

# Kapitel 4

Buch Dahmen-Reusken

RWTH Aachen University

2022

# Problemstellung

## Bisher: Lineare Gleichungssysteme

- ▶ geg.:  $A \in \mathbb{R}^{n \times n}$ ,  $b \in \mathbb{R}^n$   
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$
- ▶ Annahme:  $\det A \neq 0$   
 $\Rightarrow$  Spalten von  $A$  bilden eine Basis in  $\mathbb{R}^n$   
 $\Rightarrow Ax = b$  eindeutig lösbar.

# Problemstellung

## Bisher: Lineare Gleichungssysteme

- ▶ geg.:  $A \in \mathbb{R}^{n \times n}$ ,  $b \in \mathbb{R}^n$   
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$
- ▶ Annahme:  $\det A \neq 0$   
 $\Rightarrow$  Spalten von  $A$  bilden eine Basis in  $\mathbb{R}^n$   
 $\Rightarrow Ax = b$  eindeutig lösbar.

## Jetzt: Lineare Ausgleichsrechnung

- ▶ geg.:  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ ,  $m > n$  (später auch  $m < n$ )  
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$

# Problemstellung

## Bisher: Lineare Gleichungssysteme

- ▶ geg.:  $A \in \mathbb{R}^{n \times n}$ ,  $b \in \mathbb{R}^n$   
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$
- ▶ Annahme:  $\det A \neq 0$   
 $\Rightarrow$  Spalten von  $A$  bilden eine Basis in  $\mathbb{R}^n$   
 $\Rightarrow Ax = b$  eindeutig lösbar.

## Jetzt: Lineare Ausgleichsrechnung

- ▶ geg.:  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ ,  $m > n$  (später auch  $m < n$ )  
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$   
 $\Rightarrow$  im Allgemeinen nicht lösbar! , d.h. für jedes  $x \in \mathbb{R}^n$ :  $Ax \neq b$

# Problemstellung

## Bisher: Lineare Gleichungssysteme

- ▶ geg.:  $A \in \mathbb{R}^{n \times n}$ ,  $b \in \mathbb{R}^n$   
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$
- ▶ Annahme:  $\det A \neq 0$   
 $\Rightarrow$  Spalten von  $A$  bilden eine Basis in  $\mathbb{R}^n$   
 $\Rightarrow Ax = b$  eindeutig lösbar.

## Jetzt: Lineare Ausgleichsrechnung

- ▶ geg.:  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ ,  $m > n$  (später auch  $m < n$ )  
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$   
 $\Rightarrow$  im Allgemeinen nicht lösbar! , d.h. für jedes  $x \in \mathbb{R}^n$ :  $Ax \neq b$
- ▶ Lösung: Bestimme  $x^* \in \mathbb{R}^n$ , so dass

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

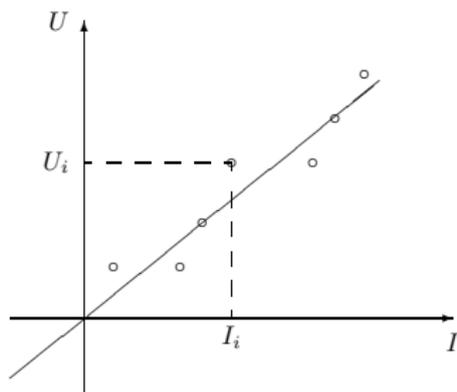
# Bestimmung des elektrischen Widerstands (Beispiel 4.1)

- ▶ Ohmsches Gesetz:  $U = I R$
- ▶ Aufgabe: Bestimme Widerstand  $R$  im Stromkreis aus einer Reihe von Messungen:

$(U_i, I_i)$  (Spannung, Stromstärke),  $i = 1, \dots, m$ .

- ▶ **Problem:** Messungen (Daten) sind mit Fehlern behaftet, d.h.

$U_i \neq I_i R$ , für fast alle  $i = 1, \dots, m$ .



# Beispiel 4.1

Vorgehen:

- ▶ Fehler in Messung  $i$  (Residuum)

$$r_i = I_i R - U_i, \quad i = 1, \dots, m$$

# Beispiel 4.1

Vorgehen:

- ▶ Fehler in Messung  $i$  (Residuum)

$$r_i = I_i R - U_i, \quad i = 1, \dots, m$$

- ▶ Ein Maß für den Gesamtfehler: Summe der Fehlerquadrate

$$f(R) := \sum_{i=1}^m r_i^2 = \sum_{i=1}^m (I_i R - U_i)^2$$

# Beispiel 4.1

Vorgehen:

- ▶ Fehler in Messung  $i$  (Residuum)

$$r_i = I_i R - U_i, \quad i = 1, \dots, m$$

- ▶ Ein Maß für den Gesamtfehler: Summe der Fehlerquadrate

$$f(R) := \sum_{i=1}^m r_i^2 = \sum_{i=1}^m (I_i R - U_i)^2$$

- ▶ Bestimme Widerstand  $R^*$  so, dass Gesamtfehler minimal wird

$$R^* = \arg \min_R f(R)$$

# Beispiel 4.1

Vorgehen:

- ▶ Fehler in Messung  $i$  (Residuum)

$$r_i = I_i R - U_i, \quad i = 1, \dots, m$$

- ▶ Ein Maß für den Gesamtfehler: Summe der Fehlerquadrate

$$f(R) := \sum_{i=1}^m r_i^2 = \sum_{i=1}^m (I_i R - U_i)^2$$

- ▶ Bestimme Widerstand  $R^*$  so, dass Gesamtfehler minimal wird

$$R^* = \arg \min_R f(R)$$

- ▶ Extremum der quadratischen Funktion  $f(R)$

$$f'(R^*) = 0 \quad \Rightarrow \quad R^* = \left( \sum_{i=1}^m U_i I_i \right) / \left( \sum_{i=1}^m I_i^2 \right)$$

# Allgemeiner: Polynomial Data-Fitting

Anstelle Ursprungsgerade, betrachte allgemeineren Fall ...

Gegeben:

- ▶  $m$  Messungen an den Punkten  $y_1, y_2, \dots, y_m$  mit zugehörigen Daten  $z_1, z_2, \dots, z_m$
- ▶ Polynom  $n - 1$ -ter Ordnung (wobei  $n < m$ )

$$f(y) = c_0 + c_1 y + \dots + c_{n-1} y^{n-1}$$

# Allgemeiner: Polynomial Data-Fitting

Anstelle Ursprungsgerade, betrachte allgemeineren Fall ...

Gegeben:

- ▶  $m$  Messungen an den Punkten  $y_1, y_2, \dots, y_m$  mit zugehörigen Daten  $z_1, z_2, \dots, z_m$
- ▶ Polynom  $n - 1$ -ter Ordnung (wobei  $n < m$ )

$$f(y) = c_0 + c_1 y + \dots + c_{n-1} y^{n-1}$$

Summe der Fehlerquadrate

$$\sum_{i=1}^m (f(y_i) - z_i)^2$$

In Matrix-Vektor Notation

$$\|A x - b\|_2^2$$

mit ...

# Polynomial Data-Fitting

mit

$$A = \begin{pmatrix} 1 & y_1 & \cdots & y_1^{n-1} \\ 1 & y_2 & \cdots & y_2^{n-1} \\ \vdots & \vdots & & \vdots \\ 1 & y_m & \cdots & y_m^{n-1} \end{pmatrix}, \quad x = \begin{pmatrix} c_0 \\ c_1 \\ \vdots \\ c_{n-1} \end{pmatrix}, \quad b = \begin{pmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{pmatrix}$$

# Polynomial Data-Fitting

mit

$$A = \begin{pmatrix} 1 & y_1 & \cdots & y_1^{n-1} \\ 1 & y_2 & \cdots & y_2^{n-1} \\ \vdots & \vdots & & \vdots \\ 1 & y_m & \cdots & y_m^{n-1} \end{pmatrix}, \quad x = \begin{pmatrix} c_0 \\ c_1 \\ \vdots \\ c_{n-1} \end{pmatrix}, \quad b = \begin{pmatrix} z_1 \\ z_2 \\ \vdots \\ z_m \end{pmatrix}$$

## Aufgabe

Bestimme  $x^* \in \mathbb{R}^n$ , so dass

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

oder (gleichbedeutend) gilt:

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

# Lineares Ausgleichsproblem

## Allgemeine Problemstellung

Modellansatz:  $y(t; x_1, \dots, x_n)$  mit Parametern  $x_1, \dots, x_n$ .

(Meß-)Daten:  $b_i \approx y(t_i; x_1, \dots, x_n)$ ,  $i = 1, \dots, m$ .

Annahme: Modell ist **linear** in den Parametern:

$$y(t_i; x_1, \dots, x_n) = a_{i,1}x_1 + \dots + a_{i,n}x_n, \quad i = 1, \dots, m.$$

**Gauß-Fehlerquadratkriterium:** man bestimme Parameter  $x_1, \dots, x_n$ , die

$$\sum_{i=1}^m (y(t_i; x_1, \dots, x_n) - b_i)^2$$

minimieren.

# Lineares Ausgleichsproblem: Matrixformulierung

Aufgabe:

$$\min_x \sum_{i=1}^m (a_{i,1}x_1 + \dots + a_{i,n}x_n - b_i)^2.$$

Setzt man

$$A = (a_{i,j})_{i,j=1}^{m,n} \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m,$$

nimmt das Minimierungsproblem die äquivalente kompakte Form

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2^2$$

# Lineares Ausgleichsproblem: Matrixformulierung

Aufgabe:

$$\min_x \sum_{i=1}^m (a_{i,1}x_1 + \dots + a_{i,n}x_n - b_i)^2.$$

Setzt man

$$A = (a_{i,j})_{i,j=1}^{m,n} \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m,$$

nimmt das Minimierungsproblem die äquivalente kompakte Form

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2^2$$

## Lineares Ausgleichsproblem

Zu gegebenen  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^m$ , bestimme  $x^* \in \mathbb{R}^n$ , so dass

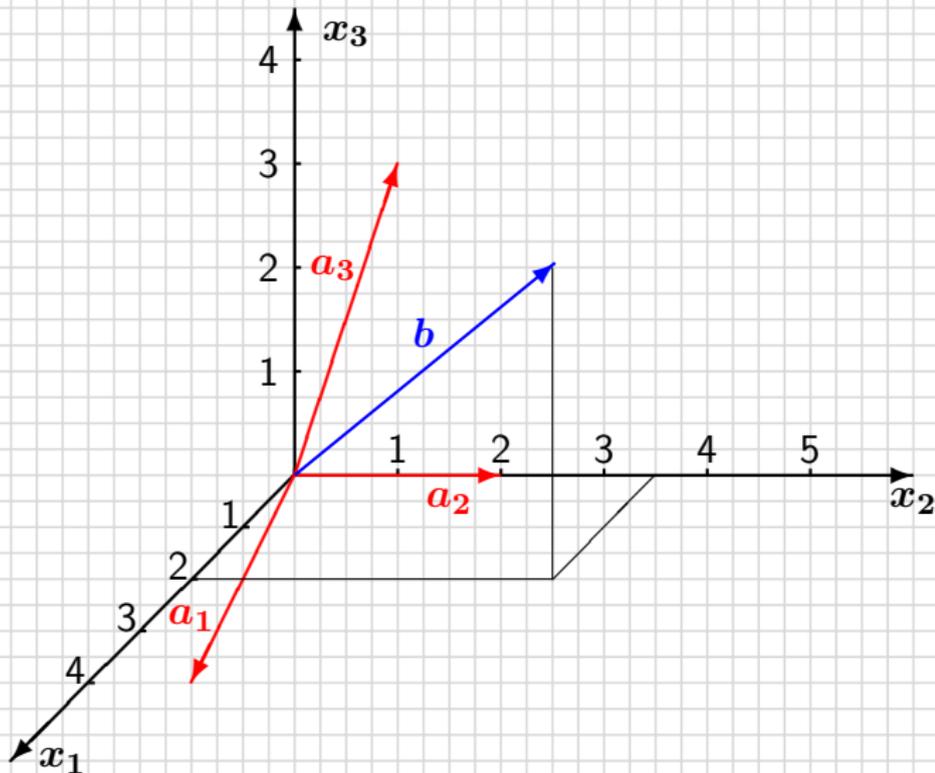
$$\|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^n} \|Ax - b\|_2.$$

