

# Numerisches Rechnen

## Lineare Ausgleichsrechnung

M. Grepl

J. Berger & R. O'Connor

Institut für Geometrie und Praktische Mathematik  
RWTH Aachen

Wintersemester 2015/16

# Vorlesungsinhalt

1. Fehleranalyse: Kondition, Rundungsfehler, Stabilität
  - a)  $y = f(x)$ , Eingabefehler  $\Delta x \rightarrow$  Ausgabefehler  $\Delta y$
  - b) Fehler aufgrund Gleitpunktdarstellung
  - c) Fehler (durch Algorithmus)  $\approx$  Fehler (durch Kondition)
2. Lineare Gleichungssysteme, direkte Lösungsverfahren  
geg.:  $A \in \mathbb{R}^{n \times n}$ ,  $b \in \mathbb{R}^n$ ;  
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$
3. Lineare Ausgleichsrechnung  
geg.:  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ ,  $m > n$ ;  
ges.:  $x^* \in \mathbb{R}^n$ , so dass  $x^* = \arg \min_{x \in \mathbb{R}^n} \|Ax - b\|_2$

# Übersicht

Themen: Dahmen & Reusken Kap. 4.1-4.4, 4.7

- ▶ Das lineare Ausgleichsproblem
- ▶ Singulärwertzerlegung (SVD)

Was Sie mitnehmen sollten:

- ▶ Was ist ein lineares Ausgleichsproblem
- ▶ Wie ist das lineare Ausgleichsproblem konditioniert
- ▶ Welche Lösungsverfahren gibt es und wie stabil sind diese
- ▶ Definition, Eigenschaften und Anwendungen der SVD

# 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.:  $A \in \mathbb{R}^{m \times n}$ ,  $b \in \mathbb{R}^m$ ,  $m > n$ ;  
ges.:  $x \in \mathbb{R}^n$ , so dass  $Ax = b$  ?  
 $\Rightarrow$  im Allgemeinen nicht lösbar, d.h.  $Ax \neq b$  !
- ▶ Lösung: Bestimme  $x^* \in \mathbb{R}^n$ , so dass

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

## Beispiel 4.1

- ▶ Ohmsches Gesetz:  $U = RI$
- ▶ 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.  
 $U_i \neq RI_i$ , für fast alle  $i = 1, \dots, m$ .



## Beispiel 4.1

Vorgehen:

D: MV

- ▶ Fehler in Messung  $i$  (Residuum)

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

- ▶ Ein Maß für den Fehler: Summe der Fehlerquadrate

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

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

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

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

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

# Polynomial Data-Fitting

Anstelle Ursprungsgerade, betrachte allgemeineren Fall ...

Gegeben:

D:ML

- ▶  $m$  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 ...

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

## Aufgabe

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

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

oder (gleichbedeutend)

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

gilt.



# Machine Vision – Optical Flow

- ▶ Definition: **optical flow is the *apparent* motion of brightness patterns in the image.**
- ▶ Eventuell nicht identisch mit dem (wahren) Geschwindigkeitsfeld im Bild
  - ▶ aperture problem
  - ▶ rotierende Kugel bei konstanter Beleuchtung vs. ruhende Kugel bei rotierender Beleuchtung
- ▶ Anwendungen
  - ▶ Optische Navigation von Robotern und Fahrzeugen
  - ▶ Optische Maus
  - ▶ Segmentierung (Erkennung von bewegten Objekten)
  - ▶ ...

# Optical Flow Estimation

## Aufgabe

- ▶ Bestimme das Geschwindigkeitsfeld  $u(x, y)$  und  $v(x, y)$  aus zwei aufeinanderfolgenden Bildern,  $I(x, y)$ , eines Videos.

