


Einführung in die Programmierung

Tutorium 6




Wintersemester 2025/2026

Arbeitsgruppe Systemsoftware
Angewandte Informatik 12

Naive Darstellung rationaler Zahlen im Rechner:


- Zähler $q = \sum Q_i \cdot 2^i$ und Nenner $p = \sum P_i \cdot 2^i$ werden hintereinander als gleichgroße Datenworte $D = Q_0 \cdots Q_{n-1} P_0 \cdots P_{n-1}$ abgelegt
- Vor dem Ablegen sind Nenner und Zähler mithilfe ihres größten gemeinsamen Teilers (ggT) zu kürzen
- **Problem:** Rechnen in diesem Zahlensystem ist aufwendig und kann schnell zu Überläufen im Zähler oder Nenner führen



Darstellung von Zahlen im Festkommaformat (Naiv):

- Rationale Zahlen können wie gewohnt im Binärsystem mit zusätzlichem Nachkommateil dargestellt werden
- Wertigkeit des i -ten Bit im Vor- und Nachkommateil ergibt sich mit 2^{i-k}

$$\begin{aligned}
 z &= (-1)^{v_z} \cdot (V_{n-2} \cdots V_k \cdot N_{k-1} \cdots N_0)_2 \equiv (-1)^{v_z} \cdot 2^{-k} \cdot (V_{n-2} \cdots V_k N_{k-1} \cdots N_0)_2 \\
 &= (-1)^{Z_{n-1}} \cdot 2^{-k} \cdot (Z_{n-2} Z_{n-3} \cdots Z_1 Z_0)_2 = (-1)^{Z_{n-1}} \frac{1}{2^k} \sum_{i=0}^{n-2} Z_i 2^i
 \end{aligned}$$



Darstellung von Zahlen im Festkommaformat (Zweierkomplement):


- Festkommazahlen werden in realen Systemen üblicherweise im Zweierkomplement mit zusätzlichem Nachkommateil dargestellt
- Man rechnet mit ihnen genau wie mit ganzen Zweierkomplement-Zahlen

$$\begin{aligned} Z &= (V_{n-2} \cdots V_k \cdot N_{k-1} \cdots N_0)_2 - v_Z 2^{n-1} \equiv 2^{-k} \cdot [(V_{n-2} \cdots V_k N_{k-1} \cdots N_0)_2 - v_Z 2^{n-1}] \\ &= 2^{-k} \cdot [(Z_{n-2} Z_{n-3} \cdots Z_1 Z_0)_2 - Z_{n-1} 2^{n-1}] = \frac{1}{2^k} \sum_{i=0}^{n-1} (-1)^{\delta_{i,n-1}} Z_i 2^i \end{aligned}$$

Kronecker- δ
 (1 if $i = i$)

Kronecker- δ

$$\delta_{i,j} \equiv \begin{cases} 1 & \text{if } i = j \\ 0 & \text{else.} \end{cases}$$




- Fließkommazahlen (Gleitkommazahlen, engl. Floating-point numbers) stellen rationale Zahlen durch die folgenden Bestandteile dar:
 - Mantisse M als normalisierte Binärzahl in gepackter, dh. impliziter Darstellung
 - Kommaposition als Charakteristik C in Exzess-Darstellung (Exponent E mit Bias k)
 - Vorzeichenbit v_z
- Bezeichnung für Fließkommaformate: $S m E c$


$$z = (-1)^{v_z} \cdot 2^{\overbrace{C-k}^E} \cdot (1 \cdot M)_2 = (-1)^{z_{n-1}} \cdot 2^{\sum_{j=m}^{n-2} [z_j 2^j] - (2^{\overbrace{n-m-1-k}^c} - 1)} \cdot \underbrace{\frac{1}{2^m} \sum_{i=0}^{m-1} z_j 2^j}_M$$

Verstecktes Bit
(engl. Hidden bit)
↓





Äquidistante
Zerlegung



Zerlegung in
uneinheitliche
Abstände

- Die **IEEE-754-Norm** umfasst drei unterschiedliche Gleitkommaformate
 - **Single-Precision-Format** (S23E8) mit Vorzeichenbit: $n = 1 + 8 + 23 = 32$
 - **Double-Precision-Format** (S52E11) mit Vorzeichenbit: $n = 1 + 11 + 52 = 64$
 - **Extended-Precision-Format** (S64E15) mit Vorzeichenbit: $n = 1 + 15 + 64 = 80$
- Darüber hinaus bietet IEEE-754 Möglichkeiten, auch ± 0 und $\pm \infty$ darzustellen: Darstellung der Null, wenn $E = 0$ und $M = 0$ sind
- Die Norm IEEE-754 wurde 1985 durch das **Institute of Electrical and Electronics Engineers** festgelegt

