

Darstellung rationaler und reeller Zahlen Vorlesung vom 20.11.20

Rationale Zahlen:

Rationale Zahlen als Brüche ganzer Zahlen.

q -adische Brüche, periodische q -adische Brüche. Beispiele.

Satz: Jede rationale Zahl ist als **periodischer** q -adischer Bruch darstellbar.

Eindeutigkeit durch $0, \overline{9}$ statt 1.

Praktische Realisierung: Dynamische Ziffernanzahl. Aufwand pro Addition problemabhängig. (Hauptnenner, Kürzen).

Reelle Zahlen:

Reelle Zahlen als **unendliche** q -adische Brüche.

Satz: \mathbb{R} ist nicht abzählbar. Folgerung: Es gibt keine Zifferndarstellung von \mathbb{R} .

Konsequenz: Numerisches Rechnen mit reellen Zahlen ist nicht möglich!

Festkommazahlen:

Absoluter und relativer Fehler. Beispiele.

Definition von Festkommazahlen und Gleitkommazahlen. Beispiele.

Festkommazahlen

$$z_{n-1} z_{n-2} \cdots z_0, z_{-1} \cdots z_{-m} = \sum_{i=-m}^{n-1} z_i q^i, \quad z_i \in \{0, \dots, q-1\}.$$

$\ell = m + n$ Stellen verfügbar; $n, m \in \mathbb{N}$ **fest gewählt**.

Beispiel: $q = 10, \ell = 4, n = 3, m = 1$

$x = 0,123$, Runden: $\tilde{x} = 0,1$ relativer Fehler: $|x - \tilde{x}|/|x| \approx 0.2$

$x = 123$, exakt darstellbar: $\tilde{x} = 123$ relativer Fehler: $|x - \tilde{x}|/|x| = 0$

Folgerung:

Im Sinne einer optimalen Stellenausnutzung n, m **variabel halten!**

Gleitkommazahlen $\mathbb{G}(\ell, q)$

Definition: (Gleitkommazahlen) Jede in der Form

$$\tilde{x} = (-1)^s a \cdot q^e \quad (1)$$

mit Vorzeichenbit $s \in \{0, 1\}$, Exponent $e \in \mathbb{Z}$ und *Mantisse* $a = 0$ oder

$$a = 0, a_1 \cdots a_\ell = \sum_{i=1}^{\ell} a_i q^{-i}, \quad a_i \in \{0, \dots, q-1\}, a_1 \neq 0,$$

darstellbare Zahl \tilde{x} heißt **Gleitkommazahl** mit *Mantissenlänge* $\ell \in \mathbb{N}$, $\ell \geq 1$.

Die Menge all dieser Zahlen heißt $\mathbb{G}(q, \ell)$.

Die Darstellung (1) heißt **normalisierte Gleitkommadarstellung**.

Approximation durch Runden

normalisierte Darstellung:

$$x = a^* q^e, \quad e \in \mathbb{Z}, \quad q^{-1} \leq a^* < 1$$

unendlicher q -adischer Bruch:

$$a^* = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \dots = \sum_{i=1}^{\infty} a_i q^{-i}, \quad a_i \in \{0, \dots, q-1\}$$

Approximation durch Runden

normalisierte Darstellung:

$$x = a^* q^e, \quad e \in \mathbb{Z}, \quad q^{-1} \leq a^* < 1$$

unendlicher q -adischer Bruch:

$$a^* = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \dots = \sum_{i=1}^{\infty} a_i q^{-i}, \quad a_i \in \{0, \dots, q-1\}$$

Runden: $\tilde{x} = \text{rd}(x) := a q^e$

$$a = \sum_{i=1}^{\ell} a_i q^{-i} + \begin{cases} 0 & \text{falls } a_{\ell+1} < \frac{1}{2}q \\ q^{-\ell} & \text{falls } a_{\ell+1} \geq \frac{1}{2}q \end{cases}$$

Fehlerabschätzung: Absoluter Fehler

Satz: Zu jedem $N \in \mathbb{N}$ gibt es ein $x \in \mathbb{R}$, so daß

$$|x - \text{rd}(x)| \geq q^N .$$

Fehlerabschätzung: Absoluter Fehler

Satz: Zu jedem $N \in \mathbb{N}$ gibt es ein $x \in \mathbb{R}$, so daß

$$|x - \text{rd}(x)| \geq q^N .$$

Beweis:

Wähle $x = 0, z_1 \cdots z_\ell z_{\ell+1} \cdot q^{\ell+1+N}$ mit $z_1, z_{\ell+1} \neq 0$ und $N \in \mathbb{N}$.

