

# **3 Direkte Verfahren zur Lösung linearer Gleichungssysteme**

## **3.1 Vorbemerkungen**

## **3.2 Störungstheorie**

## **3.3 Das Lösen von Dreieckssystemen**

## **3.4 Gauß-Elimination**

## **3.5 Pivotisierung**

## **3.6 Equilibrierung und Nachiteration**

## **3.7 Stabilität bei der Gauß-Elimination**

## 3.1 Vorbemerkungen

Einige Stimmen zum Ansinnen, lineare Gleichungssysteme mit Gaußelimination auf Computern zu lösen:

*„A 78-rowed Matrix would need to be carried to no less than 46 places to ensure even an approximate accuracy in the first decimal place.“*

Hotelling, 1943

*„Very little is known about the methods so far described, [but] what little information there is tends to indicate that these methods are unstable and that rounding errors accumulate so seriously that the methods are impractical for large values of  $n$ .“*

Bargmann, Montgomery and von Neumann, 1946

**Bezeichnungen:**

$$\begin{array}{ccccccccccc}
 a_{1,1} & x_1 & + & a_{1,2} & x_2 & + & \cdots & + & a_{1,n} & x_n & = & b_1 \\
 a_{2,1} & x_1 & + & a_{2,2} & x_2 & + & \cdots & + & a_{2,n} & x_n & = & b_2 \\
 \vdots & & & & & & & & & & \vdots & \vdots \\
 a_{m,1} & x_1 & + & a_{m,2} & x_2 & + & \cdots & + & a_{m,n} & x_n & = & b_m
 \end{array}$$

ist ein

System von  $m$  linearen Gleichungen in den  $n$  Unbekannten  $x_1, x_2, \dots, x_n$ .

Kurzschreibweise:  $A\mathbf{x} = \mathbf{b}$

mit

$$A = [a_{i,j}]_{1 \leq i \leq m, 1 \leq j \leq n} \in \mathbb{C}^{m \times n},$$

$$\mathbf{x} = [x_1, \dots, x_n]^\top \in \mathbb{C}^n,$$

$$\mathbf{b} = [b_1, \dots, b_m]^\top \in \mathbb{C}^m.$$

$A$  heißt **Koeffizientenmatrix** und  $\mathbf{b}$  **rechte Seite** des linearen Gleichungssystems.

**Geometrische Deutung:** Jede der  $m$  Gleichungen repräsentiert eine Hyperebene im  $\mathbb{C}^n$ :

$$A(i, :)\mathbf{x} = b_i \text{ mit } A(i, :) = [a_{i,1}, a_{i,2}, \dots, a_{i,n}] \quad (i = 1, 2, \dots, m).$$

Gesucht ist der Durchschnitt dieser Hyperebenen.

**Analytische Deutung:** Mit  $A(:, j) = [a_{1,j}, a_{2,j}, \dots, a_{m,j}]^\top$  lässt sich  $A\mathbf{x} = \mathbf{b}$  auch als

$$x_1 A(:, 1) + x_2 A(:, 2) + \dots + x_n A(:, n) = \mathbf{b}$$

schreiben. Gesucht sind also Koeffizienten  $x_j$ , mit deren Hilfe man die rechte Seite  $\mathbf{b}$  als Linearkombination der Spalten von  $A$  darstellen kann.

## Existenz und Eindeutigkeit der Lösung:

Definiert man das **Bild** von  $A$  (engl. range) durch

$$\mathcal{R}(A) := \left\{ \mathbf{y} \in \mathbb{C}^m : \exists \mathbf{x} = [x_1, \dots, x_n]^\top \in \mathbb{C}^n \text{ mit } \mathbf{y} = A\mathbf{x} = \sum_{j=1}^n x_j A(:, j) \right\},$$

so besitzt  $A\mathbf{x} = \mathbf{b}$  genau dann (mindestens) eine Lösung, wenn  $\mathbf{b} \in \mathcal{R}(A)$  gilt.

Der **Kern** oder **Nullraum** von  $A$  ist durch

$$\mathcal{N}(A) := \{ \mathbf{z} \in \mathbb{C}^n : A\mathbf{z} = \mathbf{0} \}$$

definiert. Offensichtlich besitzt  $A\mathbf{x} = \mathbf{b}$  höchstens eine Lösung, wenn  $\mathcal{N}(A) = \{\mathbf{0}\}$  gilt.

Für quadratische Matrizen  $A \in \mathbb{C}^{n \times n}$  (in diesem Kapitel werden wir uns ausschließlich mit solchen Matrizen befassen) heißt das:

$Ax = b$  ist genau dann eindeutig lösbar, wenn  $A$  invertierbar ist.

**Satz 3.1.** Für eine quadratische Matrix  $A \in \mathbb{C}^{n \times n}$  sind die folgenden fünf Aussagen äquivalent:

- (a)  $A$  ist invertierbar.
- (b)  $\mathcal{N}(A) = \{\mathbf{0}\}$ .
- (c)  $\mathcal{R}(A) = \mathbb{C}^n$ .
- (d) Alle Eigenwerte von  $A$  sind ungleich 0.
- (e)  $\det(A) \neq 0$ .

## 3.2 Störungstheorie

Wir betrachten zunächst Störungen der Einheitsmatrix:

**Lemma 3.2.** Für  $A \in \mathbb{C}^{n \times n}$  gelte  $\|A\| < 1$  für eine Matrixnorm  $\|\cdot\|$  auf  $\mathbb{C}^{n \times n}$ . Dann gilt

(a)  $I - A$  ist invertierbar.

(b) Die Inverse besitzt die Darstellung

$$(I - A)^{-1} = \sum_{j=0}^{\infty} A^j \quad (\text{Neumannsche Reihe}).$$

(c) Für die Inverse gilt die Abschätzung  $\|(I - A)^{-1}\| \leq \frac{1}{1 - \|A\|}$ .

Der folgende Satz gibt ein Maß für den Abstand einer invertierbaren Matrix zur nächstgelegenen singulären Matrix an.

**Lemma 3.3.** *Zu gegebenen Vektoren  $x, y \in \mathbb{C}^n$  mit  $\|x\|_p = \|y\|_p = 1$ ,  $1 \leq p \leq \infty$ , existiert stets eine Matrix  $B \in \mathbb{C}^{n \times n}$  mit*

$$\|B\|_p = 1 \quad \text{und} \quad Bx = y.$$

**Satz 3.4.** *Es sei  $A \in \mathbb{C}^{n \times n}$  invertierbar. Dann gilt*

$$\begin{aligned} \min \left\{ \frac{\|\Delta A\|_p}{\|A\|_p} : \Delta A \in \mathbb{C}^{n \times n} \text{ so, dass } A + \Delta A \text{ singular} \right\} \\ = \frac{1}{\|A\|_p \|A^{-1}\|_p} \quad (1 \leq p \leq \infty). \end{aligned}$$

Es sei  $\|\cdot\|$  eine Matrixnorm in  $\mathbb{C}^{n \times n}$ . Ist  $A \in \mathbb{C}^{n \times n}$  invertierbar, so heißt

$$\text{cond}(A) = \text{cond}_{\|\cdot\|}(A) := \|A\| \|A^{-1}\| \quad (\geq 1)$$

die **Konditionszahl** von  $A$ . Für singuläre Matrizen  $A$  setzen wir  $\text{cond}(A) = \infty$ . (Kurzschreibweise:  $\text{cond}_p(A)$ , falls  $\|\cdot\| = \|\cdot\|_p$ .)

