

Pořadové testy v regresi při rušivé heteroskedasticitě

Radim Navrátil, Jana Jurečková

Katedra pravděpodobnosti a matematické statistiky, MFF UK, Praha

Robust 2014, Jetřichovice
22.1.2014

Úvod

Homoskedasticita je často předpokládána při klasické analýze lineárního modelu.

Heteroskedasticita:

- Můžeme testovat její přítomnost před statistickou inferencí.
- Najít přístup, který je invariantní vůči heteroskedasticitě.

Cíl:

- Testy o regresi za přítomnosti rušivé heteroskedasticity.
- Testy homoskedasticity za přítomnosti rušivé regrese.

Oba typy testů jsou založeny na vhodných ancilárních statistikách, není tedy nutné odhadovat rušivé parametry modelu.

Historie

- Lineární model s možnou heteroskedasticitou

$$Y_i = \beta_0 + \mathbf{x}_i^\top \boldsymbol{\beta} + \sigma_i U_i, \quad i = 1, \dots, n.$$

- Požadavky na znalost struktury σ_i – mnoho modelů.
- Testy heteroskedasticity: Breusch and Pagan (1979), Carroll and Ruppert (1981), Koenker and Bassett (1982), Dette and Munk (1999).
- Pořadové testy: Akritas and Albers (1993), Gutenbrunner (1994).
- Odhad parametrů: Dixon and McKean (1996).

Model

$$Y_i = \beta_0 + \mathbf{x}_i^\top \boldsymbol{\beta} + \exp\{\mathbf{z}_i^\top \boldsymbol{\gamma}\} U_i, \quad i = 1, \dots, n,$$

$$\beta_0 \in \mathbb{R}, \boldsymbol{\beta} \in \mathbb{R}^p, \boldsymbol{\gamma} \in \mathbb{R}^q,$$

- \mathbf{x}_i je p -rozměrný vektor regresorů.
- \mathbf{z}_i je q -rozměrný vektor regresorů.
- U_i jsou i.i.d. náhodné veličiny s distribuční funkcí F , resp. absolutně spojitou hustotou f a konečnými nenulovými Fisherovými informacemi vzhledem k posunutí i měřítka.

$$\begin{aligned} \mathbf{H}_1 : \boldsymbol{\gamma} &= \mathbf{0}, \text{ proti alternativě } \mathbf{K}_1 : \boldsymbol{\gamma} \neq \mathbf{0}, \\ \mathbf{H}_2 : \boldsymbol{\beta} &= \mathbf{0}, \text{ proti alternativě } \mathbf{K}_2 : \boldsymbol{\beta} \neq \mathbf{0}. \end{aligned}$$

Test H_1

Za $H_1 : \gamma = \mathbf{0}$ máme model

$$Y_i = \beta_0 + \mathbf{x}_i^\top \boldsymbol{\beta} + U_i, \quad i = 1, \dots, n.$$

Zkonstruujeme vektor regresních pořadových skóru

$\hat{\mathbf{a}}_n(\alpha) = (\hat{a}_{n,1}(\alpha), \dots, \hat{a}_{n,n}(\alpha))^\top$, optimální řešení úlohy lineárního programování:

$$\hat{\mathbf{a}}_n(\alpha) = \arg \max \{ \mathbf{Y}_n^\top \mathbf{a} \mid \mathbf{X}_n^{*\top} \mathbf{a} = (1 - \alpha) \mathbf{1}_n^\top \mathbf{1}_n, \mathbf{a} \in [0, 1]^n \}, \quad 0 < \alpha < 1,$$

kde $\mathbf{Y}_n = (Y_1, \dots, Y_n)^\top$, $\mathbf{1}_n = (1, \dots, 1)^\top \in \mathbb{R}^n$ a
 $\mathbf{X}_n = (\mathbf{x}_1, \dots, \mathbf{x}_n)^\top$, $\mathbf{X}_n^* = (\mathbf{1}_n, \mathbf{X}_n)$.

