

Einführung in die Programmierung

Tutorium 7



Wintersemester 2025/2026

Arbeitsgruppe Systemsoftware
Angewandte Informatik 12

Implementieren Sie die IEEE-754-konforme Addition zweier Fließkommazahlen (**ieee32_add_u**) rein mittels Ganzzahlarithmetik und Bitoperationen, inklusive aller Teilschritte wie

- Exponentenausrichtung,
- Addition der Mantissen,
- Normalisierung nach Subtraktion
- Rundung

Beispiel $34 + (-7)$ **Umwandlung von 34 in IEEE 754**1. Vorzeichen dokumentierenFalls positiv: $S = 0$ Falls negativ: $S = 1$ 2. Umwandlung in eine Binärzahl

$$(34)_D = (100010,0)_B$$

3. Normalisierung der Binärzahl

$$(100010,0)_B = (1,000100)_B * 2^5$$

Beispiel $34 + (-7)$ **Umwandlung von 34 in IEEE 754**3. Normalisierung der Binärzahl

$$(100010,0)_B = (1,000100)_B * 2^5$$

4. Exponenten berechnen

$$(5)_D + (127)_D \text{ (Bias)} = (132)_D = (10000100)_B$$

5. Mantisse erzeugen

Nehme von $(1,000100)_B$ Nachkommastellen,
also 000100.

Beispiel $34 + (-7)$ **Umwandlung von 34 in IEEE 754**6. Alles zusammensetzen

0	1000 0100	000 1000 0000 0000 0000 0000
---	-----------	------------------------------

Beispiel $34 + (-7)$ **Umwandlung von -7 in IEEE 754**1. Vorzeichen dokumentierenFalls positiv: $S = 0$ Falls negativ: $S = 1$ 2. Umwandlung in eine Binärzahl

$$(7)_D = (111,0)_B$$

3. Normalisierung der Binärzahl

$$(111,0)_B = (1,11)_B * 2^2$$

Beispiel $34 + (-7)$ **Umwandlung von -7 in IEEE 754**3. Normalisierung der Binärzahl

$$(111,0)_B = (1,11)_B * 2^2$$

4. Exponenten berechnen

$$(2)_D + (127)_D \text{ (Bias)} = (129)_D = (10000001)_B$$

5. Mantisse erzeugen

Nehme von $(1,11)_B$ Nachkommastellen,
also 11.

Beispiel $34 + (-7)$ **Umwandlung von -7 in IEEE 754**6. Alles zusammensetzen

1	1000 0001	110 0000 0000 0000 0000 0000
---	-----------	------------------------------

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000
---	-----------	------------------------------

 $(34)_D$

1	1000 0001	110 0000 0000 0000 0000 0000
---	-----------	------------------------------

 $(-7)_D$

1. Extraktion der Komponenten
2. Exponentenausrichtung
3. Addition der Mantissen
4. Normalisierung
5. Rundung

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000	$(34)_D$
---	-----------	------------------------------	----------

1	1000 0001	110 0000 0000 0000 0000 0000	$(-7)_D$
---	-----------	------------------------------	----------

1. Extraktion der Komponenten

0	1000 0100	1,000 1000 0000 0000 0000 0000
---	-----------	--------------------------------

Mantissen mit Hidden-Bit!

1	1000 0001	1,110 0000 0000 0000 0000 0000
---	-----------	--------------------------------

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000	$(34)_D$
---	-----------	------------------------------	----------

1	1000 0001	110 0000 0000 0000 0000 0000	$(-7)_D$
---	-----------	------------------------------	----------

2. Exponentenausrichtung

Exponenten müssen immer identisch sein. Allerdings...

1000 0100	$= (132)_D \neq (129)_D =$	1000 0001
-----------	----------------------------	-----------

Immer kleineren Exponenten an größeren anpassen.

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000	$(34)_D$
---	-----------	------------------------------	----------

1	1000 0001	110 0000 0000 0000 0000 0000	$(-7)_D$
---	-----------	------------------------------	----------

2. Exponentenausrichtung

$$\begin{array}{llll}
 (34)_D & = & (100010,0)_B & = & (1,000100)_B & * 2^5 & \text{(echte)} \\
 (7)_D & = & (111,0)_B & = & (1,11)_B & * 2^2 & \text{Exponenten} \\
 & & & & & & \text{unterscheiden} \\
 & & & & & & \text{sich um 3}
 \end{array}$$

Immer kleineren Exponenten an größeren anpassen.

