

## Kapitel 3: Ausgleichsrechnung

Hauptanwendung ist beim Anpassen eines Modells  $y = f(x, c)$  an einen Datensatz  $\{(x_j, y_j)\}_{j=1}^m$ , d.h. bestimme  $c$ , so dass gilt

$$y_j \approx f(x_j, c), \quad j = 1, \dots, m.$$

Hängt  $f$  linear von  $c = (c_1, \dots, c_n)$  ab, d.h.

$$f(x, c) = c_1 f_1(x) + \dots + c_n f_n(x)$$

mit gegebenen Funktionen  $f_1, \dots, f_n$ , führt die Forderung

$$\sum_{j=1}^m |y_j - f(x_j, c)|^2 \rightarrow \min!$$

auf das lineare Ausgleichsproblem mit

$$A = \begin{pmatrix} f_1(x_1) & \dots & f_n(x_1) \\ \vdots & & \vdots \\ f_1(x_m) & \dots & f_n(x_m) \end{pmatrix} \quad \text{und} \quad b = \begin{pmatrix} y_1 \\ \vdots \\ y_m \end{pmatrix}.$$

### Problem 3: Das lineare Gleichungssystem

$$Ax = b, \quad A \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m,$$

ist möglicherweise nicht lösbar, d.h.  $b \notin \text{Bild}(A)$ . Gesucht ist die Lösung  $x^* \in \mathbb{R}^n$  des linearen Ausgleichsproblems

$$\|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^n} \|Ax - b\|_2.$$

**3.1 Satz:** Seien  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^m$ .

(i) Problem 3 ist lösbar.

(ii)  $x^* \in \mathbb{R}^n$  löst Problem 3 genau dann wenn gilt

$$A^T Ax^* = A^T b \quad (\text{Normalengleichung}).$$

(iii) Die Lösungsmenge der Normalengleichung ist der affine Unterraum  $\{x^* + y : y \in \text{Kern}(A)\}$ .

## Bemerkungen:

(i) Für eine Matrix  $A \in \mathbb{R}^{n \times m}$  ist die Matrix  $A^T A$  positiv semi-definit.

(ii) Im Fall  $\text{Rang}(A) = n$  ist  $A^T A$  positiv definit. In diesem Fall ist Problem 3 eindeutig lösbar. Zur Lösung der Normalengleichung kann man die Cholesky-Zerlegung von  $A^T A$  verwenden.

## 3.2 Konditionierung des Problems 3

**Definition+Resultat:** Für  $A \in \mathbb{R}^{m \times n}$ ,  $m \geq n = \text{Rang}(A)$ , definiere

$$\|A\|_2 := \max_{\|x\|_2=1} \|Ax\|_2 = \sqrt{\|A^T A\|_2} = \sqrt{\lambda_{\max}(A^T A)}$$

und

$$\text{cond}_2(A) := \sqrt{\text{cond}_2(A^T A)} = \sqrt{\frac{\lambda_{\max}(A^T A)}{\lambda_{\min}(A^T A)}}.$$

Seien

$$\cos \theta = \frac{\|Ax^*\|_2}{\|b\|_2} \quad \text{und} \quad \tan \theta = \frac{\|Ax^* - b\|_2}{\|Ax^*\|_2}.$$

**Störungensatz:** Es gilt

$$\frac{\|x^* - \tilde{x}\|_2}{\|x^*\|_2} \leq \frac{\text{cond}_2(A)}{\cos \theta} \cdot \frac{\|\Delta b\|_2}{\|b\|_2}$$

und

$$\frac{\|x^* - \tilde{x}\|_2}{\|x^*\|_2} \leq \left( \text{cond}_2(A) + \text{cond}_2^2(A) \tan \theta \right) \cdot \frac{\|\Delta A\|_2}{\|A\|_2}.$$

**Bemerkung:** Falls  $\cos \theta \ll 1$  oder  $\tan \theta \gg 1$  gilt, ist das Problem 3 wesentlich anderes konditioniert als ein reguläres lineares Gleichungssystem.

