

# Kapitel 07 - Darstellung von Informationen

Peter Ulbrich

AG Systemsoftware

Veranstaltungswebsite

# Einleitung

- **Bisher:**
  - Elementare Datentypen, wie z. B. `int`, `bool`, `char`, `float`
  - Bitoperationen und Byte-Order sind ebenfalls bekannt
- **Was noch fehlt:**
  - Interner Aufbau der Datentypen
    - Zweierkomplement
    - IEEE-754
  - Konvertierung zwischen den Datentypen

# Darstellung von Gleitkommazahlen

- Zur Erinnerung: Gleitkommazahlen im Standard IEEE 754 definiert
- In C Unterscheidung zwischen
  - einfacher Genauigkeit (32 Bit → `float`) und
  - doppelter Genauigkeit (64 Bit → `double`)
- Außerdem noch (nur für den Spezialfall der Gleitkommazahlen)
  - Halbe Genauigkeit (16 Bit)
  - Vierfache Genauigkeit (128 Bits)
  - Achtfache Genauigkeit (256 Bits)

Schauen wir uns die Kodierung  
einmal im Detail an

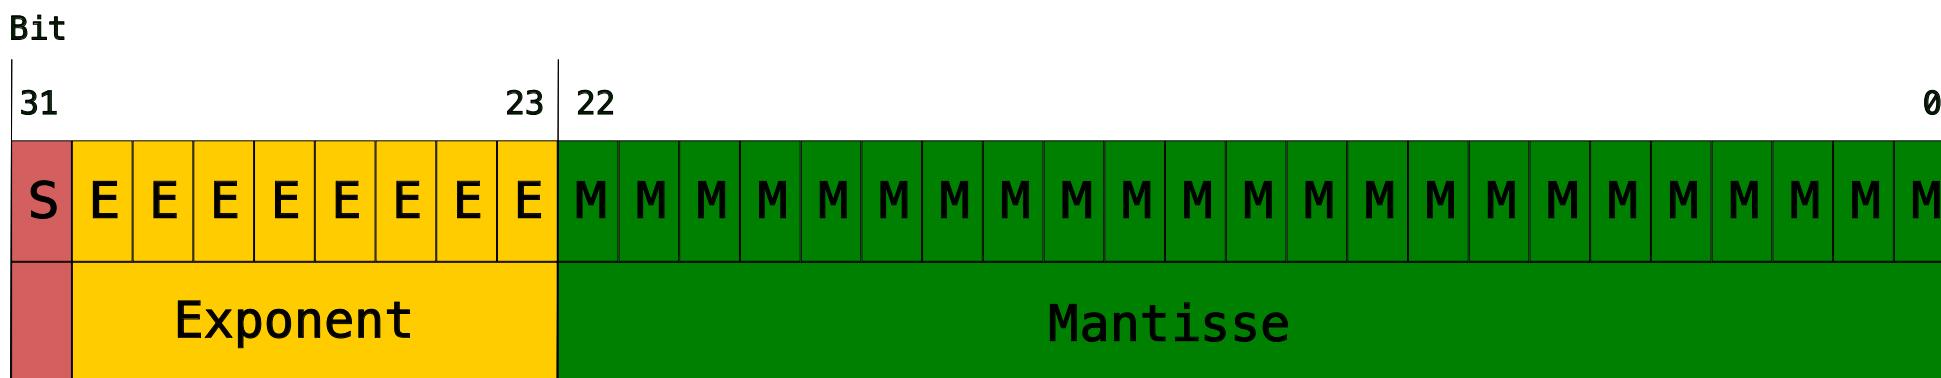
# Darstellung von Gleitkommazahlen

- Wie kann Gleitkommazahl dargestellt werden?
  - Vorkomma- und Nachkommaanteil
    - Nachkommadarstellung mit Exponent
  - Die zweite Darstellung ist die **Normalisierung** der Gleitkommazahl.  
→ **Float  $F = (-1)$**
- $4711.1174_D$        $0.47111174 \cdot 10^4_D$
- Was bedeutet das jetzt alles? 🤔**

# Aufbau einer Gleitkommazahl

Bestandteil	Bits (FP-32)
Vorzeichen $S$ (Sign)	Bit 31
Exponent $E$	Bit 30-23
Mantisse $M$ (Nachkommateil)	Bit 22-0

- Aufbau einer Gleitkommazahl mit einfacher Genauigkeit (32 Bit)



# Gleitkommazahl - Vorzeichen $S$

- Höchstwertiges Bit
- Mögliche Werte:
  - $0$  → positive Zahl
  - $1$  → negative Zahl
- Deswegen ist das Vorzeichen in der Formel auch als  $(-1)^S$  dargestellt

