

## 5) Lineare Gleichungssysteme.

### 5.1) Motivation: ein Beispiel.

Betrachten wir das folgende Problem:

Sei  $P_n = \{ \text{Polynome } P \mid p(t) = a_0 + a_1 t + \dots + a_n t^n \}$ .

$P_n$  ist ein Vektorraum und  $\dim(P_n) = n+1$ .

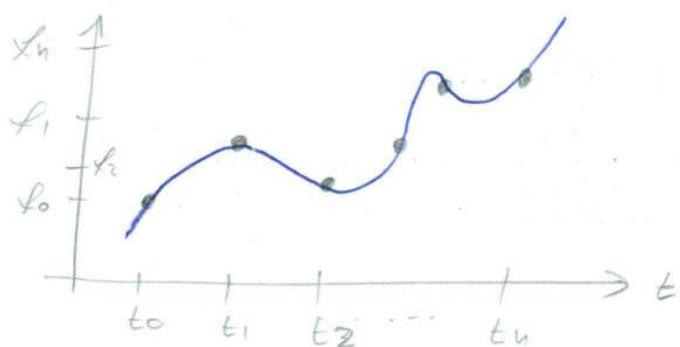
In der Tat,  $\phi: P_n \rightarrow \mathbb{R}^{n+1}$

$$(a_0 + a_1 t + \dots + a_n t^n) \mapsto (a_0, a_1, \dots, a_n)$$

ist ein Isomorphismus. Ohne es explizit zu erwähnen, haben wir die kanonische Basis:  $(1; t; t^2; \dots; t^n)$ , die nach der Abbildung  $\phi$  ist die kanonische Basis von  $\mathbb{R}^{n+1}$ , d.h.,  $\phi(1) = (1, 0, \dots, 0)$ ,  $\phi(t) = (0, 1, 0, \dots, 0), \dots, \phi(t^n) = (0, \dots, 0, 1)$ .

Problem: Gegeben:  $t_0 < t_1 < \dots < t_n$ ,  $n+1$  reelle Zahlen und  $f_0, f_1, \dots, f_n$  andere  $n+1$  reelle Zahlen

Gesucht: Polynom  $p \in P_n$  s.d.  $p(t_i) = f_i, i=0, \dots, n$ .



$\Rightarrow$  Zu lösen:  $\begin{cases} a_0 + a_1 t_0 + \dots + a_n t_0^n = f_0 \\ a_0 + a_1 t_1 + \dots + a_n t_1^n = f_1 \\ \vdots \\ a_0 + a_1 t_n + \dots + a_n t_n^n = f_n \end{cases}$

Betrachtungen: Man kann es auch in Matrixform  
umschreiben:

$$T \cdot \vec{a} = \vec{f}, \text{ mit}$$

$$T = \begin{pmatrix} 1 & t_0 & t_0^2 & \dots & t_0^n \\ 1 & t_1 & t_1^2 & \dots & t_1^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & t_n & t_n^2 & \dots & t_n^n \end{pmatrix}, \quad \vec{a} = \begin{pmatrix} a_0 \\ a_1 \\ \vdots \\ a_n \end{pmatrix}, \quad \vec{f} = \begin{pmatrix} f_0 \\ f_1 \\ \vdots \\ f_n \end{pmatrix}.$$

Das Problem ist immer lösbar, wenn  $t_0, \dots, t_n$  alle verschieden sind, weil dann  $T$  ist invertierbar. ( $\Rightarrow$  Übung).

$$\Rightarrow \vec{a} = T^{-1} \vec{f} \text{ ist die Lösung.}$$

Frage: Wie findet man die Lösung (effizient)?

## 5.2) Gauß-Verfahren.

### 5.2.1) Numerisches Beispiel:

Teil 1:

$$\begin{cases} 4x_1 + 8x_2 + 12x_3 = 4 \\ 3x_1 + 8x_2 + 13x_3 = 5 \\ 2x_1 + 9x_2 + 18x_3 = 11 \end{cases}$$

- ① Pivot:
- Normalisieren die erste Gleichung, d.h., in der Form  $x_1 + \dots = \dots$  bringen.
  - Dann entfernen "x<sub>1</sub>" aus den 2. und 3. Gleichungen.

$$\Rightarrow \begin{cases} x_1 + 2x_2 + 3x_3 = 1 \\ 2x_2 + 4x_3 = 2 \\ 5x_2 + 12x_3 = 9 \end{cases}$$

② Neues Pivot:  
 . Normalisieren 2. Gleichung  
 . Dann, entfernen "x<sub>3</sub>" aus der 3. Gleichung.

$$\Rightarrow \begin{cases} x_1 + 2x_2 + 3x_3 = 1 \\ x_2 + 2x_3 = 1 \\ 2x_3 = 4 \end{cases}$$

③ Pivot  $\Rightarrow \begin{cases} x_1 + 2x_2 + 3x_3 = 1 \\ x_2 + 2x_3 = 1 \\ x_3 = 2 \end{cases}$

Teil 2: ④ Aus 2. Gleichung entfernen "x<sub>3</sub>".

$$\Rightarrow \begin{cases} x_1 + 2x_2 + 3x_3 = 1 \\ x_2 = -3 \quad (\equiv 1 - 2 \cdot 2) \\ x_3 = 2 \end{cases}$$

⑤ Aus 1. Gleichung entfernen "x<sub>2</sub>" und "x<sub>3</sub>"

$$\Rightarrow \begin{cases} x_1 = 1 \quad (\equiv 1 - 2 \cdot (-3) - 3 \cdot 2 = 1) \\ x_2 = -3 \\ x_3 = 2 \end{cases}$$

Zu lösen:

$$\begin{cases} a_{11}x_1 + \dots + a_{1n}x_n = b_1 \\ \vdots \\ a_{nn}x_1 + \dots + a_{nn}x_n = b_n \end{cases}, \quad (A \cdot x = b)$$

$$A \vec{x} = \vec{b} \text{ mit } A = \begin{pmatrix} a_{11} & \dots & a_{1n} \\ \vdots & \ddots & \vdots \\ a_{nn} & \dots & a_{nn} \end{pmatrix}, \vec{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}, \vec{b} = \begin{pmatrix} b_1 \\ \vdots \\ b_n \end{pmatrix}.$$

• Steien  $A^{(k)}$  und  $b^{(k)}$  die Matrizen nach dem  $(k-1)$ -te Schritt.

$$\left\{ \begin{array}{l} x_1 + a_{12}^{(k)}x_2 + a_{13}^{(k)}x_3 + \dots + a_{1n}^{(k)}x_n = b_1^{(k)} \\ x_2 + a_{23}^{(k)}x_3 + \dots + a_{2n}^{(k)}x_n = b_2^{(k)} \\ \vdots \\ x_{k-1} + a_{k-1,k}^{(k)}x_k + \dots + a_{k-1,n}^{(k)}x_n = b_{k-1}^{(k)} \\ a_{kk}^{(k)}x_k + \dots + a_{kn}^{(k)}x_n = b_k^{(k)} \\ \vdots \\ a_{n,k}^{(k)}x_k + \dots + a_{n,n}^{(k)}x_n = b_n^{(k)} \end{array} \right.$$

⇒ Im  $k$ -te Schritt:  $a_{kk}^{(k)}$  =  $k$ -te Pivot.

Setze:  $a_{k,e}^{(k+1)} := \frac{a_{k,e}^{(k)}}{a_{kk}^{(k)}}$  für  $e = k+1, \dots, n$

$$\text{und } b_k^{(k+1)} := \frac{b_k^{(k)}}{a_{kk}^{(k)}}$$

Für  $i = k+1, \dots, n$ :  $a_{i,e}^{(k+1)} := a_{i,e}^{(k)} - a_{ik}^{(k)} \cdot a_{k,e}^{(k)}$

für  $e = k+1, \dots, n$ .

$$\text{und } b_i^{(k+1)} := b_i^{(k)} - a_{ke}^{(k+1)} \cdot b_k^{(k)}$$

## 5.2.2) Gauss-Algorithmus:

. Input: Matrix  $A \in M_n(\mathbb{R})$  (invertierbar)  
 Vektor  $\vec{b} \in \mathbb{R}^n$

. Output: Vektor  $\vec{x} \in \mathbb{R}^n$  s.d.  $A\vec{x} = \vec{b}$ .

Für  $k=1$  bis  $n-1$ :

• falls  $a_{kk}=0$ , suche das kleinste  $\ell \geq k$  s.d.  $a_{\ell k} \neq 0$   
 und vertausche Zeile  $k$  und  $\ell$ . (\*)

$$\cdot p := 1/a_{kk}$$

• Für  $\ell=k+1$  bis  $n$ :

$$\quad \cdot a_{k,\ell} := a_{k,\ell} \cdot p;$$

$$\cdot b_k := b_k \cdot p$$

• Für  $i=k+1$  bis  $n$

• Für  $\ell=k+1$  bis  $n$

$$\quad \cdot a_{i,\ell} := a_{i,\ell} - a_{i,k} \cdot a_{k,\ell};$$

$$\quad \cdot b_i := b_i - a_{i,k} \cdot b_k;$$

$$\cdot p := 1/a_{nn};$$

$$\cdot b_n := b_n \cdot p;$$

Teil 1: Für  $\ell=n-1$  bis 1:

$$\quad \cdot b_\ell := b_\ell - \sum_{k=\ell+1}^n a_{\ell,k} \cdot b_k$$

Bemerkung: Schnell (\*) funktioniert immer wenn A invertierbar ist. Sousst wäre  $\text{Rank}(A) < n$ !

Frage: Ist es klar?

$\dim(\text{Im}(A))$

(63)

• Wie lange ist die Laufzeit von Gauss-Algorithmus?

Lemma 5.1), Die Laufzeit von Gauss-Algorithmus ist  $\mathcal{O}(n^3)$ .

Beweis: Das folgt aus die drei "for" Schleifen ineinander.