Geometrische Interpretation  $Ax = b$ 

$$A = \begin{bmatrix} 4 & 0 & 0 \\ 1 & 2 & 1 \\ 0 & 0 & 3 \end{bmatrix}$$

$$b = \begin{bmatrix} 2 \\ 3.5 \\ 3 \end{bmatrix}$$

$$\Rightarrow x = \begin{bmatrix} 0.5 \\ 1 \\ 1 \end{bmatrix}$$

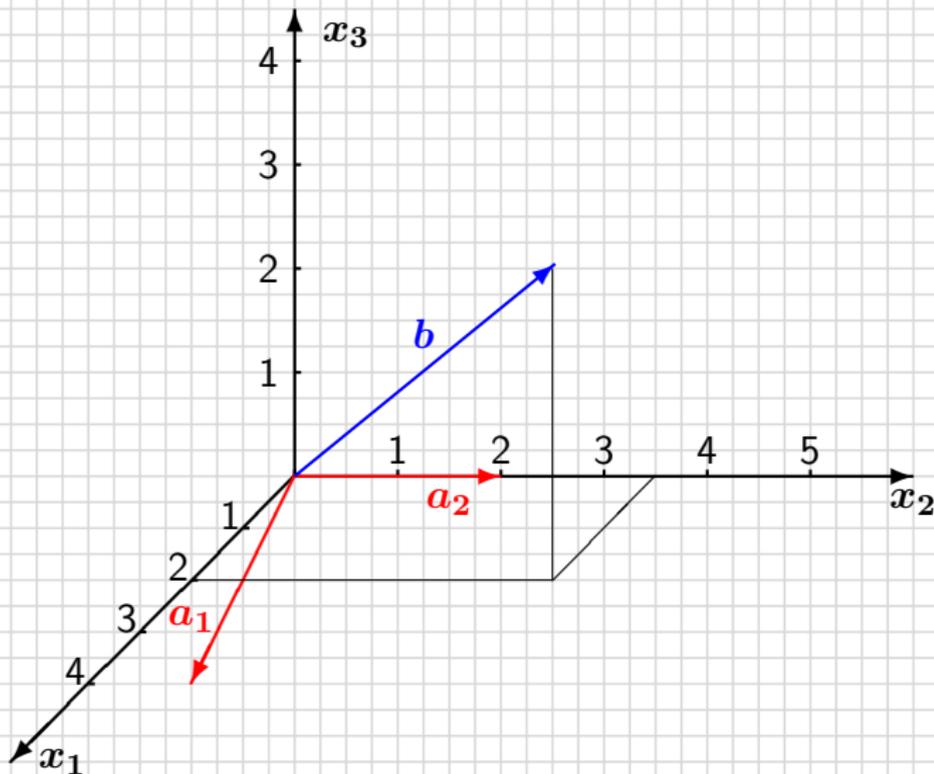


# Geometrische Interpretation $\min_{x \in \mathbb{R}^2} \|Ax - b\|_2$

$$A = \begin{bmatrix} 4 & 0 \\ 1 & 2 \\ 0 & 0 \end{bmatrix}$$

$$b = \begin{bmatrix} 2 \\ 3.5 \\ 3 \end{bmatrix}$$

$$\Rightarrow x^* = ?$$

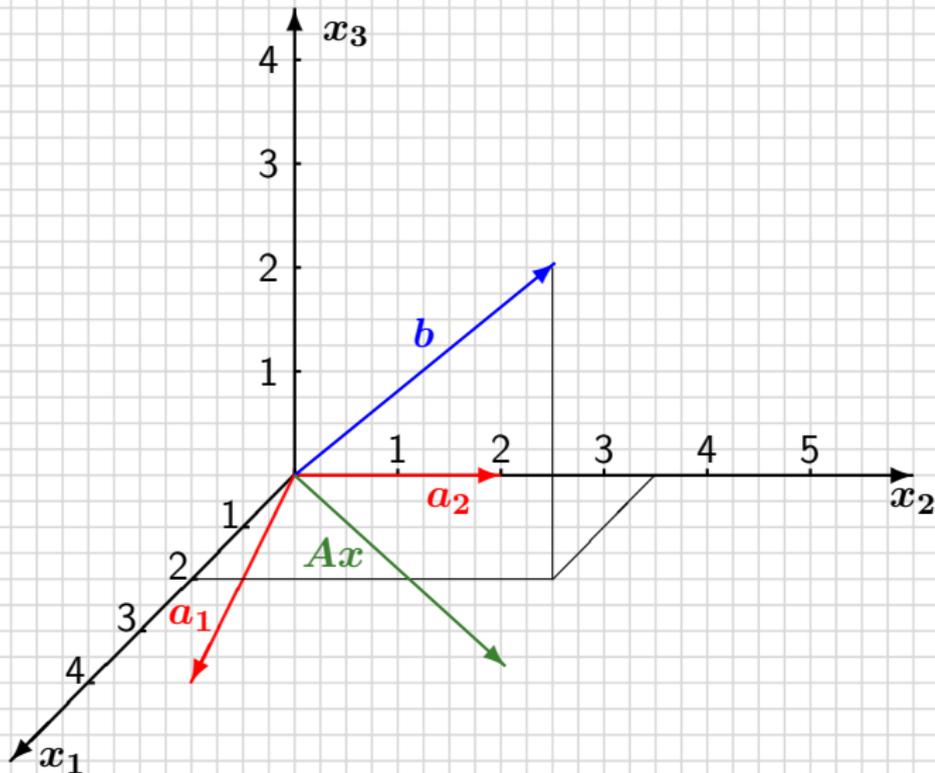


Geometrische Interpretation  $\min_{x \in \mathbb{R}^2} \|Ax - b\|_2$ 

$$A = \begin{bmatrix} 4 & 0 \\ 1 & 2 \\ 0 & 0 \end{bmatrix}$$

$$b = \begin{bmatrix} 2 \\ 3.5 \\ 3 \end{bmatrix}$$

$$\Rightarrow x^* = ?$$

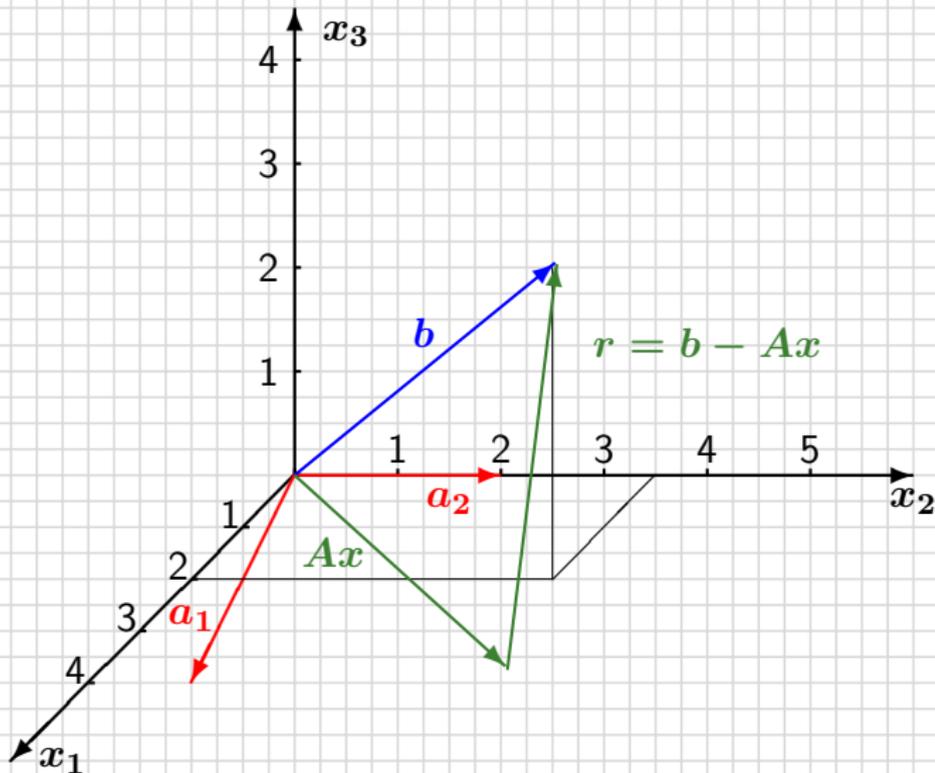


Geometrische Interpretation  $\min_{x \in \mathbb{R}^2} \|Ax - b\|_2$ 

$$A = \begin{bmatrix} 4 & 0 \\ 1 & 2 \\ 0 & 0 \end{bmatrix}$$

$$b = \begin{bmatrix} 2 \\ 3.5 \\ 3 \end{bmatrix}$$

$$\Rightarrow x^* = ?$$



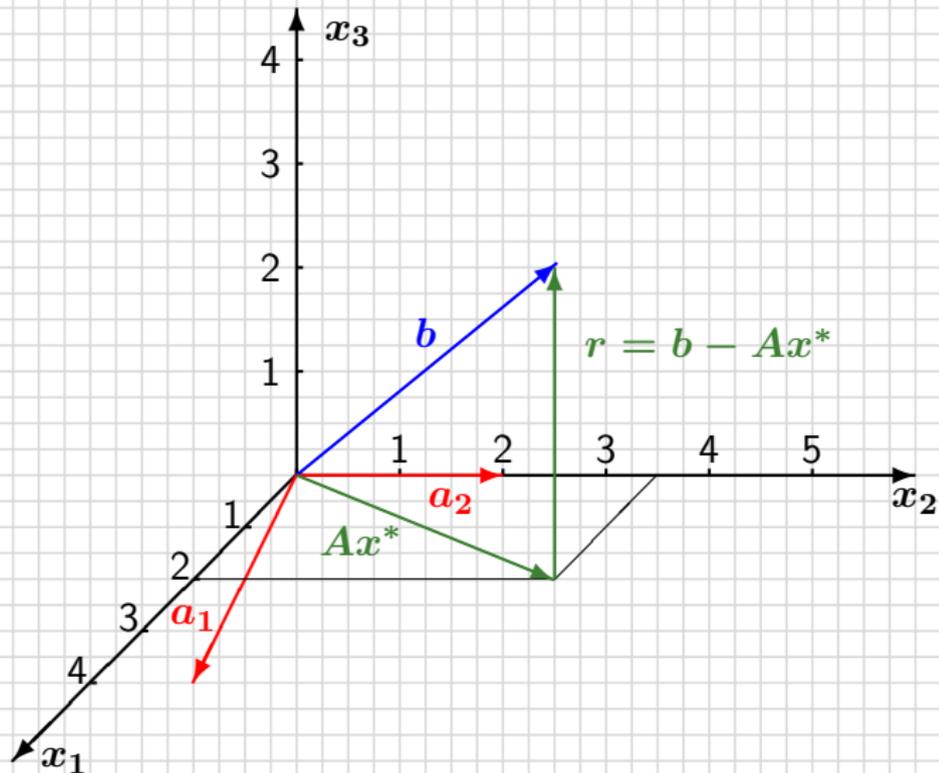
Geometrische Interpretation  $\min_{x \in \mathbb{R}^2} \|Ax - b\|_2$ 

$$A = \begin{bmatrix} 4 & 0 \\ 1 & 2 \\ 0 & 0 \end{bmatrix}$$

$$b = \begin{bmatrix} 2 \\ 3.5 \\ 3 \end{bmatrix}$$

$$\Rightarrow x^* = \begin{bmatrix} 0.5 \\ 1.5 \end{bmatrix}$$

$$\Rightarrow \|r\|_2 = 3$$



# Lineares Ausgleichsproblem: Fallunterscheidung

Falls  $\text{Rang}(A) \neq n$ : keine eindeutige Lösung. Deshalb Fallunterscheidung.

## Gewöhnliches lineares Ausgleichsproblem (Aufgabe 4.3)

Zu gegebenem  $A \in \mathbb{R}^{m \times n}$ , mit  $\text{Rang}(A) = n$ , und  $b \in \mathbb{R}^n$  bestimme  $x^* \in \mathbb{R}^n$ , so dass

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

# Lineares Ausgleichsproblem: Fallunterscheidung

Falls  $\text{Rang}(A) \neq n$ : keine eindeutige Lösung. Deshalb Fallunterscheidung.

## Gewöhnliches lineares Ausgleichsproblem (Aufgabe 4.3)

Zu gegebenem  $A \in \mathbb{R}^{m \times n}$ , mit  $\text{Rang}(A) = n$ , und  $b \in \mathbb{R}^n$  bestimme  $x^* \in \mathbb{R}^n$ , so dass

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

## Allgemeines lineares Ausgleichsproblem (Aufgabe 4.4)

Zu gegebenem  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^n$  bestimme  $x^* \in \mathbb{R}^n$  mit minimaler Euklidischer Norm, so dass

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

## Beispiel 4.5

Man vermutet, dass die Meßdaten

$t$	0	1	2	3
$y$	3	2.14	1.86	1.72

einer Gesetzmäßigkeit der Form

$$y = f(t) = \alpha \frac{1}{1+t} + \beta$$

mit noch zu bestimmenden Parametern  $\alpha, \beta \in \mathbb{R}$  gehorchen.

## Beispiel 4.5

Man vermutet, dass die Meßdaten

$t$	0	1	2	3
$y$	3	2.14	1.86	1.72

einer Gesetzmäßigkeit der Form

$$y = f(t) = \alpha \frac{1}{1+t} + \beta$$

mit noch zu bestimmenden Parametern  $\alpha, \beta \in \mathbb{R}$  gehorchen.

### Frage/Problem

- ▶ Wie lautet das zugehörige lineare Ausgleichsproblem?

## Beispiel 4.5

Meßdaten

$t$	0	1	2	3
$y$	3	2.14	1.86	1.72

Gesetzmäßigkeit

$$y = f(t) = \alpha \frac{1}{1+t} + \beta$$

Das Ausgleichsproblem lautet  $\|A x^* - b\|_2 = \min_{x \in \mathbb{R}^2} \|A x - b\|_2$ , wobei

 $x$

## Beispiel 4.5

Meßdaten

$t$	0	1	2	3
$y$	3	2.14	1.86	1.72

Gesetzmäßigkeit

$$y = f(t) = \alpha \frac{1}{1+t} + \beta$$

Das Ausgleichsproblem lautet  $\|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^2} \|Ax - b\|_2$ , wobei

$$x = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}, \quad A$$

## Beispiel 4.5

Meßdaten

$t$	0	1	2	3
$y$	3	2.14	1.86	1.72

Gesetzmäßigkeit

$$y = f(t) = \alpha \frac{1}{1+t} + \beta$$

Das Ausgleichsproblem lautet  $\|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^2} \|Ax - b\|_2$ , wobei

$$x = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}, \quad A = \begin{pmatrix} \frac{1}{1+0} & 1 \\ \frac{1}{1+1} & 1 \\ \frac{1}{1+2} & 1 \\ \frac{1}{1+3} & 1 \end{pmatrix}$$

## Beispiel 4.5

Meßdaten

$t$	0	1	2	3
$y$	3	2.14	1.86	1.72

Gesetzmäßigkeit

$$y = f(t) = \alpha \frac{1}{1+t} + \beta$$

Das Ausgleichsproblem lautet  $\|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^2} \|Ax - b\|_2$ , wobei

$$x = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}, \quad A = \begin{pmatrix} \frac{1}{1+0} & 1 \\ \frac{1}{1+1} & 1 \\ \frac{1}{1+2} & 1 \\ \frac{1}{1+3} & 1 \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ \frac{1}{2} & 1 \\ \frac{1}{3} & 1 \\ \frac{1}{4} & 1 \end{pmatrix}, \quad b$$

## Beispiel 4.5

Meßdaten

$t$	0	1	2	3
$y$	3	2.14	1.86	1.72

Gesetzmäßigkeit

$$y = f(t) = \alpha \frac{1}{1+t} + \beta$$

Das Ausgleichsproblem lautet  $\|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^2} \|Ax - b\|_2$ , wobei

$$x = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}, \quad A = \begin{pmatrix} \frac{1}{1+0} & 1 \\ \frac{1}{1+1} & 1 \\ \frac{1}{1+2} & 1 \\ \frac{1}{1+3} & 1 \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ \frac{1}{2} & 1 \\ \frac{1}{3} & 1 \\ \frac{1}{4} & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 3 \\ 2.14 \\ 1.86 \\ 1.72 \end{pmatrix}.$$

# Best-Approximation-Aufgabe

Lineares Ausgleichsproblem:

Bestimme dasjenige  $\mathbf{y}^*$  in  $U = \text{Bild}(A) = \{A\mathbf{x} \mid \mathbf{x} \in \mathbb{R}^n\} \subset \mathbb{R}^m$ , so dass

$$\|\mathbf{y}^* - \mathbf{b}\|_2 = \min_{\mathbf{y} \in U} \|\mathbf{y} - \mathbf{b}\|_2.$$

# Best-Approximation-Aufgabe

Lineares Ausgleichsproblem:

Bestimme dasjenige  $\mathbf{y}^*$  in  $U = \text{Bild}(A) = \{A\mathbf{x} \mid \mathbf{x} \in \mathbb{R}^n\} \subset \mathbb{R}^m$ , so dass

$$\|\mathbf{y}^* - \mathbf{b}\|_2 = \min_{\mathbf{y} \in U} \|\mathbf{y} - \mathbf{b}\|_2.$$

Beispiel einer Best-Approximation-Aufgabe.

