

# KAPITEL 4. Lineare Ausgleichsrechnung

---

**Beispiel 4.1.** Das Ohmsche Gesetz:

$$U = RI$$


Eine Meßreihe von Daten:

$$(U_i, I_i) \quad (\text{Spannung, Stromstärke}), \quad i = 1, \dots, m.$$

Aufgabe: man bestimme aus diesen Meßdaten den Widerstand  $R$  im Stromkreis. Theoretisch:

$$U_i = RI_i, \quad i = 1, \dots, m.$$

Aber Daten sind mit *Fehlern* behaftet.



Man kann hierzu versuchen, die durch eine Wahl von  $R$  bedingten Residuen  $U_i - RI_i$  zu quadrieren, aufzusummieren und dasjenige  $R$  zu suchen, das diesen Ausdruck minimiert:

$$f(R) := \sum_{i=1}^m (RI_i - U_i)^2 = \min.$$

Da  $f$  eine quadratische Funktion ist, kann nur ein Extremum vorliegen, das durch die Nullstelle der Ableitung gegeben ist:

$$0 = f'(R) = \sum_{i=1}^m 2(RI_i - U_i)I_i = 2R \left( \sum_{i=1}^m I_i^2 \right) - 2 \sum_{i=1}^m U_i I_i.$$

Hier ergibt sich diese Nullstelle  $R^*$  als

$$R^* = \left( \sum_{i=1}^m U_i I_i \right) / \left( \sum_{i=1}^m I_i^2 \right). \quad \triangle$$

## Beispiel 4.2.

---

In der Fourieranalyse wird eine  $T$ -periodische Funktion  $f$  durch eine Linearkombination der  $T$ -periodischen trigonometrischen Polynome

$$1, \cos(ct), \sin(ct), \cos(2ct), \sin(2ct), \dots, \cos(Nct), \sin(Nct)$$

mit  $c := \frac{2\pi}{T}$  in der Form

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

approximiert.

Annahme: nicht  $f$ , sondern nur eine Reihe von Meßdaten

$$b_i \approx f(t_i), \quad 0 \leq t_1 < t_2 < \dots < t_m \leq T,$$

ist bekannt, wobei  $m > 2N + 1$ .

Ansatz zur Bestimmung der Koeffizienten  $a_0, a_1, b_1, a_2, b_2, \dots, a_N, b_N$ :

$$\sum_{i=1}^m (g_N(t_i) - b_i)^2 = \min.$$

△

# Das allgemeine lineare Ausgleichsproblem

---

Das Minimierungsproblem

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

wird in Matrixform dargestellt. 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 eine kompakte Form an:

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

Also:

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

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

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. Das zugehörige lineare Ausgleichsproblem hat die Gestalt (4.14), mit

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

Die Lösung von (4.14) lässt sich auf die Lösung des linearen Gleichungssystems

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

reduzieren, das häufig als *Normalgleichungen* bezeichnet wird.

Beachte: für  $A \in \mathbb{R}^{m \times n}$  ist die Matrix  $A^T A \in \mathbb{R}^{n \times n}$  stets *quadratisch*.

Kernaussage:

**Satz 4.5.**  $x^* \in \mathbb{R}^n$  ist genau dann Lösung des linearen Ausgleichsproblems (4.14), wenn  $x^*$  Lösung der Normalgleichungen


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

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

# Geometrische Interpretation

Anschaulich ist klar, daß die Differenz  $b - Ax$  gerade *senkrecht* auf dem Bildraum  $\text{Bild}(A) = \{Ax \mid x \in \mathbb{R}^n\}$  stehen muß, damit der Abstand  $\|Ax - b\|_2$  minimal ist. Also gilt:

$$\|Ax - b\|_2 = \min \iff Ax - b \perp \text{Bild}(A),$$



In Beispiel 3.32 wurde bereits folgende Tatsache gezeigt:

**Bemerkung 4.6.** 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 in den Abschnitten 4.3 und 4.4 auf den Fall, daß  $A$  vollen Spaltenrang hat:  $\text{Rang}(A) = n$ .*

Der Fall  $\text{Rang}(A) < n$  wird in Abschnitt 4.7 diskutiert.