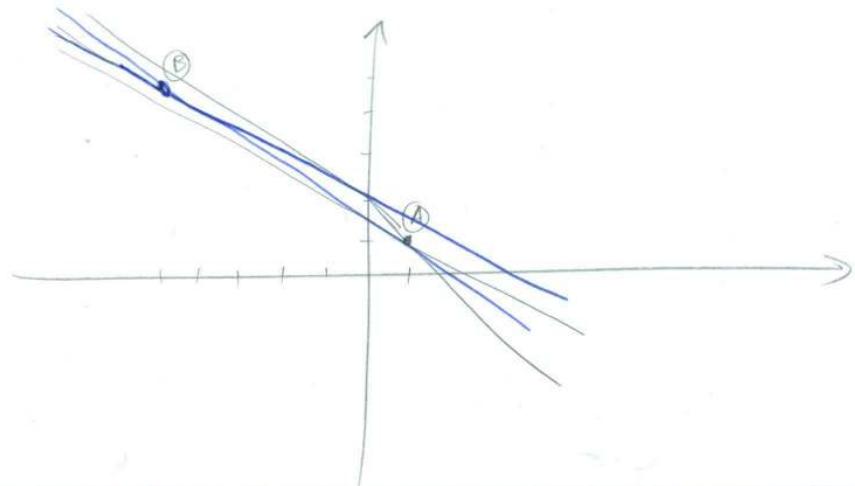
### • 5.2.3) Schlecht Konditionierte Systeme.

• Beispiel:  $\begin{cases} 4,21861\textcircled{3} \cdot x_1 + 6,327917 \cdot x_2 = 10,546530 & (1) \\ 3,14159\textcircled{2} \cdot x_1 + 4,712390 \cdot x_2 = 7,853982 & (2) \end{cases}$

(A)  $\begin{cases} 4,21861\textcircled{1} \cdot x_1 + 6,327917 \cdot x_2 = 10,546530 \\ 3,14159\textcircled{4} \cdot x_1 + 4,712390 \cdot x_2 = 7,853980 \end{cases}$

Lösungen:  $\begin{cases} (A) : x_1 = 1, x_2 = 1 \\ (B) : x_1 = -5, x_2 = 5. \end{cases}$

• Wieso passiert es? Weil (1) und (2) sind fast parallel.



(64)

- Wir werden eine Konditionszahl auch für lineare Systeme definieren.

Für eine Matrix  $A$  wird eine Norm eingeführt durch  $\|A\| := \max_{\|x\|=1} \|Ax\|$ , wobei  $\|x\| = \left(\sum_{k=1}^n x_k^2\right)^{1/2}$ .

- $\|\cdot\|$  ist eine Abbildung von  $M_n(\mathbb{R})$  nach  $\mathbb{R}_+$  mit:

- (1)  $\|A\| > 0$  für alle  $A \neq 0$ ,
- (2)  $\|\alpha A\| = |\alpha| \|A\|$  für alle  $\alpha \in \mathbb{R}$ ,  $A \in M_n(\mathbb{R})$ ,
- (3)  $\|A+B\| \leq \|A\| + \|B\|$  für alle  $A, B \in M_n(\mathbb{R})$ .  
(Dreieckungleichung).

Damit werden wir die Definition des Konditionszahls

$$\text{rc}(A) := \|A\| \cdot \|\tilde{A}\|$$

motivieren. Für praktische Anwendungen, man kann bis  $\lfloor \log_{10} \text{rc}(A) \rfloor$  signifikante Stellen verlieren.

Im vorherigen Beispiel ist:  $\|A\| \approx 8,9 \dots$ ,  $\|\tilde{A}\| \approx 1,5 \cdot 10^7$

$$\Rightarrow \text{rc}(A) \approx 1,4 \cdot 10^8$$

## 5.3) Konditionszahl für lineare Gleichungssysteme.

### 5.3.1) Norm.

Definition 5.2) Eine Abbildung  $\|\cdot\|: \mathbb{R}^n \rightarrow \mathbb{R}$  heisst Norm, falls:

- (a)  $\|x\| \geq 0$  und  $\|x\|=0 \Leftrightarrow x=0$  (Positivität)
- (b)  $\|\lambda x\| = |\lambda| \|x\|, \forall x \in \mathbb{R}^n, \lambda \in \mathbb{R}$  (Homogenität)
- (c)  $\|x+y\| \leq \|x\| + \|y\|, \forall x, y \in \mathbb{R}^n$  (Dreiecksungleichung).

Lemma 5.3) Die Euklidische Norm, definiert durch

$$\|x\| = \|x\|_2 = \sqrt{\sum_{k=1}^n x_k^2}$$

ist eine Norm.

Beweis: (a) Klar.

$$(b) \|\lambda x\| = \sqrt{\sum_{k=1}^n \lambda^2 x_k^2} = \sqrt{\lambda^2} \sqrt{\sum_{k=1}^n x_k^2} = |\lambda| \|x\| \quad \checkmark$$

$$(c) \|x+y\|^2 = \sum_{k=1}^n (x_k + y_k)^2 = \sum_{k=1}^n x_k^2 + \sum_{k=1}^n y_k^2 + 2 \cdot \sum_{k=1}^n x_k \cdot y_k \leq \|x\|^2 + \|y\|^2 + 2 \cdot \sum_{k=1}^n |x_k| \cdot |y_k|$$

$$\leq (\|x\| + \|y\|)^2 = \|x\|^2 + \|y\|^2 + 2 \cdot \|x\| \cdot \|y\|$$

$$\Leftrightarrow \left( \sum_{k=1}^n |x_k| \cdot |y_k| \right)^2 \leq \sum_{k=1}^n x_k^2 \sum_{k=1}^n y_k^2 = \sum_{k=1}^n (|x_k| \cdot |y_k|)^2$$

$$\Leftrightarrow \sum_{k,e=1}^n (|x_k| \cdot |y_k|) \cdot (|x_e| \cdot |y_e|) \leq \sum_{k=1}^n \frac{1}{2} (x_k^2 y_e^2 + y_e^2 x_k^2)$$

Das gilt wegen  $\frac{1}{2}(a^2 + b^2) \geq |ab| \quad (\Leftrightarrow (a-b)^2 \geq 0)$ . #

(66)

Bemerkung: Die Definition 5.2 gilt auch für Matrizen, da  $M_n(\mathbb{R}) \cong \mathbb{R}^{n^2}$  (isomorph).

Definition 5.4) Eine Norm auf  $M_n(\mathbb{R})$  heißt submultiplikativ, falls für alle  $A, B \in M_n(\mathbb{R})$ , gilt

$$\|A \cdot B\| \leq \|A\| \cdot \|B\|.$$

Lemma 5.5) Die spektrale Norm einer Matrix  $A \in M_n(\mathbb{R})$  definiert durch

$$\|A\| := \sup_{\|x\|=1} \|Ax\| \equiv \sup_{\|x\|\neq 0} \frac{\|Ax\|}{\|x\|}$$

ist eine submultiplikative Matrixnorm.

Beweis: ①  $\|A\| = \sup_{\|x\|=1} \|Ax\| \geq 0$ , weil  $\|\cdot\|$  ist eine Norm.

- $A=0 \Rightarrow \|A\|=0 \cdot V$ .
- Zu zeigen, dass  $\{\|A\|=0 \Rightarrow A=0\}$ , man kann zeigen, dass  $A \neq 0 \Rightarrow \|A\| \neq 0$ .
- Aber,  $A \neq 0 \Rightarrow \exists i \text{ s.d. } A_{ii} \neq 0$ . Nehme  $e_i = (0, \dots, \underset{i}{1}, \dots, 0)^T$  die Spalte  $i$ .
- $\Rightarrow \|A\| \geq \|Ae_i\| \geq \underbrace{\|A\|}_{\neq 0} \cdot \|e_i\| = \|A\|$ .

$$\textcircled{b} \quad \|2A\| = \sup_{\|x\|=1} \|2Ax\| = |2| \cdot \sup_{\|x\|=1} \|Ax\| = |2| \cdot \|A\|.$$

$$\textcircled{c} \quad \|A+B\| = \sup_{\|x\|=1} \|Ax+Bx\| \leq \sup_{\|x\|=1} (\|Ax\| + \|Bx\|) \\ \leq \sup_{\|x\|=1} \|Ax\| + \sup_{\|x\|=1} \|Bx\| = \|A\| + \|B\|.$$

$\Rightarrow \|\cdot\|$  ist eine Norm.

• Ist die Norme submultiplikativ? Sei  $B \neq 0$  (Sache klar). (67)

$$\cdot \|A \cdot B\| = \sup_{\|x\| \neq 0} \frac{\|A \cdot Bx\|}{\|x\|}$$

$\Rightarrow$  weil für  $x \neq 0$ ,  
 $\|Bx\| \neq 0$   
 $\Leftrightarrow Bx \neq 0$   
 $\Rightarrow \sup$  wird erreicht für  
 $x \in \text{sd. } \|Bx\| \neq 0$

$$= \sup_{\|Bx\| \neq 0} \frac{\|A \cdot Bx\|}{\|Bx\|} \cdot \frac{\|Bx\|}{\|x\|}$$

$$\leq \sup_{\|Bx\| \neq 0} \frac{\|A \cdot Bx\|}{\|Bx\|} \cdot \sup_{\|Bx\| \neq 0} \frac{\|Bx\|}{\|x\|}$$

$$= \|A\|$$

$$\leq \sup_{\|x\| \neq 0} \frac{\|Bx\|}{\|x\|}$$

$$\leq \|A\| \cdot \|B\|.$$

weil  $\exists x \text{ s.d. } \|x\| \neq 0 \exists x \text{ s.d. } \|Bx\| \neq 0$

• Notationen: Für eine Matrix  $A = (a_{ij})_{1 \leq i, j \leq n} \in M_n(\mathbb{R})$ :

•  $A^t := (a_{j,i})_{1 \leq i, j \leq n} \in M_n(\mathbb{R})$  die zu A transponierte Matrix.

