



Rechnerstrukturen und Betriebssysteme

64-040 Vorlesung RSB
Kapitel 4: Arithmetische Operationen

Norman Hendrich



Universität Hamburg
Fakultät für Mathematik, Informatik und Naturwissenschaften
Fachbereich Informatik
Technische Aspekte Multimodaler Systeme

Wintersemester 2025/2026

Arithmetik

Addition und Subtraktion

Multiplikation

Division

Höhere Funktionen

Mathematische Eigenschaften

Literatur

Wiederholung: Stellenwertsystem („Radixdarstellung“)

- ▶ Wahl einer geeigneten Zahlenbasis b („Radix“)
 - ▶ 10: Dezimalsystem
 - ▶ 16: Hexadezimalsystem (Sedezimalsystem)
 - ▶ 2: Dualsystem
- ▶ Menge der entsprechenden Ziffern $\{0, 1, \dots, b - 1\}$
- ▶ inklusive einer besonderen Ziffer für den Wert Null
- ▶ Auswahl der benötigten Anzahl n von Stellen

$$|z| = \sum_{i=0}^{n-1} a_i \cdot b^i$$

b Basis a_i Koeffizient an Stelle i

- ▶ universell verwendbar, für beliebig große Zahlen

Integer-Datentypen in C und Java

C:

- ▶ Zahlenbereiche definiert in Headerdatei `/usr/include/limits.h`
`LONG_MIN`, `LONG_MAX`, `ULONG_MAX` etc.
- ▶ Zweierkomplement (`signed`), Ganzzahl (`unsigned`)
- ▶ die Werte sind plattformabhängig !

Java:

- ▶ 16-bit, 32-bit, 64-bit Zweierkomplementzahlen
- ▶ Wrapper-Klassen `Short`, `Integer`, `Long`

```
Short.MAX_VALUE      =      32767
Integer.MIN_VALUE   = -2147483648
Integer.MAX_VALUE   = 2147483647
Long.MIN_VALUE      = -9223372036854775808L
...
```

- ▶ Werte sind für die Sprache fest definiert

Addition im Dualsystem

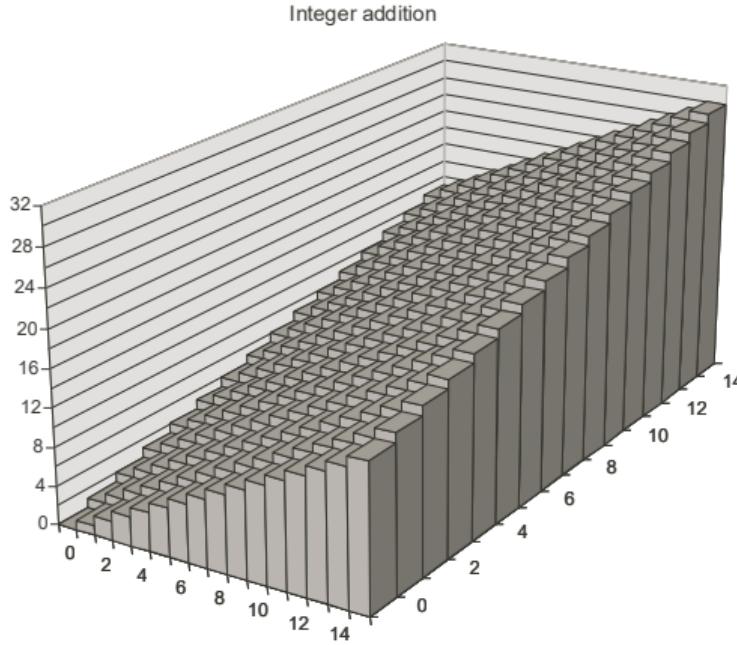
- ▶ funktioniert genau wie im Dezimalsystem
- ▶ Addition mehrstelliger Zahlen erfolgt stellenweise
- ▶ Additionsmatrix

+	0	1
0	0	1
1	1	10

- ▶ Beispiel

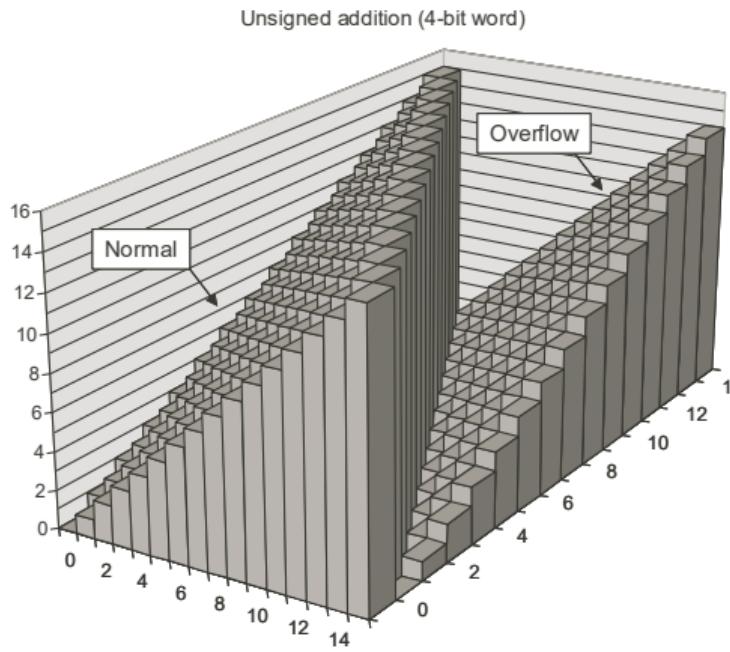
$$\begin{array}{r} 1011\ 0011 \\ + 0011\ 1001 \\ \hline \text{Ü} \quad 11 \quad 11 \\ \hline 1110\ 1100 \end{array} \quad \begin{array}{r} = 179 \\ = 57 \\ \hline = 11 \\ \hline = 236 \end{array}$$

unsigned Addition: Visualisierung



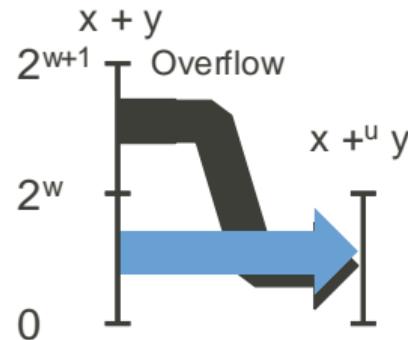
- ▶ Wortbreite der Operanden ist w , hier 4-bit
- ▶ Zahlenbereich der Operanden x, y ist $0 \dots (2^w - 1)$ (0..15)
- ▶ Zahlenbereich des Resultats s ist $0 \dots (2^{w+1} - 2)$ (0..30)

unsigned Addition: Visualisierung (cont.)



