

# Konsistenzeigenschaften des (Adaptive) Lasso

Hauptseminar Erweiterungen des linearen Regressionsmodells und  
genomische Anwendungen in der Biomedizin  
WS 2014/2015

Kristina Kaucher

1. Dezember 2014

## 1 Einleitung

# Inhaltsverzeichnis

- 1 Einleitung
- 2 Oracle Eigenschaften des Lasso

# Inhaltsverzeichnis

- 1 Einleitung
- 2 Oracle Eigenschaften des Lasso
- 3 Der Adaptive Lasso

# Inhaltsverzeichnis

- 1 Einleitung
- 2 Oracle Eigenschaften des Lasso
- 3 Der Adaptive Lasso
- 4 Simulation des Lasso und Adaptive Lasso

# Inhaltsverzeichnis

- 1 Einleitung
- 2 Oracle Eigenschaften des Lasso
- 3 Der Adaptive Lasso
- 4 Simulation des Lasso und Adaptive Lasso
- 5 Literaturverzeichnis

- Zugrunde liegendes lineares Modell:  $\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}$ .
- Mit Ergebnisvektor  $\mathbf{Y} \in \mathbb{R}^{n \times 1}$ , Designmatrix  $\mathbf{X} \in \mathbb{R}^{n \times p}$  und dem Vektor der Messfehler  $\boldsymbol{\varepsilon} \in \mathbb{R}^{n \times 1}$ .
- $\mathbf{X}$  fest vorgegeben und  $\boldsymbol{\varepsilon} \sim \mathcal{N}(0, \sigma^2 \mathbf{I})$  und  $\boldsymbol{\beta}^0$  bezeichnet den wahren Koeffizientenvektor.
- Was versteht man unter einer „Oracle-Ungleichung“?

- Annahme  $p \leq n$  und  $\mathbf{X}$  hat vollen Rang  $p$ 
  - Kleinsten Quadrate Schätzer  $\hat{\mathbf{b}} := (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y}$  gibt den Fehler  $\|\mathbf{X}(\hat{\mathbf{b}} - \boldsymbol{\beta}^0)\|_2^2 / \sigma^2 \sim \chi_p^2$ , also  $\frac{\mathbb{E}[\|\mathbf{X}(\hat{\mathbf{b}} - \boldsymbol{\beta}^0)\|_2^2]}{n} = \frac{\sigma^2}{n} p$ .
  - Reparametrisierung zu orthonormalem Design  $\Rightarrow$  jeder Parameter  $\beta_j^0$  wird mit quadratischer Genauigkeit  $\frac{\sigma^2}{n}$  geschätzt.
- Was ist jedoch im Fall  $p > n$ ?
  - Wir müssen annehmen, dass nur ein paar unserer  $\beta_j^0$  ungleich Null sind, dazu sei  $S_0 := \{j : \beta_j^0 \neq 0, j = 1, \dots, p\}$  mit  $|S_0| := s_0$  die aktive Menge der Koeffizienten.
  - Wüssten wir wie  $S_0$  aussieht, dann wüssten wir auch welche  $\mathbf{X}^{(j)}$  für unser Modell irrelevant sind und hätten eine quadratische Genauigkeit von  $\frac{\sigma^2}{n} s_0$  für den Schätzer von  $\boldsymbol{\beta}^0$ .
  - $S_0$  ist jedoch unbekannt  $\Rightarrow$  Regularisierung der  $\beta_j$  benötigt.

- Regularisierung mit der  $l_1$ -Norm über den Lasso-Schätzer:

$$\hat{\beta} := \arg \min_{\beta} \left\{ \frac{\| \mathbf{Y} - \mathbf{X} \beta \|_2^2}{n} + \lambda \| \beta \|_1 \right\}$$

mit dem Regularisierungsparameter  $\lambda > 0$

- Wir werden sehen: Mit geeigneter Wahl von  $\lambda$  (der Ordnung  $\sigma \sqrt{\log \frac{p}{n}}$ ) erfüllt der Lasso mit großer Wahrscheinlichkeit die Oracle-Ungleichung

$$\frac{\| \mathbf{X}(\hat{\beta} - \beta^0) \|_2^2}{n} \leq c \frac{\sigma^2 \log(p)}{n} s_0.$$

- $c > 0$  kann dabei explizit in Abhängigkeit von  $p$  und/oder  $n$  durch  $\hat{\Sigma} := \mathbf{X}^\top \mathbf{X} / n$  angegeben werden,  $\log(p)$  ist der Preis, den wir zahlen  $S_0$  nicht zu kennen.

