

# Übung 1: Maschinenzahlen

Für  $b, t \in \mathbb{N}$ ,  $e_{\min}, e_{\max} \in \mathbb{Z} \cup \{\pm\infty\}$  heißt

$$F(b, t, e_{\min}, e_{\max}) := \left\{ \sigma \cdot \underbrace{(0, z_1 \dots z_t)}_{\substack{\text{Vorzeichen} \\ \text{Mantisse}}} \cdot b^e \mid \sigma \in \{1, -1\}, \right. \\ \left. z_1 \neq 0, z_1, \dots, z_t \in \{0, \dots, b-1\}, e \in \{e_{\min}, \dots, e_{\max}\} \right\} \cup \{0\}$$

die Menge der Fließkommazahlen zur Basis  $b$  und Mantissenlänge  $t$ .

Ist  $b$  gerade so ist der Rundungsoperator  $\text{rd} : \mathbb{R} \rightarrow F$  für

$$\mathbb{R} \ni x = \sigma \cdot (0, z_1 \dots z_t z_{t+1} \dots) \cdot b^e \text{ durch}$$

$$\text{rd}(x) = \begin{cases} \sigma \cdot (0, z_1 \dots z_t) \cdot b^e, & z_{t+1} \leq \frac{b}{2}-1 \\ \sigma \cdot (0, z_1 \dots (z_t+1)) \cdot b^e, & z_{t+1} \geq \frac{b}{2} \end{cases}$$

definiert.

Für die Beispiele betrachten wir im folgenden

$$F = F(10, 4, -\infty, \infty).$$

Damit ist z.B.

$$\text{rd}(\pi) = \text{rd} (+ (0, 31415\dots) \cdot 10^{41}) = 0,3142 \cdot 10^4$$

und

$$\text{rd}(\sqrt{2}) = \text{rd} (0,14142\dots \cdot 10^1) = 0,1414 \cdot 10^1$$

Es heißt

$$\text{macheps} := \varepsilon^* := \text{eps} := \frac{1}{2} b^{(-t+1)}$$

die Maschinengenauigkeit zu  $F(b, t, \ell_{\min}, \ell_{\max})$ .

Satz: Es ist

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

und für  $x \in \mathbb{R}$  gilt (falls  $\ell_{\min} = -\infty, \ell_{\max} = \infty$ )

$$\left[ \text{eps} \geq \left| \frac{\text{rd}(x) - x}{x} \right| \quad (=: |\varepsilon|) \right] \Rightarrow$$

$$\left[ \exists \varepsilon \in \mathbb{R}, |\varepsilon| \leq \text{eps}, \text{ so dass } \varepsilon = \frac{\text{rd}(x) - x}{x} \right] \Rightarrow$$

$$\left[ \exists \varepsilon \in \mathbb{R}, |\varepsilon| \leq \text{eps}, \text{ mit } \text{rd}(x) = x(1+\varepsilon) \right]$$

Beweis: VL  $\square$

Die Maschinen-/Ersatz-Operationen  $\tilde{+}, \tilde{-},$

$\tilde{x}, \tilde{\div} : \overline{F} \times \overline{F} \rightarrow \overline{F}$  sind für  $x, y \in \overline{F}$

durch

$$x \tilde{o} y := \text{rd}(x o y)$$

$$= (x o y)(1 + \varepsilon)$$

$$o \in \{+, -, \times, \div\}$$

gegeben. Weiter bezeichne Rundungsfehler

~~folgendes Problem~~

$$\text{sqrt}(x) := \text{rd}(\sqrt{x'}) \stackrel{\text{Satz}}{=} \sqrt{x'}(1+\varepsilon), \quad \text{Rundungsfehler}$$

das maschinelle Wurzelziehen.

Bei verkettenen Ausdrücken können sich die Rundungsfehler hochschankeln / akkumulieren.