Fehlerabschätzung: Absoluter Fehler

Satz: Zu jedem $N \in \mathbb{N}$ gibt es ein $x \in \mathbb{R}$, so daß

$$|x - \text{rd}(x)| \geq q^N .$$

Beweis:

Wähle $x = 0, z_1 \cdots z_\ell z_{\ell+1} \cdot q^{\ell+1+N}$ mit $z_1, z_{\ell+1} \neq 0$ und $N \in \mathbb{N}$.

Der absolute Rundungsfehler kann beliebig groß werden.

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0 .$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0.$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Beweisskizze: O.B.D.A. $x > 0$. Aufrunden: $a_{\ell+1} \geq \frac{1}{2}q$

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0.$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Beweisskizze: O.B.D.A. $x > 0$. Aufrunden: $a_{\ell+1} \geq \frac{1}{2}q$

$$x = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \dots \cdot q^e, \quad a_1 \neq 0$$

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0.$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Beweisskizze: O.B.D.A. $x > 0$. Aufrunden: $a_{\ell+1} \geq \frac{1}{2}q$

$$x = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \cdots \cdot q^e, \quad a_1 \neq 0$$

$$\text{rd}(x) = (0, a_1 a_2 \cdots a_\ell + q^{-\ell}) \cdot q^e$$

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0.$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Beweisskizze: O.B.D.A. $x > 0$. Aufrunden: $a_{\ell+1} \geq \frac{1}{2}q$

$$x = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \dots \cdot q^e, \quad a_1 \neq 0$$

$$\text{rd}(x) = (0, a_1 a_2 \cdots a_\ell + q^{-\ell}) \cdot q^e$$

$$\frac{|x - \text{rd}(x)|}{|x|}$$

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0.$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Beweisskizze: O.B.D.A. $x > 0$. Aufrunden: $a_{\ell+1} \geq \frac{1}{2}q$

$$x = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \dots \cdot q^e, \quad a_1 \neq 0$$

$$\text{rd}(x) = (0, a_1 a_2 \cdots a_\ell + q^{-\ell}) \cdot q^e$$

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{(q^{-\ell} - a_{\ell+1} q^{-(\ell+1)}) \cdot q^e}{q^{-1} \cdot q^e}$$

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0.$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Beweisskizze: O.B.D.A. $x > 0$. Aufrunden: $a_{\ell+1} \geq \frac{1}{2}q$

$$x = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \dots \cdot q^e, \quad a_1 \neq 0$$

$$\text{rd}(x) = (0, a_1 a_2 \cdots a_\ell + q^{-\ell}) \cdot q^e$$

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{(q^{-\ell} - a_{\ell+1}q^{-(\ell+1)}) \cdot q^e}{q^{-1} \cdot q^e} \leq \frac{q^{-\ell} - \frac{1}{2}q \cdot q^{-(\ell+1)}}{q^{-1}}$$

Fehlerabschätzung: Relativer Fehler

Satz: Es sei q eine gerade Zahl. Dann gilt

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{1}{2}q^{-(\ell-1)} =: \text{eps}(q, \ell) \quad \forall x \in \mathbb{R}, x \neq 0.$$

Die Zahl $\text{eps}(q, \ell)$ heißt **Maschinengenauigkeit**.

Beweisskizze: O.B.D.A. $x > 0$. Aufrunden: $a_{\ell+1} \geq \frac{1}{2}q$

$$x = 0, a_1 a_2 \cdots a_\ell a_{\ell+1} \dots \cdot q^e, \quad a_1 \neq 0$$

$$\text{rd}(x) = (0, a_1 a_2 \cdots a_\ell + q^{-\ell}) \cdot q^e$$

$$\frac{|x - \text{rd}(x)|}{|x|} \leq \frac{(q^{-\ell} - a_{\ell+1}q^{-(\ell+1)}) \cdot q^e}{q^{-1} \cdot q^e} \leq \frac{q^{-\ell} - \frac{1}{2}q \cdot q^{-(\ell+1)}}{q^{-1}} = \frac{1}{2}q \cdot q^{-\ell}$$

Maschinengenauigkeit

Der relative Rundungsfehler ist durch $eps(q, \ell)$ beschränkt.