# Kondition des linearen Ausgleichsproblems

$$\kappa_2(A) := \max_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2} / \min_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}.$$

Ausgleichsproblem mit Störungen:

$$\|A\tilde{x} - \tilde{b}\|_2 = \min.$$



**Satz 4.7.** Für die Kondition des linearen Ausgleichsproblems bezüglich Störungen in  $b$  gilt

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

## Beispiel 4.8.

---

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

Man kann einfach nachrechnen, daß  $\kappa_2(A) \approx 2.62$  und

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

gilt. Für  $\tilde{b} = (0.01, 1, 0.01)^T$  erhält man

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

Daraus folgt

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

also eine schlechte Kondition. Es gilt

$$\cos \Theta = \frac{\|Ax^*\|_2}{\|b\|_2} = 0.01.$$

△

**Satz 4.9.** Für die Kondition des linearen Ausgleichsproblems bezüglich Störungen in  $A$  gilt

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

## Lösung der Normalgleichungen

Die Matrix  $A^T A$  ist symmetrisch positiv definit.  
Folglich ergibt sich die Methode:

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

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

von  $A^T A$ .

- Löse

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

durch Vorwärts- bzw. Rückwärtseinsetzen.

- 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.

## Beispiel 4.12.

---

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

Das lineare Ausgleichsproblem  $\|Ax - b\|_2 = \min$  hat die Lösung  $x^* = (1, 1)^T$  (für alle  $\delta > 0$ ). Außerdem gilt  $\Theta = 0$ .

Daher wird die Kondition dieses Problems durch  $\kappa_2(A)$  beschrieben.

Man rechnet einfach nach, daß

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

gilt. 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:

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

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

**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

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

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

$$Qb = \left( \begin{array}{c} b_1 \\ b_2 \end{array} \right) \begin{array}{l} \} n \\ \} m - n \end{array} ,$$

dann ist  $x^* = \tilde{R}^{-1}b_1$  die Lösung des linearen Ausgleichsproblems (4.14). Die Norm  $\|Ax^* - b\|_2$  ist gerade durch  $\|b_2\|_2$  gegeben.

Grundidee:

$$\|Ax - b\|_2^2 = \|QAx - Qb\|_2^2 = \|Rx - Qb\|_2^2 = \|\tilde{R}x - b_1\|_2^2 + \|b_2\|_2^2.$$



Aus Satz 4.13 ergibt sich nun folgende Methode:

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

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

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.

---

Sei

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

d.h.  $m = 3$ ,  $n = 2$ . Man bestimme die Lösung  $x^* \in \mathbb{R}^2$  von

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

- Annullierung von  $a_{3,1}$ :

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

(In der Praxis werden die Transformationen  $G_{1,3}A$  und  $G_{1,3}b$  ausgeführt, *ohne* daß  $G_{1,3}$  explizit berechnet wird.)

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

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

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:

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

Als Norm des Residuums ergibt sich:

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

△

Wegen Satz 3.41 gilt

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

d.h., das Quadrieren der Kondition, das bei den Normalgleichungen auftritt, wird vermieden. Außerdem ist die Berechnung der  $QR$ -Zerlegung über Givens- oder Householder-Transformationen ein sehr stabiles Verfahren, wobei die Fehlerverstärkung durch  $\kappa_2(A)$  (und nicht  $\kappa_2(A)^2$ ) beschrieben wird.

## Beispiel 4.16

---

Wir nehmen  $A$  und  $b$  wie in Beispiel 4.12. Die Methode über die  $QR$ -Zerlegung von  $A$ , auf einer Maschine mit  $\text{eps} \approx 10^{-16}$ , ergibt

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

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

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

## 4.5 Zum statistischen Hintergrund - lineare Regression

---

Gegeben seien Daten  $(t_1, y_1), \dots, (t_m, y_m)$  mit  
 $t_i$ : feste (deterministische) Meßpunkte,  
 $y_i$ : Realisierungen von *Zufallsvariablen*  $Y_i$ .