- ▶ Wortbreite der Operanden **und des Resultats** ist w
 - ⇒ Überlauf, sobald das Resultat größer als $(2^w - 1)$
 - ⇒ oberstes Bit geht verloren
- $(16..30) \rightarrow (0..14)$

unsigned Addition: Überlauf



- ▶ Wortbreite ist w
- ▶ Zahlenbereich der Operanden x, y ist $0 \dots (2^w - 1)$
- ▶ Zahlenbereich des Resultats s ist $0 \dots (2^{w+1} - 2)$
- ▶ Werte $s \geq 2^w$ werden in den Bereich $0 \dots 2^w - 1$ abgebildet

Subtraktion im Dualsystem

- ▶ Subtraktion mehrstelliger Zahlen erfolgt stellenweise
- ▶ (Minuend - Subtrahend), Überträge berücksichtigen
- ▶ Beispiel

$$\begin{array}{r} 1011\ 0011 & = 179 \\ - 0011\ 1001 & = 57 \\ \hline \text{Ü } 1111 & \\ \hline 111\ 1010 & = 122 \end{array}$$

- ▶ Alternative: Subtraktion durch Addition des b -Komplements ersetzen

Subtraktion mit b -Komplement

- ▶ bei Rechnung mit fester Stellenzahl n gilt:

$$K_b(z) + z = b^n = 0$$

weil b^n gerade nicht mehr in n Stellen hineinpasst

- ▶ also gilt für die Subtraktion auch:

$$x - y = x + K_b(y)$$

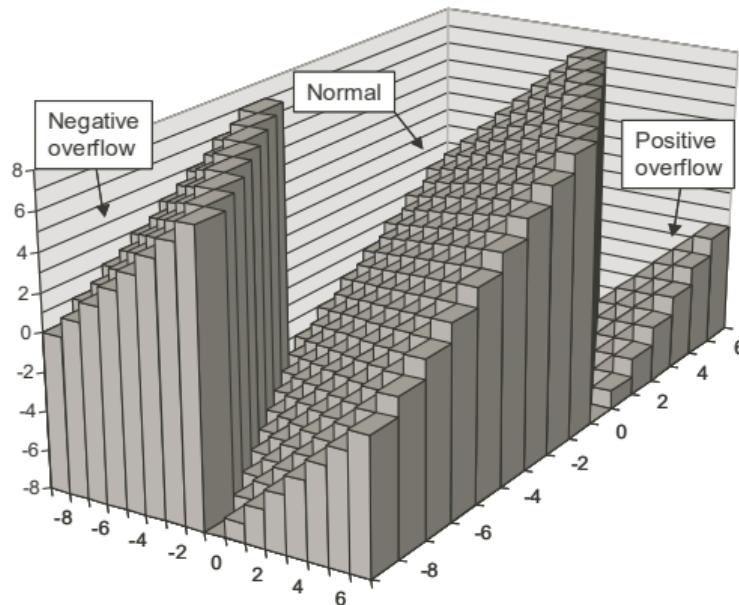
⇒ Subtraktion kann durch Addition des b -Komplements ersetzt werden!

Voraussetzung: begrenzte Stellenanzahl

- ▶ und für Integerzahlen gilt außerdem

$$x - y = x + K_{b-1}(y) + 1$$

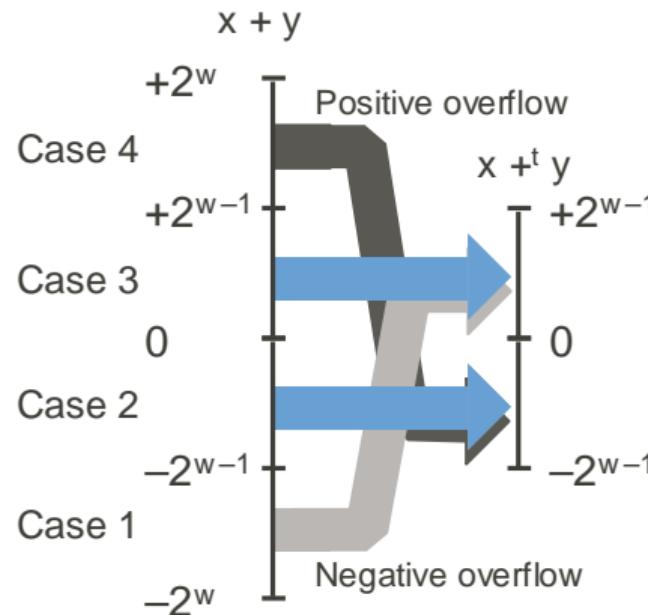
Two's complement addition (4-bit word)



[1]

- ▶ Wortbreite der Operanden ist w , hier 4-bit
- ▶ Zahlenbereich der Operanden x, y ist $-2^{w-1} \dots (2^{w-1} - 1)$
- ▶ Zahlenbereich des Resultats s ist $-2^w \dots (2^w - 2)$
- ⇒ Überlauf in beide Richtungen möglich

signed Addition: Überlauf



- Wortbreite des Resultats ist w : Bereich $-2^{w-1} \dots (2^{w-1} - 1)$
- Überlauf positiv wenn Resultat $\geq 2^{w-1}$: Summe negativ
 $-" -$ negativ $-" -$ $< -2^{w-1}$: Summe positiv