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000	$(34)_D$
---	-----------	------------------------------	----------

1	1000 0001	110 0000 0000 0000 0000 0000	$(-7)_D$
---	-----------	------------------------------	----------

2. Exponentenausrichtung

$$\begin{aligned}
 (34)_D &= (100010,0)_B = (1,000100)_B * 2^5 \\
 (7)_D &= (111,0)_B = (0,00111)_B * 2^5
 \end{aligned}$$

(echte) Exponenten unterscheiden sich um 0

Immer kleineren Exponenten an größeren anpassen.

Beispiel

$34 + (-7)$

Addition von 34 und -7 in IEEE 754

0	1000 0100	000 1000 0000 0000 0000 0000	$(34)_D$
---	-----------	------------------------------	----------

1	1000 0001	110 0000 0000 0000 0000 0000	$(-7)_D$
---	-----------	------------------------------	----------

3. Addition der Mantissen

	1	,	0	0	0	1	0
-	0	,	0	0	1	1	1
Ü	1		1	1	1	1	
	0	,	1	1	0	1	1

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000	$(34)_D$
---	-----------	------------------------------	----------

1	1000 0001	110 0000 0000 0000 0000 0000	$(-7)_D$
---	-----------	------------------------------	----------

4. Normalisierung

Das Ergebnis muss in der Form 1, xxx... vorliegen.

In unserem Fall trifft das nicht zu, deshalb:

$$0, 11011 * 2^5 = 1, 1011 * 2^4$$

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000
---	-----------	------------------------------

 $(34)_D$

1	1000 0001	110 0000 0000 0000 0000 0000
---	-----------	------------------------------

 $(-7)_D$ **5. Rundung**

Es muss gerundet werden, wenn Summe der Mantissen 23-Bit-Bereich verlässt.

In unserem Fall passiert das nicht.

Beispiel $34 + (-7)$ **Addition von 34 und -7 in IEEE 754**

0	1000 0100	000 1000 0000 0000 0000 0000
---	-----------	------------------------------

 $(34)_D$

1	1000 0001	110 0000 0000 0000 0000 0000
---	-----------	------------------------------

 $(-7)_D$ **6. Zusammensetzen**

0	1000 0011	101 1000 0000 0000 0000 0000
---	-----------	------------------------------

 $(27)_D$

Code

```
138 // a) Extraktion von Vorzeichen und Exponenten
139 sign_a = a & SIGN_MASK;
140 sign_b = b & SIGN_MASK;
141 exp_a = (a & EXP_MASK) >> 23;
142 exp_b = (b & EXP_MASK) >> 23;
143 mant_a = ((a & MANT_MASK) | HIDDEN_BIT) << 3;
144 mant_b = ((b & MANT_MASK) | HIDDEN_BIT) << 3;
```

Code

138

// a) Extraktion von Vorzeichen und Exponenten

139

sign_a = a & SIGN_MASK;

140

sign_b = b & SIGN_MASK;

141

exp_a = (a & EXP_MASK) >> 23;

142


exp_b = (b & EXP_MASK) >> 23;

143

mant_a = ((a & MANT_MASK) | HIDDEN_BIT) << 3;

144

mant_b = ((b & MANT_MASK) | HIDDEN_BIT) << 3;



Code

```
138 // a) Extraktion von Vorzeichen und Exponenten
139 sign_a = a & SIGN_MASK;
140 sign_b = b & SIGN_MASK;
141 exp_a = (a & EXP_MASK) >> 23;
142 exp_b = (b & EXP_MASK) >> 23;
143 mant_a = ((a & MANT_MASK) | HIDDEN_BIT) << 3;
144 mant_b = ((b & MANT_MASK) | HIDDEN_BIT) << 3;
```

a 0 1 0 0 0 0 1 0 0 0 0 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 ;

b 1 1 0 0 0 0 0 0 1 1 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

Durchlauf beispielhaft für a

a	0	1	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
SIGN_MASK	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
&	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

```
138 // a) Extraktion von Vorzeichen und Exponenten
139 sign_a = a & SIGN_MASK;
140 sign_b = b & SIGN_MASK;
141 exp_a = (a & EXP_MASK) >> 23;
142 exp_b = (b & EXP_MASK) >> 23;
143 mant_a = ((a & MANT_MASK) | HIDDEN_BIT) << 3;
144 mant_b = ((b & MANT_MASK) | HIDDEN_BIT) << 3;
```

