



# Robustifikace hřebenové regrese - první pokusy

Tomáš Jurczyk

Matematicko-fyzikální fakulta, UNIVERZITA KARLOVA V PRAZE, Katedra pravděpodobnosti a matematické statistiky, Sokolovská 83, 18675 Praha 8, ČR



## 1 Abstrakt

Jeden z problémů, se kterými se můžeme při datové analýze setkat, je multikolarita (téměř lineární závislost mezi regresory). Multikolarita vede k nestabilitě řešení normální rovnice a může způsobit velký rozptyl odhadu regresních koeficientů. Jednou z metod, která se snaží tento problém řešit je hřebenová regrese. Tato metoda ale není imunní vůči přítomnosti kontaminace, která může multikolaritu skrýt nebo ji naopak uměle vytvořit. Tento příspěvek se věnuje prvním jednoduchým pokusům o robustifikaci metody hřebenové regrese. V práci jsou představeny dva návrhy založené na robustní metodě nejmenších vážených čtverců (LWS).

## 2 Multikolarita

### Značení

Předpokládáme lineární regresní model  $y = X\beta + e$ , kde regresní matice má plnou hodnost  $h(X) = k$ ,  $e \sim (0, \sigma^2 I)$ .  $b$  je klasický odhad  $\beta$  metodou nejmenších čtverců.

### Co je to multikolarita

Termín multikolarita nebo také kolinerita označuje situaci, kdy jsou regresory „téměř“ lineárně závislé.

## 3 Hřebenová regrese

### Jak řešit problém s multikolaritou?

Místo klasického odhadu se v případě podezření na multikolaritu raději použijte vychýlený odhad:

#### Definice hřebenové regrese

Pro  $\delta \geq 0$  definujeme hřebenový odhad vektoru  $\beta$  jako

$$b_\delta = (X'X + \delta I)^{-1} X'y.$$

- Tento odhad má při malých hodnotách  $\delta$  (přesněji  $0 < \delta < 2\sigma^2 \|\beta\|^{-2}$ ) menší čtvercovou chybu než klasický odhad  $b$ .

### Volba $\delta$

Možnosti, jak volit  $\delta$ :

- Odhadne se horní mez (viz předešlá vlastnost):  $\delta = 2s^2 \|\hat{b}\|^{-2}$ , kde  $s^2$  je odhad  $\sigma^2$ . Někdy se také doporučuje  $\delta = ks^2 \|\hat{b}\|^{-2}$ .
- Grafickou metodu zvanou ridge trace, kde se vynášejí do grafu hřebenové odhady koeficientů proti proměnné  $\delta$ . Za vhodné volbu  $\delta$  se pak považuje podle autorů metody taková hodnota, při níž jsou již znaménka a hodnoty složek  $b_\delta$  stabilizovány.

### Problémy

Hřebenová regrese není díky své konstrukci uzpůsobena pro práci s odlehými pozorováními. Navíc odlehá pozorování mohou multikolaritu skrýt nebo ji naopak uměle vytvořit – už i jedno přidání odlehle pozorování může výrazně změnit, jak výběrový korelační koeficient, tak například i výše zmíněné indexy podmíněnosti.

**Detekce multikolarity v kontaminovaných datech je velmi důležitá, protože odhaluje pravé závislosti v datech.**

### Důsledky

Nechť  $X = PTQ'$  je rozklad matice  $X$  podle singulárních hodnot.



- $P'P = Q'Q = QQ' = I_k$
- $T$  diagonální s  $t_1 \geq t_2 \geq \dots \geq t_k > 0$
- Za multikolarity je hodnota  $t_k$ , případně i dalších  $t_j$ , velmi malá.

Dá se ukázat, že:

$$E \|b\|^2 = \|\beta\|^2 + \sigma^2 \sum_{i=1}^k t_i^{-2}$$

$$\text{var } b = \sigma^2 \sum_{i=1}^k t_i^{-2} q_i q_i'$$

$q_i$  sloupce matice  $Q$ .

Multikolarita způsobuje velkou očekávanou hodnotu délky vektoru  $b$  a může způsobit velký rozptyl statistiky  $b_j$ .

### Detekce

Jednou z možností zjišťování multikolarity je využití indexů podmíněnosti:

$$\eta_j = t_1/t_j, j = 1, \dots, k.$$

Tyto je výhodné takto definovat především pro  $X$  s normovanými sloupci.

Použití – v literatuře se uvádí toto:

- $\eta_j < 10(30)$  – vše v pořádku
- $\eta_j \in (10(30), 100)$  – podezření na multikolaritu, je nutná opatrnost
- $\eta_j > 100$  – jedná se o silný vztah mezi regresory

Výsledky převzaty z knihy [Zvára (1989)].