# Oracle Eigenschaften des Lasso

## Lemma 2.1 (Basis-Ungleichung)

Für den Lasso Schätzer  $\hat{\beta}$  gilt die folgende Ungleichung

$$\frac{\|\mathbf{X}(\hat{\beta} - \beta^0)\|_2^2}{n} + \lambda \|\hat{\beta}\|_1 \leq \frac{2}{n} \boldsymbol{\varepsilon}^\top \mathbf{X}(\hat{\beta} - \beta^0) + \lambda \|\beta^0\|_1$$

## Beweis.

Es gilt

$$\frac{\|\mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}}\|_2^2}{n} + \lambda \|\hat{\boldsymbol{\beta}}\|_1 \leq \frac{\|\mathbf{Y} - \mathbf{X} \boldsymbol{\beta}^0\|_2^2}{n} + \lambda \|\boldsymbol{\beta}^0\|_1.$$

Die Addition von  $\frac{\|\mathbf{Y} - \mathbf{X} \boldsymbol{\beta}^0\|_2^2}{n}$  auf beiden Seiten bringt

$$\frac{\|\mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}}\|_2^2}{n} + \frac{\|\mathbf{Y} - \mathbf{X} \boldsymbol{\beta}^0\|_2^2}{n} + \lambda \|\hat{\boldsymbol{\beta}}\|_1 \leq 2 \frac{\|\mathbf{Y} - \mathbf{X} \boldsymbol{\beta}^0\|_2^2}{n} + \lambda \|\boldsymbol{\beta}^0\|_1.$$

Nach Ausnutzung der Dreiecksungleichung und der Eigenschaft  $\mathbf{Y} = \mathbf{X} \hat{\boldsymbol{\beta}}$  erhalten wir für die linke Seite der Ungleichung

$$\begin{aligned} \frac{\|\mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}}\|_2^2}{n} + \frac{\|\mathbf{Y} - \mathbf{X} \boldsymbol{\beta}^0\|_2^2}{n} + \lambda \|\hat{\boldsymbol{\beta}}\|_1 \\ \geq \frac{\|\mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} + \mathbf{Y} - \mathbf{X} \boldsymbol{\beta}^0\|_2^2}{n} + \lambda \|\hat{\boldsymbol{\beta}}\|_1 \end{aligned}$$

$$= \frac{\|\mathbf{X}(\hat{\beta} - \beta^0)\|_2^2}{n} + \lambda \|\hat{\beta}\|_1.$$

Die rechte Seite der Ungleichung ergibt mit  $\mathbf{Y} = \mathbf{X}\beta^0 + \varepsilon$  und  $\mathbf{Y} = \mathbf{X}\hat{\beta}$

$$\begin{aligned} 2 \frac{\|\mathbf{Y} - \mathbf{X}\beta^0\|_2^2}{n} + \lambda \|\beta^0\|_1 &= \frac{2}{n} (\mathbf{Y} - \mathbf{X}\beta^0)^T (\mathbf{Y} - \mathbf{X}\beta^0) \\ &= \frac{2}{n} \varepsilon^T \mathbf{X}(\hat{\beta} - \beta^0) + \lambda \|\beta^0\|_1. \end{aligned}$$

Womit die Aussage bewiesen ist. □

- $\frac{2}{n} \boldsymbol{\epsilon}^\top \mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}^0)$  ist der empirische Verfahrensteil des Problems, er lässt sich hinsichtlich der  $l_1$ -Norm einfach einschränken mit

$$2|\boldsymbol{\epsilon}^\top \mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}^0)| \leq \left( \max_{1 \leq j \leq p} 2|\boldsymbol{\epsilon}^\top \mathbf{X}^{(j)}| \right) \|\hat{\boldsymbol{\beta}} + \boldsymbol{\beta}^0\|_1.$$

- Im empirischen Verfahrensteil spielt der Zufall noch eine Rolle  $\Rightarrow$  Regularisierung um ihn zu überstimmen wird benötigt, dazu sei

$$\mathcal{J} := \left\{ \max_{1 \leq j \leq p} \frac{2}{n} |\boldsymbol{\epsilon}^\top \mathbf{X}^{(j)}| \leq \lambda_0 \right\}.$$

- Unter der Annahme, dass  $\lambda \geq \lambda_0$  können wir sicherstellen, dass wir auf  $\mathcal{J}$  den zufälligen Teil des Problems loswerden können.

