např. porovnání shody více než dvou metod stanovení analytu, účinku více než 2 léčiv na dané onemocnění, účinku více než 2 hnojiv na výnos, ...
 - určení vlivu způsobu přípravy vzorků (několika způsoby),
 - zpracování mezilaboratorních porovnávacích zkoušek (MPZ).

2

Úvod

- PODSTATA metody: rozklad celkového rozptylu na rozptyl vyvolaný vlivem jednotlivých faktorů (objasněná složka rozptylu) a náhodný rozptyl (neobjasněná složka rozptylu).
- Předmětem statistického testování je statistická významnost poměru mezi rozptylem způsobeným faktorem/faktory a náhodným rozptylem.
- Máme-li 1 faktor = jednofaktorová ANOVA, v případě 2 faktorů = dvoufaktorová ANOVA.
- Předpoklady pro použití ANOVA:
 - data pocházejí z normálního rozdělení, náhodné chyby ε_{ij} jsou náhodné veličiny s nulovou střední hodnotou,
 - rozptyly sloupců dat (v tabulce ANOVA) jsou stejné,
 - každý sloupec je náhodným výběrem ze svého základního souboru.
- Ověření předpokladu normality v QC Expertu:
 - Q-Q graf Jackknife reziduů (odchylek od celkového průměru) – v případě normálního rozdělení vznikne v grafu lineární závislost s nulovým úsekem a jednotkovou směrnicí.


3

Jednofaktorová ANOVA

- Formulace modelu: sleduje se faktor **A** na k úrovních A_1, \dots, A_k . Na každé úrovni je provedeno n_i měření (celkový počet měření označujeme N).
- Z tabulky ANOVA lze vytvořit model ve tvaru: $x_{ij} = \mu + \alpha_i + \varepsilon_{ij}$
 μ ... celkový aritmetický průměr všech hodnot v matici \bar{x} ,
 α_i ... efekt i -té úrovně faktoru A popsaný sloupcovým průměrem \bar{x}_i ,
 ε_{ij} ... náhodná chyba.
- Jednofaktorová ANOVA porovnává střední hodnoty (průměry) dvou či více úrovní faktoru **A** čili sloupců v tabulce ANOVA za účelem určit, zda alespoň jedna sloupcový průměr (\bar{x}_i) se liší od ostatních.
- H_0 : „Všechny střední hodnoty jsou stejné“ ($H_0: \alpha_i = 0$).
- H_1 : „Alespoň jedna střední hodnota se odlišuje od ostatních“ ($H_1: \alpha_i \neq 0$).

A₁	A₂	A..	A_k
X_{11}	X_{21}	$X..$	X_{k1}
X_{12}	X_{22}	$X..$	X_{k2}
X_{13}	X_{23}	X_{jj}	X_{k3}
X_{14}	X_{24}		X_{k4}
X_{15}			X_{k5}

Tabulka ANOVA



4

Jednofaktorová ANOVA

- Odvození modelu ANOVA:

$$x_{ij} = \mu + \alpha_i + \epsilon_{ij}$$

$$x_{ij} = \bar{x} + (\bar{x}_i - \bar{\bar{x}}) + (x_{ij} - \bar{x}_i)$$

$$(x_{ij} - \bar{x})^2 = [(\bar{x}_i - \bar{\bar{x}}) + (x_{ij} - \bar{x}_i)]^2$$

sumací přes řádky (i) a sloupce (j) získáme

$$\sum_{i \ j} (x_{ij} - \bar{x})^2 = \sum_{i \ j} (\bar{x}_i - \bar{\bar{x}})^2 + \sum_{i \ j} (x_{ij} - \bar{x}_i)^2 + 2 \sum_{i \ j} (\bar{x}_i - \bar{\bar{x}})(x_{ij} - \bar{x}_i),$$

což lze zjednodušit na

$$S_0 = S_A + S_R + 2 \cdot 0 = S_A + S_R$$

- Vzorce pro výpočet jednofaktorové ANOVA na kalkulačce:

S_0 „představuje“ celkový rozptyl

$$S_0 = \sum_i \sum_j (x_{ij}^2) - \frac{T^2}{N}$$

S_A „představuje“ rozptyl mezi jednotlivými úrovněmi faktoru A

$$S_A = \sum_{i=1}^k \left(\frac{T_i^2}{n_i} \right) - \frac{T^2}{N}$$

S_R „představuje“ reziduální (zbytkový, neobjasněný) rozptyl, tj. uvnitř úrovní faktoru A

$$S_R = S_0 - S_A$$

T ... součet všech hodnot v tabulce ANOVA

T_i ... sloupcový součet

5

Jednofaktorová ANOVA

- Testační statistika pro faktor A:

$$F_A = \frac{\frac{S_A}{(k-1)}}{\frac{S_R}{(N-k)}} = \frac{S_A \cdot (N-k)}{S_R \cdot (k-1)}$$


Při platnosti H_0 je $F_A < F_{\text{krit}(\alpha, k-1, N-k)}$, pokud je $F_A > F_{\text{krit}(\alpha, k-1, N-k)}$, je nutné H_0 na hladině významnosti α zamítout a průměry jsou rozdílné.

