

Kurze Einführung in Regularisierung und penalisierte Schätzansätze in der Statistik

Sarah Brockhaus
nach einer Vorlage von David Rügamer

13. November 2015

1. Regularisierung in der Statistik
2. Anwendungsbeispiel
3. Weiterführende Verwendung penalisierter Schätzverfahren

Regularisierung in der Statistik

Problemstellung

KQ-Kriterium (KQ, Kleinste Quadrate):

$$\text{KQ}(\beta) = (y - \mathbf{X}\beta)'(y - \mathbf{X}\beta) \rightarrow \min_{\beta}$$

KQ-Schätzung basiert auf Lösung des Gleichungssystems

$$\mathbf{X}'\mathbf{X}\beta = \mathbf{X}'y$$

Voraussetzung: \mathbf{X} besitzt vollen Rang $p \Leftrightarrow \mathbf{X}'\mathbf{X}$ ist invertierbar

Problematisch:

- ▶ Korrelierte Einflussgrößen \Rightarrow nahezu kollineare Spalten in \mathbf{X}
- ▶ $p \rightarrow \infty$ bzw. $p > n$

\Rightarrow Theoretische Lösung existiert, Optimierung jedoch numerisch instabil

Statistische Regularisierung

Im Allgemeinen meist Erweiterung des KQ-Kriteriums durch einen Strafterm

$$\text{PLS}(\beta) = (\mathbf{y} - \mathbf{X}\beta)'(\mathbf{y} - \mathbf{X}\beta) + \lambda \cdot \text{pen}(\beta) \rightarrow \min_{\beta}$$

zum sogenannten *penalisierten KQ-Kriterium* (*Penalized Least Squares*).

Der Bestrafungsterm $\text{pen}(\beta)$ misst die Komplexität der Regressionskoeffizienten während der *Glättungsparameter* $\lambda \geq 0$ dessen Einfluss steuert:

- ▶ $\lambda \rightarrow 0$: Keine / kaum Bestrafung; es ergibt sich wieder das KQ-Kriterium
- ▶ $\lambda \rightarrow \infty$: Die Penalisierung besitzt einen großen Einfluss

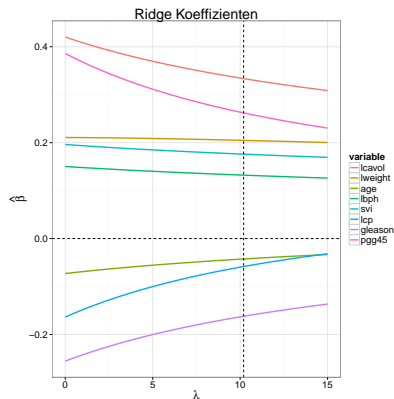
Bekannte Regularisierungsansätze

- ▶ Ridge Regression (engl. ridge, dt. First, Grat, Bergrücken):
 - ▶ $\text{pen}(\boldsymbol{\beta}) = \sum_{j=1}^k \beta_j^2 = \boldsymbol{\beta}'\boldsymbol{\beta}$
 - ▶ Schrumpft Koeffizienten gegen Null
 - ▶ Vorteil: falls λ groß $\Rightarrow \mathbf{X}'\mathbf{X} + \lambda I_p$ invertierbar, auch wenn $\mathbf{X}'\mathbf{X}$ keinen vollen Rang besitzt.
 - ▶ Ridge-Schätzer besitzt kleinere (Ko-)Varianz als KQ-Schätzer für $\lambda > 0$, ist aber verzerrt
→ insbesondere für hochdimensionales oder annähernd kollineares \mathbf{X} wird MSE von Varianz stärker beeinflusst als von Bias, was zu einem geringerm MSE des Ridge-Schätzer führen kann
- ▶ LASSO (Least Absolute Shrinkage and Selection Operator):
 - ▶ $\text{pen}(\boldsymbol{\beta}) = \sum_{j=1}^k |\beta_j|$
 - ▶ Schrumpft Koeffizienten nicht nur gegen sondern auch auf Null und kann damit zur Konstruktion sparsamer Modelle verwendet werden

Wichtig: Regularisierungsverfahren basieren auf der Annahme, dass alle Koeffizienten hinsichtlich ihrer absoluten Werte vergleichbar sind.