Überlauf: Erkennung

- ▶ Erkennung eines Überlaufs bei der Addition?
- ▶ wenn beide Operanden das gleiche Vorzeichen haben und sich das Vorzeichen des Resultats unterscheidet

- ▶ Java-Codebeispiel

```
int a, b, sum;          // operands and sum
boolean ovf;            // ovf flag indicates overflow

sum = a + b;
ovf = ((a < 0) == (b < 0)) && ((a < 0) != (sum < 0));
```

Subtraktion mit Einer- und Zweierkomplement

- Subtraktion ersetzt durch Addition des Komplements

Dezimal	1-Komplement	2-Komplement
10	0000 1010	0000 1010
+(-3)	1111 1100	1111 1101
+7	1 0000 0110	1 0000 0111
Übertrag:	addieren +1	verwerfen
	0000 0111	0000 0111

- **(b-1)-Komplement** der Zahl z $K_{b-1}(z) = b^n - z - b^{-m}$ für $z \neq 0$

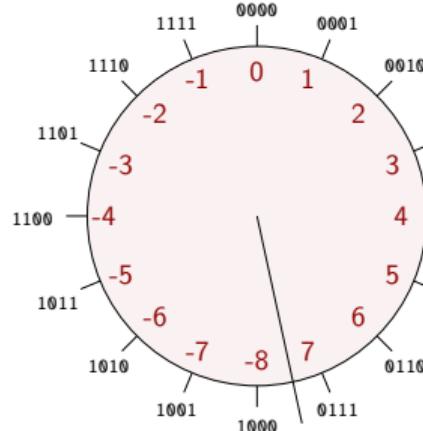
$$= 0 \quad \text{für } z = 0$$

- **b-Komplement** der Zahl z $K_b(z) = b^n - z$ für $z \neq 0$

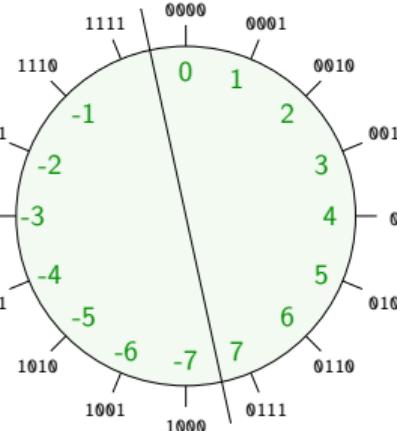
$$= 0 \quad \text{für } z = 0$$

Veranschaulichung: Zahlenkreis

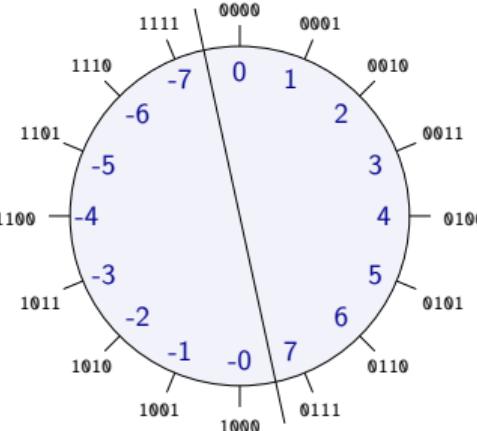
Beispiel für 4-bit Zahlen



2-Komplement



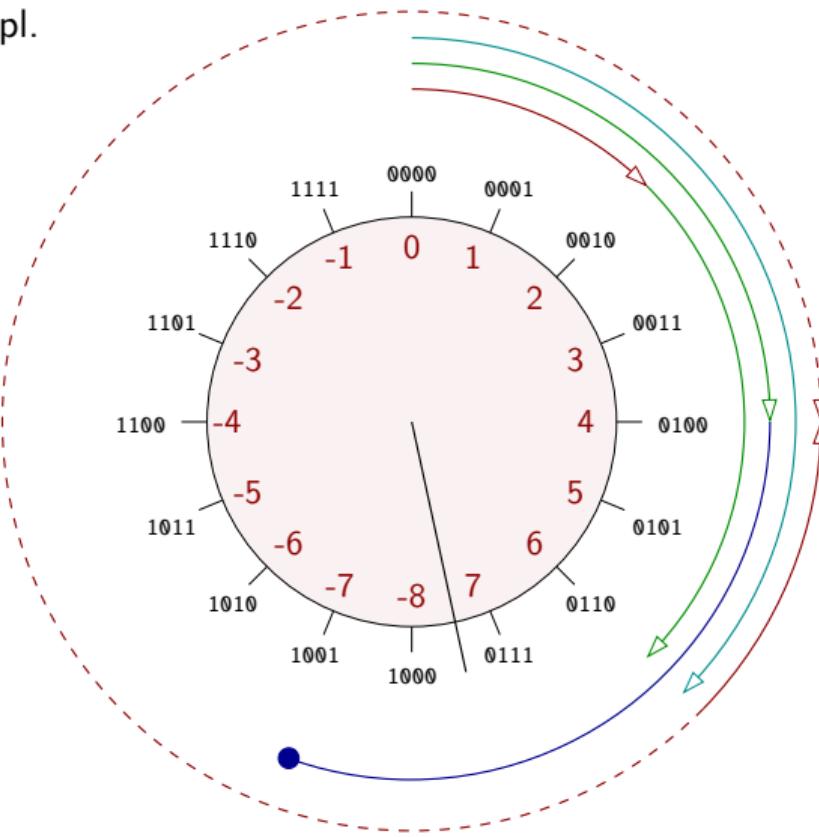
1-Komplement

Betrag+Vorzeichen
MSB \cong Vorzeichen

- Komplement-Arithmetik als Winkeladdition
- Web-Anwendung: *Visualisierung im Zahlenkreis* (JavaScript, aus [3])

Zahlenkreis: Addition, Subtraktion

2-Kompl.