### 3.3 Numerische Algorithmen ( $\text{Rang}(A) = n \leq m$ )

Methoden	Lösung	Kondition	Aufwand
Normalengleichung	$A^T A x = A^T b$	$\text{cond}(A)^2$	$\frac{mn^2}{2} + \frac{n^3}{6}$
QR-Zerlegung $A = Q \begin{pmatrix} R \\ 0 \end{pmatrix}$ $Q^T Q = I, R \in \mathbb{R}^{n \times n}$	$Rx = (q_{ij})_{i,j=1,\dots,n}^T b$	$\text{cond}(A)$	$mn^2 - \frac{n^3}{3}$
Singulärwertzerlegung $A = U \Sigma V^T$ $U U^T = I, V^T V = I$ $\Sigma \in \mathbb{R}^{m \times n}$	$\Sigma V^T x = U^T b$	$\text{cond}(A)$	$2mn^2 + 4n^3$

Normalengleichung: Die Berechnung von  $A^T A$  ist aufwändig und birgt die Gefahr von Genauigkeitsverlust durch Rundungsfehler.

QR-Zerlegung kann z.B. mit Hilfe von Householder-Transformationen

$$Q_v = I - 2 \frac{v v^T}{\|v\|_2^2}, \quad v \in \mathbb{R}^n, \quad v \neq 0,$$

berechnet werden. Wesentlich ist, dass für  $y = (y_1, \dots, y_n) \in \mathbb{R}^n$ ,  $y \neq 0$ , gilt

$$Q_v y = -\alpha e_1, \quad v = y + \alpha e_1, \quad \alpha = \operatorname{sgn}(y_1) \|y\|_2.$$

Diese Wahl von  $\alpha$  hilft die Auslöschung bei der numerischen Berechnung von  $v = (y_1 + \alpha, y_2, \dots, y_n)$  zu vermeiden. Falls  $y_1 = 0$  ist, setze  $\alpha = \|y\|_2$  oder  $\alpha = -\|y\|_2$ . Die QR-Zerlegung ist stabiler als die LR-Zerlegung und wird auch zum Lösen von regulären Gleichungssystemen benutzt. Der Nachteil ist der doppelt so hohe Rechenaufwand.

## Algorithmus (Householder-Verfahren):

Eingabe:  $A \in \mathbb{R}^{m \times n}$ ,  $m \geq n = \text{Rang}(A)$ .

Initialisierung:  $A^{(0)} = (a_{ij}^{(0)}) = (\bar{a}_1^{(0)}, \dots, \bar{a}_n^{(0)}) = A$

Für  $j = 1, \dots, n$  berechne

$$(1) v^{(j)} = \bar{a}_1^{(j-1)} + \text{sign}(a_{jj}^{(j-1)}) \cdot \|\bar{a}_1^{(j-1)}\|_2 e_j$$

$$(2) A^{(j)} = Q_{v^{(j)}} \cdot A^{(j-1)} = \begin{pmatrix} * & \dots & * & & \\ & \ddots & \vdots & & *_{j,n-j} \\ & & * & & \\ & & & & \\ 0_{m-j,j} & & & \bar{a}_1^{(j)}, \dots, \bar{a}_{m-j}^{(j)} & \end{pmatrix}.$$

Ergebnis:

$$A = \underbrace{Q_{v^{(1)}} \cdots Q_{v^{(n)}}}_{=Q \in \mathbb{R}^{m \times m}} \cdot A^{(n)} \quad \text{mit} \quad A^{(n)} = \begin{pmatrix} R \\ 0_{m-n,n} \end{pmatrix}.$$

Singulärwertzerlegung ist rechenaufwendiger als die  $QR$ -Zerlegung, ist aber stabiler, falls der numerische  $\text{Rang}(A) < n$  ist.

**Satz:** Es sei  $A \in \mathbb{R}^{m \times n}$ ,  $\text{Rang}(A) = r \leq \min(m, n)$ . Dann existieren orthogonale Matrizen  $V \in \mathbb{R}^{n \times n}$  und  $U \in \mathbb{R}^{m \times m}$ , so dass

$$U^T A V = \underbrace{\begin{pmatrix} \sigma_1 & & & 0 & \dots & 0 \\ & \ddots & & \vdots & & \vdots \\ & & & \vdots & & \vdots \\ & & & \sigma_r & & \vdots \\ 0 & \dots & 0 & 0 & \dots & 0 \\ \vdots & & & \vdots & & \vdots \\ 0 & \dots & 0 & 0 & \dots & 0 \end{pmatrix}}_{=\Sigma}, \quad \Sigma \in \mathbb{R}^{m \times n}.$$

**Definition:** Es sei  $A = U \Sigma V^T$ . Die Matrix

$$A^+ = V \Sigma^+ U^T, \quad \Sigma^+ = \begin{pmatrix} \text{diag}(\sigma_1^{-1}, \dots, \sigma_r^{-1}) & 0_{r, m-r} \\ 0_{n-r, r} & 0_{n-r, m-r} \end{pmatrix},$$

heißt die Moore-Pseudo-Inverse von  $A$ .