# Gleitkommazahl - Exponent $E$

- Darstellung mit **Bias**:

Auf den Exponent wird **zusätzlich** immer eine Konstante addiert

- **Konstante abhängig** von der **Genauigkeit** der Gleitkommazahl

- Ist für **jede Genauigkeit** fest
  - Einfache Genauigkeit  $\rightarrow$  Bias  $B = 127$
- **Beispiel:**  $E = 16$  ( $\rightarrow 2^{16}$ )  $\rightarrow$  **0001 0000**
  - Bias wird addiert:  $E = 16 + B = 143 \rightarrow$  **1000 1111**
  - *Biased Exponent* wird in das Exponentfeld eingetragen

# Gleitkommazahl - Exponent $E$

- Warum so kompliziert?
- Wozu die Verwendung eines Bias?
- Darstellbarer Wertebereich:  $2^{-126} - 2^{127}$  für einfache Genauigkeit
- Nach Bias-Addition: 1 – 254
  - Darstellung mit 7 Bit möglich
  - Keine Verschwendung von einem Bit für Vorzeichen
- Exponentwerte mit spezieller Bedeutung
  - 0000 0000 = 0 → u. a. für die Null
  - 1111 1111 = 255 →  $\infty$  und Not a Number (=NaN)

# Gleitkommazahl - Mantisse $M$

- Nachkommanteil  $M$  einer Zahl in binärer Darstellung

- Bestimmung

- Verschiebe das Komma bis eine 1 vor dem Komma steht
  - Das höchstwertige Bit ist Vorkommaanteil (implizite 1, wird nicht gespeichert)
  - Restlichen Bits entsprechen dem Nachkommanteil  $M$

- Beispiel:  $8.125_D = \underbrace{1000}_{2^2 2^2 2^2}, 001 \quad 2^{-3} = 0,125$ 
  - Verschiebung des Kommas, bis nur das MSBit noch vor dem Komma steht  
 $\rightarrow 1.00001 \cdot 2^3$
  - Exponent entspricht Anzahl an verschobenen Stellen  
 $\rightarrow E = 3 + B = 3 + 127 = 130$

# Genauigkeit der Gleitkommazahlen

- Beispiele bis hierher gelten nur für einfache Genauigkeit
- Berechnungsformel ist allerdings für alle gleich
  - $\text{Float } F = (-1)^S \cdot (1 + M) \cdot (2)^E$
- Unterschiede: Wertebereich, Bias und Bitbreite von Exponent und Mantisse  
→ Ansonsten kein Unterschied in der Berechnung!

Name	Bits	$E$ (Bits)	Bias	Min. $E$	Max. $E$	$M$ (Bits)
FP-16 ( <i>Half</i> )	16	5	15	-14	15	10
FP-32 ( <i>Single</i> )	32	8	127	-126	127	23
FP-64 ( <i>Double</i> )	64	11	1023	-1022	1023	52

# Umwandlung Nachkommaanteil

- Nachkommastellen sind in ebenfalls gut darstellbar
- **Beispiel:**  $16.625_D$
- **Vorkommaanteil:** Ist einfach  $\rightarrow 2^4 = 0001\ 0000$
- **Nachkommaanteil:** Darstellung als Summe von Zweierpotenzen  
 $\rightarrow 2^{-1} + 2^{-2} + 2^{-3} + 2^{-4} + \dots$
- **Beispiel:**  $0.625_D = 2^{-1} + 2^{-3} = .101_B$

# Ungenauigkeit von Gleitkommazahlen

- Gleitkommazahlen **ungeeignet** für **exakte Darstellung beliebiger Zahlen**:
- $0.375_D = 0.011 \rightarrow 2^{-2} + 2^{-3}$
- **Aber:**  $0.1_D$  nicht genau darstellbar  $\rightarrow$  Rundung auf nächste darstellbare Zahl
- Verschiedene Rundungsstrategien:
  - Immer **aufrunden** (zu  $+\infty$ )
  - Immer **abrunden** (zu  $-\infty$ )
  - Immer **Richtung Null** runden

Es gibt verschiedene Online-Tools für das Darstellen von IEEE-754-Zahlen, zum Beispiel auf [weltz.de](http://weltz.de)

