Zwischenkapitel Datentypen und Operationen

Realisierung der Basiselemente in Hardware

ZK.1 Bitvektoren, natürliche Zahlen, ganze Zahlen

Bitvektoren

- kleinste Informationseinheit ist das BIT
- komplexere Informationseinheiten sind durch Bitvektoren darstellbar:
  - 4Bit = Nibble, 8Bit = Byte, 16Bit = Word
    32Bit = Doubleword, 64Bit = Quadword
- Operationen
  - Schiebeoperationen
  - Test Bit i, Set Bit i
  - logische Verknüpfungen (AND, OR, ...)

Schiebeoperationen

- Verschieben eines Operanden um *n* Bitstellen
- Man unterscheidet (gemäß Behandlung der Datenformatgrenzen)
  - logisches Schieben
  - arithmetisches Schieben

- sll/srl (shift left/right logical)
  - Verschieben um *n* Stellen
  - Nachziehen von Nullen
  - herausfallende Bits in Übertragsbit (carry bit)
- sla/sra (shift left/right arithmetic)
  - Verschieben um *n* Stellen
  - zieht von links das Bit mit höchster Wertigkeit nach
  - sla=Mult mit 2^n, sra=Div durch 2^n

Schieben um 1 Bit

- $srl_1(a_{n-1},...,a_0) = (0,a_{n-1},...,a_1)$
- $sll_1(a_{n-1},...,a_0) = (a_{n-2},...,a_0,0)$
- $sra_1(a_{n-1},...,a_0) = (a_{n-1},a_{n-1},...,a_1)$
- $sla_1(a_{n-1},...,a_0) = (a_{n-1},a_{n-3},...,a_1,0)$

Schieberegister

$srl_1(a_{n-1},...,a_0) = (0,a_{n-1},...,a_1)$

sel	op
0	load
1	sla
2	sra
3	srl
4	srl

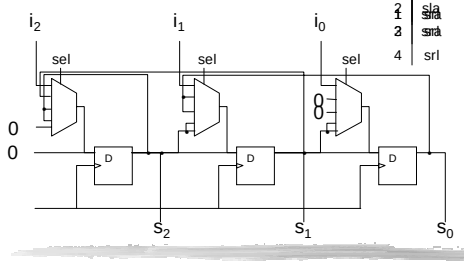

Natürliche Zahlen

- Interpretation des Bitvektors als Dualzahl

  sei $a = (a_{n-1}, a_{n-2},..., a_1, a_0)$

  $nat(a) = 2^{n-1} \cdot a_{n-1} + 2^{n-2} \cdot a_{n-2} + ... + 2 \cdot a_1 + a_0$

- Es gibt auch andere Kodierungen
  - BCD
  - Gray
  - ...

Ganze Zahlen

- Darstellung im Zweierkomplement

  Sei $a = (a_{n-1},..., a_0)$

  $int(a) = -2^{n-1} \cdot a_{n-1} + 2^{n-2} \cdot a_{n-2} + ... + 2 \cdot a_1 + a_0$

- Zweierkomplement von a

  $a' = \bar{a} + 1$

Im Vergleich zu anderen Darstellungen

Darstellung	*redundant / irredundant*	*symmetrischer Zahlenbereich*	*geeignet zum Rechnen*
Betrag und Vorzeichen	**redundant**	**ja**	**bedingt**
Einer-Komplement	**redundant**	**ja**	**gut**
Zweier-komplement	**irredundant**	**nein**	**sehr gut**

Addition

Hardware-Realisierung eines 1-Bit Addition

Inputs			Outputs		
A	B	CarryIn	CarryOut	Sum	Comments
0	0	0	0	0	0 + 0 + 0 = 00
0	0	1	0	1	0 + 0 + 1 = 01
0	1	0	0	1	0 + 1 + 0 = 01
0	1	1	1	0	0 + 1 + 1 = 10
1	0	0	0	1	1 + 0 + 0 = 01
1	0	1	1	0	1 + 0 + 1 = 10
1	1	0	1	0	1 + 1 + 0 = 10
1	1	1	1	1	1 + 1 + 1 = 11