- Die Diagonalelemente der Grammatrix  $\hat{\Sigma}$  bezeichnen wir im folgenden mit  $\hat{\sigma}_j := \hat{\Sigma}_{jj} \forall j = 1, \dots, p$

### Lemma 2.2

Sei  $\hat{\sigma}_j^2 = 1 \forall j = 1, \dots, p$ . Dann gilt für  $t > 0$  und für  $\lambda_0 := 2\sigma\sqrt{\frac{t^2 + 2\log(p)}{n}}$

$$\mathbb{P}[\mathcal{J}] \geq 1 - 2 \exp\left(\frac{-t^2}{2}\right).$$

### Beweis.

Siehe [BvdG11] Kapitel 6, Beweis zu Lemma 6.2. □

- Aus den beiden Lemmata 2.1 und 2.2 gewinnen wir eine Konsistenzeigenschaft des Lasso

### Korollar 2.3 (Konsistenzeigenschaft des Lasso.)

Sei  $\hat{\sigma}_j^2 = 1 \forall j = 1, \dots, p$ . Für  $t > 0$  sei der Regularisierungsparameter

$$\lambda_0 := 4\hat{\sigma} \sqrt{\frac{t^2 + 2 \log(p)}{n}},$$

wobei  $\hat{\sigma}$  ein Schätzer für  $\sigma$  ist. Dann gilt mit einer Wahrscheinlichkeit von mindestens  $1 - \alpha$  für

$$\alpha := 2 \exp\left(\frac{-t^2}{2}\right) + \mathbb{P}[\hat{\sigma} \leq \sigma],$$

dass

$$\frac{2}{n} \|\mathbf{X}(\hat{\beta} - \beta^0)\|_2^2 \leq 3\lambda \|\beta^0\|_1.$$

- Wir schließen, dass die Wahl von  $\lambda$  mit Ordnung  $\sqrt{\log(p)/n}$  und die Annahme, dass die  $l_1$ -Norm des wahren  $\beta^0$  von kleinerer Ordnung als  $\sqrt{n/\log(p)}$  ist, in der Konsistenz des Lasso endet.
- Dabei ist die geeignete Wahl des Schätzers  $\hat{\sigma}$  von  $\sigma$  (nicht zu klein aber auch nicht zu groß) wichtig, wir denken an den Schätzer  $\hat{\sigma} := \mathbf{Y}^\top \mathbf{Y} / n$ .
- Mit dem Signal-Rausch-Verhältnis  $SNR := \|\mathbf{X} \beta^0\|_2 / \sqrt{n} \sigma$  unterliegt der Schätzer  $\hat{\sigma}$  der Ungleichung  $\sigma \leq \hat{\sigma} \leq c\sigma$ , wobei sich die Konstante  $c$  gut kontrollieren lässt.
- Wir definieren

$$\beta_{j,S} := \beta_j \mathbf{1}_{\{j \in S\}} \quad \text{und} \quad \beta_{j,S^c} := \beta_j \mathbf{1}_{\{j \notin S\}}$$

dann gilt  $\beta = \beta_S + \beta_{S^c}$ .

## Lemma 2.4

Auf dem Ereignis  $\mathcal{J}$  gilt für  $\lambda \geq 2\lambda_0$

$$\frac{2}{n} \|\mathbf{X}(\hat{\boldsymbol{\beta}} - \boldsymbol{\beta}^0)\|_2^2 + \lambda \|\hat{\boldsymbol{\beta}}_{S_0^c}\|_1 \leq 3\lambda \|\hat{\boldsymbol{\beta}}_{S_0} - \boldsymbol{\beta}_{S_0}^0\|_1.$$

Beweis.