Regresní kvantily

Koenker and Bassett (1978) zobecnili pojem kvantilu pro lineární regresní model, α -regresní kvantil:

$$\hat{\beta}_n(\alpha) = \operatorname{argmin} \left\{ \sum_{i=1}^n \rho_\alpha(Y_i - \mathbf{x}_i^{*\top} \mathbf{t}) \mid \mathbf{t} \in \mathbb{R}^{p+1} \right\},$$

kde $\rho_\alpha(x) = |x| \cdot (\alpha \mathbb{I}\{x > 0\} + (1 - \alpha) \mathbb{I}\{x < 0\})$.

Koenker and Bassett (1978): $\hat{\beta}_n(\alpha)$ lze počítat jako komponentu β optimálního řešení $(\beta, \mathbf{r}^+, \mathbf{r}^-)$ úlohy lineárního programování

$$\min \alpha \mathbf{1}_n^\top \mathbf{r}^+ + (1 - \alpha) \mathbf{1}_n^\top \mathbf{r}^-$$

vzhledem k

$$\begin{aligned} \mathbf{X}_n^* \beta + \mathbf{r}^+ - \mathbf{r}^- &= \mathbf{Y}_n \\ (\beta, \mathbf{r}^+, \mathbf{r}^-) &\in \mathbb{R}^{p+1} \times \mathbb{R}_+^{2n}, \end{aligned}$$

kde $\mathbf{Y}_n = (Y_1, \dots, Y_n)^\top$, $\mathbf{1}_n = (1, \dots, 1)^\top \in \mathbb{R}^n$ a
 $\mathbf{X}_n = (\mathbf{x}_1, \dots, \mathbf{x}_n)^\top$, $\mathbf{X}_n^* = (\mathbf{1}_n, \mathbf{X}_n)$.

Regresní pořadové skóry

Regresní kvantily – úloha lineárního programování:

$$\min \alpha \mathbf{1}_n^\top \mathbf{r}^+ + (1 - \alpha) \mathbf{1}_n^\top \mathbf{r}^-$$

vzhledem k

$$\begin{aligned}\mathbf{X}_n^* \boldsymbol{\beta} + \mathbf{r}^+ - \mathbf{r}^- &= \mathbf{Y}_n \\ (\boldsymbol{\beta}, \mathbf{r}^+, \mathbf{r}^-) &\in \mathbb{R}^{p+1} \times \mathbb{R}_+^{2n}.\end{aligned}$$

Vektor regresních pořadových skórů $\hat{\mathbf{a}}_n(\alpha)$ je optimálním řešením duální úlohy:

$$\hat{\mathbf{a}}_n(\alpha) = \arg \max \{ \mathbf{Y}_n^\top \mathbf{a} \mid \mathbf{X}_n^{*\top} \mathbf{a} = (1 - \alpha) \mathbf{X}_n^{*\top} \mathbf{1}_n, \mathbf{a} \in [0, 1]^n \}, \quad 0 < \alpha < 1.$$

Klíčová vlastnost: $\hat{\mathbf{a}}_n(\alpha)$ je invariantní vůči regresi \mathbf{X}_n^* , t.j. $\hat{\mathbf{a}}_n(\alpha)$ se nezmění pokud místo \mathbf{Y}_n pozorujeme $\mathbf{Y}_n + \mathbf{X}_n^* \boldsymbol{\delta}$ pro všechna $\boldsymbol{\delta} \in \mathbb{R}^{p+1}$.

Testová statistika

- Zvolíme funkci $\varphi : (0, 1) \mapsto \mathbb{R}$, integrovatelnou se čtvercem, "tvaru U".



$$\hat{b}_{n,i} = - \int_0^1 (\varphi(t) - \bar{\varphi}) d\hat{a}_{n,i}(t).$$



$$\mathbf{S}_n = n^{-1/2} \sum_{i=1}^n (\mathbf{z}_i - \hat{\mathbf{z}}_i) \hat{b}_{n,i}, \quad \mathcal{T}_n^2 = \frac{1}{A^2(\varphi)} \mathbf{S}_n^\top \hat{\mathbf{D}}_n^{-1} \mathbf{S}_n,$$



$$A^2(\varphi) = \int_0^1 (\varphi(t) - \bar{\varphi})^2 dt, \quad \bar{\varphi} = \int_0^1 \varphi(t) dt.$$