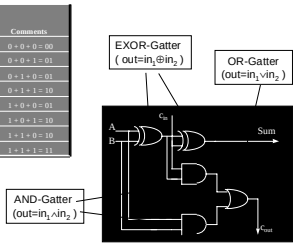

Addition: 32-Bit-Addierer

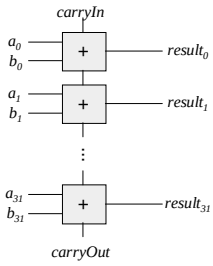

Überlauferkennung

- Bei natürlichen Zahlen: $c_{out} = 1$
- Bei ganzen Zahlen im Zweierkomplement sei $s = a + b$ mit $a = (a_{n-1}, a_{n-2},..., a_1, a_0)$ etc.
  - $a \geq 0$ und $b<0$ oder $a<0$ und $b \geq 0$
    - ➔ kein Überlauf
  - $a \geq 0$ und $b \geq 0$
    - ➔ Überlauf bei $s<0$
  - $a<0$ und $b<0$
    - ➔ Überlauf bei $s \geq 0$

Überlauferkennung

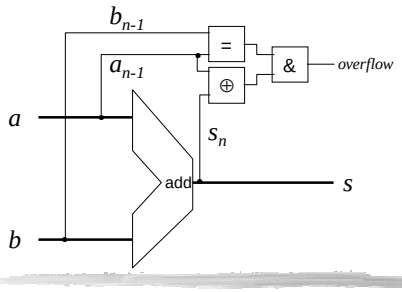

Subtraktion

- Addition mit Zweierkomplement
- Überlauferkennung sei $s = a - b$ mit $a = (a_{n-1}, a_{n-2},..., a_1, a_0)$ etc.
  - $a \geq 0$ und $b \geq 0$ oder $a<0$ und $b<0$
    - ➔ kein Überlauf
  - $a \geq 0$ und $b<0$
    - ➔ Überlauf bei $s<0$
  - $a<0$ und $b \geq 0$
    - ➔ Überlauf bei $s \geq 0$

Überlauferkennung

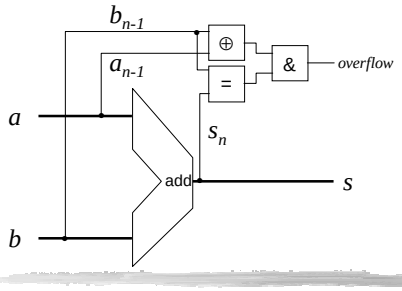

Aufbau einer einfachen ALU

- Logische Grundoperationen auf einem Bit

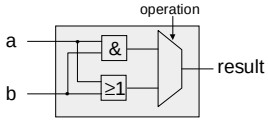

Aufbau einer einfachen ALU

- Addition

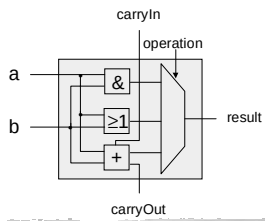

Aufbau einer einfachen ALU

- Zusammenschaltung

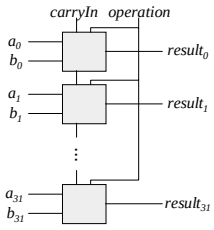

Aufbau einer einfachen ALU

- Subtraktion:

$a - b = a + (-b) = a + (\overline{b} + 1) = a + \overline{b} + 1$

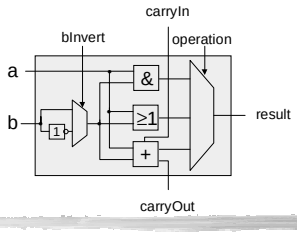

Aufbau einer einfachen ALU

- Vergleich a < b: $a < b \Leftrightarrow a - b < 0$

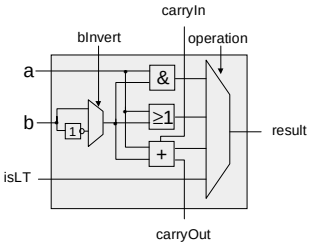

Aufbau einer einfachen ALU

MSB-Zelle

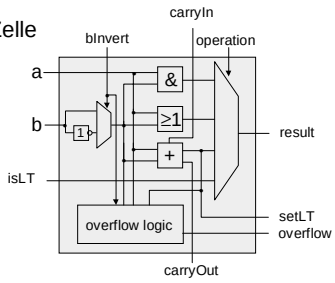

Aufbau einer einfachen ALU

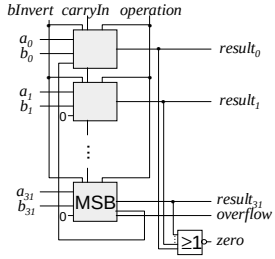

bInvert	carryIn	operation	result
0	-	00	a∧b
0	-	01	a∨b
1	-	00	a∧$\overline{b}$
1	-	01	a∨$\overline{b}$
0	0	10	a+b
0	1	10	a+b+1
1	0	10	a-b-1
1	1	10	a-b
1	1	11	a<b?1:0
...	...	....	...

Multiplikation im Zweierkomplement

Multiplikation nach der Schulmethode

```
0101 * 0011
     0011
    0000
   0011
  0000
 0001111
```

- Bei negativen Zahlen muss zuerst der Betrag gebildet werden, erst dann kann multipliziert werden.
- Verfahren ist ziemlich langsam, da insgesamt *n* Additionen ausgeführt werden, insbesondere Addition mit Null.

Verfahren von Booth

A. Booth. A Signed Binary Multiplication Scheme. Q.J.Mech.Appl.Math. 4:236:240 (1951)

Beobachtung

- Enthält der Multiplikator *y* einen Nullblock der Länge *k*, so kann die Multiplikation durch ein Shift der Zwischensumme um *k* Stellen beschleunigt werden.
- Enthält der Multiplikator *y* einen Einsblock von Stelle *u* bis Stelle *v*, z.B.:

  0.....01.....10.....0
  v *u*

  so können die zum Einsblock gehörigen (*v*-*u*+1) Additionen der Multiplikation nach Schulmethode wegen $int(0\ldots01\ldots10\ldots0)=2^{v+1}-2^u$ durch eine Addition an der Stelle *v*+1 und eine Substraktion an der Stelle *u* ersetzt werden

Verfahren von Booth

$X * Y$ mit $Y = 0\ldots0\overbrace{1\ldots1}^{v\ u}0\ldots0$

add/shift

$X*Y = X2^u+X2^{u+1}+\ldots+X2^v = X\,(2^u+2^{u+1}+\ldots+2^v)$

NR: 00111000 = 00111111 - 00000111
$= (2^{v+1}-1) - (2^u-1) = 2^{v+1}-2^u$

$= X\,(2^{v+1}-2^u) = X2^{v+1} - X2^u$

$Y = 0\ldots01\ldots10\ldots0$
shift shift
add/shift sub/shift

Verfahren von Booth

- Arithmetische Operationen sind nur an den 0→1 und 1→0 Wechsel im Multiplikator erforderlich.
- Man erhält die Rechenvorschrift

y_i	y_{i-1}	Operation
0	0	shift
0	1	add; shift
1	0	sub; shift
1	1	shift

mit $y_{-1}=0$

Verfahren von Booth: Beispiel

x	y_3	y_2	y_1	y_0	Operation	Zwischenergebnis
0010	0	1	1	0		0000
				↑	shift	0000 0
			↑		sub (add 1110)	1110 0
			↑		shift	1111 00
		↑			shift	1111 100
	↑				add 0010	0001 100
	↑				shift	0000 1100

Korrektheit des Verfahrens von Booth

Satz
Das Verfahren von Booth multipliziert sowohl positive als auch negative Zahlen