Satz 3.4 besagt, dass der (relative) Abstand (gemessen in  $\|\cdot\|_p$ ) einer regulären Matrix  $A$  zur Menge der singulären Matrizen gerade  $1/\text{cond}_p(A)$  beträgt.

Man kann  $\text{cond}(A)$  als (normalisierte) Fréchet-Ableitung der Abbildung  $A \mapsto A^{-1}$  interpretieren:

$$\text{cond}(A) = \lim_{h \rightarrow 0} \sup_{\|\Delta A\| \leq h \|A\|} \frac{\|(A + \Delta A)^{-1} - A^{-1}\|}{h} \frac{1}{\|A^{-1}\|}.$$

**Satz 3.5.** *Mit  $\| \cdot \|$  bezeichnen wir eine Vektornorm in  $\mathbb{C}^n$  sowie eine passende Matrixnorm in  $\mathbb{C}^{n \times n}$ . Es seien  $A, \Delta A \in \mathbb{C}^{n \times n}$  sowie  $b, \Delta b \in \mathbb{C}^n$ .  $A$  sei invertierbar und für die Störungsmatrix  $\Delta A$  gelte  $\|\Delta A\| < 1/\|A^{-1}\|$ . Schließlich seien  $x = A^{-1}b$  die Lösung des ungestörten LGS  $Ay = b$  und  $x + \Delta x = (A + \Delta A)^{-1}(b + \Delta b)$  die Lösung des gestörten LGS  $(A + \Delta A)y = b + \Delta b$  (beachten Sie, dass  $A + \Delta A$  invertierbar ist). Dann folgt*

$$\frac{\|\Delta x\|}{\|x\|} \leq \frac{\text{cond}(A)}{1 - \text{cond}(A) \frac{\|\Delta A\|}{\|A\|}} \left( \frac{\|\Delta A\|}{\|A\|} + \frac{\|\Delta b\|}{\|b\|} \right). \quad (3.1)$$

**Interpretation:** Relative Fehler in den Daten  $A$  und  $b$  verstärken sich mit dem Faktor  $\text{cond}(A)$  ins Ergebnis  $x = A^{-1}b$ . Auf einem Rechner mit Rundungseinheit  $u$  muss man also mindestens mit einem Fehler der Größenordnung  $\text{cond}(A) \cdot u$  in  $x$  rechnen – ein LGS  $Ax = b$  ist durch *kein* Verfahren zuverlässig lösbar, wenn  $\text{cond}(A) \geq 1/u$  gilt.

## Weitere Eigenschaften der Konditionszahl:

1. Sie ist normabhängig, z.B.  $\text{cond}_p(I_n) = \|I_n\|_p \|I_n\|_p = 1$  für  $p \geq 1$ , aber  $\text{cond}_F(I_n) = \|I_n\|_F \|I_n\|_F = n$ . Aber sind  $\|\cdot\|_\alpha$  und  $\|\cdot\|_\beta$  Matrixnormen in  $\mathbb{C}^{n \times n}$ , so gibt es stets Konstanten  $c, C > 0$  mit  $c \text{cond}_\alpha(A) \leq \text{cond}_\beta(A) \leq C \text{cond}_\alpha(A)$  für alle  $A$ .

Z.B. 
$$\frac{1}{n} \text{cond}_2(A) \leq \text{cond}_1(A) \leq n \text{cond}_2(A),$$

oder 
$$\frac{1}{n} \text{cond}_\infty(A) \leq \text{cond}_2(A) \leq n \text{cond}_\infty(A).$$

2. Immer gilt  $\text{cond}(A) \geq 1$ .
3. Ist  $A$  symmetrisch und positiv definit, so ist

$$\text{cond}_2(A) = \lambda_{\max}(A) / \lambda_{\min}(A)$$

4. Ist  $U \in \mathbb{C}^{n \times n}$  unitär, so ist  $\text{cond}_2(U) = 1$  und

$$\text{cond}_2(AU) = \text{cond}_2(UA) = \text{cond}_2(A) \quad \forall A \in \mathbb{C}^{n \times n}.$$

Ist  $\tilde{x}$  eine **Näherungslösung** des linearen Gleichungssystems  $Ax = b$ , so ist der **relative Rückwärtsfehler** (gemessen in einer Vektor- bzw. Matrixnorm  $\|\cdot\|$  auf  $\mathbb{C}^n$  bzw.  $\mathbb{C}^{n \times n}$ , „normwise backward error“) definiert durch

$$\eta(\tilde{x}) = \min \left\{ \varepsilon : (A + \Delta A)\tilde{x} = b + \Delta b, \frac{\|\Delta A\|}{\|A\|} \leq \varepsilon, \frac{\|\Delta b\|}{\|b\|} \leq \varepsilon \right\} .$$

**Satz 3.6** (Rigal und Gaches, 1967). *Es bezeichne  $\|\cdot\|$  eine Vektornorm auf  $\mathbb{C}^n$  sowie die dadurch induzierte Matrixnorm auf  $\mathbb{C}^{n \times n}$ . Der Norm-Rückwärtsfehler einer Näherungslösung  $\tilde{x} \in \mathbb{C}^n$  zum linearen Gleichungssystem  $Ax = b$  mit  $A \in \mathbb{C}^{n \times n}$  invertierbar,  $b \in \mathbb{C}^n$ , ist gegeben durch*

$$\eta(\tilde{x}) = \frac{\|r\|}{\|A\| \|\tilde{x}\| + \|b\|}, \quad (3.2)$$

wobei der Vektor  $r := b - A\tilde{x}$  das **Residuum** von  $\tilde{x}$  bezüglich des linearen Gleichungssystems bezeichnet.

Normabschätzungen sind nicht immer hinreichend aussagekräftig. In solchen Fällen ist oft eine komponentenweise Analyse notwendig. Der **Komponenten-Rückwärtsfehler** („componentwise backward error“) ist definiert durch

$$\omega_{E,f}(\tilde{\mathbf{x}}) := \min \{ \varepsilon : (A + \Delta A)\tilde{\mathbf{x}} = \mathbf{b} + \Delta \mathbf{b}, |\Delta A| \leq \varepsilon E, |\Delta \mathbf{b}| \leq \varepsilon \mathbf{f}, \} .$$

(Die Ungleichungen sind komponentenweise zu lesen.) Hierbei besitzen die Matrix  $E$  und der Vektor  $\mathbf{f}$  nichtnegative Einträge und stellen Fehlertoleranzen für jede einzelne Komponente dar. Spezielle Wahlen:

- $E = |A|$ ,  $\mathbf{f} = |\mathbf{b}|$ : liefert den relativen Komponenten-Rückwärtsfehler.
- $E = |A| \mathbf{e} \mathbf{e}^\top$ ,  $\mathbf{e} = [1, \dots, 1]^\top$ ,  $\mathbf{f} = |\mathbf{b}|$ : Zeilen-Rückwärtsfehler
- $E = \mathbf{e} \mathbf{e}^\top |A|$ ,  $\mathbf{f} = \|\mathbf{b}\|_\infty \mathbf{e}$ : Spalten-Rückwärtsfehler
- $E = \|A\| \mathbf{e} \mathbf{e}^\top$ ,  $\mathbf{f} = \|\mathbf{b}\| \mathbf{e}$ : liefert bis auf Konstante Norm-Rückwärtsfehler.

