

# Fließkommaarithmetik auf Z80-Rechnern

**Jens Müller, 18.04.2026**

korrigierte Version vom 22.04.2026

# Motivation

- Auf 8-Bit-Rechnern werden Fließkommaberechnungen meistens in einem BASIC-Interpreter ausgeführt und sind für viele Anwender eine undurchsichtige Black Box.
- Fließkommaberechnungen gelten als langsam.
- Implementierung einer 32-Bit-Fließkommaarithmetik im BASIC-Compiler von JKCEMU 0.9.9

# Abbildung binärer Kommazahlen

| Bit 2 | Bit 1 | Bit 0 | Komma | Bit -1   | Bit -2   | Bit -3   |
|-------|-------|-------|-------|----------|----------|----------|
| 4     | 2     | 1     |       | 0,5      | 0,25     | 0,125    |
| $2^2$ | $2^1$ | $2^0$ |       | $2^{-1}$ | $2^{-2}$ | $2^{-3}$ |

Beispiele:

3,25 dezimal

011,010 binär

0,125 dezimal

000,001 binär

# Approximierte Zahlen (1)

- Alle binären Kommazahlen, deren Nachkommaanteil nicht aus der Summe von Teilungen durch 2 gebildet werden kann, sind nicht exakt abbildbar (z.B. 0,1 0,3 0,7)
- Solche Dezimalzahlen werden mit Binärzahlen abgebildet, deren jeweiliger numerischer Wert nur angenähert der Dezimalzahl entspricht → Approximation
- **Dezimale Kommazahlen sind als Binärzahlen meistens nicht exakt numerisch abbildbar!**

# Approximierte Zahlen (2)

- Durch die Approximation entstehen Rundungsfehler, die mit jedem Rechenschritt größer werden!

Beispiel in BASIC:

```
10 A=0
20 FOR I=1 TO 1000
30 A=A+0.1
40 NEXT I
50 PRINT A
```

# Fließkommazahlen (1)

- Wenn das Komma fließend ist (nach links und rechts verschiebbar), lassen sich bei gleicher Genauigkeit sehr kleine und sehr große Zahlen abbilden.
- Abbildung mit Mantisse (Basiszahl) und Exponent (Position des Kommas)
- Größe der Mantisse bestimmt die Genauigkeit.
- Größe des Exponenten bestimmt den Wertebereich.

# Fließkommazahlen (2)

Mantisse und Exponent am Beispiel von Dezimalzahlen:

| Mantisse | Exponent | Wert                     |
|----------|----------|--------------------------|
| 12345    | 0        | $12345 * 10^0 = 12345$   |
| 123      | -4       | $123 * 10^{-4} = 0,0123$ |
| 9876     | 2        | $9876 * 10^2 = 987600$   |

# Fließkommazahlen auf Z80-Rechnern

- ZX81 BASIC, ZX Spectrum BASIC und Locomotive BASIC (Amstrad CPC und damit auch KC compact) arbeiten mit 40-Bit-Fließkommazahlen (4 Byte Mantisse, 1 Byte Exponent).
- Microsoft BASIC für i8080 von 1978 arbeitet mit 32-Bit-Fließkommazahlen (3 Byte Mantisse, 1 Byte Exponent).
- Die meisten der in der DDR verwendeten BASIC-Interpreter basieren auf Microsoft BASIC und arbeiten deshalb auch mit 32-Bit-Fließkommazahlen.

# 32-Bit-Fließkommazahlen

- 8 Bit Exponent → Wertebereich ca.  $\pm 10^{-38}$  bis  $\pm 10^{38}$
- 24 Bit Mantisse → Genauigkeit ca. 7,2 Dezimalstellen  
(0FFFFFFh = 16777215)
- Wegen Fehleranteil durch Approximationen wird bei der Ausgabe häufig auf 6 Dezimalstellen gerundet.
- 1 Bit Vorzeichen → **das sind zusammen 33 Bit!**  
→ siehe Normalisierung (später)

# Sonderfall Null

- Numerisch 0 muss oft separat betrachtet werden (z.B. bei Division)
- Deshalb Festlegung:  
Wert 0 = alle Bytes Null, bei 8-Bit-Rechner nur Test auf Exponent = 0
- Da Exponent = 0 für numerisch 0 steht, muss der „normale“ Exponent 0 anders abgebildet werden → Offset (Bias)
- Offset (bei 32 Bit) historisch meistens 80h, in IEEE 754 mit 7Fh festgelegt

