

Statistische Signifikanz in hochdimensionalen linearen Modellen - Handout

Stella Preußler

15. Januar 2015

Einleitung

Thema: Statistische Signifikanz in hochdimensionalen linearen Modellen...

... durch **p-Werte**, also

Ziel: Konstruktion von p-Werten für Hypothesen in hochdimensionalen linearen Modellen.

Definition 1 p-Wert = $\mathbb{P}[|T| \geq t]$ unter H_0 ,

wobei T Teststatistik und t Experimentausgang.

Der p-Wert ist also die Wahrscheinlichkeit ein solches Stichprobenergebnis oder ein noch extremeres zu erhalten, wenn die Nullhypothese wahr ist.

1 Grundlegendes: Modell und Hypothesen

Wir betrachten ein **hochdimensionales lineares System** von der Form

$$\mathbf{Y} = \mathbf{X}\beta^0 + \epsilon, \quad (1)$$

mit Ergebnisvektor $\mathbf{Y} \in \mathbb{R}^{n \times 1}$,

fest vorgegebene Designmatrix $\mathbf{X} \in \mathbb{R}^{n \times p}$,

wahrem Parametervektor $\beta^0 \in \mathbb{R}^{p \times 1}$ und

stochastischem Fehlervektor $\epsilon \in \mathbb{R}^{n \times 1}$ mit $\epsilon \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$,

im Fall $p \gg n$ und beschäftigen uns mit **Nullhypothesen** der Form:

$$H_{0,j} : \beta_j^0 = 0 \quad j = 1, \dots, p. \quad (2)$$

2 Ein angemessener Schätzer

2.1 Die Ridge Regression

Die Ridge Regression

$$\hat{\beta} = \operatorname{argmin}_{\beta} \left(\|\mathbf{Y} - \mathbf{X}\beta\|_2^2 / n + \lambda \|\beta\|_2^2 \right), \quad (3)$$

wo $\lambda = \lambda_n$ der Regularisierungsparameter und Ω die Kovarianzenmatrix des Ridgeschätzers und wir annehmen, dass

$$\min_{j \in \{1, \dots, p\}} \Omega_{jj}(\lambda) = \min_{j \in \{1, \dots, p\}} \operatorname{Var}[\hat{\beta}_j](\lambda) > 0, \quad (4)$$

schätzt eigentlich $\theta^0 = P_{\mathbf{X}}\beta^0 \in \mathcal{R}(\mathbf{X})$, wobei $\mathcal{R}(\mathbf{X}) \subset \mathbb{R}^p$ der lineare Raum, der durch die n Zeilen von \mathbf{X} aufgespannt wird und $P_{\mathbf{X}}$ die **Projektion von \mathbb{R}^p auf $\mathcal{R}(\mathbf{X})$** ist.

Es gilt

$$0 < L_C \leq \liminf_{\lambda \in (0, C]} \min_{j \in \{1, \dots, p\}} \operatorname{Var}[\hat{\beta}_j] \leq M_C \quad (5)$$

für ein $0 < C < \infty$ und Konstanten mit $0 < L_C < M_C < \infty$ abhängig von C und der Designmatrix \mathbf{X} , und

$$\max_{j \in \{1, \dots, p\}} \left(\mathbb{E}[\hat{\beta}_j] - \theta_j^0 \right)^2 \leq \min_{j \in \{1, \dots, p\}} \operatorname{Var}[\hat{\beta}_j], \quad (6)$$

für einen Regularisierungsparameter $\lambda > 0$ der folgende Eigenschaft* hat:

$$\lambda \left(\min_{j \in \{1, \dots, p\}} \operatorname{Var}[\hat{\beta}_j] \right)^{-1/2} \leq n^{-1/2} \sigma \|\theta^0\|_2^{-1} \lambda_{\min \neq 0}(\hat{\Sigma}) \quad (7)$$

wo $\lambda_{\min \neq 0}(\hat{\Sigma})$ kleinster Eigenwert $\neq 0$ der Kovarianzmatrix $\hat{\Sigma} = n^{-1} \mathbf{X}^T \mathbf{X}$.

2.2 Die korrigierte Ridge Regression stochastisch modelliert

Die **korrigierte Ridge Regression** $\hat{\beta}_{\operatorname{corr};j}$ mit Regularisierungsparameter $\lambda > 0$ zum Testen von $H_{0,j}$

$$\hat{\beta}_{\operatorname{corr};j} = \hat{\beta}_j - \hat{B}_{H_{0,j}} = \hat{\beta}_j - \sum_{k \neq j} (P_{\mathbf{X}})_{jk} \hat{\beta}_{\operatorname{init};k} \quad (8)$$

kann durch

$$\hat{\beta}_{\operatorname{corr};j} = Z_j + \gamma_j \quad (j = 1, \dots, p) \quad (9)$$

$Z_1, \dots, Z_p \sim \mathcal{N}(0, n^{-1} \sigma^2 \Omega)$, $\Omega = \Omega(\lambda)$,