Durchlauf beispielhaft für a

Einführung in die Programmierung

Code

```
138 // a) Extraktion von Vorzeichen und Exponenten
```

```
139     sign_a = a & SIGN_MASK;
```

```
140     sign_b = b & SIGN_MASK;
```

```
141 exp_a = (a & EXP_MASK) >> 23;
```

```
142     exp_b = (b & EXP_MASK) >> 23;
```

```
143 mant_a = ((a & MANT_MASK) | HIDDEN_BIT) << 3;
```

```
144 mant_b = ((b & MANT_MASK) | HIDDEN_BIT) << 3;
```

[illegible][illegible]

Durchlauf beispielhaft für a

&

0	1	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

>> 23

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

>> 23

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---


```
138 // a) Extraktion von Vorzeichen und Exponenten
139 sign_a = a & SIGN_MASK;
140 sign_b = b & SIGN_MASK;
141 exp_a = (a & EXP_MASK) >> 23;
142 exp_b = (b & EXP_MASK) >> 23;
143 mant_a = ((a & MANT_MASK) | HIDDEN_BIT) << 3;
144 mant_b = ((b & MANT_MASK) | HIDDEN_BIT) << 3;
```

Durchlauf beispielhaft für a

<< 3

Code

```
146 // Sortieren: A soll der Betragsgrossere sein
147 if (exp_b > exp_a || (exp_b == exp_a && mant_b > mant_a)) {
148     uint32_t ts = sign_a; sign_a = sign_b; sign_b = ts;
149     int32_t te = exp_a; exp_a = exp_b; exp_b = te;
150     uint64_t tm = mant_a; mant_a = mant_b; mant_b = tm;
151 }
```

Der Code tauscht die Operanden a und b, falls $|B| > |A|$, um sicherzustellen, dass a stets der betragsmäßig Größere ist.

Warum ist das wichtig?

Indem wir sicherstellen, dass wir immer "Große Zahl minus Kleine Zahl" rechnen, sparen wir uns komplizierte Fallunterscheidungen für negative Zwischenergebnisse und wechselnde Vorzeichen.

Code

```
153 // b) Angleichen
154 int shift = exp_a - exp_b;
155 if (shift > 60) {
156     mant_b = 0; // Zu klein
157 } else if (shift > 0) {
158     remainder = mant_b & ((1ULL << shift) - 1);
159     mant_b >>= shift;
160     if (remainder != 0) mant_b |= 1; // Sticky bit setzen
161 }
162 res_exp = exp_a;
163 res_sign = sign_a;
```

Code

```

153 // b) Angleichen
154 int shift = exp_a - exp_b;
155 if (shift > 60) {
156     mant_b = 0; // Zu klein
157 } else if (shift > 0) {
158     remainder = mant_b & ((1ULL << shift) - 1);
159     mant_b >>= shift;
160     if (remainder != 0) mant_b |= 1; // Sticky bit setzen
161 }
162 res_exp = exp_a;
163 res_sign = sign_a;

```

exp_a

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

exp_b

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

-

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Berechnet Abstand zwischen Exponenten der beiden Zahlen.

Code

```
153 // b) Angleichen
154 int shift = exp_a - exp_b;
155 if (shift > 60) {
156     mant_b = 0; // Zu klein
157 } else if (shift > 0) {
158     remainder = mant_b & ((1ULL << shift) - 1);
159     mant_b >>= shift;
160     if (remainder != 0) mant_b |= 1; // Sticky bit setzen
161 }
162 res_exp = exp_a;
163 res_sign = sign_a;
```

Wenn der Unterschied zwischen den Exponenten extrem groß ist, ist die Zahl B so winzig im Vergleich zu A, dass sie nach dem Verschieben komplett verschwindet.

Statt die Bits zu schieben wird Rechenzeit gespart, indem $\text{mant}_b = 0$.

Code

```
153 // b) Angleichen
154 int shift = exp_a - exp_b;
155 if (shift > 60) {
156     mant_b = 0; // Zu klein
157 } else if (shift > 0) {
158     remainder = mant_b & ((1ULL << shift) - 1);
159     mant_b >>= shift;
160     if (remainder != 0) mant_b |= 1; // Sticky bit setzen
161 }
162 res_exp = exp_a;
163 res_sign = sign_a;
```

shift

[illegible]

Code

```

153 // b) Angleichen
154 int shift = exp_a - exp_b;
155 if (shift > 60) {
156     mant_b = 0; // Zu klein
157 } else if (shift > 0) {
158     remainder = mant_b & ((1ULL << shift) - 1);
159     mant_b >>= shift;
160     if (remainder != 0) mant_b |= 1; // Sticky bit setzen
161 }
162 res_exp = exp_a;
163 res_sign = sign_a;

```

<< shift

1

-

Isoliert Bits, die beim folgenden Rechts-Shift verloren gehen würden.

