

64-040 Modul IP7: Rechnerstrukturen

[http://tams.informatik.uni-hamburg.de/
lectures/2011ws/vorlesung/rs](http://tams.informatik.uni-hamburg.de/lectures/2011ws/vorlesung/rs)

Andreas Mäder



Universität Hamburg
Fakultät für Mathematik, Informatik und Naturwissenschaften
Fachbereich Informatik

Technische Aspekte Multimodaler Systeme

Wintersemester 2011/2012



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Inhalt und Lernziele

- ▶ Wie funktioniert ein Digitalrechner?
- ▶ Warum Mikroprozessoren?

Kennenlernen der Themen:

- ▶ Prinzip des von-Neumann-Rechners
- ▶ Abstraktionsebenen, Hardware/Software-Schnittstelle
- ▶ Rechnerarithmetik, Zahldarstellung, Codierung
- ▶ Prozessor mit Steuerwerk und Operationswerk
- ▶ Speicher und -ansteuerung, Adressierungsarten
- ▶ Befehlsätze, Maschinenprogrammierung
- ▶ Assemblerprogrammierung, Speicherverwaltung

- ▶ Fähigkeit zum Einschätzen zukünftiger Entwicklungen
- ▶ Chancen und Grenzen der Miniaturisierung

Motivation

- ▶ Wie funktioniert ein Digitalrechner?
- ▶ Mikroprozessoren?

Warum ist das überhaupt wichtig?

- ▶ Informatik ohne Digitalrechner undenkbar
- ▶ Grundverständnis der Interaktion von SW und HW
- ▶ zum Beispiel für „performante“ Software
- ▶ Variantenvielfalt von Mikroprozessorsystemen
 - ▶ Supercomputer, Server, Workstations, PCs, ...
 - ▶ Medienverarbeitung, Mobile Geräte, ...
 - ▶ RFID-Tags, Wegwerfcomputer, ...
- ▶ Bewertung von Trends und Perspektiven



Motivation

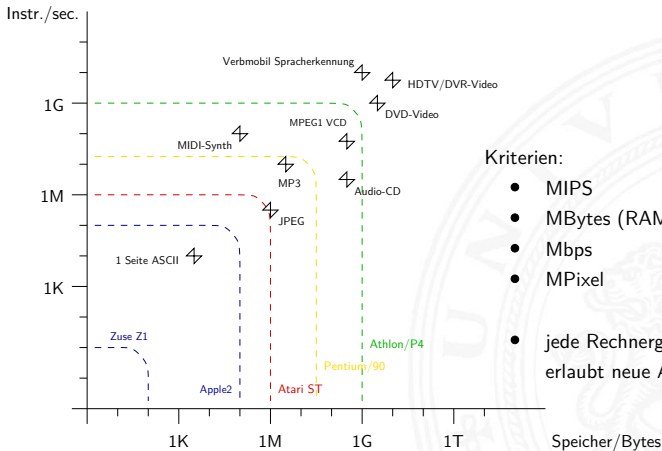
- ▶ ständige Fortschritte in Mikroelektronik und Optoelektronik
- ▶ und zwar weiterhin *exponentielles* Wachstum (50%...100% pro Jahr)
 - ▶ Rechenleistung von Prozessoren („Performance“)
 - ▶ Speicherkapazität (DRAM, SRAM, FLASH)
 - ▶ Speicherkapazität (Festplatten)
 - ▶ Bandbreite (Netzwerke)
- ▶ ständig neue Möglichkeiten und Anwendungen
- ▶ ständig neue Produkte und Techniken
- ▶ und ganz gewiss kein „stationärer Zustand“
- ▶ Roadmaps derzeit bis über 2020 hinaus...



Technologie-Fortschritt

- ▶ exponentielles Wachstum, typisch 50% pro Jahr
 - ▶ ständig neue Möglichkeiten und Anwendungsfelder
 - ▶ ständig neue Produkte und Techniken
-
- ▶ Details zu Rechnerorganisation veralten schnell
 - ▶ aber die Konzepte bleiben gültig (!)
-
- ▶ Schwerpunkt der Vorlesung auf dem „Warum“
 - ▶ bitte ein Gefühl für Größenordnungen entwickeln
-
- ▶ Software entwickelt sich teilweise viel langsamer
 - ▶ LISP seit 1958, Prolog 1972, Smalltalk/OO 1972, usw.

Technologie-Fortschritt: neue Anwendungsfelder



Neue Anwendungsfelder: Beispiel ReBirth



Propellerheads ReBirth 1996, www.rebirthmuseum.com

- ▶ Techno per Software: Echtzeit-Software-Emulation der legendären Roland Synthesizer TB-303 TR-808 TR-909 auf einem PC

Neue Anwendungsfelder: Beispiel Autotune

Sie sehen gut aus, aber Ihr Gesang ist lausig?

**ANTARES AutoTune und ATR-1:
Perfekter Gesang aus der Box**

Sie sehen gut aus, aber Ihr Gesang ist lausig? Kein Problem, denn mit ANTARES Auto Tune als Software oder dem ATR-1 Hardware-Rack wird Ihre Aufnahme trotzdem perfekt!

- 19" Gehäuse
- Datenformat 20 bit linear, 56 bit intern
- Samplingfrequenz 46,875 kHz
- AD-Wandlung 20 bit (103 dB Dynamic Range)
- DA-Wandlung 24 bit (105 dB Dynamic Range)
- freistufig durch MIDI-Steuerung
- Inputs und Outputs:
 - XLR symmetrisch,
 - Klinke symmetrisch/asymmetrisch
- Display: 2 x 20 Zeichen LCD, Korrektur-Indikator 10 x LED, Input-Level 6 x LED

Softwareversionen erhältlich für:

- Stand-alone, TDM und VST für Mac
- DirectX für IBM-incompatible PCs

DM 1.998,-
unveränderliche Preisempfehlung

ANTARES
REALLY GOOD. STUFF FOR MAKING MUSIC.

hyperactive

Hyperactive Audiotechnik GmbH
 Silberlochstraße 9
 05222 Tonnesteln
 Tel. (0 61 28) 98 23 27
 Fax (0 61 28) 98 23 28
 hyperactive@t-online.de

Mitglied im VMDI e.V.
 Fördermitglied des VST

AUTO-TUNE

Antares Autotune 1999



Themen heute

- ▶ Geschichte der Datenverarbeitung
- ▶ Wichtige Beispiele

- ▶ Technologie-Fortschritt, Skalierung
- ▶ Moore's Gesetz, ITRS-Roadmap
- ▶ Grenzen der Miniaturisierung: Smart-Dust

- ▶ Grundprinzip des von-Neumann-Rechners
- ▶ Aufbau, Befehlszyklus, Befehlssatz



Gliederung

1. Einführung
2. Digitalrechner
 - Semantic Gap
 - Abstraktionsebenen
 - Virtuelle Maschine
 - Beispiel: HelloWorld
 - von-Neumann-Konzept
 - Geschichte
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung



Gliederung (cont.)

8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur





Gliederung (cont.)

21. Speicherhierarchie





Definition: Digitalrechner

Tanenbaum: Structured Computer Organization

A digital computer is a machine that can solve problems for people by carrying out instructions given to it. A sequence of instructions describing how to perform a certain task is called a program.

The electronic circuits of each computer can recognize and directly execute a limited set of simple instructions into which all its programs must be converted before they can be executed.

- ▶ Probleme lösen: durch Abarbeiten einfacher **Befehle**
- ▶ Abfolge solcher Befehle ist ein **Programm**
- ▶ Maschine versteht nur ihre eigene **Maschinsprache**



Befehlssatz und Semantic Gap

- ▶ ... *directly execute a limited set of simple instructions.* ...

Typische Beispiele für solche Befehle:

- ▶ addiere die zwei Zahlen in Register R1 und R2
 - ▶ überprüfe, ob das Resultat Null ist
 - ▶ kopiere ein Datenwort von Adresse 13 ins Register R4
- ⇒ extrem niedriges Abstraktionsniveau
- ▶ natürliche Sprache mit Kontextwissen
 Beispiel: „vereinbaren Sie einen Termin mit dem Steuerberater“
 - ▶ **Semantic gap**: Diskrepanz zu einfachen/elementaren Anweisungen
 - ▶ Vermittlung zwischen Mensch und Computer erfordert zusätzliche Abstraktionsebenen und Software



Rechnerarchitektur bzw. -organisation

- ▶ Definition solcher Abstraktionsebenen bzw. Schichten
- ▶ mit möglichst einfachen und sauberen Schnittstellen
- ▶ jede Ebene definiert eine neue (mächtigere) **Sprache**

- ▶ diverse Optimierungs-Kriterien/Möglichkeiten:
 - ▶ Performance, Hardwarekosten, Softwarekosten, ...
 - ▶ Wartungsfreundlichkeit, Stromverbrauch, ...

Achtung / Vorsicht:

- ▶ Gesamtverständnis erfordert Kenntnisse auf allen Ebenen
- ▶ häufig Rückwirkung von unteren auf obere Ebenen



Rückwirkung von unteren Ebenen: Arithmetik

```

public class Overflow {
    ...
    public static void main( String[] args ) {
        printInt( 0 );           // 0
        printInt( 1 );           // 1
        printInt( -1 );          // -1
        printInt( 2+(3*4) );     // 14
        printInt( 100*200*300 ); // 6000000
        printInt( 100*200*300*400 ); // -1894967296 (!)
        printDouble( 1.0 );      // 1.0
        printDouble( 0.3 );      // 0.3
        printDouble( 0.1 + 0.1 + 0.1 ); // 0.30000000000000004 (!)
        printDouble( (0.3) - (0.1+0.1+0.1) ); // -5.5E-17 (!)
    }
}
    
```


Rückwirkung von unteren Ebenen: Performance

```

public static double sumRowCol( double[][] matrix ) {
    int rows = matrix.length;
    int cols = matrix[0].length;
    double sum = 0.0;
    for( int r = 0; r < rows; r++ ) {
        for( int c = 0; c < cols; c++ ) {
            sum += matrix[r][c];
        }
    }
    return sum;
}
    
```

Matrix creation (5000×5000)

2105 msec.

Matrix row-col summation

75 msec.

Matrix col-row summation

383 msec.

⇒ 5x langsamer

Sum = 600.8473695346258 / 600.8473695342268

⇒ andere Werte

Maschine mit mehreren Ebenen

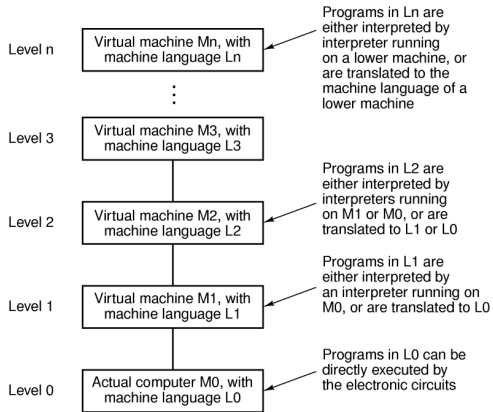


Figure 1-1. A multilevel machine.



Abstraktionsebenen und Sprachen

- ▶ jede Ebene definiert eine neue (mächtigere) Sprache
- ▶ Abstraktionsebene \iff Sprache
- ▶ $L_0 < L_1 < L_2 < L_3 < \dots$

Software zur Übersetzung zwischen den Ebenen

- ▶ **Compiler:**
Erzeugen eines neuen Programms, in dem jeder L1 Befehl durch eine zugehörige Folge von L0 Befehlen ersetzt wird
- ▶ **Interpreter:**
direkte Ausführung der L0 Befehlsfolgen zu jedem L1 Befehl



Virtuelle Maschine

- ▶ für einen Interpreter sind L1 Befehle einfach nur Daten
- ▶ die dann in die zugehörigen L0 Befehle umgesetzt werden

⇒ dies ist gleichwertig mit einer:

Virtuellen Maschine M1 für die Sprache L1

- ▶ ein Interpreter erlaubt es, jede beliebige Maschine zu simulieren
- ▶ und zwar auf jeder beliebigen (einfacheren) Maschine M0
- ▶ Programmierer muss sich nicht um untere Schichten kümmern
- ▶ Nachteil: die virtuelle Maschine ist meistens langsamer als die echte Maschine M1
- ▶ Maschine M0 kann wiederum eine virtuelle Maschine sein (!)
- ▶ unterste Schicht ist jeweils die Hardware

Übliche Einteilung der Ebenen

Anwendungsebene	Hochsprachen (Java, Smalltalk, ...)
Assemblerebene	low-level Anwendungsprogrammierung
Betriebssystemebene	Betriebssystem, Systemprogrammierung
Rechnerarchitektur	Schnittstelle zwischen SW und HW, Befehlssatz, Datentypen
Mikroarchitektur	Steuerwerk und Operationswerk: Register, ALU, Speicher, ...
Logikebene	Grundsaltungen: Gatter, Flipflops, ...
Transistorebene	Transistoren, Chip-Layout
Physikalische Ebene	Elektrotechnik, Geometrien

Beispiel: Sechs Ebenen

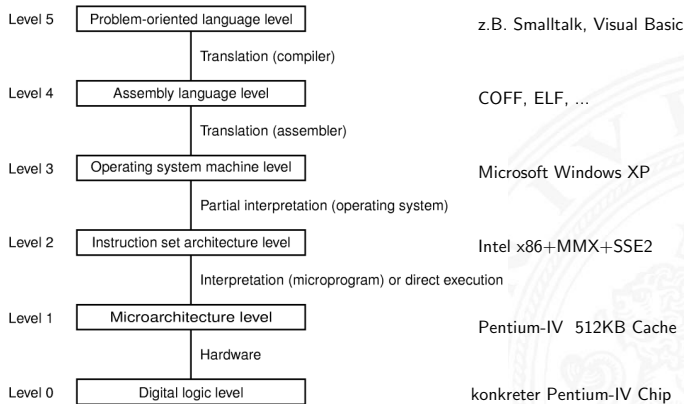


Figure 1-2. A six-level computer. The support method for each level is supported is indicated below it (along with the name of the supporting program).

Hinweis: Ebenen vs. Vorlesungen im BSc-Studiengang

Anwendungsebene: SE1..SE3, AD, ...

Assemblerebene: RS

Betriebssystemebene: GSS

Rechnerarchitektur: RS, RAM

Mikroarchitektur: RS, RAM

Logikebene: RS, RAM

Device-Level: RAM



HelloWorld: Anwendungsebene: Quellcode

```

/* HelloWorld.c - print a welcome message */

#include <stdio.h>

int main( int argc, char ** argv ) {
    printf( "Hello, world!\n" );
    return 0;
}
  
```

Übersetzung

```

gcc -S HelloWorld.c
gcc -c HelloWorld.c
gcc -o HelloWorld.exe HelloWorld.c
  
```




HelloWorld: Assemblerebene: cat HelloWorld.s

```

main:
    leal    4(%esp), %ecx
    andl   $-16, %esp
    pushl  -4(%ecx)
    pushl  %ebp
    movl   %esp, %ebp
    pushl  %ecx
    subl   $4, %esp
    movl   $.LC0, (%esp)
    call   puts
    movl   $0, %eax
    addl   $4, %esp
    popl   %ecx
    popl   %ebp
    leal   -4(%ecx), %esp
    ret
    
```



HelloWorld: Objectcode: od -x HelloWorld.o

```

00000000 457f 464c 0101 0001 0000 0000 0000 0000
00000020 0001 0003 0001 0000 0000 0000 0000 0000
00000040 00f4 0000 0000 0000 0034 0000 0000 0028
00000060 000b 0008 4c8d 0424 e483 fff0 fc71 8955
00000100 51e5 ec83 c704 2404 0000 0000 fce8 ffff
00000120 b8ff 0000 0000 c483 5904 8d5d fc61 00c3
00000140 6548 6c6c 2c6f 7720 726f 646c 0021 4700
00000160 4343 203a 4728 554e 2029 2e34 2e31 2032
00000200 3032 3630 3131 3531 2820 7270 7265 6c65
00000220 6165 6573 2029 5328 5355 2045 694c 756e
00000240 2978 0000 732e 6d79 6174 0062 732e 7274
00000260 6174 0062 732e 7368 7274 6174 0062 722e
00000300 6c65 742e 7865 0074 642e 7461 0061 622e
00000320 7373 2e00 6f72 6164 6174 2e00 6f63 6d6d
00000340 6e65 0074 6e2e 746f 2e65 4e47 2d55 7473
...
    
```

HelloWorld: Disassemblieren: objdump -d HelloWorld.o

```

HelloWorld.o:      file format elf32-i386
Disassembly of section .text:
00000000 <main>:
  0:   8d 4c 24 04          lea    0x4(%esp),%ecx
  4:   83 e4 f0            and    $0xffffffff0,%esp
  7:   ff 71 fc            pushl  0xffffffffc(%ecx)
 a:   55                  push   %ebp
 b:   89 e5                mov    %esp,%ebp
 d:   51                  push   %ecx
 e:   83 ec 04            sub    $0x4,%esp
11:  c7 04 24 00 00 00 00  movl   $0x0,(%esp)
18:  e8 fc ff ff ff      call   19 <main+0x19>
1d:  b8 00 00 00 00      mov    $0x0,%eax
22:  83 c4 04            add    $0x4,%esp
...
    
```



HelloWorld: Maschinencode: od -x HelloWorld.exe

```

00000000 457f 464c 0101 0001 0000 0000 0000 0000
00000020 0002 0003 0001 0000 8310 0804 0034 0000
00000040 126c 0000 0000 0000 0034 0020 0009 0028
00000060 001c 001b 0006 0000 0034 0000 8034 0804
00000100 8034 0804 0120 0000 0120 0000 0005 0000
00000120 0004 0000 0003 0000 0154 0000 8154 0804
00000140 8154 0804 0013 0000 0013 0000 0004 0000
00000160 0001 0000 0001 0000 0000 0000 8000 0804
00000200 8000 0804 04c4 0000 04c4 0000 0005 0000
00000220 1000 0000 0001 0000 0f14 0000 9f14 0804
00000240 9f14 0804 0104 0000 0108 0000 0006 0000
00000260 1000 0000 0002 0000 0f28 0000 9f28 0804
. . .
    
```



Hardware: „Versteinerte Software“

- ▶ eine virtuelle Maschine führt L1 Software aus
 - ▶ und wird mit Software oder Hardware realisiert
- ⇒ Software und Hardware sind logisch äquivalent
„Hardware is just petrified Software“ (K.P.Lentz)
— jedenfalls in Bezug auf L1 Programmausführung

Entscheidung für Software- oder Hardwarerealisierung?

- ▶ abhängig von vielen Faktoren, u.a.
- ▶ Kosten, Performance, Zuverlässigkeit
- ▶ Anzahl der (vermuteten) Änderungen und Updates
- ▶ Sicherheit gegen Kopieren, ...



von-Neumann-Konzept

- ▶ J. Mauchly, J.P. Eckert, J. von-Neumann 1945
- ▶ System mit Prozessor, Speicher, Peripheriegeräten
- ▶ gemeinsamer Speicher für Programme und Daten
- ▶ Programme können wie Daten manipuliert werden
- ▶ Daten können als Programm ausgeführt werden
- ▶ Befehlszyklus: Befehl holen, decodieren, ausführen
- ▶ enorm flexibel
- ▶ **alle** aktuellen Rechner basieren auf diesem Prinzip
- ▶ aber vielfältige Architekturvarianten, Befehlssätze, usw.

von-Neumann Rechner




Figure 1-5. The original von Neumann machine.

Fünf zentrale Komponenten:

- ▶ Prozessor mit **Steuerwerk** und **Rechenwerk** (ALU, Register)
- ▶ **Speicher**, gemeinsam genutzt für Programme und Daten
- ▶ **Eingabe-** und **Ausgabewerke**



von-Neumann Rechner (cont.)

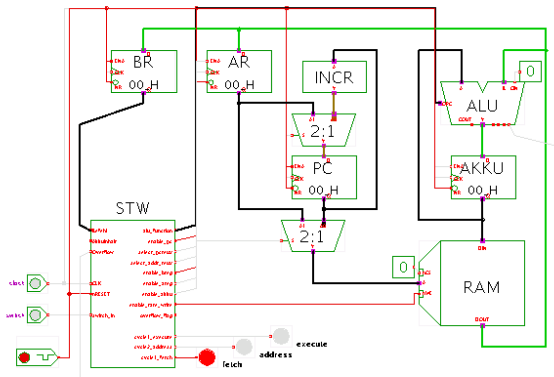
- ▶ Steuerwerk: zwei zentrale Register
 - ▶ Befehlszähler (*program counter PC*)
 - ▶ Befehlsregister (*instruction register IR*)
- ▶ Operationswerk (Datenpfad, *data-path*)
 - ▶ Rechenwerk (*arithmetic-logic unit ALU*)
 - ▶ Universalregister (mindestens 1 *Akkumulator*, typisch 8..64 Register)
 - ▶ evtl. Register mit Spezialaufgaben
- ▶ Speicher (*memory*)
 - ▶ Hauptspeicher/RAM: *random-access memory*
 - ▶ Hauptspeicher/ROM: *read-only memory* zum Booten
 - ▶ Externspeicher: Festplatten, CD/DVD, Magnetbänder
- ▶ Peripheriegeräte (Eingabe/Ausgabe, *I/O*)

PRIMA: die Primitive Maschine

ein (minimaler) 8-bit von-Neumann Rechner

- ▶ RAM: Hauptspeicher 256 Worte à 8-bit
- ▶ vier 8-bit Register:
 - ▶ PC: program-counter
 - ▶ BR: instruction register („Befehlsregister“)
 - ▶ AR: address register (Speicheradressen und Sprungbefehle)
 - ▶ AKKU: accumulator (arithmetische Operationen)
- ▶ eine ALU für Addition, Inkrement, Shift-Operationen
- ▶ ein Schalter als Eingabegerät
- ▶ sehr einfacher Befehlssatz
- ▶ Demo: <http://tams.informatik.uni-hamburg.de/applets/hades/webdemos/50-rtlib/90-prima/chapter.html>


PRIMA: die Primitive Maschine




<http://tams.informatik.uni-hamburg.de/applets/hades/webdemos/50-rtlib/90-prima/chapter.html>

PRIMA: die Zyklen


Befehl holen




decodieren




PC inkrementieren




rechnen



speichern

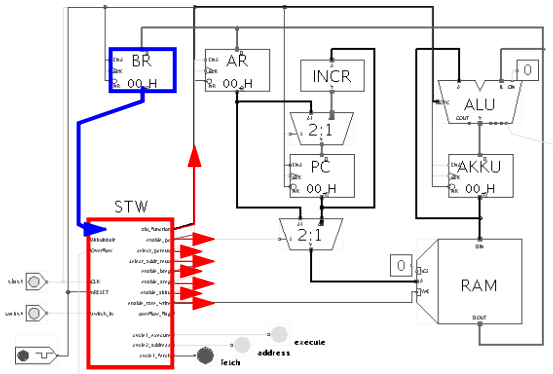


springen

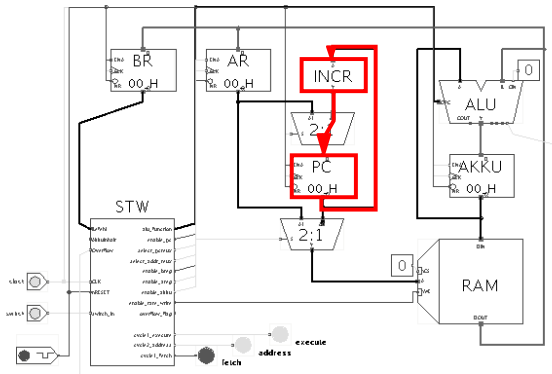


PRIMA: decodieren

Steuersignale = decode(BR)

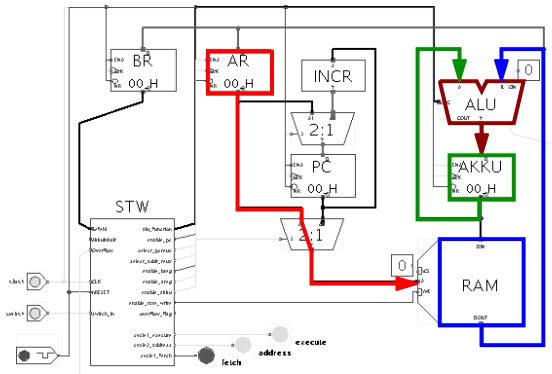


PRIMA: PC inkrementieren

 $PC = PC + 1$


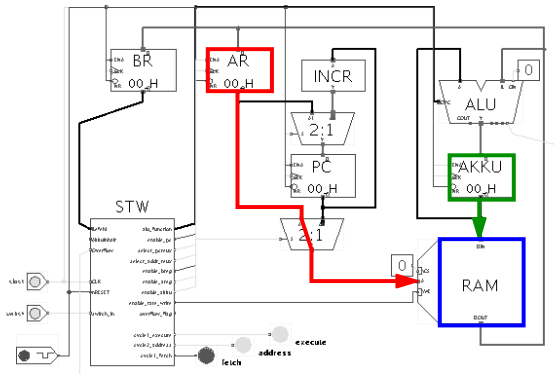
PRIMA: rechnen

Akku = Akku + RAM[AR]



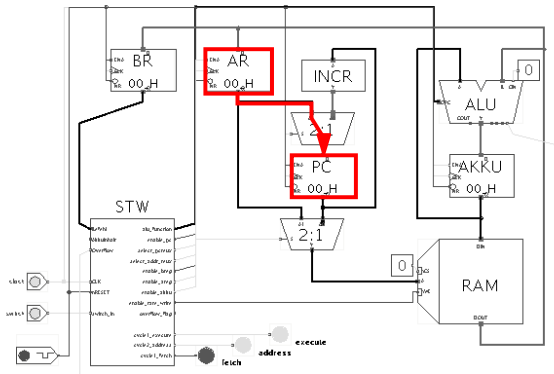
PRIMA: speichern

RAM[AR] = Akku



PRIMA: springen

PC = AR



PRIMA: Simulator

		0	20	40	60	80	100	120	140	160	180	200	220	240	
PC:	238														
AR:	251	0	0	72	128	12	72	0	128	128	1	72	14	131	9
BR:	0	1	0	4	200	0	2	199	108	92	191	191	0	42	252
		2	0	72	9	72	14	0	0	72	137	128	72	72	6
		3	1	5	250	5	0	198	0	193	92	158	250	253	0
AKKU:	0	4	10	14	72	131	72	72	0	14	9	11	9	9	72
OV:	0	5	9	0	101	68	3	197	0	0	189	44	248	252	252
state:	0	6	0	72	9	128	9	127	0	1	0	33	72	193	128
		7	42	3	45	28	8	92	0	193	191	22	251	234	216
		8	10	9	10	9	72	8	0	128	72	11	9	9	0
SW:	<input type="checkbox"/>	9	100	2	0	4	5	0	0	138	171	183	249	250	1
		10	14	72	72	12	128	8	0	14	9	5	72	0	
trace:	<input type="checkbox"/>	11	0	248	45	0	28	0	0	0	0	0	252	251	
hex:	<input type="checkbox"/>	12	72	9	9	72	128	8	9	72	0	0	9	72	0
disassemble:	<input type="checkbox"/>	13	2	3	3	4	92	0	195	192	192	0	254	250	1
		14	9	72	10	131	0	9	1	15	72	7	72	9	9
		15	9	249	0	92	0	121	194	0	192	5	253	251	0
		16	72	9	72	9	0	0	137	72	9	2	9	0	
		17	45	7	3	2	0	196	142	191	191	0	253	251	
		18	9	72	9	10	0	72	72	9	10	22	12	72	
		19	8	221	5	0	0	121	193	190	0	77	0	251	

ADD 251

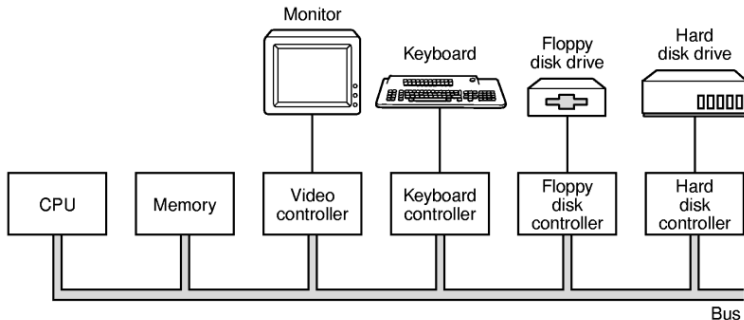
Ablaufprotokoll, '?<center>' für Hilfe...

Cmd>

Takt Befehl 5 Befehle Reset RAM löschen Laden... Sichern...



<http://tams.informatik.uni-hamburg.de/applets/jython/prima.html>

Personal Computer: Aufbau des IBM PC (1981)



- ▶ Intel 8086/8088, 512 KByte RAM, Betriebssystem MS-DOS
- ▶ alle Komponenten über den zentralen („ISA“-) Bus verbunden
- ▶ Erweiterung über Einsteckkarten

Personal Computer: Prototyp (1981) und Hauptplatine



Personal Computer: Aufbau mit PCI-Bus (2000)

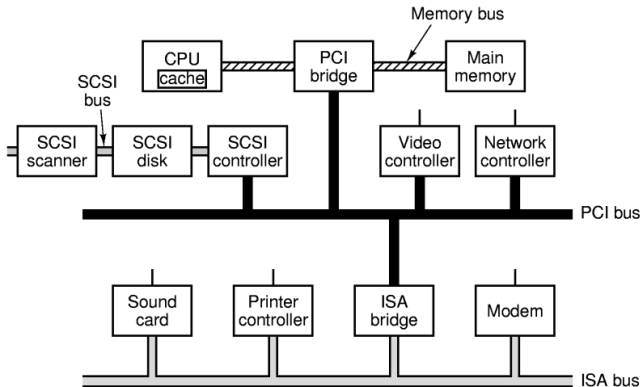



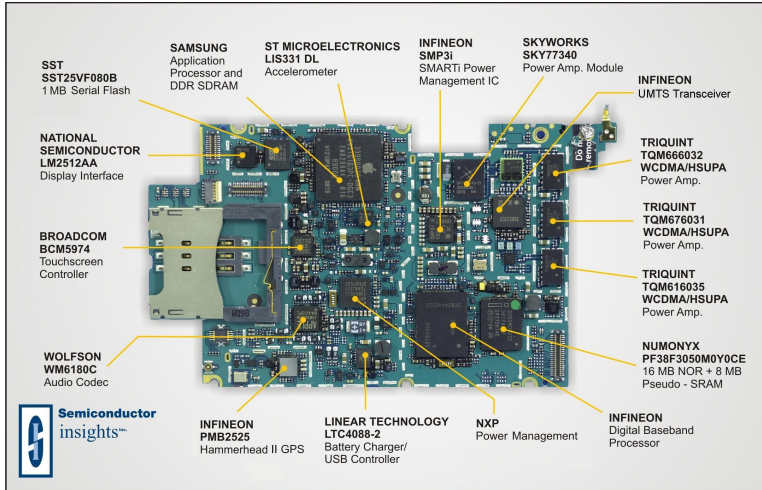
Figure 2-30. A typical modern PC with a PCI bus and an ISA bus. The modem and sound card are ISA devices; the SCSI controller is a PCI device.

Personal Computer: Hauptplatine (2005)



http://de.wikibooks.org/wiki/Computerhardware_für_Anfänger

Mobilgeräte: Smartphone (2010)






Timeline: Vorgeschichte


- ???? Abakus als erste Rechenhilfe
- 1642 Pascal: Addierer/Subtrahierer
- 1671 Leibniz: Vier-Operationen-Rechenmaschine
- 1837 Babbage: Analytical Engine

- 1937 Zuse: Z1 (mechanisch)
- 1939 Zuse: Z3 (Relais, Gleitkomma)
- 1941 Atanasoff & Berry: ABC (Röhren, Magnettrommel)
- 1944 Mc-Culloch Pitts (Neuronenmodell)
- 1946 Eckert & Mauchly: ENIAC (Röhren)
- 1949 Eckert, Mauchly, von Neumann: EDVAC
(erster speicherprogrammierter Rechner)
- 1949 Manchester Mark-1 (Indexregister)

Abakus





Mechanische Rechenmaschinen



- 1623 Schickard: Sprossenrad, Addierer/Subtrahierer
- 1642 Pascal: „Pascalene“
- 1673 Leibniz: Staffelwalze, Multiplikation/Division
- 1774 Philipp Matthäus Hahn: erste gebrauchsfähige „4-Spezies“-Maschine

Difference Engine


Charles Babbage 1822: Berechnung nautischer Tabellen



Original von 1832 und Nachbau von 1989, London Science Museum


Analytical Engine

Charles Babbage 1837-1871: frei programmierbar, Lochkarten, unvollendet




Zuse Z1

Konrad Zuse 1937: 64 Register, 22-bit, mechanisch, Lochfilm




Zuse Z3

Konrad Zuse 1941, 64 Register, 22-bit, 2000 Relays, Lochfilm




Atanasoff-Berry Computer (ABC)

J.V. Atanasoff 1942: 50-bit Festkomma, Röhren und Trommelspeicher, fest programmiert



ENIAC — Electronic Numerical Integrator and Computer

Mauchly & Eckert, 1946: Röhren, Steckbrett-Programm



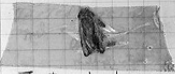
First computer bug

9/2

9/9

0800 Auckan started
 1000 stopped - auckan ✓
 13'00 (033) MP-MC 1.45249000
 (033) PRO 2 2.130476415
 correct 2.130476415
 Relays 6-2 in 033 failed special speed test
 in relay 11,000 test.