Sei  $V$  ein Vektorraum mit Skalarprodukt  $\langle \cdot, \cdot \rangle$ ,

Norm  $\|\mathbf{v}\| := \langle \mathbf{v}, \mathbf{v} \rangle^{\frac{1}{2}}$ .

## Best-Approximation-Aufgabe 4.8

Es sei  $U \subset V$  ein  $n$ -dimensionaler Teilraum von  $V$ . Zu  $\mathbf{v} \in V$  bestimme  $\mathbf{u}^* \in U$ , so dass

$$\|\mathbf{u}^* - \mathbf{v}\| = \min_{\mathbf{u} \in U} \|\mathbf{u} - \mathbf{v}\|.$$

# Best-Approximation-Aufgabe

## Satz 4.11

Es existiert ein eindeutiges  $u^* \in U$ , das

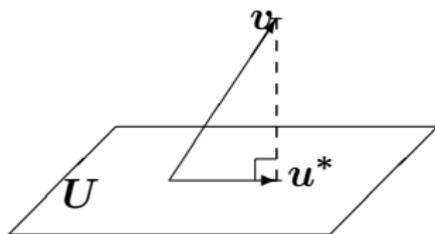
$$\|u^* - v\| = \min_{u \in U} \|u - v\| \quad (1)$$

erfüllt. Ferner gilt (1) genau dann, wenn

$$\langle u^* - v, u \rangle = 0 \quad \forall u \in U,$$

d.h.,  $u^* - v$  senkrecht (bzgl.  $\langle \cdot, \cdot \rangle$ ) zu  $U$  ist. Das Element  $u^*$  ist somit die **orthogonale Projektion** (bzgl.  $\langle \cdot, \cdot \rangle$ ) von  $v$  auf  $U$ .

# Orthogonale Projektion



## Definition 4.12

Es seien  $V$  ein Vektorraum mit Skalarprodukt  $\langle \cdot, \cdot \rangle$  und dadurch induzierter Norm  $\|\cdot\| = \langle \cdot, \cdot \rangle^{1/2}$  und  $U$  ein endlichdimensionaler Unterraum von  $V$ . Zu  $v \in V$  existiert ein eindeutiges  $P_U(v) \in U$ , so dass  $v - P_U(v) \perp U$ , d.h.,

$$\langle v - P_U(v), u \rangle = 0 \quad \forall u \in U.$$

Die Abbildung  $P_U : V \rightarrow U$  ist die **orthogonale Projektion** (auf  $U$ ).

# Orthogonale Projektion

## Eigenschaften der orthogonalen Projektion

- ▶ Die Abbildung  $P_U : V \rightarrow U$  ist **linear**.
- ▶  $P_U$  ist ein **Projektor**, d.h.  $P_U(u) = u$  für alle  $u \in U$  ( $P_U^2 = P_U$ ).
- ▶ Die Abbildung  $P_U$  ist **symmetrisch**, d.h.,

$$\langle P_U(v), w \rangle = \langle v, P_U(w) \rangle, \quad \forall v, w \in V.$$

- ▶  $P_U$  ist beschränkt und zwar gilt

$$\|P_U\| = \sup_{\|v\|=1} \|P_U(v)\| = 1.$$

# Bestimmung von $P_U(v)$

Es seien  $\{\phi_1, \dots, \phi_n\}$  eine **Basis** für  $U$  und  $P_U(v) = \sum_{j=1}^n c_j \phi_j$ .

Wir definieren

$$\begin{aligned} c &= (c_1, \dots, c_n)^T, & \hat{v} &= (\langle v, \phi_1 \rangle, \dots, \langle v, \phi_n \rangle)^T, \\ G &:= (\langle \phi_k, \phi_j \rangle)_{j,k=1}^n & & \text{(Gram-Matrix)}. \end{aligned}$$

Die Matrix  $G$  ist symmetrisch positiv definit.

# Bestimmung von $P_U(v)$

Es seien  $\{\phi_1, \dots, \phi_n\}$  eine Basis für  $U$  und  $P_U(v) = \sum_{j=1}^n c_j \phi_j$ .

Wir definieren

$$\begin{aligned} c &= (c_1, \dots, c_n)^T, & \hat{v} &= (\langle v, \phi_1 \rangle, \dots, \langle v, \phi_n \rangle)^T, \\ G &:= (\langle \phi_k, \phi_j \rangle)_{j,k=1}^n & & \text{(Gram-Matrix)}. \end{aligned}$$

Die Matrix  $G$  ist symmetrisch positiv definit.

Es gilt:  $Gc = \hat{v}$ .

Die Berechnung einer orthogonalen Projektion läuft also im Allgemeinen auf die Lösung eines Gleichungssystems mit einer symmetrisch positiv definiten Matrix hinaus.

# Bestimmung von $P_U(v)$

Wichtiger Spezialfall:

$\{\phi_1, \dots, \phi_n\}$  eine **Orthonormalbasis** für  $U$ :

$$\langle \phi_i, \phi_j \rangle = \delta_{ij}, \quad i, j = 1, \dots, n.$$

Es gilt  $G = I$ .

## Folgerung 4.13

Für jedes  $v \in V$  löst

$$P_U(v) := \sum_{j=1}^n \langle v, \phi_j \rangle \phi_j$$

die Best-Approximation-Aufgabe 4.8.

## Beispiel 4.14: Fourier-Best-Approximation

$V := C([0, 2\pi])$  und  $\langle f, g \rangle := \int_0^{2\pi} f(t)g(t) dt$ .

Die trigonometrischen Funktionen

$\cos(kt)$ ,  $k = 0, \dots, N$ ,  $\sin(\ell t)$ ,  $\ell = 1, \dots, N$ ,  
bilden ein **Orthogonalsystem** bezüglich dieses Skalarprodukts.

$U$ : der von diesen  $2N + 1$  Funktionen aufgespannte Raum.

## Beispiel 4.14: Fourier-Best-Approximation

$V := C([0, 2\pi])$  und  $\langle f, g \rangle := \int_0^{2\pi} f(t)g(t) dt$ .

Die trigonometrischen Funktionen

$$\cos(kt), \quad k = 0, \dots, N, \quad \sin(\ell t), \quad \ell = 1, \dots, N,$$

bilden ein **Orthogonalsystem** bezüglich dieses Skalarprodukts.

$U$ : der von diesen  $2N + 1$  Funktionen aufgespannte Raum.

Die Funktion  $g_N(t) := \frac{1}{2}a_0 + \sum_{k=1}^N a_k \cos(kt) + b_k \sin(kt)$ ,

$$a_k := \frac{1}{\pi} \int_0^{2\pi} f(t) \cos(kt) dt, \quad b_k := \frac{1}{\pi} \int_0^{2\pi} f(t) \sin(kt) dt,$$

löst die Aufgabe

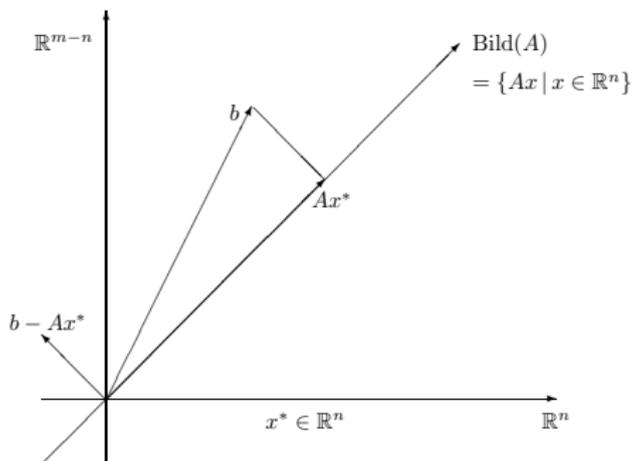
$$\|g_N - f\|_{L^2}^2 = \int_0^{2\pi} (g_N(t) - f(t))^2 dt = \min_{g \in U} \|g - f\|_{L^2}^2.$$

# Normalgleichungen

Die Lösung des linearen Ausgleichsproblems lässt sich auf die Lösung des linearen Gleichungssystems

$$A^T A x = A^T b$$

reduzieren, das häufig als **Normalgleichungen** bezeichnet wird.



# Normalgleichungen

**Annahme:** die Matrix  $A$  hat vollen Spaltenrang.

## Satz 4.15

Der Vektor  $x^* \in \mathbb{R}^n$  ist genau dann Lösung des gewöhnlichen linearen Ausgleichsproblems, wenn  $x^*$  Lösung der sogenannten **Normalgleichungen**

$$A^T A x = A^T b$$

ist. Die Systemmatrix  $A^T A$  ist symmetrisch positiv definit.

# Normalgleichungen

**Annahme:** die Matrix  $A$  hat vollen Spaltenrang.

## Satz 4.15

Der Vektor  $x^* \in \mathbb{R}^n$  ist genau dann Lösung des gewöhnlichen linearen Ausgleichsproblems, wenn  $x^*$  Lösung der sogenannten **Normalgleichungen**

$$A^T A x = A^T b$$

ist. Die Systemmatrix  $A^T A$  ist symmetrisch positiv definit.

## Bemerkung 4.17

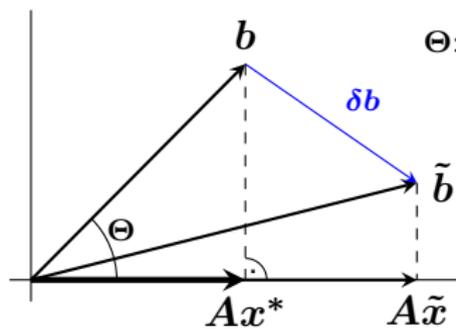
Die Abbildung  $b \mapsto x^*$ ,  $x^* = (A^T A)^{-1} A^T b$ , ist **linear**. Da im Falle  $m = n$  gerade  $(A^T A)^{-1} A^T = A^{-1}$  gilt, kann man die Matrix  $(A^T A)^{-1} A^T$  als eine Verallgemeinerung der Inversen betrachten.

# Kondition des gewöhnlichen linearen Ausgleichsproblems

Für  $A \in \mathbb{R}^{m \times n}$  sei  $\kappa_2(A) := \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} / \min_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}$ .

# Kondition des gewöhnlichen linearen Ausgleichsproblems

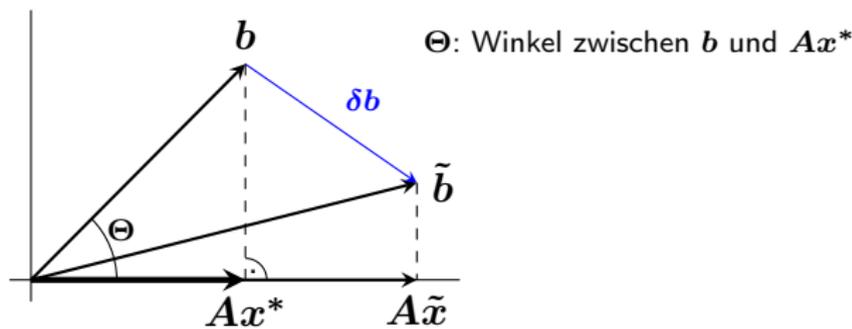
Für  $A \in \mathbb{R}^{m \times n}$  sei  $\kappa_2(A) := \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} / \min_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}$ .



$\Theta$ : Winkel zwischen  $b$  und  $Ax^*$

# Kondition des gewöhnlichen linearen Ausgleichsproblems

Für  $A \in \mathbb{R}^{m \times n}$  sei  $\kappa_2(A) := \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} / \min_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}$ .



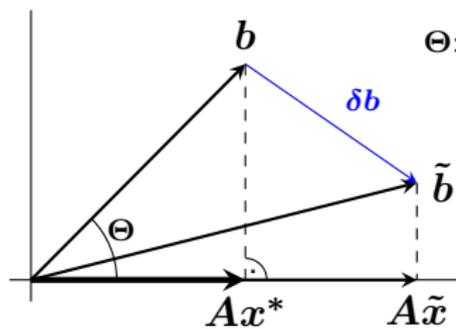
## Satz 4.18

Für die Kondition des linearen Ausgleichsproblems bezüglich Störungen in  $b$  gilt

$$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \leq \frac{\kappa_2(A)}{\cos \Theta} \frac{\|\tilde{b} - b\|_2}{\|b\|_2}.$$

# Kondition des gewöhnlichen linearen Ausgleichsproblems

Für  $A \in \mathbb{R}^{m \times n}$  sei  $\kappa_2(A) := \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} / \min_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}$ .



$\Theta$ : Winkel zwischen  $b$  und  $Ax^*$

## Satz 4.20

Für die Kondition des linearen Ausgleichsproblems bezüglich Störungen in  $A$  gilt

$$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \leq \left( \kappa_2(A) + \kappa_2(A)^2 \tan \Theta \right) \frac{\|\tilde{A} - A\|_2}{\|A\|_2}$$

## Beispiel 4.19

Gegeben seien

$$A := \begin{pmatrix} 1 & 1 \\ 0 & 0 \\ 0 & 1 \end{pmatrix} \quad \text{und} \quad b := \begin{pmatrix} 0.01 \\ 1 \\ 0 \end{pmatrix},$$

sowie eine gestörte rechte Seite  $\tilde{b} = (0.01, 1, 0.01)^T$ . Bestimmen Sie  $x^*$  und  $\tilde{x}$ , und diskutieren Sie die Kondition des linearen Ausgleichsproblems.