## 4 Nejmenší vážené čtverce

Nejprve definujeme metodu vážených nejmenších čtverců:

### Definice WLS

Nechť  $w_i > 0, i = 1, \dots, n$  jsou váhy. Potom odhad

$$b^{(WLS,w)} = \underset{\beta \in \mathbb{R}^p}{\text{argmin}} \sum_{i=1}^n w_i r_i^2(\beta)$$

nazoveme odhadem metodou vážených nejmenších čtverců (WLS – the weighted least squares).

Ekvivalentně

$$b^{(WLS,w)} = (X'WX)^{-1} X'Wy,$$

kde  $n$  je počet pozorování,  $r_i$  je reziduum pro  $i$ -té pozorování a  $W = \text{diag}(w_1, \dots, w_n)$ .

- Takto definované vážené nejmenší čtverce jsou vlastně klasickou regresí na data  $W^{1/2}y, W^{1/2}X$ . Každé pozorování je převáženo.

Nyní definujeme metodu, která byla představena v článku [Višek (2001)]. Jedná se o robustní metodu, kterou bychom rádi využili při robustifikaci hřebenové regrese.

### Definice LWS

Nechť  $1 = w_1 \geq w_2 \geq \dots \geq w_n \geq 0$  jsou váhy. Potom

$$b^{(LWS,w)} = \underset{\beta \in \mathbb{R}^p}{\text{argmin}} \sum_{i=1}^n w_i r_i^2(\beta)$$

se nazývá odhad metodou nejmenších vážených čtverců (LWS – the least weighted squares).  $r_{(n)}^2 \geq \dots \geq r_{(1)}^2$  jsou uspořádané kvadráty reziduí.

- Všimněme si, že jednotlivé váhy nejsou přímo přiřazeny konkrétnímu pozorování, metoda sama přiřadí váhy implicitně k pozorováním.
- Výsledný odhad LWS je vlastně odhad WLS s váhovou maticí  $W(\pi)$ , která vznikne jistou permutací prvků na diagonále matice  $W$ , tedy

$$b^{(LWS,w)} = (X'W(\pi)X)^{-1} X'W(\pi)y,$$

kde  $\pi$  je permutace zajišťující minimalizaci kritériální funkce LWS.

### Algoritmus výpočtu LWS<sup>1</sup>

Dva cykly – vnitřní cyklus vybírá metodou iterativně vážených nejmenších čtverců kandidáta na dosažení minima (je potřeba iterační metoda, protože přiřazení vah závisí na reziduích a rezidua závisí na odhadu koeficientů). Vnější cyklus zaznamenává do té doby nejlepší model a také kolikrát byl dosažen. Pokud je do té doby nejlepšího modelu dosaženo opakovaně (řekněme 20 krát) algoritmus končí a tento model je prohlášen za odhad LWS.

<sup>1</sup>Podrobnější informace o algoritmu například v článku [Višek (2008)].

## Reference

- [Rousseeuw and Leroy (1987)] Rousseeuw, P. J., and Leroy, A. M., Robust Regression and Outlier Detection, John Wiley & Sons, 1987.
- [Višek (2001)] Višek, J. Á., Regression with high breakdown point, Robust 2000 (eds. Jaromír Antoch & Gejza Dolmal, published by Union of Czech Mathematicians and Physicists), Prague: matfyzpress, 324-356, 2001.
- [Višek (2008)] Višek, J. Á., Consistency of the Instrumental Weighted Variables, To appear in Annals of the Institute of Statistical Mathematics, 2008.
- [Zvára (1989)] Zvára, K., Regresní analýza, Academia, Praha, 1989.

## 5 Robustifikace hřebenové regrese

V této části budou představeny dva první jednoduché návrhy na robustifikaci metody hřebenové regrese za použití nejmenších vážených čtverců. Také bude shrnuto, jak si tyto metody vedly v případech, kdy byla multikolarita kontaminací zakrytá.

### Hřebenová regrese a WLS

Nejdříve je potřeba si uvědomit, že volba vah u WLS neřeší problém se závislostí mezi regresory. Jednotlivá pozorování jsou převážena, to ale nepotlačí závislosti mezi jednotlivými složkami pozorování. Proto pokud je problém s multikolaritou u regresní matice  $X$ , bude tento problém i u  $W^{1/2}X$ . Hřebenovou regresí pro WLS má tedy smysl definovat jako  $b_\delta^{WLS,w} = (X'WX + \delta I)^{-1} X'Wy$ .

### Hřebenová regrese a LWS (robustní hřebenová regrese)

#### Popis metody

Dvoukrokový odhad:

- 1.krok: Nejdříve se spočítá LWS
- 2.krok: V prvním kroku získané  $W(\pi)$  využijeme pro výpočet klasické hřebenové regrese na data  $W(\pi)^{1/2}y, W(\pi)^{1/2}X$ . Tedy  $b_\delta^{LWS,w} = (X'W(\pi)X + \delta I)^{-1} X'W(\pi)y$ .