**Lineare Regression** basiert auf dem Ansatz

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

$a_k(t)$ : geeignete Ansatzfunktionen,  
 $F_i$ : Meßfehler (Zufallsvariablen).

Ziel: eine *Schätzung*  $\hat{x} = (\hat{x}_1, \dots, \hat{x}_n)^T$  für den unbekanntem Parametersatz  $x = (x_1, \dots, x_n)^T \in \mathbb{R}^n$  bestimmen.

Einen solchen Schätzer liefert die lineare Ausgleichsrechnung.

Sei nämlich  $\hat{x}$  die Lösung des linearen Ausgleichsproblems

$$\|Ax - y\|_2^2 \rightarrow \min.$$

Dann ist  $\hat{x}$  ebenfalls eine Zufallsvariable.

Annahmen:

- $F_i$  unabhängig, identisch verteilt mit Erwartungswert  $\mathbb{E}(F_i) = 0$
- Varianz-Kovarianzmatrix

$$V(F) := \mathbb{E}(FF^T) = \left( \mathbb{E}(F_i F_j) \right)_{i,j=1}^m = \sigma^2 I$$

Dann gilt

$$\mathbb{E}(\hat{x}) = x, \quad V(\hat{x}) = \mathbb{E}\left((\hat{x} - x)(\hat{x} - x)^T\right) = \sigma^2 (A^T A)^{-1}.$$

Der Schätzer ist **erwartungstreu** und hat **minimale Varianz**.

Man spricht von einem *Best Linear Unbiased Estimator* (BLUE).

Annahmen:

- $F_i$  unabhängig, identisch verteilt mit Erwartungswert 0
- Varianz-Kovarianzmatrix  $V(F) = \sigma^2 I$
- $F_i$  normalverteilt

$\Rightarrow$ :  $Y_i$  normalverteilt,  $\mathbb{E}(Y) = Ax$ ,  $V(Y) = \sigma^2 I$ . Dichtefunktion von  $Y_i$ :

$$f_i(z) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{z-(Ax)_i}{\sigma}\right)^2}.$$

Für die Meßreihe  $y_1, \dots, y_m$  ist die Likelihood-Funktion definiert durch

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

Ein Parameterwert  $\tilde{x}$  heißt *Maximum-Likelihood-Schätzwert*, wenn

$$L(\tilde{x}; y_1, \dots, y_m) \geq L(x; y_1, \dots, y_m) \quad \text{für alle } x \in \mathbb{R}^n$$

Der Maximum-Likelihood-Schätzer ist gerade der Schätzer  $\hat{x}$  aus dem linearen Ausgleichsproblem, weil

$$\|y - A\tilde{x}\|_2 = \min_{x \in \mathbb{R}^n} \|y - Ax\|_2.$$



## 4.6 Orthogonale Projektion auf einem Teilraum

---

Gegeben: ein Vektorraum  $V$  über  $\mathbb{R}$  mit einem Skalarprodukt  $\langle \cdot, \cdot \rangle$ .

Durch  $\|v\| := \langle v, v \rangle^{\frac{1}{2}}$  wird eine Norm auf  $V$  definiert.

**Aufgabe.** Sei  $U \subset V$  ein  $n$ -dimensionaler Teilraum von  $V$ .

Zu  $v \in V$  bestimme  $u^* \in U$ , für das

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

gilt.

Im Falle des linearen Ausgleichsproblems ist  $U = \text{Bild}(A)$ ,  $A \in \mathbb{R}^{m \times n}$ ,  $V = \mathbb{R}^m$ ,  $\langle u, v \rangle = \sum_{j=1}^m u_j v_j$ , D.h.  $\|\cdot\| = \|\cdot\|_2$ .

