

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 Δy
 - 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)

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.

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 $Ax = b$?

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. $Ax \neq b$!

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)

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

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

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

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

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

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 $n < m$)

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

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 ...

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

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.

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 $I_t = \frac{\partial I}{\partial t}$.

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

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 ∇I ist unbekannt (vgl. "Barberpole Illusion").

Optical Flow Estimation

Spatial Coherence Constraint[†]

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

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

[†]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

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

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 5×5 Fenster)

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 5×5 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

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

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

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

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

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

$$\Rightarrow x^* = ?$$




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

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 beschränken 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?

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

$$x =$$

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

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

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

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

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 \mathbf{b} gilt

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

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

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.

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.

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.

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.

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 $\delta > 0$).

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.

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

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

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.

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.

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

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:

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

Lösung über QR-Zerlegung

Daraus folgt:

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

Lösung über QR-Zerlegung

Daraus folgt:

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

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:

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

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

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

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

Lösung über QR-Zerlegung

Daraus folgt:

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

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

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

Lösung über QR-Zerlegung

Daraus folgt:

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

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.

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 $a_{3,1}$:

$$A^{(2)} =$$

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 $a_{3,1}$:

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

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

$$A^{(3)} =$$

Beispiel 4.15.

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

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

Beispiel 4.15.

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

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

Beispiel 4.15.

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

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

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 4.15.

- 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:

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.

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.

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.

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 ($m \gg n$)		
Stabilität		

Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand ($m \gg n$)	ca. $\frac{1}{2}mn^2$	
Stabilität		

Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand ($m \gg n$)	ca. $\frac{1}{2}mn^2$	ca. mn^2
Stabilität		

Zusammenfassung

	Normalgleichungen	QR-Zerlegung
Rechenaufwand ($m \gg n$)	ca. $\frac{1}{2}mn^2$	ca. mn^2
Stabilität	instabil, wenn	

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 $\theta \approx 0$	

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	

Zusammenfassung

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

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

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 : σ_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

Singulärwertzerlegung – Geometrische Interpretation




Quelle: Trefethen & Bau

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

- Singulärwerte: Längen σ_1, σ_2 der Halbachsen von AS .

Singulärwertzerlegung – Geometrische Interpretation




Quelle: Trefethen & Bau

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

- ▶ Singulärwerte: Längen σ_1, σ_2 der Halbachsen von AS .
- ▶ Linkssingulärvektoren: Einheitsvektoren $\{u_1, u_2\}$ in Richtung der Halbachsen von AS

Singulärwertzerlegung – Geometrische Interpretation




Quelle: Trefethen & Bau

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

- ▶ Singulärwerte: Längen σ_1, σ_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:

► $Av_i = \sigma_i u_i, A^T u_i = \sigma_i v_i, i = 1, \dots, n.$

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:

- ▶ $Av_i = \sigma_i u_i, A^T u_i = \sigma_i v_i, i = 1, \dots, n.$
- ▶ $\text{Rang}(A) = r = \text{Anzahl der von Null verschiedenen Singulärwerte.}$

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:

- ▶ $Av_i = \sigma_i u_i, A^T u_i = \sigma_i v_i, i = 1, \dots, n.$
- ▶ $\text{Rang}(A) = r = \text{Anzahl der von Null verschiedenen Singulärwerte.}$
- ▶ $\|A\|_2 = \sigma_1 = \sigma_{\max}$

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

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

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 $A^T A$:

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

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 $A = A^T$.

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 $|\det(A)| = \prod_{i=1}^n \sigma_i$

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:

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:

- ▶ $\text{Rang}(A_k) = k$.

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

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

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

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

Lineares Ausgleichsproblem

Bestimme x^* , so dass

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

Lösung mit SVD: $A = U \Sigma V^T$

$$\|Ax - b\|_2 =$$

Lineares Ausgleichsproblem

Bestimme x^* , so dass

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

Lösung mit SVD: $A = U \Sigma V^T$

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

Lineares Ausgleichsproblem

Bestimme x^* , so dass

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

Lösung mit SVD: $A = U \Sigma V^T$

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

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 $x^* = V y$.

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

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

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

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), ...