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

v_z	10	C	0	M
63	62		52	51
				0

Vorzeichen	Charakteristik	Mantisse	Bedeutung	Mathematische Darstellung
0	000...000	M	Fließkommazahl ohne 1	$(0.M)_2 \cdot 2^{-16383+1}$
1	000...000	M	Fließkommazahl ohne 1	$-(0.M)_2 \cdot 2^{-16383+1}$
0	$0 < E < 2^{c-1} - 1$	M	Fließkommazahl	$(1.M)_2 \cdot 2^{C-16383}$
1	$0 < E < 2^{c-1} - 1$	M	Fließkommazahl	$-(1.M)_2 \cdot 2^{C-16383}$
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

14

C

0

M


79 78


64 63

0

Art der Daten	Schlüsselwort	Format	Speicherplatz	Platzhalter
Rationale Zahlen $\mathbb{Q}$	float	Single-Precision-Format S8E32	32 Bit $\hat{=}$ 8 Nibble $\hat{=}$ 4 Byte	%f
	double	Double-Precision-Format S11E52	64 Bit $\hat{=}$ 16 Nibble $\hat{=}$ 8 Byte	%lf
	long double	Extended-Precision-Format S15E64	80 Bit $\hat{=}$ 20 Nibble $\hat{=}$ 10 Byte	%Lf


- Fließkomma-Verarbeitungseinheit (engl. Floating-Point-Unit, kurz: FPU) ist auf Fließkommazahlenarithmetik spezialisierte Hardware
- Bereits 1980 nutzte die FPU 8087 von Intel® das S15E64-Format





Implementieren Sie die Funktion `extract_parts`, um eine gegebene 32-Bit-Zahl `u` in ihre Bestandteile zu zerlegen. Nutzen Sie dazu die definierten Masken (`SIGN_MASK`, `EXP_MASK`, `MANT_MASK`) und Shift-Operatoren:

- Isolieren Sie das Vorzeichenbit in die Variable `sign`.
- Extrahieren Sie die 8 Exp-Bits und schieben Sie diese an die niederwertigste Stelle (`exp`).
- Extrahieren Sie die 23 Mantissen-Bits (`mant`).



Code

```
40 static void print_float_parts(uint32_t u, const char *label, float as_decimal) {
41     uint32_t sign = 0, exp = 0, mant = 0;
42
43     // a)
44     sign = (u & SIGN_MASK) >> 31;
45     exp  = (u & EXP_MASK) >> 23;
46     mant = (u & MANT_MASK);
47
48     printf("%s = %g\n\r", label, (double)as_decimal);
49     printf("Sign bit of %s: %u\n\r", label, sign);
50     printf("Exponent of %s: ", label);
51     print_bits_uint(exp, EXP_BITS);
52     putchar('\n');
53     putchar('\r');
54     printf("Mantissa of %s: ", label);
55     print_bits_uint(mant, MANT_BITS);
56     putchar('\n');
57     putchar('\n');
58     putchar('\r');
59 }
```

Berechnen Sie das Vorzeichen per XOR sowie den Exponenten unter Berücksichtigung des Bias und multiplizieren Sie die Mantissen inklusive Hidden Bit. Normalisieren Sie das entstehende Produkt und führen Sie abschließend die Rundung „Round to Nearest, Ties to Even“ durch, wobei auch ein möglicher Überlauf nach dem Runden abgefangen werden muss.

$$\begin{aligned}
 x \cdot y &= (-1)^{v_{zx}} \cdot 2^{\overbrace{C_x - k}^{E_x}} \cdot (1 \cdot M_x)_2 \cdot (-1)^{v_{zy}} \cdot 2^{\overbrace{C_y - k}^{E_y}} \cdot (1 \cdot M_y)_2 \\
 &= (-1)^{v_{zx} \oplus v_{zy}} \cdot 2^{\overbrace{C_x - k}^{E_x} + \overbrace{C_y - k}^{E_y}} \cdot \text{norm}(1 \cdot M_x \cdot 1 \cdot M_y)_2 \\
 &= (-1)^{\overbrace{v_{zx} \oplus v_{zy}}^{v_{zxy}}} \cdot 2^{\overbrace{C_x + C_y - k - k}^{E_{xy}}} \cdot 2^\mu \cdot \frac{1}{2^{2m}} \overbrace{M_x \cdot M_y}^{M_{xy}}
 \end{aligned}$$

Code

```
61 static uint32_t ieee32_mul_u(uint32_t a, uint32_t b) {
62     int32_t res_exp = 0;
63     uint32_t res_sign = 0;
64     uint64_t prod = 0;
65
66     if (is_nan_u(a) || is_nan_u(b)) return 0x7FC00000;
67     if (is_zero_u(a) || is_zero_u(b)) {
68         if (is_inf_u(a) || is_inf_u(b)) return 0x7FC00000; // 0 * Inf
69         return (a ^ b) & SIGN_MASK;
70     }
71
72     if (is_inf_u(a) || is_inf_u(b)) return ((a ^ b) & SIGN_MASK) | EXP_MASK;
73
74     // a) Vorzeichen bestimmen
75     res_sign = (a ^ b) & SIGN_MASK;
76
77     // b) Exponenten addieren
78     res_exp = (int32_t)((a & EXP_MASK) >> 23) + (int32_t)((b & EXP_MASK) >> 23) - EXP_BIAS;
79
80     ...
```