## Beispiel 4.19

Gegeben seien

$$\mathbf{A} := \begin{pmatrix} 1 & 1 \\ 0 & 0 \\ 0 & 1 \end{pmatrix} \quad \text{und} \quad \mathbf{b} := \begin{pmatrix} 0.01 \\ 1 \\ 0 \end{pmatrix},$$

sowie eine gestörte rechte Seite  $\tilde{\mathbf{b}} = (0.01, 1, 0.01)^T$ . Bestimmen Sie  $\mathbf{x}^*$  und  $\tilde{\mathbf{x}}$ , und diskutieren Sie die Kondition des linearen Ausgleichsproblems.

Die Lösung der Normalgleichungen liefert

$$\mathbf{x}^* = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{b} = \begin{pmatrix} 0.01 \\ 0 \end{pmatrix},$$

sowie für die gestörte rechte Seite

$$\tilde{\mathbf{x}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \tilde{\mathbf{b}} = \begin{pmatrix} 0 \\ 0.01 \end{pmatrix}.$$

## Beispiel 4.19

Daraus folgt

$$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 100 \frac{\|\tilde{b} - b\|_2}{\|b\|_2},$$

also eine schlechte Kondition des linearen Ausgleichsproblems.

## Beispiel 4.19

Daraus folgt

$$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 100 \frac{\|\tilde{b} - b\|_2}{\|b\|_2},$$

also eine schlechte Kondition des linearen Ausgleichsproblems.

Mit Hilfe von Satz 4.18 erhält man aus

$$\kappa_2(A) \approx 2.62 \quad \text{und} \quad \cos \Theta = \frac{\|A x^*\|_2}{\|b\|_2} = 0.01,$$

für die Kondition bezüglich Störungen in  $b$

$$\frac{\kappa_2(A)}{\cos \Theta} = 262,$$

d.h. eine schlechte Kondition, obwohl  $\kappa_2(A)$  klein ist.

# Lineare Regression: Statistischer Hintergrund

Es seien  $(t_1, y_1), \dots, (t_m, y_m)$  Daten, mit  $t_i$  feste (deterministische) Messpunkte und die  $y_i$  Realisierungen von **Zufallsvariablen**  $Y_i$ .

Die **Lineare Regression** basiert auf einem Ansatz der Form

$$Y_i = \sum_{k=1}^n a_k(t_i)x_k + F_i, \quad i = 1, \dots, m,$$

wobei die  $a_k(t)$  geeignete Ansatzfunktionen sind.

Modell- oder Messfehler werden durch die **Zufallsvariablen**  $F_i$  dargestellt.

# Lineare Regression: Statistischer Hintergrund

Es seien  $(t_1, y_1), \dots, (t_m, y_m)$  Daten, mit  $t_i$  feste (deterministische) Messpunkte und die  $y_i$  Realisierungen von **Zufallsvariablen**  $Y_i$ .

Die **Lineare Regression** basiert auf einem Ansatz der Form

$$Y_i = \sum_{k=1}^n a_k(t_i)x_k + F_i, \quad i = 1, \dots, m,$$

wobei die  $a_k(t)$  geeignete Ansatzfunktionen sind.

Modell- oder Messfehler werden durch die **Zufallsvariablen**  $F_i$  dargestellt.

Die gegebenen Messdaten  $\mathbf{y} = (y_1, \dots, y_m)^T$  sind Realisierungen von  $\mathbf{Y} = (Y_1, \dots, Y_m)^T$ .

Wir definieren die Zufallsvariable

$$\hat{\mathbf{x}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y}.$$

$\hat{\mathbf{x}}$  ist ein **Schätzer** für den unbekanntem Parametersatz.

# Lineare Regression: Statistischer Hintergrund

$\hat{x}$  ist ein **Schätzer** für den unbekannt Parametersatz  $x$ .

Annahme:  $F_i$  sind unabhängig, identisch verteilt mit Erwartungswert  $\mathbb{E}(F_i) = \mathbf{0}$  und Varianz-Kovarianzmatrix  $\sigma^2 I$ .

# Lineare Regression: Statistischer Hintergrund

$\hat{x}$  ist ein **Schätzer** für den unbekanntens Parametersatz  $x$ .

Annahme:  $F_i$  sind unabhängig, identisch verteilt mit Erwartungswert  $\mathbb{E}(F_i) = 0$  und Varianz-Kovarianzmatrix  $\sigma^2 I$ .

- ▶  $\hat{x}$  ist der “Best Linear Unbiased Estimator” (**BLUE**). Es gilt:
  - $\hat{x}$  ist **linear** in  $y$ .
  - $\hat{x}$  ist **erwartungstreu**:  $\mathbb{E}(\hat{x}) = x$ .
  - $\hat{x}$  hat **minimale Varianz**.

# Lineare Regression: Statistischer Hintergrund

$\hat{x}$  ist ein **Schätzer** für den unbekanntens Parametersatz  $x$ .

Annahme:  $F_i$  sind unabhängig, identisch verteilt mit Erwartungswert  $\mathbb{E}(F_i) = 0$  und Varianz-Kovarianzmatrix  $\sigma^2 I$ .

- ▶  $\hat{x}$  ist der “Best Linear Unbiased Estimator” (**BLUE**). Es gilt:
  - $\hat{x}$  ist **linear** in  $y$ .
  - $\hat{x}$  ist **erwartungstreu**:  $\mathbb{E}(\hat{x}) = x$ .
  - $\hat{x}$  hat **minimale Varianz**.
- ▶  $\hat{x}$  ist der “Maximum-Likelihood-Schätzer” (**MLS**).  
Weitere Annahme:  $F_i$  sind normalverteilt.  
Für die Messreihe  $y_1, \dots, y_m$  ist die Likelihood-Funktion:

$$L(x; y_1, \dots, y_m) := \left( \frac{1}{2\pi\sigma^2} \right)^{\frac{m}{2}} e^{-\frac{1}{2\sigma^2} \|y - Ax\|_2^2}.$$

Das **Maximum dieser Funktion** wird an der Stelle  $\hat{x}$  angenommen.

# Lösung über Normalgleichungen

Da die Matrix  $A^T A$  **symmetrisch positiv definit** ist, ergibt sich folgende Methode:

## Lösung über Normalgleichungen

- ▶ Berechne  $A^T A$ ,  $A^T b$ .
- ▶ Berechne die Cholesky-Zerlegung von  $A^T A$

$$LDL^T = A^T A$$

- ▶ Löse

$$L y = A^T b, \quad L^T x = D^{-1} y$$

durch Vorwärts- bzw. Rückwärtseinsetzen.

# Lösung über Normalgleichungen

Da die Matrix  $A^T A$  **symmetrisch positiv definit** ist, ergibt sich folgende Methode:

## Lösung über Normalgleichungen

- ▶ Berechne  $A^T A$ ,  $A^T b$ .
- ▶ Berechne die Cholesky-Zerlegung von  $A^T A$

$$LDL^T = A^T A$$

- ▶ Löse

$$L y = A^T b, \quad L^T x = D^{-1} y$$

durch Vorwärts- bzw. Rückwärtseinsetzen.

Rechenaufwand: etwa  $mn^2 + \frac{1}{3}n^3$  Flop.

# Lösung über Normalgleichungen — Nachteile

- ▶ Die Berechnung von  $\mathbf{A}^T \mathbf{A}$  ist für große  $m$  aufwendig ( $mn^2$  Flop).

# Lösung über Normalgleichungen — Nachteile

- ▶ Die Berechnung von  $A^T A$  ist für große  $m$  aufwendig ( $mn^2$  Flop).
- ▶ Rundungsfehler bei der Berechnung von  $A^T A$  und  $A^T b$  (im ersten Schritt des Verfahrens) können mit einem Faktor  $\kappa_2(A^T A)$  verstärkt werden.

# Lösung über Normalgleichungen — Nachteile

- ▶ Die Berechnung von  $A^T A$  ist für große  $m$  aufwendig ( $mn^2$  Flop).
- ▶ Rundungsfehler bei der Berechnung von  $A^T A$  und  $A^T b$  (im ersten Schritt des Verfahrens) können mit einem Faktor  $\kappa_2(A^T A)$  verstärkt werden.
- ▶ Bei der Lösung des Systems  $A^T A x = A^T b$  über das Cholesky-Verfahren werden die in der Durchführung entstehenden Rundungsfehler mit (höchstens)

$$\kappa_2(A^T A)$$

verstärkt. Es gilt  $\kappa_2(A^T A) = \kappa_2(A)^2$ .

Folglich wird die Rundungsfehlerverstärkung durch  $\kappa_2(A)^2$  beschrieben.

## Beispiel 4.24

Gegeben seien

$$A = \begin{pmatrix} \sqrt{3} & \sqrt{3} \\ \delta & 0 \\ 0 & \delta \end{pmatrix}, \quad b = \begin{pmatrix} 2\sqrt{3} \\ \delta \\ \delta \end{pmatrix}, \quad 0 < \delta \ll 1.$$

Bestimmen Sie die Lösung des linearen Ausgleichsproblems über die Normalgleichungen und diskutieren Sie das Ergebnis.

## Beispiel 4.24

Gegeben seien

$$A = \begin{pmatrix} \sqrt{3} & \sqrt{3} \\ \delta & 0 \\ 0 & \delta \end{pmatrix}, \quad b = \begin{pmatrix} 2\sqrt{3} \\ \delta \\ \delta \end{pmatrix}, \quad 0 < \delta \ll 1.$$

Bestimmen Sie die Lösung des linearen Ausgleichsproblems über die Normalgleichungen und diskutieren Sie das Ergebnis.

- ▶ Das lineare Ausgleichsproblem hat die Lösung  $x^* = (1, 1)^T$  (für alle  $\delta > 0$ ).

## Beispiel 4.24

Gegeben seien

$$A = \begin{pmatrix} \sqrt{3} & \sqrt{3} \\ \delta & 0 \\ 0 & \delta \end{pmatrix}, \quad b = \begin{pmatrix} 2\sqrt{3} \\ \delta \\ \delta \end{pmatrix}, \quad 0 < \delta \ll 1.$$

Bestimmen Sie die Lösung des linearen Ausgleichsproblems über die Normalgleichungen und diskutieren Sie das Ergebnis.

- ▶ Das lineare Ausgleichsproblem hat die Lösung  $x^* = (1, 1)^T$  (für alle  $\delta > 0$ ).
- ▶ Es gilt  $\Theta = 0$  und damit  $\cos \Theta = 1$ , d.h. die **Kondition** des Problems wird ausschließlich durch  $\kappa_2(A)$  beschrieben.

## Beispiel 4.24

Gegeben seien

$$A = \begin{pmatrix} \sqrt{3} & \sqrt{3} \\ \delta & 0 \\ 0 & \delta \end{pmatrix}, \quad b = \begin{pmatrix} 2\sqrt{3} \\ \delta \\ \delta \end{pmatrix}, \quad 0 < \delta \ll 1.$$

Bestimmen Sie die Lösung des linearen Ausgleichsproblems über die Normalgleichungen und diskutieren Sie das Ergebnis.

- ▶ Das lineare Ausgleichsproblem hat die Lösung  $x^* = (1, 1)^T$  (für alle  $\delta > 0$ ).
- ▶ Es gilt  $\Theta = 0$  und damit  $\cos \Theta = 1$ , d.h. die **Kondition** des Problems wird ausschließlich durch  $\kappa_2(A)$  beschrieben.
- ▶ Man rechnet einfach nach, dass

$$\kappa_2(A) \approx \frac{\sqrt{6}}{\delta}.$$

## Beispiel 4.24

- Ein stabiles Verfahren sollte ein Resultat  $\tilde{\mathbf{x}}$  liefern, mit

$$\frac{\|\tilde{\mathbf{x}} - \mathbf{x}^*\|_2}{\|\mathbf{x}^*\|_2} \lesssim \kappa_2(\mathbf{A}) \text{ eps}$$

## Beispiel 4.24

- ▶ Ein stabiles Verfahren sollte ein Resultat  $\tilde{x}$  liefern, mit

$$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \lesssim \kappa_2(A) \text{ eps}$$

- ▶ Die Lösung dieses Problems über die Normalgleichungen und das Cholesky-Verfahren auf einer Maschine mit  $\text{eps} \approx 10^{-16}$  ergibt jedoch:

$$\delta = 10^{-4} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 2 \cdot 10^{-8} \approx \frac{1}{3} \kappa_2(A)^2 \text{ eps}$$

$$\delta = 10^{-6} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 2 \cdot 10^{-4} \approx \frac{1}{3} \kappa_2(A)^2 \text{ eps}$$

## Beispiel 4.24

- ▶ Ein stabiles Verfahren sollte ein Resultat  $\tilde{x}$  liefern, mit

$$\frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \lesssim \kappa_2(A) \text{ eps}$$

- ▶ Die Lösung dieses Problems über die Normalgleichungen und das Cholesky-Verfahren auf einer Maschine mit  $\text{eps} \approx 10^{-16}$  ergibt jedoch:

$$\delta = 10^{-4} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 2 \cdot 10^{-8} \approx \frac{1}{3} \kappa_2(A)^2 \text{ eps}$$

$$\delta = 10^{-6} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 2 \cdot 10^{-4} \approx \frac{1}{3} \kappa_2(A)^2 \text{ eps}$$

Das Lösungsverfahren ist (in diesem Beispiel) **nicht stabil**.

# Lösung über QR-Zerlegung

Zur Erinnerung:

- ▶ Für  $A \in \mathbb{R}^{m \times n}$ ,  $m > n$ , mit  $\mathbf{Rang}(A) = n$ , folgt aus der QR-Zerlegung von  $A$ , dass

$$Q A = R = \begin{pmatrix} \tilde{R} \\ \mathbf{0} \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix},$$

wobei die obere Dreiecksmatrix  $\tilde{R} \in \mathbb{R}^{n \times n}$  regulär ist.

# Lösung über QR-Zerlegung

Zur Erinnerung:

- ▶ Für  $A \in \mathbb{R}^{m \times n}$ ,  $m > n$ , mit  $\text{Rang}(A) = n$ , folgt aus der QR-Zerlegung von  $A$ , dass

$$QA = R = \begin{pmatrix} \tilde{R} \\ \mathbf{0} \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix},$$

wobei die obere Dreiecksmatrix  $\tilde{R} \in \mathbb{R}^{n \times n}$  regulär ist.