	Chips 1	Chips 2	Chips 3	Chips 4
	0,324	0,455	0,420	0,447
	0,311	0,467	0,463	0,377
	0,352	0,448	0,424	0,398
\bar{x}_i	0,329	0,457	0,436	0,407
T_i	0,987	1,370	1,307	1,222

% Na v chipsech

$$k = 4, n_i = 3 \\ N = 12$$

$$T = 0,987 + 1,370 + 1,307 + 1,222 = 4,886$$



6



Párové porovnání v jednofaktorové ANOVA

- Když ANOVA určí, že faktor **A** je statisticky významný, je pomocí párového porovnání (multiple comparison procedure – MCP) možné nalézt ty úrovně faktoru **A**, které se liší od ostatních. Je tedy možné určit, který sloupcový(é) průměr(y) (\bar{x}_i) se liší od ostatních.
- Při MCP se každý \bar{x}_i porovnáván postupně se všemi ostatními.
 - Např. pro $k = 3$ jde o tato porovnání $\bar{x}_1 \leq \bar{x}_2$, $\bar{x}_1 \leq \bar{x}_3$ a $\bar{x}_2 \leq \bar{x}_3$.
- Existuje více metod MCP, QC.Expert používá **Scheffého porovnání**.
 - Testační kritérium má následující podobu pro případ, kdy se \bar{x}_i a \bar{x}_j od sebe liší:

$$\frac{|\bar{x}_i - \bar{x}_j|}{\sqrt{s^2 \left(\frac{1}{n_i} + \frac{1}{n_j} \right)}} \geq \sqrt{(k-1) F_{krit(k-1, N-k)}}$$

Princip: testování významnosti rozdílů jednotlivých sloupcových průměrů, př. pro $k = 3$ $\bar{x}_1 - \bar{x}_2$, $\bar{x}_1 - \bar{x}_3$ a $\bar{x}_2 - \bar{x}_3$.

Je-li rozdíl statistický významný (tj. odlišný od 0), tak IS tohoto rozdílu nebude obsahovat 0. Je-li rozdíl statisticky nevýznamný (tj. rovný 0), tak IS rozdílu bude obsahovat 0.

7



Dvoufaktorová ANOVA

- Provádí se experimenty na různých úrovních dvou faktorů **A** a **B**. Kombinace úrovní faktoru tvoří strukturu tabulky ANOVA, jejímž elementem je tzv. celá. Platí, že celá [ij] odpovídá i -té úrovní faktoru **A** a j -té úrovní faktoru **B**. V každé cele může být n_{ij} pozorování.

	B₁	B₂	B_{..}	B_m
A₁
A₂
A_{..}	.	.	x_{ij}	.
A_k

ANOVA bez opakování (2P)

	B₁	B₂	B_{..}	B_m
A₁
A₂
A_{..}
A_k

Vyvážená ANOVA (2B)

	B₁	B₂	B_{..}	B_m
A₁
A₂
A_{..}
A_k

Nevyvážená ANOVA (2U)

- Pokud se kromě řádkových α_i a sloupcových β_j efektů uplatňuje i vliv různých kombinací sloupcových a řádkových efektů, vyskytuje se také interakční člen τ_{ij} .

8



Dvoufaktorová ANOVA

- Podrobně (pro výpočty na kalkulačce) se budeme zabývat pouze ANOVA 2P.