Mantissenlänge $\ell \iff \ell$ gültige Stellen $\iff eps(q, \ell) = \frac{1}{2}q^{-(\ell-1)}$

Praktische Realisierung

endlicher Exponenten-Bereich:

$$e \in \{e_{\min}, e_{\min} + 1, \dots, e_{\max} - 1, e_{\max}\} \subset \mathbb{Z}$$

endlicher Zahlen-Bereich:

$$x_{\min} := q^{e_{\min}-1} \leq |x| \leq (1 - q^{-\ell})q^{e_{\max}} =: x_{\max}$$

$x < x_{\min}$: underflow oder $x = 0$

$x > x_{\max}$: overflow oder $x = NaN$

IEEE 754 - Standard

	float	double
Länge in Bits	32	64
Vorzeichen s Bits	1	1
Exponent e Bits	8	11
Mantisse a Bits	23	52
Maschinengenauigkeit eps	$6,0 \cdot 10^{-8}$	$1,1 \cdot 10^{-16}$
e_{\min}	- 126	- 1022
e_{\max}	128	1024
x_{\min}	$1,2 \cdot 10^{-38}$	$2,2 \cdot 10^{-308}$
x_{\max}	$3,4 \cdot 10^{+38}$	$1,8 \cdot 10^{+308}$

Zahlenmengen statt Zahlen

Menge aller Approximationen \tilde{x} auf ℓ gültige Stellen im q -System:

$$\text{rd}(x) \in \{\tilde{x} \in \mathbb{R} \mid \tilde{x} = x(1 + \varepsilon), |\varepsilon| \leq \text{eps}(q, \ell)\}, \quad x \in \mathbb{R}$$

Menge aller $x \in \mathbb{R}$, die auf $\tilde{x} = \text{rd}(x) \in \mathbb{G}(q, \ell)$ gerundet werden:

$$R(\tilde{x}) = \{x \in \mathbb{R} \mid \tilde{x} = \text{rd}(x)\}, \quad \tilde{x} \in \mathbb{G}(q, \ell)$$

Zahlenmengen statt Zahlen

Menge aller Approximationen \tilde{x} auf ℓ gültige Stellen im q -System:

$$\text{rd}(x) \in \{\tilde{x} \in \mathbb{R} \mid \tilde{x} = x(1 + \varepsilon), |\varepsilon| \leq \text{eps}(q, \ell)\}, \quad x \in \mathbb{R}$$

Menge aller $x \in \mathbb{R}$, die auf $\tilde{x} = \text{rd}(x) \in \mathbb{G}(q, \ell)$ gerundet werden:

$$R(\tilde{x}) = \{x \in \mathbb{R} \mid \tilde{x} = \text{rd}(x)\}, \quad \tilde{x} \in \mathbb{G}(q, \ell)$$

Satz: Es sei q eine gerade Zahl und

$$\tilde{x} = aq^e \in \mathbb{G}(q, \ell), \quad q^{-1} < a_0, a_1 \cdots a_\ell \leq 1 .$$

Dann gilt $R(\tilde{x}) = [\alpha(\tilde{x}), \beta(\tilde{x}))$ mit

$$\alpha(\tilde{x}) = \tilde{x} - q^{e-1} \text{eps} , \quad \beta(\tilde{x}) = \tilde{x} + q^{e-1+a_0} \text{eps} .$$

Gleichheits-Abfragen von Gleitkomma-Zahlen

Folgerung: Die Abfrage `if $\tilde{x} == \tilde{y}$` mit $\tilde{x}, \tilde{y} \in \mathbb{G}(q, \ell)$ ist sinnlos!

$$\tilde{x} = \tilde{y} \not\Rightarrow x = y, \quad \tilde{x} = \text{rd}(x), \tilde{y} = \text{rd}(y)$$

Gleichheits-Abfragen von Gleitkomma-Zahlen

Folgerung: Die Abfrage `if $\tilde{x} == \tilde{y}$` mit $\tilde{x}, \tilde{y} \in \mathbb{G}(q, \ell)$ ist sinnlos!

$$\tilde{x} = \tilde{y} \not\Rightarrow x = y, \quad \tilde{x} = \text{rd}(x), \tilde{y} = \text{rd}(y)$$

umgekehrt: $x = y \Rightarrow \text{rd}(x) = \text{rd}(y)$ aber

$$x = a + b, y = x \quad \tilde{x} = \text{rd}(a) + \text{rd}(b), \tilde{y} = \text{rd}(x) \not\Rightarrow \tilde{x} = \tilde{y}$$

Gleichheits-Abfragen von Gleitkomma-Zahlen

Folgerung: Die Abfrage `if $\tilde{x} == \tilde{y}$` mit $\tilde{x}, \tilde{y} \in \mathbb{G}(q, \ell)$ ist sinnlos!

$$\tilde{x} = \tilde{y} \not\Rightarrow x = y, \quad \tilde{x} = \text{rd}(x), \tilde{y} = \text{rd}(y)$$

umgekehrt: $x = y \Rightarrow \text{rd}(x) = \text{rd}(y)$ aber

$$x = a + b, y = x \quad \tilde{x} = \text{rd}(a) + \text{rd}(b), \tilde{y} = \text{rd}(x) \not\Rightarrow \tilde{x} = \tilde{y}$$

Gleichheits-Abfragen von Gleitkomma-Zahlen verboten!

