

# Kapitel 2

Buch Dahmen-Reusken

RWTH Aachen University

2022

# Normierte Räume

## Definition

Sei  $V$  ein  $\mathbb{R}$ -Vektorraum. Eine Abbildung  $\|\cdot\| : V \rightarrow \mathbb{R}$  heißt **Norm** auf  $V$ , falls

- ▶  $\|v\| \geq 0 \forall v \in V$  und  $\|v\| = 0$  nur wenn  $v = 0$ .
- ▶ Für alle  $a \in \mathbb{R}$ ,  $v \in V$  gilt  $\|a v\| = |a| \|v\|$
- ▶ Für alle  $v, w \in V$  gilt die Dreiecksungleichung
$$\|v + w\| \leq \|v\| + \|w\|$$

Wenn eine Norm auf  $V$  definiert ist, nennt man  $V$  oft einen **linearen normierten** Raum.

# Vektornormen

## Beispiel

Sei  $V = \mathbb{R}^n$ ,  $\mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$ .

Für jedes  $p$  mit  $1 \leq p \leq \infty$  wird eine Norm definiert durch

$$\|\mathbf{x}\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$

Speziell:

► 1-Norm: 
$$\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|$$

# Vektornormen

## Beispiel

Sei  $V = \mathbb{R}^n$ ,  $\mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$ .

Für jedes  $p$  mit  $1 \leq p \leq \infty$  wird eine Norm definiert durch

$$\|\mathbf{x}\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$

Speziell:

- ▶ 1-Norm:  $\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|$
- ▶  $\infty$ -Norm:  $\|\mathbf{x}\|_\infty = \max_{i=1, \dots, n} |x_i|$

# Vektornormen

## Beispiel

Sei  $V = \mathbb{R}^n$ ,  $\mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$ .

Für jedes  $p$  mit  $1 \leq p \leq \infty$  wird eine Norm definiert durch

$$\|\mathbf{x}\|_p = \left( \sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$

Speziell:

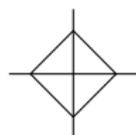
- ▶ 1-Norm:  $\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|$
- ▶  $\infty$ -Norm:  $\|\mathbf{x}\|_\infty = \max_{i=1, \dots, n} |x_i|$
- ▶ 2-Norm:  $\|\mathbf{x}\|_2 = \left( \sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}}$  (Euklidische Norm)

Bemerkung: 2-Norm wird durch ein Skalarprodukt induziert.

## Vektornormen

Einheitskreise in  $\mathbb{R}^2$ :  $\{\mathbf{x} \in \mathbb{R}^2 : \|\mathbf{x}\| = 1\}$ 

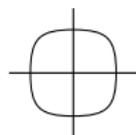
$$\|\mathbf{x}\|_1 = \sum_{i=1}^2 |\mathbf{x}_i|$$



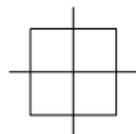
$$\|\mathbf{x}\|_2 = \left( \sum_{i=1}^2 |\mathbf{x}_i|^2 \right)^{1/2} = \sqrt{\mathbf{x}^T \mathbf{x}}$$



$$\|\mathbf{x}\|_p = \left( \sum_{i=1}^2 |\mathbf{x}_i|^p \right)^{1/p} \quad (1 \leq p < \infty)$$



$$\|\mathbf{x}\|_\infty = \max_{1 \leq i \leq 2} |\mathbf{x}_i|$$



# Weitere Beispiele

“Endlich-dimensionaler Vektorraum” beinhaltet nicht nur  $\mathbb{R}^n$ :

## Beispiel

Die Menge

$$\Pi_m := \left\{ \sum_{i=0}^m a_i t^i \mid a_i \in \mathbb{R} \right\}$$

ist ein  $\mathbb{R}$ -Vektorraum der Dimension  $m + 1$ .

Die Monome  $M_i(t) := t^i$ ,  $i = 0, \dots, m$ , dienen als Basis.

# Weitere Beispiele

“Endlich-dimensionaler Vektorraum” beinhaltet nicht nur  $\mathbb{R}^n$ :

## Beispiel

Die Menge

$$\Pi_m := \left\{ \sum_{i=0}^m a_i t^i \mid a_i \in \mathbb{R} \right\}$$

ist ein  $\mathbb{R}$ -Vektorraum der Dimension  $m + 1$ .

Die Monome  $M_i(t) := t^i$ ,  $i = 0, \dots, m$ , dienen als Basis.

Unendlich-dimensionaler Vektorraum:  $V = C^0(I)$ ,  $I = [a, b] \subset \mathbb{R}$ , mit Norm

$$\|f\|_p = \left( \int_a^b |f(x)|^p dx \right)^{\frac{1}{p}}$$

## Satz 2.10

Auf einem endlich-dimensionalen Vektorraum  $V$  sind alle Normen äquivalent, d.h. zu je zwei Normen  $\|\cdot\|_*$  und  $\|\cdot\|_{**}$  existieren beschränkte, positive Konstanten  $c$  und  $C$ , so dass

$$c\|v\|_* \leq \|v\|_{**} \leq C\|v\|_*, \quad \text{für alle } v \in V$$

## Satz 2.10

Auf einem endlich-dimensionalen Vektorraum  $V$  sind alle Normen äquivalent, d.h. zu je zwei Normen  $\|\cdot\|_*$  und  $\|\cdot\|_{**}$  existieren beschränkte, positive Konstanten  $c$  und  $C$ , so dass

$$c\|v\|_* \leq \|v\|_{**} \leq C\|v\|_*, \quad \text{für alle } v \in V$$

## Beispiel

Sei  $V = \mathbb{R}^n$ , dann gilt

$$\|x\|_\infty \leq \|x\|_2 \leq \|x\|_1$$

und

$$\|x\|_2 \leq \sqrt{n}\|x\|_\infty$$

$$\|x\|_1 \leq \sqrt{n}\|x\|_2$$

$$\|x\|_1 \leq n\|x\|_\infty$$

# Lineare Abbildungen und Operatornormen

$X$  und  $Y$ : lineare normierte Räume (über  $\mathbb{R}$ ) mit Normen  $\|\cdot\|_X$ ,  $\|\cdot\|_Y$ .  
 Eine Abbildung  $\mathcal{L} : X \rightarrow Y$  heißt linear, falls für  $x, z \in X$  und  $\alpha, \beta \in \mathbb{R}$  gilt

$$\mathcal{L}(\alpha x + \beta z) = \alpha \mathcal{L}(x) + \beta \mathcal{L}(z)$$

## Beispiel

Eine Matrix  $B \in \mathbb{R}^{m \times n}$

$$B = (b_{i,j})_{i,j=1}^{m,n} = \begin{pmatrix} b_{1,1} & \cdots & b_{1,n} \\ \vdots & & \vdots \\ b_{m,1} & \cdots & b_{m,n} \end{pmatrix}, \quad b_{i,j} \in \mathbb{R},$$

entspricht der Abbildung  $B : \mathbb{R}^n \rightarrow \mathbb{R}^m$ ,  $Bx = \sum_{j=1}^n x_j b_j$ , mit  $b_j$  die  $j$ -te Spalte der Matrix  $B$ .

# Lineare Abbildungen und Operatornormen

## Beispiel

$X = \mathbb{R}^{m+1}$ ,  $Y = \Pi_m$  mit Basis  $\{\phi_0, \dots, \phi_m\}$ .

$$\mathcal{L}(a) := \sum_{i=0}^m a_i \phi_i, \quad a \in \mathbb{R}^{m+1}$$

# Lineare Abbildungen und Operatornormen

## Beispiel

$X = \mathbb{R}^{m+1}$ ,  $Y = \Pi_m$  mit Basis  $\{\phi_0, \dots, \phi_m\}$ .

$$\mathcal{L}(a) := \sum_{i=0}^m a_i \phi_i, \quad a \in \mathbb{R}^{m+1}$$

## Operatornorm

Sei  $\mathcal{L} : X \rightarrow Y$  eine lineare Abbildung.

$$\|\mathcal{L}\|_{X \rightarrow Y} := \sup_{x \neq 0} \frac{\|\mathcal{L}(x)\|_Y}{\|x\|_X}$$

Wichtige Eigenschaft:

$$\|\mathcal{L}(x)\|_Y \leq \|\mathcal{L}\|_{X \rightarrow Y} \|x\|_X, \quad \text{für all } x \in X$$

# Matrixnormen

Lineare Abbildung in Form einer Matrix, dann Matrixnorm:=Operatornorm.

## Definition

Sei  $A \in \mathbb{R}^{n \times n}$  und  $\|\cdot\|$  eine Norm auf  $\mathbb{R}^n$ , dann ist durch

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

eine dazugehörige **Matrixnorm** definiert.

## Beachte

Definition gilt entsprechend auch für  $A \in \mathbb{R}^{m \times n}$ .

Die **induzierte Matrixnorm**  $\|A\|$  ist die kleinste Zahl  $c$ , so dass gilt

$$\|Ax\| \leq c\|x\| \quad \text{für alle } x \in \mathbb{R}^n.$$

# Matrixnormen

Lineare Abbildung in Form einer Matrix, dann Matrixnorm:=Operatornorm.

## Definition

Sei  $A \in \mathbb{R}^{n \times n}$  und  $\|\cdot\|$  eine Norm auf  $\mathbb{R}^n$ , dann ist durch

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

eine dazugehörige **Matrixnorm** definiert.

Es gilt:

- ▶  $\|A\| \geq 0$ , und  $\|A\| = 0$  nur wenn  $A = 0$ .
- ▶ Für alle  $\alpha \in \mathbb{R}$ :  $\|\alpha A\| = |\alpha| \|A\|$
- ▶ Dreiecksungleichung:

$$\|A + B\| \leq \|A\| + \|B\|$$

# Matrixnormen

Lineare Abbildung in Form einer Matrix, dann Matrixnorm:=Operatornorm.

## Definition

Sei  $A \in \mathbb{R}^{n \times n}$  und  $\|\cdot\|$  eine Norm auf  $\mathbb{R}^n$ , dann ist durch

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

eine dazugehörige **Matrixnorm** definiert.

und:

- ▶  $\|Ax\| \leq \|A\| \|x\|$
- ▶  $\|AB\| \leq \|A\| \|B\|$
- ▶  $\|I\| = 1$

# Matrixnormen

Aus der Definition ergeben sich folgende Formeln für  $A \in \mathbb{R}^{m \times n}$ :

► 1-Norm:

(max. Spaltensumme)

$$\|A\|_1 = \max_{j=1, \dots, n} \sum_{i=1}^m |a_{ij}|$$

# Matrixnormen

Aus der Definition ergeben sich folgende Formeln für  $A \in \mathbb{R}^{m \times n}$ :

- ▶ 1-Norm: (max. Spaltensumme)

$$\|A\|_1 = \max_{j=1, \dots, n} \sum_{i=1}^m |a_{ij}|$$

- ▶  $\infty$ -Norm: (max. Zeilensumme)

$$\|A\|_\infty = \max_{i=1, \dots, m} \sum_{j=1}^n |a_{ij}|$$

# Matrixnormen

Aus der Definition ergeben sich folgende Formeln für  $A \in \mathbb{R}^{m \times n}$ :

- ▶ 1-Norm: (max. Spaltensumme)

$$\|A\|_1 = \max_{j=1, \dots, n} \sum_{i=1}^m |a_{ij}|$$

- ▶  $\infty$ -Norm: (max. Zeilensumme)

$$\|A\|_\infty = \max_{i=1, \dots, m} \sum_{j=1}^n |a_{ij}|$$

- ▶ 2-Norm: (Spektralnorm)

$$\|A\|_2 = \sqrt{\lambda_{\max}(A^T A)}$$

wobei  $\lambda_{\max}(A^T A)$  der größte Eigenwert von  $A^T A$  ist.

# Matrixnormen

## Beispiel

Für  $A = \begin{pmatrix} 2 & -3 \\ 1 & 1 \end{pmatrix}$  ergibt sich:

## Matrixnormen

## Beispiel

Für  $A = \begin{pmatrix} 2 & -3 \\ 1 & 1 \end{pmatrix}$  ergibt sich:

$$\|A\|_1 = 4, \quad \|A\|_\infty = 5, \quad \|A\|_2 = \sqrt{\frac{1}{2} (15 + 5\sqrt{5})},$$

## Matrixnormen

## Beispiel

Für  $A = \begin{pmatrix} 2 & -3 \\ 1 & 1 \end{pmatrix}$  ergibt sich:

$$\|A\|_1 = 4, \quad \|A\|_\infty = 5, \quad \|A\|_2 = \sqrt{\frac{1}{2} (15 + 5\sqrt{5})},$$

denn die Eigenwerte von  $A^T A = \begin{pmatrix} 5 & -5 \\ -5 & 10 \end{pmatrix}$  kann man über

$$\det(A^T A - \lambda I) = 0 \iff (5 - \lambda)(10 - \lambda) - 25 = 0$$

bestimmen und damit

$$\lambda_1 = \frac{1}{2} (15 - 5\sqrt{5}), \quad \lambda_2 = \frac{1}{2} (15 + 5\sqrt{5}).$$

# Landau-Symbol

## Landau-Symbol $\mathcal{O}$

Betrachte zwei Funktionen  $g, h : \mathbb{R} \rightarrow \mathbb{R}$ . Wir verwenden die Notation

$$g(x) = \mathcal{O}(h(x)) \quad (x \rightarrow x_0)$$

wenn es Konstanten  $C > 0$  und  $\delta > 0$  gibt, so dass gilt:

$$|g(x)| \leq C|h(x)|, \quad \forall x \text{ mit } |x - x_0| < \delta$$

- ▶ Anschauliche Bedeutung  
 $g$  wächst nicht wesentlich schneller als  $h$  (in einer Umgebung von  $x_0$ )
- ▶ Definition gilt entsprechend auch für  $g, h : \mathbb{R}^n \rightarrow \mathbb{R}^m$ .

## Taylor-Entwicklung: Skalare Funktionen

Taylor-Entwicklung (von  $f$  um  $x_0$ )

Für hinreichend oft differenzierbares  $f : \mathbb{R} \rightarrow \mathbb{R}$  gilt

$$f(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 + \dots \\ + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1} + \frac{f^{(k)}(\xi)}{k!}(x - x_0)^k,$$

wobei  $\xi$  eine Zahl zwischen  $x$  und  $x_0$  ist.

$f^{(n)}(x_0)$  ist die  $n$ -te Ableitung von  $f$  an der Stelle  $x_0$ .

## Taylor-Entwicklung: Skalare Funktionen

Taylor-Polynom vom Grad  $k - 1$  in  $x_0$ 

$$p_{k-1}(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 \\ + \dots + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1}.$$

## Taylor-Entwicklung: Skalare Funktionen

Taylor-Polynom vom Grad  $k - 1$  in  $x_0$ 

$$p_{k-1}(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 \\ + \dots + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1}.$$

- ▶ Für  $k = 1$  erhält man den [Mittelwertsatz](#)

$$\frac{f(x) - f(x_0)}{x - x_0} = f'(\xi),$$

wobei  $\xi$  eine Zahl zwischen  $x$  und  $x_0$  ist.

- ▶ Oft verwendete Darstellung

$$f(x) = p_{k-1}(x) + \mathcal{O}(|x - x_0|^k) \quad (x \rightarrow x_0)$$

## Taylor-Entwicklung: Skalare Funktionen

Taylor-Polynom vom Grad  $k - 1$  in  $x_0$ 

$$p_{k-1}(x) = f(x_0) + f'(x_0)(x - x_0) + \frac{f^{(2)}(x_0)}{2}(x - x_0)^2 + \dots + \frac{f^{(k-1)}(x_0)}{(k-1)!}(x - x_0)^{k-1}.$$

- ▶ Für  $k = 1$  erhält man den [Mittelwertsatz](#)

$$\frac{f(x) - f(x_0)}{x - x_0} = f'(\xi),$$

wobei  $\xi$  eine Zahl zwischen  $x$  und  $x_0$  ist.