# Normalisierung

- Exponent = 0  $\rightarrow$  Zahl hat Wert 0  
Exponent  $\neq$  0  $\rightarrow$  Zahl hat Wert ungleich 0
- Ist der Exponent  $\neq$  0, ist der Wert der ganzen Zahl  $\neq$  0 und damit ist auch die Mantisse  $\neq$  0 und muss mindestens ein 1-Bit haben. Das höchste gesetzte Bit wird ganz nach links geschoben (und der Exponent entsprechend verkleinert)  $\rightarrow$  Bei einer Nicht-Null-Zahl ist das oberste Bit der Mantisse immer gesetzt und braucht deshalb nicht gespeichert zu werden  $\rightarrow$  An dieser Stelle steht das Vorzeichen.

# IEEE 754

- Mit Aufkommen von mathematischen Co-Prozessoren Anfang der 80er Jahre (i8087 erschien 1980) wurde eine Standardisierung notwendig.
- IEEE 754 wurde 1985 verabschiedet und definiert verschiedene Fließkommaformate, u.a.
  - 32 Bit (einfache Genauigkeit, float, single)
  - 64 Bit (doppelte Genauigkeit, double)
- Das oberste Bit ist das Vorzeichen, danach kommt der Exponent  
→ auf 8-Bit-Rechnern so nicht performant abbildbar,  
da der Exponent um 1 Bit zur Byte-Grenze verschoben ist

# Addition und Subtraktion

- Exponenten beider Zahlen müssen gleich sein  
→ Operand mit kleinerem Exponent wird angepasst:  
Mantisse wird solange nach rechts geschoben und Exponent entsprechend erhöht, bis die Exponenten gleich sind
- Sind die Exponenten gleich, können die Mantissen einfach addiert bzw. subtrahiert werden.
- Bei einem Überlauf wird die Mantisse um ein Bit verschoben und der Exponent angepasst.
- Zum Schluss wird das Ergebnis normalisiert.

# Multiplikation und Division

- Exponenten werden addiert (Multiplikation) bzw. subtrahiert (Division).
- Mantissen werden multipliziert bzw. dividiert.
- Ergebnis wird wieder normalisiert.

# Quadratwurzel

- Quadratwurzel wird meistens mit dem iterativen Heron-Verfahren berechnet:  $x_{n+1} = (x_n + y_n) / 2$
- Startwert: Eingangswert mit halbiertem (um ein Bit nach rechts verschobenem) Exponenten
  - Startwert liegt damit schon in der Nähe des Ergebnisses.
  - für 32 Bit Genauigkeit damit nur 6 Iterationsschritte notwendig

# Sinus, Cosinus, Tangens, Arkustangens

- Sinus: Taylorreihe mit vorberechneten Koeffizienten:  
 $\sin(x) = x - x^3/3! + x^5/5! - x^7/7! + \dots$   
Koeffiziententabelle:  $-1/3!, +1/5!, -1/7!, +1/9!, -1/11!, \dots$
- Für 32 Bit Genauigkeit reichen 6 Iterationsschritte
- $\cos(x) = \sin(x + 90^\circ)$
- $\tan(x) = \sin(x) / \cos(x)$
- $\arctan(x) = x - x^3/3 + x^5/5 - x^7/7 + \dots$   
9 Iterationsschritte für 32 Bit Genauigkeit notwendig

# Natürlicher Logarithmus (1)

- Der Logarithmus wird mit einer Taylorreihe berechnet, die jedoch nur im Bereich 0,75 bis 1,0 schnell konvergiert.
- Zuerst wird x durch n-fache Teilung durch 2 oder n-fache Multiplikation mit 2 (bei Binärzahlen sehr schnell) in den Bereich 0.5 bis 1 gebracht und eine Differenz berechnet, die dann später zu addieren ist:

$$\ln(x * n / 2) = \ln(x) + (n * \ln(0.5))$$

$$\ln(x * n * 2) = \ln(x) + (n * \ln(2))$$

# Natürlicher Logarithmus (2)

- Bei  $x < 0.75$  wird  $x$  mit 1.5 multipliziert und o.g. Differenz um  $\ln(1.5)$  reduziert, da sonst die Taylorreihe zu langsam konvergiert.

