

Numerische Mathematik für Elektrotechniker

Zahlendarstellung, Rundungsfehler, Stabilität eines Algorithmus

Benjamin Berkels

Karl-Heinz Brakhage, Thomas Jankuhn, Christian Löbbert

Institut für Geometrie und Praktische Mathematik
RWTH Aachen

Wintersemester 2019/2020

Zusammenfassung letzte Vorlesung

Kondition

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

Frage:

- ▶ Was ist die (relative) Kondition eines Problems?

⇒ Die relative Kondition eines Problems bezeichnet **das Verhältnis des relativen Ausgabefehlers zum relativen Eingabefehler**, d.h. die Sensitivität des Problems unter Störungen der Eingabedaten.

Zusammenfassung letzte Vorlesung

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

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

mit

$$\kappa_{\text{rel}}(x) = \kappa_{\text{rel}}^{\infty}(x) := \max_j \left| \frac{\partial f(x)}{\partial x_j} \cdot \frac{x_j}{f(x)} \right|$$

$n=1$
 $\left(\frac{f'(x) \cdot x}{f(x)} \right)$

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

Für $f(x) = Ax$ linear, invertierbar gilt

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

Heute in der Vorlesung

Themen: Dahmen & Reusken Kap 2.2-2.3

- ▶ Zahlendarstellung und Rundungsfehler
- ▶ Gleitpunktarithmetik
- ▶ Stabilität eines Algorithmus

Was Sie mitnehmen sollten:

- ▶ Wie werden Zahlen im Computer dargestellt
- ▶ Wichtige Eigenschaften der Gleitpunktarithmetik
- ▶ Stabilität vs. Kondition

Motivation

Warum betrachten wir Gleitpunktdarstellung?

- Aufgrund der Art und Weise, wie Zahlen im Computer dargestellt werden, können überraschende Ergebnisse auftreten

```
>> u = 0.3/0.1;
```

```
>> 3 - u
```

```
ans = 4.4409e-16
```

Ein paar schlechte Beispiele:

1. D.N. Arnold, *Some disasters attributable to bad numerical computing*, 1998. <https://www.ima.umn.edu/~arnold/disasters/>
2. T. Huckle, *Collection of Software Bugs*, 2011. <https://www5.in.tum.de/~huckle/bugse.html>
3. K. Vuik, *Some disasters caused by numerical errors*. <http://ta.twi.tudelft.nl/users/vuik/wi211/disasters.html>

Beispiel 2.31.

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

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

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

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.

Darstellung nicht eindeutig!

$$0.19999 \dots \cdot 10^0 = 0.20000 \dots \cdot 10^0$$

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 $b = 2$)

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

Normalisierte Gleitpunktdarstellung

Gleitpunktdarstellung:

$$\begin{aligned} x &= \pm 0.d_1 d_2 \dots d_m \times b^e \\ &= \pm \left(\sum_{j=1}^m d_j b^{-j} \right) \times b^e \end{aligned}$$

wobei

- ▶ Basis $b \in \mathbb{N} \setminus \{1\}$
- ▶ Exponent $e \in \mathbb{Z}$ mit $r \leq e \leq R$
- ▶ Mantisse $f = \pm 0.d_1 d_2 \dots d_m$, $d_j \in \{0, 1, \dots, b-1\}$
- ▶ Mantissenlänge m
- ▶ Normalisierung: $d_1 \neq 0$ für $x \neq 0$

$$M(10, 1, \overset{-1}{0}, \overset{1}{0})$$



Maschinenzahlen

Nur endliche Anzahl von Zahlen darstellbar m, r, R vs. ∞ :

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

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

Kardinalität von $\mathbb{M}(b, m, r, R)$ ist endlich und hat

$$2 \times (b-1) \times b^{m-1} \times (R-r+1) \quad \text{Elemente.}$$

Definition (Rundung)

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

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

Bildbereich

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

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

- ▶ Betragsmäßig größte Zahl:

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

Erinnerung: Geomet. Reihe $(b-1) \sum_{j=1}^m b^{-j} = 1 - b^{-m}$

- ▶ **Bildbereich** $\mathbb{D} := [-x_{\text{MAX}}, -x_{\text{MIN}}] \cup [x_{\text{MIN}}, x_{\text{MAX}}]$

Achtung: Die Endlichkeit von e beschränkt den **Bildbereich**!

- ▶ **Unterlauf**, wenn $0 \neq |x| < |x_{\text{MIN}}|$;
- ▶ **Überlauf**, wenn $|x| > |x_{\text{MAX}}|$.

