

# Sparse Recovery II

Modellparameter  $\in \mathbb{R}^{M+1}$

LASSO:  $\min_w \frac{1}{2} \|y - \Phi(x) \cdot w\|^2 + \alpha \cdot \|w\|_1$

Least absolute shrinkage and selection operator

Daten der abhängigen Größe  $y = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix} \in \mathbb{R}^n$


approximierende Funktionen  $\Phi(x) = \begin{pmatrix} \varphi^T(x^1) \\ \vdots \\ \varphi^T(x^n) \end{pmatrix} \in \mathbb{R}^{n \times (M+1)}$

Datenunabhängiger Größen  $\in \mathbb{R}^p$

Bayes-Interpretation:

$p(y_i; w) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y_i - \varphi^T(x^i) \cdot w)^2}{2\sigma^2}} \Leftarrow y_i \sim \mathcal{N}(\varphi^T(x^i) \cdot w, \sigma^2)$

$i=1, \dots, n$   
Fehlerdichte



Laplace normal  
"mehr Maß auf Erwartungswert und 'Null' oder 'groß' wahrscheinlich Tail"

- $E(y_i) = \varphi^T(x^i) \cdot w$
- $\text{Var}(y_i) = \sigma^2$

$p(w_j) = \frac{1}{2\tau} e^{-\frac{|w_j|}{\tau}} \Leftarrow w_j \sim \text{Lap}(0, \tau)$

$j=0, \dots, M$   
Prior dichte

Laplace-verteilt:  
 •  $E(w_j) = 0$   
 •  $\text{Var}(w_j) = 2\tau^2$   
 (ii)  $\| \cdot \|_1^2$  Regularisierung

$\mathcal{L}(w) = \prod_{i=1}^n p(y_i; w) \cdot \prod_{j=0}^M p(w_j) = \frac{1}{((2\pi\sigma^2)^n)} e^{-\frac{\|y - \Phi(x) \cdot w\|^2}{2\sigma^2}} \cdot \frac{1}{(2\tau)^{M+1}} e^{-\frac{\|w\|_1}{\tau}}$   
 ~ Bayes a-posteriori      iid-Messungen von Daten


$\max_w \ln \mathcal{L}(w) = \ln \left( \frac{1}{((2\pi\sigma^2)^n)} \cdot \frac{1}{(2\tau)^{M+1}} \right) - \frac{\|y - \Phi(x) \cdot w\|^2}{2\sigma^2} - \frac{\|w\|_1}{\tau}$   
 Maximum Likelihood      Konstante

$\rightarrow \min_w \frac{1}{2} \|y - \Phi(x) \cdot w\|^2 + \frac{\sigma^2}{\tau} \|w\|_1$

=  $\alpha$  - Verhältnis zwischen  $\sigma^2$  und  $\tau$   
 "Gewichtung des Dünn-Besetztheit"

$F(w) := f(w) + g(w)$

- konvex
  - differenzierbar
  - konvex
  - nicht-differenzierbar
- Approximation + Einfache Funktion



Idee zur iterativen Berechnung von  $w^*$

1. Modell für  $f(w) = \frac{1}{2} \|y - P \cdot w\|^2$  (2)

Obere Schranke

$$f(w) = f(v) + \int_0^1 f'(v + \tau(w-v)) d\tau \quad \text{Kettenregel}$$

$$= f(v) + \int_0^1 \nabla^T f(v + \tau(w-v)) \cdot (w-v) d\tau$$

Hauptsatz der Differential- und Integralrechnung:  
 $f(v + \tau(w-v)) \Big|_0^1 = f(w) - f(v)$

$$= f(v) + \nabla^T f(v) \cdot (w-v) + \int_0^1 \underbrace{[\nabla f(v + \tau(w-v)) - \nabla f(v)]^T}_{\leq} (w-v) d\tau$$

Cauchy-Schwarz  $\|\nabla f(v + \tau(w-v)) - \nabla f(v)\| \cdot \|w-v\|$   
 $|a^T b| \leq \|a\| \cdot \|b\|$

Lipschitz-Konstante  $> 0$ .

Annahme:  $\|\nabla f(u) - \nabla f(v)\| \leq L \cdot \|u-v\| \quad \forall u, v$   
 "Gradient von  $f$  ist Lipschitz-stetig"

$$\leq L \cdot \|v + \tau(w-v) - v\| \cdot \|w-v\|$$

$$= L \tau \|w-v\|^2$$

$$\leq f(v) + \nabla^T f(v) \cdot (w-v) + \int_0^1 L \cdot \tau \cdot \|w-v\|^2 d\tau =$$

$$= f(v) + \nabla^T f(v) \cdot (w-v) + L \cdot \|w-v\|^2 \cdot \int_0^1 \tau d\tau$$

$$= f(v) + \nabla^T f(v) \cdot (w-v) + \frac{L}{2} \|w-v\|^2 = \tilde{f}(w, v) - \text{Modell für } f$$

$\int_0^1 \tau d\tau = \frac{\tau^2}{2} \Big|_0^1 = \frac{1^2}{2} - \frac{0^2}{2} = \frac{1}{2}$