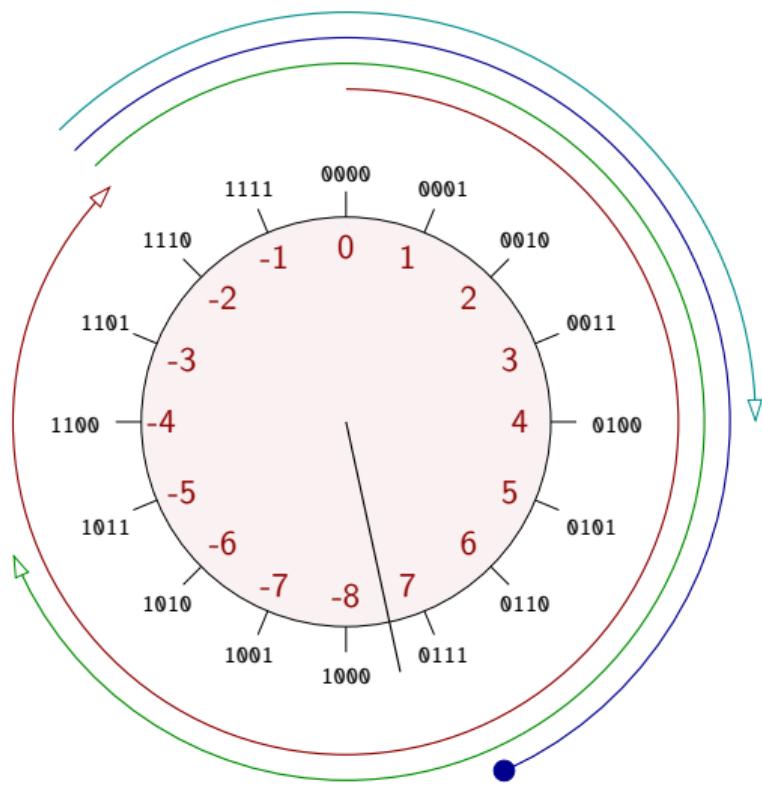


$$\begin{aligned}0010 + 0100 &= 0110 \\0100 + 0101 &= 1001 \\0110 - 0010 &= 0100\end{aligned}$$

0010
0100
0101
0110

Zahlenkreis: Addition, Subtraktion (cont.)

2-Kompl.



$$1110 + 1101 = 1011$$

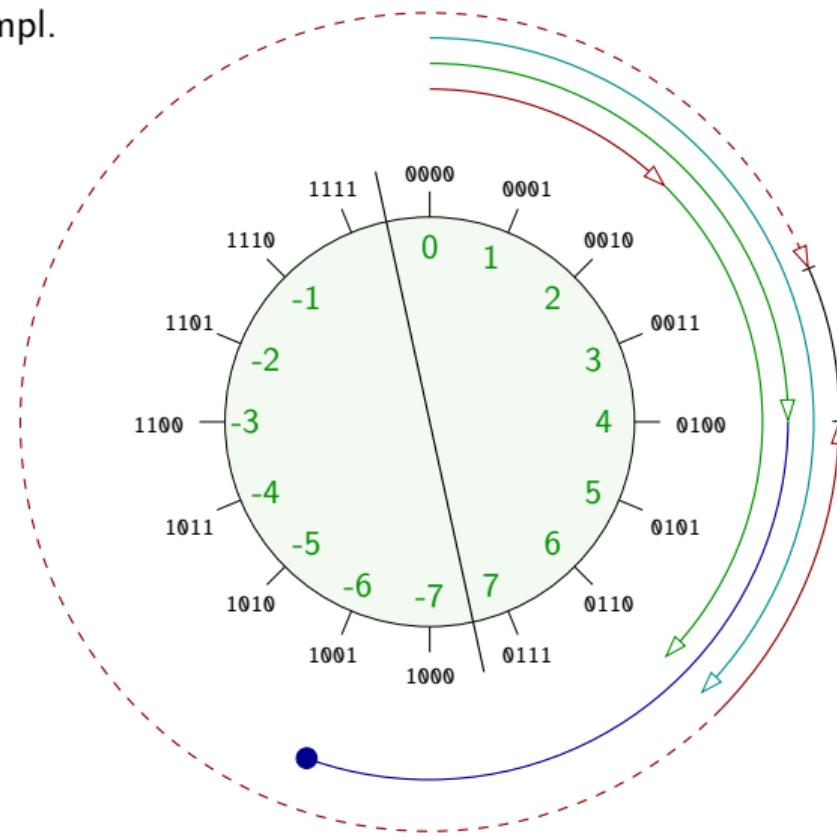
$$1110 + 1001 = \textcolor{red}{0111}$$

$$1110 + 0110 = 0100$$

1110**1101****1001****0110**

Zahlenkreis: Addition, Subtraktion (cont.)

1-Kompl.