**Satz 3.7** (Oettli und Prager, 1964). *Der Komponenten-Rückwärtsfehler besitzt die Darstellung*

$$\omega_{E,f}(\tilde{\mathbf{x}}) = \max_{i=1}^n \frac{|r_i|}{(E|\tilde{\mathbf{x}}| + \mathbf{f})_i},$$

wobei  $\mathbf{r} = \mathbf{b} - A\tilde{\mathbf{x}}$  und  $\xi/0$  gleich Null zu setzen ist, falls,  $\xi = 0$  und andernfalls  $\xi/0 = \infty$ .

### 3.3 Das Lösen von Dreieckssystemen

Eine Matrix der Form

$$L = \begin{bmatrix} \ell_{1,1} & & & \\ \ell_{2,1} & \ell_{2,2} & & \\ \vdots & & \ddots & \\ \ell_{n,1} & \ell_{n,2} & \cdots & \ell_{n,n} \end{bmatrix} \in \mathbb{C}^{n \times n} \quad (\ell_{i,j} = 0 \text{ für } i < j)$$

heißt **untere Dreiecksmatrix**.  $L$  ist genau dann invertierbar, wenn  $\det(L) = \prod_{j=1}^n \ell_{j,j} \neq 0$ . Die invertierbaren unteren Dreiecksmatrizen bilden bez. der Matrizenmultiplikation eine Gruppe.  $L$  heißt **normierte** untere  $\Delta$ -Matrix, wenn  $\ell_{i,i} = 1$  ( $i = 1, 2, \dots, n$ ) ist. Die normierten unteren  $\Delta$ -Matrizen bilden bez. der Matrizenmultiplikation ebenfalls eine Gruppe. Analoge Aussagen gelten für **obere**  $\Delta$ -Matrizen  $R = [r_{i,j}] \in \mathbb{C}^{n \times n}$  ( $r_{i,j} = 0$  für  $i > j$ ).

Ist  $\det(L) \neq 0$ , so besitzt das untere  $\triangle$ -System  $Lx = c$  genau eine Lösung, die man durch **Vorwärts-Substitution**,

$$x_j = \frac{1}{\ell_{j,j}} (c_j - \ell_{j,1}x_1 - \cdots - \ell_{j,j-1}x_{j-1}) \quad (j = 1, 2, \dots, n),$$

mit  $n$  Divisionen,  $n(n-1)/2$  Multiplikationen und  $n(n-1)/2$  Additionen, also mit insgesamt  $n^2$  Gleitpunktoperationen berechnen kann.

Obere  $\triangle$ -Systeme  $Rx = d$  werden – falls  $\det(R) \neq 0$  – analog durch **Rückwärts-Substitution**,

$$x_j = \frac{1}{r_{j,j}} (d_j - r_{j,j+1}x_{j+1} - \cdots - r_{j,n}x_n) \quad (j = n, n-1, \dots, 1),$$

in  $O(n^2)$  Gleitpunktoperationen gelöst.

Wir wollen als nächstes zeigen, dass Vorwärts- und Rückwärtssubstitution rückwärtsstabile Algorithmen zur Lösung von Dreieckssystemen sind. Hierzu sind zwei Lemmata hilfreich:

**Lemma 3.8.** *Sind  $|\delta_j| \leq u$  und  $\rho_j = \pm 1$  für  $j = 1, \dots, n$  und gilt  $nu < 1$ , so ist*

$$\prod_{j=1}^n (1 + \delta_j)^{\rho_j} = 1 + \vartheta_n, \quad \text{mit} \quad |\vartheta_n| \leq \frac{nu}{1 - nu}.$$

**Lemma 3.9.** *Der Ausdruck  $y := \left( c - \sum_{i=1}^{k-1} a_i b_i \right) / b_k$  werde gemäß folgendem Algorithmus in Gleitpunktarithmetik mit Rundungseinheit  $u$  ausgewertet:*

*$s := c;$     **for**  $i = 1 : k - 1$ ,  $s := s - a_i b_i$ ; **end**     $s := s / b_k$ ;*

*Dann besitzt der berechnete Wert  $\tilde{y} := \text{fl}(y)$  die Darstellung*

$$b_k \tilde{y} (1 + \vartheta_k) = c - \sum_{i=1}^{k-1} a_i b_i (1 + \vartheta_i), \quad |\vartheta_i| \leq \frac{iu}{1 - iu}.$$

**Satz 3.10.** Die untere  $\Delta$ -Matrix  $L = [\ell_{i,j}] \in \mathbb{C}^{n \times n}$  sei invertierbar. Die Lösung von  $Lx = c$  werde in Gleitpunktarithmetik mit Rundungseinheit  $u$  durch Vorwärtssubstitution bestimmt. Dann erfüllt die berechnete Lösung  $\tilde{x}$  das LGS

$$(L + \Delta L)\tilde{x} = c$$

mit einer unteren Dreiecksmatrix  $\Delta L = [\lambda_{i,j}] \in \mathbb{C}^{n \times n}$ , wobei

$$|\lambda_{i,j}| \leq n u |\ell_{i,j}| + O(u^2) \quad (1 \leq i, j \leq n)$$

*gilt.*

## 3.4 Gauß-Elimination

### 3.4.1 Geschichtliches

**220 v. Chr. – 9 n. Chr.** *Chiu Chang Suan Shu* (*Neun Bücher arithmetischer Technik*). China. Buch 8 enthält eine Anleitung, LGS bis zur Dimension 5 mittels Elimination zu lösen.

**1750.** Gabriel Cramer: *Cramersche Regel*. Theoretisch einwandfrei aber praktisch unbrauchbar. (Lösung eines  $10 \times 10$  Problems erfordert ca. 300 Mio Multiplikationen.)

**1809,1823.** Carl Friedrich Gauß: *Theoria motus corporum ...* und *Theoria combinationis observationum ...*. Beschreibt Eliminationsverfahren für symmetrische Matrizen aus der Ausgleichsrechnung.

**1890.** Wilhelm Jordan: *Handbuch der Vermessungskunde*. Erste schriftliche Erwähnung des Gauß-Jordan Algorithmus.

**1948.** Alan Turing: Darstellung von GE als Folge von Multiplikationen mit unteren Dreiecksmatrizen.

**1961.** James Wilkinson: Rundungsfehleranalyse von GE.

**Stand der Kunst.** Zuverlässige Lösung von sehr großen Systemen möglich ( $N \approx 10^5$  für vollbesetzte,  $N \approx 10^7$  für dünn besetzte Matrizen). Software von hoher Qualität verfügbar (e.g. LAPACK).

### 3.4.2 Der Algorithmus

**Idee:** Transformiere  $Ax = b$ ,  $A \in \mathbb{C}^{n \times n}$  mit  $\det(A) \neq 0$ , auf ein oberes Dreieckssystem  $Rx = d$ , ohne die Lösung zu verändern. (Löse dann  $Rx = d$  durch Rückwärts-Substitution.)

Die Lösung eines Gleichungssystems verändert sich nicht, wenn man von der  $j$ -ten Gleichung das  $\lambda$ -fache der  $i$ -ten Gleichung subtrahiert ( $i < j$ ).

Formal: Statt  $Ax = b$  betrachte  $(LA)x = Lb$  mit

$$L = I - m_j u_i^T \in \mathbb{R}^{n \times n}.$$

Dabei ist  $m_j = \lambda u_j \in \mathbb{C}^n$ ;  $u_i$  und  $u_j$  bezeichnen den  $i$ -ten bzw.  $j$ -ten Einheitsvektor im  $\mathbb{R}^n$ .