Siehe Tafelanschrieb. □

- Es werden weitere Bedingungen an die Designmatrix  $\mathbf{X}$  benötigt  $\Rightarrow$  Kompatibilität zwischen der  $l_1$ -Norm und der  $l_2$ -Norm

### Definition 2.5 (Kompatibilitätsbedingung)

*Wir sagen, dass die Kompatibilitätsbedingung für die Menge  $S_0$  erfüllt ist, wenn für ein  $\phi_0 > 0$  und alle  $\beta$ , die der Ungleichung  $\|\beta_{S_0^c}\|_1 \leq 3\|\beta_{S_0}\|_1$  genügen, gilt*

$$\|\beta_{S_0}\|_1^2 \leq (\beta^\top \hat{\Sigma} \beta) \frac{s_0}{\phi_0^2}.$$

## Satz 2.6

Angenommen die aktive Menge  $S_0$  erfüllt die Ungleichung (2.5), dann gilt auf dem Ereignis  $\mathcal{J}$  mit  $\lambda \geq 2\lambda_0$

$$\frac{\|X(\hat{\beta} - \beta^0)\|_2^2}{n} + \lambda \|\hat{\beta} - \beta^0\|_1 \leq \frac{4s_0}{\phi_0^2} \lambda^2.$$

Beweis.

Siehe Tafelanschrieb. □

- Kombination des Satzes 2.6 und dem Lemma 2.2 sichert unter bestimmten Bedingungen die Konsistenz des Lasso:

### Korollar 2.7

*Es sei  $\hat{\sigma}_j = 1$  für alle  $j = 1, \dots, p$  und die Kompatibilitätsbedingung (2.5) gelte für  $S_0$ . Für  $t > 0$  sei der Regularisierungsparameter*

*$\lambda := 4\hat{\sigma} \sqrt{\frac{t^2 + 2 \log(p)}{n}}$ , dann gilt mit einer Wahrscheinlichkeit von mindestens  $1 - \alpha$ , wobei*

$$\alpha := 2 \exp\left(\frac{-t^2}{2}\right) + \mathbb{P}[\hat{\sigma} \leq \sigma],$$

*dass*

$$\frac{\|X(\hat{\beta} - \beta^0)\|_2^2}{n} + \lambda \|\hat{\beta} - \beta^0\|_1 \leq \frac{4s_0}{\phi_0^2} \lambda^2.$$

- Frage: Wann versagt der Lasso?
- Betrachte die Grammatrix  $\hat{\Sigma}$  die wir mit Hilfe von Blockmatritzen  $\hat{\Sigma}_{ij}$   $i, j = 1, 2$  folgendermaßen darstellen können

$$\hat{\Sigma} = \mathbf{X}^\top \mathbf{X} / n = \begin{pmatrix} \hat{\Sigma}_{11} & \hat{\Sigma}_{12} \\ \hat{\Sigma}_{21} & \hat{\Sigma}_{22} \end{pmatrix},$$

wobei  $\hat{\Sigma}_{11} \in \mathbb{R}^{s_0 \times s_0}$ .

### Satz 2.8 (Inkonsistenz der Variablenauswahl.)

Angenommen  $s_0 = 2m + 1 \geq 3$  für ein  $m \in \mathbb{N}$  und  $p = s_0 + 1$ , sodass es genau einen irrelevanten Koeffizienten  $\beta_j^0$  gibt. Sei

$\hat{\Sigma}_{11} = (1 - \rho_1) \mathbf{I}_{s_0 \times s_0} + \rho_1 \mathbf{J}_{s_0 \times s_0}$  wobei  $\mathbf{J}_{s_0 \times s_0}$  die  $s_0 \times s_0$  Matrix mit nur 1en ist. Sei  $\hat{\Sigma}_{12} = \rho_2 \mathbf{I}_{s_0 \times 1}$  und  $\hat{\Sigma}_{22} = 1$ . Gilt

$$-\frac{1}{s_0 - 1} < \rho_1 < -\frac{1}{s_0} \quad \text{und} \quad 1 + (s_0 - 1)\rho_1 < |\rho_2| < \sqrt{\frac{1 + (s_0 - 1)\rho_1}{s_0}},$$

dann kann die Variablenauswahl des Lasso nicht konsistent sein.