•  $A^{-1}$  ist die Inverse von A (falls A invertierbar)

5.3.2) Jetzt kommen wir zu einer Konditionszahl.

Sei A invertierbar und betrachten wir

$$A\vec{x} = \vec{b}.$$

Was passiert, wenn wir eine Störung auf  $\vec{b}$  machen?  $\vec{b} \rightarrow \vec{b} + \Delta \vec{b}$ .

Dann wird die Lösung  $\vec{x} \rightarrow \vec{x} + \Delta \vec{x}$  mit:

$$A(\vec{x} + \Delta \vec{x}) = \vec{b} + \Delta \vec{b}$$

$$\Rightarrow A \cdot \Delta \vec{x} = \Delta \vec{b}, \text{ d.h., } \Delta \vec{x} = A^{-1} \cdot \Delta \vec{b} = \|A^{-1}\| \cdot \Delta \vec{b}$$

Deshalb ist der relative Fehler:

$$\frac{\|\Delta \vec{x}\|}{\|\vec{x}\|} = \frac{\|A^{-1} \Delta \vec{b}\|}{\|\vec{x}\|} \leq \|A^{-1}\| \cdot \frac{\|\Delta \vec{b}\|}{\|\vec{b}\|} \cdot \frac{\|\vec{b}\|}{\|\vec{x}\|} \leq \|A^{-1}\| \cdot \|A\| \cdot \frac{\|\Delta \vec{b}\|}{\|\vec{b}\|}$$

Deshalb, der relative Fehler <sup>auf  $\vec{b}$</sup>  vergroßert sich bis zum Faktor  $\|\vec{A}^{-1}\| \cdot \|A\|$ .

(68)

Definition 5.6) Sei  $A\vec{x} = \vec{b}$  ein lineares System mit  $A$  invertierbar, dann heißt

$$\kappa(A) := \|\vec{A}^{-1}\| \cdot \|A\|$$

die Konditionszahl dieses Systems.

Bemerkung: Man kann auch andere Normen dazwischen verwenden.

Bemerkung: Aus  $\frac{\|\Delta\vec{x}\|}{\|\vec{x}\|} \leq \kappa(A) \cdot \frac{\|\Delta\vec{b}\|}{\|\vec{b}\|}$  folgt, dass man bis zu  $[\log_{10} \kappa(A)]$  signifikante Stellen während der Lösung von  $A\vec{x} = \vec{b}$  verlieren.

### 5.3.3) Berechnung von $\kappa(A)$ .

Um  $\kappa(A)$  zu berechnen, müssen wir  $\|A\|$  und  $\|\vec{A}^{-1}\|$  berechnen.

Ein Exkurs: Betrachten wir  $n$  Vektoren in  $\mathbb{R}^n$ ,  $\vec{v}_1, \dots, \vec{v}_n$ , mit folgender Eigenschaft:

$$\bullet (\vec{v}_i, \vec{v}_j) := \sum_{k=1}^n v_i(k) v_j(k) = \delta_{i,j} = \begin{cases} 1, & \text{für } i=j, \\ 0, & \text{sonst.} \end{cases}$$

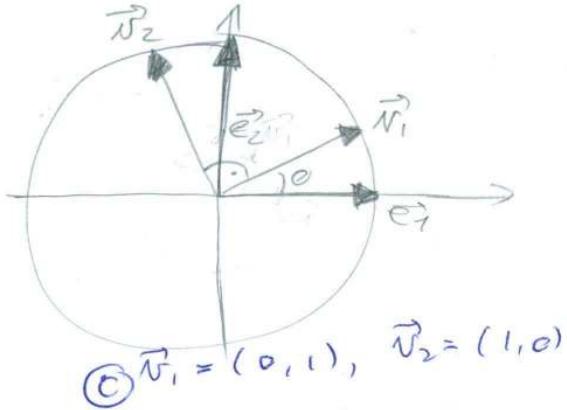
(Skalarprodukt)

Geometrisch gesehen, die Länge des  $\vec{v}_i$  sind 1, weil  $\|\vec{v}_i\|^2 = \sum_{k=1}^n v_i(k)^2 = 1$ , und der Winkel zwischen zwei Vektoren ist  $90^\circ$  (für alle Paare), d.h. orthogonal.

(69)

Beispiel: In  $\mathbb{R}^2$ : ①  $\vec{e}_1 = (1, 0)$ ,  $\vec{e}_2 = (0, 1)$   
 ↪ haben diese Eigenschaft,

②  $\vec{v}_1 = (\cos \theta, \sin \theta)$ ;  $\vec{v}_2 = (-\sin \theta, \cos \theta)$   
 auch ( $\forall \theta \in [0, 2\pi]$ ).



Wieso orthogonal? Weil der Winkel  $\varphi \in [0, \pi]$  zwischen

$$\text{Bsp: } \begin{array}{l} \text{① } R = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \\ \text{② } R = \begin{pmatrix} \cos \theta & -\sin \theta \\ \sin \theta & \cos \theta \end{pmatrix} \\ \text{③ } R = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \end{array}$$

die Geraden  $\{\lambda \vec{v}_1, \lambda \in \mathbb{R}\}$  und  $\{\mu \vec{v}_2, \mu \in \mathbb{R}\}$  ist durch  
 $\varphi = \arccos \left( \frac{(\vec{v}_1, \vec{v}_2)}{\|\vec{v}_1\| \cdot \|\vec{v}_2\|} \right)$  gegeben.

Definieren nun die Matrix  $R = (\vec{v}_1, \dots, \vec{v}_n)$ , d.h.,

$$R_{ij} = v_i(j).$$

Dann,  $R^T R = \mathbb{I} = R R^T$  \*

$$\begin{aligned} \text{In der Tat, } (R^T R)_{ij} &= \sum_{k=1}^n (R^T)_{ik} \cdot (R)_{kj} \\ &= \sum_{k=1}^n R_{ki} \cdot R_{kj} \stackrel{\text{df.}}{=} \sum_{k=1}^n v_i(k) v_j(k) = \delta_{ij}. \end{aligned}$$

- Eine reelle Matrix mit der Eigenschaft  $\oplus$  heisst Orthogonale Matrix.
- Geometrisch:  $R$  macht eine Drehung zwischen die kanonische Basis von  $\mathbb{R}^n$ ,  $\{\vec{e}_1, \dots, \vec{e}_n\}$  und  $\{\vec{v}_1, \dots, \vec{v}_n\}$ :  $\boxed{\vec{v}_k = R \vec{e}_k}$

• Definiere nun  $A = R \begin{pmatrix} \overbrace{\lambda_1, 0}^{\stackrel{:=}{\lambda}} \\ \vdots \\ 0 \end{pmatrix} R^t$ .

$A$  hat die Eigenschaften:

$$(a) A = A^t$$

$$(b) A \vec{v}_i = \lambda_i \vec{v}_i.$$

• In der Tat,  $A^t = (R \begin{pmatrix} \lambda_1, 0 \\ \vdots \\ 0 \end{pmatrix} R^t)^t = \underbrace{(R^t)^t}_{=R} \underbrace{\begin{pmatrix} \lambda_1, 0 \\ \vdots \\ 0 \end{pmatrix}}_{= \begin{pmatrix} \lambda_1, 0 \\ \vdots \\ 0 \end{pmatrix}} R^t$

und  $(A \vec{v}_i)(e) = \sum_{e=1}^n Q_{k,e} \cdot \lambda_e \cdot \sum_{j=1}^n (Q^t)_{ej} v_i(j)$

$$= \sum_{j=1}^n Q_{je} \lambda_i v_i(j) =$$

$$= \sum_{j=1}^n Q_{je} N_i(j) = \delta_{ei}$$

$$= \sum_{e=1}^n v_i(e) \delta_{ei} = \lambda_i v_i(e).$$

Bemerkung: In Lineare Algebra wird es gezeigt, dass jede symmetrische Matrix  $A$  kann als  $\text{(reelle)}$   $A = R \begin{pmatrix} \lambda_1, 0 \\ \vdots \\ 0 \end{pmatrix} R^t$  dargestellt sein.  
(mit  $R$  orthogonal),  $\lambda_1, \dots, \lambda_n \in \mathbb{R}$ .

Ende der Excuses.

• Sei  $A \vec{x} = \vec{b}$  unser lineares Gleichungssystem.

Setze  $B := A^t \cdot A$ . Dann  $B = B^t$ , so  $\exists \lambda_1, \dots, \lambda_n \in \mathbb{R}$

und  $\vec{v}_1, \dots, \vec{v}_n \in \mathbb{R}^n$  s.d.  $B = R \begin{pmatrix} \lambda_1, 0 \\ \vdots \\ 0 \end{pmatrix} R^t$  und  $B \vec{v}_i = \lambda_i \vec{v}_i$ .

$$\Rightarrow \vec{v}_i^t \cdot B \cdot \vec{v}_i = \lambda_i \underbrace{\vec{v}_i^t \cdot \vec{v}_i}_{=1} = \lambda_i. \stackrel{:=}{\lambda} 1$$

$$\Rightarrow \vec{v}_i^t \cdot A^t \cdot A \vec{v}_i = \lambda_i$$

$$\Leftrightarrow \|A \vec{v}_i\|^2 \Rightarrow \boxed{\lambda_i \geq 0}.$$

(71)

- Ordne  $\lambda_1, \dots, \lambda_n$  wie folgt:  $0 \leq \lambda_1 \leq \dots \leq \lambda_n$ . Dann ist

Lemma 5.7)  $\|A\| = \sqrt{\lambda_n}$

$$\begin{aligned}
 \text{Beweis: } \|A\|^2 &= \left( \max_{x \neq 0} \frac{\|Ax\|}{\|x\|} \right)^2 = \max_{x \neq 0} \frac{\|Ax\|^2}{\|x\|^2} \\
 &= \max_{x \neq 0} \frac{x^t A^t Ax}{x^t x} = \max_{x \neq 0} \frac{x^t Bx}{x^t x} \\
 &= \max_{x \neq 0} \frac{x^t R^t A^t R x}{x^t R^t R x} \stackrel{y = R^t x}{=} \max_{y \neq 0} \frac{y^t A y}{y^t y} \\
 &= \max_{y \neq 0} \frac{\sum_{k=1}^n \lambda_k y_k^2}{\sum_{k=1}^n y_k^2} \leq \lambda_n \quad \text{wobei Gleichheit} \\
 &\quad \text{ist für } y = \vec{v}_n.
 \end{aligned}$$

$$\Rightarrow \|A\|^2 = \lambda_n \Rightarrow \|A\| = \sqrt{\lambda_n}.$$

Mittwoch, 24.11.