Zur Überprüfung der Annahme:  $f(w) \leq \tilde{f}(w, v) \quad \forall v$

$$\nabla f(w) = \frac{1}{2} (y^T y - 2y^T \cdot P \cdot w + w^T \cdot P^T \cdot P \cdot w) = -P^T \cdot y + P^T \cdot P \cdot w = P^T \cdot (P \cdot w - y)$$

$$\|\nabla f(u) - \nabla f(v)\| = \|P^T \cdot (P \cdot u - y) - P^T \cdot (P \cdot v - y)\| = \|P^T \cdot P \cdot (u-v)\|$$

= größter Eigenwert

$$= \frac{\|P^T \cdot P \cdot (u-v)\|}{\|u-v\|} \cdot \|u-v\| \leq \max_{\|w\|=1} \|P^T \cdot P \cdot w\| \cdot \|u-v\| = \lambda_{\max}(P^T \cdot P)$$

Spektralnorm von  $P$

$$\boxed{L := \lambda_{\max}(P^T \cdot P) = \|P\|^2}$$

Lipschitz-Konstante

$$\|P\| := \max_{\|w\| \leq 1} \|P \cdot w\| = \sqrt{\lambda_{\max}(P^T \cdot P)}$$

2. Modell minimierung  $f(w) + g(w) \leq \underbrace{\tilde{F}(w, v)}_{= F(w)} + g(w) \quad \forall v \quad (3)$

$\min_w \quad \cancel{f(v)} + \nabla^T f(v) \cdot (w - v) + \frac{L}{2} \|w - v\|^2 + \alpha \|w\|_1$

obere Schranke  
-  $\tilde{F}(w, v)$

"unabhängig von w"

$\min_w \quad \sum_{j=0}^M \nabla_j f(v) \cdot w_j + \frac{L}{2} (w_j - v_j)^2 + \alpha |w_j|$

minimiere bzgl.  $w_j$ , da separable Funktion

j-fest:

a)  $w_j \geq 0 \Rightarrow \min_{w_j} \nabla_j f(v) \cdot w_j + \frac{L}{2} (w_j - v_j)^2 + \alpha \cdot w_j$

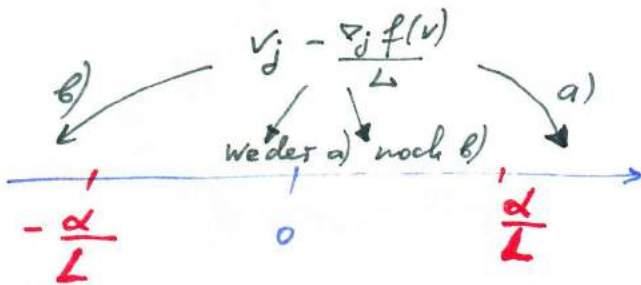
Optimalität:  $\nabla_j f(v) + L(w_j - v_j) + \alpha = 0$

$\Rightarrow w_j^a = \left[ v_j - \frac{\nabla_j f(v)}{L} \right] - \frac{\alpha}{L}$

b)  $w_j < 0 \Rightarrow \min_{w_j} \nabla_j f(v) \cdot w_j + \frac{L}{2} (w_j - v_j)^2 - \alpha \cdot w_j$

Optimalität:  $\nabla_j f(v) + L(w_j - v_j) - \alpha = 0$


$w_j^b = \left[ v_j - \frac{\nabla_j f(v)}{L} \right] + \frac{\alpha}{L}$



Lösung des Modellminimierung  $\Rightarrow w_j = \left[ \left| v_j - \frac{\nabla_j f(v)}{L} \right| - \frac{\alpha}{L} \right]_+ \cdot \text{sgn} \left( v_j - \frac{\nabla_j f(v)}{L} \right)$

Shrinkage / Soft-thresholding:  $T_\beta(z) = [ |z| - \beta ]_+ \cdot \text{sgn}(z)$

Schrittweite  $\leftarrow$  Gradientenschritt



$\Rightarrow$   $w = \frac{T_\alpha}{L} \left( v - \frac{1}{L} \nabla f(v) \right)$   
 Thresholding  $= \Phi^T(\Phi \cdot v - y)$

"kleine Einträge werden zu Null gesetzt"

Iteration  $v := w(t)$  und  $w := w(t+1)$

$\rightarrow$  Sparsity!

# Iterative Shrinkage-Thresholding Algorithm (ISTA)

4

$$w(t+1) := T_{\frac{\alpha}{L}} \left( w(t) - \frac{1}{L} \cdot \Phi^T \cdot (\Phi \cdot w(t) - y) \right)$$

$\uparrow$  (t+1)-te Iterierte       $\uparrow$  t-te Iterierte

Konvergenz:

$$F(w(t+1)) \leq \tilde{F}(w(t+1), w(t)) = \min_w \tilde{F}(w, w(t))$$

1. obere Schranke      2. Modellminimierung

$$\leq \min_w \tilde{F}(w(t), w(t)) = F(w(t))$$

einsetzen

$\Rightarrow F(w(t))$  ist monoton fallend  $\rightarrow$  Konvergenz gegen lokale Minima

= globale, da konvexes Optimierungsproblem

Ohne Beweis (analog):

$$F(w(t)) - F(w^*) \leq \frac{\alpha \cdot L \cdot \|w(0) - w^*\|^2}{2 \cdot t} \approx O\left(\frac{1}{t}\right)$$

$\uparrow$  t-te Iterierte       $\uparrow$  Lösung des Optimierungsproblems

Abstand von der 0-ten Iterierten zur Lösung

Konvergenzrate ist sublinear