Beweis
Wir betrachten im Verfahren von Booth an jeder Stelle die Differenz $(y_{i-1}-y_i)$ und berechnen das Multiplikationsergebnisses durch die Summe

$$\begin{aligned} S &= (y_{-1}-y_0)\cdot 2^0\cdot int(x) + \\ &\quad (y_0-y_1)\cdot 2^1\cdot int(x) + \\ &\quad \ldots \\ &\quad (y_{n-3}-y_{n-2})\cdot 2^{n-2}\cdot int(x) + \\ &\quad (y_{n-2}-y_{n-1})\cdot 2^{n-1}\cdot int(x) \\ &= int(x)\cdot(-y_{n-1}\cdot 2^{n-1} + y_{n-2}\cdot 2^{n-2} + \ldots + y_1\cdot 2^1 + y_0\cdot 2^0) \\ &= int(x)\cdot int(y) \end{aligned}$$

Hardwarerealisierung der Methode von Booth

- Multiplikation wird unter der Verwendung der Additionshardware implementiert:

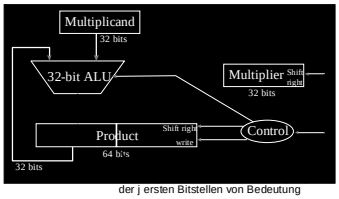

der j ersten Bitstellen von Bedeutung

Billigere Realisierung

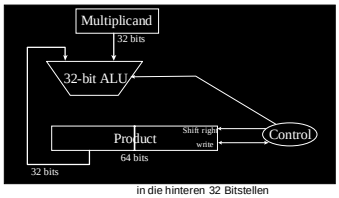

Nachteil dieser Realisierung

- Vorgestellte Realisierung für die *n*-Bit Multiplikation benötigt $\geq n \cdot \log n$ Gatterlaufzeiten unter Benutzung eines schnellen Addierers
- Es gibt effizientere Realisierungen für die *n*-Bit Multiplikation, die mit ungefähr $\log n$ Gatterlaufzeiten auskommen

Division

- Division
  - restoring, non restoring
  - SRT-Division
  - iterative Verfahren: Newton-Verfahren, Goldschmidt-Verfahren

Division

- Schulmethode

```
10011010 : 1110 = 1011
-1110↓↓↓|
  10101|
  -1110↓
    1110
   -1110
    0000
```


Division

- Abgewandelte Schulmethode

```
 10011010 : 1110 = 01...
-1110|                 ↑
 -101|  <0 ————————————|
+1110↓  restore         |
 10011                  |
 -1110                  |
   101  ≥0 ——————————————
   ...
```


Division

- Abgewandelte Schulmethode

```
Divisor  Dividend        Rest           Q
10011010-111000000000 = -110101100110 ⇒ 0
10011010- 11100000000 = -011001100110 ⇒ 0
10011010-  1110000000 = -001011100110 ⇒ 0
10011010-   111000000 = -000100100110 ⇒ 0
10011010-    11100000 = -000001000110 ⇒ 0
10011010-     1110000 =  000000101010 ⇒ 1
00101010-      111000 = -000000001110 ⇒ 0
00101010-       11100 =  000000001110 ⇒ 1
00001110-        1110 =  000000000000 ⇒ 1
```

Divisionswerk

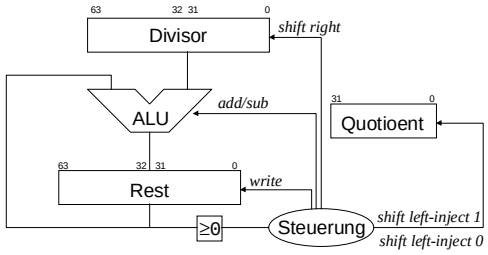

Divisionswerk - Steuerung

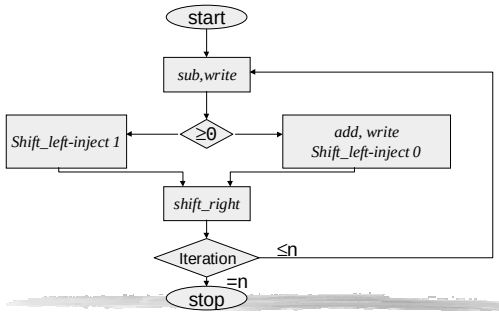

- wrap-around Arithmetik: Überträge werden weggelassen
- bei Audio-, Videoanwendungen: Ausgabe des größten darstellbaren Wertes besser