## Annahmen

- ▶ **Brightness Constancy**  
Helligkeit des gleichen Objekts/Punkts bleibt konstant in jedem Bild
- ▶ **Temporal Persistence**  
Geringfügige Bewegungen von einem Bild zum nächsten Bild
- ▶ **Spatial Coherence**  
Benachbarte Pixel im Bild haben die gleiche Geschwindigkeit (gehören zum gleichen Objekt)

# Optical Flow Estimation

## Brightness Constancy Equation

$$I(x, y, t) = I(x + \delta x, y + \delta y, t + \delta t).$$

Aus Taylor-Entwicklung der rechten Seite ergibt sich

$$I_x u + I_y v + I_t = 0$$

mit optischem Fluss  $(u, v)$  und partiellen Ableitungen  $I_x = \frac{\partial I}{\partial x}$ ,  $I_y = \frac{\partial I}{\partial y}$  und  $I_t = \frac{\partial I}{\partial t}$ .

**Problem:** eine Gleichung, zwei Unbekannte  
 $\Rightarrow$  Lösung nicht eindeutig

**Aperture Problem:** Komponente des optischen Flusses rechtwinklig zum Gradienten  $\nabla I$  ist unbekannt (vgl. "Barberpole Illusion").

# Optical Flow Estimation

## Spatial Coherence Constraint<sup>†</sup>

- ▶ Benachbarte Pixel haben gleichen optischen Fluss  $(u, v)$
- ▶ Betrachte Nachbarn in einem  $5 \times 5$  Fenster um das Pixel herum, d.h. 25 Pixel  $p_1, \dots, p_{25}$
- ▶ Wir erhalten 25 Gleichungen pro Pixel

$$\begin{bmatrix} I_x(p_1) & I_y(p_1) \\ I_x(p_2) & I_y(p_2) \\ \vdots & \vdots \\ I_x(p_{25}) & I_y(p_{25}) \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = - \begin{bmatrix} I_t(p_1) \\ I_t(p_2) \\ \vdots \\ I_t(p_{25}) \end{bmatrix}$$

---

<sup>†</sup>B.D. Lucas and T. Kanade (1981), An iterative image registration technique with an application to stereo vision. Proceedings of Imaging Understanding Workshop, pages 121–130.

# Optical Flow Estimation

- ▶ Lineares Ausgleichsproblem mit

$$A = \begin{bmatrix} I_x(p_1) & I_y(p_1) \\ I_x(p_2) & I_y(p_2) \\ \vdots & \vdots \\ I_x(p_{25}) & I_y(p_{25}) \end{bmatrix}, \quad x = \begin{bmatrix} u \\ v \end{bmatrix}, \quad b = - \begin{bmatrix} I_t(p_1) \\ I_t(p_2) \\ \vdots \\ I_t(p_{25}) \end{bmatrix}$$

- ▶ Lösung

$$(A^T A) x = A^T b$$

oder

$$\begin{bmatrix} \sum I_x I_x & \sum I_x I_y \\ \sum I_x I_y & \sum I_y I_y \end{bmatrix} \begin{bmatrix} u \\ v \end{bmatrix} = - \begin{bmatrix} \sum I_x I_t \\ \sum I_y I_t \end{bmatrix}$$

(Summation über alle Pixel im  $5 \times 5$  Fenster)

- ▶ Matlab Demo D:ML

# Definition

## Lineares Ausgleichsproblem

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

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

gilt.

oder:

## Lineares Ausgleichsproblem

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

$$x^* = \arg \min_{x \in \mathbb{R}^n} \|A x - b\|_2^2.$$

# Definition

Warum 2-Norm?

- ▶  $\|Ax - b\|_2^2$  ist differenzierbar und Ableitung ist linear
- ▶ Euklidische Norm bleibt bei orthogonalen Transformationen erhalten, d.h. für jede orthogonale Matrix  $Q \in \mathbb{R}^{m \times m}$  ist

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

äquivalent zu

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

Auch möglich:

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_1 \text{ oder } \min_{x \in \mathbb{R}^n} \|Ax - b\|_\infty$$


⇒ führt auf lineares Optimierungsproblem

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

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

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

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

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



# 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.

N4.1 & N4.2

## Bemerkung

- ▶ Für  $A \in \mathbb{R}^{m \times n}$  ist die Matrix  $A^T A \in \mathbb{R}^{n \times n}$  stets quadratisch.
- ▶ Falls  $A \in \mathbb{R}^{m \times n}$  vollen (Spalten-)Rang  $n$  hat, so ist die Matrix  $A^T A \in \mathbb{R}^{n \times n}$  symmetrisch positiv definit.