**Beispiel.**

$$\begin{bmatrix} 2 & -1 & -3 & 3 \\ 4 & 0 & -3 & 1 \\ 6 & 1 & -1 & 6 \\ -2 & -5 & 4 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} = \begin{bmatrix} 1 \\ -8 \\ -16 \\ -12 \end{bmatrix}.$$

1. Schritt: Eliminiere  $x_1$  aus der zweiten, dritten und vierten Gleichung. Um das zu erreichen, subtrahiert man das  $l_{i,1} = \frac{a_{i,1}}{a_{1,1}}$ -fache der ersten Gleichung von der  $i$ -ten ( $i = 2, 3, 4$ ). Hier:  $l_{2,1} = 2$ ,  $l_{3,1} = 3$ ,  $l_{4,1} = -1$ .

Mit

$$L_1 = I - \begin{bmatrix} 0 \\ l_{2,1} \\ l_{3,1} \\ l_{4,1} \end{bmatrix} [1 \ 0 \ 0 \ 0] = \begin{bmatrix} 1 & 0 & 0 & 0 \\ -2 & 1 & 0 & 0 \\ -3 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \end{bmatrix}$$

ergibt sich

$$L_1[A|\mathbf{b}] = \left[ \begin{array}{cccc|c} 2 & -1 & -3 & 3 & 1 \\ 0 & 2 & 3 & -5 & -10 \\ 0 & 4 & 8 & -3 & -19 \\ 0 & -6 & 1 & 4 & -11 \end{array} \right] .$$

2. Schritt: Eliminiere  $x_2$  aus der dritten und vierten Gleichung, d.h. subtrahiere das  $l_{i,2} = \frac{a_{i,2}}{a_{2,2}}$ -fache der zweiten Gleichung von der  $i$ -ten ( $i = 3, 4$ ).  
Hier:  $l_{3,2} = 2, l_{4,2} = -3$ . Mit

$$L_2 = I - \begin{bmatrix} 0 \\ 0 \\ l_{3,2} \\ l_{4,2} \end{bmatrix} [0 \ 1 \ 0 \ 0] = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & -2 & 1 & 0 \\ 0 & 3 & 0 & 1 \end{bmatrix}$$

ergibt sich

$$L_2 L_1 [A|\mathbf{b}] = \left[ \begin{array}{cccc|c} 2 & -1 & -3 & 3 & 1 \\ 0 & 2 & 3 & -5 & -10 \\ 0 & 0 & 2 & 7 & 1 \\ 0 & 0 & 10 & -11 & -41 \end{array} \right].$$

**3. Schritt:** Eliminiere  $x_3$  aus der vierten Gleichung, d.h. subtrahiere das  $l_{i,3} = \frac{a_{i,3}}{a_{3,3}}$ -fache der dritten Gleichung von der  $i$ -ten ( $i = 4$ ). Hier  $l_{4,3} = 5$ .

Mit

$$L_3 = I - \begin{bmatrix} 0 \\ 0 \\ 0 \\ l_{4,3} \end{bmatrix} [0 \ 0 \ 1 \ 0] = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & -5 & 1 \end{bmatrix}$$

ergibt sich

$$\left[ \begin{array}{cccc|c} 2 & -1 & -3 & 3 & 1 \\ 0 & 2 & 3 & -5 & -10 \\ 0 & 0 & 2 & 7 & 1 \\ 0 & 0 & 0 & -46 & -46 \end{array} \right] .$$

Die Eliminationsphase ist jetzt abgeschlossen und wir können  $x_4, x_3, x_2, x_1$  durch Rückwärts-Substitution bestimmen:

$$x_4 = 1, \quad x_3 = \frac{1}{2}[1 - 7x_4] = -3, \quad x_2 = \frac{1}{2}[-10 - 3x_3 + 5x_4] = 2,$$
$$x_1 = \frac{1}{2}[1 + x_2 + 3x_3 - 3x_4] = -\frac{9}{2}.$$

Das Gaußsche Eliminationsverfahren liefert eine **LR-Zerlegung** von  $A$ , d.h. eine Faktorisierung  $A = L \cdot R$  mit einer normierten unteren  $\triangle$ -Matrix  $L$  und einer oberen  $\triangle$ -Matrix  $R$ .

Im allgemeinen:  $L_{n-1} \cdots L_2 L_1 A = R$ , d.h.

$$A = (L_{n-1} \cdots L_2 L_1)^{-1} R = (L_1^{-1} L_2^{-1} \cdots L_{n-1}^{-1}) R =: L \cdot R.$$

In unserem Beispiel:

$$L = \begin{bmatrix} 1 & 0 & 0 & 0 \\ -2 & 1 & 0 & 0 \\ -3 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \end{bmatrix}^{-1} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & -2 & 1 & 0 \\ 0 & 3 & 0 & 1 \end{bmatrix}^{-1} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & -5 & 1 \end{bmatrix}^{-1}$$

$$= \begin{bmatrix} 1 & 0 & 0 & 0 \\ 2 & 1 & 0 & 0 \\ 3 & 0 & 1 & 0 \\ -1 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 2 & 1 & 0 \\ 0 & -3 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 5 & 1 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 2 & 1 & 0 & 0 \\ 3 & 2 & 1 & 0 \\ -1 & -3 & 5 & 1 \end{bmatrix}, \text{ also } A = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 2 & 1 & 0 & 0 \\ 3 & 2 & 1 & 0 \\ -1 & -3 & 5 & 1 \end{bmatrix} \begin{bmatrix} 2 & -1 & -3 & 3 \\ 0 & 2 & 3 & -5 \\ 0 & 0 & 2 & 7 \\ 0 & 0 & 0 & -46 \end{bmatrix}.$$

**Lemma 3.11.** *Mit  $\mathbf{u}_i \in \mathbb{R}^n$  bezeichnen wir den  $i$ -ten Einheitsvektor. Sei  $\mathbf{m}_i = [0, \dots, 0, \ell_{i+1,i}, \dots, \ell_{n,i}]^\top \in \mathbb{C}^n$  ( $1 \leq i \leq n-1$ ). Für die Matrizen*

$$L_i = I - \mathbf{m}_i \mathbf{u}_i^\top \in \mathbb{C}^{n \times n}$$

*gelten:*

- (a)  $L_i^{-1} = I + \mathbf{m}_i \mathbf{u}_i^\top.$   
 (b)  $L_1^{-1} L_2^{-1} \cdots L_{n-1}^{-1} = I + \mathbf{m}_1 \mathbf{u}_1^\top + \mathbf{m}_2 \mathbf{u}_2^\top + \cdots + \mathbf{m}_{n-1} \mathbf{u}_{n-1}^\top.$

Bei der numerischen Rechnung wird die Matrix  $A$  durch die „Zwischenmatrizen“ überschrieben (analog für die rechte Seite). Außerdem müssen die Nullen unterhalb der Hauptdiagonalen nicht gespeichert werden, man verwendet diese Felder für die Zahlen  $\ell_{i,j}$ .

### Pseudocode:

```
for  $j = 1 : n - 1$   
  if  $a_{j,j} = 0$  then  
    stop  
  else  
    for  $i = j + 1 : n$   
       $a_{i,j} := a_{i,j} / a_{j,j}$   
       $b_i := b_i - a_{i,j} b_j$   
      for  $k = j + 1 : n$   
         $a_{i,k} := a_{i,k} - a_{i,j} a_{k,j}$ 
```

Aufwand:  $\frac{2}{3}n^3 + O(n^2)$  flops.

