

## 9.3. ANDERE REGRESSIONSVERFAHREN

Lit. Murphy: Machine Learning - A probabilistic view

Least squares Schätzer:  $\sum_{i=1}^n |y_i - w^T X_i|^2 \stackrel{!}{=} \min$

$\downarrow$   $i$ -te Zeile der Design-Matrix  $A$

Verlustfunktion = RSS (residual sum of squares)

### PROBLEM 1: ROBUSTHEIT

Der LSE ist anfällig für Ausreißer.

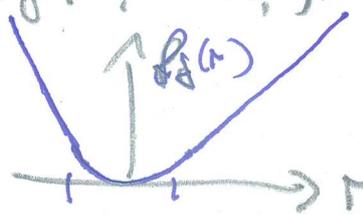
ALTERNATIVE 1 minimiere  $l^1$ -Norm  $\sum_{i=1}^n |y_i - w^T X_i|$

$\hat{=}$  MLE im Laplace-Modell  $f_{\mathcal{D}}(y_i | x_i) \propto e^{-|y_i - w^T X_i|}$

Minimierung ist Meeres Optimierungsproblem

ALTERNATIVE 2 minimiere Huber loss  $\sum_{i=1}^n f_{\delta}(y_i - w^T X_i)$

wobei  $f_{\delta}(r) = \begin{cases} r^2/2 & \text{für } |r| \leq \delta \\ \delta|r| - \frac{\delta^2}{2} & \text{für } |r| > \delta \end{cases}$

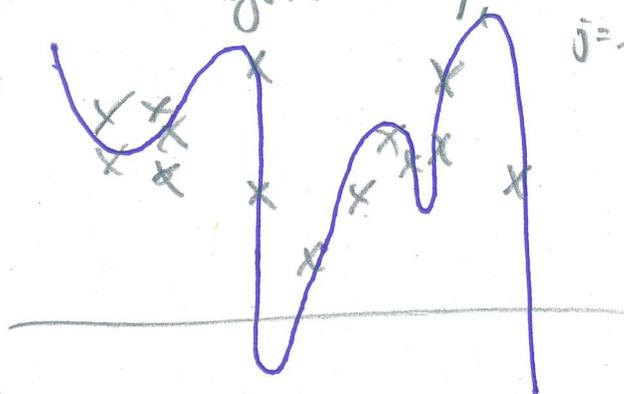


Vorteil: schnelle Optimierung durch numerische Verfahren (quasi-Newton)

## PROBLEM 2: OVERTFITTING

Bsp. Polynomielle Regression  $y_i = \sum_{j=1}^k w_j x_i^j + \varepsilon_i$

$k$  zu groß:



LSE hat zu viele große Gewichte  $w_j$

ALTERNATIVE: Ridge regression:  $\lambda > 0$  fest

$$\text{minimiere } J(w) = \underbrace{\frac{1}{n} \sum_{i=1}^n |y_i - w^T x_i|^2}_{\text{RSS}} + \underbrace{\lambda \|w\|^2}_{\text{penalty}}$$

bestraft große Gewichte

bzw. äquivalent:  $B > 0$  fest

minimiere RSS unter Nebenbedingung  $\|w\| \leq B$

$\lambda$  groß  $\leftrightarrow$   $B$  klein

$$\nabla J(w) = -\frac{2}{n} A^T Y + \frac{2}{n} A^T A w + 2\lambda w \stackrel{!}{=} 0$$

Min.

$$\Rightarrow \hat{w}_{\text{ridge}} = (\lambda I_d + A^T A)^{-1} A^T Y$$

$d$  größer  $\Rightarrow$  mehr Reg. Konst.  $\lambda$

Zudem numerisch vorteilhaft: Für  $\lambda > 0$  einfache  
Berechnung von  $\hat{w}_{\text{ridge}}$  via QR-Zerlegung

### PROBLEM 3: HOCHDIMENSIONALER PARAMETERRAUM

z. B.  $d > n \Rightarrow \text{Rang}(A) < d \Rightarrow \ker(A) \neq \{0\}$

$\Rightarrow Aw = \Pi Y$  hat keine eindeutige Lösung  $w$

ZIEL: SPARSITY Finde Schätzer  $\hat{w}$  mit  $\hat{w}_k = 0$   
für "viele"  $k$ .

$\leadsto$  Identifikation der relevanten Einflussfaktoren

ANSATZ 1: Hard sparsity  $\|w\|_0 := \#\{j \in \{1, \dots, d\} : w_j \neq 0\}$   
 $s \in \{1, \dots, d\}$  fest

Minimiere  $\|Y - Aw\|^2$  unter NB  $\|w\|_0 \leq s$

bzw. minimiere  $\mathcal{J}(w) := \underbrace{\|Y - Aw\|^2}_{\text{RSS}} + \lambda \underbrace{\|w\|_0}_{\ell^0 \text{ penalty}}$ ,  $\lambda > 0$  fest

## PROBLEME:

- $w \mapsto \|w\|_0$  unstetlich, nicht konvex

$\leadsto$  Optimierung von  $J$  ist aufwändig

- Größe der Gewichte wird nicht berücksichtigt

## ANSATZ 2: Soft Sparsity, $l^1$ Regularisierung

$$\|w\|_0 \leadsto \|w\|_1 = \sum_{j=1}^d |w_j|$$

Lipschitz-stetlich und konvex!