Code

```
80      // c) Mantissen inkl. Hidden Bit holen
81      uint64_t mant_a = (a & MANT_MASK) | HIDDEN_BIT;
82      uint64_t mant_b = (b & MANT_MASK) | HIDDEN_BIT;
83
84      // d) 48 Bit Produkt berechnen
85      prod = mant_a * mant_b;
86
87      // e) Entscheiden, ob man um 23 oder 24 Bit shiftet
88      int shift;
89      if (prod & (1ULL << 47)) { // Ergebnis >= 2.0
90          shift = 24;
91          res_exp++;
92      } else {
93          shift = 23;
94      }
95      ...
```

Code

```
96      // f) Extrahieren der Bits, die weggeworfen würden (Rest)
97      uint64_t remainder = prod & ((1ULL << shift) - 1);
98      uint64_t half      = 1ULL << (shift - 1); // Das Bit genau bei 0.5
99
100     prod >>= shift; // Normalisieren
101
102     // Round to nearest, ties to even
103     if (remainder > half) {
104         prod++; // Aufrunden
105     } else if (remainder == half) {
106         if (prod & 1) prod++; // Bei genau 0.5 zur geraden Zahl runden
107     }
108     ...
```

Code

```
109      // g) Falls durch das Aufrunden ein Überlauf in der Mantisse passiert (z.B. alle 1er
        werden zu 100...)
110      if (prod & (1ULL << 24)) { // Sollte nach Shift max 23 Bits haben (Bit 24 wäre Hidden
        für nächste Stufe)
111          prod >>= 1;
112          res_exp++;
113      }
114
115      if (res_exp >= 255) return res_sign | EXP_MASK;
116      if (res_exp <= 0) return res_sign; // Underflow -> 0
117
118      return res_sign | (res_exp << 23) | (prod & MANT_MASK);
119  }
```

Implementieren Sie die Funktion `ieee32_inv_u`, um das Reziproke $1/x$ zu berechnen, indem Sie den neuen Exponenten über $253 - \text{exp}$ bestimmen und die neue Mantisse durch ganzzahlige Division von 2.0 durch die Eingangsmantisse ermitteln. Runden Sie das Ergebnis anschließend korrekt ("Round to Nearest, Ties to Even") und normalisieren Sie es bei Bedarf.

$$z^{-1} = \frac{1}{(-1)^{v_z} \cdot 2^{C-k} \cdot (1.M)_2} = (-1)^{v_z} \cdot 2^{\overbrace{(2k-C)-k}^{-E}} \cdot 2^m \cdot 1.0/M$$

Code

```
222 // a) Zerlegung der Eingabe
223 sign = x & SIGN_MASK;
224 exp  = (int32_t)((x & EXP_MASK) >> 23);
225 mant = (x & MANT_MASK) | HIDDEN_BIT;
226
227 // Sonderfälle (IEEE 754)
228 if (is_nan_u(x)) return 0x7FC00000; // NaN -> Quiet NaN
229 if (is_zero_u(x)) return sign | EXP_MASK; // +/- 0 -> +/- Inf
230 if (is_inf_u(x)) return sign; // +/- Inf -> +/- 0
231 ...
```

Code

```
232 // b) Berechnung des neuen Exponenten
233 // Formel:  $1 / (M * 2^E) = (1/M) * 2^{-E}$ .
234 // Wir berechnen  $(2/M) * 2^{(-E-1)}$  um im Bereich  $[1.0, 2.0)$  zu bleiben.
235 // Neuer Bias-Exp =  $127 + (- (exp - 127)) - 1 = 253 - exp$ .
236 res_sign = sign;
237 res_exp  = 253 - exp;
238 ...
```

Code

```
239 // c) Division der Mantisse (2.0 / M)
240 // Wir nutzen einen 64-Bit Zähler (1ULL << 47), der 2.0 repräsentiert.
241 // Division: (2^47) / mant. Ergebnis liegt um 2^24 (Bit 24 gesetzt wenn >= 2.0,
    sonst Bit 23).
242 numerator = 1ULL << 47;
243 res_mant = numerator / mant;
244 remainder = numerator % mant;
245 ...
```


Code

```
246 // d) Rundung (Round to Nearest, Ties to Even)
247 // Ist der Rest größer als der halbe Divisor? -> Aufrunden
248 // Ist der Rest genau halb und das aktuelle Ergebnis ungerade? -> Aufrunden
    (zur geraden Zahl)
249 if (remainder > (mant / 2)) {
250     res_mant++;
251 } else if ((remainder * 2 == mant) && (res_mant & 1)) {
252     res_mant++;
253 }
254 ...
```

Code

```
246 // e) Normalisierung nach Division
247 // Falls x exakt 1.0 (oder 2^k) war, ist 2.0/1.0 = 2.0.
248 // Dann ist Bit 24 gesetzt (1ULL << 24). Wir müssen durch 2 teilen und Exp erhöhen.
249 if (res_mant & (1ULL << 24)) {
250     res_mant >>= 1;
251     res_exp++;
252 }
253 ...
```