(72)

## 5.4) LU-Zerlegung

( $\equiv$  LR-Zerlegung).

Die Laufzeit um  $A\vec{x} = \vec{b}$  zu lösen ist  $\mathcal{O}(n^3)$ . Falls wir eine Reihe von Gleichungssystemen mit einem gegebenen  $A$  und verschiedene  $\vec{b}$  haben, kann man die folgende Zerlegung von  $A$  benutzen:

Satz 5.8 Falls beim Gauss'schen Algorithmus keine Zeilenumtauschungen stattfinden, d.h. jede der Hauptminoren eine reguläre Matrix ist, dann  $\exists!$  Matrizen  $L$  und  $U$  mit:

- ①  $L$  eine untere Dreieckmatrix mit 1 auf der Diagonale,
- ②  $U$  eine obere Dreieckmatrix,
- ③  $A = L \cdot U$ .

Bew.: Um die LU-Zerlegung zu erhalten, brauchen wir  $\mathcal{O}(n^3)$  Laufzeit (gleicher wie Gauss) aber dann kann man das System in nur  $\mathcal{O}(n^2)$  Laufzeit lösen.

Idee: Beweis: Das folgt aus dem Gauss'schen Algorithmus wenn man die Rechnungen auf den Zeilen explizit als Matrix-Produkt darstellt.

1. Schritt:

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots \\ a_{21} & a_{22} & \cdots \\ \vdots & \vdots & \ddots \end{pmatrix}$$

④ Ohne Normalisierungsschritt.

Sei  $L^{(1)} := \begin{pmatrix} 1 & & & \\ -\frac{a_{21}}{a_{11}} & 1 & & \\ -\frac{a_{31}}{a_{11}} & 0 & 1 & \\ \vdots & 0 & \ddots & \ddots \end{pmatrix}$  und

$$A^{(1)} := \begin{pmatrix} a_{11} & a_{12} & \dots & a_{13} \\ 0 & a_{22} - \frac{a_{21} \cdot a_{12}}{a_{11}} & a_{23} - \frac{a_{21} \cdot a_{13}}{a_{11}} \\ 0 & a_{32} - \frac{a_{31} \cdot a_{12}}{a_{11}} & a_{33} - \frac{a_{31} \cdot a_{13}}{a_{11}} \\ \vdots & \vdots & \ddots & \ddots \end{pmatrix} \equiv \begin{pmatrix} a_{11}^{(1)} & a_{12}^{(1)} & a_{13}^{(1)} \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} \\ 0 & a_{32}^{(1)} & a_{33}^{(1)} \\ \vdots & \vdots & \ddots & \ddots \end{pmatrix}$$

Dann,  $L^{(1)} \cdot A = A^{(1)}$ , d.h.,

$$A = (L^{(1)})^{-1} \cdot A^{(1)}.$$

Die Inverse von  $L^{(1)}$  ist die folgende:

$$(L^{(1)})^{-1} = \begin{pmatrix} 1 & & & \\ \frac{a_{21}}{a_{11}} & 1 & & \\ \frac{a_{31}}{a_{11}} & 0 & 1 & \\ \vdots & 0 & \ddots & \ddots \end{pmatrix}$$

In der Tat:  $L^{(1)} = \mathbb{I} + \ell^{(1)} \cdot e_1^t$  mit

$$\ell^{(1)} = \begin{pmatrix} 0 \\ \ell_2^{(1)} \\ \vdots \\ \ell_n^{(1)} \end{pmatrix}, e_1^t = (1, 0, \dots, 0).$$

$$\text{und } (L^{(1)})^{-1} = \mathbb{I} - \ell^{(1)} \cdot e_1^t.$$

$$\begin{aligned} \Rightarrow (L^{(1)})^{-1} \cdot L^{(1)} &= (\mathbb{I} - \ell^{(1)} \cdot e_1^t)(\mathbb{I} + \ell^{(1)} \cdot e_1^t) \\ &= \mathbb{I} - \cancel{\ell^{(1)} \cdot e_1^t} + \cancel{\ell^{(1)} \cdot e_1^t} - \underbrace{\ell^{(1)} \cdot e_1^t \cdot \ell^{(1)} \cdot e_1^t}_{=0} \\ &= \mathbb{I}. \end{aligned}$$

(74)

Am 2. Schritt: Sei  $L^{(2)} := \begin{pmatrix} 1 & & & \\ 0 & 1 & & \\ \vdots & -\frac{a_{32}^{(1)}}{a_{22}^{(1)}} & 1 & \\ 0 & -\frac{a_{42}^{(1)}}{a_{22}^{(1)}} & 0 & 1 \end{pmatrix}$

und  $A^{(2)} := \begin{pmatrix} a_{11}^{(1)} & a_{12}^{(1)} & a_{13}^{(1)} & \\ 0 & a_{22}^{(1)} & a_{23}^{(1)} & \dots \\ 0 & 0 & a_{33}^{(1)} - \frac{a_{32}^{(1)} a_{23}^{(1)}}{a_{22}^{(1)}} & a_{23}^{(1)} \end{pmatrix}$

So dass  $L^{(2)} A^{(1)} = A^{(2)}$

$$\Rightarrow A^{(1)} = (L^{(2)})^{-1} \cdot A^{(2)}$$

mit  $(L^{(2)})^{-1} = \begin{pmatrix} 1 & 0 & 0 & \\ 0 & 1 & 0 & \\ \vdots & a_{32}^{(1)} / a_{22}^{(1)} & 1 & \\ 0 & a_{42}^{(1)} / a_{22}^{(1)} & 0 & \end{pmatrix}$

$$\Rightarrow A = (L^{(1)})^{-1} \cdot (L^{(2)})^{-1} \cdot A^{(2)}$$

Man macht so weiter bis  $A^{(n-1)}$ , die eine obere Dreieckmatrix ist:

$$A = \underbrace{(L^{(1)})^{-1} \cdot (L^{(2)})^{-1} \cdots (L^{(n-1)})^{-1}}_{:= L} \cdot \underbrace{A^{(n-1)}}_{:= U}$$

Man muss noch zeigen, dass  $L$  eine untere Dreieckmatrix mit 1 auf der Diagonale:

Seien  $B_1$  und  $B_2$  zwei Matrizen dieser Form,

d.h.,  $B_1 = \begin{pmatrix} 1 & & \\ * & 0 & \\ & & 1 \end{pmatrix}$  und  $B_2 = \begin{pmatrix} 1 & & \\ * & 0 & \\ & & 1 \end{pmatrix}$ .

Dann: Für  $j > i$ :  $(B_1 \cdot B_2)_{i,j} = \sum_{k=1}^n \underbrace{(B_1)_{ik}}_{=0 \text{ für } k > i} \underbrace{(B_2)_{kj}}_{=0 \text{ für } k < i} = 0$ .

Für  $j = i$ :  $(B_1 \cdot B_2)_{i,i} = (B_1)_{ii} \cdot (B_2)_{ii} = 1$ .

Zuletzt, die Eindeutigkeit: Nehmen wir an,  $\exists L, \tilde{L}, U, \tilde{U}$   
s.d.  $A = L \cdot U = \tilde{L} \cdot \tilde{U}$  und  $\textcircled{a}, \textcircled{b}, \textcircled{c}$  gelten.

Dann,  $L^{-1} \tilde{L} = U \tilde{U}^{-1}$ .

Aber,  $L^{-1} \tilde{L}$  ist eine untere Dreiecksmatrix  
und  $U \tilde{U}^{-1}$  eine obere Dreiecksmatrix.  
und dazu,  $\tilde{L} \tilde{L}^{-1}$  hat 1 auf der Diagonale.

$$\Rightarrow L^{-1} \tilde{L} = U \tilde{U}^{-1} = \mathbb{1}.$$

$$\Rightarrow \tilde{L} = L \text{ und } U = \tilde{U}.$$

Anwendung: Wenn wir die LU-Zerlegung  
(Siehe auch) haben, können wir das Problem  
Beispiel, siehe  $\textcircled{a}$ )  $A\vec{x} = \vec{b}$  so lösen:

$$LU\vec{x} = \vec{b} \Leftrightarrow \begin{cases} L\vec{y} = \vec{b}, \\ U\vec{y} = \vec{x}. \end{cases}$$

Die Lösung von  $L\vec{y} = \vec{b}$  und dann  
 $U\vec{y} = \vec{x}$  erfolgen mittels eines vereinfachten  
Gaußverfahrens, wie folgt:

Algorithmus 5.9) Gauß für untere Dreieckmatrizen)

Inp: Unter Dreieckmatrix A, Vektor  $\vec{b}$   
Out: Vektor  $\vec{x} \parallel$  Lösung von  $A\vec{x} = \vec{b}$

for ( $i = 0$ ;  $i < n$ ;  $i++$ )

$$\{ x[i] = b[i];$$

for ( $j = 0$ ;  $j < i$ ;  $j++$ )

$$\{ x[\delta] = x[\delta] - A[\delta+i:\delta] \cdot x[i]; \}$$

$$\} x[i] = x[i] / A[i+1:i+1];$$

Gibt  $A[i:j]$  aus, da  $A$  als Vektor gespeichert ist.