Bildbereich und Genauigkeit

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

- ▶ Es gibt einen begrenzten Bereich von Zahlen, die dargestellt werden können

Die Endlichkeit von e beschränkt den **Bildbereich**.

- ▶ Es gibt nur eine endliche Anzahl von Zahlen, die innerhalb des Bildbereichs dargestellt werden können

Die Endlichkeit von f beschränkt die **Genauigkeit**.

Maschinengenauigkeit – Beispiel

Gleitpunktdarstellung: $b = 10, m = 6$

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

Gleitpunktdarstellung: $b = 2, m = 10$

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

$$x \in \mathbb{D}$$

$$\Rightarrow x = \pm \left(\sum_{j=1}^{\infty} d_j b^{-j} \right) b^e \quad \text{mit} \quad r \leq e \leq R$$

$$d_j \neq 0$$

$$\Rightarrow |f(x)| = \left| \left(\sum_{j=1}^m d_j b^{-j} \right) b^e \right|$$

$$\uparrow$$

$$b^{-m-1} < \frac{b}{2}$$

$$\Rightarrow |x - f(x)| \leq \frac{b^{-m}}{2} b^e$$

$$|x| \geq d_1 b^{-1} b^e \geq b^{-1} b^e$$

$$\Rightarrow \frac{|f(x) - x|}{|x|} \leq \frac{\frac{b^{-m}}{2} \cancel{b^e}}{b^{-1} \cancel{b^e}} = \frac{b^{1-m}}{2}$$

Maschinengenauigkeit

- Für den relativen Rundungsfehler erhält man für $x \in \mathbb{D}$

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

- 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 ε erfüllt $|\varepsilon| \leq \text{eps}$ und es gilt

$$\frac{\text{fl}(x) - x}{x} =: \varepsilon$$

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

Maschinengenauigkeit – Beispiel

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

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

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

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

Historie

Vor dem Jahr 1985

- ▶ Kein einheitlicher Standard
- ▶ Jeder Computer hatte seine eigene Gleitpunktdarstellung
- ▶ Manche binär (Basis 2, 8, 16), manche dezimal, sogar trinär!
- ▶ Gleitpunktarithmetik hat sich auf unterschiedlichen Computern unterschiedlich verhalten!

Im Jahr 1985

- ▶ ANSI/IEEE Standard 754-1985 for Binary Floating-Point Arithmetic
- ▶ ANSI - American National Standards Institute
- ▶ IEEE - Institute of Electrical and Electronics Engineers
- ▶ Alle Computer seit 1985 benutzen diesen Standard
- ▶ Maschinen-unabhängiges Modell, wie sich Gleitpunktarithmetik verhält

IEEE Standard

- ▶ Double-precision floating-point

64-bit Wort mit

52 bits für f

11 bits für e

1 bit für das Vorzeichen

- ▶ Der Exponent e ist eine ganze Zahl im Intervall

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

- ▶ Effektive Mantisse " $1 + f$ "

($d_1 = 1$ durch Normalisierung, muss nicht gespeichert werden)

IEEE Standard

- ▶ x_{MIN} : $f = 0$ und $e = -1022$
- ▶ x_{MAX} : $f = 1 - \text{eps}$ und $e = 1023$
- ▶ Überlauf: $e = 1024$ und $f = 0$
 - ▶ Schreibweise: **infinity** oder Inf
 - ▶ Erfüllt: $1/\text{Inf} = 0$ und $\text{Inf} + \text{Inf} = \text{Inf}$
- ▶ Not-a-Number oder NaN: $e = 1024$ und $f \neq 0$
 - ▶ undefinierte Zahl, z.B. $0/0$
- ▶ Unterlauf: $e = -1023$ (Sonderfall: denormalisierte Zahlen)
- ▶ 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

Pseudoarithmetik

Exakte elementare arithmetische Operation von Maschinenzahlen
 $\nRightarrow$ Maschinenzahl

Beispiel

$b = 10, m = 3$:

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

Ähnliches passiert bei Multiplikation und Division.

Exakte Arithmetik $\rightsquigarrow$ Pseudoarithmetik (Gleitpunktarithmetik),

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

Pseudoarithmetik

Forderung

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

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

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

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

und ein ε mit $|\varepsilon| \leq \text{eps}$ gilt (falls $|x \nabla y| \leq x_{\text{MAX}} \wedge x \oslash y \neq 0$).

Vorsicht bei Pseudoarithmetik:

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

Assoziativgesetz

Beispiel 2.36.

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

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

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

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

Exakte Rechnung:

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

Pseudoarithmetik:

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

aber

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

Distributivgesetz

Beispiel 2.37.