  ---> Sättigungsarithmetik

  auf sie kann bei vielen Prozessoren für die digitale Signalverarbeitung umgeschaltet werden

	Wrap-around Arithmetik	Sättigungs-Arithmetik
a	"1000"	"1000"
b	"1000"	"1000"
a+b	"0000"	"1111"

Probleme mit Festkommazahlen

Bei Zweierkomplement-Darstellung mit *n* Stellen vor und *k* hinter dem Komma

- keine ganz grossen bzw. kleinen Zahlen darstellbar !
  Zahlen mit grösstem Absolutbetrag: $(2^{n+k-1}-1)/2^k$ und -2^{n-1}
  z.B. 0111.1111_b = 7.9375 und 1000.0000_b = -8
  Zahlen mit kleinstem Absolutbetrag: -2^{-k} und 2^{-k}
  z.B. 0000.0001_b = 0.0625 und 1111.1111_b = -0.0625
- Operationen sind nicht abgeschlossen !
  $2^{n-1}+2^{n-1}$ ist nicht darstellbar, obwohl die Operanden darstellbar sind.
- Assoziativgesetz und Distributivgesetz gelten nicht !
  $(2^{n-1}+2^{n-1})-2^{n-1} \neq 2^{n-1}+(2^{n-1}-2^{n-1})$

ZK.2 Gleitkommazahlen

Gleitkommadarstellung

Idee: Repräsentiere Zahl durch Vorzeichen, Exponent und Mantisse, Position des Kommas liegt also nicht fest!
Abdeckung eines größeren Zahlenbereichs bei gegebener Stellenanzahl

- Gleitkommadarstellung einfacher Genauigkeit: $(-1)^S \cdot M \cdot 2^E$

31	30 29 28 27 26 25 24 23	22 21 . . . 3 2 1 0
S	Exponent E	Mantisse M

- Gleitkommadarstellung doppelter Genauigkeit: $(-1)^S \cdot M \cdot 2^E$

63	62 61 . . . 53 52	51 50 . . . 3 2 1 0
S	Exponent E	Mantisse M

- Es bleibt noch festzulegen, wie die Mantissenbits bzw. Exponentenbits als Zahlen M bzw. E interpretiert werden sollen.

Normalisierte Gleitkommadarstellungen

Beobachtung
Gleitkommadarstellung einer Zahl ist nicht eindeutig !
$0.111 \cdot 2^3 = 0.0111 \cdot 2^4$

Definition
Eine Gleitkommazahl (S,M,E) heisst **normalisiert**, wenn $1 \le M < 2$
d.h. wenn M von der Form $1.m_{-1} \ldots m_{-k}$ ist.

Die 1 vor dem Komma braucht nicht abgespeichert zu werden (→ „**hidden bit**")

31	30 29 28 27 26 25 24 23	22 21 . . . 3 2 1 0
S	Exponent E	Mantisse m
		$m_{-1}\, m_{-2} \ldots \ldots m_{23}$

Für eine normalisierte Gleitkommazahl ergibt sich der Mantissenwert M als $M = 1 + \Sigma_{i=-1,\ldots,-k} m_i 2^i$.

⇒ Die Zahl 0 muß als Spezialfall behandelt werden !

Gleitkommadarstellung - IEEE 754 Standard

31	30 29 28 27 26 25 24 23	22 21 . . . 3 2 1 0
S	Exponent E	Mantisse m
	$e_7\, e_6 \ldots e_0$	

- Gemäß IEEE 754-Standard werden die Exponentenbits als vorzeichenlose Zahl interpretiert.
- Um auch negative Exponenten darstellen zu können, wird von der Interpretation als vorzeichenlose Zahl eine Konstante, der sogenannte **Bias**, subtrahiert.
- Bei n Exponentenbits wird der Bias gewählt als $\mathbf{BIAS = 2^{n-1}-1}$, also bei einfacher Genauigkeit BIAS = 127, bei doppelter Genauigkeit BIAS = 1023.
- Bei n Exponentenbits ergibt sich also für E:

$$E = \Sigma_{i=0,\ldots,n-1} e_i 2^i - BIAS$$

Sonderfälle IEEE 754 Standard

- **Der Exponent 0 spielt beim IEEE 754-Standard eine Sonderrolle**: Sind alle Exponentenbits 0, so wird **ausnahmsweise** das „hidden bit" der Mantissendarstellung weggelassen, so daß die Zahl

$$(\Sigma_{i=-1,\ldots,-k} m_i 2^i)\, 2^{-126}$$

dargestellt wird.

