




Kvantilová regrese a odhad Paretova indexu

Jan Dienstbier

dienstbi@karlin.mff.cuni.cz

KPMS, MFF-UK, Praha



V příspěvku je načrtnut jeden z možných přístupů k odhadu Paretova indexu v regresním případě, kdy jsou náhodné veličiny stochasticky závislé na vektoru nezávislých proměnných. Metoda využívá kvantilové regrese.

Analýza extrémních událostí

Necht jsou X_1, \dots, X_n pro $n \in N$ nezávislé stejně rozdělené náhodné veličiny se spojitou distribuční funkcí. Podle **Fisher-Tippetovy věty** lze pak vlastnosti rozdělení chvostů X_i (tj. i vlastnosti maxim $X_{n,n} := \max\{X_1, \dots, X_n\}$) asymptoticky popsat jediným parametrem γ – tzv. **Paretovým indexem**. Mluvíme o třech **sférách přitažlivosti** neboli o rozděleních


- **Fréchet-Paretova typu** pro $\gamma > 0$, tj. s těžkými chvosty,
- **Gumbelova typu** pro $\gamma = 0$, tj. s exponenciálními chvosty,
- **Weibullová typu** pro $\gamma < 0$, tj. s omezenými chvosty.

V literatuře byla popsána celá řada odhadů γ – viz Beirlant et al. (2004).

Př. Hillův odhad

$$H_{k,n} = \frac{1}{k} \sum_{i=0}^{k-1} \log X_{n-i,n} - \log X_{n-k,n}.$$

Na obrázku vidíme **závislost Hillova odhadu na k** , tj. volbě podílu dat použitých pro výpočet. Data byla získána simulací z absolutních hodnot Tukeyho rozdělení o dvou stupních volnosti ($|T_2|$). Skutečná hodnota $\gamma = 0.5$ je indikována čarou. Lze vyzorovat klesající rozptyl odhadu s rostoucím k a naopak rostoucí vychýlení. Příklad demonstruje **důležitost volby "optimálního" podílu dat**, problém, který se tak či onak objeje u většiny odhadů extrémního indexu γ .



Regresní případ

Uvažujme nyní regresní případ $Y_i = \beta^\top \mathbf{x}_i + \mathbf{u}_i$, $i = 1, \dots, n$, kde \mathbf{u}_i jsou nezávislé náhodné veličiny. Vraťme se nyní zpět a podívejme se, co nám brání použít odhadů odvozené pro stejně rozdělené náhodné veličiny.

Motivace:

$$\frac{1}{\log 2} \log \left\{ \frac{Q(1 - 1/4y) - Q(1 - 1/2y)}{Q(1 - 1/2y) - Q(1 - 1/y)} \right\} \xrightarrow{y \rightarrow \infty} \gamma,$$

kde $Q(y) = F^\leftarrow(y) = \inf \{x : F(x) \geq y\}$.

$$\downarrow Q(1 - 1/y) \approx X_{n-k+1,n} (!)$$

Pickandsův odhad

$$\hat{\gamma}_{P,k} := \frac{1}{\log 2} \log \left(\frac{X_{n-\lceil k/4 \rceil + 1, n} - X_{n-\lceil k/2 \rceil + 1, n}}{X_{n-\lceil k/2 \rceil + 1, n} - X_{n-k+1, n}} \right)$$

Je tedy nutné odhadnout $Q(1 - 1/y)$ něčím "lepším" než je $X_{n-k+1,n}$.

Kvantilová regrese

Myšlenkou lineární kvantilové regrese je nalezení řešení minimalizační úlohy

$$\min_{b \in \mathbb{R}^p} \sum_{i=1}^n \rho_\tau(y_i - \mathbf{x}_i^\top b),$$

kde ρ_τ označuje ztrátovou funkci

$$\rho_\tau(u) := u \cdot (\tau - I(u < 0)).$$

Za **τ -tý regresní kvantil** se pak označuje $\hat{Q}_Y(\tau|x_i) := x_i^\top \hat{b}(\tau|Y, \mathbf{x})$. Přirozeně se tak nabízí nasledující modifikace stávajících odhadů, použitelná nejen pro Pickandsův ale např. i pro Hillův odhad.

1 Obecný model

$$\mathbf{u}_i \sim F(\theta(\mathbf{x}_i); z)$$



$$Q(\tau) \approx \hat{Q}_Y(\tau|x_i)$$

2 Model se stejně rozdelenými chybami


$$\mathbf{u}_i \sim F(\theta; z)$$



$$Q(\tau) \approx \hat{b}_0(\tau|Y, \mathbf{x})$$


Simulační studie

- metodu demonstrujeme pro model se stejně rozdelenými chybami
- jiné simulace však ukázaly její funkčnost i pro obecnější model – ten by ale vyžadoval více prostoru pro diskuzi



První obrázek ukazuje graf modifikovaného Hillova odhadu v závislosti na k , tj. pro různá $\tau = [k/n]$. Byla opět simulována náhodná čísla z $|T_2|$, tentokrát však s malým lineárním posunutím $Y_i = 0.002X_i + |T_2|$, $X_i = 1, \dots, 1000$. Modře je vyznačen modifikovaný Hillův odhad využívající kvantilové regrese s lineárním trendem, červeně pak modifikovaný Hillův odhad založený na kvadratickém trendu, který je v této situaci zjevně neadekvátní (zbytečně široký). Pro srovnání je zakreslen obvyklý Hillův odhad – červeně a Hillův odhad aplikovaný na data, z nichž byl zpětně odstraněn lineární trend – černě.

Na dalším obrázku znovu vidíme grafy kvantilovou regresí modifikovaných odhadů – Hillův odhad (modře) a Momentový odhad (šedě). Tentokrát byla generována data z Paretova $Pa(4)$ rozdělení a přičtena ke kvadratickému trendu $Y_i = 1/20X_i^2 + 2X_i + |Pa(4)|$, kde $X_i = \{1, \dots, 40, 1, \dots, 40, \dots, 1, \dots, 40\}$ a $i = 1, \dots, 1200$. Skutečná hodnota $\gamma = 0.25$ je vyznačena obvyklým způsobem černou čarou.



Výhled do budoucna

Prezentovaná metoda byla načrtnuta pouze v hrubých obrysech. Řada otázek tak zůstává otevřena. Například konzistence odhadů byla dosud dokázána pouze pro v praxi nepoužitelný Pickandsův odhad – viz Chernozhukov (2000). Tento důkaz však nelze použít pro jiné odhady. Východiskem by snad mohl být funkcionální přístup k odhadu γ popsáný v Drees (1998). Zcela není dořešena ani vlastní konstrukce odhadů např. důležitá problematika jejich invariance na posunutí, otázka τ versus $\frac{k}{n}$ atp. Pro aplikaci do praxe pak schází implementace do statistického softwaru (např. do R).

Literatura

- [1] Beirlant J. et al. (2004). *Statistics of Extremes*, John Wiley, Chichester.
- [2] Drees H. (1998). *On Smooth Statistical Tail Functionals*, Scandinavian Journal of Statistics **25**, 187–210.
- [3] Chernozhukov V. (2000). *Conditional Extremes and Near-Extremes: Concepts, Estimation, and Economic Applications*, Stanford Ph.D. Dissertation, <http://www.mit.edu/~vchern/ced.ps>
- [4] Koenker R. (2005). *Quantile Regression*, Cambridge University Press, Cambridge