

1 10-Analýza rozptylu jednoduchého třídění, ANOVA, Jednofaktorová analýza rozptylu

1.1 Nová látka

1.1.1 Testování homogenity rozptylů u r náhodných výběrů

- homogenita (stejnorodost) rozptylů u většího množství náhodných výběrů je důležitým předpokladem, který musí být splněn, abychom mohli provést tzv. ANOVU - jednofaktorovou analýzu rozptylu (viz dále).
- předpokládejme, že máme $r \geq 2$ náhodných výběrů
- testujeme nulovou hypotézu $H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_r^2 = \sigma^2$ oproti alternativní hypotéze H_1 : alespoň jedna dvojice rozptylů se liší
- testy rozptylu
 1. Levenův test
 - `levene.test(D,K)` knihovna `lawstat` ; $D\dots$ vektor dat, $K\dots$ typ skupiny
 - je založen na analýze rozptylu absolutních hodnot centrováných pozorování
 - výpočet je založen na 'hraní si' s odhady středních hodnot
 2. Brownův-Forsytův test
 - je modifikací Levenova testu
 - je založen na mediánu (namísto střední hodnoty)
 - při větších rozsazích náhodných výběrů ($n_i > 20$) jej lze použít i na data, které nejsou z normálního rozdělení
 - v Rku ho používat nebudeme, ale je dobré, abyste o něm aspoň slyšeli
 3. Bartlettův test
 - `bartlett.test(D,K)` knihovna `stat`
 - můžeme jej použít, pouze pokud jsou rozsahy všech výběrů větší než 6
 - nelze jej použít, pokud je více náhodných výběrů z výrazně nenormálního rozložení

1.1.2 ANOVA - Jednofaktorová analýza rozptylu

- zkoumá závislost intervalové/poměrové proměnné X na nominální proměnné A , které má alespoň dvě varianty
- $A\dots$ faktor; varianty $A\dots$ úrovně faktoru
- závislost X na A se projeví tím, že existuje statisticky významný rozdíl v průměrech proměnné X v náhodných výběrech, které vznikly třídením podle variant proměnné A .
- motivační příklady
 - má metoda výuky (faktor A) vliv na počet bodů (intervalová proměnná X) dosažených studenty v závěrečném testu?

- má typ potravy pračlověka (A) vliv na šířku stoliček (X)?
- má způsob života (A : na stromu-šplh; na zemi - šplhá málo) vliv na intenzitu svalových úponů na rukou (X)?
- má pohlaví (A) vliv na hmotnost člověka (X), nebo na šířku očnic (X)?

- trocha matematiky

- předpokládáme, že faktor A má $r \geq 2$ úrovní A_1, \dots, A_r , přičemž i -té úrovni odpovídá n_i pozorování X_{i1}, \dots, X_{in_i} . Tato pozorování tvoří náhodný výběr z $N(\mu_i, \sigma^2)$, $i = 1, \dots, r$. Celkový počet pozorování je $n = \sum_{i=1}^r n_i$. Jednotlivé náhodné výběry jsou stochasticky nezávislé.
- !!! Před samotnou ANOVOU musíme vždy ověřit předpoklady normality všech výběrů (r testů) a homogeneity rozptylů (1 hromadný test)
- Tečková anotace

* součet hodnot v i -tém výběru

$$X_{i\cdot} = \sum_{j=1}^{n_i} X_{ij}$$

* výběrový průměr v i -tém výběru

$$M_{i\cdot} = \frac{1}{n_i} X_{i\cdot}$$

- klasický aritmetický průměr dat z i -té skupiny, jen trochu jinak zapsaný

* součet hodnot všech výběrů

$$X_{..} = \sum_{i=1}^r \sum_{j=1}^{n_i} X_{ij}$$

* celkový průměr všech r výběrů

$$M_{..} = \frac{1}{n} X_{..}$$

- klasický aritmetický průměr všech dat

* celkový součet čtverců

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

- charakterizuje variabilitu jednotlivých pozorování kolem celkového průměru

- stejný princip jako výběrový rozptyl, akorát ho nedělíme počtem pozorování

- má počet stupňů volnosti $f_T = n - 1$

* skupinový součet čtverců

$$S_A = \sum_{i=1}^r n_i (M_{i\cdot} - M_{..})^2$$

- charakterizuje variabilitu mezi jednotlivými náhodnými výběry

- má počet stupňů volnosti $f_A = r - 1$

* reziduální součet čtverců

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

- charakterizuje variabilitu uvnitř jednotlivých výběrů - má počet stupňů volnosti
 $f_E = n - r$

- lze dokázat $S_T = S_A + S_E$.