- ▶ Oft verwendete Darstellung

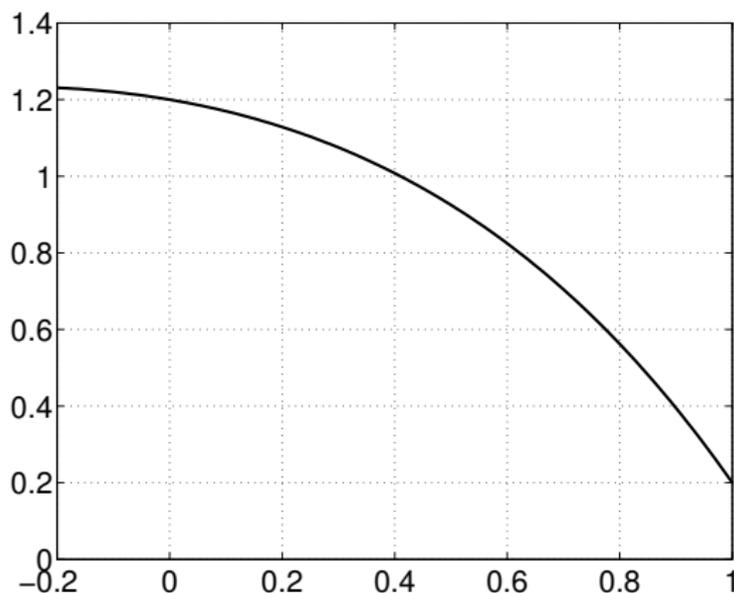
$$f(x) = p_{k-1}(x) + \mathcal{O}(|x - x_0|^k) \quad (x \rightarrow x_0)$$

Siehe auch Matlab-Demo 2.23.

# Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um  $x_0 = 0$  von

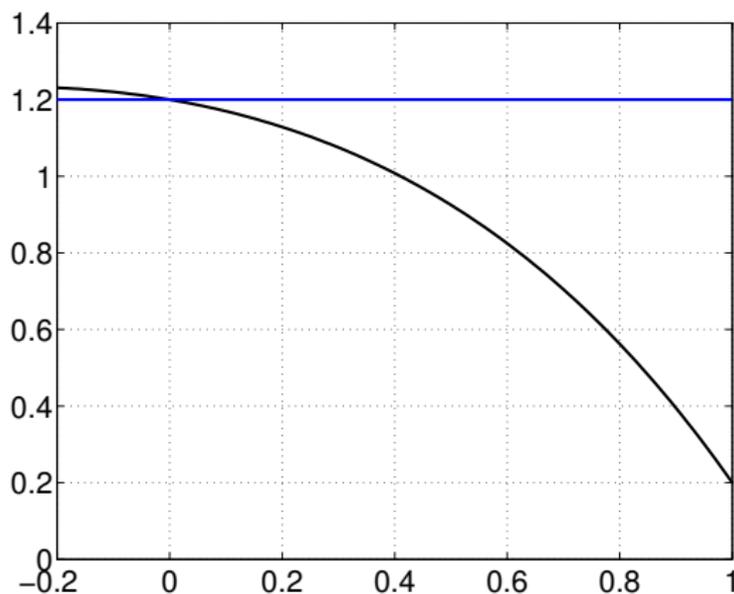
$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$



# Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um  $x_0 = 0$  von

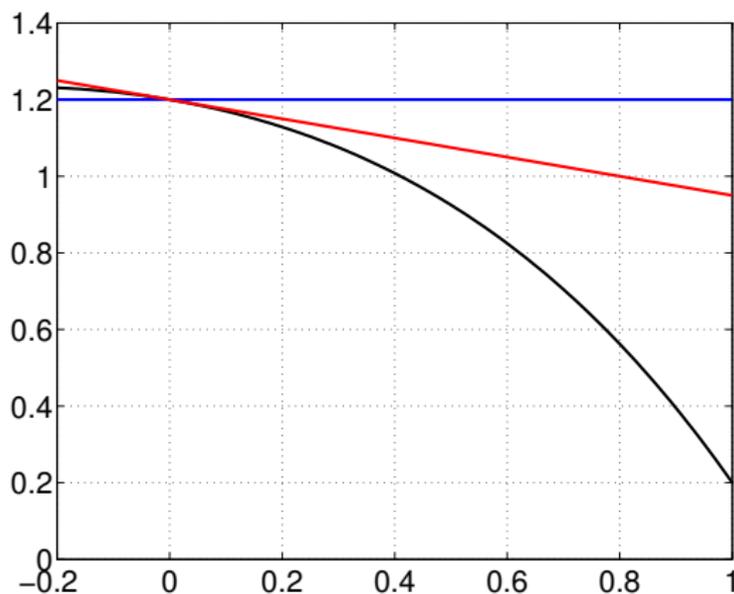
$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$



# Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um  $x_0 = 0$  von

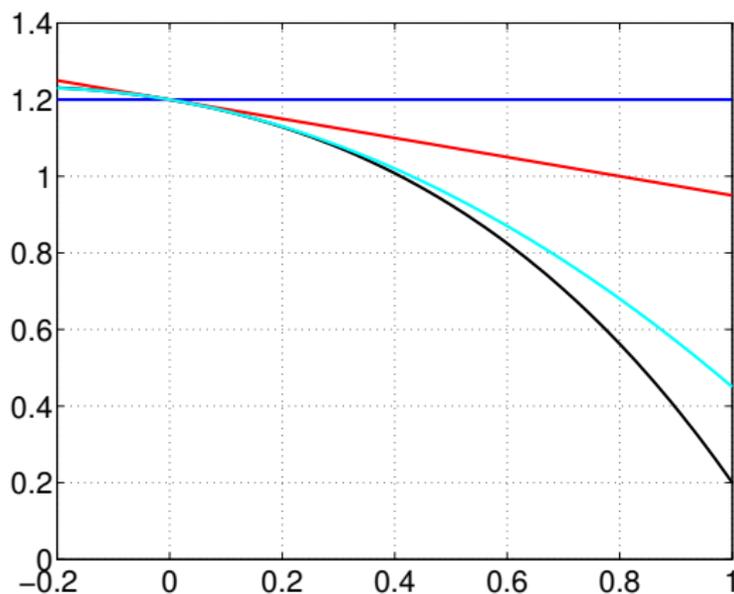
$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$



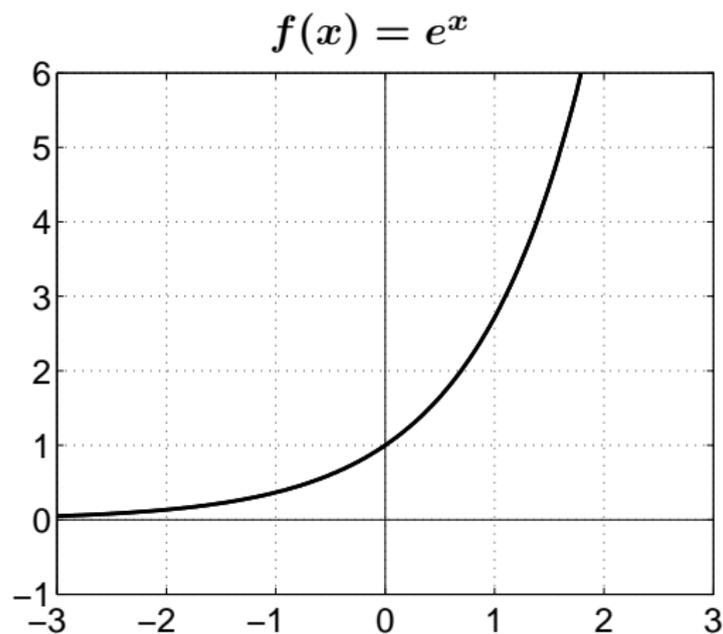
# Taylor-Entwicklung: Skalare Funktionen

Taylor-Reihenentwicklung 0., 1. und 2. Ordnung um  $x_0 = 0$  von

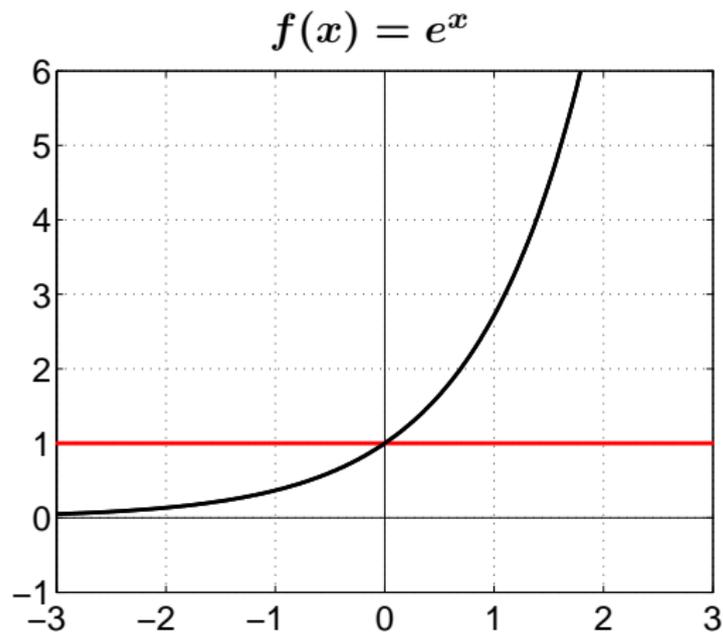
$$f(x) = -0.1x^4 - 0.15x^3 - 0.5x^2 - 0.25x + 1.2$$



## Taylor-Entwicklung: Skalare Funktionen

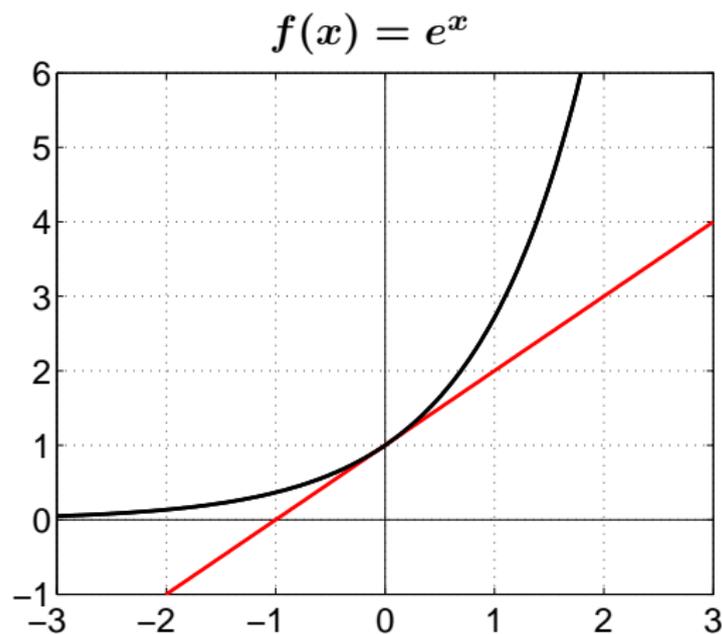


## Taylor-Entwicklung: Skalare Funktionen



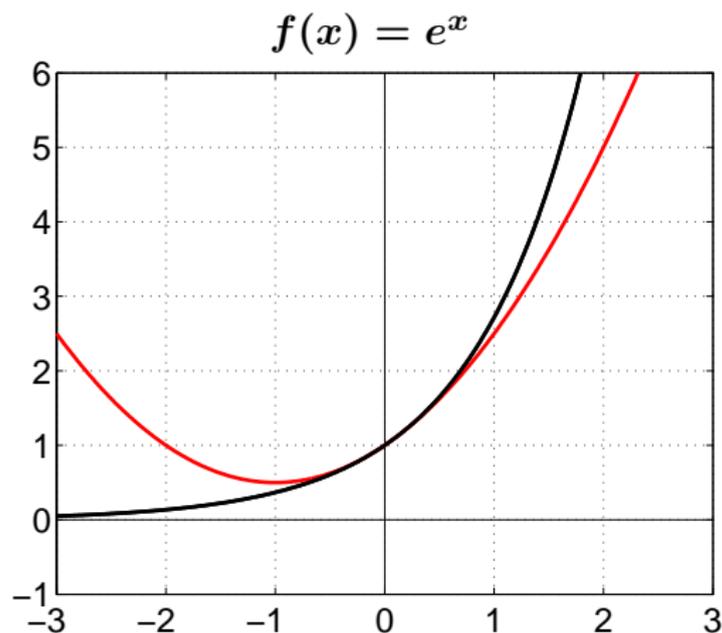
Taylor-Pol. 0. Grades in 0:  $p_0(x) = 1$

## Taylor-Entwicklung: Skalare Funktionen



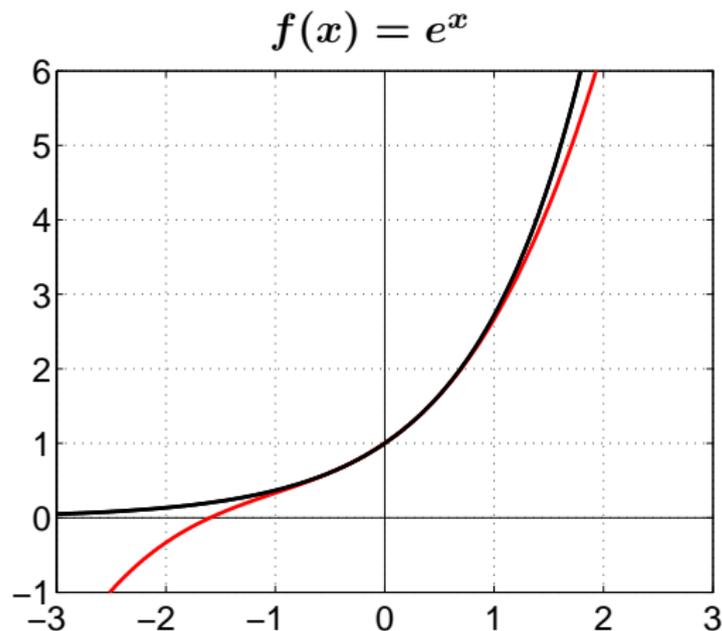
Taylor-Pol. 1. Grades in 0:  $p_1(x) = 1 + x$

## Taylor-Entwicklung: Skalare Funktionen



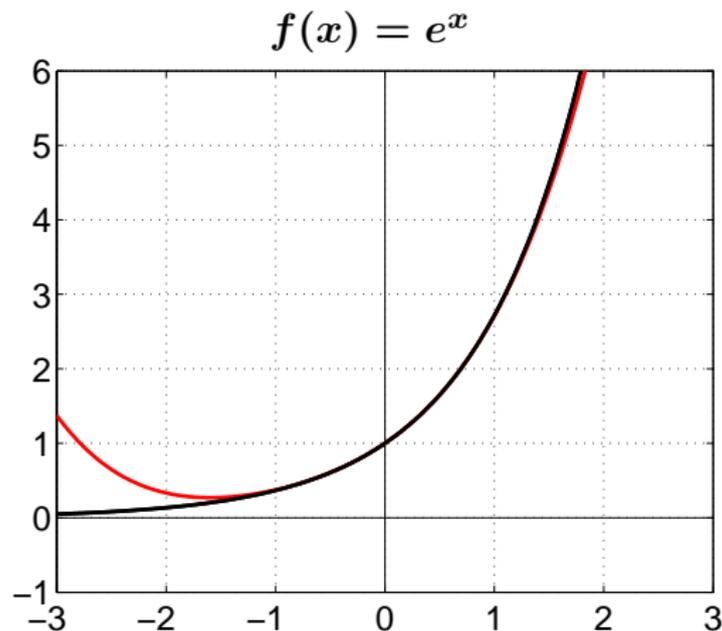
Taylor-Pol. 2. Grades in 0:  $p_2(x) = 1 + x + \frac{x^2}{2!}$