# Der Adaptive Lasso

- $\hat{\beta}$  erfüllt nur unter sehr starken Voraussetzungen mit hoher Wahrscheinlichkeit die Oracle-Ungleichung.
- $\hat{\beta}$  regularisiert jeden Koeffizient  $\beta_j$  genau gleich, die Beobachtungen  $\mathbf{X}^{(j)}$  können jedoch unterschiedlich starken Einfluss haben  $\Rightarrow$  unterschiedlich starke Regularisierung der Koeffizienten  $\beta_j$  benötigt.
- Der Adaptive Lasso realisiert diese Regularisierung:

$$\hat{\beta}_{\text{adap}}^{(n)} := \arg \min_{\beta} \left\{ \frac{\|\mathbf{Y} - \mathbf{X}\beta\|_2^2}{n} + \lambda_n \sum_{j=1}^p \tilde{w}_j |\beta_j| \right\},$$

mit  $\tilde{w}_j := 1/|\tilde{\beta}_j|^\gamma$ ,  $\gamma > 0$  wobei  $\tilde{\beta}$  ein initialer ( $\sqrt{n}$ -konsistenter) Schätzer für  $\beta^0$  ist (z.B. kleinste Quadrate Schätzer).

- $\tilde{w}$  sollte in Abhängigkeit von den Daten clever gewählt werden und ist  $\tilde{\beta}_j = 0$  so setze auch  $\hat{\beta}_{\text{adap},j} = 0$ .
- $\hat{S}_{\text{adap}} := \{j : \hat{\beta}_{\text{adap},j} \neq 0, j = 1, \dots, p\}$  ist die aktive Menge des Adaptive Lasso.

- Für geeigneten Wahl von  $\lambda_n$  besitzt der Adaptive Lasso die Oracle Eigenschaften.

### Satz 3.1

Gilt  $\lambda_n/\sqrt{n} \rightarrow 0$  und  $\lambda_n n^{(\gamma-1)/2} \rightarrow \infty$ , dann erfüllt der Adaptive Lasso  $\hat{\beta}_{adap}^{(n)}$  die folgenden Eigenschaften

1. Konsistenz in der Variablenauswahl, d.h.  $\lim_{n \rightarrow \infty} \mathbb{P}[\hat{S}_{adap} = S_0] = 1$
2. Asymptotische Normalität:  $\sqrt{n}(\hat{\beta}_{adap, S_0}^{(n)} - \beta_{S_0}^0) \rightarrow \mathcal{N}(0, \sigma^2 \hat{\Sigma}_{11}^{-1})$ ,

wobei  $\hat{\Sigma}_{11} \in \mathbb{R}^{s_0 \times s_0}$ .

### Beweis.

Siehe [Z06] Kapitel „APPENDIX: PROOFS“.



## Bemerkung 3.2

- (1) Der initiale Schätzer  $\tilde{\beta}$  muss nicht unbedingt  $\sqrt{n}$ -konsistent sein, damit der Adaptive Lasso seine guten Eigenschaften behält. Angenommen es existiert eine aufsteigende Folge  $\{a_n\}_{n \in \mathbb{N}}$ , sodass  $a_n \rightarrow \infty$  für  $n \rightarrow \infty$  und  $a_n(\tilde{\beta} - \beta^0) = O_p(1)$ , dann gelten die Oracle Eigenschaften aus Satz 3.1 auch noch wenn  $\lambda_n = o(\sqrt{n})$  und  $a_n^\gamma \lambda_n / \sqrt{n} \rightarrow \infty$ .
- (2) Das von den Daten abhängige Regularisierungsgewicht  $\tilde{w}$  ist der Schlüssel in Satz 3.1. Wenn der Stichprobenumfang wächst werden die Gewichte der  $\hat{\beta}_{\text{adapt},j}^{(n)} = 0$  zu unendlicher Größe aufgeblasen, während die Gewichte der  $\hat{\beta}_{\text{adapt},j}^{(n)} \neq 0$  gegen eine feste Konstante konvergieren. Also

$$\tilde{w}_j \rightarrow \infty \text{ für } j \notin \hat{S}_{\text{adapt}},$$

$$\tilde{w}_j \rightarrow c_j < \infty \text{ für } j \in \hat{S}_{\text{adapt}}.$$

# Simulation des Lasso und Adaptive Lasso

- Jetzt geht es weiter mit Simulationen, die die vorgestellten Eigenschaften des Lasso und des Adaptive Lasso veranschaulichen und vergleichen.

- [BvdG11] PETER BÜHLMANN, SARA VAN DE GEER. „*Statistics for High-Dimensional Data*“, Springer, 2011.
- [Z06] HUI ZOU. „*The adaptive lasso and its oracle properties*“, *Journal of the American Statistical Association*, 101(476), 1418-1429, 2006.