

PŘEDPOKLADY MNČ

1. Regresní parametry (b_i) mohou nabývat libovolných hodnot. (V praxi obvykle existují omezení fyzikálního smyslu.)
2. Regresní model je lineární v parametrech. (Pomocí LR lze řešit např. i polynomické závislosti.)
3. Žádné dva sloupce matice \mathbf{X} nejsou kolineární, tj. rovnoběžné vektory. (V datech matice \mathbf{X} se nevyskytuje multikolinearita, matice $\mathbf{X}^T\mathbf{X}$ je dobře podmíněná.)
4. Chyby ε_i mají nulovou střední hodnotu. (Chyby "rovnoměrně" kolísají kolem 0, jejich hodnoty nejsou systematicky ovlivňovány.)
5. Náhodné chyby ε_i mají konstantní rozptyl (homoskedasticita).
6. Jednotlivé hodnoty závisle proměnné jsou získány nezávislým měřením. (Vzájemně nekorelované chyby ε_i .)
7. Nezávisle proměnné veličiny nejsou zatíženy systematickými či náhodnými chybami nebo jsou náhodné chyby zanedbatelné vůči náhodným chybám


POSTUPY PŘI PORUŠENÍ PŘEDPOKLADŮ MNČ

METODA PODMÍNKOVÝCH NEJMENŠÍCH ČTVERCŮ

- Používá se, pokud jsou na parametry b_i kladena omezení. Patří sem úlohy, kdy:
 - Některé parametry musí nabývat zadaných hodnot.
 - Některé parametry musí zachovávat vzájemné poměry.
 - Regresní model musí procházet zadanými body.

METODA VÁŽENÝCH NEJMENŠÍCH ČTVERCŮ

- Aplikujeme ji v případě, kdy náhodné chyby nemají konstantní rozptyl (byla prokázána heteroskedasticita v datech).
- Do rovnice pro výpočet účelové funkce se vkládá váhový koeficient w_i .




$$RSC = U(b) = \sum_i \left[y_i w_i - \sum_j w_i x_{ij} b_j \right]^2 \quad \text{kde } w_i \text{ je např. } \frac{1}{y} \text{ či } \frac{1}{\sigma}$$

METODA RACIONÁLNÍCH HODNOSTÍ

- Používá se v případě prokázané multikolinearity v datech.
- Obvykle se aplikuje při řešení polynomické regrese.

ORTOGONÁLNÍ REGRESE

- Jde o zvláštní případ metody rozšířených nejmenších čtverců pro případ, kdy chyby na ose x a y jsou srovnatelné ($s_x = s_y$).
- Je to obdoba MNČ, zde se minimalizuje suma kolmých vzdáleností experimentálních bodů od přímky.



ROBUSTNÍ REGRESE

- V případě porušení předpokladu normality chyb závisle proměnné nejsou odhady parametrů získané MNČ efektivní.
- Odhady parametrů získané MNČ jsou silně citlivé na přítomnost OB a EB.
- V takových případech místo kritéria MNČ použijeme robustního kritéria, které je jak na porušení předpokladu normality, tak na vlivné body málo citlivé. Nejznámější jsou M-odhady vycházející z minimalizace kritéria:

$$U_M = \sum_{i=1}^n \rho \left(\frac{e_i}{\sigma} \right) \quad \text{kde } \rho \text{ je vhodná funkce}$$

Př.: Welschův M-odhad – minimalizuje se čtverec vážených normovaných reziduí:

$$\rho = \frac{w^2}{2} \cdot \left(1 - \exp\left(-\frac{e_i/\sigma}{w}\right)^2 \right)$$

L_p – regrese

- Je příkladem robustních metod, kde se na rozdíl od MNČ minimalizuje součet:

$$U = |e_i|^p$$

- pro $p = 1$ – L_1 *aproximace* neboli *robustní mediánová regrese*, je vhodná pro data s OB na obou stranách nebo chybami s Laplaceovým rozdělením (špičatost rozdělení chyb > 3)
- pro $p = 2$ – MNČ
- pro $1 < p < 2$ – robustní regrese vůči odlehlým hodnotám (standardně se p volí 1,5)
- pro $p > 2$ (obvykle $p = 5-10$) – *metoda nejmenší maximální chyby*, což je metoda silně nerobustní k OB a je vhodná pro rovnoměrné rozdělení chyb (špičatost rozdělení chyb < 3)

Pro L_1 -aproximaci je účelová funkce

$$U = \sum_{i=1}^n |e_i|$$

a v případě přímky je účelová funkce

$$U = \sum_{i=1}^n |y_i - b_0 - b_1 x_i|$$