## Annahme:

- ▶ Wir beschranken uns hier auf den Fall, dass  $A$  vollen Spaltenrang hat:  $\text{Rang}(A) = n$  (Fall  $\text{Rang}(A) < n$ , siehe SVD).

# 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.

N4.1 & N4.2

## Satz 4.5

$x^* \in \mathbb{R}^n$  ist genau dann Lösung des linearen Ausgleichsproblems, wenn  $x^*$  Lösung der Normalgleichung

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

ist. Das System der Normalgleichung hat stets mindestens eine Lösung. Sie ist genau dann *eindeutig*, wenn  $\text{Rang}(A) = n$  gilt.

## Beispiel 4.3

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. Wie lautet das zugehörige lineare Ausgleichsproblem?

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

wobei

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

# Kondition des linearen Ausgleichsproblems

## Satz 4.7

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

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

## Satz 4.9.

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

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

Wobei hier  $\kappa_2(A) := \max_{\|x\|=1} \|A x\|_2 / \min_{\|x\|=1} \|A x\|_2$ .

N4.3

## Beispiel 4.8.

Gegeben seien

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

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.

Die Lösung der Normalgleichung liefert

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

sowie für die gestörte rechte Seite

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

## Beispiel 4.8.

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 4.7 erhält man aus

$$\kappa_2(A) \approx 2.62$$

und

$$\cos \Theta = \frac{\|A x^*\|_2}{\|b\|_2} = 0.01$$

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.



# 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

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

von  $A^T A$

- ▶ Löse

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

durch Vorwärts- bzw. Rückwärtseinsetzen.

# Lösung über Normalgleichungen — Nachteile

- ▶ Die Berechnung von  $A^T A$  ist für große  $m$  aufwendig und birgt die Gefahr von Genauigkeitsverlust durch Auslöschungseffekte. Die Einträge von  $A^T A$  sind also mit (möglicherweise erheblichen relativen) Fehlern behaftet.
- ▶ Bei der Lösung des Systems  $A^T A x = A^T b$  über das Cholesky-Verfahren werden die Rundungsfehler in  $A^T A$  und  $A^T b$  mit

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

verstärkt. Es gilt

$$\kappa_2(A^T A) = \kappa_2(A)^2.$$

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

N4.4

## Beispiel 4.12.

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 4.12.

- 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 Normalgleichung und das Cholesky-Verfahren auf einer Maschine mit  $\text{eps} \approx 10^{-16}$  ergibt jedoch:

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

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

# 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

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

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.

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

- ▶ Das lineare Ausgleichsproblem ist gegeben durch: Zu gegebenem  $A \in \mathbb{R}^{m \times n}$  und  $b \in \mathbb{R}^m$ , bestimme  $x^* \in \mathbb{R}^n$ , für dass

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

gilt.

## Lösung über QR-Zerlegung

Daraus folgt:

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

und mit

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

erhält man

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

## Lösung über QR-Zerlegung

## Satz 4.13.

Sei  $A \in \mathbb{R}^{m \times n}$  mit  $\text{Rang}(A) = n$  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

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

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 linearen Ausgleichsproblems. Die Norm  $\|A x^* - b\|_2$  ist gerade durch  $\|b_2\|_2$  gegeben.

# Lösung über QR-Zerlegung

Aus Satz 4.13 ergibt sich nun folgende Methode:

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

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

z.B. mittels Givens-Rotationen oder Householder-Spiegelungen  
und berechne

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

- ▶ Löse

$$\tilde{R}x = b_1$$

mittels Rückwärtseinsetzen.

- ▶ Die Norm des Residuums  $\min_{x \in \mathbb{R}^n} \|Ax - b\|_2 = \|Ax^* - b\|_2$   
ist gerade durch  $\|b_2\|_2$  gegeben.