**Bemerkung 4.18.** Weil  $U$  ein endlich-dimensionaler Teilraum ist, existiert ein Element in  $U$  mit minimalem Abstand zu  $v$ , d.h. es existiert  $u^* \in U$ , für das  $\|u^* - v\| = \min_{u \in U} \|u - v\|$  gilt.  $\triangle$

**Satz 4.20.** Unter den Bedingungen von Aufgabe 4.17 existiert ein eindeutiges  $u^* \in U$ , das

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


erfüllt. Ferner gilt das 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.

$u^*$  ist somit die **orthogonale Projektion** (bzgl.  $\langle \cdot, \cdot \rangle$ ) von  $v$  auf  $U$ .

Die Lösung der Aufgabe 4.17 ist also die *orthogonale Projektion* (bzgl.  $\langle \cdot, \cdot \rangle$ ) von  $v$  auf den Unterraum  $U$ .



## Eigenschaften der Projektion

---

Zu  $v \in V$  existiert ein eindeutiges  $P_U(v) \in U$ , so daß  $v - P_U(v) \perp U$ , d.h. ,  $\langle v - P_U(v), u \rangle = 0 \quad \forall u \in U$ .

Mit  $P_U : V \rightarrow U$  ist also eine wohldefinierte Abbildung gegeben.

(i) Die Abbildung  $P_U : V \rightarrow U$  ist linear.

(ii)  $P_U$  ist ein *Projektor*, d.h.  $P_U(u) = u$  für alle  $u \in U$  ( $P_U^2 = P_U$ ).

(iii) Die Abbildung  $P_U$  ist symmetrisch,

$$\text{d.h. } \langle P_U(v), w \rangle = \langle v, P_U(w) \rangle, \quad \forall v, w \in V.$$

(iv)  $P_U$  is beschränkt und zwar gilt  $\|P_U\| = \sup_{\|v\|=1} \|P_U(v)\| = 1$ .

Wie kann man  $P_U(v)$  berechnen?

Sei  $\{\phi_1, \dots, \phi_n\}$  eine *Basis* für  $U$ . Dann hat  $\hat{u} = P_U(v)$  eine eindeutige Darstellung

$$P_U(v) = \sum_{j=1}^n c_j \phi_j$$

mit gewissen Koeffizienten  $c_j = c_j(v)$ . Es gilt

$$0 = \langle v - P_U(v), \phi_k \rangle = \langle v, \phi_k \rangle - \sum_{j=1}^n c_j \langle \phi_j, \phi_k \rangle, \quad k = 1, \dots, n.$$

Definiert man die *Gram-Matrix*  $\mathbf{G} := \left( \langle \phi_k, \phi_j \rangle \right)_{j,k=1}^n$  und die Vektoren  $\mathbf{c} = (c_1, \dots, c_n)^T$ ,  $\mathbf{v} = (\langle v, \phi_1 \rangle, \dots, \langle v, \phi_n \rangle)^T$  so ergibt sich

$$\mathbf{G}\mathbf{c} = \mathbf{v}$$

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

## 4.7 Singulärwertzerlegung (SVD) und Pseudoinverse

---

Wir definieren die Lösungsmenge

$$L(b) := \{x \in \mathbb{R}^n \mid x \text{ ist Lösung des linearen Ausgleichproblems}\}$$

**Lemma 4.24.** Die Lösungsmenge  $L(b)$  hat folgende Eigenschaften:

- (i) Es existiert ein **eindeutiges**  $x^* \in \mathbb{R}^n$ , so daß  $x^* = L(b) \cap \text{Kern}(A)^\perp$ , wobei  $\text{Kern}(A)^\perp := \{z \in \mathbb{R}^n \mid y^T z = 0, \forall y \in \text{Kern}(A)\}$ .
- (ii) Für alle  $x \in L(b) \setminus \{x^*\}$  gilt  $\|x\|_2 > \|x^*\|_2$ , d.h.,  $x^*$  hat die kleinste Euklidische Norm in  $L(b)$ .