- ▶ Multiplikation mit (einer orthogonalen Matrix)  $Q$  verändert nicht die euklidische Länge eines Vektors, d.h.

$$\|x\|_2 = \|Qx\|_2 \text{ für alle } x \in \mathbb{R}^n.$$

# Lösung über QR-Zerlegung

Zur Erinnerung:

- ▶ Für  $A \in \mathbb{R}^{m \times n}$ ,  $m > n$ , mit  $\text{Rang}(A) = n$ , folgt aus der QR-Zerlegung von  $A$ , dass

$$QA = R = \left( \begin{array}{c} \tilde{R} \\ \mathbf{0} \end{array} \right) \left. \begin{array}{l} \} n \\ \} m - n \end{array} \right.,$$

wobei die obere Dreiecksmatrix  $\tilde{R} \in \mathbb{R}^{n \times n}$  regulär ist.

- ▶ Multiplikation mit (einer orthogonalen Matrix)  $Q$  verändert nicht die euklidische Länge eines Vektors, d.h.

$$\|x\|_2 = \|Qx\|_2 \text{ für alle } x \in \mathbb{R}^n.$$

- ▶ Das lineare Ausgleichsproblem: bestimme  $x^* \in \mathbb{R}^n$ , so dass

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

# Lösung über QR-Zerlegung

Daraus folgt:

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

# Lösung über QR-Zerlegung

Daraus folgt:

$$\|A x^* - b\|_2 = \min_{x \in \mathbb{R}^n} \|A x - b\|_2 = \min_{x \in \mathbb{R}^n} \|Q(Ax - b)\|_2$$

# Lösung über QR-Zerlegung

Daraus folgt:

$$\begin{aligned}\|A x^* - b\|_2 &= \min_{x \in \mathbb{R}^n} \|A x - b\|_2 = \min_{x \in \mathbb{R}^n} \|Q(Ax - b)\|_2 \\ &= \min_{x \in \mathbb{R}^n} \|Q A x - Q b\|_2\end{aligned}$$

# Lösung über QR-Zerlegung

Daraus folgt:

$$\begin{aligned}\|A x^* - b\|_2 &= \min_{x \in \mathbb{R}^n} \|A x - b\|_2 = \min_{x \in \mathbb{R}^n} \|Q(Ax - b)\|_2 \\ &= \min_{x \in \mathbb{R}^n} \|Q A x - Q b\|_2 \\ &= \min_{x \in \mathbb{R}^n} \|R x - Q b\|_2.\end{aligned}$$

# Lösung über QR-Zerlegung

Daraus folgt:

$$\begin{aligned}\|A x^* - b\|_2 &= \min_{x \in \mathbb{R}^n} \|A x - b\|_2 = \min_{x \in \mathbb{R}^n} \|Q(Ax - b)\|_2 \\ &= \min_{x \in \mathbb{R}^n} \|Q A x - Q b\|_2 \\ &= \min_{x \in \mathbb{R}^n} \|R x - Q b\|_2.\end{aligned}$$

Mit  $R = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ ,  $Q b = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ , erhält man

# Lösung über QR-Zerlegung

Daraus folgt:

$$\begin{aligned}
 \|A x^* - b\|_2 &= \min_{x \in \mathbb{R}^n} \|A x - b\|_2 = \min_{x \in \mathbb{R}^n} \|Q(Ax - b)\|_2 \\
 &= \min_{x \in \mathbb{R}^n} \|Q A x - Q b\|_2 \\
 &= \min_{x \in \mathbb{R}^n} \|R x - Q b\|_2.
 \end{aligned}$$

Mit  $R = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ ,  $Q b = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ , erhält man

$$\|A x^* - b\|_2^2 = \min_{x \in \mathbb{R}^n} \left\| \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} x - \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \right\|_2^2$$

# Lösung über QR-Zerlegung

Daraus folgt:

$$\begin{aligned}
 \|A x^* - b\|_2 &= \min_{x \in \mathbb{R}^n} \|A x - b\|_2 = \min_{x \in \mathbb{R}^n} \|Q(Ax - b)\|_2 \\
 &= \min_{x \in \mathbb{R}^n} \|Q A x - Q b\|_2 \\
 &= \min_{x \in \mathbb{R}^n} \|R x - Q b\|_2.
 \end{aligned}$$

Mit  $R = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ ,  $Q b = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ , erhält man

$$\begin{aligned}
 \|A x^* - b\|_2^2 &= \min_{x \in \mathbb{R}^n} \left\| \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} x - \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \right\|_2^2 \\
 &= \min_{x \in \mathbb{R}^n} \left( \|\tilde{R} x - b_1\|_2^2 + \|b_2\|_2^2 \right)
 \end{aligned}$$

# Lösung über QR-Zerlegung

Daraus folgt:

$$\begin{aligned}
 \|A x^* - b\|_2 &= \min_{x \in \mathbb{R}^n} \|A x - b\|_2 = \min_{x \in \mathbb{R}^n} \|Q(Ax - b)\|_2 \\
 &= \min_{x \in \mathbb{R}^n} \|Q A x - Q b\|_2 \\
 &= \min_{x \in \mathbb{R}^n} \|R x - Q b\|_2.
 \end{aligned}$$

Mit  $R = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ ,  $Q b = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}$ , erhält man

$$\begin{aligned}
 \|A x^* - b\|_2^2 &= \min_{x \in \mathbb{R}^n} \left\| \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix} x - \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \right\|_2^2 \\
 &= \min_{x \in \mathbb{R}^n} \left( \|\tilde{R} x - b_1\|_2^2 + \|b_2\|_2^2 \right) \\
 &= \|b_2\|_2^2 \text{ für } \tilde{R} x = b_1
 \end{aligned}$$

# Lösung über QR-Zerlegung

## Satz 4.25

Seien  $A \in \mathbb{R}^{m \times n}$  mit  $\mathbf{Rang}(A) = n$  und  $b \in \mathbb{R}^m$ .

Sei  $Q \in \mathbb{R}^{m \times m}$  eine orthogonale Matrix und  $\tilde{R} \in \mathbb{R}^{n \times n}$  eine obere Dreiecksmatrix, so dass

$$Q A = R := \begin{pmatrix} \tilde{R} \\ \mathbf{0} \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix}.$$

Dann ist die Matrix  $\tilde{R}$  regulär. Schreibt man

$$Q b = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} \begin{matrix} \} n \\ \} m - n \end{matrix},$$

dann ist  $x^* = \tilde{R}^{-1} b_1$  die Lösung des gewöhnlichen linearen Ausgleichsproblems. Es gilt  $\|A x^* - b\|_2 = \|b_2\|_2$ .

# Lösung über QR-Zerlegung

Aus Satz 4.25 ergibt sich nun folgende Methode:

- ▶ Bestimme die  $QR$ -Zerlegung von  $A$

$$QA = \begin{pmatrix} \tilde{R} \\ \mathbf{0} \end{pmatrix} \quad (\tilde{R} \in \mathbb{R}^{n \times n}),$$

z.B. mittels Givens- oder Householder-Transformationen und berechne

$$Qb = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix}.$$

- ▶ Löse  $\tilde{R}x = b_1$  mittels Rückwärtseinsetzen.

# Lösung über QR-Zerlegung

Aus Satz 4.25 ergibt sich nun folgende Methode:

- ▶ Bestimme die  $QR$ -Zerlegung von  $A$

$$QA = \begin{pmatrix} \tilde{R} \\ \mathbf{0} \end{pmatrix} \quad (\tilde{R} \in \mathbb{R}^{n \times n}),$$

z.B. mittels Givens- oder Householder-Transformationen und berechne

$$Qb = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix}.$$

- ▶ Löse  $\tilde{R}x = b_1$  mittels Rückwärtseinsetzen.

Rechenaufwand (für Householder und  $m \gg n$ ): etwa  $2mn^2$  Flop.

## Beispiel 4.26

Gegeben seien

$$A = \begin{pmatrix} 3 & 7 \\ 0 & 12 \\ 4 & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 10 \\ 1 \\ 5 \end{pmatrix},$$

d.h.  $m = 3, n = 2$ .

Man bestimme die Lösung  $x^* \in \mathbb{R}^2$  des zugehörigen linearen Ausgleichsproblem über QR-Zerlegung mittels Givens-Rotation.

## Beispiel 4.26

Gegeben seien

$$A = \begin{pmatrix} 3 & 7 \\ 0 & 12 \\ 4 & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 10 \\ 1 \\ 5 \end{pmatrix},$$

d.h.  $m = 3, n = 2$ .

Man bestimme die Lösung  $x^* \in \mathbb{R}^2$  des zugehörigen linearen Ausgleichsproblem über QR-Zerlegung mittels Givens-Rotation.

Annullierung von  $a_{3,1}$ :

$$A^{(2)}$$

## Beispiel 4.26

Gegeben seien

$$A = \begin{pmatrix} 3 & 7 \\ 0 & 12 \\ 4 & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 10 \\ 1 \\ 5 \end{pmatrix},$$

d.h.  $m = 3, n = 2$ .

Man bestimme die Lösung  $x^* \in \mathbb{R}^2$  des zugehörigen linearen Ausgleichsproblem über QR-Zerlegung mittels Givens-Rotation.

Annullierung von  $a_{3,1}$ :

$$A^{(2)} = G_{1,3}A = \begin{pmatrix} 5 & 5 \\ 0 & 12 \\ 0 & -5 \end{pmatrix}, \quad b^{(2)} = G_{1,3}b$$

## Beispiel 4.26

Gegeben seien

$$A = \begin{pmatrix} 3 & 7 \\ 0 & 12 \\ 4 & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 10 \\ 1 \\ 5 \end{pmatrix},$$

d.h.  $m = 3, n = 2$ .

Man bestimme die Lösung  $x^* \in \mathbb{R}^2$  des zugehörigen linearen Ausgleichsproblem über QR-Zerlegung mittels Givens-Rotation.

Annullierung von  $a_{3,1}$ :

$$A^{(2)} = G_{1,3}A = \begin{pmatrix} 5 & 5 \\ 0 & 12 \\ 0 & -5 \end{pmatrix}, \quad b^{(2)} = G_{1,3}b = \begin{pmatrix} 10 \\ 1 \\ -5 \end{pmatrix}.$$

**Zur Erinnerung:** die Transformationen  $G_{1,3}A$  und  $G_{1,3}b$  werden in der Praxis ausgeführt, **ohne** dass  $G_{1,3}$  explizit berechnet wird.

## Beispiel 4.26

Annullierung von  $a_{3,2}^{(2)}$ :

$A^{(3)}$

## Beispiel 4.26

Annullierung von  $a_{3,2}^{(2)}$ :

$$A^{(3)} = G_{2,3}A^{(2)} = \begin{pmatrix} 5 & 5 \\ 0 & 13 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix}, b^{(3)}$$

## Beispiel 4.26

Annullierung von  $a_{3,2}^{(2)}$ :

$$A^{(3)} = G_{2,3}A^{(2)} = \begin{pmatrix} 5 & 5 \\ 0 & 13 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix}, \quad b^{(3)} = G_{2,3}b^{(2)} = \begin{pmatrix} 10 \\ \frac{37}{13} \\ -\frac{55}{13} \end{pmatrix}$$

## Beispiel 4.26

Annullierung von  $a_{3,2}^{(2)}$ :

$$A^{(3)} = G_{2,3}A^{(2)} = \begin{pmatrix} 5 & 5 \\ 0 & 13 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix}, \quad b^{(3)} = G_{2,3}b^{(2)} = \begin{pmatrix} 10 \\ \frac{37}{13} \\ -\frac{55}{13} \end{pmatrix}$$

Lösung von

$$\begin{pmatrix} 5 & 5 \\ 0 & 13 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 10 \\ \frac{37}{13} \end{pmatrix}$$

durch Rückwärtseinsetzen liefert

$$x^* = \left( \frac{301}{169}, \frac{37}{169} \right)^T.$$

## Beispiel 4.26

Annullierung von  $a_{3,2}^{(2)}$ :

$$A^{(3)} = G_{2,3}A^{(2)} = \begin{pmatrix} 5 & 5 \\ 0 & 13 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix}, \quad b^{(3)} = G_{2,3}b^{(2)} = \begin{pmatrix} 10 \\ \frac{37}{13} \\ -\frac{55}{13} \end{pmatrix}$$

Lösung von

$$\begin{pmatrix} 5 & 5 \\ 0 & 13 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 10 \\ \frac{37}{13} \end{pmatrix}$$

durch Rückwärtseinsetzen liefert

$$x^* = \left( \frac{301}{169}, \frac{37}{169} \right)^T.$$

Als Norm des Residiums ergibt sich:

## Beispiel 4.26

Annullierung von  $a_{3,2}^{(2)}$ :

$$A^{(3)} = G_{2,3}A^{(2)} = \begin{pmatrix} 5 & 5 \\ 0 & 13 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \tilde{R} \\ 0 \end{pmatrix}, \quad b^{(3)} = G_{2,3}b^{(2)} = \begin{pmatrix} 10 \\ \frac{37}{13} \\ -\frac{55}{13} \end{pmatrix}$$

Lösung von

$$\begin{pmatrix} 5 & 5 \\ 0 & 13 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 10 \\ \frac{37}{13} \end{pmatrix}$$

durch Rückwärtseinsetzen liefert

$$x^* = \left( \frac{301}{169}, \frac{37}{169} \right)^T.$$

Als Norm des Residiums ergibt sich:

$$\|b_2\|_2 = \frac{55}{13}.$$

## Lösung über QR-Zerlegung — Stabilität

## Beachte

- ▶ Wegen Satz 3.57 gilt

$$\kappa_2(A) = \kappa_2(\tilde{R}),$$

d.h. das **Quadrieren der Kondition**, das bei den Normalgleichungen auftritt, wird **vermieden**.

## Lösung über QR-Zerlegung — Stabilität

## Beachte

- ▶ Wegen Satz 3.57 gilt

$$\kappa_2(\mathbf{A}) = \kappa_2(\tilde{\mathbf{R}}),$$

d.h. das **Quadrieren der Kondition**, das bei den Normalgleichungen auftritt, wird **vermieden**.