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

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

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

aber

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

Auslöschung

Beispiel 2.38.

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 δ_x, δ_y .

Auslöschung

Betrachte

$$a = 1.23456 \text{ und } b = 1.23567.$$

Sind a und b Ergebnisse aus Rechnungen mit Gleitpunktarithmetik, so sind die niedrigen Stellen durch Rundungsfehler verfälscht.

Angenommen, die letzten drei Stellen sind verfälscht.

Differenz der korrekten Stellen

$$1.23 - 1.23 = 0$$

Allerdings hat

$$b - a = 0.00111 = 0.111 \cdot 10^{-2}$$

keine einzige korrekte Stelle!

Die korrekten Stellen in a und b löschen sich in $a - b$ aus!

Führende Nullen sind nicht Teil der resultierenden Maschinenzahl.

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 κ_{rel} die relative Konditionszahl von f . Es gilt

$$\nabla \in \{\cdot, \div\} : \kappa_{\text{rel}} \leq 1 \quad \text{für alle } x, y,$$

$$\nabla \in \{+, -\} : \kappa_{\text{rel}} \gg 1 \quad \text{wenn } |x \nabla y| \ll \max\{|x|, |y|\}$$

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

Beispiel: Polynom 7. Grades

$$\begin{aligned} p(x) &= (x - 1)^7 \\ &= x^7 - 7x^6 + 21x^5 - 35x^4 + 35x^3 - 21x^2 + 7x - 1 \end{aligned}$$

Matlab-Demo

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 die **Numerische Methode** (ein stabiler Algorithmus) **gute Ergebnisse** liefert.

Ziel: Numerische Methode soll Fehlerverstärkung nicht noch weiter vergrößern

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

$$\phi_2(x) = \frac{1}{2} - \frac{1}{2} \varepsilon_1(x)$$

$$\phi_1(6.000227, 0.01) = -1.00$$

$$\phi_2(x) = 1.00$$

$$\Rightarrow K_{\text{rel}} = \max(|\varepsilon_1, \phi_2|) = 1.00$$

Beispiel 2.39.

Bestimmung der kleineren Lösung u^* von

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

für $a_1 = 6.000227$, $a_2 = 0.01$.

Algorithmus I

$$\begin{aligned} u^* = f(a_1, a_2) &= -\frac{-2 \cdot a_1}{2} - \sqrt{\left(\frac{-2 \cdot a_1}{2}\right)^2 - a_2} \\ &= a_1 - \sqrt{a_1^2 - a_2}. \end{aligned}$$

$$\begin{aligned} & y_1 = a_1 \\ \longrightarrow & y_2 = y_1^2 - a_2 \\ \longrightarrow & y_3 = \sqrt{y_2} \\ \longrightarrow & u^* = a_1 - y_3 \end{aligned}$$

Beispiel 2.39.

Algorithmus I

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

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

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

Exakte Lösung:

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

- ▶ Problem 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**

Beispiel 2.39.

Bestimmung der Lösung u^* von

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

für $a_1 = 6.000227$, $a_2 = 0.01$.

Algorithmus II (Alternative)

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

$$y_1 = a_1 a_1$$

$$\longrightarrow y_2 = y_1 - a_2$$

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

$$\longrightarrow y_4 = a_1 + y_3$$

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

Beispiel 2.39.

Algorithmus II

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

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

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

Exakte Lösung:

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

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

⇒ Algorithmus II ist **stabil**

Rückwärtsstabilität

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


Definition

Das Verfahren heißt **rückwärts stabil**, wenn es für alle $x \in X$ ein $\tilde{x} \in X$ gibt, so dass

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

⇒ Ein rückwärts stabiler Algorithmus gibt die **exakte** Lösung des **nahezu richtigen Problems** (Daten, d.h. $x \rightarrow \tilde{x} = x + \Delta x$).

Rückwärtsanalyse



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 $\tilde{f}$ wurden

zurückgespiegelt auf Fehler in den Daten $\tilde{x}$.



Vorteil: Auswertung von $f(\tilde{x})$ ist Frage nach Kondition von f .

Beispiel 2.40.: Summation ist rückwärts stabil

Geg.: Maschinenzahlen x_1 , x_2 , x_3 , Maschinengenauigkeit **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 $|\varepsilon_i| \leq \mathbf{eps}$, $i = 2, 3$.

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

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

Beispiel 2.40.: 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

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

$\Rightarrow$ 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

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

Beispiel 2.40.

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

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

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

Die Größenordnung der Fehler ist identisch

$\Rightarrow$ Berechnung von S ist ein stabiler Algorithmus.