# Spezielle Gleitkommazahlen

- *Genau Null*
  - Exponent und Mantisse haben jeweils Wert 0
  - Vorzeichen unterscheidet zwischen  $+0$  und  $-0$
- *Infinity ( $\infty$ )*
  - Alle Bits im Exponent gesetzt, Mantisse hat Wert 0
  - Vorzeichenbit bestimmt  $\pm\infty$
- *NaN (Not a Number)*
  - Kodiert mathematisch nicht erlaubte Operationen (z.B. Division durch 0)
  - Exponentbits alle gesetzt, aber Mantisse hat Wert  $\neq 0$

# Beispiel - Umwandlung in Gleitkommazahl

- **Beispiel:** Aus  $16.625 = 10000.101_B$  wird:
  1. Verschiebe Komma bis hinter die höchste Stelle  $\rightarrow 1.0000101 \cdot 2^4$
  2. Exponenten  $E = 4 + 127 = 131 = 10000011$
  3. Mantisse  $M$  entspricht Nachkommaanteil  $\rightarrow 0000101$
  4. Vorzeichenbit  $S$ : Zahl positiv  $\rightarrow 0$
- Insgesamt

**0100 0001 1000 0101 0000 0000 0000 0000**

# Einschub: Floating-Point Unit (FPU)

- Berechnung von Gleitkommazahlen braucht auf der CPU viele Schritte
  - Verwendung von Gleitkommazahlen ist ein Flaschenhals
- Einsatz spezialisierter Hardware-Komponente nur für Gleitkommazahlen:
  - **Floating-Point Unit (FPU)**
- Auf allen modernen CPUs enthalten
- Einige alte CPUs und Mikrocontroller enthalten diese aber nicht
- Falls nicht vorhanden, dann Rückfall auf Software-Berechnung

# Einschub: Fixed-Point

- Und wenn wir eine **feste Anzahl** an Nachkommastellen benötigen?
- **Lösung: Fixed-Point-Zahlen**
- Nur per Software möglich, keine übliche Hardware-Komponente
- Eigene Umsetzung notwendig, C bietet keine vorhandene Implementierung
- **Beispiel:**  $16.375_D$  in Fixed-Point-Notation mit 2 Nachkommastellen

$10000.011 \rightarrow 010000.01$  (Fixed-Point)

# Zwischenstand

- Wir kennen jetzt **fast alles Grundlegende**, was **elementare Datentypen** angeht!
  - Zeit für einen Blick **in** die CPU
    - Byte-Order wurde bereits vorgestellt (✓)
    - **Es fehlt:** Kodierung der Zahlen zur effizienten Verarbeitung
- Jetzt!

# Sign-Magnitude

- Vorgehen: „Ergänze eine positive Zahl in Binärdarstellung um Vorzeichenbit“
  - $0 \rightarrow \text{positiv}$
  - $1 \rightarrow \text{negativ}$
- Beispiel:  $-3 = 1\ 11$
- Vorteil: Einfach zu lesen und zu konvertieren
- Aber: Es kostet Mehraufwand
  - Hälfte des Zahlenraums geht an das Vorzeichen verloren
  - $0$  wird doppelt kodiert:  $+0 \rightarrow 00$  und  $-0 \rightarrow 10$

# Beispiele - Sign-Magnitude

- Bitbreite: 1 Byte = 8 Bit
- Beispiel:  $-79_D$

Sign	64	32	16	8	4	2	1
1	1	0	0	1	1	1	1

- Beispiel:  $-255_D$

...	Sign	128	64	32	16	8	4	2	1
...	1	1	1	1	1	1	1	1	1

→ Bei fester Byte-Größe **Überlauf in das nächste Byte** (7 Bits verschwendet)

# Einerkomplement

- **Positive Zahl:** Keine Veränderung der Binärdarstellung – wie bisher
- **Negative Zahl**
  - Umwandlung in Binärdarstellung
  - **Invertiere** den Wert jedes Bits
- Negative Zahlen haben ebenfalls **1 als MSBit**
- **Beispiel:**
  - $+79 \rightarrow 0100\ 1111_B$
  - $-79 \rightarrow 1011\ 0000_1$
- **Auch hier gilt:** 0 wird doppelt kodiert mit  $+0$  ( $00_1$ ) und  $-0$  ( $11_1$ )

# Umwandlung Einerkomplement zu Dezimal

- MSB ist 0: Umwandlung in Dezimal wie bisher
- MSB ist 1:
  1. Wandle die Binärzahl in Dezimalzahl um
  2. Addiere 1
- Beispiel: -79