## Beispiel 4.15.

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 4.15.

- 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 — Kondition

## Beachte

- ▶ Wegen Satz 3.14 gilt

N4.4

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

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  $\kappa_2(A)$  (und nicht  $\kappa_2(A)^2$ ) beschrieben wird.

**Beispiel:** Matlab Demo lineare Ausgleichsrechnung

N4.5

&

D:ML

## Beispiel 4.16

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

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

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

Wegen der sehr guten Stabilität dieser Methode sind die Resultate viel besser als in Beispiel 4.12.

## Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand ( $m \gg n$ )	ca. $\frac{1}{2}mn^2$	ca. $mn^2$
Stabilität	instabil, wenn $\kappa_2(A) \gg 1$ und $\theta \approx 0$ stabil, wenn $\kappa_2(A) \approx 1$ oder $\theta \approx \frac{\pi}{4}$	stabil

# Übersicht

Themen: Dahmen & Reusken Kap. 4.1-4.4, **4.7**

- ▶ Das lineare Ausgleichsproblem
- ▶ **Singulärwertzerlegung (SVD)**

Was Sie mitnehmen sollten:

- ▶ Was ist ein lineares Ausgleichsproblem
- ▶ Wie ist das lineare Ausgleichsproblem konditioniert
- ▶ Welche Lösungsverfahren gibt es und wie stabil sind diese
- ▶ **Definition, Eigenschaften und Anwendungen der SVD**

# Motivation

Lösung des linearen Ausgleichsproblems (für  $\text{Rang}(A) = n$ ):

$$x^* = (A^T A)^{-1} A^T b.$$

Problem: –  $(A^T A)^{-1}$  existiert nicht für  $\text{Rang}(A) < n$   
– Lösung lineares Ausgleichsproblem nicht eindeutig  
⇒ zusätzliche Auswahlbedingung

## Allgemeines Lineares Ausgleichsproblem

Sei  $b \in \mathbb{R}^m$  und  $A \in \mathbb{R}^{m \times n}$ . Die Aufgabe: bestimme  $x^*$  mit **minimaler Euklidischer Norm**, für das

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

gilt, hat eine eindeutige Lösung.

- ▶ QR-Zerlegung mit Pivotisierung
- ▶ Singulärwertzerlegung (SVD = Singular Value Decomposition)

# Singulärwertzerlegung

## Satz

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


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

Hierbei sind:

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



# Singulärwertzerlegung – Geometrische Interpretation




Quelle: Trefethen & Bau

Abbildung der Einheitskugel  $S = \{x : \|x\|_2 = 1\}$  durch  $A$

- ▶ Singulärwerte: Längen  $\sigma_1, \sigma_2$  der Halbachsen von  $AS$ .
- ▶ Linkssingulärvektoren: Einheitsvektoren  $\{u_1, u_2\}$  in Richtung der Halbachsen von  $AS$
- ▶ Rechtssingulärvektoren: Einheitsvektoren  $\{v_1, v_2\} \in S$ , Urbild der Halbachsen von  $AS$ , so dass  $Av_j = \sigma_j u_j$ .

# Singulärwertzerlegung – Geometrische Interpretation



# Singulärwertzerlegung

Fall:  $m = 4$ ,  $n = 2$ ,  $\text{rank}(A) = 2$

► Full SVD

$$\begin{bmatrix} \times & \times \\ \times & \times \\ \times & \times \\ \times & \times \end{bmatrix} = \begin{bmatrix} \times & \times & \times & \times \\ \times & \times & \times & \times \\ \times & \times & \times & \times \\ \times & \times & \times & \times \end{bmatrix} \begin{bmatrix} \times & \mathbf{0} \\ \mathbf{0} & \times \\ \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \times & \times \\ \times & \times \end{bmatrix}$$