$$0010 + 0100 = 0110$$

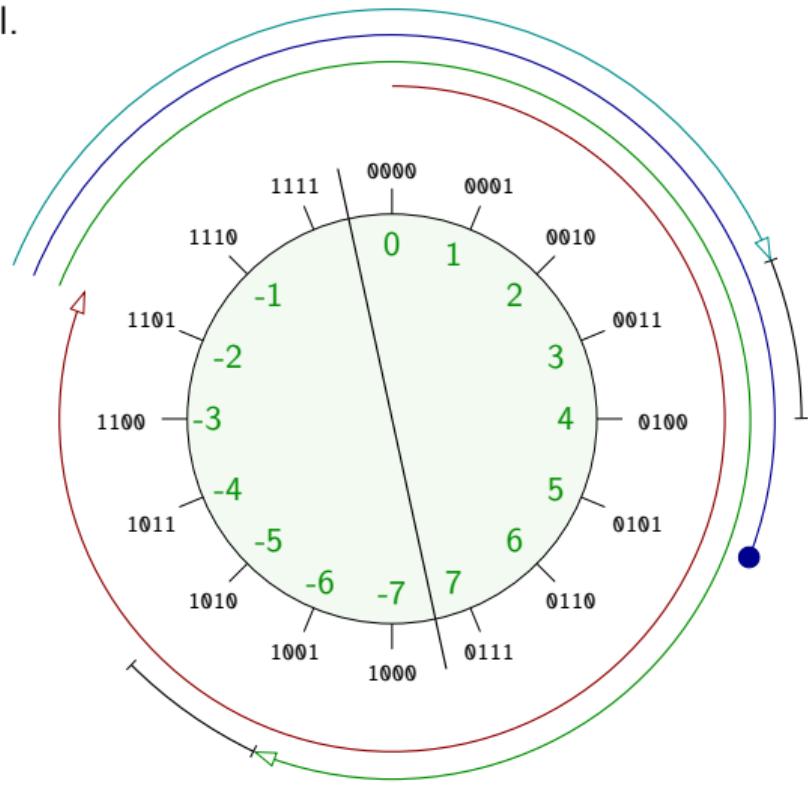
$$0100 + 0101 = 1001$$

$$0110 + 1101 + 1 = 0100$$

0010 1101
0100
0101
0110

Zahlenkreis: Addition, Subtraktion (cont.)

1-Kompl.



$$1101 + 1100 + 1 = 1010$$

$$1101 + 1000 = \textcolor{red}{0101}$$

$$1101 + 0110 + 1 = \textcolor{blue}{0100}$$

1101**1100****1000****0110**

in C: unsigned Zahlen

- ▶ für hardwarenahe Programme und Treiber
- ▶ für modulare Arithmetik („multi-precision arithmetic“)
- ▶ aber evtl. ineffizient (vom Compiler schlecht unterstützt)

- ▶ Vorsicht vor solchen Fehlern

```
unsigned int i, cnt = ...;
for( i = cnt-2; i >= 0; i-- ) {
    a[i] += a[i+1];
}
```

in C: Casting-Regeln

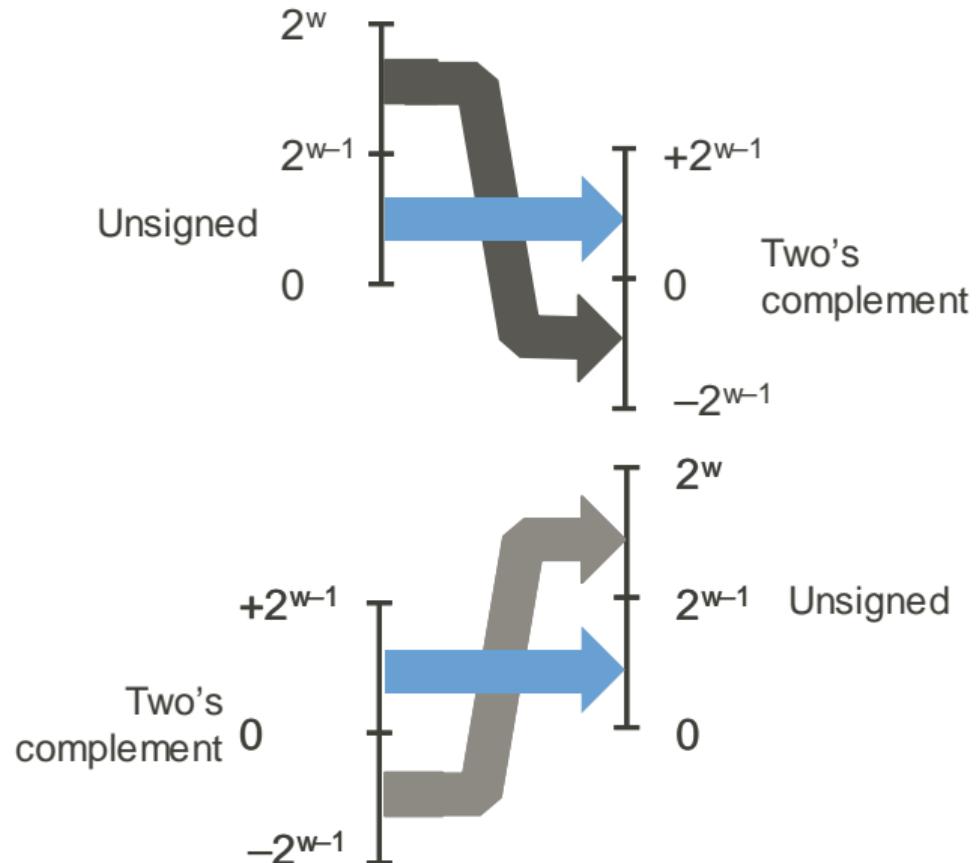
- ▶ Bit-Repräsentation wird nicht verändert
- ▶ kein Effekt auf positiven Zahlen
- ▶ Negative Werte als (große) positive Werte interpretiert

```
short int          x = 15213;
unsigned short int ux = (unsigned short) x; // 15213

short int          y = -15213;
unsigned short int uy = (unsigned short) y; // 50323
```

- ▶ Schreibweise für Konstanten:
 - ▶ ohne weitere Angabe: signed
 - ▶ Suffix „U“ für unsigned: 0U, 4294967259U

in C: unsigned / signed Interpretation



in C: Vorsicht bei Typumwandlung

► Arithmetische Ausdrücke:

- ▶ bei gemischten Operanden: Auswertung als unsigned
- ▶ auch für die Vergleichsoperationen <, >, ==, <=, >=
- ▶ Beispiele für Wortbreite 32-bit:

Konstante 1	Relation	Konstante 2	Auswertung	Resultat
0	==	0U	unsigned	1
-1	<	0	signed	1
-1	<	0U	unsigned	0
2147483647	>	-2147483648	signed	1
2147483647U	>	-2147483648	unsigned	0
2147483647	>	(int) 2147483648U	signed	1
-1	>	-2	signed	1
(unsigned) -1	>	-2	unsigned	1

Sign-Extension

- ▶ Gegeben: w -bit Integer x
- ▶ Umwandeln in $w + k$ -bit Integer x' mit gleichem Wert?