Code

```
153 // b) Angleichen
154 int shift = exp_a - exp_b;
155 if (shift > 60) {
156     mant_b = 0; // Zu klein
157 } else if (shift > 0) {
158     remainder = mant_b & ((1ULL << shift) - 1);
159     mant_b >>= shift;
160     if (remainder != 0) mant_b |= 1; // Sticky bit setzen
161 }
162 res_exp = exp_a;
163 res_sign = sign_a;
```

Das vorläufige Ergebnis bekommt Vorzeichen und Exponent des betragsmäßig größeren Operanden A.

Code

```
166     if (sign_a == sign_b) {
167         // c) Addition durchfuehren
168         res_mant = mant_a + mant_b;
169         // Ueberlauf addieren? (Bit 27 gesetzt, da wir um 3 erweitert haben 23+1+3 = 27)
170         if (res_mant & (1ULL << 27)) {
171             // Sticky Bit bewahren beim Rechts-Shift
172             if (res_mant & 1) res_mant |= 2; // Sticky weitergeben
173             res_mant >>= 1;
174             res_exp++;
175         }
176         ...
```

Der if-Block implementiert die Addition der Mantissen bei identischen Vorzeichen der Operanden.

Falls durch die Addition ein Überlauf in Bit 27 entsteht, wird die Mantisse erneut normalisiert und der Exponent inkrementiert.

Code

```

166     if (sign_a == sign_b) {
167         // c) Addition durchfuehren
168         res_mant = mant_a + mant_b;
169         // Ueberlauf addieren? (Bit 27 gesetzt, da wir um 3 erweitert haben 23+1+3 = 27)
170         if (res_mant & (1ULL << 27)) {
171             // Sticky Bit bewahren beim Rechts-Shift
172             if (res_mant & 1) res_mant |= 2; // Sticky weitergeben
173             res_mant >>= 1;
174             res_exp++;
175         }
176         ...

```

sign_a

[illegible]

sign_b

[illegible]

Code

```
176     } else {  
177         // d) Subtraktion (mant_a >= mant_b garantiert durch Sortierung)  
178         res_mant = mant_a - mant_b;  
179         if (res_mant == 0) return 0;  
180     ...
```


Code

```
176     } else {  
177         // d) Subtraktion (mant_a >= mant_b garantiert durch Sortierung)  
178         res_mant = mant_a - mant_b;  
179         if (res_mant == 0) return 0;  
180         ...
```

Falls das Ergebnis der Subtraktion exakt 0 ist, beenden wir die Funktion sofort und geben 0 zurück, da keine Normalisierung oder Rundung mehr nötig ist.


Code

```
181      // e) Normalisieren (Links Shift bis Bit 26 gesetzt ist)
182      while (!(res_mant & (1ULL << 26))) {
183          res_mant <<= 1;
184          res_exp--;
185          if (res_exp <= 0) return 0; // Underflow
186      }
187  }
```

Solange an der höchsten Position (Bit 26, unser "Start-Bit") noch eine 0 steht, ist die Zahl zu weit rechts.

Wir müssen sie also so lange nach links schieben, bis die erste 1 vorne anstößt. Erst dann ist sie gültig normalisiert.


```
Code
181      // e) Normalisieren (Links Shift bis Bit 26 gesetzt ist)
182      while (!(res_mant & (1ULL << 26))) {
183          res_mant <<= 1;
184          res_exp--;
185          if (res_exp <= 0) return 0; // Underflow
186      }
187  }
```



Code

```
181      // e) Normalisieren (Links Shift bis Bit 26 gesetzt ist)
182      while (!(res_mant & (1ULL << 26))) {
183          res_mant <<= 1;
184          res_exp--;
185          if (res_exp <= 0) return 0; // Underflow
186      }
187  }
```

Arithmetischen Unterlauf (Underflow) abfangen, indem das Ergebnis auf Null setzt, sobald der Exponent durch die für die Normalisierung erforderliche Verringerung den zulässigen Wertebereich unterschreitet.