$A \qquad U \qquad \Sigma \qquad V^T$

► Reduced SVD

$$\begin{bmatrix} \times & \times \\ \times & \times \\ \times & \times \\ \times & \times \end{bmatrix} = \begin{bmatrix} \times & \times \\ \times & \times \\ \times & \times \\ \times & \times \end{bmatrix} \begin{bmatrix} \times & \mathbf{0} \\ \mathbf{0} & \times \end{bmatrix} \begin{bmatrix} \times & \times \\ \times & \times \end{bmatrix}$$

$A \qquad \hat{U} \qquad \hat{\Sigma} \qquad V^T$

# Singulärwertzerlegung

- ▶ Annahme:  $m \geq n$

- ▶ Fall  $m < n$ : betrachte SVD von  $A^T$

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

- ▶ Singulärwerte sind reell und nichtnegativ

- ▶ Konvention

- ▶  $\sigma_{\max} = \sigma_1$  größter Singulärwert
  - ▶  $\sigma_{\min} = \sigma_n$  kleinster Singulärwert
  - ▶ der Größe nach geordnet

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$$

- ▶ SVD ist numerisch rückwärtsstabil berechenbar

$$A + \Delta A = \tilde{U} \tilde{\Sigma} \tilde{V}^T \text{ mit } \|\Delta A\|_2 = \mathcal{O}(\text{eps})$$

# Eigenschaften

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

- ▶  $Av_i = \sigma_i u_i, A^T u_i = \sigma_i v_i, i = 1, \dots, n.$
- ▶  $\text{Rang}(A) = r = \text{Anzahl der von Null verschiedenen Singulärwerte.}$
- ▶  $\|A\|_2 = \sigma_1 = \sigma_{\max}$
- ▶  $\|A^{-1}\|_2 = \frac{1}{\sigma_n}$ , falls  $A$  eine reguläre  $n \times n$  Matrix ist
- ▶  $\kappa_2(A) = \|A\|_2 \|A^{-1}\|_2 = \frac{\sigma_1}{\sigma_n}$ , falls  $A$  eine reguläre  $n \times n$  Matrix ist
- ▶  $\kappa_2(A) = \|A\|_2 \|A^+\|_2 = \frac{\sigma_1}{\sigma_n} = \frac{\sigma_{\max}}{\sigma_{\min}}$ , falls  $\text{Rang}(A) = n.$

# Eigenschaften

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

- Die strikt positiven Singulärwerte sind die Wurzeln der strikt positiven Eigenwerte von  $A^T A$ :

$$\{\sigma_i \mid i = 1, \dots, r\} = \{\sqrt{\lambda_i(A^T A)} \mid i = 1, \dots, r\}$$

- Die Singulärwerte sind gleich dem Absolutbetrag der Eigenwerte von  $A$  falls  $A = A^T$ .

- Für  $A \in \mathbb{R}^{n \times n}$  gilt  $|\det(A)| = \prod_{i=1}^m \sigma_i$

- Die Pseudoinverse  $A^+ \in \mathbb{R}^{n \times m}$  ist definiert durch

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

mit  $\Sigma^+ = \text{diag}(\sigma_1^{-1}, \dots, \sigma_r^{-1}, 0, \dots, 0) \in \mathbb{R}^{n \times m}$ .

# Eigenschaften – Low-Rank Approximation

Sei  $A = U \Sigma V^T$  eine Singulärwertzerlegung von  $A \in \mathbb{R}^{m \times n}$  mit Singulärwerten  $\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0$ . Für  $k \leq r = \text{Rang}(A)$  definiere

$$A_k = U \Sigma_k V^T$$

mit  $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k, 0, \dots, 0) \in \mathbb{R}^{m \times n}$ . Dann gilt:

- ▶  $\text{Rang}(A_k) = k$ .
- ▶ Die Distanz zwischen  $A_k$  und  $A$  ist

$$\|A - A_k\|_2 = \sigma_{k+1}.$$

- ▶  $A_k$  ist die beste Approximation an  $A$  vom Rang  $\leq k$

$$\|A - A_k\|_2 = \min_{\text{Rang}(B) \leq k} \|A - B\|_2.$$

# Lineares Ausgleichsproblem

Bestimme  $x^*$ , so dass

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

Lösung mit SVD:  $A = U \Sigma V^T$

$$\begin{aligned}\|Ax - b\|_2 &= \|U^T A V V^T x - U^T b\|_2 \\ &= \|\Sigma(V^T x) - (U^T b)\|_2 \\ &= \|\Sigma y - (U^T b)\|_2\end{aligned}$$

Dann  $y = \Sigma^{-1}(U^T b)$  und  $x^* = V y$ .