1.1.3 Testování hypotéz o shodě středních hodnot

- na hladině významnosti α testujeme nulovou hypotézu, která tvrdí že všechny střední hodnoty jsou stejné $H_0 : \mu_1 = \dots = \mu_r$, proti alternativní hypotéze $H_1 : \text{Alespoň jedna dvojice tsředních hodnot se liší}$.
- vliv faktoru A není významný, oproti alternativě, že vliv faktoru A je významný.
- Testová statistika má tvar

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

- H_0 zamítáme na hladině významnosti α , pokud $F_A \in \langle F_{1-\alpha}(r-1, n-r), \infty \rangle$
- případně H_0 zamítáme na hladině významnosti α , pokud p -hodnota < α .
- výsledky výpočtů lze zapsat do přehledné tabulky - na hodině jsme si jí neuváděli

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

1.1.4 Post-hoc metody mnohonásobného porovnávání

- zamítneme-li nulovou hypotézu o shodě středních hodnot, chceme zjistit, která dvojice středních hodnot se významně liší na hladině významnosti α
- 2 mětody: *Tukeyova, Scheffého*
- Tukeyova metoda
 - * používá se, mají-li všechny výběry týž rozsah p
 - * rovnost středních hodnot $\mu_l = \mu_k$ zamítne na hladině významnosti α , pokud

$$|M_{k.} - M_{l.}| \geq q_{1-\alpha}(r, n-r) \frac{S_*}{\sqrt{p}}, \quad (2)$$

kde kvantily $q_{1-\alpha}$ najdeme ve statistických tabulkách a S_* je z minulé hodiny známý vážený průměr výběrových rozptylů. Lze jej ale zjednodušeně vypočítat podle vzorce $S_*^2 = \frac{S_E}{f_E}$.

- * existuje i modifikace Tukeyovy metody pro nestejné rozsahy výběrů tzv. *Tukey HSD metoda*
 - Scheffého metoda
 - * používá se, pokud nejsou rozsahy všech výběrů stejné
 - * rovnost středních hodnot μ_k a μ_l zamítneme na hladině významnosti α , když

$$|M_{k\cdot} - M_{l\cdot}| \geq S_* \sqrt{(r-1) \left(\frac{1}{n_k} + \frac{1}{n_l} \right) F_{1-\alpha}(r-1, n-r)}. \quad (3)$$

- * $S_*^2 = \frac{S_E}{f_E}$
- * metody mnohonásobného porovnávání jsou slabší, než ANOVA, proto se může stát, že ANOVOU zamítneme H_0 o shodě středních hodnot ale metody mnohonásobného porovnávání u žádné dvojice významný rozdíl nenašou.
- * dochází tomu tehdy, když p-hodnota pro ANOVU je jen o málo nižší než zvolená hladina významnosti

- POSTUP TESTOVÁNÍ ANOVY:

1. ověření normality
 - Q-Q plot + test
 - slabé porušení nevadí, anova na to není příliš citlivá
2. ověření rozptylu
 - krabicový graf - je šířka krabic stejná?; + test
 - na slabé porušení homogeneity rozptylu není anova příliš citlivá
3. testování shody středních hodnot
4. dojde-li k zamítnutí H_0 o shodě středních hodnot, použijeme *post-hoc metody*

- Zajímavost k testování homogeneity rozptylů:

Parametr σ^2 není znám a je třeba testovat hypotézu $H_0 : \mu_1 = \dots = \mu_r$. Na první pohled by se zdálo, že tento problém lze snadno převést na testování dvou nezávislých výběrů, a to tak, že vytvoříme dvojice souborů a na každou dvojici aplikujeme dvouvýběrový t-test na hladině významnosti α . Jestliže alespoň jedna dvojice dá signifikantní výsledek (tedy zamítáme hypotézu o shodnosti středních hodnot vybrané dvojice), zdá se, že můžeme zamítnout hypotézu H_0 . A současně hned vidíme, které dvojice se od sebe signifikantně liší. Tento postup však nesplňuje podmínu, že pravděpodobnost chyby prvního druhu má být α . Je-li totiž nulová hypotéza správná, pak každý t-test dá signifikantní výsledek, tj. zamítne hypotézu o shodě středních hodnot, s pravděpodobností α . My však chceme H_0 zamítnout, když alespoň jeden ze všech testů dá signifikantní výsledek. Takže pravděpodobnost zamítnutí H_0 , je-li správná, bude při $I \geq 3$ větší než α .

Příklad z hodiny:

Ústav antropologie vypsal konkurový přijetí nového antropologa do svých řad. Ředitel ústavu se rozhodl, že nedá na hezký obličejík a naučené fráze a vezme někoho, kdo je ve svém oboru zručný. Každý uchazeč měl za úkol provést v rámci pohovoru několik měření a byl mu stopován čas potřebný k měření. Konkurzu se zúčastnili tři kandidáti. Časy jejich měření v minutách jsou zaznamenány v tabulce:

1.antropolog:	3.6	3.8	3.7	3.5
2.antropolog:	4.3	3.9	4.2	3.9
3.antropolog:	4.2	4.5	4.0	4.1

Na hladině významnosti $\alpha = 0.05$ testujte hypotézu, že rychlosť měření těchto tří antropologů jsou stejně. Zamítnete-li nulovou hypotézu, určete, výkony kterých antropologů se liší na dané hladině významnosti $\alpha = 0.05$ a stanovte závěr, který by řediteli ústavu mohl zajímat.

Poznámka: Před samotným testováním **nezapomeňte ověřit, že všechny tři výběry pochází z normálních rozložení a že rozptyly těchto výběrů jsou shodné**. Jsou to důležité předpoklady, které musí být splněny, abychom mohli analýzu rozptylu použít. Normalitu otestujte pomocí vhodného testu (případně i graficky pomocí Q-Q plotu), shodu rozptylů potom ověřte pomocí Levenova testu a graficky pomocí krabicových diagramů. Proč nemůžeme k otestování shody rozptylů použít Bartlettův test?