Praxisbeispiel

Aufgabe: Plotten Sie

$$f(x) = \begin{cases} \frac{x - \pi}{\sin(x)} & \text{falls } \sin(x) \neq 0 \\ -1 & \text{falls } \sin(x) = 0 \end{cases} \quad x \in \left[\frac{1}{2}\pi, \frac{3}{2}\pi\right]$$

```
function tumbplot(n)
```

```
h=pi/n;
```

```
for i=1:n+1
```

```
    x(i) = pi/2 + (i-1)*h;
```

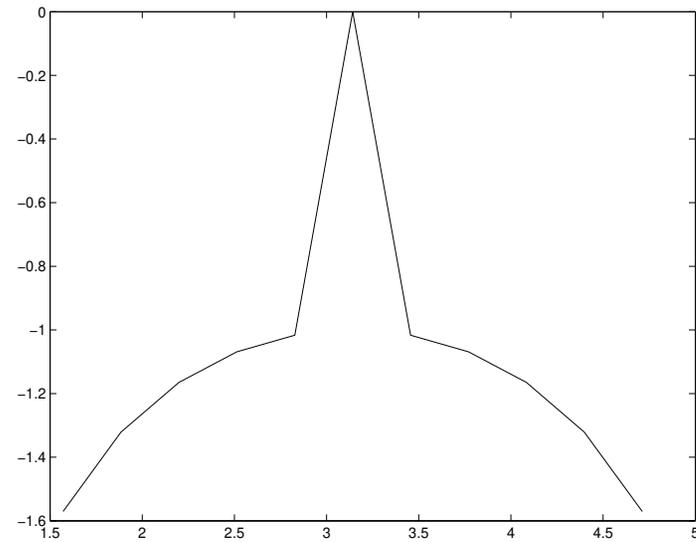
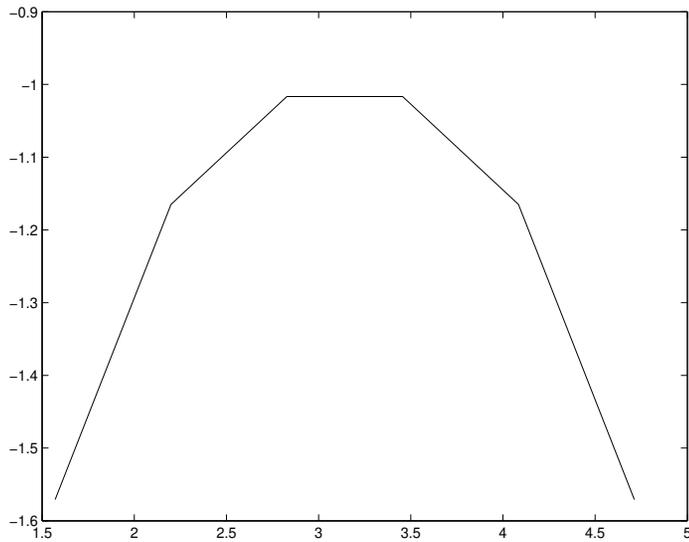
```
    if (sin(x(i))==0) y(i) = -1;
```

```
    else y(i) = (x(i)-pi)/sin(x(i)); end;
```

```
end;
```

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

Was ist passiert?



Das Ergebnis von TumbPlot für $n = 5$ und $n = 10$.

siehe Abschnitt 5.3.6 im Skript

Gleichheits-Abfragen von Gleitkomma-Zahlen

Folgerung: Die Abfrage `if $\tilde{x} == \tilde{y}$` mit $\tilde{x}, \tilde{y} \in \mathbb{G}(q, \ell)$ ist sinnlos!

$$\tilde{x} = \tilde{y} \not\Rightarrow x = y, \quad \tilde{x} = \text{rd}(x), \tilde{y} = \text{rd}(y)$$

umgekehrt: $x = y \Rightarrow \text{rd}(x) = \text{rd}(y)$ aber

$$x = a + b, y = x \quad \tilde{x} = \text{rd}(a) + \text{rd}(b), \tilde{y} = \text{rd}(x) \not\Rightarrow \tilde{x} = \tilde{y}$$

Gleichheits-Abfragen von Gleitkomma-Zahlen verboten!