Falls  $\text{Rang}(A) = r < n$ , definiere Pseudo-Inverse  $A^+ \in \mathbb{R}^{n \times m}$  durch

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

mit  $\Sigma^+ = \text{diag}(\sigma_1^{-1}, \dots, \sigma_r^{-1}, 0, \dots, 0) \in \mathbb{R}^{n \times m}$ .

Lösung des **allgemeinen linearen Ausgleichsproblems**:  $x^* = A^+ b$ .



# Numerischer Rang

Rang einer Matrix wird in der Praxis fast immer über die Singulärwerte bestimmt. Falls

$$\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0$$

so gilt  $\text{Rang}(A) = r$ .

Problem: Rundungsfehler aufgrund Maschinengenauigkeit

$$A \rightarrow \tilde{A}, \quad \sigma_i \rightarrow \tilde{\sigma}_i, \quad i = 1, \dots, n.$$

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

## Numerischer Rang

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

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

# Image Compression

Singulärwertzerlegung von  $A$

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

kann geschrieben werden als

$$A = \sum_{i=1}^p \sigma_i u_i v_i^T = \sigma_1 u_1 v_1^T + \sigma_2 u_2 v_2^T + \dots + \sigma_p u_p v_p^T$$

mit  $p = \min(m, n)$ .

Approximation der Matrix  $A$  vom Rang  $k$ ,  $k \leq p$ , ist

$$A_{\mathbf{k}} = \sum_{i=1}^{\mathbf{k}} \sigma_i u_i v_i^T$$


und  $\|A - A_k\|_2 = \sigma_{k+1}$ .

**Datenkompression:**

$\Rightarrow$  Speicherbedarf für  $A_k$  ist  $k(m + n)$  vs.  $mn$  für  $A$ .

# Image Compression


Betrachte Schwarz Weiß-Bild  $I(x, y)$  als Matrix  $A$ : Einträge in Matrix entsprechen Graustufen des jeweiligen Pixels.




Je nach Anwendung: Principal Component Analysis (PCA), Proper Orthogonal Decomposition (POD), Karhunen-Loève Decomposition.

# Image Compression


$k = 1$ , compression = 0.00548




$k = 20$ , compression = 0.11



$k = 40$ , compression = 0.219



Original: A. Duerer, Melencolia I



# Image Compression



Gatlinburg-Tagung: J.H. Wilkinson, W. Givens, G. Forsythe,  
A. Householder, G. Henrici, F.L. Bauer (von links nach rechts)

# Berechnung der Singulärwerte

Verfahren:

- ▶ Wurzeln der Eigenwerte von  $A^T A$

Problem: – Aufwand relativ hoch  
– nicht stabil

- ▶ Fehlerverstärkung mit  $\kappa(A)^2$  anstelle von  $\kappa(A)$  (vgl. Normalgleichung)
- ▶ Problematisch bei Berechnung der Singulärwerte mit  $\sigma_k \ll \|A\|_2$ .
- ▶ Golub-Kahan-Reinsch Algorithmus
  - ▶ Schritt 1: Bidiagonalisierung mit Householder-Transformation
  - ▶ Schritt 2: Reduktion auf Diagonalgestalt

...oder in MATLAB:

```
>> [U,S,V] = svd(A)
```

# Zusammenfassung

Singulärwertzerlegung wird eingesetzt für

- ▶ Bestimmung des (numerischen) Rangs einer Matrix
- ▶ Berechnung von Norm und Konditionszahl
- ▶ ...

Viele Praktische Anwendungen:

- ▶ signal processing, image processing, statistics, reduced-order modelling, inverse problems (regularization), ...