Summenbildung

Summenbildung tritt in vielen Problemen z. B. Skalarprodukte, Matrix/Vektor-Multiplikation, ... auf.

Wir betrachten: $S_n = \sum_{j=1}^n x_j$

Analog zum Fall $S = (x_1 + x_2) + x_3$ kann man zeigen, dass

$$\begin{aligned} (x_1 \oplus x_2 \oplus \cdots \oplus x_n) - (x_1 + x_2 + \cdots + x_n) \\ \doteq x_1(\varepsilon_1 + \varepsilon_2 + \cdots + \varepsilon_n) \\ + x_2(\varepsilon_2 + \cdots + \varepsilon_n) + \cdots + x_n\varepsilon_n \end{aligned}$$

mit $|\varepsilon_i| \leq \text{eps}$, $i = 1, \dots, n$.

- ▶ Der erste Summand wird mit größtem Fehler multipliziert.
- ▶ Reihenfolge bei der Summation wichtig

⇒ der relative Fehler wird am kleinsten, wenn die betragsgrößten Summanden zuletzt aufsummiert werden (vgl. Beispiel 2.36.).

Zusammenfassung

Was Sie mitnehmen sollten:

Wie werden Zahlen im Computer dargestellt

- ▶ Maschinenzahlen $\mathbb{M}(b, m, r, R)$
 $\Rightarrow x_{\min}, x_{\max}, \mathbf{eps}, |\varepsilon| \leq \mathbf{eps}$

Welche Probleme können dabei/deswegen auftreten?

- ▶ Assoziativ- und Distributivgesetz nicht mehr gültig
- ▶ Gefahr der Auslöschung bei $\nabla \in \{+, -\}$

Zusammenfassung

Stabilität vs. Kondition

- ▶ Bei einem **stabilen Lösungsverfahren** bleiben die im Laufe der Rechnung erzeugten Rundungsfehler in der Größenordnung der durch die **Kondition des Problems bedingten unvermeidbaren Fehler**.
- ▶ Kenntnisse über die Kondition eines Problems sind oft für die Interpretation oder Bewertung der Ergebnisse von entscheidender Bedeutung
 - ▶ “Schlechtes Ergebnis” bedeutet nicht unbedingt gleich “instabiler Algorithmus”, sondern deutet evtl. auf eine schlechte Kondition des Problems hin.
- ▶ In einem Algorithmus sollen (wegen Stabilität) **Auslöschungseffekte vermieden werden**.

Verständnisfragen

Es seien $x_{\min}$ bzw. $x_{\max}$ die kleinste bzw. größte (strikt) positive Zahl sowie eps die relative Maschinengenauigkeit in der Menge $\mathbb{M}(b, m, r, R)$ der Maschinenzahlen und $\mathbb{D} := [-x_{\max}, -x_{\min}] \cup [x_{\min}, x_{\max}]$. Ferner beschreibe $\text{fl} : \mathbb{D} \rightarrow \mathbb{M}(b, m, r, R)$ die Standardrundung. Alle Zahlen sind im Dezimalsystem angegeben.

Berechnen Sie $x_{\max}$ für $\mathbb{M}(3, 2, -1, 3)$

$$x_{\max} = (1 - b^{-m}) b^R = \dots = 29$$

Verständnisfragen

Es seien $x_{\min}$ bzw. $x_{\max}$ die kleinste bzw. größte (strikt) positive Zahl sowie eps die relative Maschinengenauigkeit in der Menge $\mathbb{M}(b, m, r, R)$ der Maschinenzahlen und $\mathbb{D} := [-x_{\max}, -x_{\min}] \cup [x_{\min}, x_{\max}]$. Ferner beschreibe $\text{fl} : \mathbb{D} \rightarrow \mathbb{M}(b, m, r, R)$ die Standardrundung. Alle Zahlen sind im Dezimalsystem angegeben.

Berechnen Sie $x_{\max}$ für $\mathbb{M}(3, 2, -1, 3)$

24

w Es gilt $\left| \frac{\text{fl}(x-y) - (x-y)}{(x-y)} \right| \leq \text{eps}$ für alle $x, y \in \mathbb{M}(b, m, r, R)$ mit $x \neq y$ und $|x - y| \leq x_{\max}$.

f Es gilt $\left| \frac{\text{fl}(x-y) - (x-y)}{(x-y)} \right| \leq \text{eps}$ für alle $x, y \in \mathbb{D}$ mit $x \neq y$ und $|x - y| \leq x_{\max}$.

f Bei einem stabilen Algorithmus ist der Ausgabefehler nicht viel größer als der Eingabefehler.