Dieses Algorithmus entspricht das folgende:

$$b_i = \sum_{j=1}^i a_{ij} x_j = a_{ii} x_i + \sum_{j=1}^{i-1} a_{ij} x_j$$

$$\Leftrightarrow x_i = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1}^{i-1} a_{ij} x_j \right).$$

Wenn  $A$  eine obere Dreieckmatrix ist,

dann,  $b_i = \sum_{j=1}^n a_{ij} x_j = a_{ii} x_i + \sum_{j=i+1}^n a_{ij} x_j$

$$\Leftrightarrow x_i = \frac{1}{a_{ii}} \left( b_i - \sum_{j=i+1}^n a_{ij} x_j \right), i=1, \dots, n.$$

Deshalb haben wir das folgende Algorithmus.

Algorithmus 5.10) (Gauss für obere Dreieckmatrix).

In put: Obere Dreieckmatrix  $A$ , Vektor  $\vec{b}$ .

Output: Vektor  $\vec{x}$  // Lösung var

```

for (i=n; i>0; i--)
  {
     $x[i] = b[i];$ 
    for (j=i+1; j<n; j++)
      {
         $x[j] = x[j] - A[i+n-j] \cdot x[i];$ 
      }
     $x[i] = x[i] / A[i+n-i];$ 
  }
  
```

Lemma 5.11) Algorithmen 5.10 und 5.9 haben  
eine Laufzeit  $O(n^2)$ .

Beweis: Es folgt aus den 2 ineinander "for"-Schleifen.

Frage: Wie ändert sich die Aussage von Satz 5.8 falls A eine Matrix voller Rang ist, aber nicht alle Hauptminoren regulär sind? (77)

- Wir müssen dazu einige Zeilen vertauschen.  
Das wird durch Permutationsmatrizen geklappt.

Definition 5.12) Sei  $\sigma \in S_n$  eine Permutation von  $\{1, \dots, n\}$ . Dann ist die assoziierte Permutationsmatrix  $P = (P_{i,j})$  durch

$$P_{i,j} = \begin{cases} 1, & \text{für } \sigma(i) = j, \\ 0, & \text{sonst.} \end{cases}$$

Bemerkung: Permutationsmatrizen sind orthogonal.  
In der Tat:

$$(P^T P)_{i,i} = \sum_{k=1}^n P_{ki} P_{ki} = \begin{cases} 1, & \text{für } i=i, \\ 0, & \text{sonst.} \end{cases}$$

Lemma 5.13) Sei  $A \in M_n(\mathbb{R})$  und  $\sigma \in S_n$ . Sei  $P = P(\sigma)$  die assoziierte Permutationsmatrix.

Dann  $\tilde{A} = P \cdot A$   
entspricht die Matrix  $\tilde{A}$  mit vertauschten Zeilen.

$$(\tilde{A})_{i,j} = A_{\sigma(i),j}$$

Beweis:  $(\tilde{A})_{i,j} = \sum_{k=1}^n P_{ik} \cdot A_{\sigma(k),j} = A_{\sigma(i),j} \cdot \#$

$$\# = \begin{cases} 1, & \text{für } k=\sigma(i), \\ 0, & \text{sonst.} \end{cases}$$

Satz 5.14) Sei  $A$  eine Matrix voller Rang.  
 Dann  $\exists$  eine Permutationsmatrix  $P$ ,  
 eine untere Dreiecksmatrix  $L$  mit 1  
 auf der Diagonale, und eine  
 obere Dreiecksmatrix  $U$  s.d.

$$P \cdot A = L \cdot U.$$

Bemerkung:  $P \cdot A = LU$  heisst "spaltenpivotisierte LU-Zerlegung".

Beweis: Idee: Ähnlich wie bei Satz 5.8, aber  
 dazu muss man ggf. Zeile vertauschen  
 (falls  $A_{k,k}^{(k-1)} = 0$ ).

1. Schritt: Da  $A$  voller Rang ist, existiert  
 ein  $p \geq 1$  s.d.  $A_{p,1} \neq 0$ .

Sei  $p(1) := \min \{k \geq 1 \mid A_{k,1} \neq 0\}$ .

Dann, wählt man die Permutation

$$\pi_1 = \begin{pmatrix} 1 & 2 & \dots & p(1) & \dots & n \\ p(1) & 2 & \dots & 1 & \dots & n \end{pmatrix}, P_1 := P(\pi_1).$$

$$\Rightarrow \tilde{A} := P_1 \cdot A.$$

Da  $(P_1)^{-1} = P_1^t$ , haben wir

$$A = P_1^t \cdot \tilde{A} \text{ und } \tilde{A}_{11} \neq 0.$$

Dann machen wir 1 Schritt wie beim  
 Satz 5.8; i.e., finden wir  $L^{(1)}$  und  $A^{(1)}$   
 s.d.  $L^{(1)} A^{(1)} = \tilde{A}$ .

$$\Rightarrow A = P_1^t \cdot (L^{(1)})^{-1} A^{(1)}.$$

K2,3,...,n. Schritt: analog ( $P^{(k)} \rightarrow p(k) = \min \{j \geq k \mid A_{j,k}^{(k-1)} \neq 0\}$ ).

Wir erhalten:

$$A = P_1^t \cdot (L^{(1)})^{-1} P_2^t \cdot (L^{(2)})^{-1} \cdots P_{n-1}^t \cdot (L^{(n-1)})^{-1} \cdot A^{(n-1)}.$$

Letztlich sei  $P := P_{n-1} \dots P_1$ , dann,

$$\begin{aligned} P \cdot A &= P_{n-1} \cdots \underbrace{P_1 P_1^t (L^{(1)})^{-1}}_{=I} P_2^t (L^{(2)})^{-1} \cdots P_{n-1}^t (L^{(n-1)})^{-1} A^{(n-1)} \\ &= P_{n-1} \cdots P_2 (L^{(1)})^{-1} P_2^t \cdots P_{n-1}^t \\ &\quad \cdot P_{n-1} \cdots P_3 (L^{(2)})^{-1} P_3^t \cdots P_{n-1}^t \\ &\quad \vdots \\ &\quad P_{n-1} (L^{(n-2)})^{-1} P_{n-1}^t \\ &\quad (L^{(n-1)})^{-1} \cdot \tilde{A}^{(n-1)}. \end{aligned}$$

Sei, setze  $\tilde{L}^{(k)} = P_{n-1} \cdots P_{k+1} \cdot L^{(k)} \cdot P_{k+1}^t \cdots P_{n-1}^t$   
 $\Rightarrow (\tilde{L}^{(k)})^{-1} = P_{n-1} \cdots P_{k+1} (L^{(k)})^{-1} P_{k+1}^t \cdots P_{n-1}^t$   
 und  $P \cdot A = \underbrace{(\tilde{L}^{(1)})^{-1} \cdots (\tilde{L}^{(n-1)})^{-1}}_{=: L} \cdot \underbrace{\tilde{A}^{(n-1)}}_{=: U}$

Noch zu zeigen:  $L$  ist eine untere Dreiecksmatrix mit "1" auf der Diagonale.

Falls  $P_e \neq I$ , dann  $P_e$  in  $P_e X$  vertauscht Zeile  $e$  mit irgendeiner anderen Zeile  $m \neq e$ . und  $X P_e^t$  dasselbe aber auf Spalten.

$$\Rightarrow \text{Für } k: e_k^t P_e = e_k^t.$$

$$\begin{aligned} \text{Sei, } P_{n-1} \cdots P_{k+1} \tilde{L}^{(k)} P_{k+1}^t \cdots P_{n-1}^t &= \\ &= P_{n-1} \cdots P_{k+1} (I - e_m^t \cdot e_k) P_{k+1}^t \cdots P_{n-1}^t \\ &= I - \underbrace{P_{n-1} \cdots P_{k+1} e_m^t}_{\text{Vektor der Form }} e_k^t. \end{aligned}$$

$\Rightarrow \tilde{L}^{(k)}$  unter  $\exists \Delta$  mit "diage(1), f4"  
 $\Rightarrow$  auch für  $L$ .

#

$$\begin{pmatrix} 0 \\ 1 \\ \vdots \\ * \\ \vdots \\ 1 \end{pmatrix}^t$$

• Aus Satz 5.14 erhält man das folgende  
 (dem Beweis von)

(80)

### Algorithmus:

Eingabe: Reguläre Matrix  $A \in \mathbb{K}^{n \times n}$ .

Ausgabe: Spaltenpivisierte LU-Zerlegung von  $A$ .

$$\cdot U = A$$

$$\cdot L = \mathbb{I}$$

$$\cdot P = \mathbb{I}$$

for ( $k=1; k \leq n; k++$ )

{ Wähle das kleinste  $i > k$  s.d.  $U_{ik} \neq 0$  }

. vertausche  $i$  und  $k$ . Zeilen von  $P, R, L$ ;

for ( $j=k+1; j \leq n; j++$ )

$$\cdot L_{jk} = \frac{U_{j,k}}{U_{k,k}}$$

. for ( $m=k; m < n; m++$ )

$$\{ U_{jm} = U_{jm} - L_{km} \cdot U_{k,m} \}$$

}

}

Beispiel:

$$A = \begin{pmatrix} -1 & 3 & -1 \\ 3 & -8 & 4 \\ 2 & -2 & 4 \end{pmatrix} = \underbrace{\begin{pmatrix} 1 & 0 & 0 \\ -3 & 1 & 0 \\ -2 & 0 & 1 \end{pmatrix}}_L \underbrace{\begin{pmatrix} -1 & 3 & -1 \\ 0 & 1 & 1 \\ 0 & 4 & 2 \end{pmatrix}}_U$$

$$= \underbrace{\begin{pmatrix} 1 & 0 & 0 \\ -3 & 1 & 0 \\ -2 & 4 & 1 \end{pmatrix}}_L \cdot \underbrace{\begin{pmatrix} -1 & 3 & -1 \\ 0 & 1 & 1 \\ 0 & 0 & -2 \end{pmatrix}}_U$$

$$\Rightarrow \text{Für } b = \begin{pmatrix} 2 \\ -3 \\ 6 \end{pmatrix}: \quad \underbrace{L}_{U} y = b \Rightarrow y = \begin{pmatrix} 2 \\ 3 \\ -2 \end{pmatrix}$$

$$\text{und dann } Ux = y \Rightarrow x = \begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}.$$

## 5.5) Störungstheorie für lineare Gleichungssysteme

Das ist eine Erweiterung von Kapitel 5.3.2,  
wo wir eine Störung von  $\vec{b}$  gemacht haben.