## Taylor-Entwicklung: Skalare Funktionen



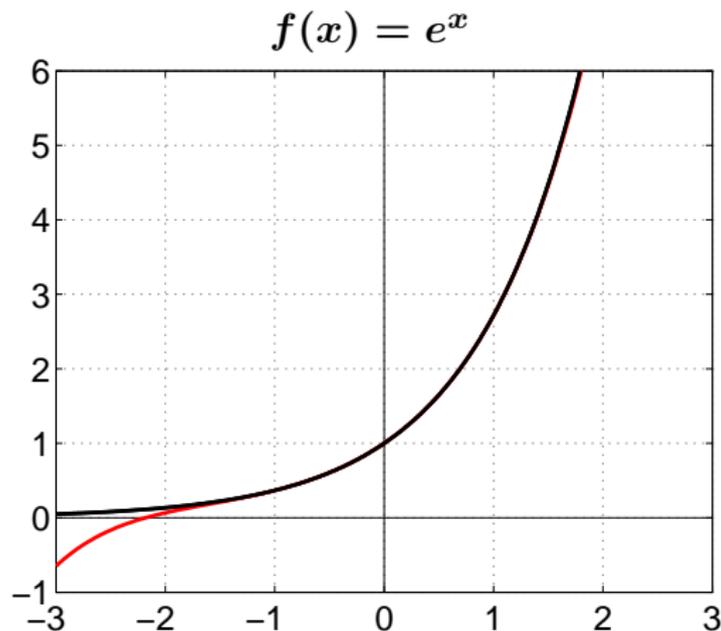
Taylor-Pol. 3. Grades in 0:  $p_3(x) = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!}$

## Taylor-Entwicklung: Skalare Funktionen



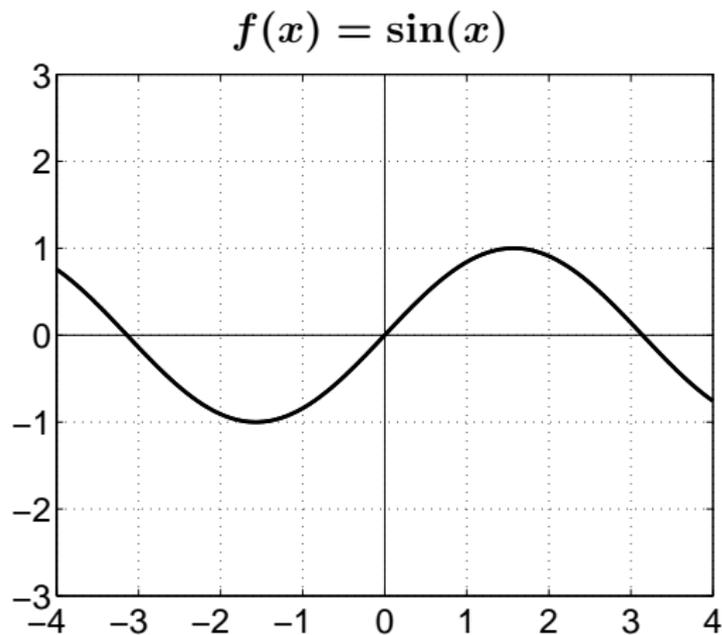
Taylor-Pol. 4. Grades in 0:  $p_4(x) = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \frac{x^4}{4!}$

## Taylor-Entwicklung: Skalare Funktionen

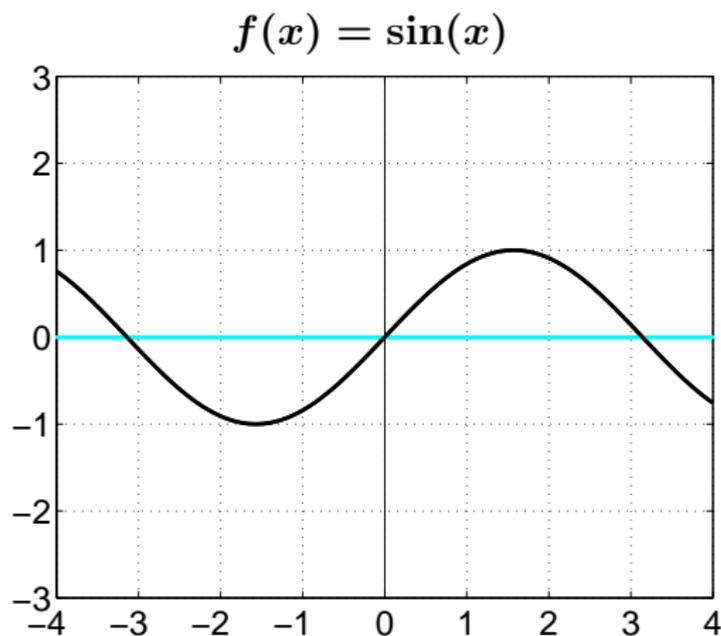


Taylor-Pol. 5. Grades in 0:  $p_5(x) = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \frac{x^4}{4!} + \frac{x^5}{5!}$

## Taylor-Entwicklung: Skalare Funktionen

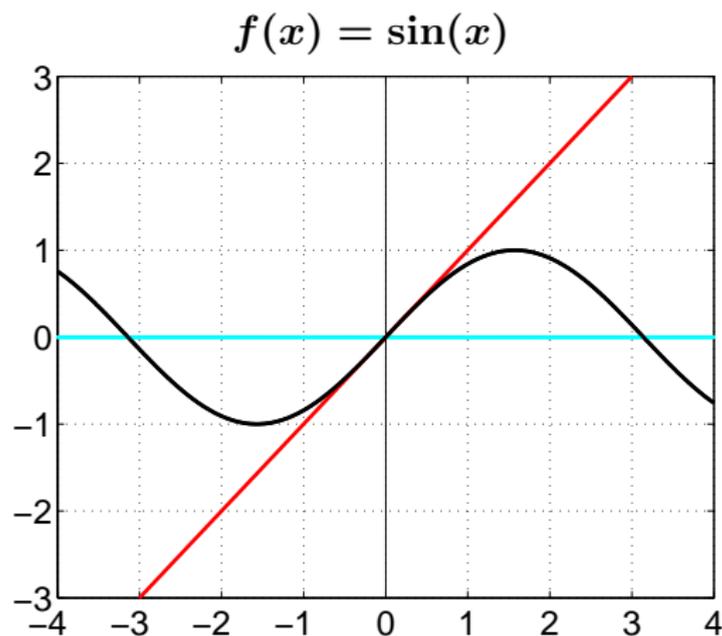


## Taylor-Entwicklung: Skalare Funktionen



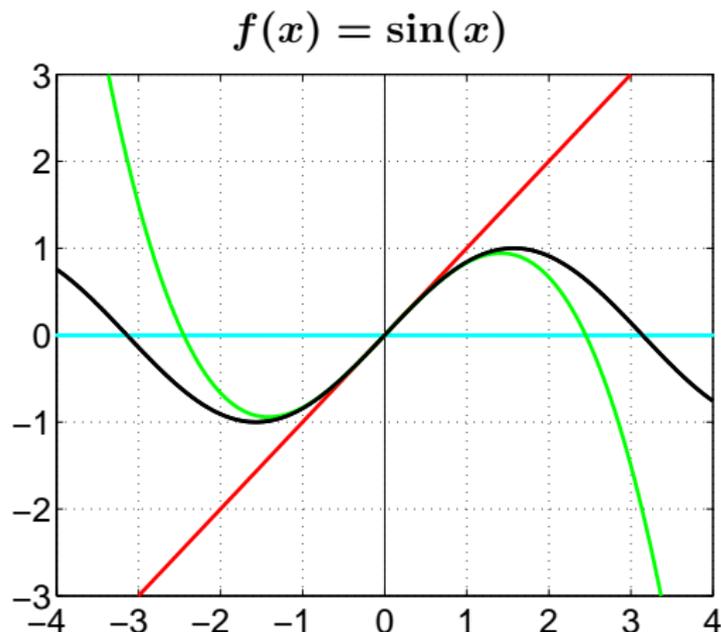
Taylor-Polynom 0. Grades in 0:  $p_0(x) = 0$

## Taylor-Entwicklung: Skalare Funktionen



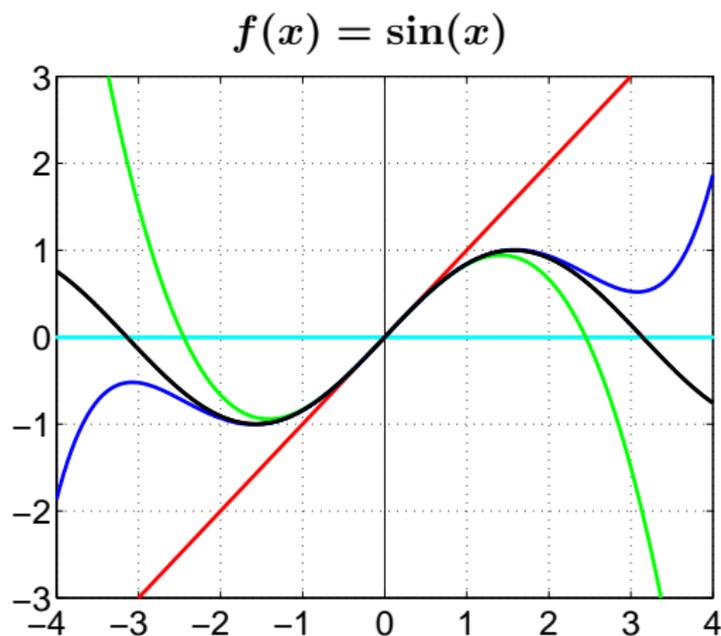
Taylor-Polynom 1. Grades in 0:  $p_1(x) = x$

## Taylor-Entwicklung: Skalare Funktionen



Taylor-Polynom 3. Grades in 0:  $p_3(x) = x - \frac{x^3}{3!}$

## Taylor-Entwicklung: Skalare Funktionen



Taylor-Polynom 5. Grades in 0:  $p_5(x) = x - \frac{x^3}{3!} + \frac{x^5}{5!}$



## Taylor-Entwicklung: Vektorwertige Funktionen

Taylor-Entwicklung (von  $f$  um  $x$ )

Für hinreichend oft differenzierbares  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  gilt

$$\begin{aligned} f(\tilde{x}) &= f(x) + \sum_{j=1}^n \frac{\partial f(x)}{\partial x_j} (\tilde{x}_j - x_j) \\ &+ \sum_{i,j=1}^n \frac{1}{2} \frac{\partial^2 f(x)}{\partial x_i \partial x_j} (\tilde{x}_i - x_i)(\tilde{x}_j - x_j) + \mathcal{O}(\|\tilde{x} - x\|_2^3). \end{aligned}$$

## Taylor-Entwicklung: Vektorwertige Funktionen

Taylor-Entwicklung (von  $f$  um  $x$ )

Für hinreichend oft differenzierbares  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  gilt

$$f(\tilde{x}) = f(x) + \sum_{j=1}^n \frac{\partial f(x)}{\partial x_j} (\tilde{x}_j - x_j) + \sum_{i,j=1}^n \frac{1}{2} \frac{\partial^2 f(x)}{\partial x_i \partial x_j} (\tilde{x}_i - x_i)(\tilde{x}_j - x_j) + \mathcal{O}(\|\tilde{x} - x\|_2^3).$$

- ▶ Gradient:  $\nabla f(x) = \left( \frac{\partial f(x)}{\partial x_1}, \dots, \frac{\partial f(x)}{\partial x_n} \right)^T$
- ▶ Hesse-Matrix:  $f''(x) = \left( \frac{\partial^2 f(x)}{\partial x_i \partial x_j} \right)_{i,j=1}^n$

## Taylor-Entwicklung: Vektorwertige Funktionen

## Kompakte Schreibweise

$$\begin{aligned} f(\tilde{x}) &= f(x) + (\nabla f(x))^T (\tilde{x} - x) \\ &\quad + \frac{1}{2}(\tilde{x} - x)^T f''(x)(\tilde{x} - x) + \mathcal{O}(\|\tilde{x} - x\|_2^3). \end{aligned}$$

oder

$$f(\tilde{x}) = f(x) + (\nabla f(x))^T (\tilde{x} - x) + \mathcal{O}(\|\tilde{x} - x\|_2^2).$$

Falls  $\|\tilde{x} - x\| \ll 1$ :

$$f(\tilde{x}) \doteq f(x) + (\nabla f(x))^T (\tilde{x} - x)$$

 $\doteq$  : Terme höherer Ordnung werden vernachlässigt.

# Fehlerquellen

Fehler im Resultat auf Grund von

- ▶ Datenfehlern (oder Eingabefehlern)

⇒ **Kondition eines Problems**

– können häufig nicht vermieden werden

# Fehlerquellen

Fehler im Resultat auf Grund von

- ▶ Datenfehlern (oder Eingabefehlern)

⇒ **Kondition eines Problems**

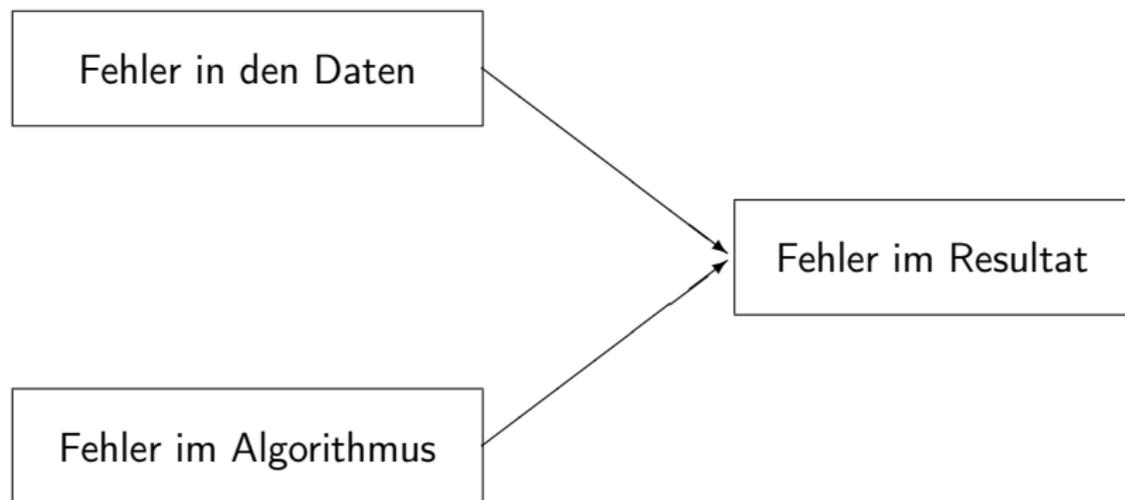
– können häufig nicht vermieden werden

- ▶ Fehler(akkumulation) im Algorithmus (z.B. Rundungsfehler)

⇒ **Stabilität eines Algorithmus**

– kann man beeinflussen durch Anpassung des Verfahrens

# Fehleranalyse: Kondition, Rundungsfehler, Stabilität



# Kondition

**Ziel:** Analyse der Fehlerverstärkung bei Datenfehlern

## Konzept der Kondition eines Problems

# Kondition

**Ziel:** Analyse der Fehlerverstärkung bei Datenfehlern

## Konzept der Kondition eines Problems

### Beachte: Kondition

- ▶ ist **unabhängig** von einem speziellen Lösungsweg (Algorithmus)
- ▶ gibt an, welche Genauigkeit man **bestenfalls (bei exakter Rechnung)** bei gestörten Eingangsdaten erwarten kann.

# Kondition

**Ziel:** Analyse der Fehlerverstärkung bei Datenfehlern

## Konzept der Kondition eines Problems

### Beachte: Kondition

- ▶ ist **unabhängig** von einem speziellen Lösungsweg (Algorithmus)
- ▶ gibt an, welche Genauigkeit man **bestenfalls (bei exakter Rechnung)** bei gestörten Eingangsdaten erwarten kann.