1100 Started Cosine Tape (Sine check)
 1525 Started Multi Adder Test.

1545  Relay #70 Panel F
 (moth) in relay.

1630 Auckan started.
 1700 closed down.

Relay #14
 Relay #3


EDVAC

Mauchly, Eckert & von Neumann, 1949: Röhren, speicherprogrammiert



Manchester Mark-1

Williams & Kilburn, 1949: Trommelspeicher, Indexregister



Manchester EDSAC

Wilkes 1951: Mikroprogrammierung, Unterprogramme, speicherprogrammiert





Timeline: Verbesserungen

1952: IBM 701	(Pipeline)
1964: IBM S/360	(Rechnerfamilie, software-kompatibel)
1971: Intel 4004	(4-bit Mikroprozessor)
1972: Intel 8008	(8-bit Mikrocomputer-System)
1979: Motorola 68000	(16/32-bit Mikroprozessor)
1980: Intel 8087	(Gleitkomma-Koprozessor)
1981: Intel 8088	(8/16-bit für IBM PC)
1984: Motorola 68020	(32-bit, Pipeline, on-chip Cache)
1992: DEC Alpha AXP	(64-bit RISC-Mikroprozessor)
1997: Intel MMX	(MultiMedia eXtension Befehlssatz)
2006: Sony Playstation 3	(1+8 Kern-Multiprozessor)
2006: Intel-VT / AMD-V	(Virtualisierung)
...	



erste Computer, ca. 1950:

- ▶ zunächst noch kaum Softwareunterstützung
- ▶ nur zwei Schichten:
 1. Programmierung in elementarer Maschinensprache (ISA level)
 2. Hardware in Röhrentechnik (device logic level)
 - Hardware kompliziert und unzuverlässig

Mikroprogrammierung (Maurice Wilkes, Cambridge, 1951):

- ▶ Programmierung in komfortabler Maschinensprache
- ▶ Mikroprogramm-Steuerwerk (Interpreter)
- ▶ einfache, zuverlässigere Hardware
- ▶ Grundidee der sog. **CISC**-Rechner (68000, 8086, VAX)



erste Betriebssysteme

- ▶ erste Rechner jeweils nur von einer Person benutzt
 - ▶ Anwender = Programmierer = Operator
 - ▶ Programm laden, ausführen, Fehler suchen, usw.
- ⇒ Maschine wird nicht gut ausgelastet
- ⇒ Anwender mit lästigen Details überfordert

Einführung von **Betriebssystemen**


- ▶ „system calls“
- ▶ Batch-Modus: Programm abschicken, warten
- ▶ Resultate am nächsten Tag abholen

zweite Generation: Transistoren

- ▶ Erfindung des Transistors 1948
- ▶ schneller, zuverlässiger, sparsamer als Röhren
- ▶ Miniaturisierung und dramatische Kostensenkung

- ▶ Beispiel Digital Equipment Corporation PDP-1 (1961)
 - ▶ 4K Speicher (4096 Worte á 18-bit)
 - ▶ 200 kHz Taktfrequenz
 - ▶ 120.000 \$
 - ▶ Grafikdisplay: erste Computerspiele
- ▶ Nachfolger PDP-8: 16.000 \$
 - ▶ erstes Bussystem
 - ▶ 50.000 Stück verkauft


J. Bardeen, W. Brattain, W. Shockley



Festplatten

Massenspeicher bei frühen Computern:

- ▶ Lochkarten
 - ▶ Lochstreifen
 - ▶ Magnetband
 - ▶ Magnettrommel
 - ▶ Festplatte
- IBM 350 RAMAC (1956)
5 MByte, 600 ms Zugriffszeit



http://de.wikibooks.org/wiki/Computerhardware_für_Anfänger

dritte Generation: ICs

- ▶ Erfindung der integrierten Schaltung 1958 (Noyce, Kilby)
- ▶ Dutzende... Hunderte... Tausende Transistoren auf einem Chip
- ▶ IBM Serie-360: viele Maschinen, ein einheitlicher Befehlssatz
- ▶ volle Softwarekompatibilität

Property	Model 30	Model 40	Model 50	Model 65
Relative performance	1	3.5	10	21
Cycle time (nsec)	1000	625	500	250
Maximum memory (KB)	64	256	256	512
Bytes fetched per cycle	1	2	4	16
Maximum number of data channels	3	3	4	6

Figure 1-7. The initial offering of the IBM 360 product line.



vierte Generation: VLSI

- ▶ VLSI = *Very Large Scale Integration*
- ▶ ab 10.000+ Transistoren pro Chip
- ▶ gesamter Prozessor passt auf einen Chip
- ▶ steigende Integrationsdichte erlaubt immer mehr Funktionen

1972 Intel 4004: erster Mikroprozessor

1975 Intel 8080, Motorola 6800, MOS 6502, ...

1981 IBM PC („personal computer“) mit Intel 8088

...

- ▶ Massenfertigung erlaubt billige Prozessoren (< 1\$)
- ▶ Miniaturisierung ermöglicht mobile Geräte

Xerox Alto: first workstation



Rechner-Spektrum

Type	Price (\$)	Example application
Disposable computer	1	Greeting cards
Embedded computer	10	Watches, cars, appliances
Game computer	100	Home video games
Personal computer	1K	Desktop or portable computer
Server	10K	Network server
Collection of Workstations	100K	Departmental minisupercomputer
Mainframe	1M	Batch data processing in a bank
Supercomputer	10M	Long range weather prediction

Figure 1-9. The current spectrum of computers available. The prices should be taken with a grain (or better yet, a metric ton) of salt.



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
 - System on a chip
 - Smart Dust
 - Roadmap und Grenzen des Wachstums
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung



Gliederung (cont.)

11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Moore's Law

- ▶ bessere Technologie ermöglicht immer kleinere Transistoren
- ▶ Materialkosten sind proportional zur Chipfläche
- ⇒ bei gleicher Funktion kleinere und billigere Chips
- ⇒ bei gleicher Größe leistungsfähigere Chips


Moore's Law

Gordon Moore, Mitgründer von Intel, 1965

Speicherkapazität von ICs vervierfacht sich alle drei Jahre

- ⇒ schnelles **exponentielles Wachstum**
 - ▶ klares Kostenoptimum bei hoher Integrationsdichte
 - ▶ trifft auch auf Prozessoren zu

Moore's Law (cont.)



Gordon Moore 1965:
 „Cramming more components onto integrated circuits“

Wird das so weitergehen?

- ▶ Vorhersage gilt immer noch
- ▶ „ITRS“ Prognose bis über Jahr 2020 hinaus

Moore's Law: Transistoren pro Speicherchip






Figure 1-8. Moore's law predicts a 60 percent annual increase in the number of transistors that can be put on a chip. The data points given in this figure are memory sizes, in bits.

Moore's Law: Evolution des Intel x86 (bis 2010)



Intel

Moore's Law: Kosten pro Komponente



Originalskizze von G. Moore www.intel.com



Moore's Law: Formel und Beispiele

$$L(t) = L(0) \times 2^{t/18}$$

mit: $L(t)$ = Leistung zum Zeitpunkt t , $L(0)$ = Leistung zum Zeitpunkt 0, und Zeit t in Monaten.

Einige Formelwerte:

Jahr 1:	1,5874
Jahr 2:	2,51984
Jahr 3:	4
Jahr 5:	10,0794
Jahr 6:	16
Jahr 7:	25,3984
Jahr 8:	40,3175

Leistungssteigerung der Spitzenrechner seit 1993

Jahr	Rechner	Linpack in Gflop/s	Zahl der Prozessoren
1993	Fujitsu NWT	124	140
1994	Intel Paragon XP/S MP	281	6.768
1996	Hitachi CP-PACS	368	2.048
1997	Intel ASCI Red (200 MHz Pentium Pro)	1.338	9.152
1998	ASCI Blue-Pacific (IBM SP 640E)	2.144	5.808
1999	ASCI Intel Red (Pentium II Xeon)	2.379	9.632
2000	ASCI White, IBM (SP Power 3)	4.903	7.424
2002	Earth Simulator, NEC	35.610	5.104
2006	JUBL	45.600	16.384
2008	IBM Roadrunner	1.105.000	124.400 ¹
2009	Jaguar am ORNL, Cray	1.759.000	224.162 ²

¹Anzahl der Kerne (6.480 Opteron, 12.960 Cell)

²Anzahl der Kerne (Basis: Opteron)



Moore's Law: Aktuelle Trends

- ▶ Miniaturisierung schreitet weiter fort
- ▶ aber Taktraten erreichen physikalisches Limit
- ▶ steigender Stromverbrauch, zwei Effekte:
 1. Leckströme
 2. proportional zu Taktrate

Entwicklungen

- ▶ 4 GByte Hauptspeicher (und mehr) wird bezahlbar
- ▶ Übergang von 32-bit auf 64-bit Adressierung
- ⇒ Integration mehrerer CPUs auf einem Chip (Dual-/Quad-Core)
- ⇒ zunehmende Integration von Peripheriegeräten
- ⇒ ab 2011: CPU plus leistungsfähiger Grafikchip
- ⇒ **SoC**: „System on a chip“

SoC: System on a chip

Gesamtes System auf einem Chip integriert:

- ▶ ein oder mehrere Prozessoren
- ▶ Befehls- und Daten-Caches für die Prozessoren
- ▶ Hauptspeicher (dieser evtl. auch extern)
- ▶ weitere Speicher für Medien/Netzwerkoperationen
- ▶ Peripherieblöcke nach Kundenwunsch konfiguriert:
 - ▶ serielle und parallele Schnittstellen, I/O-Pins
 - ▶ Displaysteuerung
 - ▶ USB, Firewire, SATA
 - ▶ Netzwerk kabelgebunden (Ethernet)
 - ▶ Funkschnittstellen: WLAN, Bluetooth, GSM/UMTS
 - ▶ Feldbusse: I²C, CAN, ...
- ▶ Handy, Medien-/DVD-Player, WLAN-Router, usw.

SoC Beispiel: Bluetooth-Controller – Chiplayout




Figure 13.9 Bluetooth Baseband Controller die photograph.

Table 13.1 Bluetooth characteristics.

Process	0.25 μm	Transistors	4,300,000	MIPS	12
Metal layers	3	Die area	20 mm^2	Power	75 mW
V _{dd} (typical)	2.5 V	Clock	0–13 MHz	MIPS/W	160

S. Furber, *ARM System-on-Chip Architecture*, 2000

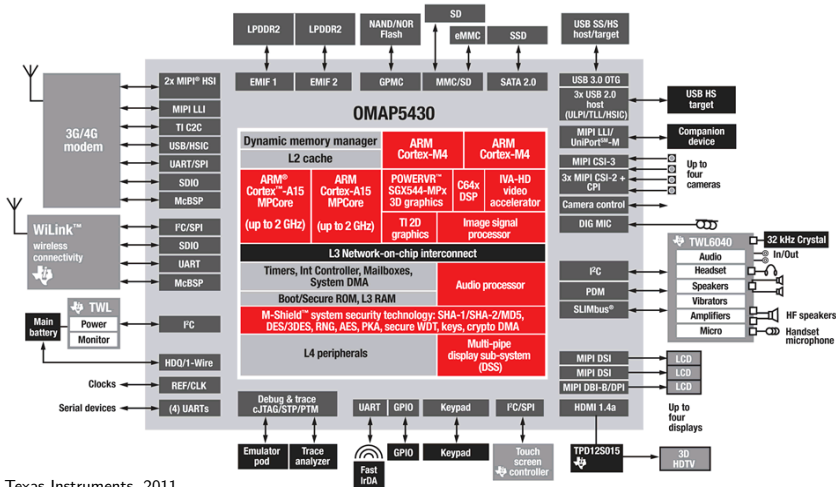
SoC Beispiel: OMAP 5430

- ▶ mehrere (verschiedene) CPUs
- ▶ Grafikbeschleuniger
- ▶ Chipsatz (Speichercontroller, Interconnect, ...)
- ▶ Schnittstellen (WiFi, 4G, USB, Audio, I/O, ...)

OMAP5430 Key Benefits

- Designed to drive Smartphones, Tablets and other multimedia-rich mobile devices
- Multi-core ARM® Cortex™ processors
 - Two ARM Cortex-A15 MPCore processors capable of speeds up to 2 GHz each
 - Two ARM Cortex-M4 processors for low-power offload and real-time responsiveness
- Multi-core POWERVR™ SGX544-MPx graphics accelerators drive 3D gaming and 3D user interfaces
- Dedicated TI 2D BitBlit graphics accelerator
- IVA-HD hardware accelerators enable full HD 1080p60, multi-standard video encode/decode as well as 1080p30 stereoscopic 3D (S3D)
- Faster, higher-quality image and video capture with up to 24 megapixels (or 12 megapixels S3D) imaging and 1080p60 (or 1080p30S3D) video
- Supports four cameras and four displays simultaneously
- Packaging and memory: 14mm x 14mm, 0.4mm pitch PoP dual-channel LPDDR2 memory

SoC Beispiel: OMAP 5430 (cont.)




Texas Instruments, 2011

Smart Dust





Wie klein kann man Computer bauen?

- ▶ Berkeley Projekt: **Smart Dust** 2002-2006
- ▶ Integration kompletter Rechensysteme auf 1 mm^3
 - ▶ vollständiger Digitalrechner CPU, Speicher, I/O
 - ▶ Sensoren Photodioden, Kompass, Gyro
 - ▶ Kommunikation Funk, optisch
 - ▶ Stromversorgung Photozellen, Batterie, Vibration, Mikroturbine
 - ▶ Echtzeit-Betriebssystem Tiny OS
 - ▶ inklusive autonome Vernetzung
- ▶ Massenfertigung? Tausende autonome Mikrorechner
- ▶ „Ausstreuen“ in der Umgebung
- ▶ vielfältige Anwendungen

Smart Dust: Konzept





Smart Dust: Prototypen



diverse Prototypen:

- vollwertige CPU / Sensoren / RF
- "out-door"-tauglich
- MEMS-"CCR" für opt. Kommunikation

Smart Dust: Corner-cube reflector („Katzenaugen“)



- ▶ CCR: seitlich zwei starre Spiegel, Gold auf Silizium
- ▶ untere Spiegelfläche beweglich (elektrostatisch, ca. 30 V)
- ▶ gezielte Modulation von eingestrahlttem Laserlicht
- ▶ Reichweiten > 100 m demonstriert

Smart Dust: Energieverbrauch

Miniatur-Solarzellen
 Wirkungsgrad ca. 3%
 26 $\mu\text{W}/\text{mm}^2$ in vollem Sonnenlicht



Batterien:	$\sim 1\text{J}/\text{mm}^2$	
Kondensatoren:	$\sim 10\text{ mJ}/\text{mm}^2$	
Solarzellen:	$\sim 0.1\text{ mW}/\text{mm}^2$	$\sim 1\text{J}/\text{mm}^2/\text{day}$ (außen,Sonne)
	$\sim 10\text{ }\mu\text{W}/\text{mm}^2$	$\sim 10\text{mJ}/\text{mm}^2/\text{day}$ (innen)
Digitalschaltung	1 nJ/instruction	(StrongArm SA1100)
Analoger Sensor	1 nJ/sample	
Kommunikation	1 nJ/bit	(passive transmitter, s.u.)
opt. digitale ASICs:	$\sim 5\text{ pJ}/\text{bit}$	(LFSR Demonstrator, 1.4V)



Grenzen des Wachstums

- ▶ Jeder exponentielle Verlauf stößt irgendwann an natürliche oder wirtschaftliche Grenzen.
- ▶ Beispiel: eine DRAM-Speicherezelle speichert derzeit etwa 100.000 Elektronen. Durch die Verkleinerung werden es mit jeder neuen Technologiestufe weniger.
- ▶ Offensichtlich ist die Grenze spätestens erreicht, wenn nur noch ein einziges Elektron gespeichert würde.
- ▶ Ab diesem Zeitpunkt gibt es bessere Performance nur noch durch bessere Algorithmen / Architekturen
- ▶ Annahme: 50 % Wachstum pro Jahr, $a^b = \exp(b \cdot \ln a)$
- ▶ Elektronen pro Speicherezelle: $100000 / (1.5^{x/\text{Jahre}}) \geq 1$.
- ▶ $x = \ln(100.000) / \ln(1.5) \approx 28$ Jahre

Roadmap: ITRS

International **T**echnology **R**oadmap for **S**emiconductors

<http://www.itrs.net/reports.html>

- ▶ non-profit Organisation
- ▶ diverse Fördermitglieder
 - ▶ Halbleiterhersteller
 - ▶ Geräte-Hersteller
 - ▶ Unis, Forschungsinstitute
 - ▶ Fachverbände aus USA, Europa, Asien
- ▶ Jährliche Publikation einer langjährigen Vorhersage
- ▶ Zukünftige Entwicklung der Halbleitertechnologie
- ▶ Komplexität typischer Chips (Speicher, Prozessoren, SoC, ...)
- ▶ Modellierung, Simulation, Entwurfssoftware



Moore's Law: Schöpferische Pause

Beispiel für die Auswirkung von Moore's Law.

Angenommen die Lösung einer Rechenaufgabe dauert derzeit vier Jahre, und die Rechenleistung wächst jedes Jahr um 60%.

Wie lösen wir das Problem ?



Moore's Law: Schöpferische Pause

Beispiel für die Auswirkung von Moore's Law.

Angenommen die Lösung einer Rechenaufgabe dauert derzeit vier Jahre, und die Rechenleistung wächst jedes Jahr um 60%.

Ein mögliches Vorgehen ist dann das folgende:

- ▶ Wir warten drei Jahre, kaufen dann einen neuen Rechner und erledigen die Rechenaufgabe in einem Jahr.
- ▶ *Wie das ?*



Moore's Law: Schöpferische Pause

Beispiel für die Auswirkung von Moore's Law.

Angenommen die Lösung einer Rechenaufgabe dauert derzeit vier Jahre, und die Rechenleistung wächst jedes Jahr um 60 %.

Ein mögliches Vorgehen ist dann das folgende:

- ▶ Wir warten drei Jahre, kaufen dann einen neuen Rechner und erledigen die Rechenaufgabe in einem Jahr.
- ⇒ Nach einem Jahr können wir einen Rechner kaufen, der um den Faktor 1,6 Mal schneller ist, nach zwei Jahren bereits $1,6 \times 1,6$ Mal schneller, und nach drei Jahren (also am Beginn des vierten Jahres) gilt $(1 + 60\%)^3 = 4,096$.
- ▶ Wir sind also sogar ein bisschen schneller fertig, als wenn wir den jetzigen Rechner die ganze Zeit durchlaufen lassen.



Wie geht es jetzt weiter?

Ab jetzt erst mal ein *bottom-up* Vorgehen: Start mit grundlegenden Aspekten, dann Kennenlernen aller Komponenten des Digitalrechners und Konstruktion eines vollwertigen Rechners.

- ▶ Grundlagen der Repräsentation von Information
- ▶ Darstellung von Zahlen und Zeichen
- ▶ arithmetische und logische Operationen
- ▶ ...

- ▶ Vorkenntnisse nicht nötig (aber hilfreich)

Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. **Information**
 - Definition und Begriff
 - Informationsübertragung
 - Zeichen
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung





Gliederung (cont.)

11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Information

- ▶ **Information** \sim abstrakter Gehalt einer Aussage
- ▶ Die Aussage selbst, mit der die Information dargestellt bzw. übertragen wird, ist eine **Repräsentation** der Information
- ▶ Das Ermitteln der Information aus einer Repräsentation heißt **Interpretation**
- ▶ Das Verbinden einer Information mit ihrer Bedeutung in der realen Welt heißt **Verstehen**

Repräsentation (Beispiele)

Beispiel: Mit der Information „25“ sei die abstrakte Zahl gemeint, die sich aber nur durch eine Repräsentation angeben lässt:

- ▶ Text deutsch: fünfundzwanzig
- ▶ Text englisch: twentyfive
- ...
- ▶ Zahl römisch: XXV
- ▶ Zahl dezimal: 25
- ▶ Zahl binär: 11001
- ▶ Zahl Dreiersystem: 221
- ...
- ▶ Morse-Code: . . . - - -



Information vs. Interpretation

- ▶ Wo auch immer Repräsentationen auftreten, meinen wir eigentlich die Information, z.B.:

$$5 \cdot (2 + 3) = 25$$

- ▶ Die Information selbst kann man überhaupt nicht notieren (!)
- ▶ Es muss immer Absprachen geben über die verwendete Repräsentation. Im obigen Beispiel ist implizit die Dezimaldarstellung gemeint, man muss also die Dezimalziffern und das Stellenwertsystem kennen.
- ▶ Repräsentation ist häufig mehrstufig, z.B.

Zahl:	Dezimalzahl	347
Ziffer:	4-bit binär	0011 0100 0111
Bit:	elektrische Spannung	0.1V 0.1V 3.3V 3.3V ...



Repräsentation vs. Ebenen

In jeder (Abstraktions-) Ebene gibt es beliebig viele Alternativen der Repräsentation

- ▶ Auswahl der jeweils effizientesten Repräsentation
- ▶ unterschiedliche Repräsentationen je nach Ebene

- ▶ Beispiel: Repräsentation der Zahl $\pi = 3.1415 \dots$ im
 - ▶ x86 Prozessor 80-bit Binärdaten, Spannungen
 - ▶ Hauptspeicher 64-bit Binärdaten, Spannungen
 - ▶ Festplatte codierte Zahl, magnetische Bereiche
 - ▶ CD-ROM codierte Zahl, Land/Pits-Bereiche
 - ▶ Papier Text, „3.14159265...“
 - ▶ ...

Information vs. Nachricht

▶ Aussagen

N1 Er besucht General Motors

N2 Unwetter am Alpenostrand

N3 Sie nimmt ihren Hut

▶ Alle Aussagen sind aber doppel/mehrdeutig:

N1 Firma? Militär?

N2 Alpen-Ostrand? Alpeno-Strand?

N3 tatsächlich oder im übertragenen Sinn?


⇒ **Interpretation:** Es handelt sich um drei **Nachrichten**, die jeweils zwei verschiedene **Informationen** enthalten



Information vs. Repräsentation

- ▶ **Information:** Wissen um oder Kenntnis über Sachverhalte und Vorgänge (Der Begriff wird nicht informationstheoretisch abgestützt, sondern an umgangssprachlicher Bedeutung orientiert).
- ▶ **Nachricht:** Zeichen oder Funktionen, die Informationen zum Zweck der Weitergabe aufgrund bekannter oder unterstellter Abmachungen darstellen (DIN 44 300).
- ▶ Beispiel für eine Nachricht: Temperaturangabe in Grad Celsius oder Fahrenheit.
- ▶ Die Nachricht ist also eine Darstellung von Informationen und nicht der Übermittlungsvorgang.


Beispiel: Binärwerte in 5 V-CMOS-Technologie



Klaus von der Heide,
 Interaktives Skript T1, demobitrep

- ▶ Spannungsverlauf des Signals ist kontinuierlich
- ▶ Abtastung zu bestimmten Zeitpunkten
- ▶ Quantisierung über abgegrenzte Wertebereiche:
 - ▶ $0.0\text{ V} \leq a(t) \leq 1.2\text{ V}$: Interpretation als 0
 - ▶ $3.3\text{ V} \leq a(t) \leq 5.0\text{ V}$: Interpretation als 1
 - ▶ außerhalb und innerhalb: ungültige Werte

Modell der Informationsübertragung




Beschreibung der **Informationsübermittlung**:

- ▶ die Nachricht N_1 entsteht durch Abbildung α aus der Information I_1
- ▶ Übertragung der Nachricht an den Zielort
- ▶ Umkehrabbildung α^{-1} aus der Nachricht N_2 liefert die Information I_2



Nachrichtentechnisches Modell der Informationsübertragung

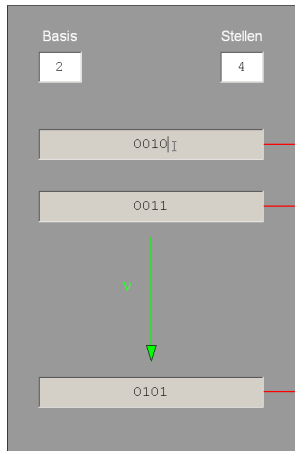


Beispiele für **Störungen**:

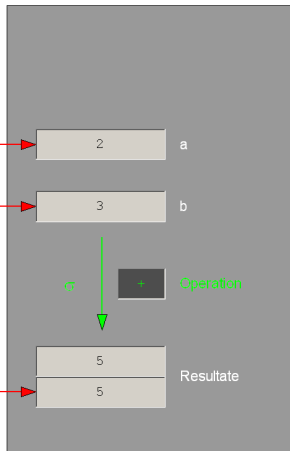
- ▶ Bitfehler beim Speichern
- ▶ Störungen beim Funkverkehr
- ▶ Schmutz oder Kratzer auf einer CD/DVD
- ▶ usw.

Demo: Information vs. Repräsentation

Repräsentation



Information



Klaus von der Heide,
Interaktives Skript T1,
infopres



Informationstreue

Ergibt α gefolgt von σ dasselbe wie ν gefolgt von α' ,
 dann heißt ν **informationstreu**.

- ▶ mit α' als der Interpretation des Resultats der Operation ν
- ▶ häufig sind α und α' gleich, aber nicht immer
- ▶ σ injektiv: **Umschlüsselung**
- ▶ ν injektiv: **Umcodierung**
- ▶ σ innere Verknüpfung der Menge \mathcal{J} und ν innere Verknüpfung der Menge \mathcal{R} : dann ist α ein Homomorphismus der algebraischen Strukturen (\mathcal{J}, σ) und (\mathcal{R}, ν) .
- ▶ σ bijektiv: Isomorphismus



Informationstreue (cont.)

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

$$1.0E20 + (-1.0E20 + 3.14) = 0$$

▶ Details: später



Beschreibung von Information durch Zeichen

- ▶ **Zeichen** (engl. *character*): Element z aus einer zur Darstellung von Information vereinbarten, einer Abmachung unterliegenden, endlichen Menge Z von Elementen.
- ▶ Die Menge heißt **Zeichensatz** oder **Zeichenvorrat** (engl. *character set*).
- ▶ Beispiel:
 - ▶ $Z_1 = \{0, 1\}$
 - ▶ $Z_2 = \{0, 1, 2, \dots, 9, A, B, C, D, E, F\}$
 - ▶ $Z_3 = \{\alpha, \beta, \gamma, \dots, \omega\}$
 - ▶ $Z_4 = \{\text{CR}, \text{LF}\}$



Binärzeichen

- ▶ **Binärzeichen** (engl. *binary element*, *binary digit*, *bit*):
Jedes der Zeichen aus einem Vorrat / aus einer Menge von zwei Symbolen.
- ▶ Beispiel:
 - ▶ $Z_1 = \{0, 1\}$
 - ▶ $Z_2 = \{\text{high}, \text{low}\}$
 - ▶ $Z_3 = \{\text{rot}, \text{grün}\}$
 - ▶ $Z_4 = \{+, -\}$



Alphabet

- ▶ **Alphabet** (engl. *alphabet*): Ein in vereinbarter Reihenfolge geordneter Zeichenvorrat $\mathcal{A} = \mathcal{Z}$
- ▶ Beispiel:
 - ▶ $\mathcal{A}_1 = \{0,1,2,\dots, 9\}$
 - ▶ $\mathcal{A}_2 = \{\text{So,Mo,Di,Mi,Do,Fr,Sa}\}$
 - ▶ $\mathcal{A}_3 = \{'A', 'B', \dots, 'Z'\}$
- ▶ **Numerischer Zeichensatz**: Zeichenvorrat aus Ziffern und/oder Sonderzeichen zur Darstellung von Zahlen
- ▶ **Alphanumerischer Zeichensatz**: Zeichensatz aus (mindestens) den Dezimalziffern und den Buchstaben des gewöhnlichen Alphabets, meistens auch mit Sonderzeichen (Leerzeichen, Punkt, Komma usw.)



Zeichenkette

- ▶ **Zeichenkette** (engl. *string*): Eine Folge von Zeichen
- ▶ **Wort** (engl. *word*): Eine Folge von Zeichen, die in einem gegebenen Zusammenhang als Einheit bezeichnet wird. Worte mit 8 Bit werden als **Byte** bezeichnet.
- ▶ **Stelle** (engl. *position*): Die Lage/Position eines Zeichens innerhalb einer Zeichenkette.
- ▶ Beispiel
 - ▶ `s = H e l l o , w o r l d !`



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information

- 5. Zahldarstellung**

Konzept der Zahl

Stellenwertsystem

Umrechnung zwischen verschiedenen Basen

Zahlenbereich und Präfixe

Festkommazahlen

Darstellung negativer Zahlen

Gleitkomma und IEEE 754

Maschinenworte



Gliederung (cont.)

Literatur

6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur





Gliederung (cont.)

- 18. Instruction Set Architecture
- 19. Assembler-Programmierung
- 20. Computerarchitektur
- 21. Speicherhierarchie





Darstellung von Zahlen und Zeichen: Übersicht

- ▶ Natürliche Zahlen (engl. *integer numbers*)
- ▶ Festkommazahlen (engl. *fixed point numbers*)
- ▶ Gleitkommazahlen (engl. *floating point numbers*)

- ▶ Aspekte der Textcodierung
- ▶ Ad-hoc Codierungen
- ▶ ASCII und ISO-8859-1
- ▶ Unicode

- ▶ Pointer (Referenzen, Maschinenadressen)



Konzept der Zahl


- ▶ das Messen ist der Ursprung der Zahl
- ▶ als Abstraktion der Anzahl von Objekten
- ▶ die man abzählen kann
- ▶ Anwendung des Distributivgesetzes:

$$2 \text{ Äpfel} + 5 \text{ Äpfel} = 7 \text{ Äpfel}$$

$$2 \text{ Birnen} + 5 \text{ Birnen} = 7 \text{ Birnen}$$

...

$$\Rightarrow 2 + 5 = 7$$





Eigenschaften eines Zahlensystems

- ▶ Zahlenbereich: kleinste und größte darstellbare Zahl?
- ▶ Darstellung negativer Werte?
- ▶ Darstellung gebrochener Werte?
- ▶ Darstellung sehr großer Werte?

- ▶ Unterstützung von Rechenoperationen?
Addition, Subtraktion, Multiplikation, Division, etc.
- ▶ Abgeschlossenheit unter diesen Operationen?

- ▶ Methode zur dauerhaften Speicherung/Archivierung?
- ▶ Sicherheit gegen Manipulation gespeicherter Werte?



Literaturtipp

Georges Ifrah
**Universal-
 geschichte der
 Zahlen**



Georges Ifrah, *Universalgeschichte der Zahlen*, 1998

Direkte Wahrnehmung vs. Zählen




Abb. 1: Auf einen Blick können wir mit unserer direkten Zahlenwahrnehmung feststellen, ob eine Gesamtheit ein, zwei, drei oder vier Elemente umfasst; Mengen, die größer sind, müssen wir meistens »zählen« – oder mit Hilfe des Vergleichs oder der gedanklichen Aufteilung in Teilmengen erfassen –, da unsere direkte Wahrnehmung nicht mehr ausreicht, exakte Angaben zu machen.

Abstraktion: Verschiedene Symbole für eine Zahl

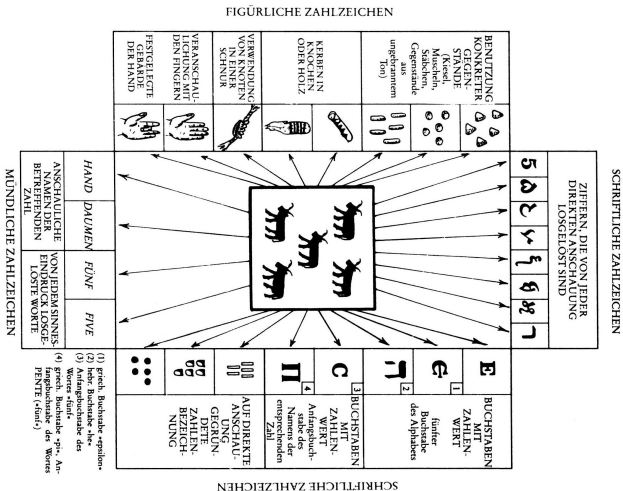


Abb. 11: Verschiedene, einer ganzen Zahl (hier der Zahl 5) zugeordnete Symbole.

Zählen mit den Fingern („digits“)

	1	2	3	4	5	6	7	8	9	10	
A											A
B											B
C											C
D											D

Speicherung: Tonbörse: 15. Jh. v. Chr.

Gegenstände, Hammel und Ziegen betreffend

- 21 Mutterschafe
- 6 weibliche Lämmer
- 8 erwachsene Hammel
- 4 männliche Lämmer
- 6 Mutterziegen
- 1 Bock
- (2) Jungziegen

Abb. 3: Eiförmige Tonbörse (46 mm × 62 mm × 50 mm), entdeckt in den Ruinen des Palastes von Nuzi (mesopotamische Stadt; ca. 15. Jh. v. Chr.). (Harvard Semitic Museum, Cambridge. Katalognummer SMN 1854)




48 Tonkügelchen im Inneren: tamper-proof

Speicherung: Kerbhölzer



Abb. 58: Kerbhölzer aus Bäckereien in Frankreich, wie sie in kleinen Ortschaften auf dem Lande üblich waren.