-128	64	32	16	8	4	2	1
1	0	1	1	0	0	0	0

1. Summe der Bitwerte:  $-128 + 32 + 16 = -80$
2. Addiere 1:  $-80 + 1 = -79$

# Zweierkomplement

- **Positive Zahl:** Keine Veränderung der Binärdarstellung
- **Negative Zahl:**
  1. Umwandlung in Binärdarstellung
  2. Invertiere jedes Bit
  3. Addiere 1
- **Vorteile des Zweierkomplements:**
  - **Keine** Überprüfung auf das Vorzeichen  
→ **Addition und Subtraktion sind identische Operationen**
  - Keine doppelte Darstellung der 0
- Dies ist die in **Computern** übliche Darstellung

# Beispiel - Zweierkomplement

- Beispiel

$$1 - 4 = -3 \Leftrightarrow 1 + (-4) = -3$$

- Umwandlung 1:  $0001_2$

- Umwandlung (-4)

1. Invertiere  $0100_B$  (+4)  $\rightarrow 1011_1$

2. Addiere 1  $\rightarrow 1100_2$

$$\begin{array}{r} 1 \\ - 4 \\ \hline \end{array}$$

- Addition:  $0001_2 + 1100_2 = 1101_2 \rightarrow -3$

- Anmerkung: Bitweise Addition erfolgt genau wie bei der schriftlichen Addition  
 $\rightarrow$  Übertrag (Carry-Over) wird bei der nächsthöheren Stelle zusätzlich addiert

$$\begin{array}{r} 0 & 0 & 0 & 1 \\ + & 1 & 1 & 0 & 0 \\ = & 1 & 1 & 0 & 1 \end{array}$$

# Zweikomplement im Computer

- Computer verwenden intern das Zweierkomplement
- Aufwand für Konvertierung < Aufwand für Rechenoperationen
- Anstatt zwei Operationen
  1. Prüfen des Vorzeichenbit
  2. anschließend Addieren oder Subtrahieren
- Nur noch eine Operation: Addition
- Achtung: Auf der Hardware kommt noch die Byte-Order hinzu!  
→ Wichtig, wenn Speicher direkt ausgelesen wird

# Typumwandlung

- **Bisher:** Darstellung von Datentypen in Hardware
- **Es fehlt:** Umwandlung von Datentypen
- In der CPU? **Egal. Abfolge von Bits von Bytes**
- **Interpretation der Bitfolge geschieht auf höherer Ebene nach fest definierten Regeln**

# Typumwandlung

- Bereits bekannt: **Implizite** Umwandlung (automatisch) in einen Datentyp
  - Skalar zu booleschem Ausdruck bei if-Blöcken
- Alternativ: **float** zu **int** bei Zuweisung (und umgekehrt)  
`float f = 3;`
- Es fehlt: **explizite** Umwandlung (manuell) in einen Datentyp, z. B. **int** zu **double**

# Typumwandlung



- In C gibt es **Type Casting**
  - Bezeichnung für **explizite Umwandlung**
- **Syntax ist einfach**
  - **Zieltyp in Klammern** davor schreiben
  - **(T) 3;** // *Umwandlung in Typ T*
- **Beispiel: (int) 3.5;**
- Besonders interessant bei komplexen Datentypen und bei Zuweisung von Speicher (→ nächstes Kapitel)

```
#include <stdio.h>

int main() {
    int i = 13;
    double d = (double) i;
    printf("%#.02f\n", d);
    return 0;
}
```

# Typumwandlung



**Achtung:** Unerwartete Fehler bei Zwischenschritten durch Umwandlungen

C

Run ▶

```
#include <stdio.h>
int main() {
    int i = 13, j = 4;
    double d = i / j;
    printf("%#.02f\n", d);
    return 0;
}
```

# Typumwandlung

Warum geschieht das?

C Run ▶

- **Implizite Umwandlung** gilt auch für **Zwischenschritte**
- Division ist **abgeschlossene Operation** zweier Integers
- **Keine** Konvertierung während Division
  - Ergebnis Division ist ein `int`
  - `double`-Umwandlung erst bei der Zuweisung
- Lösung: **explizites Type-Casting**: `double d = (double) i / j;`

```
#include <stdio.h>
int main() {
    int i = 13, j = 4;
    double d = (double)i / j;
    printf("%#.02f\n", d);
    return 0;
}
```