Wir fassen den “mathematischen Prozess” oder das “Problem” als Aufgabe auf, eine gegebene Funktion

$$f : X \rightarrow Y$$

an einer Stelle  $x \in X$  auszuwerten.

# Elementare Beispiele

- ▶ Die Berechnung der Multiplikation von  $x_1$  und  $x_2$ :

$$f(x_1, x_2) = x_1 x_2$$

und  $X = \mathbb{R}^2$ ,  $Y = \mathbb{R}$ .

# Elementare Beispiele

- ▶ Die Berechnung der Multiplikation von  $x_1$  und  $x_2$ :

$$f(x_1, x_2) = x_1 x_2$$

und  $X = \mathbb{R}^2$ ,  $Y = \mathbb{R}$ .

- ▶ Die Berechnung der Summe von  $x_1$  und  $x_2$ :

$$f(x_1, x_2) = x_1 + x_2$$

und  $X = \mathbb{R}^2$ ,  $Y = \mathbb{R}$ .

## Elementare Beispiele

- ▶ Man bestimme die kleinere Nullstelle der Gleichung

$$y^2 - 2x_1 y + x_2 = 0,$$

mit  $x_1^2 > x_2$ . Die Lösung  $y^*$  ist

$$y^* = f(x_1, x_2) = x_1 - \sqrt{x_1^2 - x_2}.$$

mit

$$X = \{(x_1, x_2) \in \mathbb{R}^2 \mid x_1^2 > x_2\},$$

$$Y = \mathbb{R}.$$

## Elementare Beispiele

- Bestimmung des Schnittpunktes zweier Geraden:

$$G_1 = \{(y_1, y_2) \in \mathbb{R}^2 \mid a_{1,1} y_1 + a_{1,2} y_2 = x_1\}$$

$$G_2 = \{(y_1, y_2) \in \mathbb{R}^2 \mid a_{2,1} y_1 + a_{2,2} y_2 = x_2\}$$

wobei  $(x_1, x_2)^T \in \mathbb{R}^2$  und  $a_{i,j}$  gegeben seien.

Mit

$$A = \begin{pmatrix} a_{1,1} & a_{1,2} \\ a_{2,1} & a_{2,2} \end{pmatrix}$$

ergibt sich

$$Ay = x.$$

## Elementare Beispiele

- Bestimmung des Schnittpunktes zweier Geraden: (Fortsetzung)

Es gilt also

$$A \cdot \mathbf{y} = \begin{pmatrix} a_{1,1} & a_{1,2} \\ a_{2,1} & a_{2,2} \end{pmatrix} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \mathbf{x}$$

**Annahme:**  $\det A \neq 0$

Dann ist  $\mathbf{y}$  durch

$$\mathbf{y} = A^{-1}\mathbf{x}$$

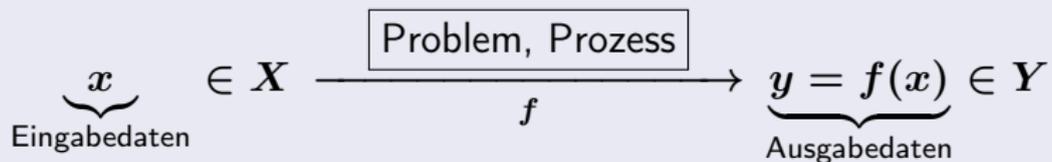
gegeben. Also Auswertung der Funktion

$$f(\mathbf{x}) = A^{-1}\mathbf{x},$$

d.h.  $X = Y = \mathbb{R}^2$ .

# Begriff der Kondition

## Ungestörtes Problem



## Begriff der Kondition

## Ungestörtes Problem

$$\underbrace{x}_{\text{Eingabedaten}} \in X \xrightarrow[\textit{f}]{\text{Problem, Prozess}} \underbrace{y = f(x)}_{\text{Ausgabedaten}} \in Y$$

## Gestörtes Problem

$$\tilde{x} = x + \Delta x \xrightarrow[\textit{f}]{\text{Problem, Prozess}} \tilde{y} = f(\tilde{x})$$

mit Eingabefehler  $\Delta x = \tilde{x} - x$

Ausgabefehler  $\Delta y = \tilde{y} - y = f(\tilde{x}) - f(x)$

## Begriff der Kondition

## Ungestörtes Problem

$$\underbrace{x}_{\text{Eingabedaten}} \in X \xrightarrow[\textit{f}]{\text{Problem, Prozess}} \underbrace{y = f(x)}_{\text{Ausgabedaten}} \in Y$$

## Gestörtes Problem

$$\tilde{x} = x + \Delta x \xrightarrow[\textit{f}]{\text{Problem, Prozess}} \tilde{y} = f(\tilde{x})$$

mit Eingabefehler  $\Delta x = \tilde{x} - x$

Ausgabefehler  $\Delta y = \tilde{y} - y = f(\tilde{x}) - f(x)$

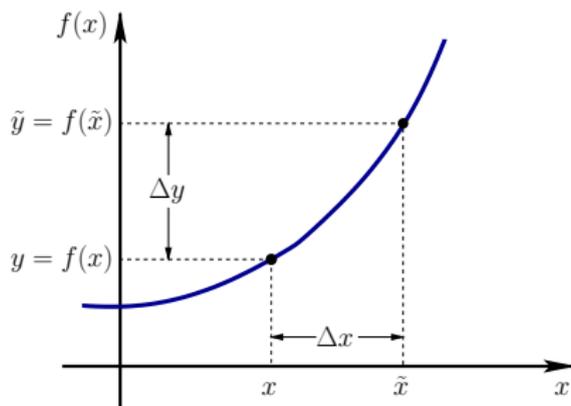
**Ziel:** Verhältnis Ausgabefehler  $\Delta y$  zu Eingabefehler  $\Delta x$ .

# Begriff der Kondition

## Arten von Fehlern

- ▶ absoluter Eingabefehler:  $\|\Delta \mathbf{x}\|_X$
- ▶ absoluter Ausgabefehler:  $\|\Delta \mathbf{y}\|_Y$
- ▶ relativer Eingabefehler:  $\delta_x = \frac{\|\Delta \mathbf{x}\|_X}{\|\mathbf{x}\|_X}$
- ▶ relativer Ausgabefehler:  $\delta_y = \frac{\|\Delta \mathbf{y}\|_Y}{\|\mathbf{y}\|_Y}$

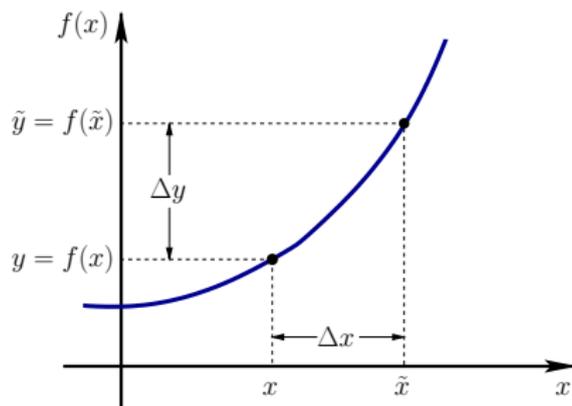
# Begriff der Kondition: skalare Funktion



Allgemein:

- ▶ absoluter Eingabefehler:  $\|\Delta \mathbf{x}\|_X$
- ▶ absoluter Ausgabefehler:  $\|\Delta \mathbf{y}\|_Y$

## Begriff der Kondition: skalare Funktion



Allgemein:

- ▶ relativer Eingabefehler:  $\delta_x = \frac{\|\Delta x\|_X}{\|x\|_X}$
- ▶ relativer Ausgabefehler:  $\delta_y = \frac{\|\Delta y\|_Y}{\|y\|_Y}$

# Begriff der Kondition

## Definition

Mit der **relativen Kondition** eines (durch  $f$  beschriebenen) Problems bezeichnet man das Verhältnis

$$\frac{\delta_y}{\delta_x}$$

des relativen Ausgabefehlers zum relativen Eingabefehler, d.h. die **Sensitivität** des Problems unter Störungen der Eingabedaten.

# Begriff der Kondition

## Definition

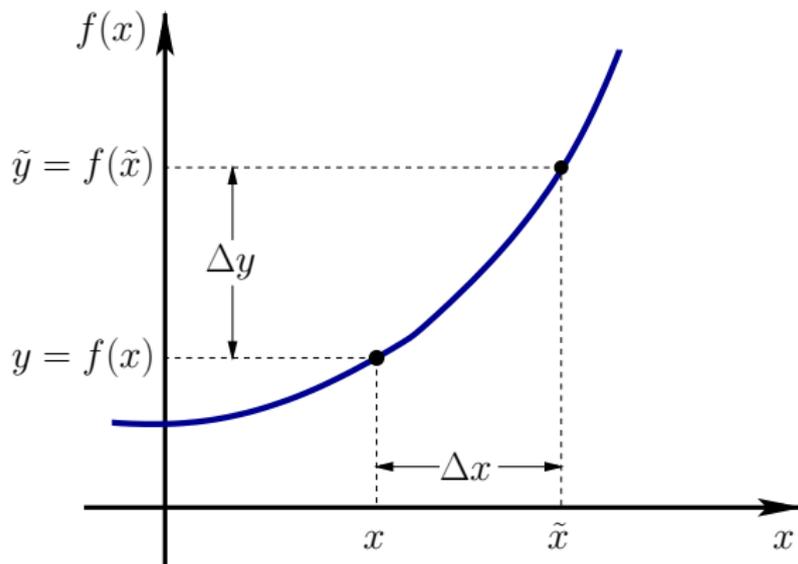
Mit der **relativen Kondition** eines (durch  $f$  beschriebenen) Problems bezeichnet man das Verhältnis

$$\frac{\delta_y}{\delta_x}$$

des relativen Ausgabefehlers zum relativen Eingabefehler, d.h. die **Sensitivität** des Problems unter Störungen der Eingabedaten.

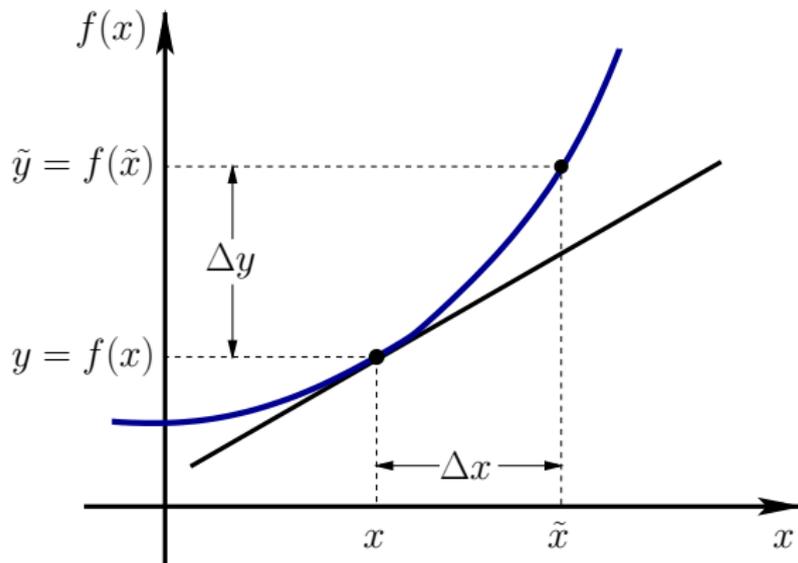
- ▶ **Absolute Kondition**: Verhältnis  $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$
- ▶ Mit Kondition wird meistens die **relative** Kondition gemeint.
- ▶ Ein Problem ist umso besser **konditioniert**, je kleinere Schranken für  $\delta_y/\delta_x$  (mit  $\delta_x \rightarrow 0$ ) existieren.

# Taylorentwicklung 1. Ordnung



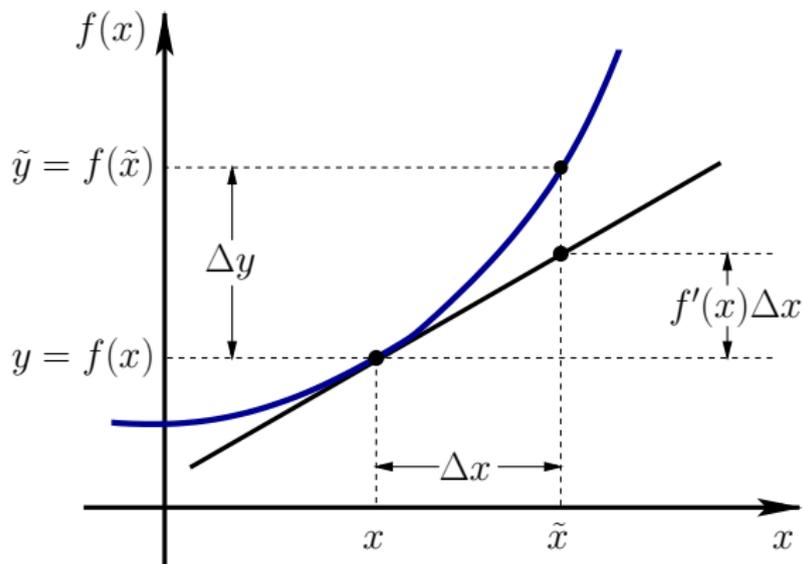
Relative / absolute Kondition: Verhältnis  $\frac{\delta_y}{\delta_x}$  bzw.  $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$ .

# Taylorentwicklung 1. Ordnung



Relative / absolute Kondition: Verhältnis  $\frac{\delta_y}{\delta_x}$  bzw.  $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$ .

# Taylorentwicklung 1. Ordnung



Relative / absolute Kondition: Verhältnis  $\frac{\delta_y}{\delta_x}$  bzw.  $\frac{\|\Delta y\|_Y}{\|\Delta x\|_X}$ .

Kondition:  $f : \mathbb{R} \rightarrow \mathbb{R}$

Taylor-Entwicklung 1. Ordnung von  $f$  um festes  $x$

$$f(\tilde{x}) \doteq f(x) + f'(x)(\tilde{x} - x)$$

Daraus erhält man die Kondition für

▶  $f : \mathbb{R} \rightarrow \mathbb{R}$  (Eingabe: Skalar, Ausgabe: Skalar)

Kondition:  $f : \mathbb{R} \rightarrow \mathbb{R}$

Taylor-Entwicklung 1. Ordnung von  $f$  um festes  $x$

$$f(\tilde{x}) \doteq f(x) + f'(x) (\tilde{x} - x)$$

Daraus erhält man die Kondition für

►  $f : \mathbb{R} \rightarrow \mathbb{R}$  (Eingabe: Skalar, Ausgabe: Skalar)

$$\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| \doteq \kappa_{\text{rel}}(x) \left| \frac{\tilde{x} - x}{x} \right|$$

mit

$$\kappa_{\text{rel}}(x) := \left| f'(x) \frac{x}{f(x)} \right|$$

Kondition:  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Für  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  lautet die Taylor-Reihenentwicklung 1. Ordnung

$$f(\tilde{x}) \doteq f(x) + (\nabla f(x))^T \cdot (\tilde{x} - x)$$

mit

$$x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \in \mathbb{R}^n.$$

Kondition:  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Für  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  lautet die Taylor-Reihenentwicklung 1. Ordnung

$$f(\tilde{x}) \doteq f(x) + (\nabla f(x))^T \cdot (\tilde{x} - x)$$

mit

$$x = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} \in \mathbb{R}^n.$$

Hieraus folgt

$$\frac{f(\tilde{x}) - f(x)}{f(x)} \doteq \sum_{j=1}^n \left( \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)} \right) \cdot \frac{\tilde{x}_j - x_j}{x_j}$$

Kondition:  $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Mit den Verstärkungsfaktoren

$$\phi_j(x) = \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)}$$

erhält man

$$\underbrace{\frac{f(\tilde{x}) - f(x)}{f(x)}}_{\text{relativer Fehler der Ausgabe}} \doteq \sum_{j=1}^n \underbrace{\phi_j(x)}_{\text{Fehlerverstärkung}} \cdot \underbrace{\frac{\tilde{x}_j - x_j}{x_j}}_{\text{relativer Fehler der Eingabe in } x_j}$$

# Kondition $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Damit erhält man die Kondition für

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  (Eingabe: Vektor, Ausgabe: Skalar)

# Kondition $f : \mathbb{R}^n \rightarrow \mathbb{R}$

Damit erhält man die Kondition für

- ▶  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  (Eingabe: Vektor, Ausgabe: Skalar)

$$\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| \stackrel{\cdot}{\leq} \kappa_{\text{rel}}(x) \sum_{j=1}^n \left| \frac{\tilde{x}_j - x_j}{x_j} \right|$$

mit

$$\kappa_{\text{rel}}(x) = \kappa_{\text{rel}}^{\infty}(x) := \max_j |\phi_j(x)|$$

und den Verstärkungsfaktoren

$$\phi_j(x) = \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)}$$

wobei  $\stackrel{\cdot}{\leq}$  entsprechend  $\stackrel{\cdot}{=}$  zu verstehen ist.