In unserem Beispiel:

$$\left[ \begin{array}{cccc|c} 2 & -1 & -3 & 3 & 1 \\ 4 & 0 & -3 & 1 & 8 \\ 6 & 1 & -1 & 6 & -16 \\ 2 & 5 & 4 & 1 & -12 \end{array} \right]$$

$\xrightarrow{1.}$

$$\left[ \begin{array}{cccc|c} 2 & -1 & -3 & 3 & 1 \\ 2 & 2 & 3 & -5 & -10 \\ 3 & 4 & 8 & -3 & -19 \\ -1 & -6 & 1 & 4 & -11 \end{array} \right]$$

$\xrightarrow{2.}$

$$\left[ \begin{array}{cccc|c} 2 & -1 & -3 & 3 & 1 \\ 2 & 2 & 3 & -5 & -10 \\ 3 & 2 & 2 & 7 & 1 \\ -1 & -3 & 10 & -11 & 41 \end{array} \right]$$

$\xrightarrow{3.}$

$$\left[ \begin{array}{cccc|c} 2 & -1 & -3 & 3 & 1 \\ 2 & 2 & 3 & -5 & -10 \\ 3 & 2 & 2 & 7 & 1 \\ -1 & -3 & 5 & -46 & -46 \end{array} \right]$$

### 3.4.3 Algorithmische Varianten von Gauß-Elimination

*kij*-Variante: (Lehrbuchvariante)

```

for  $k = 1 : n - 1$ 
  for  $i = k + 1 : n$ 
     $\ell_{i,k} = a_{i,k} / a_{k,k}$ 
    for  $j = k + 1 : n$ 
       $a_{i,j} = a_{i,j} - \ell_{i,k} a_{k,j}$ 


```

*kji*-Variante: (spaltenorientiert)

```

for  $k = 1 : n - 1$ 
  for  $s = k + 1 : n$ 
     $\ell_{s,k} = a_{s,k} / a_{k,k}$ 
  for  $j = k + 1 : n$ 
    for  $i = k + 1 : n$ 
       $a_{i,j} = a_{i,j} - \ell_{i,k} a_{k,j}$ 

```



Zugriffsmuster *kij* / *kji* Varianten.

*ikj*-Variante: (zeilenorientiert)

**for**  $i = 2 : n$

**for**  $k = 1 : i - 1$

$$\ell_{i,k} = a_{i,k} / a_{k,k}$$

**for**  $j = k + 1 : n$

$$a_{i,j} = a_{i,j} - \ell_{i,k} a_{k,j}$$

*jki*-Variante: (spaltenorientiert)

**for**  $j = 2 : n$



**for**  $s = j : n$

$$\ell_{s,j-1} = a_{s,j-1} / a_{j-1,j-1}$$

**for**  $k = 1 : j - 1$

**for**  $i = k + 1 : n$

$$a_{i,j} = a_{i,j} - \ell_{i,k} a_{k,j}$$




*ijk*-Variante: (zeilenorientiert)

```


for  $i = 2 : n$ 
  for  $j = 2 : i$ 
     $\ell_{i,j-1} = a_{i,j-1} / a_{j-1,j-1}$ 
    for  $k = 1 : j - 1$ 
       $a_{i,j} = a_{i,j} - \ell_{i,k} a_{k,j}$ 
    for  $j = i + 1 : n$ 
      for  $k = 1 : i - 1$ 
         $a_{i,j} = a_{i,j} - \ell_{i,k} a_{k,j}$ 

```



*jik*-Variante: (spaltenorientiert)

```
for  $j = 2 : n$   
  for  $s = j : n$   
     $l_{s,j-1} = a_{s,j-1} / a_{j-1,j-1}$   
  for  $i = 2 : j$   
    for  $k = 1 : i - 1$   
       $a_{i,j} = a_{i,j} - l_{i,k} a_{k,j}$   
  for  $i = j + 1 : n$   
    for  $k = 1 : j - 1$   
       $a_{i,j} = a_{i,j} - l_{i,k} a_{k,j}$ 
```




Bordering-Variante: ( $jki$ )

```

for  $j = 2 : n$ 
  for  $k = 1 : j - 2$ 
    for  $i = k + 1 : j - 1$ 
       $a_{i,j} = a_{i,j} - \ell_{i,k} a_{k,j}$ 
    for  $k = 1 : j - 1$ 
       $\ell_{j,k} = a_{j,k} / a_{k,k}$ 
      for  $i = 1 : k + 1 : j$ 
         $a_{j,i} = a_{j,i} - \ell_{j,k} a_{k,i}$ 

```




Verfahren von Crout/Doolittle:

**for**  $j = 1 : n$

$$a_{j:n,j} = a_{j:n,j} - \ell_{j:n,1:j-1} a_{1:j-1,j}$$

$$a_{j+1:n,j} = a_{j+1:n,j} / a_{j,j}$$

$$a_{j,j+1:n} = a_{j,j+1:n} - \ell_{j,1:j-1} a_{1:j-1,j+1:n}$$



Hier wird das Aufdatieren der Restmatrix (Schur-Komplement) so spät wie möglich ausgeführt.

### 3.4.4 Speicherhierarchien und die BLAS

Um auf Rechnern mit ausgeprägter Speicherhierarchie dennoch schnelle Programme zu erzielen, benutzen moderne Implementierungen als Bausteine die **Basic Linear Algebra Subroutines (BLAS)**. Diese werden von Rechnerherstellern in für ihre Systeme optimierter Form zur Verfügung gestellt. Man unterscheidet drei Levels unterschiedlicher Effizienz; hier einige typische Vertreter

Operation (Level)	Definition	$n_A$	$n_S$	$q = n_A/n_S$
saxpy (1)	$\mathbf{y} := \alpha \mathbf{x} + \mathbf{y}$	$2n$	$3n + 1$	$2/3$
Matrix-Vektor Produkt (2)	$\mathbf{y} := A\mathbf{x} + \mathbf{y}$	$2n^2$	$n^2 + 3n$	$2$
Matrix-Matrix Produkt (3)	$Y := Y + AX$	$2n^3$	$4n^2$	$n/2$

in der Tabelle:  $\alpha \in \mathbb{R}$ ,  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ ,  $A, X, Y \in \mathbb{R}^{n \times n}$

$n_A$  : Anzahl arithmetischer Operationen

$n_S$  : Anzahl Speicherzugriffe

Je größer der Quotient  $q$ , desto näher ist man am optimalen Durchsatz:

Bezeichnen  $t_A$  die Dauer einer (typischen) Gleitpunktoperation,  
 $t_S$  die Dauer einer (typischen) Speicherzugriffs, sowie  
 $t_G$  die Ausführungsdauer des Algorithmus,

so gilt

$$t_G = t_A \cdot n_A + t_S \cdot n_S = t_A n_A \left( 1 + \frac{t_S n_S}{t_A n_A} \right) = t_A n_A \left( 1 + \frac{1}{q} \frac{t_S}{t_A} \right)$$

Es ist somit effizient, Algorithmen der numerischen linearen Algebra möglichst aus BLAS2 bzw. BLAS3 Routinen aufzubauen.

Wir zeigen eine Möglichkeit, dies bei Gauß-Elimination durch Blockeinteilung zu erreichen. Wir benötigen hierzu eine Abwandlung der Gauß-Elimination für  $m \times n$ -Matrizen,  $m \geq n$ .