- ▶ **Sign-Extension:** Vorzeichenbit kopieren

$$x' = x_{w-1}, \dots, x_{w-1}, x_{w-1}, x_{w-2}, \dots, x_0$$

- ▶ Zahlenbeispiele

0110 4-bit signed: +6

0000 0110 8-bit signed: +6

0000 0000 0000 0110 16-bit signed: +6

1110 4-bit signed: -2

1111 1110 8-bit signed: -2

1111 1111 1111 1110 16-bit signed: -2

Java Puzzlers No.5

J. Bloch, N. Gafter: *Java Puzzlers: Traps, Pitfalls, and Corner Cases*. Addison-Wesley, 2005

```
public static void main( String[] args ) {
    System.out.println(
        Long.toHexString( 0x100000000L + 0xcafebabe ) );
}
```

- ▶ Programm addiert zwei Konstanten, Ausgabe in Hex-Format
- ▶ Was ist das Resultat der Rechnung?

Java Puzzlers No.5

J. Bloch, N. Gafter: *Java Puzzlers: Traps, Pitfalls, and Corner Cases*. Addison-Wesley, 2005

```
public static void main( String[] args ) {
    System.out.println(
        Long.toHexString( 0x100000000L + 0xcafebabe ) );
}
```

- ▶ Programm addiert zwei Konstanten, Ausgabe in Hex-Format
- ▶ Was ist das Resultat der Rechnung?

0xffffffffcafebabe sign-extension!

0x0000000100000000

Ü 11111110

00000000cafebabe

Ariane-5 Absturz

- ▶ Erstflug der Ariane-5 („V88“) am 04. Juni 1996
- ▶ Kurskorrektur wegen vermeintlich falscher Fluglage
- ▶ Selbstzerstörung der Rakete nach 36,7 Sekunden
- ▶ Schaden ca. 635 M€
(teuerster Softwarefehler der Geschichte?)



- ▶ bewährte Software von Ariane-4 übernommen
- ▶ aber Ariane-5 viel schneller als Ariane-4
- ▶ 64-bit Gleitkommawert für horizontale Geschwindigkeit
- ▶ Umwandlung in 16-bit Integer: dabei Überlauf

- ▶ de.wikipedia.org/wiki/Ariane_V88

Multiplikation im Dualsystem

- ▶ funktioniert genau wie im Dezimalsystem
 - ▶ $p = a \cdot b$ mit Multiplikator a und Multiplikand b
 - ▶ Multiplikation von a mit je einer Stelle des Multiplikanten b
 - ▶ Addition der Teilterme
-
- ▶ Multiplikationsmatrix – sehr einfach: $\cdot 0 / \cdot 1$

.	0	1
0	0	0
1	0	1

Multiplikation im Dualsystem (cont.)

► Beispiel

$$\begin{array}{r} 10110011 \quad \cdot \quad 1101 \\ \hline 10110011 \quad \quad \quad 1 \\ 10110011 \quad \quad \quad 1 \\ 00000000 \quad \quad \quad 0 \\ 10110011 \quad \quad \quad 1 \\ \hline \text{Ü } 11101111 \\ \hline 100100010111 \end{array} = 179 \cdot 13 = 2327
= 1001\ 0001\ 0111
= 0x917$$

unsigned Multiplikation

- ▶ bei Wortbreite w bit
 - ▶ Zahlenbereich der Operanden: $0 \dots (2^w - 1)$
 - ▶ Zahlenbereich des Resultats: $0 \dots (2^w - 1)^2 = 2^{2w} - 2^{w+1} + 1$
 - ⇒ bis zu $2w$ bits erforderlich
-
- ▶ C: Resultat enthält nur die unteren w bits
 - ▶ Java: keine unsigned Integer
 - ▶ Hardware: teilweise zwei Register *high*, *low* für die oberen und unteren Bits des Resultats

- ▶ Zahlenbereich der Operanden: $-2^{w-1} \dots (2^{w-1} - 1)$
- ▶ Zahlenbereich des Resultats: $-2^{w-1} \cdot (2^{w-1} - 1) \dots (2^{2w-2})$
- ⇒ bis zu $2w$ bits erforderlich

- ▶ C, Java: Resultat enthält nur die unteren w bits
- ▶ Überlauf wird ignoriert

```
int i = 100*200*300*400; // -1894967296
```

- ▶ Repräsentation der unteren Bits des Resultats entspricht der unsigned Multiplikation
- ⇒ kein separater Algorithmus erforderlich
Beweis: siehe Bryant, O'Hallaron: Abschnitt 2.3.5 [1]

Java Puzzlers No. 3

J. Bloch, N. Gafter: *Java Puzzlers: Traps, Pitfalls, and Corner Cases*. Addison-Wesley, 2005

```
public static void main( String args[] ) {  
    final long MICROs_PER_DAY = 24 * 60 * 60 * 1000 * 1000;  
    final long MILLIS_PER_DAY = 24 * 60 * 60 * 1000;  
    System.out.println( MICROs_PER_DAY / MILLIS_PER_DAY );  
}
```

Java Puzzlers No. 3

J. Bloch, N. Gafter: *Java Puzzlers: Traps, Pitfalls, and Corner Cases*. Addison-Wesley, 2005

```
public static void main( String args[] ) {  
    final long MICROS_PER_DAY = 24 * 60 * 60 * 1000 * 1000;  
    final long MILLIS_PER_DAY = 24 * 60 * 60 * 1000;  
    System.out.println( MICROS_PER_DAY / MILLIS_PER_DAY );  
}
```

- ▶ druckt den Wert 5, nicht 1000!
- ▶ MICROS_PER_DAY wird mit 32-bit berechnet, dabei Überlauf
- ▶ Konvertierung nach 64-bit long erst bei der Zuweisung
- ⇒ long-Konstante schreiben: 24L * 60 * 60 * 1000 * 1000

Division im Dualsystem

- ▶ $d = a/b$ mit Dividend a und Divisor b

- ▶ funktioniert genau wie im Dezimalsystem
- ▶ schrittweise Subtraktion des Divisors
- ▶ Berücksichtigen des „Stellenversetzens“

- ▶ in vielen Prozessoren nicht (oder nur teilweise) durch Hardware unterstützt
- ▶ daher deutlich langsamer als Multiplikation

Division im Dualsystem (cont.)