Frage: Wie wächst der relative Fehler  
wenn wir  $A$  und  $\vec{b}$  leicht stören?

Bemerkungen: ① Bislang haben wir nur die Spezialisierungen benutzt. Das ist die "beste", aber nicht immer schnell zu berechnen.

② Weitere submultiplikative Normen:

$$\textcircled{a} \quad \|A\| = \max_{1 \leq i, j \leq n} |a_{ij}| \quad (\text{Maximumnorm})$$

$$\textcircled{b} \quad \|A\|_F := \left( \sum_{i,j=1}^n |a_{ij}|^2 \right)^{1/2} \quad (\text{Frobeniusnorm}).$$

Notation:  $\{ \lambda \} := \max \{ |\lambda| \mid \lambda \text{ ist Eigenwert von } A \}$   
 $= \max \{ |\lambda| \mid \exists x \neq 0 \text{ mit } Ax = \lambda x \}.$

Falls  $A = R \Lambda R^{-1}$ , dann

Spezialisierung ( $A$ ) =  $\beta(A)$ , sonst in general  $\beta(A) \leq \|A\|$ .

Sei  $\Delta A$  die Störung von  $A$ ,  
 $\Delta b$  die Störung von  $b$  und  $\Delta x$   
die darauf folgende Störung von  $x$ , d.h.,

$$(A + \Delta A)(x + \Delta x) = b + \Delta b$$

mit  $Ax = b$ .

Dann:  $\underbrace{Ax}_{=} + \underbrace{\Delta A x}_{=} + (A + \Delta A)\Delta x = b + \Delta b$

Unter die Annahme, dass nicht nur  $A$  aber auch  $A + \Delta A$  invertierbar ist, erhalten wir:

$$\Delta x = (A + \Delta A)^{-1} (\Delta b - \Delta A \cdot x)$$

Dehalb müssen wir die Norm von  $(A + \Delta A)^{-1}$  abschätzen.

Lemma 5.15: Sei  $\|A\| < 1$ . Dann die Neumannsche Reihe  $\sum_{k=0}^{\infty} A^k$  konvergiert,

$$(I - A)^{-1} = \sum_{k=0}^{\infty} A^k$$

und

$$\|(I - A)^{-1}\| \leq \frac{1}{1 - \|A\|}.$$

Beweis: Aus  $\|A\| < 1$  folgt  $\lambda(A) < 1$ , d.h.  $1$  ist kein Eigenwert von  $A$  und deshalb die Eigenwerte von  $I - A$  sind  $1 - \lambda_i(A)$  mit  $\lambda_i(A)$  den Eigenwerten von  $A \Rightarrow I - A$  hat keinen Eigenwert  $0$ , d.h., invertierbar.

$$(I - A) \sum_{k=0}^n A^k = I - A^{n+1}$$

und  $\lim_{n \rightarrow \infty} A^n = 0$ , weil  $\|A^n\| \leq \|A\|^n \xrightarrow{n \rightarrow \infty} 0$ .

$$\text{Letztlich, } \|(I - A)^{-1}\| \leq \sum_{k=0}^{\infty} \|A^k\| \leq \sum_{k=0}^{\infty} \|A\|^k = \frac{1}{1 - \|A\|}.$$

$$(A \cdot e_i)^{(j)} = A_{ij}$$

$$\|A \cdot e_i\| = 0 \Leftrightarrow A_{ij} = 0 \quad \forall i = 1, \dots, n$$

$$\text{und } \|A\| \geq \|Ae_j\|$$

Mit Hilfe von Lemma 5.15 erhält man die folgende Abschätzung.

Lemma 5.16) Sei  $A$  invertierbar,  $\|\Delta A\| < \frac{1}{\|\tilde{A}^{-1}\|}$ . Dann ist auch  $A + \Delta A$  invertierbar mit

$$\|(A + \Delta A)^{-1}\| \leq \frac{\|\tilde{A}^{-1}\|}{1 - \|\tilde{A}^{-1}\| \cdot \|\Delta A\|}.$$

Beweis:  $\|\tilde{A}^{-1} \Delta A\| \leq \|\tilde{A}^{-1}\| \cdot \|\Delta A\| < 1 \Rightarrow (\mathbb{I} + \tilde{A}^{-1} \Delta A)^{-1}$  existiert und

$$\|(\mathbb{I} + \tilde{A}^{-1} \Delta A)^{-1}\| \leq \frac{1}{1 - \|\tilde{A}^{-1} \Delta A\|} \leq \frac{1}{1 - \|\tilde{A}^{-1}\| \cdot \|\Delta A\|}.$$

$$\text{Dazu: } (A + \Delta A)^{-1} = [A(\mathbb{I} + \tilde{A}^{-1} \Delta A)]^{-1}$$

$$= (\mathbb{I} + \tilde{A}^{-1} \Delta A)^{-1} \cdot A^{-1}$$

$$\text{und } \|(A + \Delta A)^{-1}\| \leq \|\tilde{A}^{-1}\| \cdot \|(\mathbb{I} + \tilde{A}^{-1} \Delta A)^{-1}\| \quad \#$$

Jetzt haben wir die nötige Abschätzungen, und  $\frac{\|\Delta x\|}{\|x\|}$  zu kontrollieren.

Satz 5.17) Unter die Annahme von Lemma 5.16,

es gilt:

$$\frac{\|\Delta x\|}{\|x\|} \leq \frac{\text{sc}(A)}{1 - \text{sc}(A) \cdot \frac{\|\Delta A\|}{\|\tilde{A}\|}} \cdot \left( \frac{\|\Delta A\|}{\|\tilde{A}\|} + \frac{\|\Delta b\|}{\|b\|} \right).$$

Bemerkung: Zum erste Ordnung:

$$\frac{\|\Delta x\|}{\|x\|} \approx \text{sc}(A) \left( \frac{\|\Delta A\|}{\|\tilde{A}\|} + \frac{\|\Delta b\|}{\|b\|} \right).$$

Beweis: Aus  $\Delta x = (A + \Delta A)^{-1} (\Delta b - \Delta A \cdot x)$   
erhalten wir die Abschätzung

$$\|\Delta x\| \leq \| (A + \Delta A)^{-1} \| \cdot \| \Delta b \| + \| \Delta A \| \cdot \| x \|$$

$$\stackrel{\text{Lemma 5.16}}{\leq} \frac{\|A^{-1}\|}{1 - \|\Delta A\| \cdot \|A\|} \left( \frac{\|\Delta b\|}{\|x\|} + \|\Delta A\| \cdot \|x\| \right) \cdot \|x\|$$

$$\text{Dazu, } \|b\| = \|Ax\| \leq \|A\| \cdot \|x\| \Rightarrow \frac{1}{\|x\|} \leq \frac{\|A\|}{\|b\|}$$

$$\text{und } \|A^{-1}\| = \frac{\operatorname{sc}(A)}{\|A\|}$$

$$\Rightarrow \frac{\|\Delta x\|}{\|x\|} \leq \frac{\operatorname{sc}(A)}{1 - \operatorname{sc}(A) \frac{\|\Delta A\|}{\|A\|}} \cdot \left( \frac{\|\Delta b\|}{\|b\|} + \frac{\|\Delta A\|}{\|A\|} \cdot \|x\| \right).$$

#

Beispiel:  $A = \begin{pmatrix} 0,505 & -0,495 \\ -0,495 & 0,505 \end{pmatrix}, \Delta A = \begin{pmatrix} -0,005 & 0 \\ 0,005 & 0 \end{pmatrix}$

$$b = \begin{pmatrix} 1 \\ -1 \end{pmatrix}, \Delta b = \begin{pmatrix} 0 \\ 0 \end{pmatrix}.$$

$$\Rightarrow x = A^{-1}b = \begin{pmatrix} 100 \\ 100 \end{pmatrix} \text{ und zum Vergleich}$$

$$x + \Delta x = (A + \Delta A)^{-1}b = \begin{pmatrix} 200 \\ 200 \end{pmatrix} \Rightarrow \Delta x = \begin{pmatrix} 100 \\ 100 \end{pmatrix}.$$

Man berechnet:  $\|A\| = 1$

$$\|A^{-1}\| = 100$$

$$\|\Delta A\| = \frac{1}{\sqrt{100}} \approx 0,00707$$

$$\Rightarrow \frac{\operatorname{sc}(A)}{1 - \operatorname{sc}(A) \frac{\|\Delta A\|}{\|A\|}} \cdot \frac{\|\Delta A\|}{\|A\|} \approx 2,4 \geq \frac{\|\Delta x\|}{\|x\|} = 1.$$

## 5.6) Stabilität der LU-Zerlegung.

. Jetzt betrachten wir den Einfluss von Rundungsfehlern.

. Notationen: .  $|A| \in M_n(\mathbb{R})$  ist die Matrix mit  
Einträge  $|a_{ij}|$  (denn  $A = (a_{ij})_{1 \leq i, j \leq n}$ ).

.  $|A| \leq |B|$  bedeutet  $|a_{ij}| \leq |b_{ij}|, 1 \leq i, j \leq n$ .

Satz 5.18) . Sei  $A \in M_n(\mathbb{R})$  und  $\tilde{L}, \tilde{U}$  die berechneten  
LU Matrizen mit seinem Rechner mit  $\varepsilon_F$   
Rundungsgenauigkeit.

$$\text{Dann } \tilde{L} \cdot \tilde{U} = A + \Delta A$$

mit

$$|\Delta A| \leq 2 \cdot (n-1) \cdot \varepsilon_F (|A| + |\tilde{L}| \cdot |\tilde{U}|) + O(\varepsilon_F^2).$$

Beweis: . Induktion über  $n$ . (Angenommen:  $A = \text{rd}(A)$ , d.h.,  
darstellbar).