Algorithmus 3.1:

**for**  $k = 1 : \min\{m - 1, n\}$

$$a_{k+1:m,k} = a_{k+1:m,k} / a_{k,k}$$

**if**  $k < n$  **then**

$$a_{k+1:m,k+1:n} = a_{k+1:m,k+1:n} - \ell_{k+1:m,k} a_{k,k+1:n}$$

Wir partitionieren die Matrizen nach  $k - 1$  Schritten von GE:

$$\begin{bmatrix} A_{1,1} & A_{1,2} & A_{1,3} \\ A_{2,1} & A_{2,2} & A_{2,3} \\ A_{3,1} & A_{3,2} & A_{3,3} \end{bmatrix} = \begin{bmatrix} L_{1,1} & O & O \\ L_{2,1} & I & O \\ L_{3,1} & O & I \end{bmatrix} \begin{bmatrix} R_{1,1} & R_{1,2} & R_{1,3} \\ O & \tilde{A}_{2,2} & \tilde{A}_{2,3} \\ O & \tilde{A}_{3,2} & \tilde{A}_{3,3} \end{bmatrix}$$

mit quadratischen Matrizen  $A_{1,1}$ ,  $A_{2,2}$ ,  $A_{3,3}$  der Dimension  $k - 1$ ,  $n_B$  bzw.  $n - (k - 1) - n_B$  ( $n_B$  eine Blockgröße zwischen 1 und  $n$ ).

Folgende Variante der GE ist reicher an BLAS3-Operationen (gezeigt ist ein Blockschritt):

1. Verwende Algorithmus 3.1 zur Faktorisierung von

$$\begin{bmatrix} \tilde{A}_{2,2} \\ \tilde{A}_{3,2} \end{bmatrix} = \begin{bmatrix} L_{2,2} \\ L_{3,2} \end{bmatrix} R_{2,2} .$$

2. Bestimme  $R_{2,3} := L_{2,2}^{-1} \tilde{A}_{2,3}$  als Lösung eines unteren Dreieckssystems mit  $n_B$  rechten Seiten (BLAS3).
3. Setze  $\tilde{\tilde{A}}_{3,3} := \tilde{A}_{3,3} - L_{3,2} R_{2,3}$  (BLAS3).

## 3.5 Pivotisierung

Das Eliminationsverfahren „bricht zusammen“ (bereits im ersten Schritt), wenn es auf die Matrix  $A = \begin{bmatrix} 0 & 1 \\ 1 & 1 \end{bmatrix}$  angewandt wird (obwohl  $\det(A) \neq 0$ ).  $A$  besitzt keine LR-Zerlegung.

**Satz 3.12.** *Es sei  $A \in \mathbb{C}^{n \times n}$  regulär. Dann sind die folgenden Aussagen äquivalent:*

- (a)  *$A$  besitzt eine LR-Zerlegung mit einer normierten unteren Dreiecksmatrix  $L$  und einer regulären oberen Dreiecksmatrix  $R$ .*
- (b) *Alle führenden Hauptuntermatrizen von  $A$  sind regulär.*

**Bemerkung.** Besitzt die reguläre Matrix  $A \in \mathbb{C}^{n \times n}$  eine LR-Zerlegung, so ist diese eindeutig bestimmt.

**Satz 3.13** (Satz von Gerschgorin). Für  $A = [a_{i,j}] \in \mathbb{C}^{n \times n}$  sind die *Gerschgorin-Kreisscheiben* durch

$$D_i := \left\{ \zeta \in \mathbb{C} : |\zeta - a_{i,i}| \leq \sum_{\substack{j=1 \\ j \neq i}}^n |a_{i,j}| \right\} \quad (i = 1, 2, \dots, n)$$

definiert. Dann gilt

$$\Lambda(A) \subseteq \bigcup_{i=1}^n D_i.$$

Dabei ist  $\Lambda(A) := \{\lambda \in \mathbb{C} : \det(A - \lambda I) = 0\}$  das *Spektrum* von  $A$ .

**Korollar 3.14.** Ist  $A = [a_{i,j}] \in \mathbb{C}^{n \times n}$  *streng diagonaldominant*, d.h. gilt

$$|a_{i,i}| > \sum_{\substack{j=1 \\ j \neq i}}^n |a_{i,j}| \quad \text{für alle } i = 1, 2, \dots, n,$$

dann ist  $A$  regulär und besitzt eine LR-Zerlegung.

Ist  $\pi$  eine Permutation der Indexmenge  $\{1, 2, \dots, n\}$ , dann ist die zugehörige **Permutationsmatrix**  $P = P_\pi = [p_{i,j}] \in \mathbb{R}^{n \times n}$  durch

$$p_{i,j} = \begin{cases} 1, & \text{falls } j = \pi(i), \\ 0, & \text{falls } j \neq \pi(i), \end{cases}$$

definiert.

- Es gilt  $P_\pi^{-1} = P_{\pi^{-1}} = P_\pi^\top$ .
- Die Menge aller Permutationsmatrizen ist eine Gruppe bezüglich der Matrizenmultiplikation.
- Die Determinante einer Permutationsmatrix hat entweder den Wert 1 oder den Wert  $-1$ .
- Ist  $A = [a_{i,j}] \in \mathbb{C}^{n \times n}$  mit den Zeilen  $z_1^\top, \dots, z_n^\top$  und Spalten  $s_1, \dots, s_n$ , so besitzt  $P_\pi A$  die Zeilen  $z_{\pi(1)}^\top, \dots, z_{\pi(n)}^\top$  und  $AP_\pi^\top$  die Spalten  $s_{\pi(1)}, \dots, s_{\pi(n)}$ . Insbesondere ist  $P_\pi A P_\pi^\top = [a_{\pi(i), \pi(j)}]$ .

**Satz 3.15.** *Es sei  $A \in \mathbb{C}^{n \times n}$  invertierbar. Dann gibt es eine Permutationsmatrix  $P \in \mathbb{R}^{n \times n}$ , so dass  $PA$  eine LR-Zerlegung besitzt:*

$$PA = LR.$$

*Dabei kann  $P$  so gewählt werden (Spaltenpivotsuche), dass die Einträge  $\ell_{i,j}$  der Matrix  $L$  alle der Ungleichung  $|\ell_{i,j}| \leq 1$  genügen.*

Die Lösung eines LGS  $Ax = b$  für beliebige reguläre Matrizen  $A \in \mathbb{C}^{n \times n}$  mittels Gauß-Elimination besteht somit aus folgenden Schritten:

- (a) Bestimme  $P, L, R$ , so dass  $PA = LR$ .
- (b) Löse  $Ly = Pb$  durch Vorwärtssubstitution.
- (c) Löse  $Rx = y$  durch Rückwärtssubstitution.

(Insbesondere dann vorteilhaft, wenn  $Ax = b_i$  mit einer Matrix  $A$  und mehreren rechten Seiten  $b_i$  zu lösen ist.)