*Abb. 59: Englische Kerbhölzer aus dem 13. Jahrhundert.
(Sammlung Society of Antiquaries, London; Zeichnung nach Menninger 1957/58, II, 42)*

Speicherung: Knotenschnüre




Abb. 66: Interpretation eines quipu: Die Zahl 658 auf der Schnur E ist gleich der Summe der Zahlen auf den Schnüren A, B, C und D. Dieses Bündel ist das erste an einem peruanischen quipu. (American Museum of Natural History, New York, B 8713; vgl. Leland Locke 1923)



Rechnen: Römische Ziffern

- ▶ Ziffern: I=1, V=5, X=10, L=50, C=100, D=500, M=1000
- ▶ Werte eins bis zehn: I, II, III, IV, V, VI, VII, VIII, IX, X
- ▶ Position der Ziffern ist signifikant:
 - ▶ nach Größe der Ziffernsymbole sortiert, größere stehen links
 - ▶ andernfalls Abziehen der kleineren von der größeren Ziffer
 - ▶ IV=4, VI=6, XL=40, LXX=70, CM=900
- ▶ heute noch in Gebrauch: Jahreszahlen, Seitennummern, usw.
 Beispiele: MDCCCXIII=1813, MMIX=2009
- keine Symbole zur Darstellung großer Zahlen
- Rechenoperationen so gut wie unmöglich

Römischer Abakus




Abb. 87: Römischer Handabakus.
 (Cabinet des Médailles, Bibliothèque Nationale Paris, br. 1925)


 10^6

 10^5

 10^4

 10^3

 10^2


10



1

Römischer Abakus

Dagegen können im Rahmen einer entwickelten Stellenwertschrift nicht nur alle beliebigen Zahlen jeder Größenordnung mit einer beschränkten Anzahl von Ziffern dargestellt werden, sondern mit ihr kann auch sehr einfach gerechnet werden. Und eben deshalb ist unser Ziffernsystem eine der Grundlagen der geistigen Fähigkeiten der modernen Menschen.

Als Beweis dafür führen wir mit römischen Ziffern eine einfache Addition durch:

CCLXVI	266
MDCCCVII	1 807
DCL	650
MLXXX	1 080
MMMDCCCIII	3 803

Ohne Übertragung auf unsere Zahlschrift wäre das sehr schwierig, wenn nicht unmöglich – und dabei handelt es sich doch bloß um eine Addition! Wie verhielte sich das erst bei einer Multiplikation oder gar bei einer Division? Mit diesen Ziffernsystemen kann nicht gerechnet werden, da ihre Grundziffern einen festgelegten Zahlenwert haben. Diese Ziffern sind keine Recheneinheiten, sondern Abkürzungen, mit denen Ergebnisse von Rechnungen festgehalten werden können, die mit Gegenständen auf der Rechentafel, dem Abakus oder dem Kugelbrett bereits gelöst worden waren.

Das 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

Einführung der Null: Babylon, 3 Jh. v. Chr.

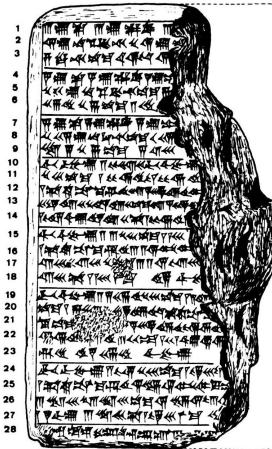
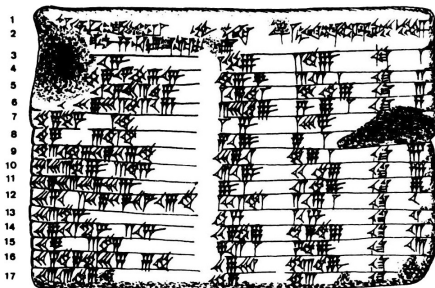


Abb. 289: Mathematische Tafel aus Uruk; sie wurde bei Schwarzgrabungen gefunden und stammt aus dem 2. oder 3. Jh. v. Chr. Es handelt sich um eines der ältesten bekannten Zeugnisse für die Verwendung der babylonischen Null.
 (Musée du Louvre, Taf. AO 6484, Rückseite; Thureau-Dangin 1922, Nr. 33, Taf. 62; 1938, 76-81. Unveröffentl. Kopie d. Verf.)

Babylon: Beispiel mit Satz des Pythagoras



Transkription

Zeile	35-SI-IL-TI SI-LI-IP-TIM	IB-SÁ SAG	IB-SÁ SI-LI-IP-TIM MU-BI-IM
2	NA-AS-SÁ-MU-Ú[un] SAG-I	...-Ú	
3	90, 15	1; 59	2; 49 KI 1
4	58, 58, 58, 14, 50, 6, 15	56, 7	3; 12, 1 KI 2
5	53, 41, 15, 33, 45	1, 16, 41	1, 50, 49 KI 3
6	59, 29, 32, 52, 16	3, 31, 49	5, 9, 1 KI 4
7	48, 54, 1, 40	1, 5	1, 37 KI 5
8	47, 6, 41, 40	5, 19	8, 1 KI 6
9	43, 11, 56, 28, 26, 40	38, 11	59, 1 KI 7
10	41, 33, 59, 3, 45	13, 19	20, 49 KI 8
11	38, 33, 36, 36	9, 1	12, 49 KI 9
12	35, 10, 2, 28, 27, 24, 16, 40	1, 22, 41	2, 16, 1 KI 10
13	33, 45	45	1, 15 KI 11
14	29, 21, 54, 2, 15	27, 59	48, 49 KI 12
15	27, 8, 3, 45	7, 12, 1	4, 49 KI 13
16	25, 48, 51, 35, 6, 40	29, 31	53, 49 KI 14
17	23, 13, 46, 4	56	53 KI 15

*Leerstelle, die das Fehlen von Einheiten einer bestimmten Größenordnung bezeichnet.

Abb. 288: Rechentafel aus der Zeit um 1800–1700 v. Chr.; ihr Inhalt belegt, daß die babylonischen Mathematiker zur Zeit der 1. Dynastie bereits den »Satz des Pythagoras« kannten.

(Columbia University of New York, Tafel Plimpton 322; unveröffentl. Kopie d. Verf.; vgl. Neugebauer/Sachs 1945, 38–41, Taf. 25)

Babylon: Sexagesimalsystem


- ▶ Einführung vor ungefähr 4000 Jahren, erstes Stellenwertsystem
- ▶ Basis 60
- ▶ zwei Symbole: | = 1 und < = 10
- ▶ Einritzen gerader und gewinkelter Striche auf Tontafeln
- ▶ Null bekannt, aber nicht mitgeschrieben
- ▶ Leerzeichen zwischen zwei Stellen
- ▶ Beispiele für Zahlen:
 - ▶ | | | | | 5
 - ▶ << | | | 23
 - ▶ | <<< $90 = 1 \cdot 60 + 3 \cdot 10$
 - ▶ | << | $3621 = 1 \cdot 3600 + 0 \cdot 60 + 2 \cdot 10 + 1$
- ▶ für Zeitangaben und Winkелеinteilung heute noch in Gebrauch

Babylon: Beispiel Potenztabelle 100^i



Klaus von der Heide
 Interaktives Skript T1
 powersbabylon

Dezimalsystem



$$\text{Number} = \sum_{i=-k}^n d_i \times 10^i$$

- ▶ das im Alltag gebräuchliche Zahlensystem
- ▶ Einer, Zehner, Hunderter, Tausender, usw.
- ▶ Zehntel, Hundertstel, Tausendstel, usw.



Dualsystem

- ▶ Stellenwertsystem zur Basis 2
- ▶ braucht für gegebene Zahl ca. dreimal mehr Stellen als Basis 10
- ▶ für Menschen daher unbequem
besser Oktal- oder Hexadezimalschreibweise, s.u.

- ▶ technisch besonders leicht zu implementieren
- ▶ weil nur zwei Zustände unterschieden werden müssen
 - ▶ z.B. zwei Spannungen, Ströme, Beleuchtungsstärken
s.o.: *Kapitel 4: Information – Binärwerte...*
 - ▶ robust gegen Rauschen und Störungen
- ▶ einfache und effiziente Realisierung von Arithmetik

Dualsystem: Potenztabelle

Stelle	Wert im Dualsystem	Wert im Dezimalsystem
2^0	1	1
2^1	10	2
2^2	100	4
2^3	1000	8
2^4	1 0000	16
2^5	10 0000	32
2^6	100 0000	64
2^7	1000 0000	128
2^8	1 0000 0000	256
2^9	10 0000 0000	512
2^{10}	100 0000 0000	1024
...

Addition im Dualsystem

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

$$\begin{array}{r|l}
 + & 0 \ 1 \\
 \hline
 0 & 0 \ 1 \\
 1 & 1 \ 10
 \end{array}$$

- ▶ Beispiel

$$\begin{array}{r}
 10110011 \\
 + 00111001 \\
 \hline
 \text{Ü} \ 11 \ 11 \\
 \hline
 11101100
 \end{array}
 \qquad
 \begin{array}{r}
 = 179 \\
 = 57 \\
 \hline
 11 \\
 \hline
 = 236
 \end{array}$$



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 ist sehr einfach:

$$\begin{array}{c|cc}
 \times & 0 & 1 \\
 \hline
 0 & 0 & 0 \\
 1 & 0 & 1
 \end{array}$$

Multiplikation im Dualsystem (cont.)

► Beispiel

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

$$\begin{aligned}
 &= 1001\ 0001\ 0111 \\
 &= 0x917
 \end{aligned}$$

Oktalsystem

- ▶ Basis 8
- ▶ Zeichensatz ist $\{0, 1, 2, 3, 4, 5, 6, 7\}$
- ▶ C-Schreibweise mit führender Null als Präfix:
 - ▶ $0001 = 1_{10}$
 - ▶ $0013 = 11_{10} = 1 \cdot 8 + 3$
 - ▶ $0375 = 253_{10} = 3 \cdot 64 + 7 \cdot 8 + 5$
 - ▶ usw.
- ⇒ Hinweis: also führende Null in C für Dezimalzahlen unmöglich
- ▶ für Menschen leichter lesbar als Dualzahlen
- ▶ Umwandlung aus/vom Dualsystem durch Zusammenfassen bzw. Ausschreiben von je drei Bits:
 - ▶ $00 = 000, 01 = 001, 02 = 010, 03 = 011,$
 - ▶ $04 = 100, 05 = 101, 06 = 110, 07 = 111$

Hexadezimalsystem

- ▶ Basis 16
- ▶ Zeichensatz ist $\{0, 1, 2, \dots, 9, A, B, C, D, E, F\}$
- ▶ C-Schreibweise mit Präfix 0x – Klein- oder Großbuchstaben

- ▶ $0x00000001 = 1_{10}$

- ▶ $0x000000fe = 254_{10} = 15 \cdot 16 + 14$

- ▶ $0x0000ffff = 65535_{10} = 15 \cdot 4096 + 15 \cdot 256 + 15 \cdot 16 + 15$

- ▶ $0xcafebabe = \dots$ erstes Wort in Java Class-Dateien
usw.

- ▶ viel leichter lesbar als entsprechende Dualzahl
- ▶ Umwandlung aus/vom Dualsystem: Zusammenfassen bzw. Ausschreiben von je vier Bits:

$$0x0 = 0000, 0x1 = 0001, 0x2 = 0010, \dots, 0x9 = 1001,$$

$$0xA = 1010, 0xB = 1011, 0xC = 1100, 0xD = 1101, 0xE = 1110, 0xF = 1111$$



Beispiel: Darstellungen der Zahl 2001

Binary 1 1 1 1 1 0 1 0 0 0 1

$$1 \times 2^{10} + 1 \times 2^9 + 1 \times 2^8 + 1 \times 2^7 + 1 \times 2^6 + 0 \times 2^5 + 1 \times 2^4 + 0 \times 2^3 + 0 \times 2^2 + 0 \times 2^1 + 1 \times 2^0$$

$$1024 + 512 + 256 + 128 + 64 + 0 + 16 + 0 + 0 + 0 + 1$$

Octal 3 7 2 1

$$3 \times 8^3 + 7 \times 8^2 + 2 \times 8^1 + 1 \times 8^0$$

$$1536 + 448 + 16 + 1$$

Decimal 2 0 0 1

$$2 \times 10^3 + 0 \times 10^2 + 0 \times 10^1 + 1 \times 10^0$$

$$2000 + 0 + 0 + 1$$

Hexadecimal 7 D 1

$$7 \times 16^2 + 13 \times 16^1 + 1 \times 16^0$$

$$1792 + 208 + 1$$

Umrechnung Dual-/Oktal-/Hexadezimalsystem

Example 1

Hexadecimal

1 9 4 8 . B 6
 0001 1001 0100 1000 . 1011 0111 00
 1 4 5 1 0 . 5 5 4

Binary

Octal

Example 2

Hexadecimal

7 B A 3 . B C 4
 0111 1011 1010 0011 . 1011 1100 0100
 7 5 6 4 3 . 5 7 0 4

Binary

Octal

- ▶ Gruppieren von jeweils 3 bzw. 4 Bits
- ▶ bei Festkomma vom Dezimalpunkt aus nach außen



Umrechnung zwischen verschiedenen Basen

- ▶ Menschen rechnen im Dezimalsystem
- ▶ Winkel- und Zeitangaben auch im Sexagesimalsystem Basis: 60
- ▶ Digitalrechner nutzen (meistens) Dualsystem

- ▶ Algorithmen zur Umrechnung notwendig
- ▶ Exemplarisch Vorstellung von drei Varianten:
 1. vorberechnete Potenztabellen
 2. Divisionsrestverfahren
 3. Horner-Schema



Umwandlung über Potenztabellen

Vorgehensweise für Integerzahlen:

- ▶ Subtraktion des größten Vielfachen einer Potenz des Zielsystems (gemäß der vorberechneten Potenztabelle) von der umzuwandelnden Zahl
- ▶ Notation dieses größten Vielfachen (im Zielsystem)
- ▶ Subtraktion wiederum des größten Vielfachen vom verbliebenen Rest
- ▶ Addition des zweiten Vielfachen zum ersten
- ▶ Wiederholen, bis Rest = 0



Potenztabellen Dual/Dezimal

Stelle	Wert
2^0	1
2^1	2
2^2	4
2^3	8
2^4	16
2^5	32
2^6	64
2^7	128
2^8	256
2^9	512
2^{10}	1024
...	

Stelle	Wert im Dualsystem
10^0	1
10^1	1010
10^2	110 0100
10^3	111 1101 0000
10^4	10 0111 0001 0000
10^5	0x186A0
10^6	0xF4240
10^7	0x989680
10^8	0x5F5E100
10^9	0x369ACA00
10^{10}	

Potenztabellen: Beispiel

Beispiel: Umwandlung Dezimal- in Dualzahl

(Verwendung von Potenztabelle 1.3.1.1/1)

Annahme: $z = (163)_{10}$

$$\begin{array}{r}
 163 \\
 \underline{-128} \quad (2^7) \quad 1000.0000 \\
 35 \\
 \underline{-32} \quad (2^5) \quad + \quad 10.0000 \\
 3 \\
 \underline{-2} \quad (2^1) \quad + \quad 10 \\
 1 \\
 \underline{-1} \quad (2^0) \quad + \quad 1 \\
 \hline
 0 \quad 1010.0011
 \end{array}$$

$$(163)_{10} \longleftrightarrow (1010.0011)_2$$

Potenztabellen: Beispiel (cont.)

Beispiel: Umformung Dual- in Dezimalzahl

gegeben: $z = (1010.0011)_2$

$$\begin{array}{r}
 1010.0011 \\
 - \quad \underline{110.0100} \quad (100)_{10} = 1 \cdot 100 = 1 \cdot 10^2 \\
 0011.1111 \\
 - \quad \underline{11.1100} \quad (60)_{10} = 6 \cdot 10 = 6 \cdot 10^1 \\
 \quad \quad 11 \\
 - \quad \underline{11} \quad (3)_{10} = 3 \cdot 1 = 3 \cdot 10^0 \\
 \quad \quad \quad 0 \quad (163)_{10}
 \end{array}$$

Divisionsrestverfahren

- ▶ Division der umzuwandelnden Zahl im Ausgangssystem durch die Basis des Zielsystems
- ▶ Erneute Division des ganzzahligen Ergebnisses (ohne Rest) durch die Basis des Zielsystems, bis kein ganzzahliger Divisionsrest mehr bleibt
- ▶ Beispiel:

$$\begin{array}{rcl}
 163 : 2 = 81 & \text{Rest} & 1 \\
 81 : 2 = 40 & \text{Rest} & 1 \\
 40 : 2 = 20 & \text{Rest} & 0 \\
 20 : 2 = 10 & \text{Rest} & 0 \\
 10 : 2 = 5 & \text{Rest} & 0 \\
 5 : 2 = 2 & \text{Rest} & 1 \\
 2 : 2 = 1 & \text{Rest} & 0 \\
 1 : 2 = 0 & \text{Rest} & 1
 \end{array}$$

$$(163)_{10} \longleftrightarrow (1010.0011)_2$$

Divisionsrestverfahren: Beispiel

Beispiel: Umwandlung Dual- in Dezimalzahl:

(wie oben)

$$\begin{array}{rcl}
 (1010.0011)_2 : (1010)_2 = 1.0000 & \text{Rest} & (11)_2 \hat{=} (3)_{10} \\
 (1.0000)_2 : (1010)_2 = 1 & \text{Rest} & (110)_2 \hat{=} (6)_{10} \\
 (1)_2 : (1010)_2 = 0 & \text{Rest} & (1)_2 \hat{=} (1)_{10}
 \end{array}
 \left. \vphantom{\begin{array}{rcl} } \right\} \uparrow$$

$$(1010.0011)_2 \longleftrightarrow (163)_{10}$$

Hinweis: Division in Basis b folgt

Demo: Interaktives Skript, stellen2stellen

Algorithmus

rechentechnisch

 darzustellende Zahl x

123

 Basis q

2

```

a := x
while a > 0
    yn := a mod q
    a := a div q
end
    
```


 $n = 1$
 $a = 123$
 $(a > 0) = 1$
 $a \bmod 2 = 1$
 $a \text{ div } 2 = 61$

000000000000000001

Resultat

Takt

 Klaus von der Heide
 Interaktives Skript T1
 stellen2stellen



Horner-Schema

- ▶ Darstellung einer Potenzsumme durch ineinander verschachtelte Faktoren

$$|z| = \sum_{i=0}^{n-1} a_i \cdot b^i = (\dots (((a_{n-1} \cdot b + a_{n-2})) \cdot b + a_{n-3}) \cdot b + \dots + a_1) \cdot b + a_0$$

Vorgehensweise:

- ▶ Darstellung der umzuwandelnden Zahl im Horner-Schema
- ▶ Durchführung der auftretenden Multiplikationen und Additionen im Zielsystem

Horner-Schema: Beispiel

gegeben: $(163)_{10}$

$$163 = (1 \cdot 10 + 6) \cdot 10 + 3$$

Umsetzung von Faktoren und Summanden ins Zielzahlensystem:

$$(10)_{10} \longleftrightarrow (1010)_2$$

$$(1)_{10} \longleftrightarrow (0001)_2$$

$$(6)_{10} \longleftrightarrow (0110)_2$$

$$(3)_{10} \longleftrightarrow (0011)_2$$

Durchführung der arithmetischen Operation

$$\begin{array}{r}
 0001 \cdot 1010 = 1010 \\
 + \quad 0110 \\
 \hline
 1.0000 \cdot 1010 = 1010.0000 \\
 + \quad \quad 0011 \\
 \hline
 1010.0011
 \end{array}$$



Horner-Schema: Beispiel (cont.)

Rückumwandlung von Dual- in Dezimalzahl

$$(1010.0011)_2 = (((((((1 \cdot 10_2) + 0) \cdot 10_2 + 1) \cdot 10_2 + 0) \cdot 10_2 + 0) \cdot 10_2 + 0) \cdot 10_2 + 1) \cdot 10_2 + 1)$$

Umsetzung von Faktoren und Summanden

$$\begin{aligned} (0)_2 &\longleftrightarrow (0)_{10} \\ (1)_2 &\longleftrightarrow (1)_{10} \\ (10)_2 &\longleftrightarrow (2)_{10} \end{aligned}$$

Horner-Schema: Beispiel (cont.)

Berechnung:

$$\begin{array}{r}
 1 \cdot 2 = 2 \\
 + \underline{0} \\
 2 \cdot 2 = 4 \\
 + \underline{1} \\
 5 \cdot 2 = 10 \\
 + \underline{0} \\
 10 \cdot 2 = 20 \\
 + \underline{0} \\
 20 \cdot 2 = 40 \\
 + \underline{0} \\
 40 \cdot 2 = 80 \\
 + \underline{1} \\
 81 \cdot 2 = 162 \\
 + \underline{1} \\
 \underline{163}
 \end{array}$$



Zahlenbereich bei fester Wortlänge

Anzahl der Bits	=	Zahlenbereich jeweils von 0 bis $(2^n - 1)$
4-bit	$2^4 =$	16
8-bit	$2^8 =$	256
10-bit	$2^{10} =$	1 024
12-bit	$2^{12} =$	4 096
16-bit	$2^{16} =$	65 536
20-bit	$2^{20} =$	1 048 576
24-bit	$2^{24} =$	16 777 216
32-bit	$2^{32} =$	4 294 967 296
48-bit	$2^{48} =$	281 474 976 710 656
64-bit	$2^{64} =$	18 446 744 073 709 551 616



Präfixe

Für die vereinfachte Schreibweise von großen bzw. sehr kleinen Werten ist die Präfixangabe als Abkürzung von Zehnerpotenzen üblich. Beispiele:

- ▶ Lichtgeschwindigkeit: $300\,000\text{ km/s} = 30\text{ cm/ns}$
- ▶ Ruheenergie des Elektrons: $0,51\text{ MeV}$
- ▶ Strukturbreite heutiger Mikrochips: 32 nm
- ▶ usw.

Es gibt entsprechende Präfixe auch für das Dualsystem. Dazu werden Vielfache von $2^{10} = 1024 \approx 1000$ verwendet.



Präfixe für Einheiten im Dezimalsystem

<i>Faktor</i>	Name	Symbol	<i>Faktor</i>	Name	Symbol
10^{24}	yotta	Y	10^{-24}	yocto	y
10^{21}	zetta	Z	10^{-21}	zepto	z
10^{18}	exa	E	10^{-18}	atto	a
10^{15}	peta	P	10^{-15}	femto	f
10^{12}	tera	T	10^{-12}	pico	p
10^9	giga	G	10^{-9}	nano	n
10^6	mega	M	10^{-6}	micro	μ
10^3	kilo	K	10^{-3}	milli	m
10^2	hecto	h	10^{-2}	centi	c
10^1	deka	da	10^{-1}	dezi	d

Präfixe für Einheiten im Dualsystem

<i>Faktor</i>	Name	Symbol	Langname
2^{60}	exbi	Ei	exabinary
2^{50}	pebi	Pi	petabinary
2^{40}	tebi	Ti	terabinary
2^{30}	gibi	Gi	gigabinary
2^{20}	mebi	Mi	megabinary
2^{10}	kibi	Ki	kilobinary

Beispiele: 1 kibibit = 1 024 bit
 1 kilobit = 1 000 bit
 1 megabit = 1 048 576 bit
 1 gibibit = 1 073 741 824 bit

IEC-60027-2, Letter symbols to be used in electrical technology

Präfixe für Einheiten im Dualsystem

In der Praxis werden die offiziellen Präfixe nicht immer sauber verwendet. Meistens ergibt sich die Bedeutung aber aus dem Kontext. Bei Speicherbausteinen sind Zweierpotenzen üblich, bei Festplatten dagegen die dezimale Angabe.

- ▶ DRAM-Modul mit 1 GB Kapazität: gemeint sind 2^{30} Bytes
- ▶ Flash-Speicherkarte 4 GB Kapazität: gemeint sind 2^{32} Bytes
- ▶ Festplatte mit Angabe 1 TB Kapazität: typisch 10^{12} Bytes
- ▶ die tatsächliche angezeigte verfügbare Kapazität ist oft geringer, weil das jeweilige Dateisystem Platz für seine eigenen Verwaltungsinformationen belegt.



Festkommadarstellung

Darstellung von **gebrochenen Zahlen** als Erweiterung des Stellenwertsystems durch Erweiterung des Laufindex zu negativen Werten:

$$\begin{aligned}
 |z| &= \sum_{i=0}^{n-1} a_i \cdot b^i + \sum_{i=-\infty}^{i=-1} a_i \cdot b^i \\
 &= \sum_{i=-\infty}^{n-1} a_i \cdot b^i
 \end{aligned}$$

mit $a_i \in N$ und $0 \leq a_i < b$.

- ▶ Der erste Summand bezeichnet den ganzzahligen Anteil, während der zweite Summand für den gebrochenen Anteil steht.



Nachkommastellen im Dualsystem

- ▶ $2^{-1} = 0.5$
- ▶ $2^{-2} = 0.25$
- ▶ $2^{-3} = 0.125$
- ▶ $2^{-4} = 0.0625$
- ▶ $2^{-5} = 0.03125$
- ▶ $2^{-6} = 0.015625$
- ▶ $2^{-7} = 0.0078125$
- ▶ ...
- ▶ alle Dualbrüche sind im Dezimalsystem exakt darstellbar (d.h. mit endlicher Wortlänge)

Beispiel: Umrechnung dezimal 0.3 nach dual

Betrachtung von gebrochenen Zahlen im Dualsystem:

$2^{-1} = 0,5$	$2^{-7} = 0,0078125$
$2^{-2} = 0,25$	$2^{-8} = 0,00390625$
$2^{-3} = 0,125$	$2^{-9} = 0,001953125$
$2^{-4} = 0,0625$	$2^{-10} = 0,0009765625$
$2^{-5} = 0,03125$	$2^{-11} = 0,00048828125$
$2^{-6} = 0,015625$	$2^{-12} = 0,000244140625$

Beispiel:

$$\begin{aligned}
 (0,3)_{10} &= 0 \cdot 2^{-1} + 1 \cdot 2^{-2} + 0 \cdot 2^{-3} + 0 \cdot 2^{-4} + 1 \cdot 2^{-5} \\
 &\quad + 1 \cdot 2^{-6} + \dots \\
 &= 2^{-2} + 2^{-5} + 2^{-6} + 2^{-9} + \dots \\
 &= (0,0\overline{1001})_2
 \end{aligned}$$



Beispiel: Dezimalbrüche, eine Nachkommastelle

- ▶ gebrochene Zahlen können je nach Wahl der Basis evtl. nur als unendliche periodische Brüche dargestellt werden.
- ▶ insbesondere: viele endliche Dezimalbrüche erfordern im Dualsystem unendliche periodische Brüche.

B=10	B=2	B=2	B=10
0,1	0,00011	0,001	0,125
0,2	0,0011	0,010	0,250
0,3	0,01001	0,011	0,375
0,4	0,0110	0,100	0,5
0,5	0,1	0,101	0,625
0,6	0,1001	0,110	0,750
0,7	0,10110	0,111	0,875
0,8	0,1100		
0,9	0,11100		



Darstellung negativer Zahlen

Drei gängige Varianten zur Darstellung negativer Zahlen:

1. Betrag und Vorzeichen
2. Exzess-Codierung (Offset-basiert)
3. **Komplementdarstellung**
 - ▶ Integerrechnung häufig im Zweierkomplement
 - ▶ Gleitkommadarstellung mit Betrag und Vorzeichen



Darstellung negativer Zahlen: Beispiele

N	N	-N	-N	-N	-N
decimal	binary	signed mag.	1's compl.	2's compl.	excess 128
1	00000001	10000001	11111110	11111111	01111111
2	00000010	10000010	11111101	11111110	01111110
3	00000011	10000011	11111100	11111101	01111101
4	00000100	10000100	11111011	11111100	01111100
5	00000101	10000101	11111010	11111011	01111011
6	00000110	10000110	11111001	11111010	01111010
7	00000111	10000111	11111000	11111001	01111001
8	00001000	10001000	11110111	11111000	01111000
9	00001001	10001001	11110110	11110111	01110111
10	00001010	10001010	11110101	11110110	01110110
20	00010100	10010100	11101011	11101100	01101100
30	00011110	10011110	11100001	11100010	01100010
40	00101000	10101000	11010111	11011000	01011000
50	00110010	10110010	11001101	11001110	01001110
60	00111100	10111100	11000011	11000100	01000100
70	01000110	11000110	10111001	10111010	00111010
80	01010000	11010000	10101111	10110000	00110000
90	01011010	11011010	10100101	10100110	00100110
100	01100100	11011010	10011011	10011100	00011100
127	01111111	11111111	10000000	10000001	00000001
128	Nonexistent	Nonexistent	Nonexistent	10000000	00000000

Betrag und Vorzeichen

- ▶ Auswahl eines Bits als Vorzeichenbit
- ▶ meistens das MSB (engl. *most significant bit*)
- ▶ restliche Bits als Dualzahl interpretiert
- ▶ Beispiel für 4-bit Wortbreite:

0000	+0	1000	-0
0001	+1	1001	-1
0010	+2	1010	-2
0011	+3	1011	-3
0100	+4	1100	-4
...			
0111	+7	1111	-7

- doppelte Codierung der Null: +0, -0
- Rechenwerke für Addition/Subtraktion aufwendig



Exzess-Codierung (Offset-basiert)

- ▶ einfache Um-Interpretation der Binärcodierung

$$z = Z - \text{offset}$$

- ▶ mit z vorzeichenbehafteter Wert, Z binäre Ganzzahl,
- ▶ beliebig gewählter Offset
- Null wird also nicht mehr durch $000\dots 0$ dargestellt
- + Größenvergleich zweier Zahlen bleibt einfach
- ▶ Anwendung: Exponenten im IEEE-754 Gleitkommaformat
- ▶ und für einige Audioformate



Exzess-Codierung: Beispiel

Bitmuster	Binärcode	Exzess-8	Exzess-6	($z = Z - \text{offset}$)
0000	0	-8	-6	
0001	1	-7	-5	
0010	2	-6	-4	
0011	3	-5	-3	
0100	4	-4	-2	
0101	5	-3	-1	
0110	6	-2	0	
0111	7	-1	1	
1000	8	0	2	
1001	9	1	3	
1010	10	2	4	
1011	11	3	5	
1100	12	4	6	
1101	13	5	7	
1110	14	6	8	
1111	15	7	9	



b -Komplement: Definition

Definition: das b -Komplement einer Zahl z ist

$$\begin{aligned}K_b(z) &= b^n - z, \quad \text{für } z \neq 0 \\ &= 0, \quad \text{für } z = 0\end{aligned}$$

- ▶ b : die Basis (des Stellenwertsystems)
- ▶ n : Anzahl der zu berücksichtigenden Vorkommastellen
- ▶ mit anderen Worten: $K_b(z) + z = b^n$

- ▶ Dualsystem: 2-Komplement
- ▶ Dezimalsystem: 10-Komplement



b-Komplement: Beispiele

$$\begin{array}{llll}
 b = 10 & n = 4 & K_{10}(3763)_{10} & = 10^4 - 3763 = 6237_{10} \\
 & n = 2 & K_{10}(0, 3763)_{10} & = 10^2 - 0,3763 = 99,6237_{10} \\
 & n = 0 & K_{10}(0, 3763)_{10} & = 10^0 - 0,3763 = 0,6237_{10} \\
 \\
 b = 2 & n = 2 & K_2(10, 01)_2 & = 2^2 - 10,01_2 = 01,11_2 \\
 & n = 8 & K_2(10, 01)_2 & = 2^8 - 10,01_2 = 11111101,11_2
 \end{array}$$



$(b - 1)$ -Komplement: Definition

Definition: das $(b - 1)$ -**Komplement** einer Zahl z ist

$$\begin{aligned} K_{b-1}(z) &= b^n - b^{-m} - z, & \text{für } z \neq 0 \\ &= 0, & \text{für } z = 0 \end{aligned}$$

- ▶ b : die Basis des Stellenwertsystems
- ▶ n : Anzahl der zu berücksichtigenden Vorkommastellen
- ▶ m : Anzahl der Nachkommastellen

- ▶ Dualsystem: 1-Komplement
- ▶ Dezimalsystem: 9-Komplement



$(b - 1)$ -Komplement: Trick

$$K_{b-1}(z) = b^n - b^{-m} - z, \quad \text{für } z \neq 0$$

- ▶ im Fall $m = 0$ gilt offenbar $K_b(z) = K_{b-1}(z) + 1$
- ⇒ das $(b - 1)$ -Komplement kann sehr einfach berechnet werden.
 Es werden einfach die einzelnen Bits/Ziffern invertiert.

- ▶ Dualsystem: 1-Komplement 1100 1001
 alle Bits invertieren 0011 0110
- ▶ Dezimalsystem: 9-Komplement 24453
 alle Ziffern invertieren 75546
 $0 \leftrightarrow 9 \quad 1 \leftrightarrow 8 \quad 2 \leftrightarrow 7 \quad 3 \leftrightarrow 6 \quad 4 \leftrightarrow 5$
 Summe: $99999 = 100000 - 1$



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 also durch Addition des b -Komplements ersetzt werden
- ▶ und für Integerzahlen gilt außerdem

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

Subtraktion mit Einer- und Zweierkomplement

- ▶ Subtraktion ersetzt durch Addition des Komplements

Decimal

$$\begin{array}{r} 10 \\ + (-3) \\ \hline \end{array}$$

+7

1's complement

$$\begin{array}{r} 00001010 \\ 11111100 \\ \hline \end{array}$$

1 00000110

carry 1

$$00000111$$

2's complement


$$\begin{array}{r} 00001010 \\ 11111101 \\ \hline \end{array}$$

1 00000111


discarded

Veranschaulichung: Zahlenkreis

Beispiel für w -bit



Zweierkomplement



Betrag und Vorzeichen

Gleitkommaformat

Wie kann man „wissenschaftliche“ Zahlen darstellen?