## Beispiel 2.26.

Gegeben sei

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = e^{3x^2}.$$

Relative Konditionszahl:

$$\kappa_{\text{rel}}(x) = \left| f'(x) \frac{x}{f(x)} \right| = 6x^2.$$

$\rightsquigarrow$  für  $|x|$  klein/groß ist  $f$  gut/schlecht konditioniert.

## Beispiel 2.26.

Gegeben sei

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = e^{3x^2}.$$

Relative Konditionszahl:

$$\kappa_{\text{rel}}(x) = \left| f'(x) \frac{x}{f(x)} \right| = 6x^2.$$

$\rightsquigarrow$  für  $|x|$  klein/groß ist  $f$  gut/schlecht konditioniert.

## Beispiel

►  $x = 0.1, \tilde{x} = 0.10001: \kappa_{\text{rel}}(0.1) = 6 \cdot 10^{-2}$

$$\left| \frac{\tilde{x} - x}{x} \right| = 10^{-4} \rightarrow \left| \frac{f(x) - f(\tilde{x})}{f(x)} \right| = 6.03 \cdot 10^{-6}$$

## Beispiel 2.26.

Gegeben sei

$$f : \mathbb{R} \rightarrow \mathbb{R}, \quad f(x) = e^{3x^2}.$$

Relative Konditionszahl:

$$\kappa_{\text{rel}}(x) = \left| f'(x) \frac{x}{f(x)} \right| = 6x^2.$$

$\rightsquigarrow$  für  $|x|$  klein/groß ist  $f$  gut/schlecht konditioniert.

## Beispiel

▶  $x = 0.1, \tilde{x} = 0.10001: \kappa_{\text{rel}}(0.1) = 6 \cdot 10^{-2}$

$$\left| \frac{\tilde{x} - x}{x} \right| = 10^{-4} \rightarrow \left| \frac{f(x) - f(\tilde{x})}{f(x)} \right| = 6.03 \cdot 10^{-6}$$

▶  $x = 4, \tilde{x} = 4.0004: \kappa_{\text{rel}}(4) = 96$

$$\left| \frac{\tilde{x} - x}{x} \right| = 10^{-4} \rightarrow \left| \frac{f(x) - f(\tilde{x})}{f(x)} \right| = 9.65 \cdot 10^{-3}$$

# Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation:  $x = (x_1, x_2)^T$ ,  $f(x) = x_1 x_2$

# Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation:  $x = (x_1, x_2)^T$ ,  $f(x) = x_1 x_2$

$$\kappa_{\text{rel}}(x) = 1 \text{ (von } x \text{ unabhängig!)}$$

Multiplikation für alle Eingangsdaten gut konditioniert.

Ein ähnliches Resultat gilt für die Division.

# Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation:  $x = (x_1, x_2)^T$ ,  $f(x) = x_1 x_2$

$$\kappa_{\text{rel}}(x) = 1 \text{ (von } x \text{ unabhängig!)}$$

Multiplikation für alle Eingangsdaten gut konditioniert.

Ein ähnliches Resultat gilt für die Division.

- ▶ Addition:  $x = (x_1, x_2)^T$ ,  $f(x) = x_1 + x_2$

# Elementare Rechenoperationen

Kondition bei

- ▶ Multiplikation:  $x = (x_1, x_2)^T$ ,  $f(x) = x_1 x_2$

$$\kappa_{\text{rel}}(x) = 1 \text{ (von } x \text{ unabhängig!)}$$

Multiplikation für alle Eingangsdaten gut konditioniert.

Ein ähnliches Resultat gilt für die Division.

- ▶ Addition:  $x = (x_1, x_2)^T$ ,  $f(x) = x_1 + x_2$

$$\kappa_{\text{rel}}(x) = \max \left\{ \left| \frac{x_1}{x_1 + x_2} \right|, \left| \frac{x_2}{x_1 + x_2} \right| \right\}$$

Bei zwei Zahlen mit gleichem Vorzeichen:  $\kappa_{\text{rel}} \leq 1$ .

**ABER:**  $\kappa_{\text{rel}}(x) \gg 1$  wenn  $x_1 \approx -x_2$ .

## Beispiel 2.29 (Nullstelle)

Bestimmung der kleineren Nullstelle  $y^*$  von  $y^2 - 2x_1y + x_2 = 0$ :

$$x = (x_1, x_2)^T, \quad y^* = f(x) = x_1 - \sqrt{x_1^2 - x_2}$$

- ▶ Partielle Ableitungen

$$\frac{\partial f(x)}{\partial x_1} = \frac{\sqrt{x_1^2 - x_2} - x_1}{\sqrt{x_1^2 - x_2}} = \frac{-y^*}{\sqrt{x_1^2 - x_2}}$$

$$\frac{\partial f(x)}{\partial x_2} = \frac{1}{2\sqrt{x_1^2 - x_2}}$$

- ▶ Verstärkungsfaktoren

$$\phi_j(x) = \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)}$$

## Beispiel 2.29 (Nullstelle)

- ▶ Verstärkungsfaktoren

$$\phi_1(x) = \frac{-y^*}{\sqrt{x_1^2 - x_2}} \cdot \frac{x_1}{y^*} = \frac{-x_1}{\sqrt{x_1^2 - x_2}}$$

$$\phi_2(x) = \frac{1}{2\sqrt{x_1^2 - x_2}} \cdot \frac{x_2}{y^*} = \frac{1}{2} - \frac{1}{2}\phi_1(x)$$

- ▶ Kondition:  $\kappa_{\text{rel}}(x) = \max_j |\phi_j(x)|$

## Beispiel 2.29 (Nullstelle)

- ▶ Verstärkungsfaktoren

$$\phi_1(x) = \frac{-y^*}{\sqrt{x_1^2 - x_2}} \cdot \frac{x_1}{y^*} = \frac{-x_1}{\sqrt{x_1^2 - x_2}}$$

$$\phi_2(x) = \frac{1}{2\sqrt{x_1^2 - x_2}} \cdot \frac{x_2}{y^*} = \frac{1}{2} - \frac{1}{2}\phi_1(x)$$

- ▶ Kondition:  $\kappa_{\text{rel}}(x) = \max_j |\phi_j(x)|$

Kondition hängt stark von der Stelle  $(x_1, x_2)$  ab:

## Beispiel 2.29 (Nullstelle)

- ▶ Verstärkungsfaktoren

$$\phi_1(x) = \frac{-y^*}{\sqrt{x_1^2 - x_2}} \cdot \frac{x_1}{y^*} = \frac{-x_1}{\sqrt{x_1^2 - x_2}}$$

$$\phi_2(x) = \frac{1}{2\sqrt{x_1^2 - x_2}} \cdot \frac{x_2}{y^*} = \frac{1}{2} - \frac{1}{2}\phi_1(x)$$

- ▶ Kondition:  $\kappa_{\text{rel}}(x) = \max_j |\phi_j(x)|$

Kondition hängt stark von der Stelle  $(x_1, x_2)$  ab:

- ▶ Wenn  $x_2 < 0$ :  $|\phi_1(x)| \leq 1$  und  $\kappa_{\text{rel}}(x) \leq 1$
- ▶ Wenn  $x_2 \approx x_1^2$ :  $|\phi_1(x)| \gg 1$  und  $\kappa_{\text{rel}}(x) \gg 1$

Kondition:  $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ ,  $f$  linear

Sei  $f = B \in \mathbb{R}^{n \times n}$ , mit  $\det B \neq 0$ , also

$$y = f(x) = Bx$$

bzw. für gestörte Daten

$$\tilde{y} = f(\tilde{x}) = B\tilde{x}$$

und damit

$$\begin{aligned} f(\tilde{x}) - f(x) &= B\tilde{x} - Bx = B(\tilde{x} - x) \\ x &= B^{-1}y \end{aligned}$$

Kondition:  $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ ,  $f$  linear

Wegen  $\|x\| = \|B^{-1}y\| \leq \|B^{-1}\| \|y\|$  gilt

$$\frac{\|f(\tilde{x}) - f(x)\|}{\|f(x)\|} = \frac{\|B(\tilde{x} - x)\|}{\|y\|} \leq \underbrace{\|B\| \cdot \|B^{-1}\|}_{\kappa(B)} \frac{\|\tilde{x} - x\|}{\|x\|}$$

wobei

$$\kappa(B) \equiv \|B\| \cdot \|B^{-1}\|$$

die **Konditionszahl** der Matrix  $B$  ist.

Kondition:  $f : \mathbb{R}^n \rightarrow \mathbb{R}^n$ ,  $f$  linear

Wegen  $\|x\| = \|B^{-1}y\| \leq \|B^{-1}\| \|y\|$  gilt

$$\frac{\|f(\tilde{x}) - f(x)\|}{\|f(x)\|} = \frac{\|B(\tilde{x} - x)\|}{\|y\|} \leq \underbrace{\|B\| \cdot \|B^{-1}\|}_{\kappa(B)} \frac{\|\tilde{x} - x\|}{\|x\|}$$

wobei

$$\kappa(B) \equiv \|B\| \cdot \|B^{-1}\|$$

die **Konditionszahl** der Matrix  $B$  ist.

Beachte:

$\kappa(B) = \kappa(B^{-1})$  hängt nur von der Matrix  $B$  (und der Norm  $\|\cdot\|$ ) ab.

## Beispiel 2.34.

Die Bestimmung des Schnittpunkts der Geraden

$$3 u_1 + 1.001 u_2 = 1.999$$

$$6 u_1 + 1.997 u_2 = 4.003.$$

(fast parallel!) ergibt das Problem  $u = A^{-1}b$  mit

$$A = \begin{pmatrix} 3 & 1.001 \\ 6 & 1.997 \end{pmatrix}, \quad b = \begin{pmatrix} 1.999 \\ 4.003 \end{pmatrix}.$$

Die Lösung ist

$$u = \begin{pmatrix} 1 \\ -1 \end{pmatrix}.$$

## Beispiel 2.34.

Die Bestimmung des Schnittpunkts der Geraden

$$3 u_1 + 1.001 u_2 = 1.999$$

$$6 u_1 + 1.997 u_2 = 4.003.$$

(fast parallel!) ergibt das Problem  $u = A^{-1}b$  mit

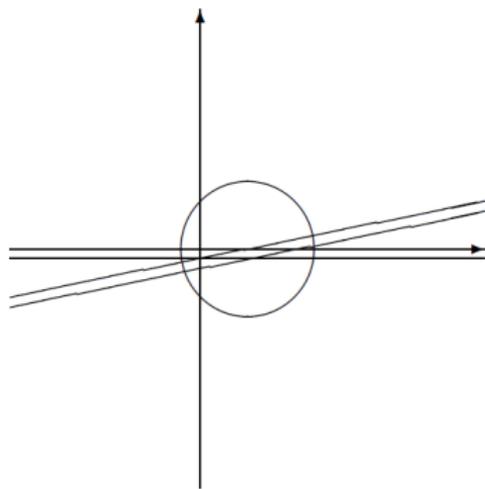
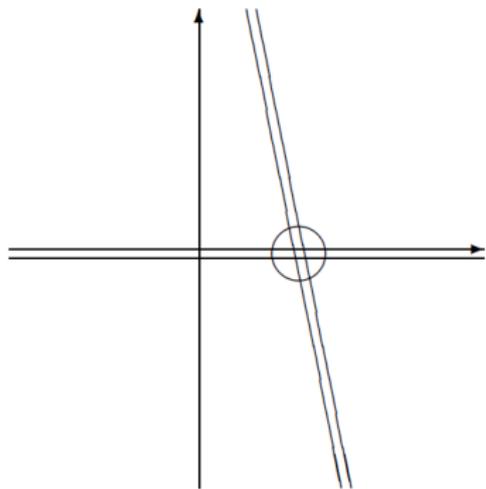
$$A = \begin{pmatrix} 3 & 1.001 \\ 6 & 1.997 \end{pmatrix}, \quad b = \begin{pmatrix} 1.999 \\ 4.003 \end{pmatrix}.$$

Die Lösung ist

$$u = \begin{pmatrix} 1 \\ -1 \end{pmatrix}.$$

Also:  $f : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ ,  $f(x) = A^{-1}x$ .

## Beispiel 2.34. Kondition bei Bestimmung eines Schnittpunktes



## Beispiel 2.34.

Effekt einer Störung in  $b$ :

$$\tilde{b} = \begin{pmatrix} 2.002 \\ 4 \end{pmatrix}, \quad \tilde{u} = A^{-1}\tilde{b}.$$

Man erhält

$$A^{-1} = \frac{-1}{0.015} \begin{pmatrix} 1.997 & -1.001 \\ -6 & 3 \end{pmatrix}, \quad \tilde{u} = \begin{pmatrix} 0.4004 \\ 0.8 \end{pmatrix}$$

## Beispiel 2.34.

Effekt einer Störung in  $b$ :

$$\tilde{b} = \begin{pmatrix} 2.002 \\ 4 \end{pmatrix}, \quad \tilde{u} = A^{-1}\tilde{b}.$$

Man erhält

$$A^{-1} = \frac{-1}{0.015} \begin{pmatrix} 1.997 & -1.001 \\ -6 & 3 \end{pmatrix}, \quad \tilde{u} = \begin{pmatrix} 0.4004 \\ 0.8 \end{pmatrix}$$

Wir betrachten die Maximumnorm:

$$\|x\| = \|x\|_{\infty} = \max_i |x_i|.$$

## Beispiel 2.34.

Es gilt

- ▶ Störung der Daten

$$\frac{\|\tilde{b} - b\|_{\infty}}{\|b\|_{\infty}} = \frac{3 \cdot 10^{-3}}{4.003} \approx 7.5 \cdot 10^{-4}$$

- ▶ Änderung des Resultats

$$\frac{\|\tilde{u} - u\|_{\infty}}{\|u\|_{\infty}} = \frac{1.8}{1} \approx 1.8$$

Schlechte Kondition wird quantifiziert durch

$$\|A\|_{\infty} \|A^{-1}\|_{\infty} = 4798.2.$$

# Kondition einer Basis

Sei  $V$  ein linearer normierter Raum mit Basis  $\Phi = \{\phi_1, \dots, \phi_n\}$ . Die **Koordinaten-Abbildung** ist durch

$$\mathcal{L} : \mathbb{R}^n \rightarrow V, \quad \mathcal{L}(a) = \sum_{i=1}^n a_i \phi_i,$$

gegeben.