- ▶ Die **Berechnung der QR-Zerlegung** über Givens- oder Householder-Transformationen ist ein **sehr stabiles Verfahren**, wobei die Fehlerverstärkung durch  $\kappa_2(\mathbf{A})$  (und nicht  $\kappa_2(\mathbf{A})^2$ ) beschrieben wird.

## Beispiel 4.28

Gegeben seien

$$A = \begin{pmatrix} \sqrt{3} & \sqrt{3} \\ \delta & 0 \\ 0 & \delta \end{pmatrix}, \quad b = \begin{pmatrix} 2\sqrt{3} \\ \delta \\ \delta \end{pmatrix}, \quad 0 < \delta \ll 1.$$

Bestimmen Sie die Lösung des linearen Ausgleichsproblems über die  $QR$ -Zerlegung und diskutieren Sie das Ergebnis.

## Beispiel 4.28

Gegeben seien

$$A = \begin{pmatrix} \sqrt{3} & \sqrt{3} \\ \delta & 0 \\ 0 & \delta \end{pmatrix}, \quad b = \begin{pmatrix} 2\sqrt{3} \\ \delta \\ \delta \end{pmatrix}, \quad 0 < \delta \ll 1.$$

Bestimmen Sie die Lösung des linearen Ausgleichsproblems über die  $QR$ -Zerlegung und diskutieren Sie das Ergebnis.

Auf einer Maschine mit  $\text{eps} \approx 10^{-16}$  erhält man

$$\delta = 10^{-4} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 2.2 \cdot 10^{-16},$$

$$\delta = 10^{-6} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 1.6 \cdot 10^{-16}.$$

## Beispiel 4.28

Gegeben seien

$$A = \begin{pmatrix} \sqrt{3} & \sqrt{3} \\ \delta & 0 \\ 0 & \delta \end{pmatrix}, \quad b = \begin{pmatrix} 2\sqrt{3} \\ \delta \\ \delta \end{pmatrix}, \quad 0 < \delta \ll 1.$$

Bestimmen Sie die Lösung des linearen Ausgleichsproblems über die  $QR$ -Zerlegung und diskutieren Sie das Ergebnis.

Auf einer Maschine mit  $\text{eps} \approx 10^{-16}$  erhält man

$$\delta = 10^{-4} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 2.2 \cdot 10^{-16},$$

$$\delta = 10^{-6} : \frac{\|\tilde{x} - x^*\|_2}{\|x^*\|_2} \approx 1.6 \cdot 10^{-16}.$$

Das Lösungsverfahren ist **sehr stabil** (vgl. Beispiel 4.24).

# Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$		
Stabilität		

# Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$	ca. $mn^2$	
Stabilität		

## Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$	ca. $mn^2$	ca. $2mn^2$ (Householder)
Stabilität		

# Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$	ca. $mn^2$	ca. $2mn^2$ (Householder)
Stabilität	instabil, wenn	

## Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$	ca. $mn^2$	ca. $2mn^2$ (Householder)
Stabilität	instabil, wenn $\kappa_2(A) \gg 1$ und $\theta \ll \frac{1}{2}\pi$	

## Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$	ca. $mn^2$	ca. $2mn^2$ (Householder)
Stabilität	instabil, wenn $\kappa_2(A) \gg 1$ und $\theta \ll \frac{1}{2}\pi$ stabil, wenn	

## Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$	ca. $mn^2$	ca. $2mn^2$ (Householder)
Stabilität	instabil, wenn $\kappa_2(A) \gg 1$ und $\theta \ll \frac{1}{2}\pi$  stabil, wenn $\kappa_2(A) \approx 1$	

## Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand $(m \gg n)$	ca. $mn^2$	ca. $2mn^2$ (Householder)
Stabilität	instabil, wenn $\kappa_2(A) \gg 1$ und $\theta \ll \frac{1}{2}\pi$ stabil, wenn $\kappa_2(A) \approx 1$	stabil

# Singulärwertzerlegung

## Satz 4.29

Zu jeder Matrix  $A \in \mathbb{R}^{m \times n}$  existieren orthogonale Matrizen  $U \in \mathbb{R}^{m \times m}$ ,  $V \in \mathbb{R}^{n \times n}$  und eine Diagonalmatrix

$$\Sigma := \text{diag}(\sigma_1, \dots, \sigma_p) \in \mathbb{R}^{m \times n}, \quad p = \min(m, n),$$

mit

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p \geq 0,$$

so dass

$$U^T A V = \Sigma.$$

## Singularwertzerlegung

## Satz 4.29

Zu jeder Matrix  $A \in \mathbb{R}^{m \times n}$  existieren orthogonale Matrizen  $U \in \mathbb{R}^{m \times m}$ ,  $V \in \mathbb{R}^{n \times n}$  und eine Diagonalmatrix

$$\Sigma := \text{diag}(\sigma_1, \dots, \sigma_p) \in \mathbb{R}^{m \times n}, \quad p = \min(m, n),$$

mit

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_p \geq 0,$$

so dass

$$U^T A V = \Sigma.$$

- ▶ Singulärwerte von  $A$  :  $\sigma_i, i = 1, \dots, p$
- ▶ Linkssingulärvektoren : Spalten von  $U = [u_1 \ u_2 \ \dots \ u_m]$
- ▶ Rechtssingulärvektoren: Spalten von  $V = [v_1 \ v_2 \ \dots \ v_n]$

## Pseudoinverse

Wir definieren  $A^\dagger \in \mathbb{R}^{n \times m}$  durch

$$A^\dagger := V \Sigma^\dagger U^T \quad \text{mit} \quad \Sigma^\dagger = \text{diag}(\sigma_1^{-1}, \dots, \sigma_r^{-1}, 0, \dots, 0) \in \mathbb{R}^{n \times m}$$

Diese Pseudoinverse ist eindeutig definiert.

## Pseudoinverse

Wir definieren  $A^\dagger \in \mathbb{R}^{n \times m}$  durch

$$A^\dagger := V \Sigma^\dagger U^T \quad \text{mit} \quad \Sigma^\dagger = \text{diag}(\sigma_1^{-1}, \dots, \sigma_r^{-1}, 0, \dots, 0) \in \mathbb{R}^{n \times m}$$

Diese Pseudoinverse ist eindeutig definiert.

Verallgemeinerung der **Konditionszahl**:

$$\kappa_2^*(A) := \|A\|_2 \|A^\dagger\|_2 = \frac{\sigma_1}{\sigma_r}$$

## Eigenschaften: Lemma 4.30

Es sei  $U^T A V = \Sigma$  eine Singulärwertzerlegung von  $A \in \mathbb{R}^{m \times n}$  mit Singulärwerten  $\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_p = 0$ ,  $p = \min\{m, n\}$ . Dann gilt:

- (i)  $Av_i = \sigma_i u_i, \quad A^T u_i = \sigma_i v_i, \quad i = 1, \dots, p.$
- (ii)  $\text{Rang}(A) = r.$

## Eigenschaften: Lemma 4.30

Es sei  $U^T A V = \Sigma$  eine Singularwertzerlegung von  $A \in \mathbb{R}^{m \times n}$  mit Singularwerten  $\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_p = 0$ ,  $p = \min\{m, n\}$ . Dann gilt:

- (i)  $Av_i = \sigma_i u_i$ ,  $A^T u_i = \sigma_i v_i$ ,  $i = 1, \dots, p$ .
- (ii)  $\text{Rang}(A) = r$ .
- (iii)  $\text{Bild}(A) = \text{Span}\{u_1, \dots, u_r\}$ ,  $\text{Kern}(A) = \text{Span}\{v_{r+1}, \dots, v_n\}$ .
- (iv)  $\|A\|_2 = \sigma_1$ .
- (v) Falls  $\text{Rang}(A) = n \leq m$ , so gilt

$$\kappa_2^*(A) = \kappa_2(A) = \frac{\max_{\|x\|_2=1} \|Ax\|_2}{\min_{\|x\|_2=1} \|Ax\|_2}$$

## Eigenschaften: Lemma 4.30

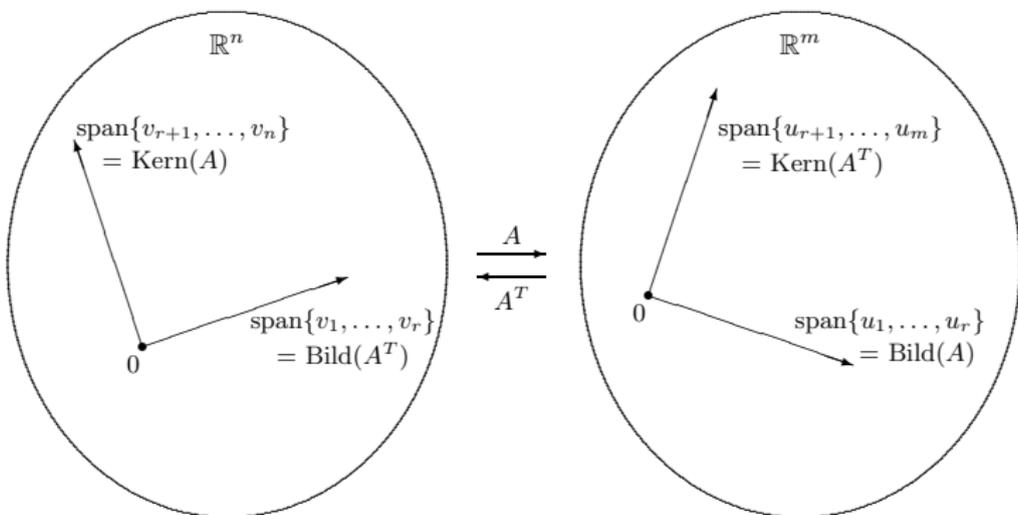
Es sei  $U^T A V = \Sigma$  eine Singularwertzerlegung von  $A \in \mathbb{R}^{m \times n}$  mit Singularwerten  $\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_p = 0$ ,  $p = \min\{m, n\}$ . Dann gilt:

- (i)  $Av_i = \sigma_i u_i$ ,  $A^T u_i = \sigma_i v_i$ ,  $i = 1, \dots, p$ .
- (ii)  $\text{Rang}(A) = r$ .
- (iii)  $\text{Bild}(A) = \text{Span}\{u_1, \dots, u_r\}$ ,  $\text{Kern}(A) = \text{Span}\{v_{r+1}, \dots, v_n\}$ .
- (iv)  $\|A\|_2 = \sigma_1$ .
- (v) Falls  $\text{Rang}(A) = n \leq m$ , so gilt

$$\kappa_2^*(A) = \kappa_2(A) = \frac{\max_{\|x\|_2=1} \|Ax\|_2}{\min_{\|x\|_2=1} \|Ax\|_2}$$

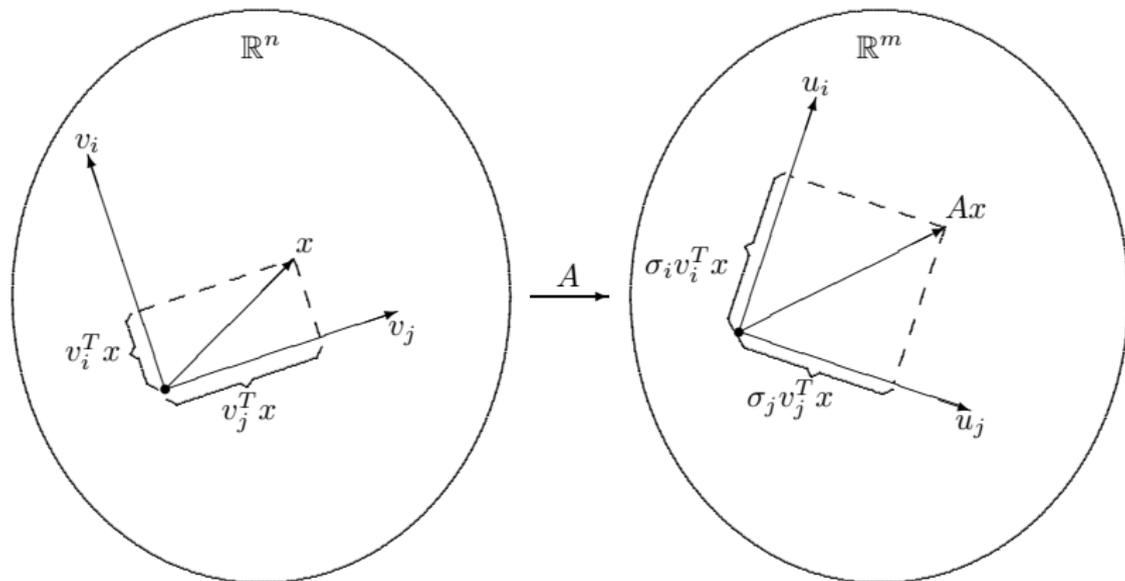
- (vi) Die strikt positiven Singularwerte sind gerade die Wurzeln der strikt positiven Eigenwerte von  $A^T A$ :

## Singulärwertzerlegung – Geometrische Interpretation



Orthogonale Basis in  $\mathbb{R}^n$  und in  $\mathbb{R}^m$ .

## Singulärwertzerlegung – Geometrische Interpretation



# Berechnung von Singulärwerten

## Lemma 4.32

Es sei  $A \in \mathbb{R}^{m \times n}$ . Es seien  $Q_1 \in \mathbb{R}^{m \times m}$ ,  $Q_2 \in \mathbb{R}^{n \times n}$  orthogonale Matrizen. Dann haben  $A$  und  $Q_1 A Q_2$  die gleichen Singulärwerte.

# Berechnung von Singulärwerten

## Lemma 4.32

Es sei  $A \in \mathbb{R}^{m \times n}$ . Es seien  $Q_1 \in \mathbb{R}^{m \times m}$ ,  $Q_2 \in \mathbb{R}^{n \times n}$  orthogonale Matrizen. Dann haben  $A$  und  $Q_1 A Q_2$  die gleichen Singulärwerte.