#### Idea aneb proč by to mohlo fungovat

Máme data, kde odlehá pozorování zakrývá problém s multikolaritou.

Indexy podmíněnosti toto neodhalí, také ridge trace vypadá odlišně než u případu s téměř závislými sloupci.

Pokud použijeme LWS s váhami, kde  $w_i = 0$  pro  $i > h$  pro nějaké  $h$  a tato metoda odhalí všechna odlehá pozorování, pak na datech  $W(\pi)^{1/2}y, W(\pi)^{1/2}X$  bude již kolinerita patrná a na tato nová data se pak použije hřebenová regrese.

*Poznámka:* Pokud by toto fungovalo, pak by se v takových případech dala LWS výhodně použít jako robustní detektor multikolarity.

#### Výsledky

Ačkoli se zdají být tyto úvahy správné, na simulovaných a také na datech z knihy [Zvára (1989)] (kapitola 9.) se ukázalo, že takto navržená metoda nefunguje, jak bychom čekali.

Za přítomnosti odlehlejších pozorování zakrývajících multikolaritu LWS neodhalí správně tato odlehá pozorování, ačkoli je na to „stavěná“. Navíc

dává přiřazením vah vždy alespoň jednomu z odlehlejších velmi vysokou důležitost.

#### Interpretace tohoto jevu

Jsem přesvědčen, že tento problém je způsoben tím, že v datech je vlastně jakási volnost způsobená téměř závislostí. V datech jsou v zásadě dvě skupiny regresorů, které se snaží vysvětlit to samé.

Při přidání odlehlejších pozorování k datům se potom může jedna z těchto skupin soustředit výhradně na vyrovnání jen tohoto pozorování – přítom může být toto vyrovnání velmi přesné. Což vede k tomu, že LWS vybere raději tento model s přesně vyrovnaným odlehlejších pozorováním místo modelu na skutečných datech, která jsou ovšem nestabilní.

#### Závěr

- Vlivem skryté multikolarity nedokáže navržená metoda ve svém prvním kroku úspěšně odhalit všechna odlehá pozorování, a proto není vhodným kandidátem pro robustní verzi hřebenové regrese.
- V knize [Rousseeuw and Leroy (1987)] doporučují autoři řešit možný problém skryté multikolarity tím, že také nejdříve očistí data od odlehlejších pozorování metodou nejmenšího mediánu čtverců a poté provedou hřebenovou regresí.

Vzhledem k předešlým úvahám a provedeným analýzám se obávám, že tato metoda také nemůže fungovat správně.

Návrh 2

### Popis metody

Pro pevné  $\delta$  se do vnitřního cyklu LWS implementuje iteračně

$$b_{(k+1)} = (X'W(\pi_{(k)})X + \delta I)^{-1} X'W(\pi_{(k)})y$$

místo

$$b_{(k+1)} = (X'W(\pi_{(k)})X)^{-1} X'W(\pi_{(k)})y.$$

Vnější cyklus pak vyhodnocuje nejlepší model podle klasického kritéria LWS.

### Nevýhody

Pro zkonstruování ridge trace se provede takto upravená metoda pro nějakou mříž hodnot  $\delta$ . Nic ale nezaručuje, že s rostoucím  $\delta$  zůstane výsledná ideální permutace vah stále stejná, což potvrdily i provedené výpočty. V ridge trace se tedy mohou vyskytovat skoky.

Tím se komplikuje výběr vhodného  $\delta$ . Navíc je také otázka, co vůbec znamenají návrhy a) na volbu  $\delta$  v části o hřebenové regresí, protože odhad z celých dat za přítomnosti kontaminace může být touto kontaminací výrazně ovlivněn, nehledě na další problémy s tím spojené.

### Výhody

S rostoucím  $\delta$  se narodí od návrhu 1 této metodě dařilo na zkoumaných datových souborech správně odhalit všechna odlehá pozorování a tím objevit skrytou multikolaritu.

### Závěr

- Možné problémy s volbou  $\delta$ .
- S rostoucím  $\delta$  se metodě daří správně identifikovat všechna odlehá pozorování zakrývajících multikolaritu!

## 6 Plány do budoucna

V tomto posteru byly prezentovány zatím jen úplně základní návrhy, je možné hledat další metody, ať už vycházející z hřebenové regrese či například z regrese s lineárními omezeními, která se také používá při výskytu kolinerity.

První výsledky prezentovaného návrhu 2 se zdají být velmi slibné, proto je potřeba se touto metodou zabývat podrobněji.

Také zůstává nezodpovězeno mnoho dalších otázek, například v práci nebyl diskutován problém dat, kde je multikolarita uměle vytvořena odlehlejšími pozorováními, apod.