$\gamma_j = (P_{\mathbf{X}})_{jj} \beta_j^0 - \sum_{k \neq j} (P_{\mathbf{X}})_{jk} (\hat{\beta}_{\operatorname{init};k} - \beta_k^0) + b_j(\lambda)$,

$b_j(\lambda) = \mathbb{E}[\hat{\beta}_j(\lambda)] - \theta_j^0$ „Schätzungsverzerrung“

stochastisch dargestellt werden. Mit den **Normalisierungsfaktoren**

$$a_{n,p;j}(\sigma) = n^{1/2} \sigma^{-1} \Omega_{jj}^{-1/2} \quad (j = 1, \dots, p) \quad (10)$$

gilt $a_{n,p;j}(\sigma) Z_j \sim \mathcal{N}(0, 1)$.

2.3 Eine asymptotische Schranke: Präzise formuliert

Definition 2 Seien X und Y reelle Zufallsvariablen. X ist kleiner-gleich Y bezüglich der gewöhnlichen stochastischen Ordnung, wenn für alle $b \in \mathbb{R}$ gilt $\mathbb{P}(X \geq b) \leq \mathbb{P}(Y \geq b)$.

Satz 1 Wir betrachte eine Schar von linearen Modellen

$$\mathbf{Y}_n = \mathbf{X}_n \beta_n^0 + \epsilon_n, n = 1, 2, \dots, \quad (11)$$

die korrigierte Ridge Regression $\hat{\beta}_{corr}$ mit geeignetem** Regularisierungsparameter $\lambda_n > 0$

$$\lambda_n \Omega_{min}(\lambda_n)^{-1/2} = o(\min(n^{-1/2} \sigma \|\theta^0\|_2^{-1} \lambda_{\min \neq 0}(\hat{\Sigma})), (n \rightarrow \infty)) \quad (12)$$

und machen folgende Annahme A:

Es gibt Konstanten $\Delta_j = \Delta_{j,n} > 0$ so dass

$$\mathbb{P} \left[\bigcap_{j=1}^{p_n} \left\{ a_{n,p;j}(\sigma) \sum_{k \neq j} (P_{\mathbf{X}})_{jk} (\hat{\beta}_{init;k} - \beta_k^0) \right\} \leq \Delta_{j,n} \right] \rightarrow 1 \quad (n \rightarrow \infty). \quad (13)$$

Dann gilt für $j \in \{1, \dots, p_n\}$ unter $H_{0,j}$: für alle $u \in \mathbb{R}^+$,

$$\limsup_{n \rightarrow \infty} \left(\mathbb{P} [a_{n,p;j}(\sigma) |\hat{\beta}_{corr;j}| > u] - \mathbb{P} [|W| + \Delta_j > u] \right) \leq 0,$$

wobei $W \sim \mathcal{N}(0, 1)$.

3 Die Herleitung der p-Werte

3.1 p-Werte

$$\text{p-Wert} = P [|W + \Delta_j| \geq a_{n,p;j}(\sigma) |\hat{\beta}_{corr;j}|] \text{ unter } H_0 \quad (14)$$

Für die individuelle Hypothese $H_{0,j}$ definieren wir daher den p-Wert für die zweiseitige Alternative als:

$$P_j = 2(1 - \Phi((a_{n,p;j}(\sigma) |\hat{\beta}_{corr;j}| - \Delta_j)_+)). \quad (15)$$

3.2 Die Herleitung der Δ_j

Satz 2 Betrachte (2) mit normalisierten Spalten $\hat{\Sigma}_{jj} \equiv 1$, welche die Kompatibilitätsbedingung mit Konstante $\Phi_0^2 = \Phi_{0,n}^2$ erfüllen. Nehme den Lasso als Initialschätzer $\hat{\beta}_{init}$ mit Regularisierungsparameter $\lambda_{Lasso} = 4\sigma \sqrt{C \log(p_n)/n}$ für ein $2 < C < \infty$. Nehme an, dass die Menge der aktiven Koeffizienten $s_0 = s_{0,n} = o((n/\log(p_n))^\xi)$ ($n \rightarrow \infty$) für ein $0 < \xi < 1/2$, und dass $\liminf_{n \rightarrow \infty} \Phi_{0,n}^2 > 0$. Dann erfüllt

$$\Delta_j := \max_{k \neq j} |a_{n,p;j}(\sigma) (P_{\mathbf{X}})_{jk}| (\log(p)/n)^{1/2-\xi} \quad (16)$$

die Bedingung A (13).

Korollar 1 *Nehme die Annahmen von Satz 2, ohne Bedingung A und mit den Bedingungen von Satz 2, an. Dann gilt, mit dem Lasso als Initialschätzer, die Aussage von Satz 1.*

Literatur

[B13] Peter Bühlmann, Statistical significance in high-dimensional linear models, *Bernoulli*, 19(4), 1212 - 1242, (2013).