- Auf diese Weise können „**denormalisierte Zahlen**" dargestellt werden, die kleiner als die kleinste darstellbare normalisierte Zahl sind.
- Die **Null** wird folgendermaßen dargestellt: Sämtliche Mantissenbits und Exponentenbits sind 0.
- **Der Exponent 2^n-1 spielt ebenfalls eine Sonderrolle**: Sind alle Exponentenbits 1 und alle Mantissenbits 0, so wird der Wert ∞ dargestellt.

IEEE 754 Standard - Spezialfälle

Normalisierte Zahl	±	0 < e < 255 (4095)	m beliebig
Denormalisierte Zahl	±	0	m ≠ 0 beliebig
Null	±	0	0
Unendlich	±	255 (4095)	0
Not a Number	±	255 (4095)	m ≠ 0 beliebig

Darstellbare normalisierte Gleitkommazahlen

	single precision	double precision
Vorzeichenstellen	1	1
Exponentenstellen	8	11
Mantissenstellen (ohne hidden Bit)	23	52
Bitstellen insgesamt	32	64
Bias	127	1023
Exponentenbereich	-126 bis 127	-1022 bis 1023
Darstellbare normalisierte Zahl mit kleinstem Absolutbetrag	2^{-126}	2^{-1022}
Darstellbare normalisierte Zahl mit größtem Absolutbetrag	$(1-2^{-24})\, 2^{128}$	$(1-2^{-53})\, 2^{1024}$
Darstellbare denormalisierte Zahl mit kleinstem Absolutbetrag	2^{-149}	2^{-1074}
Darstellbare denormalisierte Zahl mit größtem Absolutbetrag	$(1-2^{-23})\, 2^{-126}$	$(1-2^{-52})\, 2^{-1022}$

IEEE 754 Standard - Eigenschaften

- Eindeutige Zahlendarstellung, falls auf normalisierte Darstellungen beschränkt
- Nicht alle Zahlen zwischen der kleinsten und grössten darstellbaren Zahl sind darstellbar.
- Je näher bei der Null, desto dichter liegen die darstellbaren Zahlen.
- Arithmetische Operationen sind nicht abgeschlossen!
- Assoziativgesetz und Distributivgesetz gelten nicht, da bei Anwendung der Gesetze evtl. der darstellbare Zahlenbereich verlassen wird!

Addition von Gleitkommazahlen

Rechenvorschrift

- Angleichung des kleineren an den grösseren Exponenten
- Addition der Mantissen
- Normalisierung (falls erforderlich)

Beispiel

$+(1.000)_2 \cdot 2^{-1} + -(1.110)_2 \cdot 2^{-2} = +(1.000)_2 \cdot 2^{-1} + -(0.111)_2 \cdot 2^{-1}$

$= +(0.001)_2 \cdot 2^{-1}$

$= +(1.000)_2 \cdot 2^{-4}$

Multiplikation von Gleitkommazahlen

Rechenvorschrift

- Multipliziere die Vorzeichen
- Multipliziere die beiden Mantissen
- Addiere die beiden Exponenten und substrahiere (einmal) den Bias-Wert
- Normalisierung (falls erforderlich)

Beispiel

$+(1.000)_2 \cdot 2^{-1+BIAS} \times -(1.110)_2 \cdot 2^{-2+BIAS}$

Multiplikation der Vorzeichen: $0 \oplus 1 = 1$

Multiplikation der Mantissen: $(1.000)_2 \times (1.110)_2 = (1.110)_2$

Addition der Exponenten: $(-1+BIAS)+(-2+BIAS)-BIAS = (-3+BIAS)$

Resultat: $-(1.110)_2 \cdot 2^{-3+BIAS}$

Multiplikation