Um diesen Effekt zu analysieren betrachten wir die

### Fehleranalyse

am Beispiel der äquivalenten Ausdrücke

$$\boxed{a) \sqrt{1+x'} - 1} = \frac{(\sqrt{1+x'} - 1)(\sqrt{1+x'} + 1)}{\sqrt{1+x'} + 1} =$$

$$\boxed{b) \frac{x}{\sqrt{1+x'} + 1}}, \quad \text{für } |x| \approx 0.$$

Dabei kann man zwei Methoden anwenden:

Methode 1: am Beispiel a)

Ist  $f: \mathbb{R} \rightarrow \mathbb{R}$  genügend oft differenzierbar, so heißt

$$f(x+\varepsilon) = f(x) + \varepsilon f'(x) + \frac{\varepsilon^2}{2} f''(x) + \dots$$


die Taylorentwicklung von  $f$ . Ist nun  $|\varepsilon|$  klein, so ist  $|\varepsilon|^2$  sehr klein und daher nennt man

$$f(x+\varepsilon) \approx f(x) + \varepsilon f'(x)$$

Approximation erster Ordnung. Da  $\frac{d}{dx} \sqrt{x} = \frac{1}{2\sqrt{x}}$   
ist z.B.

$$\sqrt{1+\varepsilon} \approx \sqrt{1} + \varepsilon \frac{1}{2\sqrt{1}}$$

$$= 1 + \frac{\varepsilon}{2} \quad (*)$$



Nun wird auf der Maschine der Ausdruck a)  
ausgewertet als

$$\text{sqrt}(1+x) \approx 1$$

$$= \text{sqrt}((1+x)(1+\varepsilon_1)) \approx 1$$

$$= \left[ \sqrt{(1+x)(1+\varepsilon_1)} (1+\varepsilon_2) - 1 \right] (1+\varepsilon_3)$$

$$= \left[ \sqrt{1+x} \sqrt{1+\varepsilon_1} (1+\varepsilon_2) - 1 \right] (1+\varepsilon_3)$$

$$\stackrel{(*)}{\approx} \left[ \sqrt{1+x} \left( 1 + \frac{\varepsilon_1}{2} \right) (1+\varepsilon_2) - 1 \right] (1+\varepsilon_3)$$

$$= \left[ \sqrt{1+x} \left( 1 + \frac{\varepsilon_1}{2} + \varepsilon_2 + \frac{\varepsilon_1 \varepsilon_2}{2} \right) - 1 \right] (1+\varepsilon_3)$$


sehr klein

$$\approx \left[ \sqrt{1+x} \left( 1 + \frac{\varepsilon_1}{2} + \varepsilon_2 \right) - 1 \right] (1+\varepsilon_3)$$

$$= \sqrt{1+x} \left( 1 + \frac{\varepsilon_1}{2} + \varepsilon_2 \right) - 1 + \sqrt{1+x} \left( \varepsilon_3 + \frac{\varepsilon_1 \varepsilon_3}{2} + \varepsilon_2 \varepsilon_3 \right) - \varepsilon_3$$

sehr klein

$$\approx \sqrt{1+x} - 1 + \sqrt{1+x} \left( \frac{\varepsilon_1}{2} + \varepsilon_2 + \varepsilon_3 \right) - \varepsilon_3$$



Damit ist der Fehler

$$\begin{aligned} & \left| \sqrt{1+x} - 1 - (\sqrt{1+x'} - 1) \right| \\ & \leq \left| \sqrt{1+x'} \right| \cdot \left| \frac{\varepsilon_1}{2} + \varepsilon_2 \right| + \left| \sqrt{1+x'} - 1 \right| \cdot |\varepsilon_3| \\ & \leq \sqrt{1+x'} \cdot \frac{3}{2} \text{eps} + |\sqrt{1+x'} - 1| \cdot \text{eps} \\ & \stackrel{x \text{ klein}}{\approx} \left( 1 + \frac{x}{2} \right) \frac{3}{2} \text{eps} + |1 + \frac{x}{2} - 1| \cdot \text{eps} \\ & \leq \left( \frac{3}{2} + \frac{5}{4}|x| \right) \cdot \text{eps} \end{aligned}$$

Methode 2: am Beispiel (a)

Ist  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  genügend oft differenzierbar,  
so heißt

$$f(\varepsilon_1, \dots, \varepsilon_n) = f(0, \dots, 0) + Df|_0 \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix} + \frac{1}{2} \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}^\top D^2 f|_0 \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix} + \dots$$

die mehrdimensionale Taylorentwicklung von  $f$ .  
Analog heißt

$$f(\underbrace{\varepsilon_1, \dots, \varepsilon_n}_{=: \varepsilon}) \approx f(0, \dots, 0) + Df|_0 \begin{bmatrix} \varepsilon_1 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

die Approximation erster Ordnung.

