

Vliv multikolinearity a odlehlých pozorování

Tomáš Jurczyk

Univerzita Karlova v Praze,
Matematicko-fyzikální fakulta

Katedra pravděpodobnosti a matematické statistiky



ROBUST 2010, Králíky, 31.1.-5.2.2010

Struktura posteru

*Nejmenší
čtverce*

Multikolinearita
→

*Metody bojující
s multikolinearitou*

Odlehlá pozorování
↓

Multikolinearita
+ odlehlá pozorování
↓

*Robustní
metody*

Multikolinearita
→
+ odlehlá
pozorování


*Metody řešící
oba problémy*

Klasické metody

Problémy jsou v posteru názorně ukázány pomocí grafů ztrátových funkcí:

Metoda nejmenších čtverců:

Příklad (Ztrátová funkce pro LS, 2 regresory, data **bez** multikolinearity)



- ← $\sum_{i=1}^n (Y_i - x_{1i}\beta_1 - x_{2i}\beta_2)^2 = \sum_{i=1}^n r_i^2(\beta)$
- ← typický tvar pro data bez multikolinearity
- ← $(b_1, b_2)' = \mathbf{b}$ značí LS odhad – nejmenší hodnota ztrátové funkce


Problémy s multikolinearitou

Multikolinearita

- ▶ situace, kdy jsou regresory "téměř" lineárně závislé

Důsledky pro nejmenší čtverce (Ztrátová funkce pro **LS**, 2 regresory, data **s multikolinearitou**)

- tvar odpovídající silné multikolinearitě v datech
- téměř stejné hodnoty ztrátové funkce podél jisté přímky v parametrickém prostoru \Rightarrow nestabilní chování \Rightarrow **velký rozptyl odhadu**



Řešení problémů s multikolinearitou

Abychom se vyhnuli velkým rozptylům statistik b_j , doporučuje se za přítomnosti multikolinearity používat následující vychýlený odhad.

Hřebenová regrese

Pro $\delta \geq 0$ definujeme *hřebenový odhad* vektoru β jako

$$\mathbf{b}_\delta = \underset{\beta \in \mathcal{R}^p}{\operatorname{argmin}} \left(\sum_{i=1}^n r_i^2(\beta) + \delta \sum_{j=1}^p \beta_j^2 \right).$$

Jak funguje hřebenová regrese

příklad



(2 regresory, data s multikolinearitou)

Ztrátová funkce pro LS odhad

$$\sum_{i=1}^n r_i^2(\beta)$$

Ztrátová funkce pro hřebenový odhad

$$\sum_{i=1}^n r_i^2(\beta) + \delta \sum_{j=1}^p \beta_j^2$$



Struktura posteru



Metoda řešící oba problémy

*Nejmenší
čtverce*

Multikolinearita
→

*Hřebenová
regrese*

Odlehlá pozorování



Multikolinearita
+ odlehlá pozorování



*Nejmenší
vážené
čtverce*

Multikolinearita
→
+ odlehlá
pozorování

*Robustní
hřebenová
regrese*

Metoda řešící oba problémy

$$\sum_{i=1}^n r_i^2(\beta)$$

→

$$\sum_{i=1}^n r_i^2(\beta) + \delta \sum_{j=1}^p \beta_j^2$$

↓

$$\sum_{i=1}^n w_i r_{(i)}^2(\beta)$$

→

$$\sum_{i=1}^n w_i r_{(i)}^2(\beta) + \delta \sum_{j=1}^p \beta_j^2$$

Návrh robustní hřebenové regrese

Dospěli jsme tedy k návrhu metody, která by se měla umět vypořádat s oběma problémy najednou.

Hřebenový odhad nejmenších vážených čtverců

Pro $\delta \geq 0$ definujeme *hřebenový odhad nejmenších vážených čtverců* vektoru β jako

$$\mathbf{b}_{\delta}^{(LWS, w)} = \underset{\beta \in \mathcal{R}^p}{\operatorname{argmin}} \left(\sum_{i=1}^n w_i r_{(i)}^2(\beta) + \delta \sum_{j=1}^p \beta_j^2 \right).$$

Děkuji
za
pozornost

Více informací na mém posteru