**Folgerung 4.25.** Sei  $b \in \mathbb{R}^m$ ,  $A \in \mathbb{R}^{m \times n}$ . Die Aufgabe

$$\begin{cases} \text{bestimme } x^* \text{ mit minimaler Euklidischer Norm,} \\ \text{für das } \|Ax^* - b\|_2 = \min_{x \in \mathbb{R}^n} \|Ax - b\|_2 \text{ gilt,} \end{cases}$$

hat eine eindeutige Lösung.

**Satz 4.27.** 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

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

Die  $\sigma_i$  heißen *Singulärwerte* von  $A$  (singular values). Die Spalten der Matrizen  $U, V$  nennt man die *Links-* bzw. *Rechtssingulärvektoren*.

**Satz 4.28.** Sei  $U^T A V = \Sigma$  eine Singulärwertzerlegung von  $A \in \mathbb{R}^{m \times n}$  mit Singulärwerten

$$\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_p = 0, \quad p = \min\{m, n\}.$$

Definiere  $A^+ \in \mathbb{R}^{n \times m}$  durch

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

Dann ist  $A^+ b = x^*$  die Lösung des allgemeinen linearen Ausgleichproblems.

$A^+$  heißt Pseudoinverse von  $A$ .

**Lemma 4.29.** Sei  $U^T A V = \Sigma$  eine Singulärwertzerlegung von  $A$  mit Singulärwerten  $\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_p = 0$ ,  $p = \min\{m, n\}$ . Die Spalten der Matrizen  $U$  und  $V$  werden mit  $u_i$  bzw.  $v_i$  notiert. Dann gilt:

(i)  $Av_i = \sigma_i u_i, \quad A^T u_i = \sigma_i v_i, \quad i = 1, \dots, p.$

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

(iii)  $\text{Bild}(A) = \text{span}\{u_1, \dots, u_r\}, \quad \text{Kern}(A) = \text{span}\{v_{r+1}, \dots, v_n\}.$

(iv)  $\|A\|_2 = \sigma_1.$


(v) Sei  $\kappa_2^*(A) := \|A\|_2 \|A^+\|_2 = \frac{\sigma_1}{\sigma_r}$ . 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)  $\{\sigma_i \mid i = 1, \dots, r\} = \{\sqrt{\lambda_i(A^T A)} \mid i = 1, \dots, n\} \setminus \{0\} .$



# Abb. 4.6. Orthogonale Basis in $\mathbb{R}^n$ und $\mathbb{R}^m$



# Abb. 4.7. Geometrische Interpretation der Singulärwertzerlegung



## 4.7.1 Berechnung von Singulärwerten

---

**Lemma 4.30.** Sei  $A \in \mathbb{R}^{m \times n}$ , und 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:**

Eine Householder-Transformation  $Q_1$ , so daß

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

Sei  $\tilde{Q}_1 \in \mathbb{R}^{3 \times 3}$  eine Householder-Transformation, so daß

$\tilde{Q}_1 v_1 = (* \ 0 \ 0)^T$ . Mit  $\hat{Q}_1 := \begin{pmatrix} 1 & \emptyset \\ \emptyset & \tilde{Q}_1 \end{pmatrix}$  erhält man

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

Auf ähnliche Weise können Nulleinträge erzeugt werden in der 2. Spalte, 2. Zeile, 3. Spalte und 4. Spalte:

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

**Bemerkung 4.31.** Der Aufwand zur Berechnung der oberen Bidiagonalmatrix  $B$  in 4.65 beträgt  $mn^2 + \mathcal{O}(mn)$  Operationen.  $\triangle$

Die Matrix  $A$  und die sich ergebende Bidiagonalmatrix  $B$  haben die gleichen Singulärwerte.

Die Singulärwerte der Matrix  $A$  sind die Wurzeln der Eigenwerte der *Tridiagonalmatrix*  $B^TB$ .

Für die Berechnung der Eigenwerte dieser Matrix werden im allgemeinen sehr viel weniger arithmetische Operationen benötigt als für die Berechnung der Eigenwerte der (vollbesetzten) Matrix  $A^TA$ .