.  $n=1$ : klar, da  $\tilde{L}=1, \tilde{U}=A$ .

. Nehmen wir an, dass Satz 5.18 für  $n-1$  gilt.

Dann,  $A = \begin{pmatrix} \alpha & w^t \\ v & B \end{pmatrix}$  mit  $\alpha \neq 0$  (sonst Zeilaustausch)

und  $B \in M_{n-1}(\mathbb{R})$ ,  $w, v \in \mathbb{R}^{n-1}$ .

. In die LU-Zerlegung wird das Vektor

$$\tilde{z} := \text{rd}\left(\frac{1}{\alpha} \cdot v\right) \quad (\text{d.h., } \tilde{z}_k = \text{rd}\left(\frac{1}{\alpha} \cdot v_k\right), k=1, \dots, n)$$

bestimmt und dann wird  $B$  mit  $\tilde{S}$  ersetzt,  
wobei  $\tilde{S} = \text{rd}(B - \tilde{z} \cdot w^t)$ .

.  $\tilde{z} = \frac{v}{\alpha} + \Delta \tilde{z}$  mit  $|\Delta \tilde{z}| \leq \frac{|v|}{|\alpha|} \varepsilon_F$  ((da kein rel. Fehler  
auf  $\alpha$ )).

und  $\tilde{S} = B - \tilde{z} \cdot w^t + F$  mit (Siehe Lemma 2.2)  
 $|F| \leq 2 \cdot \varepsilon_F \cdot (|B| + |\tilde{z}| \cdot \|w\|^t) + O(\varepsilon_F^2)$ .

. Induktionsannahme  $\Rightarrow \tilde{L}_1 \tilde{U}_1 = \tilde{S} + F_1$  mit

$$|F_1| \leq 2(n-2) \cdot \varepsilon_F (|\tilde{S}| + |\tilde{L}_1| \cdot |\tilde{U}_1|) + O(\varepsilon_F^2).$$

Dann haben wir:

$$\tilde{L} = \begin{pmatrix} 1 & 0 \\ \tilde{z} & \tilde{L}_1 \end{pmatrix}, \quad \tilde{U} = \begin{pmatrix} \alpha & w^t \\ 0 & \tilde{U}_1 \end{pmatrix}$$

so dass

$$\tilde{L} \cdot \tilde{U} = \begin{pmatrix} 1 & 0 \\ \tilde{z} & \tilde{L}_1 \end{pmatrix} \begin{pmatrix} \alpha & w^t \\ 0 & \tilde{U}_1 \end{pmatrix} =$$

$$= \begin{pmatrix} \alpha & w^t \\ \tilde{z}\alpha & \tilde{z} \cdot w^t + \tilde{L}_1 \tilde{U}_1 \end{pmatrix}$$

$$\therefore \tilde{z} \cdot \alpha = N + \alpha \cdot \Delta \tilde{z}$$

$$\text{wegen: } \begin{cases} \tilde{z} \cdot w^t = B - \tilde{S} + F \\ \tilde{L}_1 \tilde{U}_1 = \tilde{S} + F_1 \end{cases}$$

$$\text{folgt: } \tilde{L} \cdot \tilde{U} = A + \underbrace{\begin{pmatrix} 0 & 0 \\ \alpha \cdot \Delta \tilde{z} & F + F_1 \end{pmatrix}}_{= \Delta A}$$

$$\text{SSB, 5. } |\alpha \Delta \tilde{z}| \leq M \cdot \varepsilon_F$$

$$\therefore |\tilde{S}| \leq (1+2\varepsilon_F) \cdot (|B| + |\tilde{z}| \cdot |w^t|) + O(\varepsilon_F^2)$$

$$\Rightarrow |F+F_1| \leq 2 \cdot \varepsilon_F \cdot (|B| + |\tilde{z}| \cdot |w^t| + |\tilde{L}_1| \cdot |\tilde{U}_1|) \cdot (n-2+1) + O(\varepsilon_F^2).$$

. Alles zusammen, die Abschätzung

$$|\Delta A| \leq 2(n-1) \varepsilon_F \left\{ \left( \frac{|A|}{M} \frac{|w^t|}{M} \right) + \left( \frac{1}{M} \frac{0}{M} \right) \cdot \left( \frac{|A|}{M} \frac{|w^t|}{M} \right) + O(\varepsilon_F^2) \right\}$$

+  $O(\varepsilon_F^2)$  gilt.

Bemerkung: Rückwärtstabilität folgt nicht aus

Satz 5.18. Gilt nur falls  $|\tilde{L}| \cdot |\tilde{U}| \approx |A|$ .

(↓: Gegenbeispiel).

### Partielle Pivotisierung:

- Nehmen wir die Matrix

$$A = \begin{pmatrix} \varepsilon & 1 \\ 1 & 1 \end{pmatrix}, \varepsilon > 0.$$

Dann, die exakte LU-Zerlegung ist

$$\begin{pmatrix} \varepsilon & 1 \\ 1 & 1 \end{pmatrix} = \underbrace{\begin{pmatrix} 1 & 0 \\ 1/\varepsilon & 1 \end{pmatrix}}_L \cdot \underbrace{\begin{pmatrix} \varepsilon & 1 \\ 0 & 1 - 1/\varepsilon \end{pmatrix}}_U.$$

- Falls aber  $\varepsilon$  klein genug ist, s.d. im Rechner  $1 - \frac{1}{\varepsilon}$  und  $-\frac{1}{\varepsilon}$  die gleiche Darstellung erhalte,

dann  $\tilde{U} = \begin{pmatrix} \varepsilon & 1 \\ 0 & -1/\varepsilon \end{pmatrix}$  und  $L \tilde{U} = \begin{pmatrix} \varepsilon & 1 \\ 1 & 0 \end{pmatrix}$ .

- Für  $Ax=b$  mit  $b = \begin{pmatrix} 1 \\ 0 \end{pmatrix}$ , erhält man dann statt  $x = \begin{pmatrix} -1 \\ 1 \end{pmatrix}$ ,  $\tilde{x} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ .

⇒ Fehler  $O(\varepsilon)$  kann auf Fehler  $O(1)$  <sup>sich</sup> vergroßern.

Bemerkung: Diese Instabilität wenn L oder U Einträge, die (betragmäßig) viel größer als die Einträge von A sind.

Frage: Wie kann man dieses Problem vermeiden?

- Im Beispiel: Vertauschen die Zeilen von A

$$\Rightarrow \begin{pmatrix} 1 & 1 \\ \varepsilon & 1 \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ \varepsilon & 1 \end{pmatrix} \cdot \begin{pmatrix} 1 & 1 \\ 0 & 1 - \varepsilon \end{pmatrix} : \underline{\text{Kein Problem.}}$$

Antwort: Im Schritt Nb. K, sollten man den betragmäßig größte der  $n-k+1$  möglichen Pivots  $\Rightarrow |f_{i,j}| \leq 1, 1 \leq i \leq n$ .

Diese ist die sogenannte partielle Pivotisierung.

- Bemerkung: Da  $|e_{ij}| \leq 1 \Rightarrow |L| \leq 1$ , so wird Satz 5.18 wie folgt.

Definition 5.19) Das Wachstumsfaktor einer LU-Zerlegung

$$\beta_n := \frac{\|U\|_\infty}{\|A\|_\infty}, \text{ wobei}$$

$$\|X\|_\infty := \max_{i=1, \dots, n} \sum_{j=1}^n |X_{ij}| \quad (\text{Zeilsumme norm})$$

Satz 5.20) Sei  $A \in M_n(\mathbb{R})$  invertierbar,  $\tilde{L}, \tilde{U}, \tilde{P}$  die LU-Zerlegung mit Partielle Pivotisierung (und Rundungsfehlern). Dann,

$$\tilde{L} \cdot \tilde{U} = \tilde{P} \cdot A + \Delta A$$

mit  $\|\Delta A\|_\infty \leq c \cdot \beta_n \cdot \varepsilon_F \cdot \|A\|_\infty$  ( $c$  eine Konstante).

Bemerkung: Man kann zeigen; für eine Spaltenpivotisierte LU-Zerlegung.

$$PA = LU \quad \text{von } A, \text{ dann } \beta_n \leq 2^{n-1}$$

(gleichmäßig in  $A \in M_n(\mathbb{R})$ ).  
 $\xrightarrow{\text{L}} \underline{\text{rückwärtsstabil.}}$

Praktische Problem: Die Abschätzung  $\beta_n \leq 2^{n-1}$  ist in der Praxis unbrauchbar. Man kann aber danach den Fehler kontrollieren.

## 5.7) Die Cholesky-Zerlegung.

- Wir betrachten eine bestimmte Klasse, die positiv definite Matrizen.

Definition 5.21) Eine symmetrische Matrix  $A \in M_n(\mathbb{R})$

heißt positiv definit falls für alle  $x \in \mathbb{R}^n \setminus \{0\}$ ,

$$x^T A x > 0.$$

- Einige Eigenschaften:

Lemma 5.22)  $\left\{ \begin{array}{l} \text{(a)} A \text{ positiv definit} \Rightarrow A \text{ regulär (invertierbar).} \\ \text{(b)} A_{ii} > 0. \end{array} \right.$

Beweis: (a) Wegen  $x^T A x > 0$ ,  $\forall x \neq 0$ , es folgt

$$\{Ax, x \in \mathbb{R}^n\} = \mathbb{R}^n,$$

d.h.,  $\{Ae_1, \dots, Ae_n\}$  ist eine Basis von  $\mathbb{R}^n$   
 $\Rightarrow$  Spalten linear unabhängig.

$$(b) \forall i A_{ii} = e_i^T A e_i > 0.$$

#

Definition 5.23) Eine Zerlegung  $A = L \cdot L^T$

mit unterer Dreiecksmatrix  $L$ , die <sup>(strikte)</sup> positive

Diagonaleinträge besitzt, heißt

Cholesky-Zerlegung von  $A$ .