- ▶ Masse der Sonne $1,989 \cdot 10^{30}$ kg
- ▶ Masse eines Elektrons 0,00000 00000 00000 00016 g
- ▶ Anzahl der Atome pro Mol 6023 00000 00000 00000 00000
- ...

Darstellung im Stellenwertsystem?

- ▶ gleichzeitig sehr große und sehr kleine Zahlen notwendig
- ▶ entsprechend hohe Zahl der Vorkomma- und Nachkommastellen
- ▶ durchaus möglich (Java3D: 256-bit Koordinaten)
- ▶ aber normalerweise sehr unpraktisch
- ▶ typische Messwerte haben nur ein paar Stellen Genauigkeit



Gleitkomma: Motivation

Grundidee: **halblogarithmische Darstellung einer Zahl:**

- ▶ Vorzeichen (+1 oder -1)
- ▶ *Mantisse* als normale Zahl im Stellenwertsystem
- ▶ *Exponent* zur Angabe der Größenordnung

$$z = \textit{sign} \cdot \textit{mantisse} \cdot \textit{basis}^{\textit{exponent}}$$

- ▶ handliche Wertebereiche für Mantisse und Exponent
- ▶ arithmetische Operationen sind effizient umsetzbar
- ▶ Wertebereiche für ausreichende Genauigkeit wählen

Hinweis: rein logarithmische Darstellung wäre auch möglich, aber Addition/Subtraktion sind dann sehr aufwendig.

Gleitkomma: Dezimalsystem

$$z = (-1)^s \cdot m \cdot 10^e$$

- ▶ s Vorzeichenbit
 - ▶ m Mantisse als Festkomma-Dezimalzahl
 - ▶ e Exponent als ganze Dezimalzahl
-
- ▶ Schreibweise in C/Java: Vorzeichen Mantisse E Exponent

$6.023E23$	$6,023 \cdot 10^{23}$	Avogadro-Zahl
$1.6E-19$	$1.6 \cdot 10^{-19}$	Elementarladung des Elektrons



Gleitkomma: Beispiel für Zahlenbereiche

Digits in fraction	Digits in exponent	Lower bound	Upper bound
3	1	10^{-12}	10^9
3	2	10^{-102}	10^{99}
3	3	10^{-1002}	10^{999}
3	4	10^{-10002}	10^{9999}
4	1	10^{-13}	10^9
4	2	10^{-103}	10^{99}
4	3	10^{-1003}	10^{999}
4	4	10^{-10003}	10^{9999}
5	1	10^{-14}	10^9
5	2	10^{-104}	10^{99}
5	3	10^{-1004}	10^{999}
5	4	10^{-10004}	10^{9999}
10	3	10^{-1009}	10^{999}
20	3	10^{-1019}	10^{999}




Gleitkomma: Historie

- ▶ 1937 Zuse: Z1 mit 22-bit Gleitkomma-Datenformat
- ▶ 195x Verbreitung von Gleitkomma-Darstellung für numerische Berechnungen
- ▶ 1980 Intel 8087: erster Koprozessor-Chip, ca. 45.000 Transistoren, ca. 50k FLOPS/s
- ▶ 1985 IEEE-754 Standard für Gleitkomma
- ▶ 1989 Intel 486 mit integriertem Koprozessor
- ▶ 1995 Java-Spezifikation fordert IEEE-754
- ▶ 1996 ASCI-RED: 1 TFLOPS (9152x PentiumPro)
- ▶ 2008 Roadrunner: 1 PFLOPS (12960x Cell)
- ...

FLOPS := Floating-Point Operations Per Second

Gleitkomma: Zahlenbereiche



- ▶ Darstellung üblicherweise als Betrag+Vorzeichen
- ▶ negative und positive Zahlen gleichberechtigt (symmetrisch)
- ▶ separate Darstellung für den Wert Null
- ▶ sieben Zahlenbereiche: siehe Bild
- ▶ relativer Abstand benachbarter Zahlen bleibt ähnlich (vgl. dagegen Integer: $0/1, 1/2, 2/3, \dots, 65535/65536, \dots$)

Gleitkomma: Normalisierte Darstellung

$$z = (-1)^s \cdot m \cdot 10^e$$

- ▶ diese Darstellung ist bisher nicht eindeutig:

$$123 \cdot 10^0 = 12.3 \cdot 10^1 = 1.23 \cdot 10^2 = 0.123 \cdot 10^3 = \dots$$

normalisierte Darstellung

- ▶ Exponent anpassen, bis Mantisse im Bereich $1 \leq m < b$ liegt
- ⇒ Darstellung ist dann eindeutig
- ⇒ im Dualsystem: erstes Vorkommbit ist dann also 1, muss also nicht gespeichert werden
- ▶ evtl. zusätzlich sehr kleine Zahlen nicht-normalisiert



IEEE-754 Standard

bis 1985 ein Wildwuchs von Gleitkomma-Formaten:


- ▶ unterschiedliche Anzahl Bits in Mantisse und Exponent
- ▶ Exponent mit Basis 2, 10, oder 16
- ▶ diverse Algorithmen zur Rundung
- ▶ jeder Hersteller mit eigener Variante

— Numerische Algorithmen nicht portabel


- ▶ 1985: Publikation des Standards IEEE-754 zur Vereinheitlichung
- ▶ klare Regeln, auch für Rundungsoperationen
- ▶ große Akzeptanz, mittlerweile der universale Standard

Details: unter anderem in en.wikipedia.org/wiki/IEEE_754

IEEE-754: *float* und *double*



(a)



- ▶ 32-bit-Format: einfache Genauigkeit (*single precision, float*)
- ▶ 64-bit-Format: doppelte Genauigkeit (*double precision, double*)
- ▶ Mantisse als normalisierte Dualzahl: $1 \leq m < 2$
- ▶ Exponent in Exzess-127 bzw. Exzess-1023 Codierung
- ▶ einige Sonderwerte: Null (+0, -0), NaN, Infinity



IEEE-754: Zahlenbereiche

Item	Single precision	Double precision
Bits in sign	1	1
Bits in exponent	8	11
Bits in fraction	23	52
Bits, total	32	64
Exponent system	Excess 127	Excess 1023
Exponent range	-126 to +127	-1022 to +1023
Smallest normalized number	2^{-126}	2^{-1022}
Largest normalized number	approx. 2^{128}	approx. 2^{1024}
Decimal range	approx. 10^{-38} to 10^{38}	approx. 10^{-308} to 10^{308}
Smallest denormalized number	approx. 10^{-45}	approx. 10^{-324}

Matlab-Demo: demoieee754

Zahl

178.125

IEEE-754

short real
long real

± Exponentimplizit Mantisse

0 10000110 1. 011001000100000000000000

- ▶ Zahlenformat wählen (float=short real, double=long real)
- ▶ Dezimalzahl in oberes Textfeld eingeben
- ▶ Mantisse/Exponent/Vorzeichen in unteres Textfeld eingeben
- ▶ andere Werte werden jeweils aktualisiert

Beispiele: float

- ▶ 1-bit Vorzeichen 8-bit Exponent (Exzess-127), 23-bit Mantisse

$$z = (-1)^s \cdot 2^{(eeee\ eeee-127)} \cdot 1, mmmm\ mmmm\ mmmm \dots mmm$$

- ▶ 1 1000 0000 1110 0000 0000 0000 0000 0000

$$\begin{aligned} z &= -1 \cdot 2^{(128-127)} \cdot (1 + 0,5 + 0,25 + 0,125 + 0) \\ &= -1 \cdot 2 \cdot 1,875 = -3,750 \end{aligned}$$

- ▶ 0 1111 1110 0001 0011 0000 0000 0000 0000

$$\begin{aligned} z &= +1 \cdot 2^{(254-127)} \cdot (1 + 2^{-4} + 2^{-7} + 2^{-8}) \\ &= 2^{127} \cdot 1,07421875 = 1,953965 \cdot 10^{38} \end{aligned}$$



Beispiele: float (cont.)

$$z = (-1)^s \cdot 2^{(eeee\ eeee-127)} \cdot 1, \textit{mmmm\ mmmm\ mmmm} \dots \textit{mmm}$$

- ▶ 1 0000 0001 0000 0000 0000 0000 0000 0000

$$\begin{aligned} z &= -1 \cdot 2^{(1-127)} \cdot (1 + 0 + 0 + \dots + 0) \\ &= -1 \cdot 2^{-126} \cdot 1.0 = -1,1755 \cdot 10^{-38} \end{aligned}$$

- ▶ 0 0111 1111 0000 0000 0000 0000 0000 001

$$\begin{aligned} z &= +1 \cdot 2^{(127-127)} \cdot (1 + 2^{-23}) \\ &= 1 \cdot (1 + 0,0000001) = 1,0000001 \end{aligned}$$



BitsToFloat.java

```

public static void main( String[] args ) {
    p( "1", "01111111", "000000000000000000000000" );
}
public void p( String s, String e, String m ) {
    int    sign = (Integer.parseInt( s, 2 ) & 0x1) << 31;
    int exponent = (Integer.parseInt( e, 2 ) & 0xFF) << 23;
    int mantisse = (Integer.parseInt( m, 2 ) & 0x007FFFFFFF);
    int bits = sign | exponent | mantisse;
    float  f = Float.intBitsToFloat( bits );
    System.out.println( dumpIntBits(bits) + " " + f );
}
public String dumpIntBits( int i ) {
    StringBuffer sb = new StringBuffer();
    for( int mask=0x80000000; mask != 0; mask = mask >>> 1 ) {
        sb.append( ((i & mask) != 0) ? "1" : "0" );
    }
    return sb.toString();
}
    
```




Gleitkomma: Addition, Subtraktion

Addition von Gleitkommazahlen $y = a_1 + a_2$

- ▶ Skalierung des betragsmäßig kleineren Summanden
- ▶ Erhöhen des Exponenten, bis $e_1 = e_2$ gilt
- ▶ gleichzeitig entsprechendes Skalieren der Mantisse \Rightarrow schieben
- ▶ Achtung: dabei verringert sich die effektive Genauigkeit des kleineren Summanden

- ▶ anschließend Addition/Subtraktion der Mantissen
- ▶ ggf. Normalisierung des Resultats

- ▶ Beispiele in den Übungen

Gleitkomma-Addition: Beispiel

$$a = 9,725 \cdot 10^7 \quad b = 3,016 \cdot 10^6$$

$$y = (a + b)$$

$$= (9,725 \cdot 10^7 + 0,3016 \cdot 10^7) \quad \text{Angleichung der Exponenten}$$

$$= (9,725 + 0,3016) \cdot 10^7 \quad \text{Distributivgesetz}$$

$$= (10,0266) \cdot 10^7 \quad \text{Addition der Mantissen}$$

$$= 1,00266 \cdot 10^8 \quad \text{Normalisierung}$$

$$= 1,003 \cdot 10^8 \quad \text{Runden bei fester Stellenzahl}$$

- ▶ normalerweise nicht informationstreu !



Achtung: Auslöschung

Probleme bei Subtraktion zweier Gleitkommazahlen:

- ▶ Fall 1: Exponenten stark unterschiedlich
- ▶ kleinere Zahl wird soweit skaliert, dass von der Mantisse (fast) keine gültigen Bits übrigbleiben
- ▶ kleinere Zahl geht verloren, bzw. Ergebnis ist stark ungenau
- ▶ Beispiel: $(1.0E20 + 3.14159) = 1.0E20$

- ▶ Fall 2: Exponenten und Mantisse fast gleich
- ▶ fast alle Bits der Mantisse löschen sich aus
- ▶ Resultat hat nur noch wenige Bits effektiver Genauigkeit



Gleitkomma: Multiplikation, Division

Multiplikation von Gleitkommazahlen $y = a_1 \cdot a_2$

- ▶ Multiplikation der Mantissen und Vorzeichen
- ▶ Addition der Exponenten
- ▶ ggf. Normalisierung des Resultats

$$y = (s_1 \cdot s_2) \cdot (m_1 \cdot m_2) \cdot b^{e_1 + e_2}$$

Division entsprechend:

- ▶ Division der Mantissen und Vorzeichen
- ▶ Subtraktion der Exponenten
- ▶ ggf. Normalisierung des Resultats

$$y = (s_1/s_2) \cdot (m_1/m_2) \cdot b^{e_1 - e_2}$$

IEEE-754: Infinity, Not-a-Number

- ▶ schnelle Verarbeitung großer Datenmengen
 - ▶ Statusabfrage nach jeder einzelnen Operation unbequem
 - ▶ trotzdem Hinweis auf aufgetretene Probleme wichtig
- ⇒ *Inf (infinity)*: spezieller Wert für plus/minus Unendlich
 Beispiele: $2/0$, $-3/0$, $\arctan(\pi)$, usw.
- ⇒ *NaN (not-a-number)*: spezieller Wert für ungültige Operation
 Beispiele: $\sqrt{-1}$, $\arcsin(2, 0)$, Inf / Inf , usw.

IEEE-754: *Inf*, *NaN*, ± 0

Normalized	\pm	$0 < \text{Exp} < \text{Max}$	Any bit pattern
Denormalized	\pm	0	Any nonzero bit pattern
Zero	\pm	0	0
Infinity	\pm	1 1 1...1	0
Not a number	\pm	1 1 1...1	Any nonzero bit pattern

Sign bit

- ▶ Rechnen mit *Inf* funktioniert normal: $0/\text{Inf} = 0$
- ▶ jede Operation mit *NaN* liefert wieder *NaN*



IEEE-754: FloatInfNaNDemo.java

```
java FloatInfNaNDemo
0 / 0 = NaN
1 / 0 = Infinity
-1 / 0 = -Infinity
1 / Infinity = 0.0
Infinity + Infinity = Infinity
Infinity + -Infinity = NaN
Infinity * -Infinity = -Infinity
Infinity + NaN = NaN
sqrt(2) = 1.4142135623730951
sqrt(-1) = NaN
0 + NaN = NaN
NaN == NaN? false      Achtung (!)
Infinity > NaN? false  Achtung (!)
```



ULP: Unit in the last place

- ▶ die Differenz zwischen den beiden Gleitkommazahlen, die einer gegebenen Zahl am nächsten liegen
- ▶ diese beiden Werte unterscheiden sich im niederwertigsten Bit der Mantisse \Rightarrow Wertigkeit des LSB
- ▶ daher ein Maß für die erreichbare Genauigkeit
- ▶ IEEE-754 fordert eine Genauigkeit von 0,5 ULP für die elementaren Operationen: Addition, Subtraktion, Multiplikation, Division, Quadratwurzel
= der bestmögliche Wert
- ▶ gute Mathematik-Software garantiert ≤ 1 ULP auch für höhere Funktionen: Logarithmus, Sinus, Cosinus usw.
- ▶ Progr.sprachenunterstützung, z.B. `java.lang.Math.ulp(double d)`



Rundungsfehler

- ▶ sorgfältige Behandlung von Rundungsfehlern essentiell
- ▶ teilweise Berechnung mit zusätzlichen Schutzstellen
- ▶ dadurch Genauigkeit ± 1 ULP für alle Funktionen
- ▶ ziemlich komplexe Sache

- ▶ in dieser Vorlesung nicht weiter vertieft
- ▶ beim Einsatz von numerischen Algorithmen essenziell



Datentypen in der Praxis: Maschinenworte

- ▶ die meisten Rechner sind für eine Wortlänge optimiert
- ▶ 8-bit, 16-bit, 32-bit, 64-bit, ... Maschinen
- ▶ die jeweils typische Länge eines Integerwertes
- ▶ und meistens auch von Speicheradressen
- ▶ zusätzlich Teile oder Vielfache der Wortlänge unterstützt

- ▶ 32-bit Rechner:
 - ▶ Wortlänge für Integerwerte ist 32-bit
 - ▶ adressierbarer Speicher ist 2^{32} Bytes (4 GiB)
 - ▶ bereits zu knapp für speicherhungrige Applikationen
- ▶ sukzessive Übergang zu 64-bit Rechnern



Datentypen auf Maschinenebene

- ▶ gängige Prozessoren unterstützen mehrere Datentypen
- ▶ entsprechend der elementaren Datentypen in C, Java, ...
- ▶ `void*` ist ein **Pointer** (Referenz, Speicheradresse)
- ▶ Beispiel für die Anzahl der Bytes:

C Datentyp	DEC Alpha	typ. 32-bit	Intel IA-32 (x86)
int	4	4	4
long int	8	4	4
char	1	1	1
short	2	2	2
float	4	4	4
double	8	8	8
long double	8	8	10/12
void *	8	4	4

Datentypen auf Maschinenebene (cont.)

Abhängigkeiten (!)

- ▶ Prozessor
- ▶ Betriebssystem
- ▶ Compiler

segment word size compiler	16 bit			32 bit				64 bit					
	Microsoft	Borland	Watcom	Microsoft	Intel Windows	Borland	Watcom	Gnu v.3.x	Intel Linux	Microsoft	Intel Windows	Gnu	Intel Linux
bool	2	1	1	1	1	1	1	1	1	1	1	1	1
char	1	1	1	1	1	1	1	1	1	1	1	1	1
wchar_t		2		2	2	2	2	2	2	2	2	4	4
short int	2	2	2	2	2	2	2	2	2	2	2	2	2
int	2	2	2	4	4	4	4	4	4	4	4	4	4
long int	4	4	4	4	4	4	4	4	4	4	4	8	8
__int64				8	8			8	8	8	8	8	8
enum	2	2	1	4	4	4	4	4	4	4	4	4	4
float	4	4	4	4	4	4	4	4	4	4	4	4	4
double	8	8	8	8	8	8	8	8	8	8	8	8	8
long double	10	10	8	8	16	10	8	12	12	8	16	16	16
__m64				8	8			8		8	8	8	
__m128				16	16			16	16	16	16	16	16
__m256					32					32		32	
pointer	2	2	2	4	4	4	4	4	4	8	8	8	8
far pointer	4	4	4										
function pointer	2	2	2	4	4	4	4	4	4	8	8	8	8
data member pointer (min)	2	4	6	4	4	8	4	4	4	4	4	8	8
data member pointer (max)		4	6	12	12	8	12	4	4	12	12	8	8
member function pointer (min)	2	12	6	4	4	12	4	8	8	8	8	16	16
member function pointer (max)		12	6	16	16	12	16	8	8	24	24	16	16

Table 1 shows how many bytes of storage various objects use for different compilers.

www.agner.org/optimize/calling_conventions.pdf



Literatur: Vertiefung

- ▶ Klaus von der Heide, *Vorlesung: Technische Informatik 1 — interaktives Skript*, Universität Hamburg, FB Informatik, 2005
tams.informatik.uni-hamburg.de/lectures/2004ws/vorlesung/t1
 Float/Double-Demonstration: demoieeee754
- ▶ Donald E. Knuth, *The Art of Computer Programming, Volume 4, Fascicle 0: Introduction to Combinatorial Algorithms and Boolean Functions*, Addison-Wesley, 2008
- ▶ Donald E. Knuth, *The Art of Computer Programming, Volume 4, Fascicle 1: Bitwise Tricks & Techniques, Binary Decision Diagrams*, Addison-Wesley, 2009



Literatur: Vertiefung (cont.)

- ▶ David Goldberg, *What every computer scientist should know about floating-point*, 1991
www.validlab.com/goldberg/paper.pdf
- ▶ Georges Ifrah, *Universalgeschichte der Zahlen*, div. Verlage, 1998



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
- 6. Arithmetik**
 - Addition und Subtraktion
 - Multiplikation
 - Division
 - Höhere Funktionen
 - Informationstreue
7. Textcodierung
8. Boole'sche Algebra





Gliederung (cont.)

9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Rechner-Arithmetik

- ▶ Wiederholung: Stellenwertsystem
- ▶ Addition: Ganzzahlen, Zweierkomplementzahlen
- ▶ Überlauf

- ▶ Multiplikation
- ▶ Division

- ▶ Schiebe-Operationen





Wiederholung: Stellenwertsystem

- ▶ Wahl einer geeigneten Zahlenbasis b („Radix“)
 - ▶ 10: Dezimalsystem
 - ▶ 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
```

etc.

- ▶ Werte sind für die Sprache fest definiert

Addition im Dualsystem


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

$$\begin{array}{r|l}
 + & 0 \ 1 \\
 \hline
 0 & 0 \ 1 \\
 1 & 1 \ 10
 \end{array}$$

- ▶ Beispiel


$$\begin{array}{r}
 10110011 \\
 + 00111001 \\
 \hline
 \text{Ü} \ 11 \ 11 \\
 \hline
 11101100
 \end{array}
 \qquad
 \begin{array}{r}
 = 179 \\
 = 57 \\
 \hline
 11 \\
 \hline
 = 236
 \end{array}$$

Visualisierung: 4-bit Addition




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

Visualisierung: 4-bit unsigned Addition



- ▶ Operanden und Resultat jeweils 4-bit
- ▶ Überlauf, sobald das Resultat größer als $(2^w - 1)$
- ▶ oberstes Bit geht verloren

Überlauf: unsigned Addition



- ▶ Wortbreite w , hier 4-bit
- ▶ 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

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

- ▶ Alternative: Ersetzen der Subtraktion durch Addition des b -Komplements



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 also durch Addition des b -Komplements ersetzt werden

- ▶ und für Integerzahlen gilt außerdem


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

Visualisierung: 4-bit signed Addition (Zweierkomplement)



- ▶ Zahlenbereich der Operanden: $-2^{w-1} \dots (2^{w-1} - 1)$
- ▶ Zahlenbereich des Resultats: $-2^w \dots (2^w - 2)$
- ▶ Überlauf in beide Richtungen möglich

Überlauf: signed Addition



- ▶ Zahlenbereich der Operanden: $-2^{w-1} .. (2^{w-1} - 1)$
- ▶ Zahlenbereich des Resultats: $-2^w .. (2^w - 2)$
- ▶ Überlauf in beide Richtungen möglich



Überlauf: Erkennung

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

Veranschaulichung: Zahlenkreis

Beispiel für w -bit




Zweierkomplement



Betrag und Vorzeichen

Zahlenkreis: Addition, Subtraktion



0010

0100

0101

0110

$$0010 + 0100 = 0110, \quad 0100 + 0101 = 1001, \quad 0110 - 0010 = 0100$$



Unsigned-Zahlen in C

- ▶ 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];
}
    
```



Unsigned-Typen 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

Interpretation: unsigned/signed



Typumwandlung in C: Vorsicht

- ▶ 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

Fehler

Sign-Extension

- ▶ Gegeben: w -bit Integer x
- ▶ Umwandeln in $w + k$ -bit Integer x' mit gleichem Wert?
- ▶ **Sign-Extension:** Vorzeichenbit kopieren

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

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?

0xffffffffcafebabe	(sign-extension!)
0x0000000100000000	
Ü 11111110	
0000000cafebabe	

Ariane-5 Absturz





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. 370 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

- ▶ http://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 ist sehr einfach:

$$\begin{array}{c|cc}
 \times & 0 & 1 \\
 \hline
 0 & 0 & 0 \\
 1 & 0 & 1
 \end{array}$$



Multiplikation im Dualsystem (cont.)

► Beispiel

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

$$\begin{aligned}
 &= 1001\ 0001\ 0111 \\
 &= 0x917
 \end{aligned}$$



Multiplikation: Wertebereich unsigned

- ▶ 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



Multiplikation: Zweierkomplement

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

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

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

- ▶ Wichtig: Bit-Repräsentation der unteren Bits des Resultats entspricht der unsigned Multiplikation
- ▶ kein separater Algorithmus erforderlich
- ▶ Beweis: siehe Bryant/O'Hallaron, 2.3.5



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 mit 32-bit berechnet, dabei Überlauf
- ▶ Konvertierung nach 64-bit long erst bei Zuweisung
- ▶ long-Konstante schreiben: `24L * 60 * 60 * 1000 * 1000`



Division: 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: Beispiel im Dualsystem

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

$$\begin{array}{r}
 1100100 \ / \ 11 = 0100001 \\
 \begin{array}{r}
 1 \qquad \qquad \qquad 0 \\
 11 \qquad \qquad \qquad 1 \\
 -11 \\
 \hline
 0 \qquad \qquad \qquad 0 \\
 0 \qquad \qquad \qquad 0 \\
 1 \qquad \qquad \qquad 0 \\
 10 \qquad \qquad \qquad 0 \\
 100 \qquad \qquad \qquad 1 \\
 -11 \\
 \hline
 1 \qquad \qquad \qquad 1 \quad (\text{Rest})
 \end{array}
 \end{array}$$

Division: Beispiel im Dualsystem (cont.)

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

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





Höhere mathematische Funktionen

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

- ▶ Approximation über Polynom (Taylor-Reihe) bzw. Approximation 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 $x = 3$, $y_0 = 0.5$:

$$\begin{aligned}
 y_1 &= 0.5 \cdot (2 - 3 \cdot 0.5) &&= 0.25 \\
 y_2 &= 0.25 \cdot (2 - 3 \cdot 0.25) &&= 0.3125 \\
 y_3 &= 0.3125 \cdot (2 - 3 \cdot 0.3125) &&= 0.33203125 \\
 y_4 &= 0.3332824 \\
 y_5 &= 0.3333333332557231 \\
 y_6 &= 0.3333333333333333
 \end{aligned}$$

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



Informationstreu

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

$1.0E20 + (-1.0E20 + 3.14) = 0$



Eigenschaften: Rechnerarithmetik

- ▶ Addition ist kommutative Gruppe / Abel'sche Gruppe
 - ▶ Gruppe: Abgeschlossenheit, Assoziativgesetz, neutrales Element, Inverses
 - ▶ Kommutativgesetz
- ▶ Multiplikation
 - ▶ Abgeschlossenheit: $0 \leq \text{UMult}_v(u, v) \leq 2^{w-1}$
 - ▶ Mult. ist kommutativ: $\text{UMult}_v(u, v) = \text{UMult}_v(v, u)$
 - ▶ Mult. ist assoziativ:

$$\text{UMult}_v(t, \text{UMult}_v(u, v)) = \text{UMult}_v(\text{UMult}_v(t, u), v)$$
 - ▶ Eins ist neutrales Element: $\text{UMult}_v(u, 1) = u$
 - ▶ Distributivgesetz:

$$\text{UMult}_v(t, \text{UAdd}_v(u, v)) = \text{UAdd}_v(\text{UMult}_v(t, u), \text{UMult}_v(t, v))$$



Eigenschaften: Rechnerarithmetik (cont.)

Isomorphe Algebren

- ▶ Unsigned Addition und Multiplikation (Wortbreite w Bits)
- ▶ Zweierkomplement-Addition und Multiplikation (w Bits)
- ▶ Isomorph zum Ring der ganzen Zahlen modulo 2^w

- ▶ Ring der ganzen Zahlen: Ordnungsrelationen
 - ▶ $u > 0 \quad \longrightarrow \quad u + v > v$
 - ▶ $u > 0, v > 0 \longrightarrow u \cdot v > 0$
 - ▶ diese Relationen gelten nicht bei Rechnerarithmetik (Überlauf)

Eigenschaften: Gleitkomma-Addition

verglichen mit Abel'scher Gruppe

- ▶ Abgeschlossen (Addition)? Ja
- ▶ Kommutativ? Ja
- ▶ Assoziativ? Nein
(Überlauf, Rundungsfehler)
- ▶ Null ist neutrales Element? Ja
- ▶ Inverses Element existiert? Fast
(außer für NaN und Infinity)

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

Eigenschaften: Gleitkomma-Multiplikation

verglichen mit kommutativem Ring

- ▶ Abgeschlossen (Multiplikation)? Ja
(aber Infinity oder NaN möglich)
- ▶ Kommutativ? Ja
- ▶ Assoziativ? Nein
(Überlauf, Rundungsfehler)
- ▶ 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)



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
- 7. Textcodierung**

Ad-hoc Codierungen

ASCII und ISO-8859

Unicode

Tipps und Tricks

base64-Codierung

Literatur





Gliederung (cont.)

8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur





Gliederung (cont.)

21. Speicherhierarchie





Darstellung von Texten

- ▶ Ad-Hoc Codierungen
 - ▶ Flaggen-Alphabet
 - ▶ Braille-Code
 - ▶ Morse-Code
- ▶ ASCII und ISO-8859-1
- ▶ Unicode







Wiederholung: Zeichenkette

- ▶ **Zeichenkette** (engl. *string*): Eine Folge von Zeichen
- ▶ **Wort** (engl. *word*): Eine Folge von Zeichen, die in einem gegebenen Zusammenhang als Einheit bezeichnet wird. Worte mit 8 Bit werden als **Byte** bezeichnet.
- ▶ **Stelle** (engl. *position*): Die Lage/Position eines Zeichens innerhalb einer Zeichenkette.
- ▶ Beispiel
 - ▶ `s = H e l l o , w o r l d !`


Flaggen-Signale




Flaggen-Alphabet



Braille: Blindenschrift



- ▶ Symbole als 2x3 Matrix (geprägte Punkte)
- ▶ Erweiterung auf 2x4 Matrix (für Computer)
- ▶ bis zu 64 (256) mögliche Symbole
- ▶ diverse Varianten
 - ▶ ein Symbol pro Buchstabe
 - ▶ ein Symbol pro Silbe
 - ▶ Kurzschrift/Steno



Morse-Code

Punkt: kurzer Ton
 Strich: langer Ton

Codetabelle des Morse-Codes

a	● —	o	— — —	4	● ● ● ● —
ä	● — ● —	ö	— — — ●	5	● ● ● ● ●
å	● — — ● —	p	● — — ●	6	— ● ● ● ●
b	— ● ● ●	q	— — ● —	7	— — ● ● ●
c	— ● — ●	r	● — ●	8	— — — ● ●
ch	— — — —	s	● ● ●	9	— — — — ●
d	— ● ●	t	—	.	● — ● — ● —
e	●	u	● ● —	,	— — ● ● — —
é	● ● — ● ●	ü	● ● — —	:	— — — ● ● ●
f	● ● — ●	v	● ● ● —	—	— ● ● ● ● —
g	— — ●	w	● — —	,	● — — — — ●
h	● ● ● ●	x	— ● ● —	(— ● — — — ● —
i	● ●	y	— ● — —	?	● ● — — ● ●
j	● — — —	z	— — ● ●	“	● — ● ● — ●
k	— ● —			Notruf	● ● ● — — — ● ● ●
l	● — ● ●	0	— — — — —	SP	● ●
m	— —	1	● — — — —	Anfang	— ● — ● —
n	— ●	2	● ● — — —	Ende	● ● ● — ● —
ñ	— — ● — —	3	● ● ● — —		

Morse-Code (cont.)

▶ Eindeutigkeit

Codewort: • • • • • – •

e → •

i → • •

n → – •

r → • – •


s → • • •

- ▶ bestimmte Morse-Sequenzen sind mehrdeutig
- ▶ Pause zwischen den Symbolen notwendig

▶ Codierung

- ▶ Häufigkeit der Buchstaben = $1 / \text{Länge des Codewortes}$
- ▶ Effizienz: kürzere Codeworte
- ▶ Darstellung als Codebaum

Morse-Code: Baumdarstellung (Ausschnitt)



► Anordnung der Symbole entsprechend ihrer Codierung



ASCII

American Standard Code for Information Interchange

- ▶ eingeführt 1967, aktualisiert 1986: ANSI X3.4-1986
- ▶ viele Jahre der dominierende Code für Textdateien
- ▶ alle Zeichen einer typischen Schreibmaschine
- ▶ Erweiterung des früheren 5-bit Fernschreiber-Codes (Murray-Code)

- ▶ 7-bit pro Zeichen, 128 Zeichen insgesamt
- ▶ 95 druckbare Zeichen: Buchstaben, Ziffern, Sonderzeichen (Codierung im Bereich 21..7E)
- ▶ 33 Steuerzeichen (engl: *control characters*) (0..1F,7F)



ASCII: Codetabelle

Code	...0	...1	...2	...3	...4	...5	...6	...7	...8	...9	...A	...B	...C	...D	...E	...F
0...	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1...	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2...	SP	!	"	#	\$	%	&	'	()	*	+	,	-	.	/
3...	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4...	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5...	P	Q	R	S	T	U	V	W	X	Y	Z	[\]	^	_
6...	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7...	p	q	r	s	t	u	v	w	x	y	z	{		}	~	DEL

- ▶ SP = Leerzeichen, CR = carriage-return, LF = line-feed
- ▶ ESC = escape, DEL = delete, BEL = bell, usw.

<http://de.wikipedia.org/wiki/ASCII>



ISO-8859 Familie

- ▶ Erweiterung von ASCII um Sonderzeichen und Umlaute
- ▶ 8-bit Codierung: bis max. 256 Zeichen darstellbar

- ▶ Latin-1: Westeuropäisch
- ▶ Latin-2: Mitteleuropäisch
- ▶ Latin-3: Südeuropäisch
- ▶ Latin-4: Baltisch
- ▶ Latin-5: Kyrillisch
- ▶ Latin-6: Arabisch
- ▶ Latin-7: Griechisch
- ▶ usw.