Code

```
189      // Die Mantisse ist aktuell um 3 Bits nach links verschoben.
190      // Bit 2: Guard, Bit 1: Round, Bit 0: Sticky.
191      round_bits = res_mant & 7; // Die unteren 3 Bits
192      res_mant >>= 3; // Zurück auf normale Position
193
194      if (round_bits > 4) { // > 100 (binaer) -> Aufrunden
195          res_mant++;
196      } else if (round_bits == 4) { // == 100 (binaer) -> Tie to even
197          if (res_mant & 1) res_mant++;
198      }
```

Entscheidet anhand der abgeschnittenen Nachkommastellen, ob die Mantisse aufgerundet werden muss, wobei exakt halbe Werte zur nächsten geraden Zahl gerundet werden.

Hier: Aufgerundet (Mantisse + 1), da der Rest größer als 0,5 ist.

Code

```
189      // Die Mantisse ist aktuell um 3 Bits nach links verschoben.
190      // Bit 2: Guard, Bit 1: Round, Bit 0: Sticky.
191      round_bits = res_mant & 7; // Die unteren 3 Bits
192      res_mant >>= 3; // Zurück auf normale Position
193
194      if (round_bits > 4) { // > 100 (binaer) -> Aufrunden
195          res_mant++;
196      } else if (round_bits == 4) { // == 100 (binaer) -> Tie to even
197          if (res_mant & 1) res_mant++;
198      }
```

Entscheidet anhand der abgeschnittenen Nachkommastellen, ob die Mantisse aufgerundet werden muss, wobei exakt halbe Werte zur nächsten geraden Zahl gerundet werden.

Hier: Aufgerundet, wenn die Mantisse aktuell ungerade ist.

- *Endet die Mantisse auf ...0: Zahl ist gerade.*
- *Endet die Mantisse auf ...1: Zahl ist ungerade.*

Implementieren Sie in `kahan.c` die aufsteigende, absteigende und Kahan-Summation, um numerische Stabilität zu demonstrieren.

Analysieren Sie anschließend in `task2.txt` die auftretenden Rundungsfehler bei wachsendem N sowie das historische Patriot-Raketen-Beispiel.

Code

```
19     static double sum_ascending(double* a, size_t N) {  
20         double s = 0.0;  
21         for (size_t i = 0; i < N; i++) s += a[i];  
22         return s;  
23     }
```

Code

```
19 static double sum_ascending(double* a, size_t N) {  
20     double s = 0.0;  
21     for (size_t i = 0; i < N; i++) s += a[i];  
22     return s;  
23 }
```

a

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

s

0.0

Iteration i = 0

s

0.0

 +

1.0 ⁰

 =

1.0

Code

```

19 static double sum_ascending(double* a, size_t N) {
20     double s = 0.0;
21     for (size_t i = 0; i < N; i++) s += a[i];
22     return s;
23 }

```

a

1.0^0	0.000000000000000015^1	0.000000000000000015^2
---------	--------------------------	--------------------------

 s

1.0

Iteration $i = 1$

s

1.0

 +

0.000000000000000015^1

 =

1.0

Beim Angleichen der Exponenten werden die signifikanten Bits der kleineren Zahl rechts aus der Mantisse hinausgeschoben.

Code

```

19 static double sum_ascending(double* a, size_t N) {
20     double s = 0.0;
21     for (size_t i = 0; i < N; i++) s += a[i];
22     return s;
23 }

```

a

1.0^0	0.000000000000000015^1	0.000000000000000015^2
---------	--------------------------	--------------------------

s

1.0

Iteration $i = 2$

s

1.0

 $+$

0.000000000000000015^2

 $=$

1.0

Beim Angleichen der Exponenten werden die signifikanten Bits der kleineren Zahl rechts aus der Mantisse hinausgeschoben.

Code

```
25     static double sum_descending(double* a, size_t N) {  
26         double s = 0.0;  
27         for (size_t i = N; i-- > 0; ) s += a[i];  
28         return s;  
29     }
```

Code

```

25     static double sum_descending(double* a, size_t N) {
26         double s = 0.0;
27         for (size_t i = N; i-- > 0; ) s += a[i];
28         return s;
29     }

```

a

1.0^0	0.000000000000000015^1	0.000000000000000015^2
---------	--------------------------	--------------------------

s

0.0

Iteration $i = 2$

s

0.0

 $+$

0.000000000000000015^2

 $=$

0.000000000000000015

Code

```

25 static double sum_descending(double* a, size_t N) {
26     double s = 0.0;
27     for (size_t i = N; i-- > 0; ) s += a[i];
28     return s;
29 }

```

a

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

s

0.000000000000000015

Iteration i = 1

s

0.000000000000000015

 +

0.000000000000000015 ¹

 =

0.000000000000000030

*Beide Zahlen haben denselben Exponenten.
Es muss nichts geschoben werden.*

Code

```

25 static double sum_descending(double* a, size_t N) {
26     double s = 0.0;
27     for (size_t i = N; i-- > 0; ) s += a[i];
28     return s;
29 }

```

a

1.0^0	0.000000000000000015^1	0.000000000000000015^2
---------	--------------------------	--------------------------

s

0.000000000000000030

Iteration $i = 0$

s

0.000000000000000030

 $+$

1.0^0

 $=$

1.000000000000000030

Beim Angleichen der Exponenten fallen die letzten Bits dieses Mal nicht raus!