**Pseudocode:** (Gauß-Elimination mit Spaltenpivotsuche)**for**  $k = 1 : n - 1$ Bestimme  $p$  so, dass  $|a_{p,k}| = \max_{k \leq i \leq n} |a_{i,k}|$ Vertausche  $a_{k,:}$  mit  $a_{p,:}$ Vertausche  $b_k$  mit  $b_p$ **if**  $a_{k,k} = 0$  **then****stop****else****for**  $i = k + 1 : n$  $a_{i,k} := a_{i,k} / a_{k,k}$  $b_i := b_i - a_{i,k} b_k$ **for**  $j = k + 1 : n$  $a_{i,j} := a_{i,j} - a_{i,k} a_{k,j}$

Spaltenpivotsuche muss (i.A.) immer durchgeführt werden, um **kleine Pivotelemente** zu vermeiden, die zu **ungenauen Ergebnissen** führen können:

**Beispiel:**

$$\begin{bmatrix} 10^{-20} & 1 \\ 1 & 1 \end{bmatrix} \boldsymbol{x} = \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \quad \text{Lösung } \boldsymbol{x} = \frac{1}{1 - 10^{-20}} \begin{bmatrix} -1 \\ 1 \end{bmatrix} \approx \begin{bmatrix} -1 \\ 1 \end{bmatrix}.$$

Gauß-Elimination (mit Rundungseinheit  $u = 2^{-53} \approx 10^{-16}$ ):

$$10^{-20}x_1 + x_2 = 1$$

$$(1 - 10^{20})x_2 = -10^{20}, \quad \text{gerundet } -10^{20}\tilde{x}_2 = -10^{20}, \quad \text{d.h. } \tilde{x}_2 = 1, \quad \tilde{x}_1 = 0.$$

(Gauß-Elimination mit Spaltenpivotsuche würde  $\tilde{x}_1 = -1$  und  $\tilde{x}_2 = 1$  liefern.)

Gauß-Elimination ohne Pivotsuche liefert also bei gerundeter Rechnung die Faktoren

$$\tilde{L} = \begin{bmatrix} 1 & 0 \\ 10^{20} & 1 \end{bmatrix} \quad \text{und} \quad \tilde{R} = \begin{bmatrix} 10^{-20} & 1 \\ 0 & -10^{20} \end{bmatrix}$$

anstelle der exakten Faktoren

$$L = \begin{bmatrix} 1 & 0 \\ 10^{20} & 1 \end{bmatrix} \quad \text{und} \quad R = \begin{bmatrix} 10^{-20} & 1 \\ 0 & 1 - 10^{20} \end{bmatrix}.$$

Beim Gleichungslösen wurde also verwendet

$$\tilde{L}\tilde{R} = \begin{bmatrix} 10^{-20} & 1 \\ 1 & 0 \end{bmatrix} \quad \text{statt} \quad LR = \begin{bmatrix} 10^{-20} & 1 \\ 1 & 1 \end{bmatrix} = A.$$

## 3.6 Equilibrierung und Nachiteration

Die Spaltenpivotsuche kann leicht ad absurdum geführt werden, wenn man die verschiedenen Gleichungen unterschiedlich wichtet:

**Beispiel** (aus 3.5, nur erste Gleichung wurde mit  $10^{20}$  multipliziert)

$$\begin{bmatrix} 1 & 10^{20} \\ 1 & 1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} 10^{20} \\ 0 \end{bmatrix} \quad \text{führt bei Rechnung} \\ \text{(mit Spaltenpivotsuche), } u \approx 10^{-16},$$

wie oben auf  $\tilde{x}_2 = 1$  und  $\tilde{x}_1 = 0$ .

$A$  heißt **zeilenequilibriert**, wenn in jeder Zeile die Betragssumme der Einträge gleich ist,

$$\sum_{j=1}^n |a_{i,j}| = 1 \quad (i = 1, 2, \dots, n).$$

Man kann das leicht dadurch erreichen, indem man die  $i$ -te Zeile vorab mit  $1 / \sum_{j=1}^n |a_{i,j}|$  multipliziert.

Alternative: Bestimme Pivotelement (in Schritt  $j$ ) so, dass

$$\frac{|a_{p,j}^{(j)}|}{\sum_{k=1}^n |a_{p,k}|} \geq \frac{|a_{i,j}^{(j)}|}{\sum_{k=1}^n |a_{i,k}|} \quad \text{für alle } i = j, j+1, \dots, n.$$

Man kann die Qualität einer berechneten Lösung  $\tilde{x}$  durch **Nachiteration** verbessern:

- a) Berechne Residuum  $r = b - A\tilde{x}$  (doppelt genau).
- b) Löse  $Ah = r$  (verwende LR-Zerlegung von  $A$ ).
- c) Setze  $x = \tilde{x} + h$ .

## 3.7 Stabilität bei der Gauß-Elimination

Nicht verwechseln darf man:

- **Die Stabilität eines mathematischen Problems** (hier: eines linearen Gleichungssystems mit invertierbarer Koeffizientenmatrix), die beschreibt, wie sich die Lösung **bei exakter Rechnung** verändert, wenn die Daten gestört werden.
- **Die Stabilität eines numerischen Verfahrens** (hier: der Gauß-Elimination mit Spaltenpivotsuche), die beschreibt, wie sich die **in Gleitpunktarithmetik berechnete** Lösung von der exakten Lösung unterscheidet.

**Beispiel:** (Instabilität des Problems)

$$A = \begin{bmatrix} 10 & 7 & 8 & 7 \\ 7 & 5 & 6 & 5 \\ 8 & 6 & 10 & 9 \\ 7 & 5 & 9 & 10 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 32 \\ 23 \\ 33 \\ 31 \end{bmatrix}, \quad \tilde{\mathbf{b}} = \begin{bmatrix} 32.1 \\ 22.9 \\ 33.1 \\ 30.9 \end{bmatrix},$$

$$\mathbf{x} := A^{-1} \mathbf{b} = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}, \quad \tilde{\mathbf{x}} := A^{-1} \tilde{\mathbf{b}} = \begin{bmatrix} 9.2 \\ -12.6 \\ 4.5 \\ -1.1 \end{bmatrix}$$

**Erklärung:**  $\text{cond}_{\infty}(A) = 4.488 \cdot 10^3$ , also

$$13.6 = \frac{\|\mathbf{x} - \tilde{\mathbf{x}}\|_{\infty}}{\|\mathbf{x}\|_{\infty}} \lesssim \text{cond}_{\infty}(A) \frac{\|\mathbf{b} - \tilde{\mathbf{b}}\|_{\infty}}{\|\mathbf{b}\|_{\infty}} = (4.488 \cdot 10^3) \cdot \frac{0.1}{33} = 13.6 .$$

Ein weiteres Beispiel: Die **Hilbert-Matrix** der Dimension  $n$


$$H_n = \begin{bmatrix} 1 & \frac{1}{2} & \frac{1}{3} & \cdots & \frac{1}{n} \\ \frac{1}{2} & \frac{1}{3} & \frac{1}{4} & \cdots & \frac{1}{n+1} \\ \frac{1}{3} & \frac{1}{4} & \frac{1}{5} & \cdots & \frac{1}{n+2} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \frac{1}{n} & \frac{1}{n+1} & \frac{1}{n+2} & \cdots & \frac{1}{2n-1} \end{bmatrix}$$

ist symmetrisch und positiv definit, insbesondere also invertierbar.