→ Kovariablen standardisieren!

Anwendungsbeispiel



Vergleich KQ- und Ridge-Schätzung

Simulationsdaten auf Basis des Prostata Datensatzes von Hastie, Tibshirani und Friedman (2009)

- ▶ Modellierung der logarithm. Menge an Prostata-spezifischem Abwehrstoff
- ▶ in Abhängigkeit von Einflußgrößen wie dem Volumen des Krebses (lcavol) oder dem Alter des Patienten (age).

Beispielhafter Vergleich der MSEs des Koeffizienten von lcavol, mit $\beta=0.5643$:

	KQ	Ridge
$\hat{\beta}$	0.4204	0.3336
MSE	0.0135	0.0070

Weiterführende Verwendung penalisierter Schätzverfahren

Penalisierte Schätzansätze finden in der Statistik insbesondere Verwendung in

- ▶ gemischten Modellen:

Beispiel: Schätzung der Regressionskoeffizienten im linearen gemischten Modell

$$\begin{aligned}y &= \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon} \\ \mathbf{b} &\sim \mathcal{N}(\mathbf{0}, \mathbf{G}), \boldsymbol{\varepsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{R})\end{aligned}$$

über Minimierung des PLS-Kriteriums

$$\text{PLS}(\boldsymbol{\beta}, \mathbf{b}) = (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b})' \mathbf{R}^{-1} (\mathbf{y} - \mathbf{X}\boldsymbol{\beta} - \mathbf{Z}\mathbf{b}) + \mathbf{b}' \mathbf{G}^{-1} \mathbf{b}$$

Penalisierte Schätzansätze finden in der Statistik insbesondere Verwendung in

- ▶ nicht-parametrischer Regression:

Beispiel: Schätzung eines glatten Effekts mit TP-Basis vom Grad ℓ

$$y_i = f(z_i) + \varepsilon_i = \gamma_1 + \gamma_2 z_i + \dots + \gamma_{\ell+1} z_i^\ell + \gamma_{\ell+2} (z_i - \kappa_2)_+^\ell + \dots + \gamma_d (z_i - \kappa_{m-1})_+^\ell + \varepsilon_i,$$

mit trunkierten Polynomen $(\cdot)_+^\ell$
über Minimierung des PLS-Kriteriums

$$\text{PLS}(\lambda) = \sum_{i=1}^n (y_i - f(z_i))^2 + \lambda \sum_{j=\ell+2}^d \gamma_j^2.$$

(Bestrafe Abweichung vom globalen Polynom)

Penalisierte Schätzansätze aus bayesianischer Sicht

- ▶ Penalisierungsterm kann als Glattheits- oder informative Priori angesehen werden
- ▶ Beispiel: Bayesianisches lineares gemischtes Modell
 - ▶ $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon}$
 - ▶ Nicht-informative Priori-Info für $\boldsymbol{\beta}$: $p(\boldsymbol{\beta}) \propto \text{const}$
 - ▶ Informative Gauß-Priori für \mathbf{b} : $\mathbf{b} \sim \mathcal{N}(\mathbf{0}, \mathbf{G})$
 - ▶ Gemeinsame Posteriori-Verteilung der Regressionskoeffizienten über

$$p(\boldsymbol{\beta}, \mathbf{b} | \mathbf{y}) \propto p(\mathbf{y} | \boldsymbol{\beta}, \mathbf{b})p(\boldsymbol{\beta})p(\mathbf{b})$$

⇒ Posteriori äquivalent zu penalisiertem KQ-Kriterium (9),
Posteriori-Modus äquivalent zu Koeffizientenschätzer des frequentistischen Ansatzes

Literatur

- ▶ Fahrmeir, L., T. Kneib, S. Lang und B. Marx.
Regression - Models, Methods and Applications. Springer, 2013.
- ▶ Hastie, T., R. Tibshirani und J. Friedman.
The Elements of Statistical Learning. Springer, 2009.