Code

```
31     static double kahan(double* X, size_t N) {  
32         double S = 0.0, E = 0.0, Y = 0.0, Z = 0.0;  
33         size_t i;  
34         for (i = 0; i < N; i++) {  
35             Y = X[i] - E;  
36             Z = S + Y;  
37             E = (Z - S) - Y;  
38             S = Z;  
39         }  
40         return S;  
41     }
```

Code

```
31 static double kahan(double* X, size_t N) {  
32     double S = 0.0, E = 0.0, Y = 0.0, Z = 0.0;  
33     size_t i;  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }  
40     return S;  
41 }
```

X	1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
---	------------------	-----------------------------------	-----------------------------------

S	0.0	E	0.0	Y	0.0	Z	0.0
	SUMME		AKTUELLER SUMMAND		KORRIGIERTER SUMMAND		NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

0.0

 SUMME

E

0.0

 AKTUELLER SUMMAND

Y

1.0

 KORRIGIERTER SUMMAND

Z

0.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

0.0

 SUMME

E

0.0

 AKTUELLER SUMMAND

Y

1.0

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

0.0

 SUMME

E

0.0

 AKTUELLER SUMMAND

Y

1.0

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

1.0

 SUMME

E

0.0

 AKTUELLER SUMMAND

Y

1.0

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

1.0

 SUMME

E

0.0

 AKTUELLER SUMMAND

Y

1.0

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

1.0

 SUMME

E

0.0

 AKTUELLER SUMMAND

Y

0.000000000000000015

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

1.0

 SUMME

E

0.0

 AKTUELLER SUMMAND

Y

0.000000000000000015

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

1.0

 SUMME

E

-0.000000000000000015

 AKTUELLER SUMMAND

Y

0.000000000000000015

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

1.0

 SUMME

E

-0.000000000000000015

 AKTUELLER SUMMAND

Y

0.000000000000000015

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

1.0

 SUMME

E

-0.000000000000000015

 AKTUELLER SUMMAND

Y

0.000000000000000015

 KORRIGIERTER SUMMAND

Z

1.0

 NEUE SUMME

Code

```

31  static double kahan(double* X, size_t N) {
    ...
34      for (i = 0; i < N; i++) {
35          Y = X[i] - E;
36          Z = S + Y;
37          E = (Z - S) - Y;
38          S = Z;
39      }

```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S

 SUMME
 E

 AKTUELLER SUMMAND
 Y

 KORRIGIERTER SUMMAND
 Z


 NEUE SUMME

Code

```


31  static double kahan(double* X, size_t N) {
    ...
34      for (i = 0; i < N; i++) {
35          Y = X[i] - E;
36          Z = S + Y;
37          E = (Z - S) - Y;
38          S = Z;
39      }

```




Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```



Code

```
31 static double kahan(double* X, size_t N) {  
    ...  
34     for (i = 0; i < N; i++) {  
35         Y = X[i] - E;  
36         Z = S + Y;  
37         E = (Z - S) - Y;  
38         S = Z;  
39     }
```



Code

```

31 static double kahan(double* X, size_t N) {
32     double S = 0.0, E = 0.0, Y = 0.0, Z = 0.0;
33     size_t i;
34     for (i = 0; i < N; i++) {
35         Y = X[i] - E;
36         Z = S + Y;
37         E = (Z - S) - Y;
38         S = Z;
39     }
40     return S;
41 }

```

X

1.0 ⁰	0.000000000000000015 ¹	0.000000000000000015 ²
------------------	-----------------------------------	-----------------------------------

S	E	Y	Z
1.000000000000000003	0.0	0.000000000000000030	1.000000000000000003
SUMME	AKTUELLER SUMMAND	KORRIGIERTER SUMMAND	NEUE SUMME

	Testen für unterschiedliche N
Aufsteigende Summe	Sobald die Summe groß ist, werden nachfolgende kleine Summanden wirkungslos (zu klein für die Mantisse) und komplett ignoriert.
Absteigende Summe	Kleine Zahlen werden zuerst addiert und bilden eine relevante Größe, bevor sie zur Gesamtsumme hinzugefügt werden.