$$\hat{\mathbf{D}}_n = n^{-1} (\mathbf{Z}_n - \hat{\mathbf{Z}}_n)^\top (\mathbf{Z}_n - \hat{\mathbf{Z}}_n)$$

a $\hat{\mathbf{Z}}_n = \mathbf{X}_n^* (\mathbf{X}_n^{*\top} \mathbf{X}_n^*)^{-1} \mathbf{X}_n^{*\top} \mathbf{Z}_n$ je projekce \mathbf{Z}_n na prostor sloupců matice \mathbf{X}_n^* , resp. $\hat{\mathbf{z}}_i^\top$ je i -tý řádek matice $\hat{\mathbf{Z}}_n$.

Předpoklady

(F.1) $\left| \frac{f'(x)}{f(x)} \right| \leq c|x|, \text{ pro } |x| \geq K \geq 0, c > 0.$

(F.2) $f(x) > 0$ na (A, B) a absolutně spojitá, omezená a klesající pro $x \rightarrow A+$ a $x \rightarrow B-$, kde

$$-\infty \leq A = \sup\{x : F(x) = 0\},$$

$$\infty \geq B = \inf\{x : F(x) = 1\},$$

$$\sup_{0 < u < 1} u(1-u) \frac{|f'(F^{-1}(u))|}{f^2(F^{-1}(u))} = \alpha$$

pro $1 \leq \alpha \leq 1 + \frac{1}{4} - \varepsilon, \varepsilon > 0.$

Nechť existují pozitivně definitní matice $\widehat{\mathbf{D}}$, \mathbf{M} takové, že

$$\lim_{n \rightarrow \infty} \widehat{\mathbf{D}}_n = \widehat{\mathbf{D}}, \quad \lim_{n \rightarrow \infty} n^{-1} \mathbf{X}_n^{*\top} \mathbf{X}_n^* = \mathbf{M}.$$

$$\max_{1 \leq i \leq n} \|\mathbf{x}_i^*\| = o\left(n^{\frac{1}{4}-\eta}\right) \text{ pro nějaké } \eta > 0, \text{ pro } n \rightarrow \infty.$$

Asymptotické rozdělení

Věta

Za výše uvedených předpokladů T_n^2 má za hypotézy H_1 asymptoticky χ^2 rozdělení o q stupních volnosti a za lokální alternativy

$$\mathbf{K}_{1,n} : \boldsymbol{\gamma} = \boldsymbol{\gamma}_n = n^{-1/2} \boldsymbol{\gamma}^*, \quad \boldsymbol{\gamma}^* \in \mathbb{R}^q \text{ pevné}$$

má asymptoticky χ^2 rozdělení o q stupních volnosti a parametrem necentrality

$$\eta^2 = \frac{\tau_1^2(\varphi, f)}{A^2(\varphi)} \cdot \boldsymbol{\gamma}^{*\top} \widehat{\mathbf{D}} \boldsymbol{\gamma}^*,$$

$$\tau_1(\varphi, f) = \int_0^1 \varphi(t) \left(-1 - F^{-1}(t) \frac{f'(F^{-1}(t))}{f(F^{-1}(t))} \right) dt.$$

Poznámky

- Asymptotické rozdělení za H_1 nezávisí na rozdělení chyb modelu.
- Asymptotické rozdělení za K_1 nezávisí na hodnotě rušivého parametru β .
- Asymptotická síla testu je stejná jako u klasického pořadového testu, kde parametr β je známý.
- Test nerozliší alternativy s chybami $\exp\{\mathbf{x}_i^\top \gamma\} U_i$ kvůli ancilaritě regresních pořadových skóru.

Test H_2

Model:

$$Y_i = \beta_0 + \mathbf{x}_i^\top \boldsymbol{\beta} + \exp\{\mathbf{z}_i^\top \boldsymbol{\gamma}\} U_i, \quad i = 1, \dots, n.$$

Nechť F splňuje všechny předpoklady z minulého odstavce a navíc je symetrická a $\beta_0 = 0$.

