


Minimle: Hraheniova' regresia

$$y = X\beta + \epsilon$$

$$\left[\min_{\beta} \|y - X\beta\|_2^2 + \lambda \|\beta\|_2^2 \right]$$

ako uloha s obmedzenim:

$$\left\{ \begin{array}{l} \min_{\beta} \|y - X\beta\|_2^2 \\ \|\beta\|_2^2 \leq c \end{array} \right\}$$



- Ridge: napr. riesi situaciu, ked' X_i, X_i su vysoko korelovane'
 - $\hat{\beta}$: jedna hodnota velmi velka, druhá velmi zporneá
 - $\hat{\beta}_{ridge}$: zmierni ich
 - $\hat{\beta}_{ridge}$: zmierni odhadovanie ⇒ zvyčajne: normalizacia X_1, \dots, X_{p-1} najprv
 - $\hat{\beta}_{ridge}$ je vychyleny' (aj ak model plati)
 - ale: pri zvyšovaní λ
 - ↑ zvyšuje sa vychylenosť
 - ↓ znižuje sa variancia
- } môže sa zlepšovať kvalita predikcie (MSE)

formálne: $MSE(\hat{\beta}_{ridge}) = E[(\hat{\beta}_n - \beta)^T(\hat{\beta}_n - \beta)] = \sum_{j=1}^{p-1} E[(\hat{\beta}_j^{ridge} - \beta_j)^2]$

⇒ $MSE(\hat{\beta}_{ridge}) = Var + Bias^2$; bias-variance tradeoff

$\sum_{j=1}^{p-1} D(\hat{\beta}_j^{\lambda})$ ← $\sum_{j=1}^{p-1} E(\hat{\beta}_j^{\lambda} - \beta_j) = Bias$


↓ zleša' s λ ↓ klesá s λ

Volba λ :

(kros)validacie


- validacia: kvalita predikcie na val. vzorke:

$\forall \lambda: MSE_{val}(\lambda) = \frac{1}{n} \|y - X\hat{\beta}_{\dots}(\lambda)\|^2$



$$\forall \lambda: \text{MSE}_{\text{val}}(\lambda) = \frac{1}{n_{\text{val}}} \|y - X \hat{\beta}_{\text{ridge}}(\lambda)\|^2$$

→ vyberieme λ , kt. minimalizuje $\text{MSE}_{\text{val}}(\lambda)$





- crossvalidácia: to isté, akúto val. chybu meriame crossvalidáciou

2. Lasso - least absolute shrinkage and selection operator

$$\hat{\beta}_{\text{lasso}} = \underset{\beta}{\text{argmin}} \|y - X\beta\|_2^2 + \lambda \underbrace{\sum_{j=1}^{p+1} |\beta_j|}_{\|\beta\|_1} = \|y - X\beta\|_2^2 + \lambda \|\beta\|_1$$

→ tvar s obmedzením:

$$\left\{ \begin{array}{l} \min_{\beta} \|y - X\beta\|_2^2 \\ \|\beta\|_1 \leq c \end{array} \right\}$$



- tvar obmedzenia \Rightarrow Lasso má tendenciu káčať niektoré $\hat{\beta}_j$ do nuly
- čím vyššie λ , tým viac nulových $\hat{\beta}_j$

\Rightarrow kombinuje vlastnosti Ridge a kombinatorickej selekcie: odobrajšie voči perturbáciám (postupne znižuje $\hat{\beta}_j$)
: ale podľa - niektoré $\hat{\beta}_j$ da' na nulu \Rightarrow robí selekciu param.

- L_1 -norma $\|\cdot\|_1$: nie je hladká \Rightarrow \nexists formula pre $\hat{\beta}_{\text{lasso}}$

- ale stále je Lasso konvexná úloha \Rightarrow \exists efektívne algoritmy

\Rightarrow Ridge, Lasso sú často podstatne menej náročné alternatívy ku komb. selekci

- opäť: začína sa s centrovanými a štandardizovanými dátami

- voľba λ : (cross)validácia

- \exists Group lasso pre sloping parameterizácia (dummy)
- \exists aj iné penalizačné metódy \rightarrow napr.: $p(\beta) = \sum_{j=1}^{p-1} |\beta_j|^q$ pre $q \in (0, \infty)$
: kombinácia $\|\beta\|_1$ a $\|\beta\|_2$