- Model ANOVA 2P bez interakce: $x_{ij} = \mu + \alpha_i + \beta_j + \varepsilon_{ij}$

α_i ... vliv i -té úrovně faktoru A, β_j ... vliv j -té úrovně faktoru B

$$S_0 = S_A + S_B + S_R$$

- Formulace hypotéz:

- $H_0: \alpha_i = 0$ a $\beta_j = 0$ (efekty úrovní faktorů A a B jsou nevýznamné)
- $H_1: \alpha_i \neq 0$ a $\beta_j \neq 0$ (efekty úrovní faktorů A a B jsou významné)

$$S_0 = \sum_i \sum_j (x_{ij}^2) - \frac{T^2}{N} \quad S_A = \frac{1}{m} \sum_{i=1}^k (Z_i^2) - \frac{T^2}{N} \quad S_B = \frac{1}{k} \sum_{j=1}^m (T_j^2) - \frac{T^2}{N}$$

- S_A „představuje“ rozptyl mezi jednotlivými úrovněmi faktoru A,
- S_B „představuje“ rozptyl mezi jednotlivými úrovněmi faktoru B,
- S_0 „představuje“ celkový rozptyl, S_R „představuje“ reziduální rozptyl
- $N = k \cdot m$,
- Z_i ... řádkový součet (součet i -té úrovně f. A), T_j ... sloupcový součet (součet j -té úrovně f. B).

9



Dvoufaktorová ANOVA

- Testační statistiky pro ANOVA 2P bez interakce:

$$F_A = \frac{\frac{S_A}{k-1}}{\frac{S_R}{(k-1)(m-1)}} \quad F_B = \frac{\frac{S_B}{m-1}}{\frac{S_R}{(k-1)(m-1)}}$$

- Za předpokladu platnosti H_0 je $F_A < F_{\text{krit}, \alpha}$ s $(k-1)$ a $(k-1)(m-1)$ stupni volnosti a $F_B < F_{\text{krit}, \alpha}$ s $(m-1)$ a $(k-1)(m-1)$ stupni volnosti. V opačných případech ($F_i > F_{\text{krit}}$) přijímáme H_1 .

INTERAKCE FAKTORŮ

- Jak již bylo uvedeno, kromě řádkových α_i a sloupcových β_j efektů se může uplatnit vliv různých kombinací sloupcových a řádkových efektů, vyskytuje se také interakční člen τ_{ij} .
- Model ANOVA pak je: $x_{ij} = \mu + \alpha_i + \beta_j + \tau_{ij} + \varepsilon_{ij}$.
- Obvykle se užívá **Tukeyův model interakce** – $\tau_{ij} = C \cdot \alpha_i \cdot \beta_j$, kde C je konstanta. To vede k rovnici pro celkový rozptyl $S_0 = S_A + S_B + S_I + S_R$. Model s interakcí používá QC-Expert v modulu dvoufaktorové ANOVA a T_i v něm „představuje“ rozptyl příslušející interakci.

10



Neparametrické testy v ANOVA

- KRUSKALŮV-WALLISŮV TEST

- Je neparametrickou alternativou pro jednofaktorovou ANOVA.
- Jedná se o rozšíření Wilcoxonova pořadového testu pro porovnání mediánů více než dvou náhodných výběrů.
- Předpoklady pro použití:
 - rozdelení souborů musí být stejné,
 - rozptyly souborů musí být stejné,
 - Všechny sloupce představují náhodné výběry svých základních souborů.

- FRIEDMANŮV TEST

- Je neparametrickou variantou dvoufaktorové analýzy rozptylu (varianty 2P), faktor A má k úrovni a faktor B má m úrovní.
- Postup je obdobný s Kruskalovým-Wallisovým testem.
- V rámci ACH/CHEX1 nebudeme řešit příklady na tento test.

11



Kruskalův-Wallisův test

- Formulace hypotéz:
 H_0 : „mediány všech úrovní faktoru jsou stejné“
 H_1 : „alespoň jeden medián se liší od ostatních“

- POSTUP:

1. Všechny hodnoty v tabulce ANOVA seřadíme podle velikosti a přiřadíme jím pořadová čísla (včetně průměrných pořadí pro stejné hodnoty).
2. Pro každou úroveň faktoru A (výběrový soubor) vypočítáme sumu pořadí R_1, R_2, \dots, R_k (k je počet úrovní faktoru).
3. Určíme celkový rozsah výběru $N = n_1 + n_2 + \dots + n_k$, tj. součet hodnot všech úrovní faktoru A.
4. Vypočteme testovací charakteristiku χ^2_{Kru} pomocí následujícího vztahu:

$$\chi^2_{Kru} = \frac{12}{N^2 + N} \sum_{i=1}^k \left(\frac{R_i^2}{n_i} \right) - 3(N+1)$$

5. Porovnáváme s kritickou hodnotou $\chi^2_{krit(0,95)}$ s $k - 1$ stupni volnosti.
 6. Je-li $\chi^2_{Kru} < \chi^2_{krit}$, přijímáme H_0 . Pokud je $\chi^2_{Kru} > \chi^2_{krit}$, zamítáme H_0 a přijímáme H_1 .
- Test je vhodné používat, pokud je $N >$ asi 15!

12