- Berechnung mit folgender Reihe:

$$\begin{aligned}\ln(x) &= \ln\left(\frac{1+a}{1-a}\right) \\ &= 2a + \frac{2}{3}a^3 + \frac{2}{5}a^5 + \dots \\ &= 2 \cdot \left(a + \frac{a^3}{3} + \frac{a^5}{5} + \dots\right)\end{aligned}$$

- Alternativ kann auch folgende, allgemein bekannte Taylorreihe verwendet werden (konvergiert aber langsamer):

$$\ln(1+x) = x - \frac{x^2}{2} + \frac{x^3}{3} - \frac{x^4}{4} + \frac{x^5}{5} - \dots$$

# Exponentialfunktionen

- Die Exponentialfunktion  $e^x$  wird so zerlegt, dass die eigentliche Berechnung mit Hilfe der Taylorreihe mit einem Wert kleiner 1 erfolgen kann, da nur in diesem Bereich die Reihe ausreichend schnell konvergiert.

$$e^x = e^{(k \cdot \ln(2)) + r} = e^{k \cdot \ln(2)} * e^r = 2^k * e^r \quad (\text{Verschiebung von } e^r \text{ um } k \text{ Binärstellen})$$

$$x = k \cdot \ln(2) + r$$

$$r = x - (k \cdot \ln(2))$$

- Taylorreihe:  $e^x = 1 + x + x^2/2! + x^3/3! + \dots$  mit  $x = r$
- Power-Funktion:  $a^b = e^{b \cdot \ln(a)}$

# Cordic

- Cordic (Coordinate Rotation Digital Computer) ist ein effizienter Algorithmus, mit dem sich viele mathematische Funktionen implementieren lassen.
- 1959 in den USA für Navigationsrechner für Bomber entwickelt
- 1971 zur heute üblichen Form erweitert
- Arbeitet nur mit Addition, Subtraktion, Schiebebefehlen und einer Tabelle mit Arkustangens-Werten (für  $\sin$ ,  $\cos$ )  
→ Dadurch gut in Hardware implementierbar (Co-Prozessoren)
- Aufgrund Speicherplatzbedarf und vieler Iterationsschritte selten auf Z80-Rechnern implementiert

# Speicherplatzbedarf

- Die vier Grundrechenarten inklusive Ein- und Ausgabe (Umwandlung Dezimalzahl <> Binärzahl) lassen sich in weniger als 2 kByte Programmcode implementieren.
- Beispielprogramm im JKCEMU BASIC Compiler:

```
dim a as single, b as single
input "a=";a
input "b=";b
print "a+b=";a+b
print "a-b=";a-b
print "a*b=";a*b
print "a/b=";a/b
```

# Performance

- Performance von binären 32-Bit Fließkommaberechnungen auf Z80-Rechnern:
  - Addition/Subtraktion: ca. 400 bis 1000 Taktzyklen, abhängig davon, wie weit Exponenten auseinander liegen
  - Multiplikation/Division: ca. 3500 bis 4500 Taktzyklen
  - Quadratwurzel: ca. 20000-25000 Taktzyklen
  - Sinus: ca. 50000 Taktzyklen
  - Logarithmus und Exponential-Funktion: ca. 35000-70000 Taktzyklen

# Fließkommaarithmetik mit BCD

- BCD (Binary Coded Decimal) speichert die Zahlen im Dezimalsystem
  - keine Rundungsfehler
  - geeignet für Finanzberechnungen
- Performance von 6-Byte-BCD-Arithmetik auf Z80-Rechnern:  
Multiplikation/Division: ca. 40000 Taktzyklen
- BCD-Arithmetik ist wesentlich langsamer als binäre Fließkommaarithmetik.

# Zusammenfassung

- 32-Bit binäre Fließkommaarithmetik ist auf Z80-Rechnern ein guter Kompromiss aus:
  - Rechengenauigkeit (6 angezeigte Dezimalstellen)
  - Performance (nur wenig langsamer als 32-Bit-Integer-Berechnungen)
  - Implementierungsaufwand (weniger als 2 kByte für Grundrechenarten und Ein-/Ausgabe)
- Schlechte Performance im BASIC-Interpreter liegt mehr am Interpreter als an der binäre Fließkommaarithmetik

# Zum Schluss

Vielen Dank für die Aufmerksamkeit!

Gibt es Fragen?