► Beispiele

$$100_{10} / 3_{10} = 110\ 0100_2 / 11_2 = 10\ 0001_2$$

$$1100100 \quad / \quad 11 = 0100001$$

1	0
11	1
-11	
<hr/>	
0	0
0	0
1	0
10	0
100	1
-11	
<hr/>	
1	1 (Rest)

Division im Dualsystem (cont.)

$$91_{10} / 13_{10} = 101\ 1011_2 / 1101_2 = 111_2$$

$$\begin{array}{r} 1011011 \quad / \quad 1101 = 0111 \\ 1011 \qquad \qquad \qquad 0 \\ 10110 \qquad \qquad \qquad 1 \\ -1101 \\ \hline 10011 \qquad \qquad \qquad 1 \\ -1101 \\ \hline 01101 \qquad \qquad \qquad 1 \\ -1101 \\ \hline 0 \end{array}$$

Berechnung von \sqrt{x} , $\log x$, $\exp x$, $\sin x \dots ?$

- ▶ Approximation über Polynom (Taylor-Reihe) bzw. über rationale Funktionen
 - ▶ vorberechnete Koeffizienten für höchste Genauigkeit
 - ▶ Ausnutzen mathematischer Identitäten für Skalierung
- ▶ Sukzessive Approximation über iterative Berechnungen
 - ▶ Beispiele: Quadratwurzel und Reziprok-Berechnung
 - ▶ häufig schnelle (quadratische) Konvergenz
- ▶ Berechnungen erfordern nur die Grundrechenarten

Reziprokwert: Iterative Berechnung von $1/x$

- Berechnung des Reziprokwerts $y = 1/x$ über

$$y_{i+1} = y_i \cdot (2 - x \cdot y_i)$$

- geeigneter Startwert y_0 als Schätzung erforderlich
- Beispiel $x = 3, y_0 = 0,5$:

$$y_1 = 0,5 \cdot (2 - 3 \cdot 0,5) = 0,25$$

$$y_2 = 0,25 \cdot (2 - 3 \cdot 0,25) = 0,3125$$

$$y_3 = 0,3125 \cdot (2 - 3 \cdot 0,3125) = 0,33203125$$

$$y_4 = 0,3332824$$

$$y_5 = 0,3333333332557231$$

$$y_6 = 0,3333333333333333$$

Quadratwurzel: Heron-Verfahren für \sqrt{x}

Babylonisches Wurzelziehen

- ▶ Sukzessive Approximation von $y = \sqrt{x}$ gemäß

$$y_{n+1} = \frac{y_n + x/y_n}{2}$$

- ▶ quadratische Konvergenz in der Nähe der Lösung
- ▶ Anzahl der gültigen Stellen verdoppelt sich mit jedem Schritt
- ▶ aber langsame Konvergenz fernab der Lösung
- ▶ Lookup-Tabelle und Tricks für brauchbare Startwerte y_0

Transzendente Funktionen: $\sin(x)$ usw.

- ▶ Reduktion auf geeigneten (kleinen) Wertebereich, wenn möglich
- ▶ dort dann Approximation durch Polynom oder rationale Funktion
 - ▶ $\sin(x + n \cdot 2\pi) = \sin(x)$, $\sin(x) = -\sin(-x)$
 - ▶ also im ersten Schritt $x \rightarrow x \bmod 2\pi$
 - ▶ Approximation für $\sin(y)$, Wertebereich $0 \leq y \leq \pi$
- ▶ $\exp(a + b) = \exp(a) \cdot \exp(b)$
- ▶ $\exp x = \exp(\lceil x \rceil) \cdot \exp(\lfloor x \rfloor)$ (Split x in Vor-/Nachkommastellen)
- ▶ Tabelle mit Werten für $\exp(n)$ mit Integer n
- ▶ Polynom für $\exp(y)$, $0 \leq y \leq 1$
- ▶ vorberechnete Koeffizienten für maximale Genauigkeit
- ▶ Genauigkeit typisch $\pm 2\text{ULP}$ über gesamten Wertebereich

Vorsicht mit Rundungsfehlern/Auslöschung

► $\exp(x) = 1 + x + x^2/2! + x^3/3! + \dots$

```
public class NaiveTaylorExponential {           // don't use this!!!
    public static void main(String[] args) {
        double x = Double.parseDouble(args[0]);
        double sum = 0.0;
        double term = 1.0;
        for (int i = 1; sum != sum + term; i++) {
            sum = sum + term;
            term = term * x / i;
            System.out.println(i + " " + term + " " + sum);
        }
        System.out.println(sum);
        System.out.println(Math.exp(x));
    }
}
```

<http://introcs.cs.princeton.edu/java/91float/Exponential.java.html>

Vorsicht mit Rundungsfehlern/Auslöschung

```
/* Naively compute the e^x using the Taylor series:  
 * e^x = 1 + x + x^2/2! + x^3/3! + ...  
 * and compare with Math.exp(). Catastrophic cancelation occurs  
 * if x is a large negative number. */  
% java NaiveTaylorExponential 1  
2.7182818284590455  
2.7182818284590455  
  
% java NaiveTaylorExponential 50  
5.184705528587075E21  
5.184705528587072E21  
  
% java NaiveTaylorExponential -1  
0.36787944117144245  
0.36787944117144233  
  
% java NaiveTaylorExponential -50  
11072.93338289197  
1.9287498479639178E-22
```

Informationstreue

Welche mathematischen Eigenschaften gelten bei der Informationsverarbeitung / in der gewählten Repräsentation?