Za platnosti $H_2 : \boldsymbol{\beta} = \mathbf{0}$ můžeme psát:

$$W_i = \mathbf{z}_i^\top \boldsymbol{\gamma} + V_i, \quad i = 1, \dots, n, \tag{1}$$

kde $W_i = \ln |Y_i|$, $V_i = \ln |U_i|$, $i = 1, \dots, n$.

Test H_2

Zkonstruujeme vektor regresních pořadových skóru

$\hat{\mathbf{a}}_n(\alpha) = (\hat{a}_{n,1}(\alpha), \dots, \hat{a}_{n,n}(\alpha))^{\top}$ v modelu

$$W_i = \mathbf{z}_i^{\top} \boldsymbol{\gamma} + V_i, \quad i = 1, \dots, n,$$

t.j. optimální řešení úlohy lineárního programování:

$$\hat{\mathbf{a}}_n(\alpha) = \arg \max \{ \mathbf{W}_n^{\top} \mathbf{a} \mid \mathbf{Z}_n^{\top} \mathbf{a} = (1 - \alpha) \mathbf{Z}_n^{\top} \mathbf{1}_n, \mathbf{a} \in [0, 1]^n \}, \quad 0 < \alpha < 1,$$

kde $\mathbf{W}_n = (W_1, \dots, W_n)^{\top}$, $\mathbf{1}_n = (1, \dots, 1)^{\top} \in \mathbb{R}^n$ a $\mathbf{Z}_n = (\mathbf{z}_1, \dots, \mathbf{z}_n)^{\top}$.

Předpoklady

- Nechť F je symetrická s konečnými nenulovými Fisherovými informacemi vzhledem k posunutí i měřítka a splňuje (F.1) a (F.2).
- $z_{i,1} = 1, i = 1, \dots, n$ a $\max_{1 \leq i \leq n} \|z_i\| = \mathcal{O}(1)$.
- $\tilde{\mathbf{D}}_n = \frac{1}{n} \sum_{i=1}^n z_i z_i^\top \rightarrow \tilde{\mathbf{D}}$ kde $\tilde{\mathbf{D}}$ je pozitivně definitní.
- $\tilde{\mathbf{Q}}_n(\gamma) = n^{-1} \sum_{i=1}^n e^{-z_i^\top \gamma} (\mathbf{x}_i - \hat{\mathbf{x}}_i)(\mathbf{x}_i - \hat{\mathbf{x}}_i)^\top \rightarrow \tilde{\mathbf{Q}}(\gamma), \quad \forall \gamma \in \mathbb{R}^q$,
kde $\tilde{\mathbf{Q}}(\gamma)$ je pozitivně definitní a $\hat{\mathbf{x}}_i^\top$ je i -tý řádek
 $\hat{\mathbf{X}}_n = \mathbf{Z}_n (\mathbf{Z}_n^\top \mathbf{Z}_n)^{-1} \mathbf{Z}_n^\top \mathbf{X}_n$. Dále pro jednoduchost označme
 $\tilde{\mathbf{Q}}_n(\mathbf{0}) \equiv \tilde{\mathbf{Q}}_n$ and $\tilde{\mathbf{Q}}(\mathbf{0}) \equiv \tilde{\mathbf{Q}}$.

Testová statistika

- Zvolíme funkci $\varphi : (0, 1) \mapsto \mathbb{R}$, integrovatelnou se čtvercem, neklesající a nekonstantní, pro jejíž derivaci platí, že pro všechna $0 < u < \alpha_0$, $1 - \alpha_0 < u < 1$ je

$$|\varphi'(u)| \leq c(u(1-u))^{-1-\delta} \quad \text{pro nějaké } \delta > 0.$$



$$\hat{b}_{n,i}^+ = - \int_0^1 (\varphi^+(t) - \bar{\varphi}^+) d\hat{a}_{n,i}(t), \quad \varphi^+(u) = \varphi\left(\frac{u+1}{2}\right), \quad 0 < u < 1.$$



$$\tilde{\mathbf{S}}_n = n^{-1/2} \sum_{i=1}^n (\mathbf{x}_i - \hat{\mathbf{x}}_i) \operatorname{sign} Y_i \hat{b}_{n,i}^+,$$



$$\tilde{T}_n^2 = \frac{1}{A^2(\varphi)} \tilde{\mathbf{S}}_n^\top \tilde{\mathbf{Q}}_n^{-1} \tilde{\mathbf{S}}_n$$