- ▶ immer noch nicht für mehrsprachige Dokumente geeignet

ISO-8859-1: Codetabelle (1)

Erweiterung von ASCII für westeuropäische Sprachen

Code	...0	...1	...2	...3	...4	...5	...6	...7	...8	...9	...A	...B	...C	...D	...E	...F
0...	<i>nicht belegt</i>															
1...	<i>nicht belegt</i>															
2...	SP	!	"	#	\$	%	&	'	()	*	+	,	-	.	/
3...	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4...	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5...	P	Q	R	S	T	U	V	W	X	Y	Z	[\]	^	_
6...	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7...	p	q	r	s	t	u	v	w	x	y	z	{		}	~	
8...	<i>nicht belegt</i>															
9...	<i>nicht belegt</i>															
A...	NBSP	ı	¢	£	¤	¥	¦	§	¨	©	ª	«	¬	SHY	®	ˆ
B...	°	±	²	³	´	µ	¶	·	¸	¹	º	»	¼	½	¾	¿
C...	À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
D...	Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
E...	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
F...	ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

ISO-8859-1: Codetabelle (2)

Sonderzeichen gemeinsam für alle 8859 Varianten

Code	...0	...1	...2	...3	...4	...5	...6	...7	...8	...9	...A	...B	...C	...D	...E	...F	
0...	<i>NUL</i>	<i>SOH</i>	<i>STX</i>	<i>ETX</i>	<i>EOT</i>	<i>ENQ</i>	<i>ACK</i>	<i>BEL</i>	<i>BS</i>	<i>HT</i>	<i>LF</i>	<i>VT</i>	<i>FF</i>	<i>CR</i>	<i>SO</i>	<i>SI</i>	
1...	<i>DLE</i>	<i>DC1</i>	<i>DC2</i>	<i>DC3</i>	<i>DC4</i>	<i>NAK</i>	<i>SYN</i>	<i>ETB</i>	<i>CAN</i>	<i>EM</i>	<i>SUB</i>	<i>ESC</i>	<i>FS</i>	<i>GS</i>	<i>RS</i>	<i>US</i>	
2...	wie ISO/IEC 8859, Windows-125X und US-ASCII																
3...																	
4...																	
5...																	
6...																	
7...																	<i>DEL</i>
8...																	<i>PAD</i>
9...	<i>DCS</i>	<i>PU1</i>	<i>PU2</i>	<i>STS</i>	<i>CCH</i>	<i>MW</i>	<i>SPA</i>	<i>EPA</i>	<i>SOS</i>	<i>SGCI</i>	<i>SCI</i>	<i>CSI</i>	<i>ST</i>	<i>OSC</i>	<i>PM</i>	<i>APC</i>	
A...	wie ISO/IEC 8859-1 und Windows-1252																
B...																	
C...																	
D...																	
E...																	
F...																	

ISO-8859-2

Erweiterung von ASCII für slawische Sprachen

Code	...0	...1	...2	...3	...4	...5	...6	...7	...8	...9	...A	...B	...C	...D	...E	...F
0...	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1...	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2...	SP	!	"	#	\$	%	&	'	()	*	+	,	-	.	/
3...	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4...	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5...	P	Q	R	S	T	U	V	W	X	Y	Z	[\]	^	_
6...	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7...	p	q	r	s	t	u	v	w	x	y	z	{		}	~	DEL
8...	PAD	HOP	BPH	NBH	IND	NEL	SSA	ESA	HTS	HTJ	VTS	PLD	PLU	RI	SS2	SS3
9...	DCS	PU1	PU2	STS	CCH	MW	SPA	EPA	SOS	SGCI	SCI	CSI	ST	OSC	PM	APC
A...	NBSP	Ą	ˆ	Ł	▣	Ł	Ś	§	ˆ	Š	Ş	Ť	Ž	SHY	Ž	Ž
B...	°	ą	ˆ	ł	▣	ł	ś	ˆ	,	š	ş	ť	ž	ˆ	ž	ž
C...	Ř	Á	Â	Ã	Ä	Å	Ĺ	Č	Ç	Č	É	Ę	Ě	Í	Î	Ď
D...	Đ	Ń	Ň	Ó	Ô	Õ	Ö	×	Ř	Ú	Ú	Ů	Ů	Ý	Ť	ß
E...	ř	á	â	ã	ä	å	ĺ	č	ç	č	é	ę	ě	í	î	ď
F...	ř	á	â	ã	ä	å	ĺ	č	ç	č	é	ę	ě	í	î	ď

ISO-8859-15

Modifizierte ISO-8859-1 mit €

Code	...0	...1	...2	...3	...4	...5	...6	...7	...8	...9	...A	...B	...C	...D	...E	...F
0...	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1...	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2...	SP	!	"	#	\$	%	&	'	()	*	+	,	-	.	/
3...	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4...	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5...	P	Q	R	S	T	U	V	W	X	Y	Z	[\]	^	_
6...	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7...	p	q	r	s	t	u	v	w	x	y	z	{		}	~	DEL
8...	PAD	HOP	BPH	NBH	IND	NEL	SSA	ESA	HTS	HTJ	VTS	PLD	PLU	RI	SS2	SS3
9...	DCS	PU1	PU2	STS	CCH	MW	SPA	EPA	SOS	SGCI	SCI	CSI	ST	OSC	PM	APC
A...	NBSP	ı	ç	£	€	¥	Š	š	©	ª	«	¬	SHY	®	-	
B...	°	±	²	³	Ž	μ	¶	·	ž	¹	º	»	Œ	œ	ÿ	ı
C...	À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
D...	Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
E...	à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
F...	ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ



Microsoft: Codepage 437, 850, 1252

- ▶ Zeichensatz des IBM-PC ab 1981
- ▶ Erweiterung von ASCII auf einen 8-bit Code
- ▶ einige Umlaute (westeuropäisch)
- ▶ Grafiksymbole

- ▶ http://de.wikipedia.org/wiki/Codepage_437
- ▶ verbesserte Version: Codepage 850, 858 (€-Symbol an 0xD5)
- ▶ Codepage 1252 entspricht (weitgehend) ISO-8859-1
- ▶ Sonderzeichen liegen an anderen Positionen als bei ISO-8859

Windows: Codepage 850

	*0	*1	*2	*3	*4	*5	*6	*7	*8	*9	*A	*B	*C	*D	*E	*F
0*		☺	☹	♥	♦	♣	♠	•	◻	◊	♁	♂	♀	♪	♫	☼
1*	▶	◀	↕	!!	¶	§	—	↕	↑	↓	→	←	L	↔	▲	▼
2*		!	"	#	\$	%	&	'	()	*	+	,	-	.	/
3*	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4*	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5*	P	Q	R	S	T	U	V	W	X	Y	Z	[\]	^	_
6*	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7*	p	q	r	s	t	u	v	w	x	y	z	{		}	~	△
8*	Ç	ü	é	â	ã	à	â	ç	ê	ë	è	ï	î	ì	Ä	Å
9*	É	æ	Æ	ô	ö	ò	û	ù	ÿ	Ö	Ü	ø	£	Ø	×	f
A*	á	í	ó	ú	ñ	Ñ	ª	º	¿	®	¬	½	¼	¡	«	»
B*	☐	☐	☐		†	Á	Â	À	©	¶		¶	¶	¢	¥	₯
C*	L	⊥	T	†	—	†	ã	Ã	ℒ	℞	⚖	⚖	⚖	⚖	=	⚖
D*	ð	Ð	Ê	Ë	È	Í	Î	Ï	J	Γ	■	■	■	■	■	■
E*	Ó	β	Ô	Ò	õ	Õ	μ	þ	P	Ú	Û	Ù	Ú	Ý	Ý	'
F*		±	=	¾	¶	§	÷	.	°	¨	·	¹	³	²	■	





Austausch von Texten?

- ▶ die meisten gängigen Codes (abwärts-) kompatibel mit ASCII
- ▶ unterschiedliche Codierung für Umlaute (soweit vorhanden)
- ▶ unterschiedliche Codierung der Sonderzeichen

- ▶ Unterschiedliche Konvention für Zeilenende
 - ▶ DOS/Windows: CR/LF (0D 0A)
 - ▶ Unix/Linux: LF
 - ▶ Mac OS 9: CR

 - ▶ Konverter-Tools: dos2unix, unix2dos, iconv



Unicode: Motivation

- ▶ zunehmende Vernetzung und Globalisierung
 - ▶ internationaler Datenaustausch?
 - ▶ Erstellung mehrsprachiger Dokumente?
 - ▶ Unterstützung orientalischer oder asiatischer Sprachen?

 - ▶ ASCII oder ISO-8859-1 reicht nicht aus
 - ▶ temporäre Lösungen konnten sich nicht durchsetzen, z.B:
ISO-2022: Umschaltung zwischen mehreren Zeichensätzen durch Spezialbefehle (*Escapesequenzen*).
- ⇒ **Unicode** als System zur Codierung aller Zeichen aller bekannten (lebenden oder toten) Schriftsysteme



Unicode: Versionen und History

- ▶ auch abgekürzt als UCS: **Universal Character Set**
- ▶ zunehmende Verbreitung (Betriebssysteme, Applikationen)
- ▶ Darstellung erfordert auch entsprechende Schriftarten
- ▶ <http://www.unicode.org>
<http://www.unicode.org/charts>
- ▶ 1991 1.0.0: europäisch, nahöstlich, indisch
- ▶ 1992 1.0.1: ostasiatisch (Han)
- ▶ 1993 akzeptiert als ISO/IEC-10646 Standard
- ▶ ...
- ▶ 2010 6.0: knapp 110.000 Zeichen enthalten

<http://www.unicode.org>, <http://de.wikipedia.org/wiki/Unicode>



Unicode: Schreibweise

- ▶ ursprüngliche Version nutzt 16-bit pro Zeichen
- ▶ die sogenannte „*Basic Multilingual Plane*“
- ▶ Schreibweise hexadezimal als U+xxxx
- ▶ Bereich von U+0000 .. U+FFFF
- ▶ Schreibweise in Java-Strings: \uxxxx
z.B. \u03A9 für Ω, \u20AC für das €-Symbol

- ▶ mittlerweile mehr als 2¹⁶ Zeichen
- ▶ Erweiterung um „*Extended Planes*“
- ▶ U+10000 .. U+10FFFF



Unicode: in Webseiten (HTML)

- ▶ HTML-Header informiert über verwendeten Zeichensatz
- ▶ Unterstützung und Darstellung abhängig vom Browser
- ▶ Demo <http://www.columbia.edu/~fdc/utf8>

```
<html>
<head>
<META http-equiv="Content-Type"
      content="text/html; charset=utf-8">
<title>UTF-8 Sampler</title>
</head>
...
```



Unicode: Demo

<http://www.columbia.edu/~fdc/utf8>

- English:** The quick brown fox jumps over the lazy dog.
- Jamaican:** Chruu, a kwik di kwik brong fox a jomp huova di liezi daag de, yu no siit?
- Irish:** "An bhfuil do croí ag bualadh ó faitíos an grá a mheall lena póg éada ó slí do leasa tú?" "D'fhuascaill Íosa Úrthac na hÓige Beannaithe pór Éava agus Ádairn."
- Dutch:** Pa's wijze lynx bezag vroom het fikse aquaduct.
- German:** Falsches Üben von Xylophonmusik quält jeden größeren Zwerg. (1)
- German:** Im finsternen Jagdchloß am offenen Felsquellwaller patzte der affig-flatterhafte kauzig-höfliche Bäcker über feinern verflitten kniffligen C-Xylophon. (2)
- Norwegian:** Blåbærsyltetøy ("blueberry jam", includes every extra letter used in Norwegian).
- Swedish:** Flygande bäckasiner söka strax hwila på mjuka tuvor.
- Icelandic:** Sævör grét áðan því úlpan var ónýt.
- Finnish:** (5) Törkylempijävongahdus (This is a perfect pangram, every letter appears only once. Translating it is an art on its own, but I'll say "rude lover's yelp". :-D)
- Finnish:** (5) Albert osti fagotin ja töräytti puhkuvan melodian. (Albert bought a bassoon and hooted an impressive melody.)
- Finnish:** (5) On sangen hauskaa, että polkupyörä on maanteiden jokapäiväinen ilmiö. (It's pleasantly amusing, that the bicycle is an everyday sight on the roads.)
- Polish:** Pchnąć w tę łódź jeża lub ośmiek skrzyń fig.
- Czech:** Přilíš žlutoučký kůň ůpěl d'ábelské kódy.
- Slovak:** Starý kôň na hrbe knih žuje tiško povádnuté ruže, na sŕpe sa ďateľ učí kvákať novú ódu o živote.
- Greek (monotonic):** ξεσκεπάσω την ψυχοφθόρα βδελυγμία
- Greek (polytonic):** ξεσκεπάσω την ψυχοφθόρα βδελυγμία
- Russian:** Съешь же ещё этих мягких французских булок да выпей чаю.
- Russian:** В чашках юга жип-был цитрус? Да, но фальшивый экземпляр! ёть.
- Bulgarian:** Жълпата дюля беше щастлива, че пухът, който цъфна, замръзна като гьон.
- Sami (Northern):** Vuol Ruota gedggiid leat márga luosa ja čuoŋžža.
- Hungarian:** Árvízűrő tükörűrógép.
- Spanish:** El pingüino Wenceslao hizo kilómetros bajo exhaustiva lluvia y frío, añoraba a su querido cachorro.
- Portuguese:** O próximo vôo à noite sobre o Atlântico, põe frequentemente o único médico. (3)
- French:** Les naïfs ægithales hâtifs pondant à Noël où il gèle sont sûrs d'être déçus en voyant leurs rôles d'œufs abimés.
- Esperanto:** Eĥoŝanĝo ĉiujŝade.
- Hebrew:** הַתּוֹרָה הַזֹּאת הֵיאֵשׁוּבָה בְּכָל שָׁנָה
- Japanese (Hiragana):**

いろはにほへど ちりぬるを
 わがよたれぞ つねならむ
 うゑのおくやま けふこえて
 あさきゆめみじ ゑひもせす (4)



Unicode: Demo (cont.)

<http://www.columbia.edu/~fdc/utf8>

[Šota Rustaveli](#)'s Vep'xis Tq'aosani, თჳთ, *The Knight in the Tiger's Skin* (Georgian):

ვეპ'ხის ტყაოსანი შოთა რუსთაველი

ღმერთის შემეფედრე, წუთუ კვლა დამხსნას სოფლისა შრომისა, ცეცხლს, წყალსა და მიწასა,
ჰაერთა თანა შრომისა; მომენეს ფრთენი და აღფურინდე, მივჰხუდე მას ჩემსა წდომისა, დღისით
და ღამით ვჰხედვიდე შიხსა ელვათა კრთომასა.

Tamil poetry of Subramaniya Bharathiyar: சுப்ரமணிய பாரதியார் (1882-1921):

யாமறிந்த மொழிகளிலே தமிழ்மொழி போல் இனிதாவது எங்கும் காணோம்,
பாமரராய் விலங்குகளாய், உலகனைத்தும் இகழ்ச்சிசொலப் பான்மை கெட்டு,
நாமமது தமிழ்ரெனக் கொண்டு இங்கு வாழ்ந்திடுதல் நன்றோ? சொல்லீர்!
தேமதுரத் தமிழோசை உலகமெலாம் பரவும்வகை செய்தல் வேண்டும்.



Unicode: Latin-Zeichen

- ▶ Zeichen im Bereich U+0000 bis U+007F wie ASCII
www.unicode.org/charts/PDF/U0000.pdf
- ▶ Bereich von U+0100 bis U+017F für Latin-A
Europäische Umlaute und Sonderzeichen
www.unicode.org/charts/PDF/U0100.pdf
- ▶ viele weitere Sonderzeichen ab U+0180
Latin-B, Latin-C, usw.



Unicode: Mathematische Symbole und Operatoren

Vielfältige Auswahl von Symbolen und Operatoren

- ▶ griechisch www.unicode.org/charts/PDF/U0370.pdf
- ▶ letterlike Symbols www.unicode.org/charts/PDF/U2100.pdf

- ▶ Pfeile www.unicode.org/charts/PDF/U2190.pdf
- ▶ Operatoren www.unicode.org/charts/PDF/U2A00.pdf
- ▶ ...

- ▶ Dingbats www.unicode.org/charts/PDF/U2700.pdf

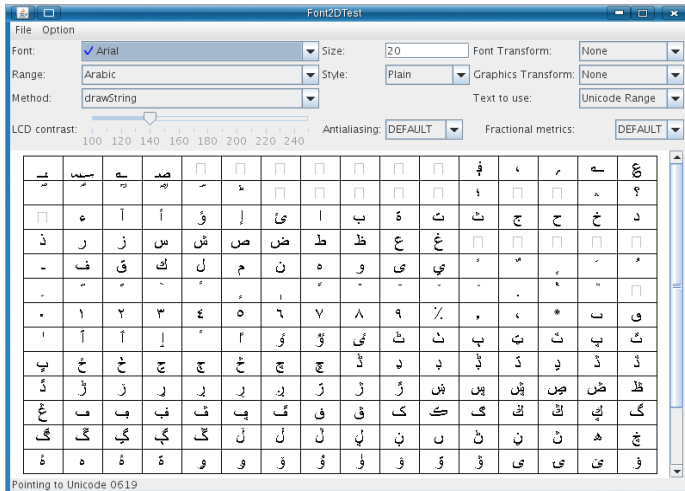


Unicode: Asiatische Sprachen

Chinesisch (traditional/simplified), Japanisch, Koreanisch

- ▶ U+3400 bis U+4DBF
www.unicode.org/charts/PDF/U3400.pdf
- ▶ U+4E00 bis U+9FCF
www.unicode.org/charts/PDF/U4E00.pdf

Unicode: Java2D Fontviewer



The screenshot shows the Font2DTest application window. The settings are as follows:

- Font: Arial
- Size: 20
- Font Transform: None
- Range: Arabic
- Style: Plain
- Graphics Transform: None
- Method: drawString
- Text to use: Unicode Range
- LCD contrast: 140 (slider)
- Antialiasing: DEFAULT
- Fractional metrics: DEFAULT

The main display area shows a grid of characters from the Arabic font. The characters are arranged in rows and columns, starting with Arabic letters and ending with some symbols. The text at the bottom of the window reads: "Pointing to Unicode 0619".

ا	ب	ت	ث	ج	ح	خ	د	ذ	ر	ز	س	ش	ص	ض	ط	ظ	ع	غ	ف	ق	ك	ل	م	ن	ه	و	ي	٠	١	٢	٣	٤	٥	٦	٧	٨	٩	/	,	*	!	"	#	\$	%	&	'	()	*	+	=	-	.	:	;	<	>	?@							
آ	أ	إ	أ	ؤ	ئ	ا	ب	ة	ت	ث	ج	ح	خ	د	ذ	ر	ز	س	ش	ص	ض	ط	ظ	ع	غ	ف	ق	ك	ل	م	ن	ه	و	ي	٠	١	٢	٣	٤	٥	٦	٧	٨	٩	/	,	*	!	"	#	\$	%	&	'	()	*	+	=	-	.	:	;	<	>	?@
آ	أ	إ	أ	ؤ	ئ	ا	ب	ة	ت	ث	ج	ح	خ	د	ذ	ر	ز	س	ش	ص	ض	ط	ظ	ع	غ	ف	ق	ك	ل	م	ن	ه	و	ي	٠	١	٢	٣	٤	٥	٦	٧	٨	٩	/	,	*	!	"	#	\$	%	&	'	()	*	+	=	-	.	:	;	<	>	?@
آ	أ	إ	أ	ؤ	ئ	ا	ب	ة	ت	ث	ج	ح	خ	د	ذ	ر	ز	س	ش	ص	ض	ط	ظ	ع	غ	ف	ق	ك	ل	م	ن	ه	و	ي	٠	١	٢	٣	٤	٥	٦	٧	٨	٩	/	,	*	!	"	#	\$	%	&	'	()	*	+	=	-	.	:	;	<	>	?@
آ	أ	إ	أ	ؤ	ئ	ا	ب	ة	ت	ث	ج	ح	خ	د	ذ	ر	ز	س	ش	ص	ض	ط	ظ	ع	غ	ف	ق	ك	ل	م	ن	ه	و	ي	٠	١	٢	٣	٤	٥	٦	٧	٨	٩	/	,	*	!	"	#	\$	%	&	'	()	*	+	=	-	.	:	;	<	>	?@



Unicode: Repräsentation?

- ▶ 16-bit für jedes Zeichen, bis zu 65536 Zeichen
- ▶ schneller Zugriff auf einzelne Zeichen über Arrayzugriffe (Index)
- ▶ aber: doppelter Speicherbedarf gegenüber ASCII/ISO-8859-1
- ▶ Verwendung u.a. in Java: Datentyp `char`

- ▶ ab Unicode-3: mehrere *Planes* zu je 65536 Zeichen
- ▶ direkte Repräsentation aller Zeichen erfordert 32-bit/Zeichen
- ▶ vierfacher Speicherbedarf gegenüber ISO-8859-1

- ▶ bei Dateien ist möglichst kleine Dateigröße wichtig
- ▶ effizientere Codierung üblich: UTF-16 und UTF-8



UTF-8

Zeichen	Unicode	Unicode binär	UTF-8 binär	UTF-8 hexadezimal
Buchstabe y	U+0079	00000000 01111001	01111001	0x79
Buchstabe ä	U+00E4	00000000 11100100	11000011 10100100	0xC3 0xA4
Zeichen für eingetragene Marke ®	U+00AE	00000000 10101110	11000010 10101110	0xC2 0xAE
Eurozeichen €	U+20AC	00100000 10101100	11100010 10000010 10101100	0xE2 0x82 0xAC
Violenschlüssel 🎹	U+1D11E	00000001 11010001 00011110	11110000 10011101 10000100 10011110	0xF0 0x9D 0x84 0x9E

<http://de.wikipedia.org/wiki/UTF-8>

- ▶ effiziente Codierung von „westlichen“ Unicode-Texten
- ▶ Zeichen werden mit variabler Länge codiert, 1..4-Bytes
- ▶ volle Kompatibilität mit ASCII

UTF-8: Algorithmus

Unicode-Bereich (hexadezimal)	UTF-Codierung (binär)	Anzahl (benutzt)
0000 0000 - 0000 007F	0*** ****	128
0000 0080 - 0000 07FF	110* **** 10** ****	1920
0000 0800 - 0000 FFFF	1110 **** 10** **** 10** ****	63488
0001 0000 - 0010 FFFF	1111 0*** 10** **** 10** **** 10** ****	bis 2^{21}

- ▶ untere 128 Zeichen kompatibel mit ASCII
- ▶ Sonderzeichen westlicher Sprachen je zwei Bytes
- ▶ führende Eins markiert Multi-Byte Zeichen
- ▶ Anzahl der führenden Einsen gibt Anz. Bytegruppen an
- ▶ Zeichen ergibt sich als Bitstring aus den ***...*
- ▶ theoretisch bis zu sieben Folgebytes a 6-bit: max. 2^{42} Zeichen



Sprach-Einstellungen: Locale

Locale: die Sprach-Einstellungen und Parameter

- ▶ auch: `i18n` („internationalization“)
- ▶ Sprache der Benutzeroberfläche
- ▶ Tastaturlayout/-belegung
- ▶ Zahlen-, Währungs-, Datums-, Zeitformate
- ▶ Linux/POSIX: Einstellung über die Locale-Funktionen der Standard C-Library (Befehl `locale`)

Java: `java.util.Locale`

Windows: Einstellung über System/Registry-Schlüssel



dos2unix, unix2dos

- ▶ Umwandeln von ASCII-Texten (z.B. Programm-Quelltexte) zwischen DOS/Windows und Unix/Linux Maschinen

- ▶ Umwandeln von a.txt in Ausgabedatei b.txt:

```
dos2unix -c ascii -n a.txt b.txt
```

```
dos2unix -c iso -n a.txt b.txt
```

```
dos2unix -c mac -n a.txt b.txt
```

- ▶ Umwandeln von Unix nach DOS/Windows, Codepage 850:

```
unix2dos -850 -n a.txt b.txt
```



iconv

Das Schweizer-Messer zur Umwandlung von Textcodierungen.

► Optionen

- `-f, --from-code=<encoding>` Codierung der Eingabedatei
- `-t, --to-code=<encoding>` Codierung der Ausgabedatei
- `-l, --list` Liste der unterstützten Codierungen ausgeben
- `-o, --output=<filename>` Name der Ausgabedatei

► Beispiel

```
iconv -f=iso-8859-1 -t=utf-8 -o foo.utf8.txt foo.txt
```



base64-Codierung

Übertragung von (Binär-) Dateien zwischen verschiedenen Rechnern?

- ▶ SMTP (Internet Mail-Protokoll) verwendet 7-bit ASCII
 - ▶ bei Netzwerk-Übertragung müssen alle Rechner/Router den verwendeten Zeichensatz unterstützen
- ⇒ Verfahren zur Umcodierung der Datei in 7-bit ASCII notwendig
- ⇒ etabliert ist das **base-64** Verfahren (RFC 2045)
- ▶ alle e-mail Dateianhänge und 8-bit Textdateien
 - ▶ Umcodierung benutzt nur Buchstaben, Ziffern und drei Sonderzeichen

base64-Codierung: Prinzip

- ▶ Codierung von drei 8-bit Bytes als vier 6-bit Zeichen
- ▶ erfordert 64 der verfügbaren 128 7-bit ASCII Symbole

- ▶ Codierung

A..Z Codes: 0..25

a..z Codes: 26..51


0..9 Codes: 52..61

+ Code: 62

/ Code: 63

= Füllzeichen, falls Anzahl der Bytes nicht durch 3 teilbar

CR Zeilenumbruch (optional), meistens nach 76 Zeichen





base64-Codierung: Prinzip (cont.)

Text content	M						a						n											
ASCII	77						97						110											
Bit pattern	0	1	0	0	1	1	0	1	0	1	1	0	0	0	0	1	0	1	1	0	1	1	1	0
Index	19			22			5			46														
Base64-encoded	T			W			F			u														

- ▶ drei 8-bit Zeichen, re-gruppirt als vier 6-bit Blöcke
- ▶ Zuordnung des jeweiligen Buchstabens/Ziffer
- ▶ ggf. =, == am Ende zum Auffüllen
- ▶ Übertragung dieser Zeichenfolge ist 7-bit kompatibel
- ▶ resultierende Datei ca. 33% größer als das Original



base64-Codierung: Tools

- ▶ im Java JDK enthalten
aber im inoffiziellen internen Teil
`sun.misc.BASE64Encoder`, bzw. `sun.misc.BASE64Decoder`
- ▶ aber diverse (open-source) Implementierungen verfügbar
Beispiel: Apache Commons <http://commons.apache.org/codec>
`org.apache.commons.codec.binary.Base64`
`org.apache.commons.codec.binary.Base64InputStream`
`org.apache.commons.codec.binary.Base64OutputStream`

base64-Codierung: Beispiel

openbook.galileodesign.de/javainsel7/javainsel_04_008.htm

```

import java.io.IOException;
import java.util.*;
import sun.misc.*;

public class Base64Demo
{
    public static void main( String[] args ) throws IOException
    {
        byte[] bytes1 = new byte[ 112 ];
        new Random().nextBytes( bytes1 );

        // buf in String
        String s = new BASE64Encoder().encode( bytes1 );
        System.out.println( s );

        // Zum Beispiel:
        // QFgwDyiQ28/4GsF75fqLMj/bAIWNwOuBmE/SCl3H2XQFpSsSz0jtyR0LU+kLiwWsnSUZljjr97Hy
        // LA3YUbf96Ym2zx9F9Y1N7P5ls0Cb/vr2crTQ/gXs757qaJF9E3szMN+E0CSSslDrrzcNBrlcQg==
        // String in byte[]
        byte[] bytes2 = new BASE64Decoder().decodeBuffer( s );
        System.out.println( Arrays.equals(bytes1, bytes2) );    // true
    }
}

```



Literatur: Vertiefung

- ▶ <http://www.unicode.org>
- ▶ The Java Tutorials, *Trail: Internationalization*
<http://download.oracle.com/javase/tutorial/i18n>



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
- 8. Boole'sche Algebra**
 - Grundbegriffe der Algebra
 - Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen





Gliederung (cont.)

12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Wiederholung: Grundbegriffe der Algebra

- ▶ Mengen
- ▶ Relationen, Verknüpfungen
- ▶ Gruppe, Abel'sche Gruppe
- ▶ Körper, Ring
- ▶ Vektorraum
- ▶ usw.





Nutzen einer (abstrakten) Algebra?!

Analyse und Beschreibung von

- ▶ gemeinsamen, wichtigen Eigenschaften
- ▶ mathematischer Operationen
- ▶ mit vielfältigen Anwendungen

Spezifiziert durch

- ▶ die Art der Elemente (z.B. ganze Zahlen, Aussagen, usw.)
- ▶ die Verknüpfungen (z.B. Addition, Multiplikation)
- ▶ zentrale Elemente (z.B. Null-, Eins-, inverse Elemente)

Anwendungen: z.B. fehlerkorrigierende Codes auf CD/DVD



Boole'sche Algebra

- ▶ George Boole, 1850: Untersuchung von logischen Aussagen mit den Werten *true* (wahr) und *false* (falsch)
- ▶ Definition einer Algebra mit diesen Werten
- ▶ Vier grundlegende Funktionen:
 - ▶ NEGATION (NOT) Schreibweisen: $\neg a, \bar{a}, \sim a$
 - ▶ UND $-"-$ $a \wedge b, a \& b$
 - ▶ ODER $-"-$ $a \vee b, a | b$
 - ▶ XOR $-"-$ $a \oplus b, a \hat{=} b$
- ▶ Claude Shannon, 1937: Realisierung der Boole'schen Algebra mit Schaltfunktionen (binäre digitale Logik)

Grundverknüpfungen

- ▶ zwei Werte: *wahr* (*true*, 1) und *falsch* (*false*, 0)
- ▶ vier grundlegende Verknüpfungen:

NOT(x)

x	
0	1
1	0

AND(x, y)

y	x	0	1
0	0	0	0
1	0	0	1

OR(x, y)

y	x	0	1
0	0	0	1
1	1	1	1

XOR(x,y)

y	x	0	1
0	0	0	1
1	1	1	0

- ▶ alle logischen Operationen lassen sich mit diesen Funktionen darstellen (*vollständige Basismenge*)



Grundverknüpfungen

- ▶ zwei Werte, $\{0, 1\}$
- ▶ insgesamt 4 Funktionen mit einer Variable
 $f_0(x) = 0$, $f_1(x) = 1$, $f_2(x) = x$, $f_3(x) = \neg x$
- ▶ insgesamt 16 Funktionen zweier Variablen
- ▶ allgemein 2^{2^n} Funktionen von n Variablen
- ▶ später noch viele Beispiele



Alle Funktionen von zwei Variablen

$x = 0\ 1\ 0\ 1$ $y = 0\ 0\ 1\ 1$	Bezeichnung	Notation	Alternativnotation	Java/C-Notation
0 0 0 0	Nullfunktion	0		0
0 0 0 1	AND	$x \cap y$		$x\&\&y$
0 0 1 0	Inhibition	$y > x$		$y>x$
0 0 1 1	Identität y	y		y
0 1 0 0	Inhibition	$x > y$		$x>y$
0 1 0 1	Identität x	x		x
0 1 1 0	XOR	$x \oplus y$	$x \neq y$	$x!=y$
0 1 1 1	OR	$x \cup y$		$x y$
1 0 0 0	NOR	$\neg(x \cup y)$		$!(x y)$
1 0 0 1	Äquivalenz	$\neg(x \oplus y)$	$x = y$	$x==y$
1 0 1 0	NICHT x	$\neg x$	x'	$!x$
1 0 1 1	Implikation	$x \leq y$	$x \rightarrow y$	$y>=x$
1 1 0 0	NICHT y	$\neg y$	y'	$!y$
1 1 0 1	Implikation	$x \geq y$	$x \leftarrow y$	$x>=y$
1 1 1 0	NAND	$\neg(x \cap y)$		$!(x\&\&y)$
1 1 1 1	Einsfunktion	1		1



Boole'sche Algebra

- ▶ 6-Tupel $\langle \{0, 1\}, \vee, \wedge, \neg, 0, 1 \rangle$ bildet eine Algebra
- ▶ $\{0, 1\}$ Menge mit zwei Elementen
- ▶ \vee ist die „Addition“
- ▶ \wedge ist die „Multiplikation“
- ▶ \neg ist das „Komplement“ (nicht das Inverse!)
- ▶ 0 (false) ist das Nullelement der Addition
- ▶ 1 (true) ist das Einselement der Multiplikation

Rechenregeln: Ring / Algebra

Eigenschaft	Ring der ganzen Zahlen	Boole'sche Algebra
Kommutativgesetz	$a + b = b + a$ $a \times b = b \times a$	$a \vee b = b \vee a$ $a \wedge b = b \wedge a$
Assoziativgesetz	$(a + b) + c = a + (b + c)$ $(a \times b) \times c = a \times (b \times c)$	$(a \vee b) \vee c = a \vee (b \vee c)$ $(a \wedge b) \wedge c = a \wedge (b \wedge c)$
Distributivgesetz	$a \times (b + c) = (a \times b) + (a \times c)$	$a \wedge (b \vee c) = (a \wedge b) \vee (a \wedge c)$
Identitäten	$a + 0 = a$ $a \times 1 = a$	$a \vee 0 = a$ $a \wedge 1 = a$
Vernichtung	$a \times 0 = 0$	$a \wedge 0 = 0$
Auslöschung	$-(-a) = a$	$\neg(\neg a) = a$
Inverses	$a + (-a) = 0$	—




Rechenregeln: Ring / Algebra (cont.)