Beispiele:

- ▶ Gilt $x^2 \geq 0$?
 - ▶ float: ja
 - ▶ signed integer: nein

 - ▶ Gilt $(x + y) + z = x + (y + z)$?
 - ▶ integer: ja
 - ▶ float: nein
- 1.0E20 + (-1.0E20 + 3.14) = 0

Festkomma Addition

unsigned Arithmetik

- ▶ Wortbreite auf w begrenzt
- ▶ kommutative Gruppe / Abel'sche Gruppe

- ▶ Abgeschlossenheit $0 \leq a \oplus_w^u b \leq 2^w - 1$
- ▶ Kommutativgesetz $a \oplus_w^u b = b \oplus_w^u a$
- ▶ Assoziativgesetz $a \oplus_w^u (b \oplus_w^u c) = (a \oplus_w^u b) \oplus_w^u c$
- ▶ neutrales Element $a \oplus_w^u 0 = a$
- ▶ Inverses $a \oplus_w^u \bar{a} = 0; \bar{a} = 2^w - a$

Festkomma Addition (cont.)

signed Arithmetik

2-Komplement

- Wortbreite auf w begrenzt
- signed und unsigned Addition sind auf Bit-Ebene identisch

$$a \oplus_w^s b = U2S(S2U(a) \oplus_w^u S2U(b))$$

⇒ isomorphe Algebra zu \oplus_w^u

- kommutative Gruppe / Abel'sche Gruppe

► Abgeschlossenheit $-2^{w-1} \leq a \oplus_w^s b \leq 2^{w-1} - 1$

► Kommutativgesetz $a \oplus_w^s b = b \oplus_w^s a$

► Assoziativgesetz $a \oplus_w^s (b \oplus_w^s c) = (a \oplus_w^s b) \oplus_w^s c$

► neutrales Element $a \oplus_w^s 0 = a$

► Inverses $a \oplus_w^s \bar{a} = 0; \quad \bar{a} = -a, a \neq -2^{w-1}$
 $a, a = -2^{w-1}$

Festkomma Multiplikation

unsigned Arithmetik

- ▶ Wortbreite auf w begrenzt
- ▶ Modulo-Arithmetik $a \otimes_w^u b = (a \cdot b) \bmod 2^w$
- ▶ \otimes_w^u und \oplus_w^u bilden einen kommutativen Ring
 - ▶ \oplus_w^u ist eine kommutative Gruppe
 - ▶ Abgeschlossenheit $0 \leq a \otimes_w^u b \leq 2^w - 1$
 - ▶ Kommutativgesetz $a \otimes_w^u b = b \otimes_w^u a$
 - ▶ Assoziativgesetz $a \otimes_w^u (b \otimes_w^u c) = (a \otimes_w^u b) \otimes_w^u c$
 - ▶ neutrales Element $a \otimes_w^u 1 = a$
 - ▶ Distributivgesetz $a \otimes_w^u (b \oplus_w^u c) = (a \otimes_w^u b) \oplus_w^u (a \otimes_w^u c)$

Festkomma Multiplikation (cont.)

signed Arithmetik

- ▶ signed und unsigned Multiplikation sind auf Bit-Ebene identisch
 - ▶ ...

isomorphe Algebren

- unsigned Addition und Multiplikation; Wortbreite w
 - signed Addition und Multiplikation; Wortbreite w 2-Komplement
 - isomorph zum Ring der ganzen Zahlen *modulo* 2^w
 - Ordnungsrelation im Ring der ganzen Zahlen
 - $a > 0 \rightarrow a + b > b$
 - $a > 0, b > 0 \rightarrow a \cdot b > 0$
 - diese Relationen **gelten nicht** bei Rechnerarithmetik!

Gleitkomma Addition

Vergleich mit kommutativer Gruppe

- ▶ Abgeschlossen? Ja
- ▶ Kommutativ? Ja
- ▶ Assoziativ?
(Überlauf, Rundungsfehler) Nein
- ▶ Null ist neutrales Element? Ja
- ▶ Inverses Element existiert?
(außer für NaN und Infinity) Fast
- ▶ Monotonie? $a \geq b \rightarrow (a + c) \geq (b + c)$
(außer für NaN und Infinity) Fast

Gleitkomma Multiplikation

Vergleich mit kommutativem Ring

- ▶ Abgeschlossen?
(aber Infinity oder NaN möglich) Ja
- ▶ Kommutativ? Ja
- ▶ Assoziativ?
(Überlauf, Rundungsfehler) Nein
- ▶ Eins ist neutrales Element? Ja
- ▶ Distributivgesetz? Nein

- ▶ Monotonie? $a \geq b; c \geq 0 \longrightarrow (a \cdot c) \geq (b \cdot c)$ Fast
(außer für NaN und Infinity)

Literatur

- [1] Randal E. Bryant and David R. O'Hallaron.
Computer systems – A programmers perspective.
Pearson Education Limited, Harlow, third, global ed. edition, 2015.
- [2] Israel Koren.
Computer Arithmetic Algorithms.
CRC Press, Boca Raton, Fla., second edition, 2001.
- [3] Laszlo Korte.
Bsc thesis: Tams tools for elearning.
Bachelorarbeit, Universität Hamburg, Fachbereich Informatik, AB TAMS, 2016.
- [4] Amos R. Omondi.
Computer Arithmetic Systems – Algorithms, Architecture and Implementations.
Prentice-Hall International (UK) Limited, Hemel Hempstead, Herfordshire, 1994.

Literatur (cont.)

[5] Otto Spaniol.

Arithmetik in Rechenanlagen.

B. G. Teubner, Stuttgart, 1976.

[6] Andrew S. Tanenbaum and Todd Austin.

Rechnerarchitektur – Von der digitalen Logik zum Parallelrechner.

Pearson Deutschland GmbH, Hallbergmoos, sixth edition, 2014.