## Kondition

Es gilt

$$\begin{aligned} & \min \{ C/|c| \mid |c| \|a\| \leq \left\| \sum_{j=1}^n a_j \phi_j \right\|_V \leq C \|a\| \quad \forall a \in \mathbb{R}^n \} \\ & = \kappa(\mathcal{L}) = \|\mathcal{L}\|_{\mathbb{R}^n \rightarrow V} \|\mathcal{L}^{-1}\|_{V \rightarrow \mathbb{R}^n} \end{aligned}$$

# Kondition einer Basis

## Gram-Matrix

Annahmen:  $\|\cdot\|_V$  entspricht  $(\cdot, \cdot)_V$ , und  $\|\cdot\| := \|\cdot\|_2$  auf  $\mathbb{R}^n$ .

Gram-Matrix:  $G_{i,j} := (\phi_i, \phi_j)_V, \quad 1 \leq i, j \leq n,$

definiert. Es gilt  $\kappa(\mathcal{L}) = \sqrt{\kappa_2(G)}$ .

# Kondition einer Basis

## Gram-Matrix

Annahmen:  $\|\cdot\|_V$  entspricht  $(\cdot, \cdot)_V$ , und  $\|\cdot\| := \|\cdot\|_2$  auf  $\mathbb{R}^n$ .

$$\text{Gram-Matrix: } G_{i,j} := (\phi_i, \phi_j)_V, \quad 1 \leq i, j \leq n,$$

definiert. Es gilt  $\kappa(\mathcal{L}) = \sqrt{\kappa_2(G)}$ .

## Beispiel

Sei  $V = \Pi_m$ , mit Dimension  $n := m + 1$ , Skalarprodukt  $(f, g)_V := \int_0^1 f(t)g(t) dt$  und die Basis  $\phi_i(t) = t^{i-1}$ ,  $i = 1, \dots, n$ .

$$G_{i,j} = \int_0^1 \phi_i(t)\phi_j(t) dt = \int_0^1 t^{i+j-2} dt = \frac{1}{i+j-1}$$

Diese Matrix  $G$  wird **Hilbert-Matrix** genannt. Sie hat eine (sehr) große Konditionszahl, z.B.  $3.75 \cdot 10^{16}$  für  $n = 12$ .

# Zahldarstellungen: Beispiel 2.40.

Wir betrachten als Beispiel die Zahl **123.75**:

- ▶ Dezimalsystem (Basis 10)

**123.75**

$$= 1 \cdot 10^2 + 2 \cdot 10^1 + 3 \cdot 10^0 + 7 \cdot 10^{-1} + 5 \cdot 10^{-2}$$

$$= 10^3 (1 \cdot 10^{-1} + 2 \cdot 10^{-2} + 3 \cdot 10^{-3} + 7 \cdot 10^{-4} + 5 \cdot 10^{-5})$$

## Zahldarstellungen: Beispiel 2.40.

Wir betrachten als Beispiel die Zahl **123.75**:

- ▶ Dezimalsystem (Basis 10)

**123.75**

$$= 1 \cdot 10^2 + 2 \cdot 10^1 + 3 \cdot 10^0 + 7 \cdot 10^{-1} + 5 \cdot 10^{-2}$$

$$= 10^3 (1 \cdot 10^{-1} + 2 \cdot 10^{-2} + 3 \cdot 10^{-3} + 7 \cdot 10^{-4} + 5 \cdot 10^{-5})$$

- ▶ Binärsystem (Basis 2)

**123.75**

$$= 1 \cdot 2^6 + 1 \cdot 2^5 + 1 \cdot 2^4 + 1 \cdot 2^3 + 0 \cdot 2^2 + 1 \cdot 2^1 + 1 \cdot 2^0 \\ + 1 \cdot 2^{-1} + 1 \cdot 2^{-2}$$

$$= 2^7 (1 \cdot 2^{-1} + 1 \cdot 2^{-2} + 1 \cdot 2^{-3} + 1 \cdot 2^{-4} + 0 \cdot 2^{-5} + 1 \cdot 2^{-6} \\ + 1 \cdot 2^{-7} + 1 \cdot 2^{-8} + 1 \cdot 2^{-9})$$

# Zahendarstellung

Seien  $b \in \mathbb{N}$ ,  $b > 1$ , fest gewählt. Jedes  $x \in \mathbb{R}$ ,  $x \neq 0$ , lässt sich in der Form

$$x = \pm \left( \sum_{j=1}^{\infty} d_j b^{-j} \right) \cdot b^e$$

darstellen, mit  $d_j \in \{0, 1, \dots, b-1\}$ ,  $d_1 \neq 0$ , und  $e$  eine ganze Zahl.

# Zahlendarstellung

Seien  $b \in \mathbb{N}$ ,  $b > 1$ , fest gewählt. Jedes  $x \in \mathbb{R}$ ,  $x \neq 0$ , lässt sich in der Form

$$x = \pm \left( \sum_{j=1}^{\infty} d_j b^{-j} \right) \cdot b^e$$

darstellen, mit  $d_j \in \{0, 1, \dots, b-1\}$ ,  $d_1 \neq 0$ , und  $e$  eine ganze Zahl.

- ▶ Dezimalsystem (Basis  $b = 10$ )

$$123.75 \Rightarrow 0.12375 \cdot 10^3$$

# Zahlendarstellung

Seien  $b \in \mathbb{N}$ ,  $b > 1$ , fest gewählt. Jedes  $x \in \mathbb{R}$ ,  $x \neq 0$ , lässt sich in der Form

$$x = \pm \left( \sum_{j=1}^{\infty} d_j b^{-j} \right) \cdot b^e$$

darstellen, mit  $d_j \in \{0, 1, \dots, b-1\}$ ,  $d_1 \neq 0$ , und  $e$  eine ganze Zahl.

- ▶ Dezimalsystem (Basis  $b = 10$ )

$$123.75 \Rightarrow 0.12375 \cdot 10^3$$

- ▶ Binärsystem (Basis  $b = 2$ )

$$123.75 \Rightarrow 0.111101111 \cdot 2^{111}$$

# Zahlendarstellung

Seien  $b \in \mathbb{N}$ ,  $b > 1$ , fest gewählt. Jedes  $x \in \mathbb{R}$ ,  $x \neq 0$ , lässt sich in der Form

$$x = \pm \left( \sum_{j=1}^{\infty} d_j b^{-j} \right) \cdot b^e$$

darstellen, mit  $d_j \in \{0, 1, \dots, b-1\}$ ,  $d_1 \neq 0$ , und  $e$  eine ganze Zahl.

- ▶ Dezimalsystem (Basis  $b = 10$ )

$$123.75 \Rightarrow 0.12375 \cdot 10^3$$

- ▶ Binärsystem (Basis  $b = 2$ )

$$123.75 \Rightarrow 0.111101111 \cdot 2^{111}$$

- ▶ Dezimalsystem (Basis  $b = 10$ )

$$\frac{1}{3} \Rightarrow 0.33333\dots \cdot 10^0$$

# Normalisierte Gleitpunktdarstellung

Floating Point Representation:

$$\begin{aligned}x &= \pm 0.d_1d_2 \dots d_m \cdot b^e \\ &= \pm \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e\end{aligned}$$

wobei

- ▶ Basis  $b \in \mathbb{N} \setminus \{1\}$

# Normalisierte Gleitpunktdarstellung

Floating Point Representation:

$$\begin{aligned}x &= \pm 0.d_1d_2 \dots d_m \cdot b^e \\ &= \pm \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e\end{aligned}$$

wobei

- ▶ Basis  $b \in \mathbb{N} \setminus \{1\}$
- ▶ Exponent  $e \in \mathbb{Z}$  mit  $r \leq e \leq R$

# Normalisierte Gleitpunktdarstellung

Floating Point Representation:

$$\begin{aligned}x &= \pm 0.d_1d_2 \dots d_m \cdot b^e \\ &= \pm \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e\end{aligned}$$

wobei

- ▶ Basis  $b \in \mathbb{N} \setminus \{1\}$
- ▶ Exponent  $e \in \mathbb{Z}$  mit  $r \leq e \leq R$
- ▶ Mantisse  $f = \pm 0.d_1d_2 \dots d_m$ ,  $d_j \in \{0, 1, \dots, b - 1\}$

# Normalisierte Gleitpunktdarstellung

Floating Point Representation:

$$\begin{aligned}x &= \pm 0.d_1d_2 \dots d_m \cdot b^e \\ &= \pm \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e\end{aligned}$$

wobei

- ▶ Basis  $b \in \mathbb{N} \setminus \{1\}$
- ▶ Exponent  $e \in \mathbb{Z}$  mit  $r \leq e \leq R$
- ▶ Mantisse  $f = \pm 0.d_1d_2 \dots d_m$ ,  $d_j \in \{0, 1, \dots, b - 1\}$
- ▶ Mantissenlänge  $m$

# Normalisierte Gleitpunktdarstellung

Floating Point Representation:

$$\begin{aligned}
 x &= \pm 0.d_1d_2 \dots d_m \cdot b^e \\
 &= \pm \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e
 \end{aligned}$$

wobei

- ▶ Basis  $b \in \mathbb{N} \setminus \{1\}$
- ▶ Exponent  $e \in \mathbb{Z}$  mit  $r \leq e \leq R$
- ▶ Mantisse  $f = \pm 0.d_1d_2 \dots d_m$ ,  $d_j \in \{0, 1, \dots, b - 1\}$
- ▶ Mantissenlänge  $m$
- ▶ Normalisierung:  $d_1 \neq 0$  für  $x \neq 0$

# Maschinenzahlen

Nur endliche Anzahl von Zahlen darstellbar:

$$x = \pm \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e, \quad r \leq e \leq R$$

⇒ Maschinenzahlen  $\mathbb{M}(b, m, r, R)$ .

Betragsmäßig kleinste bzw. größte Zahl in  $\mathbb{M}(b, m, r, R)$ :  $x_{\text{MIN}}$ ,  $x_{\text{MAX}}$ .

# Maschinenzahlen

Nur endliche Anzahl von Zahlen darstellbar:

$$x = \pm \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e, \quad r \leq e \leq R$$

⇒ Maschinenzahlen  $\mathbb{M}(b, m, r, R)$ .

Betragsmäßig kleinste bzw. größte Zahl in  $\mathbb{M}(b, m, r, R)$ :  $x_{\text{MIN}}$ ,  $x_{\text{MAX}}$ .

Reduktionsabbildung  $\text{fl} : \mathbb{D} \rightarrow \mathbb{M}(b, m, r, R)$

Für  $x \in \mathbb{D} := [-x_{\text{MAX}}, -x_{\text{MIN}}] \cup [x_{\text{MIN}}, x_{\text{MAX}}]$

$$\text{fl}(x) := \pm \begin{cases} \left( \sum_{j=1}^m d_j b^{-j} \right) \cdot b^e & \text{falls } d_{m+1} < \frac{b}{2}, \\ \left( \sum_{j=1}^m d_j b^{-j} + b^{-m} \right) \cdot b^e & \text{falls } d_{m+1} \geq \frac{b}{2}, \end{cases}$$

d.h. die letzte Stelle der Mantisse wird um eins erhöht bzw. beibehalten, falls die Ziffer in der nächsten Stelle  $\geq \frac{b}{2}$  bzw.  $< \frac{b}{2}$  ist.

$x_{\text{MIN}}$  und  $x_{\text{MAX}}$ 

- ▶ Betragmäßig kleinste ( $\neq 0$ ) Zahl:

$$d_1 = 1, d_2 = \dots = d_m = 0; e = r : x_{\text{MIN}} = b^{r-1}$$

- ▶ Betragmäßig größte Zahl:

$$d_1 = \dots = d_m = b - 1; e = R : x_{\text{MAX}} = (1 - b^{-m}) \cdot b^R$$

$x_{\text{MIN}}$  und  $x_{\text{MAX}}$ 

- ▶ Betragmäßig kleinste ( $\neq 0$ ) Zahl:

$$d_1 = 1, d_2 = \dots = d_m = 0; e = r : x_{\text{MIN}} = b^{r-1}$$

- ▶ Betragmäßig größte Zahl:

$$d_1 = \dots = d_m = b - 1; e = R : x_{\text{MAX}} = (1 - b^{-m}) \cdot b^R$$

Partition  $\mathbb{R} = \mathbb{D} \cup \mathbb{D}_{\text{min}} \cup \mathbb{D}_{\text{max}}$ , mit

$$\mathbb{D} := [-x_{\text{MAX}}, -x_{\text{MIN}}] \cup [x_{\text{MIN}}, x_{\text{MAX}}], \mathbb{D}_{\text{min}} = (-x_{\text{MIN}}, x_{\text{MIN}}),$$

$$\mathbb{D}_{\text{max}} := (-\infty, -x_{\text{MAX}}) \cup (x_{\text{MAX}}, \infty).$$

$$x \in \mathbb{D}_{\text{max}} : \text{fl}(x) := \text{sign}(x)\infty$$

$$x \in \mathbb{D}_{\text{min}} : \text{fl}(x) := \begin{cases} 0 & \text{falls } |x| < \frac{1}{2}x_{\text{MIN}} \\ \text{sign}(x)x_{\text{MIN}} & \text{falls } |x| \geq \frac{1}{2}x_{\text{MIN}} \end{cases}$$

## Maschinengenauigkeit – Beispiel

Gleitpunktdarstellung:  $b = 10, m = 6$ 

$x$	$\text{fl}(x)$	$\frac{ \text{fl}(x)-x }{x}$
$\frac{1}{3} = 0.33333333\dots$	$0.333333 * 10^0$	$1.0 * 10^{-6}$
$\sqrt{2} = 1.41421356\dots$	$0.141421 * 10^1$	$2.5 * 10^{-6}$
$e^{-10} = 0.000045399927\dots$	$0.453999 * 10^{-4}$	$6.6 * 10^{-7}$
$e^{10} = 22026.46579\dots$	$0.220265 * 10^5$	$1.6 * 10^{-6}$
$\frac{1}{10} = 0.1$	$0.100000 * 10^0$	0.0

Gleitpunktdarstellung:  $b = 2, m = 10$ 

$x$	$\text{fl}(x)$	$\frac{ \text{fl}(x)-x }{x}$
$\frac{1}{3}$	$0.1010101011 * 2^{-1}$	$4.9 * 10^{-4}$
$\sqrt{2}$	$0.1011010100 * 2^1$	$1.1 * 10^{-4}$
$e^{-10}$	$0.1011111010 * 2^{-111}$	$3.3 * 10^{-4}$
$e^{10}$	$0.1010110000 * 2^{1111}$	$4.8 * 10^{-4}$
$\frac{1}{10}$	$0.1100110011 * 2^{-11}$	$2.4 * 10^{-4}$

Dahmen &amp; Reusken

# Maschinengenauigkeit

- ▶ Für den relativen Rundungsfehler erhält man

$$\left| \frac{\text{fl}(x) - x}{x} \right| \leq \frac{\frac{b^{-m}}{2} b^e}{b^{-1} b^e} = \frac{b^{1-m}}{2}.$$

# Maschinengenauigkeit

- ▶ Für den relativen Rundungsfehler erhält man

$$\left| \frac{\text{fl}(x) - x}{x} \right| \leq \frac{\frac{b^{-m}}{2} b^e}{b^{-1} b^e} = \frac{b^{1-m}}{2}.$$

- ▶ Die (relative) **Maschinengenauigkeit**

$$\text{eps} := \frac{b^{1-m}}{2}$$

charakterisiert das Auflösungsvermögen des Rechners, d.h.

$$\text{eps} = \inf\{\delta > 0 \mid \text{fl}(1 + \delta) > 1\}$$

# Maschinengenauigkeit

- ▶ Für den relativen Rundungsfehler erhält man

$$\left| \frac{\text{fl}(x) - x}{x} \right| \leq \frac{\frac{b^{-m}}{2} b^e}{b^{-1} b^e} = \frac{b^{1-m}}{2}.$$

- ▶ Die (relative) **Maschinengenauigkeit**

$$\text{eps} := \frac{b^{1-m}}{2}$$

charakterisiert das Auflösungsvermögen des Rechners, d.h.