Ziel ist das folgende Satz.

(30)

### Satz 5.24) (Existenz der Cholesky-Zerlegung).

- Eine Cholesky-Zerlegung von  $A$  existiert  
 $\Leftrightarrow A$  positiv definit ist.

- Zum Beweis braucht man einige Vorbereitungssätze.

Definition 5.25): Sei  $A \in M_n(\mathbb{R})$  und die Blockdarstellung:

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}, \quad A_{11} \in M_p(\mathbb{R}), A_{22} \in M_{n-p}(\mathbb{R}).$$

Falls  $A_{11}$  invertierbar ist, dann

$$A = \begin{pmatrix} 1 & 0 \\ -A_{21} A_{11}^{-1} & 1 \end{pmatrix} \begin{pmatrix} A_{11} & A_{12} \\ 0 & S \end{pmatrix}$$

mit  $S' := A_{22} - A_{21} \cdot A_{11}^{-1} \cdot A_{12}$  das Schur-Komplement  
von  $A$  bzgl.  $A_{11}$ .

Lemma 5.26): Sei  $A \in M_n(\mathbb{R})$  positiv definit.  
Dann sind  $A_{11}$  und  $S'$  positiv definit

Beweis:  $A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}$ . Wegen  $A = A^t$ , haben wir

$$\begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} = \begin{pmatrix} A_{11}^t & A_{21}^t \\ A_{12}^t & A_{22}^t \end{pmatrix},$$

$$\Rightarrow A_{11} = A_{11}^t, A_{22} = A_{22}^t, A_{12} = A_{21}^t, A_{21} = A_{12}^t.$$

In besondere,  $A_{11}$  ist symmetrisch.

$$\text{Dazu, } (x, a)^t \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix} (x, a) = x^t A_{11} x > 0$$

$\forall x \in \mathbb{R}^p \setminus \{0\}$ , weil  $A$  positiv definit ist.

$\Rightarrow A_{11}$  positiv definit.

- Es folgt,  $S = A_{22} - A_{21} \cdot A_{11}^{-1} \cdot A_{12}$  ist wohldefiniert. (21)

$$\bullet S^t = A_{22}^t - A_{12}^t \cdot A_{11}^{-t} \cdot A_2^t = A_{22} - A_{21} \cdot A_{11}^{-1} \cdot A_{12} = S.$$

Letzlich, sei  $x = (x_1 \ x_2)$  mit  $x_1 := -A_{11}^{-1} \cdot A_{12} \cdot x_2$ .

Dann, für  $x_2 \neq 0$ , gilt

$$\begin{aligned} 0 < x^t A x &= (x_1 \ x_2) \begin{pmatrix} A_{11} x_1 + A_{12} x_2 \\ A_{21} x_1 + A_{22} x_2 \end{pmatrix} \\ &= (x_1 \ x_2) \begin{pmatrix} 0 \\ (A_{22} - A_{21} A_{11}^{-1} A_{12}) x_2 \end{pmatrix} = x_2 S x_2. \end{aligned}$$

$\Rightarrow$  Ist auch  $S$  positiv definit. #

. Nun kommen wir zum Beweis von Satz 5.24.

Beweis von Satz 5.24:

$\Rightarrow$ : Sei  $A = L \cdot L^t$ . Dann,

$$A^t = (L L^t)^t = (L^t)^t L^t = A.$$

Dazu,  $x^t A x = x^t L L^t x = \|L^t x\|^2 \geq 0$ .

.  $\|\cdot\|$  ist eine Norm, deshalb  $\|L^t x\| > 0$  für alle  $L^t x \neq 0$ . Wegen  $L_{ii} > 0$  und  $L_{ij} = 0$  für  $j > i$ , ist  $L$  invertierbar  $\Rightarrow x^t A x > 0, \forall x \in \mathbb{R}^n \setminus \{0\}$ .

$\Leftarrow$ : Sei  $A$  positiv definit.

Induktion:  $n=1: a_{11} > 0 \Rightarrow L = \left[ l_{11} = \sqrt{a_{11}} \right] \ . \checkmark$

Annahme: Für alle  $B \in M_{n-1}(\mathbb{R})$ , positiv definit, existiert die Cholesky-Zerlegung.

. Schreibe  $A = \begin{pmatrix} a_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix}$ , mit  $A_{21} = A_{12}^t$ ,

( $A_{22}$  positiv definit) und sei

$$S = A_{22} - \frac{1}{a_{11}} \cdot A_{21} \cdot A_{12} \quad \text{das Schur-Kapl.}\atop \text{v.a. } A \text{ bzgl. } a_{11}.$$

Lem 5.26

$$\Rightarrow S = \tilde{L} \cdot \tilde{L}^t \quad (\text{cholesky-Zerlegung}).$$

82

Und können wir setzen

$$L = \begin{pmatrix} L_{11} & 0 \\ \frac{1}{L_{11}} A_{21} & \tilde{L} \end{pmatrix}.$$

Dann,  $L \cdot L^t = \begin{pmatrix} L_{11} & 0 \\ \frac{1}{L_{11}} A_{21} & \tilde{L} \end{pmatrix} \cdot \begin{pmatrix} L_{11} & \frac{1}{L_{11}} A_{12} \\ 0 & \tilde{L}^t \end{pmatrix}$

$$= \begin{pmatrix} L_{11}^2 & a_{11} \\ A_{21} & A_{21} \cdot \frac{1}{L_{11}^2} \cdot A_{12} A_{21} + \underbrace{\tilde{L} \tilde{L}^t}_{=S} \end{pmatrix}$$

$$= \begin{pmatrix} a_{11} & A_{12} \\ A_{21} & A_{21} A_{21} + A_{22} - \frac{1}{a_{11}} A_{12} A_{21} \end{pmatrix} = A. \quad \#$$

Algorithmus?

$$A = \begin{pmatrix} a_{11} & a_{12} & \cdots \\ a_{21} & a_{22} & \cdots \end{pmatrix} = \begin{pmatrix} L_{11} & 0 \\ \frac{1}{L_{11}} A_{21} & L_{22} \end{pmatrix} \begin{pmatrix} L_{11} & L_{21} \\ 0 & L_{22} \end{pmatrix} = \begin{pmatrix} L_{11}^2 & L_{11} L_{21} \\ 0 & \text{sym. } L_{21}^2 + L_{22}^2 \cdots \end{pmatrix}$$

Für  $i \geq j: \quad a_{ij} = \sum_{k=1}^j l_{ik} l_{kj}^t = l_{ij} l_{jj} + \sum_{k=1}^{j-1} l_{ik} l_{jk}$

$$\Leftrightarrow \left\{ \begin{array}{l} l_{jj} = \sqrt{a_{jj} - \sum_{k=1}^{j-1} l_{ik}^2} \text{ und} \\ l_{ij} = \frac{1}{l_{jj}} \left( a_{ij} - \sum_{k=1}^{j-1} l_{ik} l_{jk} \right) \end{array} \right.$$

$$l_{ij} = \frac{1}{l_{jj}} \left( a_{ij} - \sum_{k=1}^{j-1} l_{ik} l_{jk} \right), \text{ für } i=j+1, \dots, n.$$

für  $j=1, \dots, n$ .

$\Rightarrow l_{11}$  aus  $a_{11}$ , dann  $l_{21}$  aus  $\{a_{12}, l_{11}\}$ ,  $l_3$  aus  $\{a_{13}, l_{11}\}$  ...  
dann  $l_{22}$  aus  $\{l_{21}, a_{22}\}$ , ...

Explizit: Siehe Algorithmus 6.49 im Bebendorf Skript.

Beispiel:  $A = \begin{pmatrix} 9 & 3 & -1 \\ 3 & 5 & -5/3 \\ 1 & -5/3 & 2 \end{pmatrix}$

$$\cdot l_{11} = \sqrt{a_{11}} = 3$$

$$\cdot l_{21} = \frac{a_{12}}{l_{11}} = \frac{3}{3} = 1$$

$$\cdot l_{31} = \frac{a_{13}}{l_{11}} = \frac{1}{3}$$

$$\cdot l_{22} = \sqrt{a_{22} - l_{21}^2} = 2$$

$$\cdot l_{32} = \frac{a_{32} - l_{31} \cdot l_{21}}{l_{22}} = -1$$

$$\cdot l_{33} = \sqrt{a_{33} - l_{31}^2 - l_{32}^2} = \sqrt{\frac{20}{9}} = \frac{\sqrt{20}}{3}.$$

$$\Rightarrow L = \begin{pmatrix} 3 & 0 & 0 \\ 1 & 2 & 0 \\ \frac{1}{3} & -1 & \frac{\sqrt{20}}{3} \end{pmatrix} \text{ und } A = L \cdot L^t.$$

Hier haben wir keine Instabilität, weil die Einträge von L werden nie gross, falls die  $a_{ii}$  klein sind.

Lemma 5.27). Sei  $A = LL^t$  eine Cholesky-Zerlegung.

Dann gilt

$$|l_{ij}| \leq \sqrt{a_{ii}} \text{ für alle } i \geq j.$$

Beweis:  $0 < a_{ii} = \sum_{j=1}^i l_{ij}^2 \Rightarrow l_{ij}^2 \leq a_{ii}, \forall j \leq i.$  #

Rückwärtsstabilität:

Satz 5.28) (ohne Beweis). Sei  $A \in M_n(\mathbb{R})$  positiv definit und  $\tilde{L}$  die mit dem Rechner berechnete Matrix. Dann

$$\tilde{L} \cdot \tilde{L}^t = A + \Delta A$$

$$\text{mit } \|\Delta A\|_\infty \leq \text{const. } \varepsilon_F \cdot \|A\|_\infty.$$