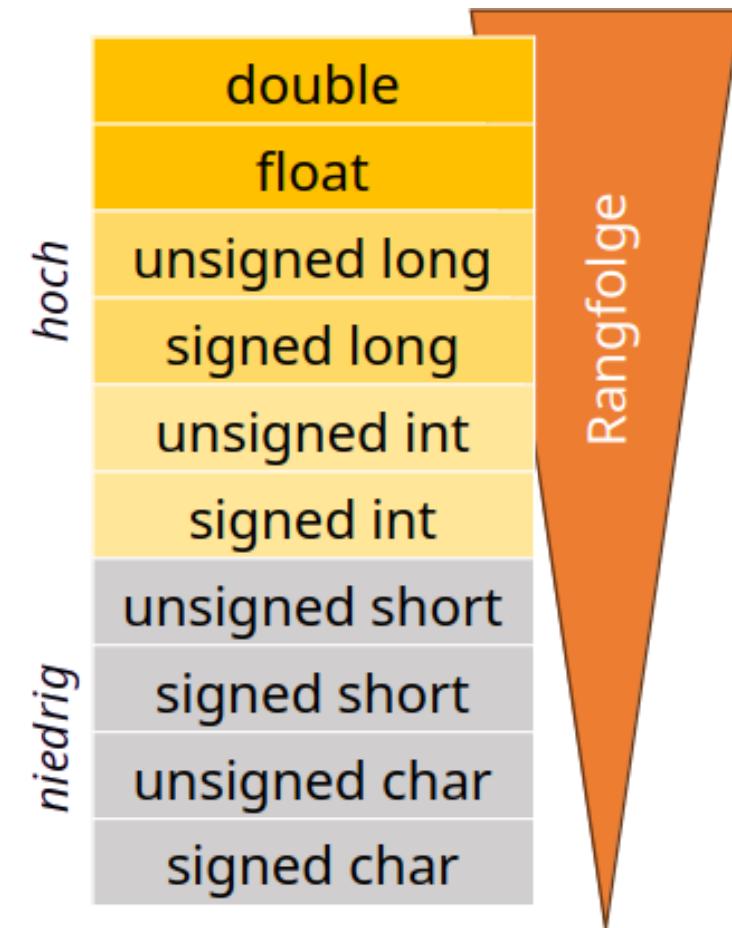
# Weitere Typumwandlungen

- **Upcasting**

- Abhängig von Parametern werden **einzelne Variablen** zu **breiterem Datentyp** umgewandelt
- Festgelegte Hierarchie für Umwandlung
- `int = char + int;` → `int = int + int;`

- **Downcasting**

- Abhängig vom Ergebnistyp werden **Variablen/das Ergebnis** zu Typ mit **weniger Bits** konvertiert
- `char = int + int;` → `char = (char)(int + int);`



# Typumwandlung in C++

- In C++ prinzipiell ähnlich, **aber** einige wichtige Unterschiede
- **Explizite Umwandlung in C++ nicht gern gesehen:**
  - Geschieht unbedingt
  - Untergräbt das Typensystem des Compilers
- **Compiler** überprüft in C++ bereits **mögliche Fehler oder Probleme**
  - In C treten **Fehler** erst **zur Laufzeit** auf
  - C++ hat feiner unterteilte Möglichkeiten zur Typenumwandlung
  - Verteilt Funktionalität von C-Style-Casting auf verschiedene Funktionen

# Typumwandlung in C++

- **static\_cast**
  - Konvertierung unter Berücksichtigung impliziter Regeln
  - `double d = static_cast<double>(3);`
- **reinterpret\_cast**:
  - Ähnlich zu C-Style-Cast, Uminterpretierung auf Bitebene (**gefährlich**)
  - `int i = reinterpret_cast<int>(3.5f);`
- **(const\_cast)**
- **(dynamic\_cast)**

# FixedSize-Typen

- Erinnerung an Integer
  - 💡 Breite in Bits ist abhängig von der Hardwarearchitektur! 💡
- Unerwartete Effekte bei *Type Casting* möglich
  - Besonders bei `int` auf unterschiedlichen CPU-Architekturen
- Dringende Empfehlung: Stattdessen Datentypen mit fester Breite verwenden
  - `uint8_t`, `uint16_t`, `uint32_t`, `uint64_t`
  - `int8_t`, `int16_t`, `int32_t`, `int64_t`
- Einbindung über den Header `<stdint.h>`

```
int32_t i32 = 0;  
uint8_t ui8 = 0;
```

# Zusammenfassung

- IEEE-754 zur Darstellung für Gleitkommazahlen
  - Probleme bei Gleitkommazahlen
  - *Fixed-Point*-Darstellung
- Zahlendarstellungen
  - Sign-Magnitude
  - Einerkomplement
  - Zweierkomplement
- Implizite Typumwandlung
  - *Down Casting*
  - *Up Casting*
- Explizite Typumwandlung
- *Fixed-Size*-Typen