$$\text{eps} = \inf\{\delta > 0 \mid \text{fl}(1 + \delta) > 1\}$$

- ▶ Der Rundungsfehler  $\varepsilon$  erfüllt  $|\varepsilon| \leq \text{eps}$  und es gilt

$$\text{fl}(x) = x(1 + \varepsilon).$$

## Maschinengenauigkeit – Beispiel

Gleitpunktdarstellung:  $b = 10$ ,  $m = 6 \rightarrow \text{eps} = \frac{1}{2} \times 10^{-5}$

$x$	$\text{fl}(x)$	$\frac{ \text{fl}(x)-x }{x}$
$\frac{1}{3} = 0.33333333 \dots$	$0.333333 * 10^0$	$1.0 * 10^{-6}$
$\sqrt{2} = 1.41421356 \dots$	$0.141421 * 10^1$	$2.5 * 10^{-6}$
$e^{-10} = 0.000045399927 \dots$	$0.453999 * 10^{-4}$	$6.6 * 10^{-7}$
$e^{10} = 22026.46579 \dots$	$0.220265 * 10^5$	$1.6 * 10^{-6}$
$\frac{1}{10} = 0.1$	$0.100000 * 10^0$	0.0

Gleitpunktdarstellung:  $b = 2$ ,  $m = 10 \rightarrow \text{eps} = 9.8 \times 10^{-4}$

$x$	$\text{fl}(x)$	$\frac{ \text{fl}(x)-x }{x}$
$\frac{1}{3}$	$0.1010101011 * 2^{-1}$	$4.9 * 10^{-4}$
$\sqrt{2}$	$0.1011010100 * 2^1$	$1.1 * 10^{-4}$
$e^{-10}$	$0.1011111010 * 2^{-111}$	$3.3 * 10^{-4}$
$e^{10}$	$0.1010110000 * 2^{1111}$	$4.8 * 10^{-4}$
$\frac{1}{10}$	$0.1100110011 * 2^{-11}$	$2.4 * 10^{-4}$

Dahmen &amp; Reusken

## IEEE Standard

- ▶ Double-precision floating-point

64-bit Wort: 52 bits für  $f$ , 11 bits für  $e$ , 1 bit für das Vorzeichen

- ▶ Der Exponent  $e$  ist eine ganze Zahl im Intervall

$$-1022 \leq e \leq 1023$$

- ▶ In MATLAB:

	Binary	Decimal
eps	$2^{-52}$	2.2204e-16
realmin	$2^{-1022}$	2.2251e-308
realmax	$(2-\text{eps}) \cdot 2^{1023}$	1.7977e+308

# Gleitpunktarithmetik

**Exakte** elementare arithmetische Operation von Maschinenzahlen  $\nrightarrow$  Maschinenzahl

## Beispiel

$b = 10, m = 3$ :

$$0.346 \cdot 10^2 + 0.785 \cdot 10^2 = 0.1131 \cdot 10^3 \neq 0.113 \cdot 10^3$$

Ähnliches passiert bei Multiplikation und Division.

Exakte Arithmetik  $\rightsquigarrow$  Gleitpunktarithmetik (Pseudoarithmetik),

z.B.:  $+$   $\rightsquigarrow$   $\oplus$ .

# Gleitpunktarithmetik

## Forderung

Für  $\nabla \in \{+, -, \cdot, \div\}$  gelte

$$x \textcircled{\nabla} y = \text{fl}(x \nabla y) \quad \text{für } x, y \in \mathbb{M}(b, m, r, R).$$

Da  $\text{fl}(x) = x(1 + \varepsilon)$ , folgt somit, dass für  $\nabla \in \{+, -, \cdot, \div\}$

$$x \textcircled{\nabla} y = (x \nabla y)(1 + \varepsilon) \quad \text{für } x, y \in \mathbb{M}(b, m, r, R)$$

und ein  $\varepsilon$  mit  $|\varepsilon| \leq \text{eps}$  gilt.

# Gleitpunktarithmetik

## Forderung

Für  $\nabla \in \{+, -, \cdot, \div\}$  gelte

$$x \circledast y = \text{fl}(x \nabla y) \quad \text{für } x, y \in \mathbb{M}(b, m, r, R).$$

Da  $\text{fl}(x) = x(1 + \varepsilon)$ , folgt somit, dass für  $\nabla \in \{+, -, \cdot, \div\}$

$$x \circledast y = (x \nabla y)(1 + \varepsilon) \quad \text{für } x, y \in \mathbb{M}(b, m, r, R)$$

und ein  $\varepsilon$  mit  $|\varepsilon| \leq \text{eps}$  gilt.

Vorsicht bei Gleitpunktarithmetik:

- ▶ Grundlegende Regeln der Algebra, die bei exakter Arithmetik gelten, sind nicht mehr gültig.
- ▶ Reihenfolge der Verküpfung spielt eine Rolle (Assoziativität der Addition geht verloren).

# Assoziativgesetz

## Beispiel 2.45

Zahlensystem mit  $b = 10$ ,  $m = 3$ . Maschinenzahlen

$$x = 6590 = 0.659 \cdot 10^4$$

$$y = 1 = 0.100 \cdot 10^1$$

$$z = 4 = 0.400 \cdot 10^1$$

Exakte Rechnung:

$$(x + y) + z = (y + z) + x = 6595.$$

## Assoziativgesetz

## Beispiel 2.45

Zahlensystem mit  $b = 10$ ,  $m = 3$ . Maschinenzahlen

$$x = 6590 = 0.659 \cdot 10^4$$

$$y = 1 = 0.100 \cdot 10^1$$

$$z = 4 = 0.400 \cdot 10^1$$

Exakte Rechnung:

$$(x + y) + z = (y + z) + x = 6595.$$

Pseudoarithmetik:

$$x \oplus y = 0.659 \cdot 10^4 \quad \text{und} \quad (x \oplus y) \oplus z = 0.659 \cdot 10^4,$$

aber

$$y \oplus z = 0.500 \cdot 10^1 \quad \text{und} \quad (y \oplus z) \oplus x = 0.660 \cdot 10^4.$$

## Distributivgesetz

## Beispiel 2.46

Für  $b = 10$ ,  $m = 3$ ,  $x = 0.156 \cdot 10^2$  und  $y = 0.157 \cdot 10^2$

$$(x - y) \cdot (x - y) = 0.01$$

$$(x \ominus y) \odot (x \ominus y) = 0.100 \cdot 10^{-1}$$

aber

$$(x \odot x) \ominus (x \odot y) \ominus (y \odot x) \oplus (y \odot y) = -0.100 \cdot 10^1.$$

## Auslöschung

## Beispiel 2.47

Betrachte

$$x = 0.73563, \quad y = 0.73441, \quad x - y = 0.00122.$$

Bei 3-stelliger Rechnung ( $b = 10$ ,  $m = 3$ ,  $\text{eps} = \frac{1}{2} \times 10^{-2}$ ):

$$\tilde{x} = \text{fl}(x) = 0.736, \quad |\delta_x| = 0.50 \cdot 10^{-3}$$

$$\tilde{y} = \text{fl}(y) = 0.734, \quad |\delta_y| = 0.56 \cdot 10^{-3}$$

Die relative Störung im Resultat:

$$\left| \frac{(\tilde{x} - \tilde{y}) - (x - y)}{x - y} \right| = \left| \frac{0.002 - 0.00122}{0.00122} \right| = 0.64$$

also sehr groß im Vergleich zu  $\delta_x$ ,  $\delta_y$ .

## Zusammenfassung Gleitpunktarithmetik

$$\left| \frac{(x \nabla y) - (x \nabla y)}{(x \nabla y)} \right| \leq \text{eps}, \quad x, y \in \mathbb{M}, \quad \nabla \in \{+, -, \cdot, \div\}$$

Die relativen Rundungsfehler bei den elementaren Gleitpunktoperationen sind  $\leq \text{eps}$ , wenn die Eingangsdaten  $x, y$  **Maschinenzahlen** sind.

Sei  $f(x, y) = x \nabla y$ ,  $x, y \in \mathbb{R}$ ,  $\nabla \in \{+, -, \cdot, \div\}$  und  $\kappa_{\text{rel}}$  die relative Konditionszahl von  $f$ . Es gilt

$$\begin{aligned} \nabla \in \{\cdot, \div\} &: \kappa_{\text{rel}} \leq 1 \quad \text{für alle } x, y, \\ \nabla \in \{+, -\} &: \kappa_{\text{rel}} \gg 1 \quad \text{wenn } |x \nabla y| \ll \max\{|x|, |y|\} \end{aligned}$$

Sehr große Fehlerverstärkung bei  $+, -$  möglich (**Auslöschung**).

# Beispiele

In Matlab:

▶  $u = 0.3/0.1$

# Beispiele

In Matlab:

- ▶  $u = 0.3/0.1$ 
  - ▶ Das Ergebnis ist nicht gleich 3, da Zähler etwas kleiner als 0.3 und Nenner etwas größer als 0.1.

# Beispiele

In Matlab:

- ▶  $u = 0.3/0.1$ 
  - ▶ Das Ergebnis ist nicht gleich 3, da Zähler etwas kleiner als 0.3 und Nenner etwas größer als 0.1.
  
- ▶  $a = 2^{100}; b = a + 2^{47}; b - a = 0$

# Beispiele

In Matlab:

- ▶  $u = 0.3/0.1$ 
  - ▶ Das Ergebnis ist nicht gleich 3, da Zähler etwas kleiner als 0.3 und Nenner etwas größer als 0.1.
- ▶  $a = 2^{100}; b = a + 2^{47}; b - a = 0$ 
  - ▶ Die relative Differenz zwischen a und b ist kleiner als eps

# Beispiele

In Matlab:

- ▶  $u = 0.3/0.1$ 
  - ▶ Das Ergebnis ist nicht gleich 3, da Zähler etwas kleiner als 0.3 und Nenner etwas größer als 0.1.
- ▶  $a = 2^{100}; b = a + 2^{47}; b - a = 0$ 
  - ▶ Die relative Differenz zwischen a und b ist kleiner als eps
  - ▶ Es gibt keine Maschinenzahl zwischen  $2^{100}$  und  $2^{100} + 2^{48}$

# Beispiele

In Matlab:

- ▶  $u = 0.3/0.1$ 
  - ▶ Das Ergebnis ist nicht gleich 3, da Zähler etwas kleiner als 0.3 und Nenner etwas größer als 0.1.
- ▶  $a = 2^{100}; b = a + 2^{47}; b - a = 0$ 
  - ▶ Die relative Differenz zwischen a und b ist kleiner als eps
  - ▶ Es gibt keine Maschinenzahl zwischen  $2^{100}$  und  $2^{100} + 2^{48}$
- ▶  $\text{eps}/3 + \text{eps}/3 + 1 - 1 = 2.220446049250313e-16$   
 $\text{eps}/3 + 1 + \text{eps}/3 - 1 = 0$

# Beispiele

In Matlab:

- ▶  $u = 0.3/0.1$ 
  - ▶ Das Ergebnis ist nicht gleich 3, da Zähler etwas kleiner als 0.3 und Nenner etwas größer als 0.1.
- ▶  $a = 2^{100}; b = a + 2^{47}; b - a = 0$ 
  - ▶ Die relative Differenz zwischen a und b ist kleiner als eps
  - ▶ Es gibt keine Maschinenzahl zwischen  $2^{100}$  und  $2^{100} + 2^{48}$
- ▶  $\text{eps}/3 + \text{eps}/3 + 1 - 1 = 2.220446049250313e-16$   
 $\text{eps}/3 + 1 + \text{eps}/3 - 1 = 0$ 
  - ▶ Assoziativgesetz gilt nicht

# Beispiele

► Auswerten der Funktion  $f(x) = 1 - x \left( \frac{x+1}{x} - 1 \right)$

Exakt:  $f(x) = 1 - x \frac{x+1-x}{x} = 0$  für alle  $x > 0$

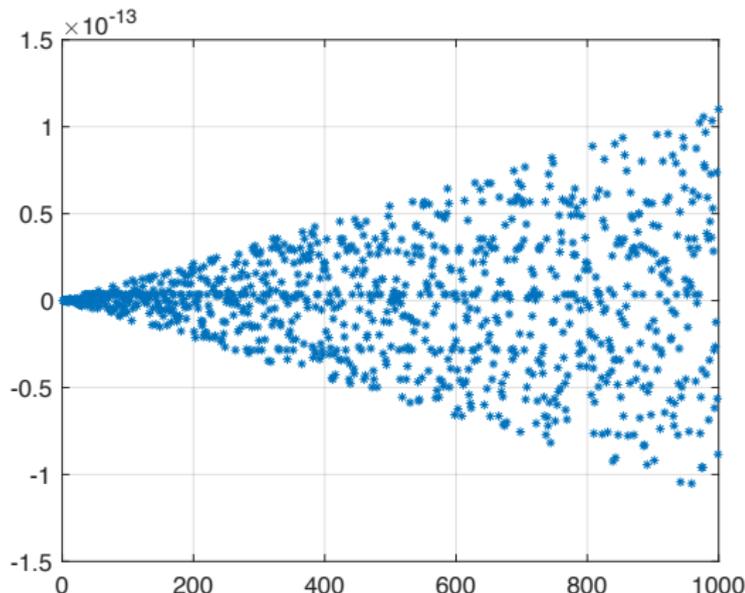
Auswertung in Matlab:

# Beispiele

- ▶ Auswerten der Funktion  $f(x) = 1 - x \left( \frac{x+1}{x} - 1 \right)$

Exakt:  $f(x) = 1 - x \frac{x+1-x}{x} = 0$  für alle  $x > 0$

Auswertung in Matlab:



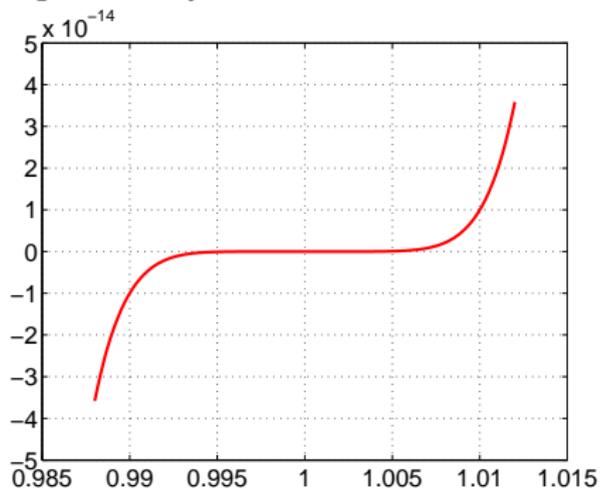
## Beispiel: Polynom 7. Grades

## Matlab Plot

```
x = 0.988 : 0.0001 : 1.012;
```

```
y = (x - 1).^7;
```

```
plot(x,y)
```



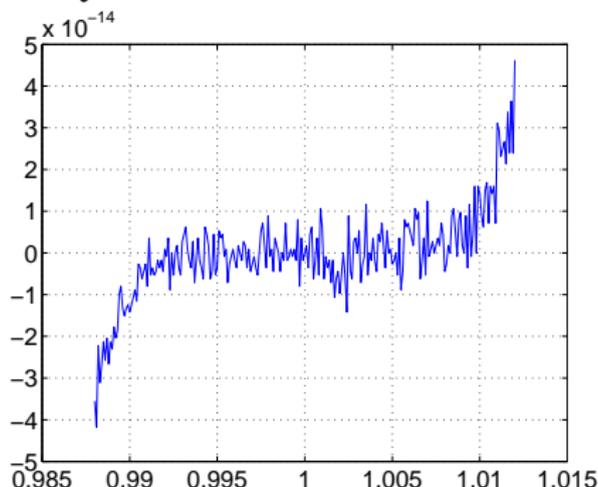
## Beispiel: Polynom 7. Grades

## Matlab Plot

```
x = 0.988 : 0.0001 : 1.012;
```

```
y = x.^7 - 7 * x.^6 + 21 * x.^5 - 35 * x.^4  
    + 35 * x.^3 - 21 * x.^2 + 7 * x - 1;
```

```
plot(x,y)
```



# Stabilität

## Definition

Ein Algorithmus heißt **gutartig** oder **stabil**, wenn die durch ihn im Laufe der Rechnung erzeugten Fehler in der Größenordnung des durch die Kondition des Problems bedingten unvermeidbaren Fehlers bleiben.