	Testen für unterschiedliche N
Kahan-Summe	Rundungsfehler werden in einer Hilfsvariable (E) gespeichert und im nächsten Schritt korrigiert, wodurch der Informationsverlust verhindert wird.

Der Faktor 0,1 ist im Binärsystem eine periodische Zahl und kann daher nicht exakt gespeichert werden.

Durch das Abschneiden der Bits entstand ein winziger Rundungsfehler, der sich über die Betriebsdauer auf ca. 0,34 Sekunden aufsummierte.

Aufgrund der hohen Geschwindigkeit der Scud-Rakete entsprach diese Zeitabweichung einer Fehlpositionierung von über 500 Metern, wodurch das Ziel außerhalb des Erfassungsbereichs (range gate) lag.



Implementieren Sie die Funktionen `ieee32_to_ll` und `ll_to_ieee32` in `fpu.c`, um die bidirektionale Konvertierung zwischen IEEE-754-Bitmustern und `long long`-Ganzzahlen durchzuführen.

Nutzen Sie hierfür ausschließlich Bit-Operationen und Ganzzahl-Arithmetik, ohne auf native Fließkomma-Datentypen zurückzugreifen.

Code

```
277 // a) Zerlegung der Eingabe
278 exp = (int32_t)((u & EXP_MASK) >> 23) - EXP_BIAS;
279 mant = (u & MANT_MASK) | HIDDEN_BIT;
280 sign = u & SIGN_MASK;
```

Vom Prinzip her dasselbe wie bei den Aufgaben vorhin!

Code

```
288 // b) Mantisse ist  $1.M * 2^{\text{exp}}$ . Bitmuster in 'mant' entspricht dem Wert *  $2^{23}$ .
289 if (exp > 23) {
290     res <<= (exp - 23);
291 } else {
292     res >>= (23 - exp);
293 }
```


Code

```
308 // a) Vorzeichen behandeln und Betrag bilden
309 if (i < 0) {
310     sign = SIGN_MASK;
311     uval = 0ULL - (unsigned long long)i;
312 } else {
313     uval = (unsigned long long)i;
314 }
```


Code

```
316 // b) Höchstes gesetztes Bit finden (MSB)
317 for (int k = 63; k >= 0; k--) {
318     if (uval & (1ULL << k)) {
319         msb = k;
320         break;
321     }
322 } exp = msb + EXP_BIAS;
```

Code

```
316 // b) Höchstes gesetztes Bit finden (MSB)
317 for (int k = 63; k >= 0; k--) {
318     if (uval & (1ULL << k)) {
319         msb = k;
320         break;
321     }
322 } exp = msb + EXP_BIAS;
```

i (33 554 435)_D / (10000000000000000000000000000000011)_B ; k 63

Da Integer keine expliziten Exponenten haben, sucht der Code in einer Schleife von Bit 63 rückwärts bis 0 nach dem ersten Bit, das eine 1 ist (das sogenannte "Most Significant Bit" oder MSB).

Code

```
324 // c) Mantisse extrahieren
325 if (msb <= 23) {
326     // Wenn Wert in 23 Bits passt: Links shiften, bis MSB auf Hidden-Bit Position liegt
327     mant = (uint32_t)((uval << (23 - msb)) & MANT_MASK);
328 } else {
329     // Wenn Wert größer ist: Rechts shiften und Runden
330     shift = msb - 23;
331     remainder = uval & ((1ULL << shift) - 1);
332     half = 1ULL << (shift - 1);
333
334     mant = (uint32_t)(uval >> shift);
335
336     ...
```

Bitmuster der vorzeichenlosen Ganzzahl (uval) so verschoben, dass ihr höchstes Bit genau auf der Position 23 landet, wobei im Fall einer Rechtsverschiebung (bei großen Zahlen) zusätzlich korrekt gerundet und ein eventueller Überlauf durch Neu Anpassung des Exponenten behandelt wird.