## 4.7.2 Rangbestimmung

---

**Lemma 4.32.** Sei  $U^T A V = \Sigma$  eine Singulärwertzerlegung von  $A$  mit Singulärwerten  $\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_p = 0$ ,  $p = \min\{m, n\}$ . Für  $0 \leq k \leq p - 1$  gilt:

$$\min\{ \|A - B\|_2 \mid B \in \mathbb{R}^{m \times n}, \text{Rang}(B) \leq k \} = \sigma_{k+1} .$$

**Folgerung 4.33.** Für  $A$  und  $\tilde{A} = A + \Delta A \in \mathbb{R}^{m \times n}$  mit Singulärwerten  $\sigma_1 \geq \dots \geq \sigma_p$  bzw.  $\tilde{\sigma}_1 \geq \dots \geq \tilde{\sigma}_p$ ,  $p = \min\{m, n\}$ , gilt

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

In diesem Sinne ist das Problem der Singulärwertbestimmung **gut konditioniert**.

Sei  $\tilde{A} = (\tilde{a}_{i,j})$  eine mit Rundungsfehlern behaftete Annäherung von  $A$ , wobei  $\tilde{a}_{i,j} = a_{i,j}(1 + \epsilon_{i,j})$  mit  $|\epsilon_{i,j}| \leq \text{eps}$ .

Mit  $E := (a_{i,j}\epsilon_{i,j}) \in \mathbb{R}^{m \times n}$  ergibt sich

$$\|A - \tilde{A}\|_2 = \|E\|_2 \leq \sqrt{m}\|E\|_\infty \leq \sqrt{m}\|A\|_\infty \text{eps} \leq \sqrt{mn}\|A\|_2 \text{eps} .$$

Deswegen definieren wir:

$$\mathcal{B}_{\tilde{A}}(\text{eps}) := \left\{ C \in \mathbb{R}^{m \times n} \mid \frac{\|\tilde{A} - C\|_2}{\|\tilde{A}\|_2} \leq \sqrt{mn} \text{eps} \right\} .$$

Der **numerische Rang**  $\text{Rang}_{\text{num}}(\tilde{A})$  der Matrix  $\tilde{A}$  ist:

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

Dieser numerische Rang hängt von der Maschinengenauigkeit  $\text{eps}$  ab.

## Bestimmung des numerischen Ranges:

Seien  $\tilde{\sigma}_1 \geq \dots \geq \tilde{\sigma}_p$  die Singulärwerte der Matrix  $\tilde{A}$ . Es gilt

$$\min_{\text{Rang}(B) \leq k} \frac{\|\tilde{A} - B\|_2}{\|\tilde{A}\|_2} = \frac{\tilde{\sigma}_{k+1}}{\tilde{\sigma}_1}, \quad 1 \leq k < p.$$

Die Umgebung  $\mathcal{B}_{\tilde{A}}(\text{eps})$  enthält also eine Matrix  $B$  mit  $\text{Rang}(B) = k$  genau dann, wenn  $\tilde{\sigma}_{k+1}/\tilde{\sigma}_1 \leq \sqrt{mn} \text{eps}$ .

Der numerische Rang der Matrix  $\tilde{A}$  ist deshalb:

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



## 4.34. Beispiel

---

Wir betrachten die Matrizen

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

wobei  $\operatorname{eps} \approx 2 * 10^{-16}$ . Es gilt  $\operatorname{Rang}(A_1) = 2$ ,  $\operatorname{Rang}(A_2) = 3$ .

Die *berechneten* Singulärwerte dieser Matrizen sind

$$7.776, 1.082, 1.731 * 10^{-16} \quad \text{bzw.} \quad 7.776, 1.082, 2.001 * 10^{-15}.$$

In beiden Fällen sind die drei berechneten Singulärwerte strikt positiv, jedoch gilt

$$\operatorname{Rang}_{\text{num}}(A_1) = \operatorname{Rang}_{\text{num}}(A_2) = 2.$$

In der Praxis würde man hieraus schließen, daß beide Matrizen den Rang 2 haben. △