**Transformation auf Bidiagonalgestalt.** Beispiel einer  $5 \times 4$ -Matrix. Wir verwenden Householdertransformationen.

$$Q_1 A = \begin{pmatrix} * & * & * & * \\ 0 & * & * & * \\ 0 & * & * & * \\ 0 & * & * & * \\ 0 & * & * & * \end{pmatrix} = \begin{pmatrix} * & v_1^T \\ 0 & * \end{pmatrix}$$

# Transformation auf Bidiagonalgestalt

Es sei  $\tilde{Q}_1 \in \mathbb{R}^{3 \times 3}$  eine Householder-Transformation, so dass

$$\tilde{Q}_1 v_1 = \begin{pmatrix} * \\ 0 \\ 0 \end{pmatrix}, \quad \text{also } v_1^T \tilde{Q}_1^T = v_1^T \tilde{Q}_1 = (* \ 0 \ 0).$$

Mit der orthogonalen Matrix  $\hat{Q}_1 := \begin{pmatrix} 1 & \emptyset \\ \emptyset & \tilde{Q}_1 \end{pmatrix} \in \mathbb{R}^{4 \times 4}$  erhält man

$$Q_1 A \hat{Q}_1 = \begin{pmatrix} * & v_1^T \\ \emptyset & * \end{pmatrix} \begin{pmatrix} 1 & \emptyset \\ \emptyset & \tilde{Q}_1 \end{pmatrix} = \begin{pmatrix} * & * & 0 & 0 \\ 0 & * & * & * \\ 0 & * & * & * \\ 0 & * & * & * \end{pmatrix}.$$

# Transformation auf Bidiagonalgestalt

Mit geeigneten Householder-Transformationen können auf ähnliche Weise Nulleinträge in der 2. Spalte, 2. Zeile, 3. Spalte und 4. Spalte erzeugt werden:

$$\begin{aligned}
 Q_2 Q_1 A \hat{Q}_1 &= \begin{pmatrix} * & * & 0 & 0 \\ 0 & * & * & * \\ 0 & 0 & * & * \\ 0 & 0 & * & * \end{pmatrix} \rightsquigarrow Q_2 Q_1 A \hat{Q}_1 \hat{Q}_2 = \begin{pmatrix} * & * & 0 & 0 \\ 0 & * & * & 0 \\ 0 & 0 & * & * \\ 0 & 0 & * & * \end{pmatrix} \\
 &\rightsquigarrow Q_3 Q_2 Q_1 A \hat{Q}_1 \hat{Q}_2 = \begin{pmatrix} * & * & 0 & 0 \\ 0 & * & * & 0 \\ 0 & 0 & * & * \\ 0 & 0 & 0 & * \end{pmatrix} \\
 &\rightsquigarrow Q_4 Q_3 Q_2 Q_1 A \hat{Q}_1 \hat{Q}_2 = \begin{pmatrix} * & * & 0 & 0 \\ 0 & * & * & 0 \\ 0 & 0 & * & * \\ 0 & 0 & 0 & * \end{pmatrix}.
 \end{aligned}$$

# Transformation auf Bidiagonalgestalt

Mit dieser Technik kann man eine beliebige Matrix  $A \in \mathbb{R}^{m \times n}$  auf Bidiagonalgestalt transformieren. Für  $m \geq n$  ergibt sich

$$Q_{m-1} \dots Q_1 A \hat{Q}_1 \dots \hat{Q}_{n-2} = B = \begin{pmatrix} * & * & & & 0 \\ & * & * & & \\ & & & * & \\ & & & & \ddots \\ & & & & & \ddots \\ & & & & & & * \\ 0 & & & & & & * \\ & & & & & & * \\ & & & & & & 0 \end{pmatrix}$$

Die Matrix  $B$  hat **obere Bidiagonalgestalt**.

# Transformation auf Bidiagonalgestalt

Mit dieser Technik kann man eine beliebige Matrix  $A \in \mathbb{R}^{m \times n}$  auf Bidiagonalgestalt transformieren. Für  $m \geq n$  ergibt sich

$$Q_{m-1} \dots Q_1 A \hat{Q}_1 \dots \hat{Q}_{n-2} = B = \begin{pmatrix} * & * & & \emptyset \\ & * & * & \\ & & * & \vdots \\ & & & \ddots \\ \emptyset & & & & * \\ & & & & * \\ & & & & \emptyset \end{pmatrix}$$

Die Matrix  $B$  hat **obere Bidiagonalgestalt**.

- ▶  $A$  und  $B$  haben die gleichen Singulärwerte.
- ▶ Die Singulärwerte von  $B$  sind die Wurzeln der Eigenwerte der **symmetrischen Tridiagonalmatrix**  $B^T B$ .
- ▶ Eigenwerte einer symmetrischen Tridiagonalmatrix können sehr effizient berechnet werden.

# Matrixzerlegungen

Zerlegungen einer Matrix  $A \in \mathbb{R}^{m \times n}$

Zerlegung	Annahmen	Methoden	Aufwand (Flop)
<b>LR</b>	$m = n$ , (regulär)	Gauss-Elim.	$\frac{2}{3}n^3$
Cholesky	$m = n$ , s.p.d.	Cholesky	$\frac{1}{3}n^3$
Eigenvektor	$m = n$ , symm.	<b>QR</b> -Alg.	$\mathcal{O}(n^3)$ (iterativ)
Schur	$m = n$	<b>QR</b> -Alg.	$\mathcal{O}(n^3)$ (iterativ)
<b>QR</b>	–	HH, Givens	$2mn^2, 3mn^2$ ( $m \gg n$ )
SVD	–	<b>QR</b> -Alg.	$\mathcal{O}(n^3)$ (iterativ)

Eigenvektorzerlegung, Schur-Zerlegung: Kapitel 7.

# Allgemeines lineares Ausgleichsproblem

## Allgemeines lineares Ausgleichsproblem (Aufgabe 4.4)

Zu gegebenem  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^n$  bestimme  $x^* \in \mathbb{R}^n$  mit minimaler Euklidischer Norm, so dass

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

# Allgemeines lineares Ausgleichsproblem

## Allgemeines lineares Ausgleichsproblem (Aufgabe 4.4)

Zu gegebenem  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^n$  bestimme  $x^* \in \mathbb{R}^n$  mit minimaler Euklidischer Norm, so dass

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

Sei  $U := \text{Bild}(A)$ . Betrachte die Aufgabe

Gesucht  $x^* \in \mathbb{R}^n$ , so dass  $Ax^* = P_U(b)$  und  $x^* \perp \text{Kern}(A)$  (1)

# Allgemeines lineares Ausgleichsproblem

## Allgemeines lineares Ausgleichsproblem (Aufgabe 4.4)

Zu gegebenem  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^n$  bestimme  $x^* \in \mathbb{R}^n$  mit minimaler Euklidischer Norm, so dass

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

Sei  $U := \text{Bild}(A)$ . Betrachte die Aufgabe

Gesucht  $x^* \in \mathbb{R}^n$ , so dass  $Ax^* = P_U(b)$  und  $x^* \perp \text{Kern}(A)$  (1)

### Satz 4.35

Aufgabe 4.4 ist äquivalent zur Aufgabe (1). Die eindeutige Lösung ist

$$x^* = \sum_{j=1}^r \sigma_j^{-1} (u_j^T b) v_j = A^\dagger b$$

# Regularisierung

Wir betrachten das **allgemeine lineare Ausgleichsproblem** mit  $\kappa_2^*(A) = \frac{\sigma_1}{\sigma_r} \gg 1$ .

Regularisierungsmethoden:

das ursprüngliche (sehr schlecht konditionierte) Problem **durch ein approximatives, aber besser konditioniertes Problem** ersetzt.

# Regularisierung

Wir betrachten das **allgemeine lineare Ausgleichsproblem** mit  $\kappa_2^*(A) = \frac{\sigma_1}{\sigma_r} \gg 1$ .

Regularisierungsmethoden:

das ursprüngliche (sehr schlecht konditionierte) Problem **durch ein approximatives, aber besser konditioniertes Problem** ersetzt.

Filterfunktion:

$$g_\alpha(z) := \begin{cases} 0 & \text{for } z \in [0, \alpha] \\ 1 & \text{for } z \in (\alpha, \infty). \end{cases}$$

Hierbei ist  $\alpha > 0$  ein noch zu wählender **Regularisierungsparameter**.

## Abgebrochenene Singularwertzerlegung (TSVD)

$$\tilde{x}_\alpha = R_\alpha \tilde{b} := \sum_{j=1}^r g_\alpha(\sigma_j) \sigma_j^{-1} (u_j^T \tilde{b}) v_j$$

## Beispiel 4.43: ein Entfaltungsproblem

Vereinfachtes eindimensionales Problem: gesucht  $g : [0, 1] \rightarrow \mathbb{R}$ , so dass

$$\int_0^1 e^{-(t-z)^2} g(z) dz = b(t) \quad \text{für alle } t \in [0, 1].$$

## Beispiel 4.43: ein Entfaltungsproblem

Vereinfachtes eindimensionales Problem: gesucht  $g : [0, 1] \rightarrow \mathbb{R}$ , so dass

$$\int_0^1 e^{-(t-z)^2} g(z) dz = b(t) \quad \text{für alle } t \in [0, 1].$$

Diskretisierung des Integrals:  $z_j = (j - \frac{1}{2})h$ ,  $j = 1, \dots, n$ ,  $h = \frac{1}{n}$ ,

$$h \sum_{j=1}^n e^{-(t-z_j)^2} g_j = b(t) \quad t \in [0, 1],$$

mit  $g_j \approx g(z_j) =: x_j$ ,  $j = 1, \dots, n$ .

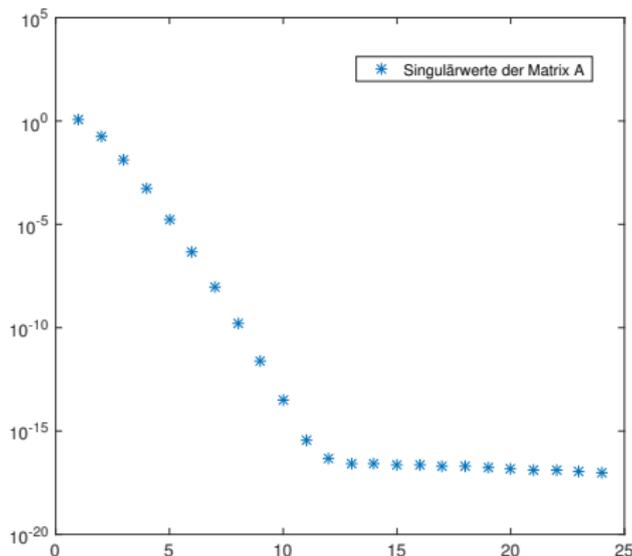
Gitter  $t_i = (i - 1)\tilde{h}$ ,  $i = 1, \dots, m$ ,  $\tilde{h} = \frac{1}{m-1}$ , mit  $m > n$ .

Lineares Ausgleichsproblem

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2, \quad \text{mit } a_{i,j} := h e^{-(t_i - z_j)^2}, \quad 1 \leq i \leq m, \quad 1 \leq j \leq n$$

# Diskretisiertes Entfaltungungsproblem

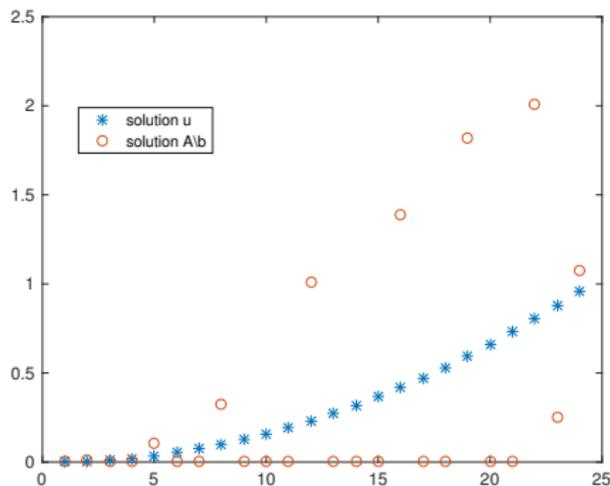
Das diskrete Problem mit  $n = 24$ ,  $m = 50$ .



Das lineare Ausgleichsproblem ist **extrem schlecht konditioniert**.

# Diskretisiertes Entfaltungungsproblem

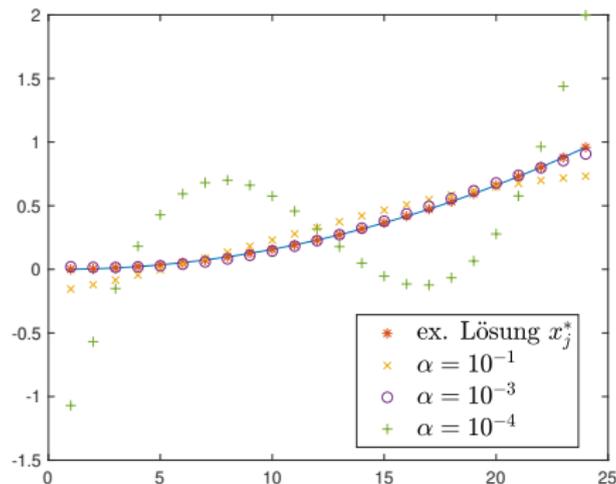
Wir wählen  $g(t) = t^2$  und entsprechend  $x_j^* = z_j^2$  ( $n = 24$ ,  $m = 50$ ).  
Das Ausgleichsproblem mit  $\mathbf{b} := \mathbf{A}\mathbf{x}^*$ , gelöst in Matlab:



Berechnete Lösung (nur Rundungsfehler!) weit von der Exakten entfernt.

# Diskretisiertes Entfaltungungsproblem mit TSVD

Wir verwenden TSVD mit unterschiedlichen Parameterwerten  $\alpha$ .



Eine gute Genauigkeit für geeignet gewähltes  $\alpha$ .

# Analyse TSVD-Regularisierung

Sei

$$A^{\dagger\dagger}b := \sum_{j=1}^r \sigma_j^{-2} (u_j^T b) v_j$$

(In Anwendungen hängt diese Größe oft mit der Glattheit der exakten Daten  $b$  zusammen).

## Satz 4.45

Für die TSVD-Annäherung  $\tilde{x}_\alpha$  gilt:

$$\|\tilde{x}_\alpha - x^*\|_2 \leq \min \left\{ \frac{1}{\sigma_r}, \frac{1}{\alpha} \right\} \|\Delta b\|_2 + \alpha \|A^{\dagger\dagger}b\|_2.$$

# Analyse TSVD-Regularisierung

Sei

$$A^{\dagger\dagger}b := \sum_{j=1}^r \sigma_j^{-2} (u_j^T b) v_j$$

(In Anwendungen hängt diese Größe oft mit der Glattheit der exakten Daten  $b$  zusammen).