Eigenschaft	Ring der ganzen Zahlen	Boole'sche Algebra
Distributivgesetz	—	$a \vee (b \wedge c) = (a \vee b) \wedge (a \vee c)$
Komplement	—	$a \vee \neg a = 1$
	—	$a \wedge \neg a = 0$
Idempotenz	—	$a \vee a = a$
	—	$a \wedge a = a$
Absorption	—	$a \vee (a \wedge b) = a$
	—	$a \wedge (a \vee b) = a$
De-Morgan Regeln	—	$\neg(a \vee b) = \neg a \wedge \neg b$
	—	$\neg(a \wedge b) = \neg a \vee \neg b$

De-Morgan Regeln

$$\neg(a \vee b) = \neg a \wedge \neg b$$



$$\neg(a \wedge b) = \neg a \vee \neg b$$



1. Ersetzen von *UND* durch *ODER* und umgekehrt
 \Rightarrow Austausch der Funktion
2. Invertieren aller Ein- und Ausgänge

Verwendung

- ▶ bei der Minimierung logischer Ausdrücke
- ▶ beim Entwurf von Schaltungen
- ▶ siehe Abschnitte: „Schaltfunktionen“ und „Schaltnetze“

XOR: Exklusiv-Oder / Antivalenz

\Rightarrow entweder a oder b (ausschließlich)
 a ungleich b

(\Rightarrow Antivalenz)

- ▶ $a \oplus b = (\neg a \wedge b) \vee (a \wedge \neg b)$
 genau einer von den Termen a und b ist wahr
- ▶ $a \oplus b = (a \vee b) \wedge \neg(a \wedge b)$
 entweder a ist wahr, oder b ist wahr, aber nicht beide gleichzeitig
- ▶ $a \oplus a = 0$



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. **Logische Operationen**
 - Boole'sche Operationen
 - Bitweise logische Operationen
 - Schiebeoperationen
 - Anwendungsbeispiele





Gliederung (cont.)

Speicher-Organisation

Literatur

10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur





Gliederung (cont.)

21. Speicherhierarchie





Logische Operationen in Java und C

- ▶ eigener Datentyp?
 - ▶ Java: Datentyp boolean
 - ▶ C: implizit für alle Integertypen
- ▶ Vergleichsoperationen
- ▶ logische Grundoperationen
- ▶ Auswertungsreihenfolge / -prioritäten
- ▶ logische Operationen auch bitweise parallel möglich (s.u.)



Vergleichsoperationen

- ▶ $a == b$ wahr, wenn a gleich b
 - ▶ $a != b$ wahr, wenn a ungleich b
 - ▶ $a >= b$ wahr, wenn a größer oder gleich b
 - ▶ $a > b$ wahr, wenn a größer b
 - ▶ $a < b$ wahr, wenn a kleiner b
 - ▶ $a <= b$ wahr, wenn a kleiner oder gleich b
-
- ▶ Vergleich zweier Zahlen, Ergebnis ist logischer Wert
 - ▶ Java: Integerwerte alle im Zweierkomplement
 - ▶ C: Auswertung berücksichtigt signed/unsigned-Typen
 - ▶ Auswertung von links nach rechts,
mit (optionaler) Klammerung



Logische Operationen in C

- ▶ zusätzlich zu den Vergleichsoperatoren $<$, $<=$, $==$, $!=$, $>$, $>=$
- ▶ drei **logische** Operatoren:
 - ! logische Negation
 - && logisches UND
 - || logisches ODER
- ▶ Interpretation der Integerwerte:
 - der Zahlenwert $0 \Leftrightarrow$ logische 0 (false)
 - alle anderen Werte \Leftrightarrow logische 1 (true)
- ▶ völlig andere Semantik als in der Mathematik (!)
- ▶ völlig andere Funktion als die bitweisen Operationen (s.u.)



Logische Operationen in C (cont.)

- ▶ verkürzte Auswertung von links nach rechts (*shortcut*)
 - ▶ Abbruch, wenn Ergebnis feststeht
 - + kann zum Schutz von Ausdrücken benutzt werden
 - kann aber auch Seiteneffekte haben, z.B. Funktionsaufrufe

▶ Beispiele

▶ `(a > b) || ((b != c) && (b <= d))`

Beispiel	Wert
<code>!0x41</code>	<code>0x00</code>
<code>!0x00</code>	<code>0x01</code>
<code>!!0x00</code>	<code>0x00</code>
<code>0x69 && 0x55</code>	<code>0x01</code>
<code>0x69 0x55</code>	<code>0x01</code>

Logische Operationen in C: Logisch vs. Bitweise

- ▶ der Zahlenwert $0 \Leftrightarrow$ logische 0 (false)
 alle anderen Werte \Leftrightarrow logische 1 (true)
- ▶ Beispiel: $x = 0x66$ und $y = 0x93$

Ausdruck (bitweise)	Wert	Ausdruck (logisch)	Wert
x	0110 0110	x	0000 0001
y	1001 0011	y	0000 0001
$x \& y$	0000 0010	$x \&\& y$	0000 0001
$x y$	1111 0111	$x y$	0000 0001
$\sim x \sim y$	1111 1101	$!x !y$	0000 0000

Logische Operationen in C: verkürzte Auswertung

- ▶ logische Ausdrücke werden von links nach rechts ausgewertet
- ▶ Klammern werden natürlich berücksichtigt
- ▶ Abbruch, sobald der Wert eindeutig feststeht (*shortcut*)
- ▶ Vor- oder Nachteile möglich (codeabhängig)
 - + $(a \ \&\& \ 5/a)$ niemals Division durch Null. Der Quotient wird nur berechnet, wenn der linke Term ungleich Null ist.
 - + $(p \ \&\& \ *p++)$ niemals Nullpointer-Zugriff. Der Pointer wird nur verwendet, wenn p nicht Null ist.

Ternärer Operator

- ▶ $\langle condition \rangle ? \langle true-expression \rangle : \langle false-expression \rangle$
- ▶ Beispiel: $(x < 0) ? -x : x$ Absolutwert von x



Logische Operationen in Java

- ▶ Java definiert eigenen Datentyp `boolean`
- ▶ elementare Werte `false` und `true`
- ▶ alternativ `Boolean.FALSE` und `Boolean.TRUE`
- ▶ **keine** Mischung mit Integer-Werten wie in C

- ▶ Vergleichsoperatoren `<`, `<=`, `==`, `!=`, `>`, `>=`
- ▶ verkürzte Auswertung von links nach rechts (*shortcut*)

- ▶ Ternärer Operator
`<condition> ? <>true-expression> : <>false-expression>`
- ▶ Beispiel: `(x < 0) ? -x : x` Absolutwert von `x`



Bitweise logische Operationen

Integer-Datentypen doppelt genutzt:

1. Zahlenwerte (Ganzzahl, Zweierkomplement, Gleitkomma)
arithmetische Operationen: Addition, Subtraktion, usw.

2. Binärwerte mit w einzelnen Bits (Wortbreite w)
Boole'sche Verknüpfungen, bitweise auf allen w Bits
 - ▶ Grundoperationen: Negation, UND, ODER, XOR
 - ▶ Schiebe-Operationen: shift-left, rotate-right, usw.



Bitweise logische Operationen (cont.)

- ▶ Integer-Datentypen interpretiert als Menge von Bits
- ▶ bitweise logische Operationen möglich
- ▶ es gibt insgesamt 2^{2^n} Operationen mit n Operanden

- ▶ in Java und C sind vier Operationen definiert:

Negation	$\sim x$	Invertieren aller einzelnen Bits
UND	$x \& y$	Logisches UND aller einzelnen Bits
OR	$x y$	Logisches ODER aller einzelnen Bits
XOR	$x \wedge y$	Logisches XOR aller einzelnen Bits

- ▶ alle anderen Funktionen können damit dargestellt werden



Bitweise logische Operationen: Beispiel

 $x = 0010\ 1110$
 $y = 1011\ 0011$
 $\sim x = 1101\ 0001$ alle Bits invertiert

 $\sim y = 0100\ 1100$ alle Bits invertiert

 $x \& y = 0010\ 0010$ bitweises UND

 $x | y = 1011\ 1111$ bitweises ODER

 $x \wedge y = 1001\ 1101$ bitweises XOR

Schiebeoperationen

- ▶ als Ergänzung der bitweisen logischen Operationen
- ▶ für alle Integer-Datentypen verfügbar

- ▶ fünf Varianten:

Shift-Left `shl`

Logical Shift-Right `srl`

Arithmetic Shift-Right `sra`


Rotate-Left `rol`

Rotate-Right `ror`

- ▶ Schiebeoperationen in Hardware leicht zu realisieren
- ▶ auf fast allen Prozessoren im Befehlssatz

Shift-Left (shl)


- ▶ Verschieben der Binärdarstellung von x um n bits nach links
- ▶ links herausgeschobene n bits gehen verloren
- ▶ von rechts werden n Nullen eingefügt



- ▶ in Java und C direkt als Operator verfügbar: $x \ll n$
- ▶ `shl` um n bits entspricht der Multiplikation mit 2^n

Logical Shift-Right (sr1)


- ▶ Verschieben der Binärdarstellung von x um n bits nach rechts
- ▶ rechts herausgeschobene n bits gehen verloren
- ▶ von links werden n Nullen eingefügt



- ▶ in Java direkt als Operator verfügbar: $x \ggg n$
 in C nur für unsigned-Typen definiert: $x \gg n$
 für signed-Typen nicht vorhanden

Arithmetic Shift-Right (sra)


- ▶ Verschieben der Binärdarstellung von x um n bits nach rechts
- ▶ rechts herausgeschobene n bits gehen verloren
- ▶ von links wird n -mal das MSB (Vorzeichenbit) eingefügt
- ▶ Vorzeichen bleibt dabei erhalten (gemäß Zweierkomplement)




- ▶ in Java direkt als Operator verfügbar: $x \gg n$
- ▶ in C nur für signed-Typen definiert: $x \gg n$
- ▶ sra um n bits ist ähnlich der Division durch 2^n

Arithmetic Shift-Right: Beispiel

- $x \gg 1$ aus $0x10D3$ (4307) wird $0x0869$ (2153)



- $x \gg 3$ aus $0x90D3$ (-28460) wird $0xF21A$ (-3558)






Arithmetic Shift-Right: Division durch Zweierpotenzen?

- ▶ positive Werte: $x \gg n$ entspricht Division durch 2^n
- ▶ negative Werte: $x \gg n$ Ergebnis ist zu klein (!)
- ▶ gerundet in Richtung negativer Werte statt in Richtung Null:
 - 1111 1011 (-5)
 - 1111 1101 (-3)
 - 1111 1110 (-2)
 - 1111 1111 (-1)
- ▶ C: Kompensation durch Berechnung von $(x + (1 \ll k) - 1) \gg k$
 Details: Bryant & O'Hallaron

Rotate-Left (rol)


- ▶ Rotation der Binärdarstellung von x um n bits nach links
- ▶ herausgeschobene Bits werden von rechts wieder eingefügt



- ▶ in Java und C nicht als Operator verfügbar
- ▶ Java: `Integer.rotateLeft(int x, int distance)`

Rotate Right (ror)

- ▶ Rotation der Binärdarstellung von x um n bits nach rechts
- ▶ herausgeschobene Bits werden von links wieder eingefügt



- ▶ in Java und C nicht als Operator verfügbar
- ▶ Java: `Integer.rotateRight(int x, int distance)`



Shifts statt Integer-Multiplikation

- ▶ Integer-Multiplikation ist auf vielen Prozessoren langsam oder evtl. gar nicht als Befehl verfügbar
- ▶ Add./Subtraktion und logische Operationen: typisch 1 Takt
Shift-Operationen: meistens 1 Takt
- ⇒ eventuell günstig, Multiplikation mit Konstanten durch entsprechende Kombination aus shifts+add zu ersetzen
 - ▶ Beispiel: $9 \cdot x = (8 + 1) \cdot x$ ersetzt durch $(x \ll 3) + x$
 - ▶ viele Compiler erkennen solche Situationen



Beispiel: bit-set, bit-clear

Bits an Position p in einem Integer setzen oder löschen?

- ▶ Maske erstellen, die genau eine 1 gesetzt hat
- ▶ dies leistet $(1 \ll p)$, mit $0 \leq p \leq w$ bei Wortbreite w

```
public int bit_set( int x, int pos ) {  
    return x | (1 << pos); // mask = 0...010...0  
}
```

```
public int bit_clear( int x, int pos ) {  
    return x & ~(1 << pos); // mask = 1...101...1  
}
```

Beispiel: Byte-Swapping *network to/from host*

Linux: /usr/include/bits/byteswap.h

```
...
/* Swap bytes in 32 bit value.  */
#define __bswap_32(x) \
    (((x) & 0xff000000) >> 24) | (((x) & 0x00ff0000) >> 8) |\
    (((x) & 0x0000ff00) << 8) | (((x) & 0x000000ff) << 24)
...
```

Linux: /usr/include/netinet/in.h

```
...
# if __BYTE_ORDER == __LITTLE_ENDIAN
#   define ntohl(x) __bswap_32 (x)
#   define ntohs(x) __bswap_16 (x)
#   define htonl(x) __bswap_32 (x)
#   define htons(x) __bswap_16 (x)
# endif
...
```




Beispiel: RGB-Format für Farbbilder

Farbdarstellung am Monitor / Bildverarbeitung?

- ▶ Matrix aus $w \times h$ Bildpunkten
- ▶ additive Farbmischung aus Rot, Grün, Blau
- ▶ pro Farbkanal typischerweise 8-bit, Wertebereich 0..255
- ▶ Abstufungen ausreichend für (untrainiertes) Auge

- ▶ je ein 32-bit Integer pro Bildpunkt
- ▶ typisch: `0x00RRGGBB` oder `0xAARRGGBB`
- ▶ je 8-bit für Alpha/Transparenz, rot, grün, blau

- ▶ `java.awt.image.BufferedImage(TYPE_INT_ARGB)`



Beispiel: RGB-Rotfilter

```

public BufferedImage redFilter( BufferedImage src ) {
    int    w = src.getWidth();
    int    h = src.getHeight();
    int    type = BufferedImage.TYPE_INT_ARGB;
    BufferedImage dest = new BufferedImage( w, h, type );

    for( int y=0; y < h; y++ ) {           // alle Zeilen
        for( int x=0; x < w; x++ ) {       // von links nach rechts
            int    rgb = src.getRGB( x, y ); // Pixelwert bei (x,y)
                                                    // rgb = 0xAARRGGBB
            int    red = (rgb & 0x00FF0000); // Rotanteil maskiert
            dest.setRGB( x, y, red );
        }
    }
    return dest;
}
    
```

Beispiel: RGB-Graufilter

```

public BufferedImage grayFilter( BufferedImage src ) {
    ...
    for( int y=0; y < h; y++ ) { // alle Zeilen
        for( int x=0; x < w; x++ ) { // von links nach rechts
            int  rgb = src.getRGB( x, y ); // Pixelwert
            int  red = (rgb & 0x00FF0000) >>>16; // Rotanteil
            int  green = (rgb & 0x0000FF00) >>> 8; // Grünanteil
            int  blue = (rgb & 0x000000FF); // Blauanteil

            int  gray = (red + green + blue) / 3; // Mittelung

            dest.setRGB( x, y, (gray<<16)|(gray<<8)|gray );
        }
    }
    ...
}
    
```



Beispiel: Bitcount (mit while-Schleife)

Anzahl der gesetzten Bits in einem Wort?

- ▶ Anwendung z.B. für Kryptalgorithmen (Hamming-Distanz)
- ▶ Anwendung für Medienverarbeitung

```
public static int bitcount( int x ) {  
    int count = 0;  
  
    while( x != 0 ) {  
        count += (x & 0x00000001); // unterstes bit addieren  
        x = x >>> 1; // 1-bit rechts-schieben  
    }  
  
    return count;  
}
```

Beispiel: Bitcount (parallel, tree)

- ▶ Algorithmus mit Schleife ist einfach aber langsam
- ▶ schnelle parallele Berechnung ist möglich

```
int BitCount(unsigned int u)
{ unsigned int uCount;
  uCount = u - ((u >> 1) & 033333333333)
           - ((u >> 2) & 011111111111);
  return ((uCount + (uCount >> 3)) & 030707070707) % 63;
}
```

- ▶ viele Algorithmen: bit-Maskierung und Schieben
 - ▶ <http://gurmeet.net/puzzles/fast-bit-counting-routines>
 - ▶ <http://graphics.stanford.edu/~seander/bithacks.html>
 - ▶ Donald E. Knuth, *The Art of Computer Programming*: Volume 4A, Combinational Algorithms: Part1, Abschnitt 7.1.3
 - ▶ `java.lang.Integer.bitCount()`
- ▶ viele neuere Prozessoren/DSPs: eigener bitcount-Befehl

Übungsaufgabe 4.4



Tipps & Tricks: Rightmost bits

Donald E. Knuth, *The Art of Computer Programming*, Vol 4.1

Grundidee: am weitesten rechts stehenden 1-Bits / 1-Bit Folgen erzeugen Überträge in arithmetischen Operationen

▶ Integer x , mit $x = (\alpha 0 [1]^a 1 [0]^b)_2$

beliebiger Bitstring α , eine Null, dann $a + 1$ Einsen und b Nullen, mit $a \geq 0$ und $b \geq 0$.

▶ Ausnahmen: $x = -2^b$ und $x = 0$

$$\Rightarrow x = (\alpha 0 [1]^a 1 [0]^b)_2$$

$$\bar{x} = (\bar{\alpha} 1 [0]^a 0 [1]^b)_2$$

$$x - 1 = (\alpha 0 [1]^a 0 [1]^b)_2$$

$$-x = (\bar{\alpha} 1 [0]^a 1 [0]^b)_2$$

$$\Rightarrow \bar{x} + 1 = -x = \overline{x - 1}$$

Tipps & Tricks: Rightmost bits (cont.)

Donald E. Knuth, *The Art of Computer Programming*, Vol 4.1

$$\begin{aligned}
 x &= (\alpha 0 [1]^a 1 [0]^b)_2 & \bar{x} &= (\bar{\alpha} 1 [0]^a 0 [1]^b)_2 \\
 x - 1 &= (\alpha 0 [1]^a 0 [1]^b)_2 & -x &= (\bar{\alpha} 1 [0]^a 1 [0]^b)_2
 \end{aligned}$$

$x \& (x - 1) = (\alpha 0 [1]^a 0 [0]^b)_2$	letzte 1 entfernt
$x \& -x = (0^\infty 0 [0]^a 1 [0]^b)_2$	letzte 1 extrahiert
$x -x = (1^\infty 1 [1]^a 1 [0]^b)_2$	letzte 1 nach links verschmiert
$x \oplus -x = (1^\infty 1 [1]^a 0 [0]^b)_2$	letzte 1 entfernt und verschmiert
$x (x - 1) = (\alpha 0 [1]^a 1 [1]^b)_2$	letzte 1 nach rechts verschmiert
$\bar{x} \& (x - 1) = (0^\infty 0 [0]^a 0 [1]^b)_2$	letzte 1 nach rechts verschmiert
$((x (x - 1)) + 1) \& x = (\alpha 0 [0]^a 0 [0]^b)_2$	letzte 1-Bit Folge entfernt



Aufbau und Adressierung des Speichers

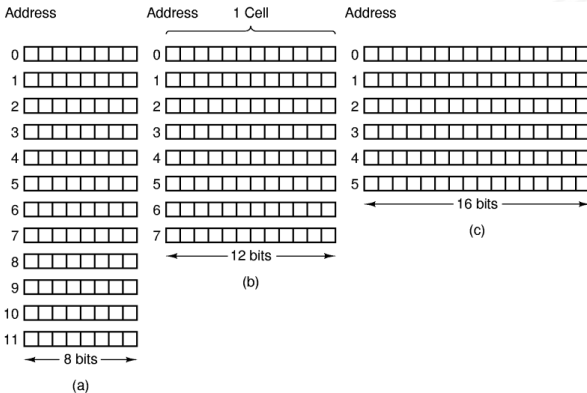
- ▶ Abspeichern von Zahlen, Zeichen, Strings?
 - ▶ kleinster Datentyp üblicherweise ein Byte (8-bit)
 - ▶ andere Daten als Vielfache: 16-bit, 32-bit, 64-bit, ...

- ▶ Organisation und Adressierung des Speichers?
 - ▶ Adressen typisch in Bytes angegeben
 - ▶ erlaubt Adressierung einzelner ASCII-Zeichen, usw.

- ▶ aber Maschine/Prozessor arbeitet wortweise
- ▶ Speicher daher ebenfalls wortweise aufgebaut
- ▶ typischerweise 32-bit oder 64-bit


Speicher-Organisation

- ▶ Speicherkapazität: Anzahl der Worte \cdot Bits/Wort
- ▶ Beispiele: $12 \cdot 8$ $8 \cdot 12$ $6 \cdot 16$ Bits



Wort-basierte Organisation des Speichers

- ▶ Speicher Wort-orientiert
- ▶ Adressierung Byte-orientiert
 - ▶ die Adresse des ersten Bytes im Wort
 - ▶ Adressen aufeinanderfolgender Worte unterscheiden sich um 4 (32-bit Wort) oder 8 (64-bit)
- ▶ Adressen normalerweise Vielfache der Wortlänge
- ▶ verschobene Adressen „in der Mitte“ eines Worts oft unzulässig





Datentypen auf Maschinenebene

- ▶ gängige Prozessoren unterstützen mehrere Datentypen
- ▶ entsprechend der elementaren Datentypen in C, Java, ...
- ▶ `void*` ist ein **Pointer** (Referenz, Speicheradresse)
- ▶ Beispiel für die Anzahl der Bytes:

C Datentyp	DEC Alpha	typ. 32-bit	Intel IA-32 (x86)
int	4	4	4
long int	8	4	4
char	1	1	1
short	2	2	2
float	4	4	4
double	8	8	8
long double	8	8	10/12
void *	8	4	4

Datentypen auf Maschinenebene (cont.)

Abhängigkeiten (!)

- ▶ Prozessor
- ▶ Betriebssystem
- ▶ Compiler

segment word size compiler	16 bit			32 bit				64 bit					
	Microsoft	Borland	Watcom	Microsoft	Intel Windows	Borland	Watcom	Gnu v.3.x	Intel Linux	Microsoft	Intel Windows	Gnu	Intel Linux
bool	2	1	1	1	1	1	1	1	1	1	1	1	1
char	1	1	1	1	1	1	1	1	1	1	1	1	1
wchar_t		2		2	2	2	2	2	2	2	2	4	4
short int	2	2	2	2	2	2	2	2	2	2	2	2	2
int	2	2	2	4	4	4	4	4	4	4	4	4	4
long int	4	4	4	4	4	4	4	4	4	4	4	8	8
__int64				8	8			8	8	8	8	8	8
enum	2	2	1	4	4	4	4	4	4	4	4	4	4
float	4	4	4	4	4	4	4	4	4	4	4	4	4
double	8	8	8	8	8	8	8	8	8	8	8	8	8
long double	10	10	8	8	16	10	8	12	12	8	16	16	16
__m64				8	8			8			8	8	8
__m128				16	16			16	16	16	16	16	16
__m256					32					32			32
pointer	2	2	2	4	4	4	4	4	4	8	8	8	8
far pointer	4	4	4										
function pointer	2	2	2	4	4	4	4	4	4	8	8	8	8
data member pointer (min)	2	4	6	4	4	8	4	4	4	4	4	8	8
data member pointer (max)		4	6	12	12	8	12	4	4	12	12	8	8
member function pointer (min)	2	12	6	4	4	12	4	8	8	8	8	16	16
member function pointer (max)		12	6	16	16	12	16	8	8	24	24	16	16

Table 1 shows how many bytes of storage various objects use for different compilers.

www.agner.org/optimize/calling_conventions.pdf

Byte-Order

- ▶ *Wie sollen die Bytes innerhalb eines Wortes angeordnet werden?*
- ▶ Speicher wort-basiert \Leftrightarrow Adressierung byte-basiert

Zwei Möglichkeiten / Konventionen:

- ▶ **Big Endian:** Sun, Mac, usw.
 das MSB (*most significant byte*) hat die kleinste Adresse
 das LSB (*least significant byte*) hat die höchste —"
- ▶ **Little Endian:** Alpha, x86
 das MSB hat die höchste, das LSB die kleinste Adresse

satirische Referenz auf Gulliver's Reisen (Jonathan Swift)

Byte-Order: Beispiel


```
int A = 15213;
int B = -15213;
long int C = 15213;
```

Dezimal: 15213


Binär: 0011 1011 0110 1101

Hex: 3 B 6 D


Linux/Alpha A Sun A



Linux C Alpha C Sun C



Linux/Alpha B Sun B



2-Komplement

Big Endian

Little Endian

Byte-Order: Beispiel-Datenstruktur

```

/* JimSmith.c - example record for byte-order demo */

typedef struct employee {
    int    age;
    int    salary;
    char   name[12];
} employee_t;

static employee_t jimmy = {
    23,                // 0x0017
    50000,             // 0xc350
    "Jim Smith",      // J=0x4a i=0x69 usw.
};
  
```



Byte-Order: x86 und SPARC

```
tams12> objdump -s JimSmith.x86.o
JimSmith.x86.o:      file format elf32-i386

Contents of section .data:
 0000 17000000 50c30000 4a696d20 536d6974  ....P...Jim Smit
 0010 68000000                                     h...

tams12> objdump -s JimSmith.sparc.o
JimSmith.sparc.o:   file format elf32-sparc

Contents of section .data:
 0000 00000017 0000c350 4a696d20 536d6974  ....PJim Smit
 0010 68000000                                     h...
```




Netzwerk-Byteorder

- ▶ Byteorder muss bei Datenübertragung zwischen Rechnern berücksichtigt und eingehalten werden
- ▶ Internet-Protokoll (IP) nutzt ein big-endian Format
- ▶ auf x86-Rechnern müssen alle ausgehenden und ankommenden Datenpakete umgewandelt werden
- ▶ zugehörige Hilfsfunktionen / Makros in `netinet/in.h`
 - ▶ inaktiv auf big-endian, **byte-swapping** auf little-endian
 - ▶ `ntohl(x)`: network-to-host-long
 - ▶ `htons(x)`: host-to-network-short
 - ▶ ...

Beispiel: Byte-Swapping *network to/from host*


Linux: `/usr/include/bits/byteswap.h`

```
...
/* Swap bytes in 32 bit value.  */
#define __bswap_32(x) \
    (((x) & 0xff000000) >> 24) | (((x) & 0x00ff0000) >> 8) |\
    (((x) & 0x0000ff00) << 8) | (((x) & 0x000000ff) << 24)
...
```

Linux: `/usr/include/netinet/in.h`

```
...
# if __BYTE_ORDER == __LITTLE_ENDIAN
#   define ntohl(x) __bswap_32 (x)
#   define ntohs(x) __bswap_16 (x)
#   define htonl(x) __bswap_32 (x)
#   define htons(x) __bswap_16 (x)
# endif
...
```

Misaligned Memory Access



- ▶ Speicher Byte-weise adressiert
- ▶ aber Zugriffe lesen/schreiben jeweils ein ganzes Wort

Was passiert bei „krummen“ (*misaligned*) Adressen?

- ▶ automatische Umsetzung auf mehrere Zugriffe
- ▶ Programmabbruch

(x86)

(SPARC)



Programm zum Erkennen der Byteorder

- ▶ Programm gibt Daten byteweise aus
- ▶ C-spezifische Typ- (Pointer-) Konvertierung
- ▶ Details: siehe Bryant 2.1.4 (und Abbildungen 2.3/2.4)

```

void show_bytes( byte_pointer start, int len ) {
    int i;
    for( i=0; i < len; i++ ) {
        printf( " %.2x", start[i] );
    }
    printf ( "\n" );
}

void show_double( double x ) {
    show_bytes( (byte_pointer) &x, sizeof( double ));
}

...
    
```



Literatur: Vertiefung

- ▶ Donald E. Knuth, *The Art of Computer Programming, Volume 4, Fascicle 1: Bitwise Tricks & Techniques, Binary Decision Diagrams*, Addison-Wesley, 2009
- ▶ Klaus von der Heide, *Vorlesung: Technische Informatik 1 — interaktives Skript*, Universität Hamburg, FB Informatik, 2005
tams.informatik.uni-hamburg.de/lectures/2004ws/vorlesung/t1



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. **Codierung**

Grundbegriffe

Ad-hoc Codierungen

Einschrittige Codes





Gliederung (cont.)

Quellencodierung
Symbolhäufigkeiten
Informationstheorie
Entropie
Kanalcodierung
Fehlererkennende Codes
Zyklische Codes
Praxisbeispiele
Literatur

11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten
14. Schaltwerke





Gliederung (cont.)

15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Definition: Codierung

Unter **Codierung** versteht man das Umsetzen einer vorliegenden Repräsentation A in eine andere Repräsentation B .

- ▶ häufig liegen beide Repräsentationen A und B in derselben Abstraktionsebene
- ▶ die Interpretation von B nach A muss eindeutig sein
- ▶ eine **Umcodierung** liegt vor, wenn die Interpretation umkehrbar eindeutig ist



Code, Codewörter

- ▶ **Codewörter:** die Wörter der Repräsentation B aus einem Zeichenvorrat Z
- ▶ **Code:** die Menge aller Codewörter
- ▶ **Blockcode:** alle Codewörter haben dieselbe Länge
- ▶ **Binärzeichen:** der Zeichenvorrat z enthält genau zwei Zeichen
- ▶ **Binärwörter:** Codewörter aus Binärzeichen
- ▶ **Binärcode:** alle Codewörter sind Binärwörter



Gründe für den Einsatz von Codes

- ▶ effiziente Darstellung und Verarbeitung von Information
- ▶ Datenkompression, -reduktion

- ▶ effiziente Übertragung von Information
 - ▶ Verkleinerung der zu übertragenden Datenmenge
 - ▶ Anpassung an die Technik des Übertragungskanals
 - ▶ Fehlererkennende und -korrigierende Codes

- ▶ Geheimhaltung von Information
 z.B. Chiffrierung in der Kryptologie
- ▶ Identifikation, Authentifikation



Wichtige Aspekte

Unterteilung gemäß der Aufgabenstellung

- ▶ **Quellencodierung:** Anpassung an Sender/Quelle
- ▶ **Kanalcodierung:** Anpassung an Übertragungsstrecke
- ▶ **Verarbeitungscodierung:** im Rechner
- ▶ sehr unterschiedliche Randbedingungen und Kriterien für diese Teilbereiche. Zum Beispiel sind fehlerkorrigierende Codes bei der Nachrichtenübertragung essentiell, im Rechner wegen der hohen Zuverlässigkeit weniger wichtig.



Darstellung von Codes

▶ Wertetabellen

- ▶ jede Zeile enthält das Urbild (zu codierende Symbol) und das zugehörige Codewort
- ▶ sortiert, um das Auffinden eines Codeworts zu erleichtern
- ▶ technische Realisierung durch Ablegen der Wertetabelle im Speicher, Zugriff über Adressierung anhand des Urbilds

▶ Codebäume

- ▶ Anordnung der Symbole als Baum
- ▶ die zu codierenden Symbole als Blätter
- ▶ die Zeichen an den Kanten auf dem Weg von der Wurzel zum Blatt bilden das Codewort

▶ Logische Gleichungen

▶ Algebraische Ausdrücke



Codierung von Text

- ▶ siehe letzte Woche
- ▶ Text selbst als Reihenfolge von Zeichen
- ▶ ASCII, ISO-8859 und Varianten, Unicode

Für geschriebenen (formatierten) Text:

- ▶ Trennung des reinen Textes von seiner Formatierung
- ▶ Formatierung: Schriftart, Größe, Farbe, usw.
- ▶ diverse applikationsspezifische Binärformate
- ▶ Markup-Sprachen (SGML, HTML)



Codierungen für Dezimalziffern

	BCD	Gray	Exzess3	Aiken	biquinär	1-aus-10	2-aus-5
0	0000	0000	0011	0000	000001	0000000001	11000
1	0001	0001	0100	0001	000010	0000000010	00011
2	0010	0011	0101	0010	000100	0000000100	00101
3	0011	0010	0110	0011	001000	0000001000	00110
4	0100	0110	0111	0100	010000	0000010000	01001
5	0101	0111	1000	1011	100001	0000100000	01010
6	0110	0101	1001	1100	100010	0001000000	01100
7	0111	0100	1010	1101	100100	0010000000	10001
8	1000	1100	1011	1110	101000	0100000000	10010
9	1001	1101	1100	1111	110000	1000000000	10100



Codierungen für Dezimalziffern

- ▶ alle Codes der Tabelle sind Binärcodes
- ▶ alle Codes der Tabelle sind Blockcodes
- ▶ jede Spalte der Tabelle listet alle Codewörter eines Codes
- ▶ jede Wandlung von einem Code der Tabelle in einen anderen Code ist eine Umcodierung
- ▶ aus den Codewörtern geht **nicht** hervor, welcher Code vorliegt
- ▶ Dezimaldarstellung in Rechnern unüblich, die obigen Codes werden also kaum noch verwendet



Begriffe für Binärcodes

- ▶ **Minimalcode:** alle $N = 2^n$ Codewörter bei Wortlänge n werden benutzt
- ▶ **Redundanter Code:** nicht alle möglichen Codewörter werden benutzt
- ▶ **Gewicht:** Anzahl der Einsen in einem Codewort
- ▶ **komplementär:** zu jedem Codewort c existiert ein gültiges Codewort \bar{c}
- ▶ **einschrittig:** aufeinanderfolgende Codewörter unterscheiden sich nur an einer Stelle
- ▶ **zyklisch:** bei n geordneten Codewörtern ist $c_0 = c_n$



Dualcode

- ▶ der Name für Codierung der Integerzahlen im Stellenwertsystem
- ▶ Codewort

$$c = \sum_{i=0}^{n-1} a_i \cdot 2^i, \quad a_i \in \{0, 1\}$$

- ▶ alle Codewörter werden genutzt: Minimalcode
- ▶ zu jedem Codewort existiert ein komplementäres Codewort
- ▶ bei fester Wortbreite ist c_0 gleich $c_n \Rightarrow$ zyklisch
- ▶ nicht einschrittig



Einschrittige Codes

- ▶ möglich für Mengen mit Ordnungsrelation
- ▶ Elemente der Menge werden durch Binärwörter codiert
- ▶ **einschrittiger Code**: die Codewörter für benachbarte Elemente der Menge unterscheiden sich in genau einer Stelle
- ▶ **zyklisch einschrittig**: das erste und letzte Wort des Codes unterscheiden sich ebenfalls genau in einer Stelle

- ▶ Einschrittige Codes werden benutzt, wenn ein Ablesen der Bits auch beim Wechsel zwischen zwei Codeworten möglich ist (bzw. nicht verhindert werden kann)
- ▶ z.B.: Winkelcodierscheiben oder digitale Schieblehre
- ▶ viele interessante Varianten möglich: siehe Knuth, AoCP




Einschrittige Codes: Matlab-Demo

- ▶ T1-Skript, Kapitel 1.4: Ablesen eines Wertes mit leicht gegeneinander verschobenen Übergängen der Bits
 - ▶ `demoeinschritt(0:59)` normaler Dualcode
 - ▶ `demoeinschritt(einschritt(60))` einschrittiger Code


- ▶ maximaler Ablesefehler
 - ▶ 2^{n-1} beim Dualcode
 - ▶ 1 beim einschrittigen Code

- ▶ Konstruktion eines einschrittigen Codes
 - ▶ rekursiv
 - ▶ als ununterbrochenen Pfad im KV-Diagramm (s.u.)