Algebraische Eigenschaften

Grundrechenarten führen aus $\mathbb{G} = \mathbb{G}(q, \ell)$ heraus:

$$\tilde{x}, \tilde{y} \in \mathbb{G} \not\Rightarrow \tilde{x} + \tilde{y} \in \mathbb{G}, \quad \text{analog: } -, \cdot, /$$

Gleitkommaarithmetik:

$$\tilde{x} \hat{+} \tilde{y} = \text{rd}(\tilde{x} + \tilde{y}), \quad \tilde{x} \hat{-} \tilde{y} = \text{rd}(\tilde{x} - \tilde{y}), \quad \tilde{x} \hat{*} \tilde{y} = \text{rd}(\tilde{x} \tilde{y}), \quad \tilde{x} \hat{:} \tilde{y} = \text{rd}(\tilde{x} : \tilde{y}), \quad \tilde{y} \neq 0$$

Algebraische Eigenschaften

Grundrechenarten führen aus $\mathbb{G} = \mathbb{G}(q, \ell)$ heraus:

$$\tilde{x}, \tilde{y} \in \mathbb{G} \not\Rightarrow \tilde{x} + \tilde{y} \in \mathbb{G}, \quad \text{analog: } -, \cdot, /$$

Gleitkommaarithmetik:

$$\tilde{x} \tilde{+} \tilde{y} = \text{rd}(\tilde{x} + \tilde{y}), \quad \tilde{x} \tilde{-} \tilde{y} = \text{rd}(\tilde{x} - \tilde{y}), \quad \tilde{x} \tilde{*} \tilde{y} = \text{rd}(\tilde{x} \tilde{y}), \quad \tilde{x} \tilde{:} \tilde{y} = \text{rd}(\tilde{x} : \tilde{y}), \quad \tilde{y} \neq 0$$

Die Folge:

Die Gleitkommazahlen mit Gleitkommaarithmetik sind kein Körper.

$\tilde{+}, \tilde{*}$ nicht assoziativ, nicht distributiv, i.a. kein Inverses bzgl. $\tilde{*}$

Computer können nicht rechnen!

Äquivalente Umformungen in \mathbb{R} sind in Gleitkommaarithmetik nicht äquivalent.

Computer können nicht rechnen!

Äquivalente Umformungen in \mathbb{R} sind in Gleitkommaarithmetik nicht äquivalent.

Beispiele:

keine binomische Formel:

$$(a \tilde{+} b) \tilde{*} (a \tilde{+} b) \neq a \tilde{*} a \tilde{+} 2 \tilde{*} a \tilde{*} b \tilde{+} b \tilde{*} b$$

Computer können nicht rechnen!

Äquivalente Umformungen in \mathbb{R} sind in Gleitkommaarithmetik nicht äquivalent.

Beispiele:

keine binomische Formel:

$$(a \tilde{+} b) \tilde{*} (a \tilde{+} b) \neq a \tilde{*} a \tilde{+} 2 \tilde{*} a \tilde{*} b \tilde{+} b \tilde{*} b$$

kein Assoziativgesetz:

$$(a \tilde{*} a \tilde{+} 2 \tilde{*} a \tilde{*} b) \tilde{+} b \tilde{*} b \neq a \tilde{*} a \tilde{+} (2 \tilde{*} a \tilde{*} b \tilde{+} b \tilde{*} b)$$

Computer können nicht rechnen!

Äquivalente Umformungen in \mathbb{R} sind in Gleitkommaarithmetik nicht äquivalent.

Beispiele:

keine binomische Formel:

$$(a \tilde{+} b) \tilde{*} (a \tilde{+} b) \neq a \tilde{*} a \tilde{+} 2 \tilde{*} a \tilde{*} b \tilde{+} b \tilde{*} b$$

kein Assoziativgesetz:

$$(a \tilde{*} a \tilde{+} 2 \tilde{*} a \tilde{*} b) \tilde{+} b \tilde{*} b \neq a \tilde{*} a \tilde{+} (2 \tilde{*} a \tilde{*} b \tilde{+} b \tilde{*} b)$$

It is hard, but it's harder to ignore it Cat Stevens

Ausblick: Kondition

Auswirkung von Eingabefehlern auf das Ergebnis