~~Während auf der Basislage der Fließrichtung ausgewertet wird~~

Mit  $f(\varepsilon_1, \varepsilon_2, \varepsilon_3)$  wie oben<sup>(II)</sup> ist nun  $f(0,0,0)$

der exakte Flussdruck a) und damit ist  
der Fehler

$$\begin{aligned} & |f(\varepsilon_1, \varepsilon_2, \varepsilon_3) - f(0, 0, 0)| \\ & \approx \|Df\|_0 \left[ \begin{matrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \end{matrix} \right] \quad (\Delta) \\ & \leq \|Df\|_0 \| \cdot \| \left[ \begin{matrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \end{matrix} \right] \|_\infty \leq \|Df\|_0 \| \cdot \text{eps} . \end{aligned}$$

Mit

$$Df|_{(\varepsilon_1, \varepsilon_2, \varepsilon_3)} = \left[ \sqrt{1+x} \frac{1}{2\sqrt{1+x}} (1+\varepsilon_2)(1+\varepsilon_3), \sqrt{(1+x)(1+\varepsilon_1)} (1+\varepsilon_3), \right. \\ \left. \sqrt{(1+x)(1+\varepsilon_1)} (1+\varepsilon_2) - 1 \right]$$

$$\Rightarrow Df|_{(0,0,0)} = \left[ \frac{1}{2} \sqrt{1+x}, \sqrt{1+x}, \sqrt{1+x} - 1 \right] \\ \Rightarrow \|Df\|_0 = \frac{3}{2} \sqrt{1+x} + |\sqrt{1+x} - 1|$$

Insgesamt also

$$\begin{aligned} & | \text{sqrt}(1+x) - 1 - (\sqrt{1+x} - 1) | \\ & \stackrel{(I)}{=} |f(\varepsilon_1, \varepsilon_2, \varepsilon_3) - f(0, 0, 0)| \\ & \stackrel{(\Delta)}{\leq} \|Df\|_0 \cdot \text{eps} = \sqrt{1+x} \cdot \frac{3}{2} \text{eps} + |\sqrt{1+x} - 1| \cdot \text{eps} \\ & \stackrel{x \text{ klein}}{\approx} \left(1 + \frac{x}{2}\right) \frac{3}{2} \text{eps} + |1 + \frac{x}{2} - 1| \text{eps} \leq \left(\frac{3}{2} + \frac{5}{4}|x|\right) \cdot \text{eps} \end{aligned}$$

das gleiche Ergebnis wie bei Methode 1.

Methode 2: am Beispiel b)

Auf der Maschine ist Ausdruck b)

$$x \approx \text{sgnf}(1+x) + 1$$

$$= \frac{x(1+\varepsilon_1)}{\left[\sqrt{(1+x)(1+\varepsilon_2)}(1+\varepsilon_3) + 1\right](1+\varepsilon_4)} =: f(\varepsilon_1, \varepsilon_2, \varepsilon_3, \varepsilon_4)$$

$$\Rightarrow Df|_0 = \left[ \frac{x}{\sqrt{1+x} + 1}, -\frac{x}{2} \cdot \frac{\sqrt{1+x}}{(\sqrt{1+x} + 1)^2} + x \cdot \frac{\sqrt{1+x}}{(\sqrt{1+x} + 1)^2}, -\frac{x}{\sqrt{1+x} + 1} \right]$$

$$\Rightarrow \|Df|_0\|_1 = 2 \frac{|x|}{\sqrt{1+x} + 1} + \frac{3}{2} \frac{|x| \sqrt{1+x}}{(\sqrt{1+x} + 1)^2}$$

$$\leq 2|x| + \frac{3}{2}|x| \underbrace{\sqrt{1+x}}_{\leq 2} \quad \text{für } |x| \leq 1$$

~~oder~~

$$\leq 5|x|$$

$$\Rightarrow |x \approx \text{sgnf}(1+x) + 1 - \left( \frac{x}{\sqrt{1+x} + 1} \right)|$$

$$\leq \|Df|_0\|_1 \cdot \text{eps} \leq 5|x| \cdot \text{eps}$$