Ablezen des Wertes aus Dualcode




Ablezen des Wertes aus einschrittigem Code




Gray-Code: Prinzip eines Winkeldrehgebers




Gray-Code: mehrstufiger Drehgeber



Gray-Code: 5-bit Codierscheibe



Gray-Code: 10-bit Codierscheibe





Einschrittiger Code: rekursive Konstruktion

- ▶ Starte mit zwei Codewörtern: 0 und 1
- ▶ Gegeben: Einschrittiger Code C mit n Codewörtern
- ▶ Rekursion: Erzeuge Code C_2 mit (bis zu) $2n$ Codewörtern
 1. hänge eine führende 0 vor alle vorhandenen n Codewörter
 2. hänge eine führende 1 vor die in umgekehrter Reihenfolge notierten Codewörter

$$\{ 0, 1 \}$$

$$\{ 00, 01, 11, 10 \}$$

$$\{ 000, 001, 011, 010, 110, 111, 101, 100 \}$$

$$\dots$$



Karnaugh-Veitch Diagramm

		x1 x0			
		00	01	11	10
x3 x2	00	0	1	3	2
	01	4	5	7	6
	11	12	13	15	14
	10	8	9	11	10

		x1 x0			
		00	01	11	10
x3 x2	00	0000	0001	0011	0010
	01	0100	0101	0111	0110
	11	1100	1101	1111	1110
	10	1000	1001	1011	1010

- ▶ 2D-Diagramm mit $2^n = 2^{n_y} \times 2^{n_x}$ Feldern
 - ▶ gängige Größen sind: 2×2 , 2×4 , 4×4
darüber hinaus: mehrere Diagramme der Größe 4×4
 - ▶ Anordnung der Indizes ist im einschrittigen-Code (!)
- ⇒ benachbarte Felder unterscheiden sich gerade um 1 Bit

Einschrittiger Code: KV-Diagramm



- ▶ jeder Pfad entspricht einem einschrittigen Code
- ▶ geschlossener Pfad: zyklisch einschrittiger Code
 - ▶ links: 0,1,3,2,6,7,5,13,15,14,10,11,9,8,12,4
 - ▶ rechts: 1,3,7,6,14,15,11,9,13,12,4,5

Einschrittiger Code: KV-Diagramm (cont.)

		x1 x0			
		00	01	11	10
x3 x2	00	0	1	3	2
	01	4	5	7	6
	11	12	13	15	14
	10	8	9	11	10

		x1 x0			
		00	01	11	10
x3 x2	00	0	1	3	2
	01	4	5	7	6
	11	12	13	15	14
	10	8	9	11	10

- ▶ linke und rechte Spalte unterscheiden sich in 1 Bit
 obere und untere Zeile unterscheiden sich in 1 Bit
- ⇒ KV-Diagramm als „außen zusammengeklebt“ denken
- ▶ Pfade können auch „außen herum“ geführt werden
 - ▶ links: 4,5,13,15,7,6,14,10,8,12 rechts: 2,6,14,10



Gray-Code: Umwandlung in/von Dualcode

Umwandlung: Dual- in Graywort

1. MSB des Dualworts wird MSB des Grayworts
 2. von links nach rechts: bei jedem Koeffizientenwechsel im Dualwort wird das entsprechende Bit im Graywort 1, sonst 0
- ▶ Beispiele $0011 \rightarrow 0010$, $1110 \rightarrow 1001$, $0110 \rightarrow 0101$ usw.
- ▶ $\text{gray}(x) = x \wedge (x \ggg 1)$



Gray-Code: Umwandlung in/von Dualcode (cont.)

Umwandlung: Gray- in Dualwort

1. MSB wird übernommen
2. von links nach rechts: wenn das Graywort eine Eins aufweist, wird das vorhergehende Bit des Dualworts invertiert in die entsprechende Stelle geschrieben, sonst wird das Zeichen der vorhergehenden Stelle direkt übernommen

▶ Beispiele $0010 \rightarrow 0011$, $1001 \rightarrow 1110$, $0101 \rightarrow 0110$ usw.

▶ in Hardware einfach durch Kette von XOR-Operationen

<http://tams.informatik.uni-hamburg.de/applets/hades/webdemos/10-gates/15-graycode/dual2gray.html>



Optimalcodes: Codes variabler Länge

- ▶ Einsatz zur Quellencodierung
- ▶ Minimierung der Datenmenge durch Anpassung an die Symbolhäufigkeiten
- ▶ häufige Symbole bekommen kurze Codewörter, seltene Symbole längere Codewörter
- ▶ anders als bei Blockcodes ist die Trennung zwischen Codewörtern nicht durch Abzählen möglich
- ⇒ Einhalten der **Fano-Bedingung** notwendig oder Einführen von **Markern** zwischen den Codewörtern



Fano-Bedingung

Eindeutige Decodierung eines Codes mit variabler Wortlänge?

Fano-Bedingung

Kein Wort aus einem Code bildet den Anfang eines anderen Codewortes

- ▶ die sogenannte **Präfix-Eigenschaft**
- ▶ nach R. M. Fano (1961)

- ▶ ein **Präfix-Code** ist eindeutig decodierbar
- ▶ Blockcodes sind Präfix-Codes



Fano-Bedingung: Beispiele

- ▶ Telefonnummern: das Vorwahlsystem gewährleistet die Fano-Bedingung

110, 112 : Notrufnummern

42883 2502 : Ortsnetz (keine führende Null)

040 42883 2502 : nationales Netz

0049 40 42883 2502 : internationale Rufnummer

- ▶ Morse-Code: Fano-Bedingung verletzt

Morse-Code

Punkt: kurzer Ton
 Strich: langer Ton

a	• —	o	— — —	4	• • • • —
ä	• — • —	ö	— — — •	5	• • • • •
å	• — — • —	p	• — — •	6	— • • • •
b	— • • •	q	— — • —	7	— — • • •
c	— • — •	r	• — •	8	— — — • •
ch	— — — —	s	• • •	9	— — — — •
d	— • •	t	—	.	• — • — • —
e	•	u	• • —	,	— — • • — —
é	• • — • •	ü	• • — —	:	— — — • • •
f	• • — •	v	• • • —	—	— • • • • —
g	— — •	w	• — —	,	• — — — — •
h	• • • •	x	— • • —	(— • — — — • —
i	• •	y	— • — —	?	• • — — • •
j	• — — —	z	— — • •	“	• — • • — •
k	— • —			Notruf	• • • — — — • • •
l	• — • •	0	— — — — —	SP	• •
m	— —	1	• — — — —	Anfang	— • — • —
n	— •	2	• • — — —	Ende	• • • — • —
ñ	— — • — —	3	• • • — —		

Morse-Code (cont.)

► Eindeutigkeit

Codewort: • • • • • – •

e → •

i → • •

n → – •

r → • – •


s → • • •

- bestimmte Morse-Sequenzen sind mehrdeutig
- Pause zwischen den Symbolen notwendig

► Codierung

- Häufigkeit der Buchstaben = $1 / \text{Länge des Codewortes}$
- Effizienz: kürzere Codeworte
- Darstellung als Codebaum

Morse-Code: Codebaum (Ausschnitt)



- ▶ Symbole als Knoten (!) oder Blätter
- ▶ Codewort am Pfad von Wurzel zum Blatt ablesen



Morse-Code: Umschlüsselung

Umschlüsselung des Codes für binäre Nachrichtenübertragung

- ▶ 110 als Umschlüsselung des langen Tons -
10 als Umschlüsselung des kurzen Tons .
0 als Trennzeichen zwischen Morse-Codewörtern
- ▶ der neue Code erfüllt die Fano-Bedingung
jetzt eindeutig decodierbar: 101010011011011001010100 (SOS)
- ▶ viele andere Umschlüsselungen möglich, z.B.:
1 als Umschlüsselung des langen Tons -
01 als Umschlüsselung des kurzen Tons .
00 als Trennzeichen zwischen Morse-Codewörtern



Codierung nach Fano

- Gegeben: die zu codierenden Urwörter a_i
 und die zugehörigen Wahrscheinlichkeiten $p(a_i)$
- ▶ Ordnung der Urwörter anhand ihrer Wahrscheinlichkeiten
 $p(a_1) \geq p(a_2) \geq \dots \geq p(a_n)$
 - ▶ Einteilung der geordneten Urwörter in zwei Gruppen mit
 möglichst gleicher Gesamtwahrscheinlichkeit. Eine Gruppe
 bekommt als erste Codewortstelle eine 0, die andere eine 1
 - ▶ Diese Teilgruppen werden wiederum entsprechend geteilt, und
 den Hälften wieder eine 0, bzw. eine 1, als nächste
 Codewortstelle zugeordnet
 - ▶ Das Verfahren wird wiederholt, bis jede Teilgruppe nur noch
 ein Element enthält
 - ▶ vorteilhafter, je größer die Anzahl der Urwörter (!)



Codierung nach Fano: Beispiel

Urbildmenge $\{A, B, C, D\}$ und zugehörige
Wahrscheinlichkeiten $\{0.45, 0.1, 0.15, 0.3\}$

0. Sortierung nach Wahrscheinlichkeiten ergibt $\{A, D, C, B\}$
 1. Gruppenaufteilung ergibt $\{A\}$ und $\{D, C, B\}$
Codierung von A mit 0 und den anderen Symbolen als 1^*
 2. weitere Teilung ergibt $\{D\}$, und $\{C, B\}$
 3. letzte Teilung ergibt $\{C\}$ und $\{B\}$
- ⇒ Codewörter sind $A = 0$, $D = 10$, $C = 110$ und $B = 111$

mittlere Codewortlänge L

- ▶ $L = 0.45 \cdot 1 + 0.3 \cdot 2 + 0.15 \cdot 3 + 0.1 \cdot 3 = 1.8$
- ▶ zum Vergleich: Blockcode mit 2 Bits benötigt $L = 2$

Codierung nach Fano: Deutsche Großbuchstaben

Buchstabe a_i	Wahrscheinlichkeit $p(a_i)$	Code (Fano)	Bits
Leerzeichen	0.15149	000	3
E	0.14700	001	3
N	0.08835	010	3
R	0.06858	0110	4
I	0.06377	0111	4
S	0.05388	1000	4
...
Ö	0.00255	111111110	9
J	0.00165	1111111110	10
Y	0.00017	11111111110	11
Q	0.00015	111111111110	12
X	0.00013	111111111111	12

Fano-Code der Buchstaben der deutschen Sprache, Ameling 1992

Codierung nach Huffman

- Gegeben: die zu codierenden Urwörter a_i
 und die zugehörigen Wahrscheinlichkeiten $p(a_i)$
- ▶ Ordnung der Urwörter anhand ihrer Wahrscheinlichkeiten
 $p(a_1) \leq p(a_2) \leq \dots \leq p(a_n)$
 - ▶ in jedem Schritt werden die zwei Wörter mit der geringsten Wahrscheinlichkeit zusammengefasst und durch ein neues ersetzt
 - ▶ das Verfahren wird wiederholt, bis eine Menge mit nur noch zwei Wörtern resultiert
 - ▶ rekursive Codierung als Baum (z.B.: links 0, rechts 1)
 - ▶ ergibt die kleinstmöglichen mittleren Codewortlängen
 - ▶ Abweichungen zum Verfahren nach Fano sind aber gering
 - ▶ vielfältiger Einsatz (u.a. bei JPEG, MPEG, ...)



Codierung nach Huffman: Beispiel

Urbildmenge $\{A, B, C, D\}$ und zugehörige
Wahrscheinlichkeiten $\{0.45, 0.1, 0.15, 0.3\}$

0. Sortierung nach Wahrscheinlichkeiten ergibt $\{B, C, D, A\}$
 1. Zusammenfassen von B und C als neues Wort E ,
Wahrscheinlichkeit von E ist dann $p(E) = 0.1 + 0.15 = 0.25$
 2. Zusammenfassen von D und E als neues Wort F mit
 $p(F) = 0.55$
 3. Zuordnung der Bits entsprechend der Wahrscheinlichkeiten
 - ▶ $F = 0$ und $A = 1$
 - ▶ Split von F in $D = 00$ und $E = 01$
 - ▶ Split von E in $C = 010$ und $B = 011$
- ⇒ Codewörter sind $A = 1$, $D = 00$, $C = 010$ und $B = 011$



Bildung eines Huffman-Baums


- ▶ Alphabet = $\{E, I, N, S, D, L, R\}$
- ▶ relative Häufigkeiten
 $E = 18, I = 10, N = 6, S = 7, D = 2, L = 5, R = 4$
- ▶ Sortieren anhand der Häufigkeiten
- ▶ Gruppierung (rekursiv)
- ▶ Aufbau des Codebaums
- ▶ Ablesen der Codebits

Bildung eines Huffman-Baums (cont.)


D	R	L	N	S	I	E
2	4	5	6	7	10	18




D	R	L	N	S	I	E
2	4	5	6	7	10	18




L	N	6	S	I	E
5	6		7	10	18



6	S	I	11	E
	7	10		18



Bildung eines Huffman-Baums (cont.)



I	00
L	010
N	011
D	1000
R	1001
S	101
E	11

1001 00 11 101 11
 R I E S E




Codierung nach Huffman: Deutsche Großbuchstaben

Zeichen	Code	Zeichen	Code
—	001	O	000110
E	010	B	100010
N	111	Z	100011
R	0110	W	100110
I	0111	F	100111
S	1010	K	0001011
T	1100	V	0001111
D	1101	Ü	00010100
H	00000	P	00010101
A	00001	Ä	00011100
U	10000	Ö	000111010
L	10010	J	0001110110
C	10110	Y	00011101111
G	10111	Q	000111011100
M	000100	X	000111011101



Codierung nach Huffman: Codebaum



ca. 4.5 Bits/Zeichen,
 1.7-Mal besser als ASCII



Codierung nach Huffman: Minimale Codelänge

- ▶ Sei C ein Huffman-Code mit durchschnittlicher Codelänge L
- ▶ Sei D ein weiterer Präfix-Code mit durchschnittlicher Codelänge M , mit $M < L$ und M minimal
- ▶ Berechne die C und D zugeordneten Decodierbäume A und B
- ▶ Betrachte die beiden Endknoten für Symbole kleinster Wahrscheinlichkeit:
 - ▶ Weise dem Vorgängerknoten das Gewicht $p_{s-1} + p_s$ zu
 - ▶ streiche die Endknoten
 - ▶ Codelänge reduziert sich um $p_{s-1} + p_s$
- ▶ Fortsetzung führt dazu, dass Baum C sich auf Baum mit durchschnittlicher Länge 1 reduziert, und D auf Länge < 1 . Dies ist aber nicht möglich.



Codierung nach Huffman: Symbole mit $p \geq 0.5$

Was passiert, wenn ein Symbol eine Häufigkeit $p_0 \geq 0.5$ aufweist?

- ▶ die Huffman-Codierung müsste weniger als ein Bit zuordnen, dies ist jedoch nicht möglich
- ⇒ Huffman- (und Fano-) Codierung ist in diesem Fall ineffizient

- ▶ Beispiel: Codierung eines Bildes mit einheitlicher Hintergrundfarbe
- ▶ andere Ideen notwendig
 - ▶ Lauflängencodierung (Fax, GIF, PNG)
 - ▶ Cosinustransformation (JPEG), usw.



Dynamic Huffman Coding

was tun, wenn

- ▶ die Symbolhäufigkeiten nicht vorab bekannt sind?
- ▶ die Symbolhäufigkeiten sich ändern können?

Dynamic Huffman Coding (Knuth 1985)

- ▶ Encoder protokolliert die (bisherigen) Symbolhäufigkeiten
- ▶ Codebaum wird dynamisch aufgebaut und ggf. umgebaut
- ▶ Decoder arbeitet entsprechend:
Codebaum wird mit jedem decodierten Zeichen angepasst
- ▶ Symbolhäufigkeiten werden nicht explizit übertragen



Kraft-Ungleichung

- ▶ Leon G. Kraft, 1949

<http://de.wikipedia.org/wiki/Kraft-Ungleichung>

- ▶ Eine notwendige und hinreichende Bedingung für die Existenz eines eindeutig decodierbaren s -elementigen Codes C mit Codelängen $l_1 \leq l_2 \leq l_3 \leq \dots \leq l_s$ über einem q -nären Zeichenvorrat F ist:

$$\sum_{i=1}^s \frac{1}{q^{l_i}} \leq 1$$

- ▶ Beispiel

$\{1, 00, 01, 11\}$ ist nicht eindeutig decodierbar,
denn $\frac{1}{2} + 3 \cdot \frac{1}{4} = 1.25 > 1$



Kraft-Ungleichung: Beispiel

- ▶ Sei $F = \{0, 1, 2\}$ (ternäres Alphabet)
 - ▶ Seien die geforderten Längen der Codewörter: 1,2,2,2,2,3,3,3
 - ▶ Einsetzen in die Ungleichung: $\frac{1}{3} + 5 \cdot \frac{1}{3^2} + 3 \cdot \frac{1}{3^3} = 1$
- ⇒ Also existiert ein passender Präfixcode.
- ▶ Konstruktion entsprechend des Beweises
- 0 10 11 12 20 21 220 221 222

Kraft-Ungleichung: Beweis

Sei $l_s = m$ und seien u_i die Zahl der Codewörter der Länge i

- ▶ Wir schreiben

$$\sum_{i=1}^s \frac{1}{q^i} = \sum_{j=1}^m \frac{u_j}{q^j} = \frac{1}{q^m} \sum_{j=1}^m u_j \cdot q^{m-j} \leq 1$$

$$u_m + \sum_{j=1}^m u_j \cdot q^{mj} \leq q^m \quad (*)$$

- ▶ Jedes Codewort der Länge i „verbraucht“ q^{m-i} Wörter aus F^m
 - ▶ Summe auf der linken Seite von $(*)$ ist die Zahl der durch den Code C benutzten Wörter von F^m
- ⇒ Wenn C die Präfix-Bedingung erfüllt, gilt $(*)$



Informationstheorie

- ▶ Informationsbegriff
- ▶ Maß für die Information?
- ▶ Entropie
- ▶ Kanalkapazität





Informationsbegriff

- ▶ n mögliche sich gegenseitig ausschließende Ereignisse A_i
- ▶ die zufällig nacheinander mit Wahrscheinlichkeiten p_i eintreten
- ▶ stochastisches Modell $W\{A_i\} = p_i$

- ▶ angewendet auf Informationsübertragung:
 das Symbol a_i wird mit Wahrscheinlichkeit p_i empfangen

- ▶ Beispiel
 - ▶ $p_i = 1$ und $p_j = 0 \quad \forall j \neq i$
 - ▶ dann wird mit Sicherheit das Symbol A_i empfangen
 - ▶ der Empfang bringt keinen Informationsgewinn

- ⇒ Informationsgewinn („Überraschung“) wird größer, je kleiner p_i



Geeignetes Maß für die Information?

- ▶ Wir erhalten die Nachricht A mit der Wahrscheinlichkeit p_A und anschließend die unabhängige Nachricht B mit der Wahrscheinlichkeit p_B
- ▶ Wegen der Unabhängigkeit ist die Wahrscheinlichkeit beider Ereignisse gegeben durch das Produkt $p_A \cdot p_B$.
- ▶ Informationsgewinn („Überraschung“) größer, je kleiner p_i
- ▶ Wahl von $1/p$ als Maß für den Informationsgewinn?
- ▶ möglich, aber der Gesamtinformationsgehalt zweier (mehrerer) Ereignisse wäre das Produkt der einzelnen Informationsgehalte
- ▶ additive Größe wäre besser \Rightarrow Logarithmus von $1/p$ bilden



Erinnerung: Logarithmus

- ▶ Umkehrfunktion zur Exponentialfunktion
- ▶ formal: für gegebenes a und b ist der Logarithmus die Lösung der Gleichung $a = b^x$
- ▶ falls die Lösung existiert, gilt: $x = \log_b(a)$

- ▶ Beispiel $3 = \log_2(8)$, denn $2^3 = 8$

- ▶ Rechenregeln
 - ▶ $\log(x \cdot y) = \log(x) + \log(y)$
 - ▶ $b^{\log_b(x)} = x$ und $\log_b(b^x) = x$
 - ▶ $\log_b(x) = \frac{\log_a(x)}{\log_a(b)}$
 - ▶ $\log_2(x) = \log(x) / \log(2) = \log(x) / 0,693141718$



Erinnerung: Binärer Logarithmus

▶ $\log_2(x) = 0.b_1b_2b_3\dots = \sum_{k>0} b_k 2^{-k}$ mit $b_k \in \{0, 1\}$
 $\log_2(x^2) = b_1.b_2b_3\dots$ wegen $\log(x^2) = 2 \log(x)$

▶ Berechnung

Input: $1 < x < 2$ (ggf. vorher skalieren)

Output: Nachkommastellen b_i der Binärdarstellung von $ld(x)$

```

i = 0
LOOP
  i = i+1
  x = x*x
  IF (x >= 2)
    THEN  x = x/2
          bi = 1
    ELSE  bi = 0
  END IF
END LOOP
    
```

Definition: Informationsgehalt

Informationsgehalt eines Ereignisses A_i mit Wahrscheinlichkeit p_i ?

- ▶ als messbare und daher additive Größe
- ▶ durch Logarithmierung (Basis 2) der Wahrscheinlichkeit:

$$I(A_i) = \log_2\left(\frac{1}{p_i}\right) = -\log_2(p_i)$$

- ▶ **Informationsgehalt** I (oder Information) von A_i
- ▶ auch **Entscheidungsgehalt** genannt
- ▶ Beispiel: zwei Nachrichten A und B

$$I(A) + I(B) = \log_2\left(\frac{1}{p_A \cdot p_B}\right) = \log_2\frac{1}{p_A} + \log_2\frac{1}{p_B}$$

Informationsgehalt: Einheit Bit

$$I(A_i) = \log_2\left(\frac{1}{p_i}\right) = -\log_2(p_i)$$

- ▶ Wert von I ist eine reelle Größe
- ▶ gemessen in der Einheit **1 Bit**

- ▶ Beispiel: nur zwei mögliche Symbole 0 und 1 mit gleichen Wahrscheinlichkeiten $p_0 = p_1 = \frac{1}{2}$
 Der Informationsgehalt des Empfangs einer 0 oder 1 ist dann

$$I(0) = I(1) = \log_2\left(1/\frac{1}{2}\right) = 1 \text{ Bit}$$

- ▶ Achtung: die Einheit Bit nicht verwechseln mit Binärstellen oder den Symbolen 0 und 1



Ungewissheit, Überraschung, Information

Vor dem Empfang einer Nachricht gibt es **Ungewissheit** über das Kommende

Beim Empfang gibt es die **Überraschung**

Und danach hat man den Gewinn an **Information**

- ▶ Alle drei Begriffe in der oben definierten Einheit **Bit** messen
- ▶ Diese Quantifizierung der **Information** ist zugeschnitten auf die Nachrichtentechnik
- ▶ umfasst nur einen Aspekt des umgangssprachlichen Begriffs **Information**



Informationsgehalt: Beispiele

Meteorit

- ▶ die Wahrscheinlichkeit, an einem Tag von einem Meteor getroffen zu werden, sei $p_M = 10^{-16}$
- ▶ Kein Grund zur Sorge, weil die Ungewissheit von $I = \log_2(1/(1 - p_M)) \approx 3,2 \cdot 10^{-16}$ sehr klein ist
 Ebenso klein ist die Überraschung, wenn das Unglück nicht passiert \Rightarrow Informationsgehalt der Nachricht „Ich wurde nicht vom Meteor erschlagen“ ist sehr klein
- ▶ Umgekehrt wäre die Überraschung groß: $\log_2(1/p_M) = 53,15$



Informationsgehalt: Beispiele (cont.)

Würfeln

- ▶ bei vielen Spielen hat die 6 eine besondere Bedeutung
- ▶ hier betrachten wir aber zunächst nur die Wahrscheinlichkeit von Ereignissen, nicht deren Semantik
- ▶ die Wahrscheinlichkeit, eine 6 zu würfeln, ist $1/6$
- ▶ $I(6) = \log_2\left(\frac{1}{6}\right) = 2,585$

Informationsgehalt: Beispiele (cont.)

Information eines Buchs

- ▶ Gegeben seien zwei Bücher
 1. deutscher Text
 2. mit Zufallsgenerator mit Gleichverteilung aus Alphabet mit 80-Zeichen erzeugt
 - ▶ Informationsgehalt in beiden Fällen?
 1. Im deutschen Text abhängig vom Kontext!
 Beispiel: Empfangen wir als deutschen Text „*Der Begriff*“, so ist „*f*“ als nächstes Symbol sehr wahrscheinlich
 2. beim Zufallstext liefert jedes neue Symbol die zusätzliche Information $I = \log_2(1/(1/80))$
- ⇒ der Zufallstext enthält die größtmögliche Information



Informationsgehalt: Beispiele (cont.)

Einzelner Buchstabe

- ▶ die Wahrscheinlichkeit, in einem Text an einer gegebenen Stelle das Zeichen „A“ anzutreffen sei $W\{A\} = p = 0,01$
- ▶ Informationsgehalt $I(A) = \log_2(1/0,01) = 6,6439$
- ▶ wenn der Text in ISO-8859-1 codiert vorliegt, werden 8 Binärstellen zur Repräsentation des „A“ benutzt
- ▶ der Informationsgehalt ist jedoch geringer

Bit : als Maß für den Informationsgehalt

bit : Anzahl der Binärstellen 0 und 1



Entropie

Obige Definition der Information lässt sich nur jeweils auf den Empfang eines speziellen Zeichens anwenden

- ▶ Was ist die **durchschnittliche Information** bei Empfang eines Symbols?
- ▶ diesen Erwartungswert bezeichnet man als **Entropie** des Systems
- ▶ Wahrscheinlichkeiten aller möglichen Ereignisse A_i seien $W\{A_i\} = p_i$
- ▶ da jeweils eines der möglichen Symbole eintrifft, gilt $\sum_i p_i = 1$



Entropie (cont.)

- ▶ dann berechnet sich die Entropie H als Erwartungswert

$$\begin{aligned} H &= E\{I(A_i)\} \\ &= \sum_i p_i \cdot I(A_i) \\ &= \sum_i p_i \log_2\left(\frac{1}{p_i}\right) \\ &= - \sum_i p_i \log_2(p_i) \end{aligned}$$

- ▶ als Funktion der Symbol-Wahrscheinlichkeiten nur abhängig vom stochastischen Modell



Entropie: Beispiele

1. drei mögliche Ereignisse mit Wahrscheinlichkeiten $\{\frac{1}{2}, \frac{1}{3}, \frac{1}{6}\}$

- ▶ dann berechnet sich die Entropie zu

$$H = -\left(\frac{1}{2}\log_2\frac{1}{2} + \frac{1}{3}\log_2\frac{1}{3} + \frac{1}{6}\log_2\frac{1}{6}\right) = 1,4591$$

2. Empfang einer Binärstelle mit den Wahrscheinlichkeiten


$$p_0 = q \text{ und } p_1 = (1 - q).$$

- ▶ für $q = \frac{1}{2}$ erhält man

$$H = -\left(\frac{1}{2}\log_2\frac{1}{2} + \left(1 - \frac{1}{2}\right)\log_2\left(1 - \frac{1}{2}\right)\right) = 1.0$$

- ▶ mittlerer Informationsgehalt beim Empfang einer Binärstelle mit gleicher Wahrscheinlichkeit für beide Symbole ist genau 1 Bit

Entropie: Diagramm



Entropie bei Empfang einer Binärstelle mit den Wahrscheinlichkeiten $p_0 = q$ und $p_1 = (1 - q)$



Entropie: Gleichverteilte Symbole

- ▶ mittlerer Informationsgehalt einer Binärstelle nur dann 1 Bit, wenn beide möglichen Symbole gleich wahrscheinlich
- ▶ entsprechendes gilt auch für größere Symbolmengen
- ▶ Beispiel: 256 Symbole (8-bit Bytes), gleich wahrscheinlich
$$H = \sum_i p_i \log_2(1/p_i) = 256 \cdot (1/256) \cdot \log_2(1/(1/256)) = 8 \text{ Bit}$$
- ▶ **Redundanz**: die Differenz zwischen dem aufgrund der Symbole möglichen (z.B. Wortlängen) und dem tatsächlich genutzten Informationsinhalt



Entropie: einige Eigenschaften

1. $H(p_1, p_2, \dots, p_n)$ ist maximal, falls $p_i = 1/n$ ($1 \leq i \leq n$)
2. H ist symmetrisch, für jede Permutation π von $1, 2, \dots, n$ gilt:

$$H(p_1, p_2, \dots, p_n) = H(p_{\pi(1)}, p_{\pi(2)}, \dots, p_{\pi(n)})$$
3. $H(p_1, p_2, \dots, p_n) \geq 0$ mit $H(0, \dots, 0, 1, \dots, 0) = 0$
4. $H(p_1, p_2, \dots, p_n, 0) = H(p_1, p_2, \dots, p_n)$
5. $H(1/n, 1/n, \dots, 1/n) \leq H(1/(n+1), 1/(n+1), \dots, 1/(n+1))$
6. H ist stetig in seinen Argumenten
7. Additivität: seien $n, m \in \mathbb{N}^+$

$$H\left(\frac{1}{n \cdot m}, \frac{1}{n \cdot m}, \dots, \frac{1}{n \cdot m}\right) = H\left(\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n}\right) + H\left(\frac{1}{m}, \frac{1}{m}, \dots, \frac{1}{m}\right)$$



Redundanz

- ▶ **Redundanz** (engl. *code redundancy*): die Differenz zwischen dem aufgrund der Symbole möglichen (z.B. Wortlängen) und dem tatsächlich genutzten Informationsinhalt $R = H_0 - H$
- ▶ relative Redundanz: $r = \frac{H_0 - H}{H_0}$
- ▶ binäre Blockcodes mit Wortlänge N bits: $H_0 = N$
gegebener Code mit m Wörtern a_i und $p(a_i)$:

$$\begin{aligned} R &= H_0 - H = H_0 - \left(- \sum_{i=1}^m p(a_i) \log_2 p(a_i) \right) \\ &= N + \sum_{i=1}^m p(a_i) \log_2 p(a_i) \end{aligned}$$



Kanalkapazität

Informationstheorie ursprünglich entwickelt zur:


- ▶ formalen Behandlung der Übertragung von Information
- ▶ über reale nicht fehlerfreie Kanäle
- ▶ deren Verhalten als stochastisches Modell formuliert werden kann

- ▶ zentrales Resultat ist die **Kanalkapazität C** des **binären symmetrischen Kanals**
- ▶ der maximal pro Binärstelle übertragbare Informationsgehalt

$$C = 1 - H(F)$$

mit $H(F)$ der Entropie des Fehlerverhaltens

Erinnerung: Modell der Informationsübertragung



- ▶ Informationsquelle
- ▶ Sender mit möglichst effizienter Kanalcodierung
- ▶ gestörter und verrauschter Übertragungskanal
- ▶ Empfänger mit Decodierer und Fehlererkennung/-korrektur
- ▶ Informationssenke und -verarbeitung




Binärer symmetrischer Kanal

- ▶ Wahrscheinlichkeit der beiden Symbole 0 und 1 ist gleich $\left(\frac{1}{2}\right)$
- ▶ Wahrscheinlichkeit P , dass bei Übertragungsfehlern aus einer 0 eine 1 wird = Wahrscheinlichkeit, dass aus einer 1 eine 0 wird
- ▶ Wahrscheinlichkeit eines Fehlers an Binärstelle i ist unabhängig vom Auftreten eines Fehlers an anderen Stellen
- ▶ Entropie des Fehlerverhaltens
$$H(F) = P \cdot \log_2(1/P) + (1 - P) \cdot \log_2(1/(1 - P))$$
- ▶ Kanalkapazität ist $C = 1 - H(F)$

Kanalkapazität: Diagramm

Kapazität des binären symmetrischen Kanals





Kanalkapazität: Konsequenzen

- ▶ bei $P = 0.5$ ist die Kanalkapazität $C = 0$
- ⇒ der Empfänger kann die empfangenen Daten nicht von einer zufälligen Sequenz unterscheiden
- ▶ bei $P > 0.5$ steigt die Kapazität wieder an
(rein akademischer Fall: Invertieren aller Bits)

Die Kanalkapazität ist eine obere Schranke

- ▶ wird in der Praxis nicht erreicht (Fehler)
- ▶ Theorie liefert keine Hinweise, wie die fehlerfreie Übertragung praktisch durchgeführt werden kann



Shannon-Theorem

C. E. Shannon: *Communication in the Presence of Noise*; Proc. IRE, Vol.37, No.1, 1949

Gegeben:

binärer symmetrischer Kanal mit Störwahrscheinlichkeit P
und Kapazität $C(P)$

Shannon-Theorem

Falls die Übertragungsrate R kleiner als $C(P)$ ist,
findet man zu jedem $\epsilon > 0$ einen Code \mathcal{C}
mit Übertragungsrate $R(\mathcal{C})$ und $C(P) \geq R(\mathcal{C}) \geq R$ und
Fehlerdecodierwahrscheinlichkeit $< \epsilon$



Shannon-Theorem (cont.)