## Satz 4.45

Für die TSVD-Annäherung  $\tilde{x}_\alpha$  gilt:

$$\|\tilde{x}_\alpha - x^*\|_2 \leq \min \left\{ \frac{1}{\sigma_r}, \frac{1}{\alpha} \right\} \|\Delta b\|_2 + \alpha \|A^{\dagger\dagger}b\|_2.$$

Man soll  $\alpha$  so wählen dass ein guter Kompromiss zwischen Datenfehler und Regularisierungsfehler erreicht wird.

Dazu sind [Parameterwahlverfahren](#) entwickelt worden.

# Tikhonov Regularisierung

Man verwendet die Filterfunktion

$$\hat{g}_\alpha(z) := \frac{z^2}{z^2 + \alpha^2}, \quad \alpha > 0.$$

Tikhonov-Regularisierung:

$$\tilde{x}_\alpha = R_\alpha \tilde{b} := \sum_{j=1}^r \hat{g}_\alpha(\sigma_j) \sigma_j^{-1} (u_j^T \tilde{b}) v_j$$

Sehr leistungsfähige Methode, insbesondere weil die [Bestimmung der SVD](#) vermieden werden kann.

# Tikhonov Regularisierung

Man verwendet die Filterfunktion

$$\hat{g}_\alpha(z) := \frac{z^2}{z^2 + \alpha^2}, \quad \alpha > 0.$$

Tikhonov-Regularisierung:

$$\tilde{x}_\alpha = R_\alpha \tilde{b} := \sum_{j=1}^r \hat{g}_\alpha(\sigma_j) \sigma_j^{-1} (u_j^T \tilde{b}) v_j$$

Sehr leistungsfähige Methode, insbesondere weil die [Bestimmung der SVD vermieden werden kann](#).

Die Tikhonov-Regularisierung  $\tilde{x}_\alpha$  ist die Lösung des gewöhnlichen linearen Ausgleichsproblems

$$\min_x \left\| \begin{pmatrix} A \\ \alpha I \end{pmatrix} x - \begin{pmatrix} \tilde{b} \\ \emptyset \end{pmatrix} \right\|_2 = \left\| \begin{pmatrix} A \\ \alpha I \end{pmatrix} \tilde{x}_\alpha - \begin{pmatrix} \tilde{b} \\ \emptyset \end{pmatrix} \right\|_2.$$

# Niedrigrangapproximation

Für  $A \in \mathbb{R}^{m \times n}$  mit  $r = \mathbf{Rang}(A) \ll \min\{m, n\}$  ist eine erhebliche **Komplexitätsreduktion** möglich.

Notationen:  $U_r, V_r$ , Matrizen mit nur den ersten  $r$  Spalten von  $U, V$ , und  $\Sigma_r = \text{diag}(\sigma_1, \dots, \sigma_r) \in \mathbb{R}^{r \times r}$ .

**Speicherbedarf** nur  $mr + nr + r \approx r(m + n)$ , und

$$A = U\Sigma V^T = U_r \Sigma_r V_r^T.$$

# Niedrigrangapproximation

Für  $A \in \mathbb{R}^{m \times n}$  mit  $r = \mathbf{Rang}(A) \ll \min\{m, n\}$  ist eine erhebliche **Komplexitätsreduktion** möglich.

Notationen:  $U_r$ ,  $V_r$ , Matrizen mit nur den ersten  $r$  Spalten von  $U$ ,  $V$ , und  $\Sigma_r = \text{diag}(\sigma_1, \dots, \sigma_r) \in \mathbb{R}^{r \times r}$ .

**Speicherbedarf** nur  $mr + nr + r \approx r(m + n)$ , und

$$A = U\Sigma V^T = U_r \Sigma_r V_r^T.$$

**Matrix-Vektor Produkt**

$$Ax = U_r \Sigma_r V_r^T x = \sum_{i=1}^r \sigma_i (v_i^T x) u_i,$$

mit Aufwand nur  $2r(m + n)$  Flop.

# Niedrigrangapproximation

Wie gut ist eine Matrix  $A \in \mathbb{R}^{m \times n}$  mit einer Matrix niedrigen Ranges approximierbar?

Sei

$$\mathcal{R}_k := \{ B \in \mathbb{R}^{m \times n} \mid \text{Rang}(B) \leq k \}, \quad 0 \leq k \leq p = \min\{m, n\}.$$

Es gilt  $\{0\} =: \mathcal{R}_0 \subsetneq \mathcal{R}_1 \subsetneq \dots \subsetneq \mathcal{R}_p = \mathbb{R}^{m \times n}$ .

# Niedrigrangapproximation

Wie gut ist eine Matrix  $A \in \mathbb{R}^{m \times n}$  mit einer Matrix niedrigen Ranges approximierbar?

Sei

$$\mathcal{R}_k := \{ B \in \mathbb{R}^{m \times n} \mid \text{Rang}(B) \leq k \}, \quad 0 \leq k \leq p = \min\{m, n\}.$$

Es gilt  $\{0\} =: \mathcal{R}_0 \subsetneq \mathcal{R}_1 \subsetneq \dots \subsetneq \mathcal{R}_p = \mathbb{R}^{m \times n}$ .

## Satz 4.47

Es sei  $U^T A V = \Sigma$  eine Singularwertzerlegung von  $A \in \mathbb{R}^{m \times n}$  mit Singularwerten  $\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_p = 0$ ,  $p = \min\{m, n\}$ . Für  $0 \leq k \leq p - 1$  gilt:

$$\min\{ \|A - B\|_2 \mid B \in \mathcal{R}_k \} = \|A - A_k\|_2 = \sigma_{k+1},$$

mit  $A_0 := 0$ ,  $A_k = U_k \Sigma_k V_k$  für  $k \geq 1$ .

# Niedrigrangapproximation

Sei 
$$K_\gamma(A) := \{ B \in \mathbb{R}^{m \times n} \mid \|A - B\|_2 \leq \gamma \}.$$

Frage: Was ist der minimale Rang der Matrizen in  $K_\gamma(A)$ ?

# Niedrigrangapproximation

Sei 
$$K_\gamma(A) := \{ B \in \mathbb{R}^{m \times n} \mid \|A - B\|_2 \leq \gamma \}.$$

Frage: Was ist der minimale Rang der Matrizen in  $K_\gamma(A)$ ?

## Lemma 4.50

Es sei  $\sigma_{p+1} := 0$ . Dann gilt:

$$\min\{ \text{Rang}(B) \mid B \in K_\gamma(A) \} = \min\{ 0 \leq k \leq p \mid \sigma_{k+1} \leq \gamma \}.$$

# Niedrigrangapproximation

Sei  $K_\gamma(A) := \{B \in \mathbb{R}^{m \times n} \mid \|A - B\|_2 \leq \gamma\}$ .

Frage: Was ist der minimale Rang der Matrizen in  $K_\gamma(A)$ ?

## Lemma 4.50

Es sei  $\sigma_{p+1} := 0$ . Dann gilt:

$$\min\{\text{Rang}(B) \mid B \in K_\gamma(A)\} = \min\{0 \leq k \leq p \mid \sigma_{k+1} \leq \gamma\}.$$

## Kondition der Singularwertbestimmung (Folgerung 4.51)

Für  $A$  und  $\tilde{A} = A + \Delta A \in \mathbb{R}^{m \times n}$  mit Singularwerten  $\sigma_1 \geq \dots \geq \sigma_p$  bzw.  $\tilde{\sigma}_1 \geq \dots \geq \tilde{\sigma}_p$ ,  $p = \min\{m, n\}$ , gilt

$$\frac{|\sigma_k - \tilde{\sigma}_k|}{|\sigma_1|} \leq \frac{\|\Delta A\|_2}{\|A\|_2}, \quad \text{für } k = 1, \dots, p.$$

# Numerischer Rang

**Problem:** Rundungsfehler aufgrund Maschinengenauigkeit

$$A \rightarrow \tilde{A}, \quad \sigma_i \rightarrow \tilde{\sigma}_i,$$

$\Rightarrow \mathbf{Rang}(\tilde{A})$  häufig  $> r$ , Abfrage " $\sigma_k = 0$ " nicht sinnvoll.

# Numerischer Rang

**Problem:** Rundungsfehler aufgrund Maschinengenauigkeit

$$A \rightarrow \tilde{A}, \quad \sigma_i \rightarrow \tilde{\sigma}_i,$$

$\Rightarrow \text{Rang}(\tilde{A})$  häufig  $> r$ , Abfrage " $\sigma_k = 0$ " nicht sinnvoll.

Für  $\tilde{A} = (\tilde{a}_{i,j}) = \text{fl}(A) \in \mathbb{R}^{m \times n}$  gilt

$$\|\tilde{A} - A\|_2 \leq \tilde{\sigma}_1 \sqrt{mn} \text{ eps} =: \delta_{\text{eps}}.$$

# Numerischer Rang

**Problem:** Rundungsfehler aufgrund Maschinengenauigkeit

$$A \rightarrow \tilde{A}, \quad \sigma_i \rightarrow \tilde{\sigma}_i,$$

$\Rightarrow \text{Rang}(\tilde{A})$  häufig  $> r$ , Abfrage " $\sigma_k = 0$ " nicht sinnvoll.

Für  $\tilde{A} = (\tilde{a}_{i,j}) = \text{fl}(A) \in \mathbb{R}^{m \times n}$  gilt

$$\|\tilde{A} - A\|_2 \leq \tilde{\sigma}_1 \sqrt{mn} \text{eps} =: \delta_{\text{eps}}.$$

Matrizen, die im Hinblick auf Rundungsfehler nicht von  $\tilde{A}$  unterscheidbar sind:

$$K_{\delta_{\text{eps}}}(\tilde{A}) := \{ B \in \mathbb{R}^{m \times n} \mid \|\tilde{A} - B\|_2 \leq \delta_{\text{eps}} \}.$$

# Numerischer Rang

## Definition: Numerischer Rang

Der **numerische Rang** der Matrix  $\tilde{A} \in \mathbb{R}^{m \times n}$  ist definiert als

$$\mathbf{Rang}_{\text{num}}(\tilde{A}) := \min\{ \mathbf{Rang}(B) \mid B \in K_{\delta_{\text{eps}}}(\tilde{A}) \}.$$

# Numerischer Rang

## Definition: Numerischer Rang

Der **numerische Rang** der Matrix  $\tilde{A} \in \mathbb{R}^{m \times n}$  ist definiert als

$$\mathbf{Rang}_{\text{num}}(\tilde{A}) := \min\{ \mathbf{Rang}(B) \mid B \in K_{\delta_{\text{eps}}}(\tilde{A}) \}.$$

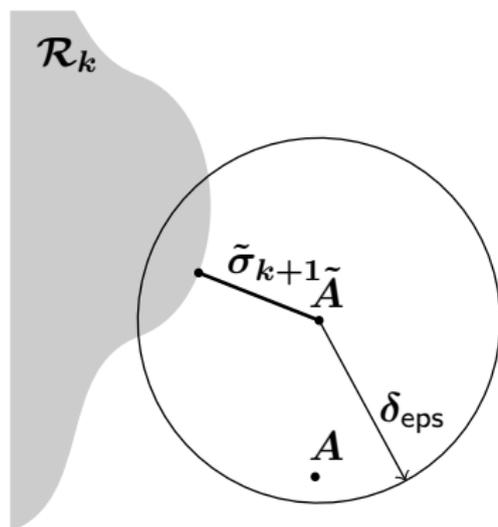
Diesen Rang kann man bestimmen:

## Folgerung 4.52

Es sei  $\tilde{\sigma}_{p+1} := 0$ . Es gilt:

$$\mathbf{Rang}_{\text{num}}(\tilde{A}) = \min\{ 0 \leq k \leq p \mid \tilde{\sigma}_{k+1} \leq \tilde{\sigma}_1 \sqrt{mn} \text{ eps} \}$$

# Numerischer Rang



Numerischer Rang: minimales  $k$  so dass  $\tilde{\sigma}_{k+1} \leq \delta_{\text{eps}}$

## Beispiel 4.54

$$A_1 = \begin{pmatrix} \frac{1}{10} & \frac{1}{3} & 0 \\ \frac{2}{10} & \frac{2}{3} & 3 \\ \frac{3}{10} & \frac{3}{3} & 0 \\ \frac{4}{10} & \frac{4}{3} & 7 \end{pmatrix}, \quad A_2 = A_1 + 10 \operatorname{eps} \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \end{pmatrix},$$

mit  $\mathbf{Rang}(A_1) = 2$ ,  $\mathbf{Rang}(A_2) = 3$ . Auf einem Rechner ( $\operatorname{eps} \approx 2 \cdot 10^{-16}$ ):  $\tilde{A}_1 = \operatorname{fl}(A_1)$ , bzw.  $\tilde{A}_2 = \operatorname{fl}(A_2)$ .

## Beispiel 4.54

$$\mathbf{A}_1 = \begin{pmatrix} \frac{1}{10} & \frac{1}{3} & 0 \\ \frac{2}{10} & \frac{2}{3} & 3 \\ \frac{3}{10} & \frac{3}{3} & 0 \\ \frac{4}{10} & \frac{4}{3} & 7 \end{pmatrix}, \quad \mathbf{A}_2 = \mathbf{A}_1 + 10 \text{ eps} \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 \end{pmatrix},$$

mit  $\text{Rang}(\mathbf{A}_1) = 2$ ,  $\text{Rang}(\mathbf{A}_2) = 3$ . Auf einem Rechner (eps  $\approx 2 \cdot 10^{-16}$ ):  $\tilde{\mathbf{A}}_1 = \text{fl}(\mathbf{A}_1)$ , bzw.  $\tilde{\mathbf{A}}_2 = \text{fl}(\mathbf{A}_2)$ .

Die (in Matlab) berechneten Singulärwerte dieser Matrizen sind

$$\tilde{\mathbf{A}}_1 : 7.776, 1.082, 1.731 \cdot 10^{-16}, \quad \tilde{\mathbf{A}}_2 : 7.776, 1.082, 2.001 \cdot 10^{-15}$$

In beiden Fällen sind alle berechnete Singulärwerte strikt positiv, jedoch gilt

$$\text{Rang}_{\text{num}}(\tilde{\mathbf{A}}_1) = \text{Rang}_{\text{num}}(\tilde{\mathbf{A}}_2) = 2.$$