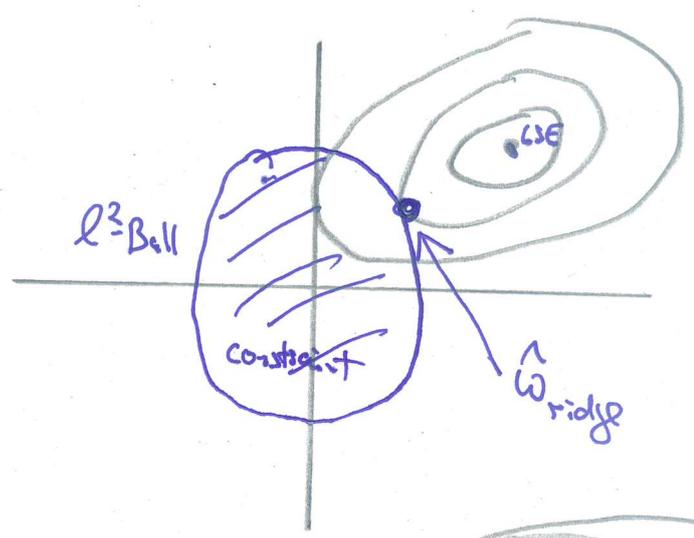
Minimiere  $\|Y-Aw\|^2$  unter NB  $\|w\|_1 \leq B$

$\leadsto$  LASSO (least absolute shrinkage and selection operator)

konvexes Optimierungsproblem

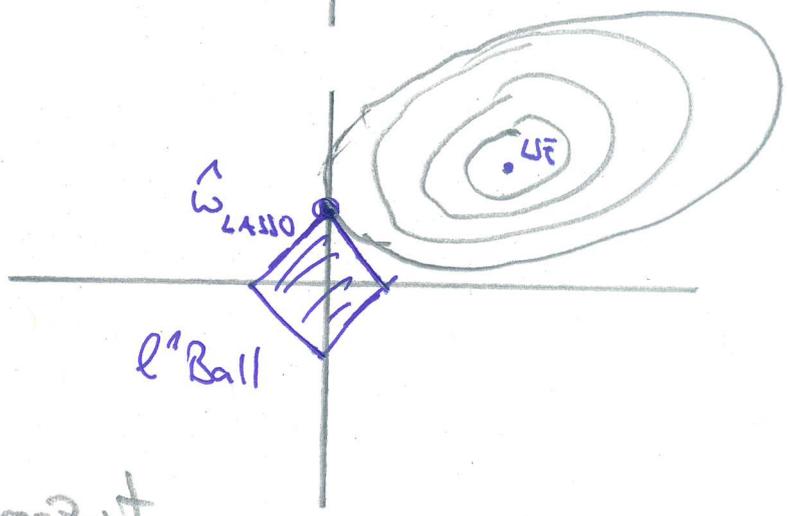
Ridge regression

$\|w\|_2 \leq B$



LASSO

$\|w\|_1 \leq B$



Minimierer bevorzugt

Ecken/Kanten/Hypoflachen des  $l^1$  Balls,  
da diese "mehr hervorstecken"

Sparse regression

$\|w\|_0 \leq B$



# PROBLEM 4: Binaire Response-Variable $Y_i \in \{0, 1\}$

~> Classification

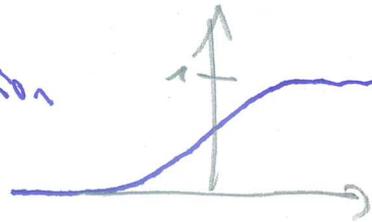
## MODELL: Logistische Regression

$Y_i \sim \text{Bernoulli}(p_i)$  bedingt unabh. geg.  $X$

$$p_i = \text{Sigm}(w^T X_i)$$

$$\text{Sigm}(x) = \frac{1}{1+e^{-x}}$$

logistische Funktion  
Sigmoid



$$\underbrace{\log\left(\frac{\overbrace{p_i}^{\text{Chancen}}}{1-p_i}\right)}_{\text{Logit-Funktion}} = w^T X_i$$

Logit-Funktion

$$L(w; Y) = \prod_{i=1}^n \text{Sigm}(w^T X_i)^{Y_i} (1 - \text{Sigm}(w^T X_i))^{1-Y_i}$$

Bestimmung des MLE z.B. via Newton-Verfahren

~> Reweighted Least Squares Algorithm