Asymptotické rozdělení

Věta

Za výše uvedených předpokladů \tilde{T}_n^2 má za hypotézy H_2 asymptoticky χ^2 rozdělení o p stupních volnosti a za lokální alternativy

$$\mathbf{K}_{2,n} : \boldsymbol{\beta} = \boldsymbol{\beta}_n = n^{-1/2} \boldsymbol{\beta}^*, \quad \boldsymbol{\beta}^* \in \mathbb{R}^p \text{ pevné}$$

má asymptoticky χ^2 rozdělení o p stupních volnosti a parametrem necentrality

$$\tilde{\eta}^2(\gamma) = \frac{\tau_1^2(\varphi, f)}{A^2(\varphi)} \cdot \boldsymbol{\beta}^{*\top} \tilde{\mathbf{Q}}^\top(\gamma) \tilde{\mathbf{Q}}^{-1}(\gamma) \tilde{\mathbf{Q}}(\gamma) \boldsymbol{\beta}^*.$$

Poznámky


- Asymptotické rozdělení za H_2 nezávisí na rozdělení chyb modelu.
- Asymptotické rozdělení za K_2 závisí na hodnotě rušivého parametru γ .
- Asymptotická síla testu je stejná jako u klasického pořadového testu, kde parametr γ je známý.
- Předpoklad symetrie.

Příklad


- Data: M. Ezekiel, K. A. Fox (1959). *Methods of correlation and regression analysis*. Wiley, New York.
- Údaje o $n = 63$ autech.
- Y_i brzdná dráha (ft) i -tého auta.
- z_i rychlosť (mph) i -tého auta.
- Uvažovaný model kvadratické závislosti:

$$Y_i = \beta z_i^2 + e_i, \quad i = 1, \dots, 63.$$


Data



Data s odhadnutou kvadratickou závislostí



Závislost reziduí na rychlosti



Příklad - obecnější model

- Možná heteroskedasticita v datech.
- Obecnější model:

$$Y_i = \beta z_i^2 + \exp\{\gamma z_i\} U_i, \quad i = 1, \dots, 63.$$

Test $\mathbf{H}_1 : \gamma = 0$ proti $\gamma > 0$:

- Testová statistika \mathcal{T}_n^2 s Wilcoxonovými skóry pro měřítko, t.j. generovaná skórovou funkcí $\varphi(t) = -1 + (2t - 1) \log \frac{t}{1-t}$.
- Odpovídající p -hodnota je 0.043 \implies heteroskedasticitu musíme připustit.

Test $\mathbf{H}_2 : \beta = 0$ proti $\beta > 0$:

- $\tilde{\mathcal{T}}_n^2$ s Wilcoxonovými skóry generovanými funkcí $\varphi(t) = t - \frac{1}{2}$.
- Odpovídající p -hodnota je 0.0085 \implies regrese je skutečně přítomná.

Závěr

Testy homoskedasticity za přítomnosti rušivé regrese a testy významnosti regrese za přítomnosti rušivé heteroskedasticity.

- Konstruovány bez nutnosti odhadu rušivých odhadů.
- Výpočetně nenáročné, odpadá riziko užití špatného odhadu.
- Rozšíření klasických pořadových testů (regresní pořadové skóry místo pořadí).
- Asymptoticky ekvivalentní odpovídajícím testům v modelu bez rušivých parametrů, kde jejich hodnoty jsou známé.
- Blízkost potvrzena i numericky pro konečný počet pozorování.
- Testy homoskedasticity s rušivou regresí $\mathbf{X}\boldsymbol{\beta}$ nerozliší alternativy s chybami $\exp\{\mathbf{x}_i^\top \boldsymbol{\gamma}\} U_i$ kvůli ancilaritě regresních pořadových skórů.
- Testy o regresi s rušivou heteroskedasticitou - předpoklad symetrie rozdělení chyb modelu.

Poděkování

Děkuji za pozornost.

Práce byla spolufinancována grantem SVV-2013-267 315 a projektem Klimatext
reg.číslo CZ.1.07/2.3.00/20.0086.