# Stabilität

## Definition

Ein Algorithmus heißt **gutartig** oder **stabil**, wenn die durch ihn im Laufe der Rechnung erzeugten Fehler in der Größenordnung des durch die Kondition des Problems bedingten unvermeidbaren Fehlers bleiben.

- ▶ Kondition ist Eigenschaft des Problems
- ▶ Stabilität ist Eigenschaft des Verfahrens/Algorithmus

⇒ Wenn ein **Problem schlecht konditioniert** ist, kann man **nicht** erwarten, dass eine **numerische Methode** (ein stabiler Algorithmus) **gute Ergebnisse** liefert.

# Stabilität

## Definition

Ein Algorithmus heißt **gutartig** oder **stabil**, wenn die durch ihn im Laufe der Rechnung erzeugten Fehler in der Größenordnung des durch die Kondition des Problems bedingten unvermeidbaren Fehlers bleiben.

- ▶ Kondition ist Eigenschaft des Problems
- ▶ Stabilität ist Eigenschaft des Verfahrens/Algorithmus

⇒ Wenn ein **Problem schlecht konditioniert** ist, kann man **nicht** erwarten, dass eine **numerische Methode** (ein stabiler Algorithmus) **gute Ergebnisse** liefert.

**Ziel:** Numerische Methode soll Fehlerverstärkung nicht signifikant weiter vergrößern

## Beispiel 2.50

Bestimmung der Lösung  $u^*$  von

$$y^2 - 2a_1y + a_2 = 0$$

für  $a_1 = 6.000227$ ,  $a_2 = 0.01$ .

Algorithmus I

$$u^* = f(a_1, a_2) = a_1 - \sqrt{a_1^2 - a_2}$$

$$\begin{aligned} y_1 &= a_1 \cdot a_1 \\ \longrightarrow y_2 &= y_1 - a_2 \\ \longrightarrow y_3 &= \sqrt{y_2} \\ \longrightarrow u^* &= a_1 - y_3 \end{aligned}$$

## Beispiel 2.50

Algorithmus I

$$u^* = f(a_1, a_2) = a_1 - \sqrt{a_1^2 - a_2}.$$

In Gleitpunktarithmetik mit  $b = 10$ ,  $m = 5$  ( $\text{eps} = \frac{1}{2} \cdot 10^{-4}$ ):

$$\tilde{u}^* = 0.90000 \cdot 10^{-3}$$

Exakte Lösung:

$$u^* = 0.83336 \cdot 10^{-3}$$

## Beispiel 2.50

Algorithmus I

$$u^* = f(a_1, a_2) = a_1 - \sqrt{a_1^2 - a_2}.$$

In Gleitpunktarithmetik mit  $b = 10$ ,  $m = 5$  ( $\text{eps} = \frac{1}{2} \cdot 10^{-4}$ ):

$$\tilde{u}^* = 0.90000 \cdot 10^{-3}$$

Exakte Lösung:

$$u^* = 0.83336 \cdot 10^{-3}$$

- ▶ Problem ist für diese Eingangsdaten  $a_1$ ,  $a_2$  gut konditioniert.
- ▶ Durch Algorithmus erzeugte Fehler sind sehr viel größer als der unvermeidbare Fehler.

⇒ Algorithmus I ist nicht stabil

Ursache: Auslöschung

## Beispiel 2.50

Bestimmung der Lösung  $u^*$  von

$$y^2 - 2a_1y + a_2 = 0$$

für  $a_1 = 6.000227$ ,  $a_2 = 0.01$ .

Algorithmus II (Alternative)

$$u^* = \frac{a_2}{a_1 + \sqrt{a_1^2 - a_2}}$$

$$y_1 = a_1 \cdot a_1$$

$$\longrightarrow y_2 = y_1 - a_2$$

$$\longrightarrow y_3 = \sqrt{y_2}$$

$$\longrightarrow y_4 = a_1 + y_3$$

$$\longrightarrow u^* = \frac{a_2}{y_4}$$

## Beispiel 2.50

Algorithmus II

$$u^* = \frac{a_2}{a_1 + \sqrt{a_1^2 - a_2}}$$

In Gleitpunktarithmetik mit  $b = 10$ ,  $m = 5$  ( $\text{eps} = \frac{1}{2} \cdot 10^{-4}$ ):

$$\tilde{u}^* = 0.83333 \cdot 10^{-3}$$

Exakte Lösung:

$$u^* = 0.83336 \cdot 10^{-3}$$

- ▶ Gesamtfehler bleibt im Rahmen der Maschinengenauigkeit.
- ▶ Auslöschung tritt nicht auf.

⇒ Algorithmus II ist **stabil**

# Rückwärtsstabilität

**Wunsch:** Auswertung von  $f : X \rightarrow Y$

**Wirklichkeit:** berechnetes Ergebnis  $\tilde{f} : X \rightarrow Y$

wobei  $f \neq \tilde{f}$  aufgrund von

- ▶ Rundungsfehlern (Maschinengenauigkeit),
- ▶ Gleitpunktarithmetik.

# Rückwärtsstabilität

**Wunsch:** Auswertung von  $f : X \rightarrow Y$

**Wirklichkeit:** berechnetes Ergebnis  $\tilde{f} : X \rightarrow Y$

wobei  $f \neq \tilde{f}$  aufgrund von

- ▶ Rundungsfehlern (Maschinengenauigkeit),
- ▶ Gleitpunktarithmetik.

Das Ziel

$$\frac{\|\tilde{f}(x) - f(x)\|}{\|f(x)\|} = \mathcal{O}(\text{eps})$$

ist zu ehrgeizig.

**Grund:** Wenn Problem  $f$  schlecht konditioniert ist, werden Datenstörungen um Kondition  $\kappa \gg 1$  des Problems verstärkt.

# Rückwärtsstabilität

Ein Verfahren zur Berechnung von  $f(x)$  liefert als Ergebnis  $\tilde{f}(x)$ .

## Definition

Das Verfahren heißt **rückwärts stabil**, wenn

$$\tilde{f}(x) = f(\tilde{x})$$

für ein  $\tilde{x}$  mit  $\frac{\|x - \tilde{x}\|}{\|x\|} = \mathcal{O}(\text{eps})$ .

⇒ Ein rückwärts stabiler Algorithmus gibt die **exakte** Lösung des Problems mit **nahezu richtigen Eingabedaten** (d.h.  $x \rightarrow \tilde{x} = x(1 + \epsilon)$ ,  $|\epsilon| \leq \text{eps}$ ).

## Rückwärtsstabilität

## Satz

Wird ein rückwärts stabiler Algorithmus zur Lösung des Problems  $f$  mit Kondition  $\kappa(x)$  angewendet, so gilt

$$\frac{\|\tilde{f}(x) - f(x)\|}{\|f(x)\|} = \mathcal{O}(\kappa(x) \text{ eps}).$$

## Beweis:

$$\frac{\|\tilde{f}(x) - f(x)\|}{\|f(x)\|} = \frac{\|f(\tilde{x}) - f(x)\|}{\|f(x)\|} \lesssim \kappa(x) \underbrace{\frac{\|\tilde{x} - x\|}{\|x\|}}_{\mathcal{O}(\text{eps})}.$$

# Rückwärtsstabilität

Was haben wir gemacht?

Fehler im Algorithmus wurden

# Rückwärtsstabilität

Was haben wir gemacht?

Fehler im Algorithmus wurden

zurückgespiegelt auf Fehler in den Daten.

# Rückwärtsstabilität

Was haben wir gemacht?

Fehler im Algorithmus wurden

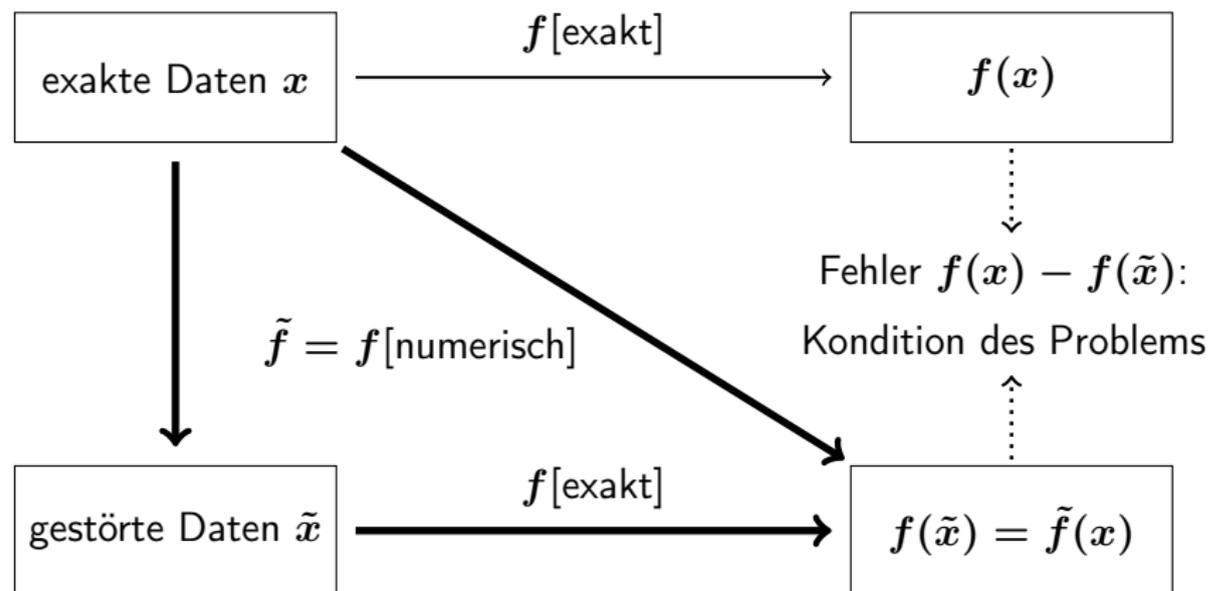
zurückgespiegelt auf Fehler in den Daten.



Konsequenz:

Fehler in  $\tilde{f}(x) = f(\tilde{x})$  ist unvermeidbar, wegen Kondition von  $f$ .

## Rückwärtsanalyse



## Beispiel 2.54: Summation ist rückwärts stabil

**Geg.:** Maschinenzahlen  $x_1, x_2, x_3$ , Maschinengenauigkeit  $\text{eps}$ .

**Ges.:** Summe  $S = (x_1 + x_2) + x_3$ .

Man erhält

$$\tilde{S} = ((x_1 + x_2)(1 + \varepsilon_2) + x_3)(1 + \varepsilon_3)$$

mit  $|\varepsilon_i| \leq \text{eps}$ ,  $i = 2, 3$ .

## Beispiel 2.54: Summation ist rückwärts stabil

**Geg.:** Maschinenzahlen  $x_1, x_2, x_3$ , Maschinengenauigkeit  $\text{eps}$ .

**Ges.:** Summe  $S = (x_1 + x_2) + x_3$ .

Man erhält

$$\tilde{S} = ((x_1 + x_2)(1 + \varepsilon_2) + x_3)(1 + \varepsilon_3)$$

mit  $|\varepsilon_i| \leq \text{eps}$ ,  $i = 2, 3$ .

Daraus folgt

$$\begin{aligned} \tilde{S} &= x_1(1 + \varepsilon_2)(1 + \varepsilon_3) + x_2(1 + \varepsilon_2)(1 + \varepsilon_3) + x_3(1 + \varepsilon_3) \\ &\doteq x_1(1 + \varepsilon_2 + \varepsilon_3) + x_2(1 + \varepsilon_2 + \varepsilon_3) + x_3(1 + \varepsilon_3) \\ &= x_1(1 + \delta_1) + x_2(1 + \delta_2) + x_3(1 + \delta_3) \end{aligned}$$

wobei

$$|\delta_1| = |\delta_2| = |\varepsilon_2 + \varepsilon_3| \leq 2 \text{eps}, \quad |\delta_3| = |\varepsilon_3| \leq \text{eps}$$

## Beispiel 2.54: Summation ist rückwärts stabil

Es gilt

$$\begin{aligned}\tilde{S} &= x_1 (1 + \delta_1) + x_2 (1 + \delta_2) + x_3 (1 + \delta_3) \\ &=: \tilde{x}_1 + \tilde{x}_2 + \tilde{x}_3,\end{aligned}$$

wobei

$$|\delta_1| = |\delta_2| = |\varepsilon_2 + \varepsilon_3| \leq 2 \text{ eps}, \quad |\delta_3| = |\varepsilon_3| \leq \text{eps}$$

⇒ Fehlerbehaftetes Resultat  $\tilde{S}$  als **exaktes** Ergebnis zu **gestörten** Eingabedaten  $\tilde{x}_i = x_i(1 + \delta_i)$ .

## Beispiel 2.54: Summation ist rückwärts stabil

Es gilt

$$\begin{aligned}\tilde{S} &= x_1 (1 + \delta_1) + x_2 (1 + \delta_2) + x_3 (1 + \delta_3) \\ &=: \tilde{x}_1 + \tilde{x}_2 + \tilde{x}_3,\end{aligned}$$

wobei

$$|\delta_1| = |\delta_2| = |\varepsilon_2 + \varepsilon_3| \leq 2 \text{ eps}, \quad |\delta_3| = |\varepsilon_3| \leq \text{eps}$$

⇒ Fehlerbehaftetes Resultat  $\tilde{S}$  als **exaktes** Ergebnis zu **gestörten** Eingabedaten  $\tilde{x}_i = x_i(1 + \delta_i)$ .

Der **durch Rechnung bedingte Fehler** ist höchstens

$$\begin{aligned}\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| &\leq \kappa_{\text{rel}}(x) \sum_{j=1}^3 \left| \frac{\tilde{x}_j - x_j}{x_j} \right| \\ &\leq \kappa_{\text{rel}}(x) \sum_{j=1}^3 |\delta_j| \leq \kappa_{\text{rel}}(x) 5 \text{ eps}.\end{aligned}$$

## Beispiel 2.54

Der für die Summation  $f(x) = f(x_1, x_2, x_3) = x_1 + x_2 + x_3$  unvermeidbare Fehler ist

$$\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| \leq \kappa_{\text{rel}}(x) \sum_{j=1}^3 \left| \frac{\tilde{x}_j - x_j}{x_j} \right| \leq \kappa_{\text{rel}}(x) 3 \text{ eps},$$

wenn Daten höchstens mit Maschinengenauigkeit gestört werden ( $\tilde{x}_i = x_i(1 + \varepsilon)$ ,  $|\varepsilon| \leq \text{eps}$ ).

## Beispiel 2.54

Der für die Summation  $f(x) = f(x_1, x_2, x_3) = x_1 + x_2 + x_3$  unvermeidbare Fehler ist

$$\left| \frac{f(\tilde{x}) - f(x)}{f(x)} \right| \leq \kappa_{\text{rel}}(x) \sum_{j=1}^3 \left| \frac{\tilde{x}_j - x_j}{x_j} \right| \leq \kappa_{\text{rel}}(x) 3 \text{ eps},$$

wenn Daten höchstens mit Maschinengenauigkeit gestört werden ( $\tilde{x}_i = x_i(1 + \varepsilon)$ ,  $|\varepsilon| \leq \text{eps}$ ).

⇒ Berechnung von  $S$  ist ein stabiler Algorithmus