Code

```
336      // Round to nearest, ties to even
337      if (remainder > half || (remainder == half && (mant & 1))) {
338          mant++;
339          // Check auf Mantissen-Überlauf durch Rundung
340          if (mant & (1u << 23)) {
341              mant = 0;
342              exp++;
343          }
344      }
345      mant &= MANT_MASK;
346  }
```

*Wird geprüft, ob gemäß der Regel aufgerundet werden muss.
Falls das Aufrunden dazu führt, dass die Mantisse überläuft, wird der Exponent erhöht und die Mantisse entsprechend korrigiert.*

Vorzeichen	Charakteristik	Mantisse	Bedeutung	Mathematische Darstellung
0	000...000	M	Fließkommazahl ohne 1	$(0.M)_2 \cdot 2^{-127+1}$
1	000...000	M	Fließkommazahl ohne 1	$-(0.M)_2 \cdot 2^{-127+1}$
0	$0 < E < 2^{c-1} - 1$	M	Fließkommazahl	$(1.M)_2 \cdot 2^{C-127}$
1	$0 < E < 2^{c-1} - 1$	M	Fließkommazahl	$-(1.M)_2 \cdot 2^{C-127}$
0	?		Unendlich (positiv)	inf bzw. ∞
1			Unendlich (negativ)	-inf bzw. $-\infty$
0	111...111	$M \neq 0$	Keine (rationale) Zahl	N. a. N. z.B.: $\sqrt[2]{-1} \cdot (1.M)$
1	111...111	$M \neq 0$	Keine (rationale) Zahl	N. a. N. z.B.: $\sqrt[2]{-1} \cdot (1.M)$

v_z

7

C

0

M

0

31

30

23

22

Vorzeichen	Charakteristik	Mantisse	Bedeutung	Mathematische Darstellung
0	000 ... 000	M	Fließkommazahl ohne 1	$(0.M)_2 \cdot 2^{-127+1}$
1	000 ... 000	M	Fließkommazahl ohne 1	$-(0.M)_2 \cdot 2^{-127+1}$
0	$0 < E < 2^{c-1} - 1$	M	Fließkommazahl	$(1.M)_2 \cdot 2^{C-127}$
1	$0 < E < 2^{c-1} - 1$	M	Fließkommazahl	$-(1.M)_2 \cdot 2^{C-127}$
0	111 ... 111	000 ... 000	Unendlich (positiv)	inf bzw. ∞
1	111 ... 111	000 ... 000	Unendlich (negativ)	-inf bzw. $-\infty$
0	111 ... 111	$M \neq 0$	Keine (rationale) Zahl	N. a. N. z.B.: $\sqrt[2]{-1} \cdot (1.M)$
1	111 ... 111	$M \neq 0$	Keine (rationale) Zahl	N. a. N. z.B.: $\sqrt[2]{-1} \cdot (1.M)$

v_z

7

C

0

M

31 30

23 22

0


```
#define P2DIGIT(strptr) (*strptr - '0')

static uint32_t str_to_ieee32(char* str) {
    uint32_t res = 0;
    char* ptr = str;
    bool has_digits = false, negative = false;
    long long int frac_part = 0, frac_divisor = 1, int_part = 0;

    if (!str || !*str) return 0x7FC00000; // NaN

    while (*ptr == ' ') { ptr++; }

    if (strstr(ptr, "NaN") == ptr || strstr(ptr, "nan") == ptr) { return 0x7FC00000; }
    if (strstr(ptr, "Inf") == ptr || strstr(ptr, "inf") == ptr) { return 0x7F800000; }
    if (strstr(ptr, "-Inf") == ptr || strstr(ptr, "-inf") == ptr) { return 0xFF800000; }

    if (*ptr == '-') { negative = true; ptr++; } else if (*ptr == '+') { ptr++; }

    // ...
}
```

```
while (*ptr >= '0' && *ptr <= '9') {  
    int_part = int_part * 10 + P2DIGIT(ptr);  
    ptr++;  
    has_digits = true;  
}
```



```
if (*ptr == '.') {  
    ptr++;  
    while (*ptr >= '0' && *ptr <= '9') {  
        frac_part = frac_part * 10 + P2DIGIT(ptr);  
        frac_divisor *= 10;  
        ptr++;  
        has_digits = true;  
    }  
}
```

```
static uint32_t str_to_ieee32(char* str) {  
    // ...  
    if (!has_digits) { return 0x7FC00000; } // Invalid input  
  
    uint32_t u_int = ll_to_ieee32(int_part);  
    uint32_t u_frac = ll_to_ieee32(frac_part);  
    uint32_t u_div = ll_to_ieee32(frac_divisor);  
    uint32_t u_inv = ieee32_inv_u(u_div);  
    uint32_t u_frac_scaled = ieee32_mul_u(u_frac, u_inv);  
  
    res = ieee32_add_u(u_int, u_frac_scaled);  
  
    if (negative) { res = res | SIGN_MASK; }  
    else res &= ~SIGN_MASK;  
  
    return res;  
}
```