Ihre Konditionszahl  $\text{cond}_2(H_n)$  wächst wie  $e^{7n/2} \approx 33^n$ :

$n$	4	6	8	10	12	14
$\text{cond}_2(H_n)$	$1.6 \cdot 10^4$	$1.5 \cdot 10^7$	$1.5 \cdot 10^{10}$	$1.6 \cdot 10^{13}$	$1.7 \cdot 10^{16}$	$1.9 \cdot 10^{19}$
$\text{cond}_\infty(H_n)$	$2.8 \cdot 10^4$	$2.9 \cdot 10^7$	$3.4 \cdot 10^{10}$	$3.5 \cdot 10^{13}$	$4.1 \cdot 10^{16}$	$4.5 \cdot 10^{19}$

Wir lösen  $H_{12}\mathbf{x} = \mathbf{b}$  mit Rundungseinheit  $u = 2^{-53} \approx 1.1 \cdot 10^{-16}$  (die rechte Seite  $\mathbf{b}$  wurde so gewählt, dass  $A^{-1}\mathbf{b} = [1, \dots, 1]^T$  gilt).



**Bezeichnungen.** Für  $A = [a_{i,j}], B = [b_{i,j}] \in \mathbb{R}^{n \times n}$  bedeute  $A \leq B$ , dass  $a_{i,j} \leq b_{i,j}$  für alle  $1 \leq i, j \leq n$  erfüllt ist. Außerdem sei  $|A| := [|a_{i,j}|] \in \mathbb{R}^{n \times n}$ .

**Satz 3.16** (Wilkinson, 1963). *Es seien  $A \in \mathbb{C}^{n \times n}$  regulär und  $b \in \mathbb{C}^n$ . In Gleitpunktarithmetik (mit Rundungseinheit  $u$ ) werde (mit beliebiger Pivotstrategie) eine LR-Zerlegung  $\tilde{L}\tilde{R} \sim PA$  von  $A$  sowie eine Lösung  $\tilde{x}$  des Systems  $Ax = b$  berechnet. Dann gelten:*

- (a)  $\tilde{L}\tilde{R} = PA + E$  mit  $|E| \leq nu|\tilde{L}||\tilde{R}| + O(u^2)$ .  
 (b)  $(A + \Delta A)\tilde{x} = b$  mit  $|\Delta A| \leq 3nu|\tilde{L}||\tilde{R}| + O(u^2)$ .

**Bemerkung 3.17.**

(a) Für absolute Normen  $\|\cdot\|$  gelten somit

$$\|E\| \leq nu\|\tilde{L}\|\|\tilde{R}\| + O(u^2) \quad \text{sowie} \quad \|\Delta A\| \leq 3nu\|\tilde{L}\|\|\tilde{R}\| + O(u^2).$$

(b) Die Konstante  $3\gamma_n + \gamma_n^2$  im Beweis von Satz 3.16 lässt sich verbessern zu  $2\gamma_n$ .

**Korollar 3.18.** *Bei Spaltenpivotsuche gilt mit den Bezeichnungen aus Satz 3.16*

$$\|\Delta A\|_\infty \leq 3 \rho n^3 \|A\|_\infty u + O(u^2),$$

wobei

$$\rho := \frac{\max_{1 \leq i, j \leq n} |\tilde{r}_{i,j}|}{\max_{1 \leq i, j \leq n} |a_{i,j}|}$$

der sog. **Wachstumsfaktor** bei Gauß-Elimination mit Spaltenpivotsuche ist. Es gilt

$$\rho \leq 2^{n-1}$$

und diese obere Schranke wird auch angenommen.

**Bemerkung 3.19.** *Mit Hilfe von Bemerkung 3.17a lässt sich zeigen, dass sogar  $\|\Delta A\|_\infty \leq 2n^2 \gamma_n \rho \|A\|_\infty$ .*

Allerdings beobachtet man in der Praxis keineswegs, dass  $\rho$  wie  $2^{n-1}$  wächst, sondern eher ein Anwachsen wie  $n^{2/3}$ .

**Rückwärtsanalyse** (interpretiere Rundefehler als Datenfehler)

$$(A + \Delta A)\tilde{\mathbf{x}} = \mathbf{b} \quad \text{mit} \quad \|\Delta A\|_{\infty} \lesssim 3 \rho n^3 \|A\|_{\infty} u$$

und **Konditionsanalyse** (wie wirken sich Datenfehler in *exakter Arithmetik* auf das Ergebnis aus)

$$\frac{\|\mathbf{x} - \tilde{\mathbf{x}}\|}{\|\mathbf{x}\|} \lesssim \text{cond}(A) \left[ \frac{\|A - \tilde{A}\|}{\|A\|} + \frac{\|\mathbf{b} - \tilde{\mathbf{b}}\|}{\|\mathbf{b}\|} \right] \quad \text{mit} \quad \text{cond}(A) := \|A\| \|A^{-1}\|$$

liefern insgesamt

$$\frac{\|\mathbf{x} - \tilde{\mathbf{x}}\|_{\infty}}{\|\mathbf{x}\|_{\infty}} \lesssim 3 n^3 \rho \text{cond}_{\infty}(A) u.$$

Gauß-Elimination mit Spaltenpivotsuche ist stabil, wenn Wachstumsfaktor  $\rho$  und Konditionszahl  $\text{cond}(A)$  klein sind.

Wir haben gesehen, dass

$$\rho \leq 2^{n-1} \text{ für alle } A \in \mathbb{R}^{n \times n}$$

gilt und dass diese Schranke angenommen wird. In der ‘Praxis’ wächst  $\rho$  aber wesentlich langsamer mit  $n$ , so dass Gauß-Elimination mit Spaltenpivotsuche **praktisch rückwärtsstabil** ist.

Ob dieser Algorithmus auch vorwärtsstabil ist, hängt von  $A$  bzw. von  $\text{cond}(A)$  ab. Wie wir am Beispiel der Hilbert-Matrix gesehen haben, gibt es invertierbare Matrizen  $A$ , die extrem schlecht konditioniert sind, aber auf den ersten Blick ganz unverdächtig aussehen.

**Vollständige Pivotsuche (complete pivoting):** Hier zeigte Wilkinson 1961 für den Wachstumsfaktor  $\rho = \rho_{CP}(n)$

$$\rho^{CP}(n) \leq \sqrt{n \cdot 2 \cdot 3^{1/2} \dots n^{1/(n-1)}} \sim cn^{1/2} n^{\frac{1}{4} \log n},$$

und dass diese Schranke nicht scharf ist. Diese Schranke wächst wesentlich langsamer als  $2^{n-1}$ , kann aber auch beträchtlich werden: sie beträgt z.B. 3570 für  $n = 100$ . Bekannte Teilergebnisse:

- $\rho^{CP}(2) = 2$
- $\rho^{CP}(3) = 9/4$
- $\rho^{CP}(4) = 4$
- $\rho^{CP}(5) < 5.005$

Die lang anhaltende Vermutung  $\rho^{CP}(n) \leq n$  wurde 1991 von Gould durch ein  $(13 \times 13)$  Gegenbeispiel widerlegt.

Die Lücke zwischen dem theoretisch schlimmsten Fall und dem in der Praxis beobachteten Wachstumsverhalten von  $\rho$  (beide Pivotstrategien) ist nach wie vor verblüffend:

“It is rare for the growth factor to exceed 10 on ‘real’ problems, regardless of the size of  $n$ .”

P. Gill, W. Murray & M. Wright,  
*Numerical Linear Algebra and Optimization* (1991)

“In practice  $g_{PP}$  is always  $n$  or less.”

J. Demmel, *Applied Numerical Linear Algebra* (1997)

“The growth suggested by the bound rarely occurs in practice. The reasons are not well understood.”

G. W. Stewart, *Matrix Algorithms I* (1998)

“Anyone that unlucky has already been hit by a truck.”

wird J. Wilkinson zugeschrieben