C. E. Shannon: *Communication in the Presence of Noise*; Proc. IRE, Vol.37, No.1, 1949

- ▶ leider liefert die Theorie keine Ideen zur Realisierung
- ▶ die Nachrichten müssen sehr lang sein
- ▶ der Code muss im Mittel sehr viele Fehler in jeder Nachricht korrigieren
- ▶ mittlerweile sehr nah am Limit: Turbo-Codes, LDPC Codes, usw.



Fehlererkennende / -korrigierende Codes

Motivation

- ▶ Informationstheorie
 - ▶ Kanalkapazität
 - ▶ Shannon-Theorem

 - ▶ zuverlässige Datenübertragung ist möglich
 - ▶ aber (bisher) keine Ideen für die Realisierung
- ⇒ fehlererkennende Codes
- ⇒ fehlerkorrigierende Codes



Fehlertypen

diverse mögliche Fehler bei der Datenübertragung

- ▶ Verwechslung eines Zeichens
- ▶ Vertauschen benachbarter Zeichen
- ▶ Vertauschen entfernter Zeichen
- ▶ Zwillings-/Bündelfehler
- ▶ usw.

 $a \rightarrow b$
 $ab \rightarrow ba$
 $abc \rightarrow cba$
 $aa \rightarrow bb$

- ▶ abhängig von der Technologie / der Art der Übertragung
 - ▶ Bündelfehler durch Kratzer auf einer CD
 - ▶ Bündelfehler bei Funk durch längere Störimpulse
 - ▶ Buchstabendreher beim „Eintippen“ eines Textes



Begriffe zur Fehlerbehandlung

- ▶ **Block-Code:** k -Informationsbits werden in n -Bits codiert
- ▶ **Faltungscodes:** ein Bitstrom wird in einen Codebitstrom höherer Bitrate codiert
- ▶ **linearer (n, k) -Code:** ein k -dimensionaler Unterraum des $GF(2)^n$
- ▶ **modifizierter Code:** eine oder mehrere Stellen eines linearen Codes werden systematisch verändert (d.h. im $GF(2)$ invertiert)
Null- und Einsvektor gehören nicht mehr zum Code
- ▶ **nichtlinearer Code:** weder linear noch modifiziert

Einschub: $GF(2)$, $GF(2)^n$

Boole'sche Algebra:

- ▶ basiert auf: UND, ODER, Negation
- ▶ UND \approx Multiplikation
 ODER \approx Addition
- ▶ aber: kein inverses Element für die ODER-Operation
 \Rightarrow kein Körper

Galois-Field mit zwei Elementen: $GF(2)$

- ▶ Körper, zwei Verknüpfungen: UND und XOR
- ▶ UND als Multiplikation
 XOR als Addition *mod* 2
- ▶ additives Inverses existiert: $x \oplus x = 0$



Begriffe zur Fehlerbehandlung (cont.)

- ▶ **systematischer Code**: wenn die zu codierende Information direkt (als Substring) im Codewort enthalten ist
- ▶ **zyklischer Code**
 - ▶ ein Block-Code (identische Wortlänge aller Codewörter)
 - ▶ zu jedem Codewort gehören auch sämtliche zyklischen Verschiebungen (Rotationen, z.B. rotate-left) des Wortes auch zum Code
 - ▶ bei serieller Übertragung erlaubt dies die Erkennung/Korrektur von Bündelfehlern



ARQ und FEC

- ▶ **Automatic Repeat Request (ARQ)**: der Empfänger erkennt ein fehlerhaftes Symbol und fordert dies vom Sender erneut an
 - ▶ bidirektionale Kommunikation erforderlich
 - ▶ unpraktisch bei großer Entfernung / Echtzeitanforderungen

- ▶ **Vorwärtsfehlerkorrektur (Forward Error Correction, FEC)**: die übertragene Information wird durch zusätzliche Redundanz (z.B. Prüfziffern) gesichert
 - ▶ der Empfänger erkennt fehlerhafte Codewörter und kann diese selbständig korrigieren

- ▶ je nach Einsatzzweck sind beide Verfahren üblich
- ▶ auch kombiniert



Hamming-Abstand

- ▶ **Hamming-Abstand:** die Anzahl der Stellen, an denen sich zwei Binärcodewörter der Länge w unterscheiden
- ▶ **Hamming-Gewicht:** Hamming-Abstand eines Codewortes vom Null-Wort

- ▶ Beispiel $a = 0110\ 0011$
 $b = 1010\ 0111$
- ⇒ Hamming-Abstand von a und b ist 3
Hamming-Gewicht von b ist 5

- ▶ Java: `Integer.bitcount(a ^ b)`



Fehlererkennende und -korrigierende Codes

- ▶ Zur *Fehlererkennung* und *Fehlerkorrektur* ist eine Codierung mit Redundanz erforderlich
- ▶ Repräsentation enthält mehr Bits, als zur reinen Speicherung nötig wären
- ▶ Codewörter so wählen, dass sie paarweise mindestens den Hamming-Abstand d haben
- ▶ dieser Abstand heißt dann **Minimalabstand** d
- ▶ Fehlererkennung bis zu $(d - 1)$ fehlerhaften Stellen
- ▶ Fehlerkorrektur bis zu $((d - 1)/2)$ fehlerhaften Stellen



Prüfinformation

Man fügt den Daten **Prüfinformation** hinzu, oft **Prüfsumme** genannt

- ▶ zur Fehlerkennung
- ▶ zur Fehlerkorrektur
- ▶ zur Korrektur einfacher Fehler, Entdeckung schwerer Fehler

verschiedene Verfahren

- ▶ Prüfziffer, Parität
- ▶ Summenbildung
- ▶ CRC-Verfahren (*cyclic-redundancy check*)
- ▶ BCH-Codes (Bose, Ray-Chauduri, Hocquengham)
- ▶ RS-Codes (Reed-Solomon)



Paritätscode

- ▶ das Anfügen eines **Paritätsbits** an ein Binärcodewort $z = (z_1, \dots, z_n)$ ist die einfachste Methode zur Erkennung von Einbitfehlern
- ▶ die Parität wird berechnet als

$$p = \left(\sum_{i=1}^n z_i \right) \bmod 2$$

- ▶ **gerade Parität** (*even parity*): $y_{\text{even}} = (z_1, \dots, z_n, p)$
 $p(y_{\text{even}}) = (\sum_i y_i) \bmod 2 = 0$
- ▶ **ungerade Parität** (*odd parity*): $y_{\text{odd}} = (z_1, \dots, z_n, \bar{p})$
 $p(y_{\text{odd}}) = (\sum_i y_i) \bmod 2 = 1$



Paritätscode: Eigenschaften

- ▶ in der Praxis meistens Einsatz der ungeraden Parität:
pro Codewort y_{odd} mindestens je eine Null und Eins
- ▶ Hamming-Abstand zweier Codewörter im Paritätscode ist mindestens 2, weil sich bei Ändern eines Nutzbits jeweils auch die Parität ändert: $d = 2$
- ▶ Erkennung von Einbitfehlern möglich:
Berechnung der Parität im Empfänger und Vergleich mit der erwarteten Parität
- ▶ Erkennung von (ungeraden) Mehrbitfehlern



Zweidimensionale Parität

- ▶ Anordnung der Daten / Informations-Bits als Matrix
- ▶ Berechnung der Parität für alle Zeilen und Spalten
- ▶ optional auch für Zeile/Spalte der Paritäten

- ▶ entdeckt 1-bit Fehler in allen Zeilen und Spalten
- ▶ erlaubt Korrektur von allen 1-bit und vielen n-bit Fehlern

- ▶ natürlich auch weitere Dimensionen möglich
n-dimensionale Anordnung und Berechnung von *n* Paritätsbits



Zweidimensionale Parität: Beispiel

H 100 1000 0	Fehlerfall 100 1000 0
A 100 0001 0	100 0101 0
M 100 1101 0	110 1101 0
M 100 1101 0	100 1101 0
I 100 1001 1	000 1001 1
N 100 1110 0	100 1110 0
G 100 0111 0	100 0111 0
I 100 1001 1	100 1000 1

- ▶ 64-Bits pro Symbol, davon 49 für Nutzdaten und 15 für Parität
- ▶ links: Beispiel für ein Codewort und Paritätsbits
- ▶ rechts: empfangenes Codewort mit vier Einzelfehlern, davon ein Fehler in den Paritätsbits



Zweidimensionale Parität: Einzelfehler

H	1001000		0
A	1000001		0
M	1001101		0
M	1001101		0
I	1001001		1
N	1001110		0
G	1000111		0
<hr/>			
I	1001001		1

Fehlerfall	1001000		0
	1000101		0 1
	1001101		0
	1001101		0
	1001001		1
	1001110		0
	1000111		0
<hr/>			
	1001001		1
			1

- ▶ Empfänger: berechnet Parität und vergleicht mit gesendeter P.
- ▶ Einzelfehler: Abweichung in je einer Zeile und Spalte
- ⇒ Fehler kann daher zugeordnet und korrigiert werden
- ▶ Mehrfachfehler: nicht alle, aber viele erkennbar (korrigierbar)



Zweidimensionale Parität: Dezimalsystem

- ▶ Parität als Zeilen/Spaltensumme mod 10 hinzufügen

▶ Daten

3	7	4
5	4	8
1	3	5

Parität

3	7	4		4
5	4	8		7
1	3	5		9
<hr/>				
9	4	7		

Fehlerfall

3	7	4		4
5	4	3		2
1	3	5		9
<hr/>				
9	4	2		



International Standard Book Number

ISBN-10 (1970), ISBN-13

- ▶ an EAN (*European Article Number*) gekoppelt
 - ▶ Codierung eines Buches als Tupel
1. Präfix (nur ISBN-13)
 2. Gruppennummer für den Sprachraum als Fano-Code:
 0 – 7, 80 – 94, 950 – 995, 9960 – 9989, 99900 – 99999
 - ▶ 0, 1: englisch – AUS, UK, USA...
 - ▶ 2: französisch – F...
 - ▶ 3: deutsch – A, DE, CH
 - ▶ ...
 3. Verlag, Nummer als Fano-Code:
 00 – 19 (1 Mio Titel), 20 – 699 (100 000 Titel) usw.
 4. verlagsinterne Nummer
 5. Prüfziffer



Prüfverfahren für ISBN-10

- ▶ ISBN-10 Zahl: z_1, z_2, \dots, z_{10}
- ▶ Prüfsumme berechnen, Symbol X steht für Ziffer 10

$$\sum_{i=1}^9 (i \cdot z_i) \pmod{11} = z_{10}$$

- ▶ ISBN-Zahl zulässig, genau dann wenn

$$\sum_{i=1}^{10} (i \cdot z_i) \pmod{11} = 0$$

- ▶ Beispiel: 0-13-713336-7

$$1 \cdot 0 + 2 \cdot 1 + 3 \cdot 3 + 4 \cdot 7 + 5 \cdot 1 + 6 \cdot 3 + 7 \cdot 3 + 8 \cdot 3 + 9 \cdot 6 = 161$$

$$161 \pmod{11} = 7$$

$$161 + 10 \cdot 7 = 231$$

$$231 \pmod{11} = 0$$



Prüfverfahren für ISBN: Fehlertypen

- ▶ Prüfziffer schützt gegen Verfälschung einer Ziffer
- ▶ –"– Vertauschung zweier Ziffern
- ▶ –"– „Falschdopplung“ einer Ziffer

- ▶ Beispiel: vertausche i -te und j -te Ziffer (mit $i \neq j$)
 Prüfsumme: $\langle \text{korrekt} \rangle - \langle \text{falsch} \rangle$
 $= i \cdot z_i + j \cdot z_j - j \cdot z_i - i \cdot z_j = (i - j) \cdot (z_i - z_k)$ mit $z_i \neq z_j$.



(3,1)-Wiederholungscode

- ▶ dreifache Wiederholung jedes Datenworts
- ▶ Generatormatrix ist

$$G = (111)$$

- ▶ Codewörter ergeben sich als Multiplikation von G mit dem Informationsvektor u (jeweils ein Bit)

$$u = 0 : x = (111) \cdot (0) = (000)$$

$$u = 1 : x = (111) \cdot (1) = (111)$$

- ▶ Verallgemeinerung als (n, k) -Wiederholungscode
- ▶ systematischer Code mit Minimalabstand $D = n$
- ▶ Decodierung durch Mehrheitsentscheid: 1-bit Fehlerkorrektur
- Nachteil: geringe Datenrate



Hamming-Code

- ▶ Hamming-Abstand 3
- ▶ korrigiert 1-bit Fehler, erkennt (viele) 2-bit und 3-bit Fehler


Verfahren: Datenwort n -bit (d_1, d_2, \dots, d_n)

1. bestimme kleinstes k mit $n \leq 2^k - k - 1$
2. Prüfbits an Bitpositionen: $2^0, 2^1, \dots, 2^{k-1}$
3. Originalbits an den übrigen Positionen
4. berechne Prüfbit i als mod 2-Summe der Bits deren Positionsnummer ein gesetztes i -bit enthält
5. dabei werden auch die Prüfbits berücksichtigt



Hamming-Code (cont.)

Schema: 2...5 Prüfbits



(7,4)-Hamming-Code

- ▶ $p_1 = d_1 \oplus d_2 \oplus d_4$
- $p_2 = d_1 \oplus d_3 \oplus d_4$
- $p_3 = d_2 \oplus d_3 \oplus d_4$

(7,4)-Hamming-Code

- ▶ sieben Codebits für je vier Datenbits
- ▶ linearer (7,4)-Block-Code
- ▶ Generatormatrix ist

$$G = \begin{pmatrix} 1 & 1 & 0 & 1 \\ 1 & 0 & 1 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

- ▶ Codewort $c = G \cdot d$



(7,4)-Hamming-Code (cont.)

- ▶ Prüfmatrix H orthogonal zu gültigen Codewörtern: $H \cdot c = 0$

$$H = \begin{pmatrix} 1 & 0 & 1 & 0 & 1 & 0 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 \end{pmatrix}$$


für ungültige Codewörter $H \cdot c \neq 0$

⇒ „Fehlersyndrom“ liefert Information über Fehlerposition / -art


Fazit

- ▶ Hamming-Codes für diverse Wortlängen konstruierbar
- + einfaches Prinzip, einfach decodierbar
- es existieren weit bessere Codes


(7,4)-Hamming-Code: Fehlerrate



(23,7)-Hamming-Code: Fehlerrate



(2048,1005)-Zufalls-Code: Fehlerrate





Binärpolynome

- ▶ jedem n -bit Wort (d_1, d_2, \dots, d_n) lässt sich ein Polynom über dem Körper $\{0, 1\}$ zuordnen
- ▶ Beispiel, mehrere mögliche Zuordnungen

$$\begin{aligned}
 100\ 1101 &= 1 \cdot x^6 + 0 \cdot x^5 + 0 \cdot x^4 + 1 \cdot x^3 + 1 \cdot x^2 + 1 \cdot x^1 + 1 \cdot x^0 \\
 &= x^6 + x^3 + x^2 + x^0 \\
 &= x^0 + x^3 + x^4 + x^6 \\
 &= x^0 + x^{-3} + x^{-4} + x^{-6} \\
 &\dots
 \end{aligned}$$

- ▶ mit diesen Polynomen kann „gerechnet“ werden: Addition, Subtraktion, Multiplikation, Division
- ▶ Theorie: Galois-Felder



Zyklische Codes (CRC)


CRC (*Cyclic Redundancy Check*)

- ▶ Polynomdivision als Basis für CRC-Codes erzeugt Prüfbits
- ▶ zyklisch: Codewörter werden durch Schieben und Modifikation (mod 2 Summe) ineinander überführt
- ▶ Familie von Codes zur Fehlererkennung insbesondere auch zur Erkennung von Bündelfehlern
- ▶ in sehr vielen Codes benutzt
 - ▶ Polynom $0x04C11DB7$ (CRC-32) in Ethernet, ZIP, PNG ...
 - ▶ weitere CRC-Codes in USB, ISDN, GSM, openPGP ...

Zyklische Codes (CRC) (cont.)

Sehr effiziente Software- oder Hardwarerealisierung

- ▶ rückgekoppelte Schieberegister und XOR
- LFSR (*Linear Feedback Shift Register*)
- ▶ Beispiel $x^5 + x^4 + x^2 + 1$



- ▶ Datenwort d_i wird bitweise in CRC-Check geschoben, Divisionsrest bildet Registerinhalt p_i
- ▶ Prüfbits p_i an Datenwort anhängen
 Test bei Empfänger: fehlerfrei, wenn $= 0$



Zyklische Codes (CRC) (cont.)


Je nach Polynom (# Prüfbits) unterschiedliche Güte

- ▶ Galois-Felder als mathematische Grundlage
- ▶ en.wikipedia.org/wiki/Cyclic_redundancy_check
en.wikipedia.org/wiki/Computation_of_CRC
de.wikipedia.org/wiki/Zyklische_Redundanzprüfung
de.wikipedia.org/wiki/LFSR

Compact Disc

Audio-CD und CD-ROM

- ▶ Polycarbonatscheibe, spiralförmige geprägte Datenspur



- ▶ spiralförmige Spur, ca. 16000 Windungen, Start innen
- ▶ geprägte Vertiefungen *pits*, dazwischen *lands*
- ▶ Wechsel pit/land oder land/pit codiert 1, dazwischen 0



Compact Disc (cont.)

Audio-CD und CD-ROM

- ▶ Auslesen durch Intensität von reflektiertem Laserstrahl
- ▶ 650 MiB Kapazität, Datenrate ≈ 150 KiB/sec (1x speed)
- ▶ von Anfang an auf billigste Fertigung ausgelegt
- ▶ mehrstufige Fehlerkorrekturcodierung fest vorgesehen
- ▶ Kompensation von Fertigungsmängeln und -toleranzen
- ▶ Korrektur von Staub und Kratzern, etc.
- ▶ Audio-CD: Interpolation nicht korrigierbarer Fehler
- ▶ Daten-CD: geschachtelte weitere Codierung
- ▶ Bitfehlerrate $\leq 10^{11}$



Compact Disc: Mehrstufige Codierung

- ▶ Daten in *Frames* à 24 Bytes aufteilen
- ▶ 75 *Sektoren* mit je 98 Frames pro Sekunde
- ▶ Sektor enthält 2352 Bytes Nutzdaten (und 98 Bytes *Subcode*)

- ▶ pro Sektor 784 Byte Fehlerkorrektur hinzufügen
- ▶ Interleaving gegen Burst-Fehler (z.B. Kratzer)
- ▶ Code kann bis 7000 fehlende Bits korrigieren

- ▶ *eight-to-fourteen* Modulation: 8-Datenbits in 14 Codebits
 2..10 Nullen zwischen zwei Einsen (pit/land Übergang)

- ▶ Daten-CD zusätzlich mit äußerem 2D *Reed-Solomon Code*
- ▶ pro Sektor 2048 Bytes Nutzdaten, 276 Bytes RS-Fehlerschutz



Farbbilder: JPEG

Joint Picture Experts Group Bildformat (1992)

- ▶ für die Speicherung von Fotos / Bildern
- ▶ verlustbehaftet

mehrere Codierungsschritte

- | | |
|---|-----------------|
| 1. Farbraumkonvertierung: RGB nach YUV | verlustbehaftet |
| 2. Aufteilung in Blöcke zu je 8x8 Pixeln | verlustfrei |
| 3. DCT (<i>discrete cosinus transformation</i>) | verlustfrei |
| 4. Quantisierung (einstellbar) | verlustbehaftet |
| 5. Huffman-Codierung | verlustfrei |



Video: MPEG

Motion Picture Experts Group: Sammelname der Organisation und diverser aufeinander aufbauender Standards

Codierungsschritte für Video

1. Einzelbilder wie JPEG (YUV, DCT, Huffman)
2. Differenzbildung mehrerer Bilder (Bewegungskompensation)
3. *Group of Pictures* (*I*-Frames, *P*-Frames, *B*-Frames)
4. Zusammenfassung von Audio, Video, Metadaten im sogenannten PES (*Packetized Elementary Stream*)
5. *Transport-Stream* Format für robuste Datenübertragung



Digitales Fernsehen: DVB

Digital Video Broadcast: Sammelname für die europäischen Standards für digitales Fernsehen

Codierungsschritte

1. Videocodierung nach MPEG-2 (geplant: MPEG-4)
2. Multiplexing mehrerer Programme nach MPEG-TS
3. optional: Metadaten (Electronic Program Guide)
4. vier Varianten für die eigentliche Kanalcodierung
 - ▶ DVB-S: Satellite
 - ▶ DVB-C: Cable
 - ▶ DVB-T: Terrestrial
 - ▶ DVB-H: Handheld/Mobile



Literatur: Vertiefung

- ▶ Richard W. Hamming, *Information und Codierung*, VCH, 1987
- ▶ Klaus von der Heide, *Vorlesung: Technische Informatik 1 — interaktives Skript*, Universität Hamburg, FB Informatik, 2005
tams.informatik.uni-hamburg.de/lectures/2004ws/vorlesung/t1
- ▶ Klaus von der Heide, *Vorlesung: Digitale Datenübertragung*, Universität Hamburg, FB Informatik, 2005
tams.informatik.uni-hamburg.de/lectures/2005ss/vorlesung/Digit
- ▶ William E. Ryan, Shu Lin, *Channel codes: classical and modern*, Cambridge University Press, 2009



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
- 11. Schaltfunktionen**
 - Definition
 - Darstellung





Gliederung (cont.)

Normalformen

Entscheidungsbäume und OBDDs

Realisierungsaufwand und Minimierung

Minimierung mit KV-Diagrammen

12. Schaltnetze

13. Zeitverhalten

14. Schaltwerke

15. Grundkomponenten für Rechensysteme

16. VLSI-Entwurf und -Technologie

17. Rechnerarchitektur

18. Instruction Set Architecture

19. Assembler-Programmierung

20. Computerarchitektur



Gliederung (cont.)

21. Speicherhierarchie





Schaltfunktionen

- ▶ **Schaltfunktion:** eine eindeutige Zuordnungsvorschrift f , die jeder Wertekombination (b_1, b_2, \dots, b_n) von Schaltvariablen einen Wert zuweist:

$$y = f(b_1, b_2, \dots, b_n) \in \{0, 1\}$$

- ▶ **Schaltvariable:** eine Variable, die nur endlich viele Werte annehmen kann. Typisch sind binäre Schaltvariablen.
- ▶ **Ausgangvariable:** die Schaltvariable am Ausgang der Funktion, die den Wert y annimmt.
- ▶ bereits bekannt: *elementare Schaltfunktionen* (AND, OR, usw.)
wir betrachten jetzt Funktionen von n Variablen

Beschreibung von Schaltfunktionen

- ▶ textuelle Beschreibungen
formale Notation, Schaltalgebra, Beschreibungssprachen
- ▶ tabellarische Beschreibungen
Funktionstabelle, KV-Diagramme, ...
- ▶ graphische Beschreibungen
Kantorovic-Baum (Datenflussgraph), Schaltbild, ...
- ▶ Verhaltensbeschreibungen \Rightarrow „was“
- ▶ Strukturbeschreibungen \Rightarrow „wie“

Funktionstabelle

- ▶ Tabelle mit Eingängen x_i und Ausgangswert $y = f(x)$
- ▶ Zeilen im Binärcode sortiert
- ▶ zugehöriger Ausgangswert eingetragen

x_3	x_2	x_1	$f(x)$
0	0	0	0
0	0	1	0
0	1	0	1
0	1	1	1
1	0	0	0
1	0	1	0
1	1	0	1
1	1	1	0

Funktionstabelle (cont.)

- ▶ Kurzschreibweise: nur die Funktionswerte notiert

$$f(x_2, x_1, x_0) = \{0, 0, 1, 1, 0, 0, 1, 0\}$$

- ▶ n Eingänge: Funktionstabelle umfasst 2^n Einträge

- ▶ Speicherbedarf wächst exponentiell mit n

z.B.: 2^{33} Bit für 16-bit Addierer (16+16+1 Eingänge)

⇒ daher nur für kleine Funktionen geeignet

- ▶ Erweiterung auf don't-care Terme, s.u.



Verhaltensbeschreibung

- ▶ Beschreibung einer Funktion als Text über ihr Verhalten
- ▶ Problem: umgangssprachliche Formulierungen oft mehrdeutig
- ▶ logische Ausdrücke in Programmiersprachen
- ▶ Einsatz spezieller (Hardware-) Beschreibungssprachen
z.B.: Verilog, VHDL, SystemC



umgangssprachlich: Mehrdeutigkeit

„Das Schiebedach ist ok (y), wenn der Öffnungskontakt (x_0) **oder** der Schließkontakt (x_1) funktionieren **oder beide nicht** aktiv sind (Mittelstellung des Daches)“

K. Henke, H.-D. Wuttke, *Schaltsysteme*

zwei mögliche Missverständnisse

- ▶ *oder*: als OR oder XOR?
- ▶ *beide nicht*: x_1 und x_0 nicht, oder x_1 nicht und x_2 nicht?

⇒ je nach Interpretation völlig unterschiedliche Schaltung



Strukturbeschreibung

- ▶ **Strukturbeschreibung:** eine Spezifikation der konkreten Realisierung einer Schaltfunktion
- ▶ vollständig geklammerte algebraische Ausdrücke
$$f = x_1 \oplus (x_2 \oplus x_3)$$
- ▶ Datenflussgraphen
- ▶ Schaltpläne mit Gattern (s.u.)
- ▶ PLA-Format für zweistufige AND-OR Schaltungen (s.u.)
- ▶ ...



Funktional vollständige Basismenge

- ▶ Menge M von Verknüpfungen über $GF(2)$ heißt **funktional vollständig**, wenn die Funktionen $f, g \in T_2$:

$$f(x_1, x_2) = x_1 \oplus x_2$$

$$g(x_1, x_2) = x_1 \wedge x_2$$

allein mit den in M enthaltenen Verknüpfungen geschrieben werden können

- ▶ Boole'sche Algebra: { AND, OR, NOT }
- ▶ Reed-Muller-Form: { AND, XOR, 1 }
- ▶ technisch relevant: { NAND }, { NOR }



Normalformen

- ▶ Jede Funktion kann auf beliebig viele Arten beschrieben werden

Suche nach Standardformen:

- ▶ in denen man alle Funktionen darstellen kann
- ▶ Darstellung mit universellen Eigenschaften
- ▶ eindeutige Repräsentation (einfache Überprüfung, ob gegebene Funktionen übereinstimmen)
- ▶ Beispiel: Darstellung von reellen Funktionen als Potenzreihe

$$f(x) = \sum_{i=0}^{\infty} a_i x^i$$



Normalformen (cont.)

- ▶ Darstellung von reellen Funktionen als Potenzreihe

$$f(x) = \sum_{i=0}^{\infty} a_i x^i$$

Normalform einer Boole'schen Funktion:

- ▶ analog zur Potenzreihe
- ▶ als Summe über Koeffizienten $\{0, 1\}$ und Basisfunktionen

$$f = \sum_{i=1}^{2^n} \hat{f}_i \hat{B}_i, \quad \hat{f}_i \in \text{GF}(2)$$

mit $\hat{B}_1, \dots, \hat{B}_{2^n}$ einer Basis des T^n

Definition: Normalform

- ▶ funktional vollständige Menge V der Verknüpfungen von $\{0, 1\}$
- ▶ Seien $\oplus, \otimes \in V$ und assoziativ
- ▶ Wenn sich alle $f \in T^n$ in der Form

$$f = (\hat{f}_1 \otimes \hat{B}_1) \oplus \cdots \oplus (\hat{f}_{2^n} \otimes \hat{B}_{2^n})$$

schreiben lassen, so wird die Form als **Normalform** und die Menge der \hat{B}_i als **Basis** bezeichnet.

- ▶ Menge von 2^n Basisfunktionen \hat{B}_i
 Menge von 2^{2^n} möglichen Funktionen f



Disjunktive Normalform (DNF)

- ▶ **Minterm:** die UND-Verknüpfung *aller* Schaltvariablen einer Schaltfunktion, die Variablen dürfen dabei negiert oder nicht negiert auftreten
- ▶ **Disjunktive Normalform:** die disjunktive Verknüpfung aller Minterme m mit dem Funktionswert 1

$$f = \bigvee_{i=1}^{2^n} \hat{f}_i \cdot m(i), \quad \text{mit } m(i) : \text{Minterm}(i)$$

auch: *kanonische disjunktive Normalform*
sum-of-products (SOP)



Disjunktive Normalform: Minterme

- ▶ Beispiel: alle 2^3 Minterme für drei Variablen
- ▶ jeder Minterm nimmt nur für eine Belegung der Eingangsvariablen den Wert 1 an

x_3	x_2	x_1	Minterme
0	0	0	$\overline{x_3} \wedge \overline{x_2} \wedge \overline{x_1}$
0	0	1	$\overline{x_3} \wedge \overline{x_2} \wedge x_1$
0	1	0	$\overline{x_3} \wedge x_2 \wedge \overline{x_1}$
0	1	1	$\overline{x_3} \wedge x_2 \wedge x_1$
1	0	0	$x_3 \wedge \overline{x_2} \wedge \overline{x_1}$
1	0	1	$x_3 \wedge \overline{x_2} \wedge x_1$
1	1	0	$x_3 \wedge x_2 \wedge \overline{x_1}$
1	1	1	$x_3 \wedge x_2 \wedge x_1$

Disjunktive Normalform: Beispiel

x_3	x_2	x_1	$f(x)$
0	0	0	0
0	0	1	0
0	1	0	1
0	1	1	1
1	0	0	0
1	0	1	0
1	1	0	1
1	1	1	0

- ▶ Zeilen der Funktionstabelle entsprechen jeweiligem Minterm
 - ▶ für f sind nur drei Koeffizienten der DNF gleich 1
- ⇒ DNF: $f(x) = (\bar{x}_3 \wedge x_2 \wedge \bar{x}_1) \vee (\bar{x}_3 \wedge x_2 \wedge x_1) \vee (x_3 \wedge x_2 \wedge \bar{x}_1)$



Allgemeine disjunktive Form

- ▶ **disjunktive Form** (sum-of-products): die disjunktive Verknüpfung (ODER) von Termen. Jeder Term besteht aus der UND-Verknüpfung von Schaltvariablen, die entweder direkt oder negiert auftreten können
- ▶ entspricht dem Zusammenfassen („Minimierung“) von Termen aus der disjunktiven Normalform
- ▶ disjunktive Form ist nicht eindeutig (keine Normalform)

▶ Beispiel

$$\text{DNF} \quad f(x) = (\overline{x_3} \wedge x_2 \wedge \overline{x_1}) \vee (\overline{x_3} \wedge x_2 \wedge x_1) \vee (x_3 \wedge x_2 \wedge \overline{x_1})$$

$$\text{minimierte disjunktive Form} \quad f(x) = (\overline{x_3} \wedge x_2) \vee (x_3 \wedge x_2 \wedge \overline{x_1})$$



Allgemeine disjunktive Form

- ▶ **disjunktive Form** (sum-of-products): die disjunktive Verknüpfung (ODER) von Termen. Jeder Term besteht aus der UND-Verknüpfung von Schaltvariablen, die entweder direkt oder negiert auftreten können
- ▶ entspricht dem Zusammenfassen („Minimierung“) von Termen aus der disjunktiven Normalform
- ▶ disjunktive Form ist nicht eindeutig (keine Normalform)

▶ Beispiel

$$\text{DNF} \quad f(x) = (\overline{x_3} \wedge x_2 \wedge \overline{x_1}) \vee (\overline{x_3} \wedge x_2 \wedge x_1) \vee (x_3 \wedge x_2 \wedge \overline{x_1})$$

$$\text{minimierte disjunktive Form} \quad f(x) = (\overline{x_3} \wedge x_2) \vee (x_3 \wedge x_2 \wedge \overline{x_1})$$

$$f(x) = (x_2 \wedge \overline{x_1}) \vee (\overline{x_3} \wedge x_2 \wedge x_1)$$



Konjunktive Normalform (KNF)

- ▶ **Maxterm:** die ODER-Verknüpfung *aller* Schaltvariablen einer Schaltfunktion, die Variablen dürfen dabei negiert oder nicht negiert auftreten
- ▶ **Konjunktive Normalform:** die konjunktive Verknüpfung aller Maxterme μ mit dem Funktionswert 0

$$f = \bigwedge_{i=1}^{2^n} \hat{f}_i \cdot \mu(i), \quad \text{mit } \mu(i) : \text{Maxterm}(i)$$

auch: *kanonische konjunktive Normalform*
product-of-sums (POS)

Konjunktive Normalform: Maxterme

- ▶ Beispiel: alle 2^3 Maxterme für drei Variablen
- ▶ jeder Maxterm nimmt nur für eine Belegung der Eingangsvariablen den Wert 0 an

x_3	x_2	x_1	Maxterme
0	0	0	$x_3 \vee x_2 \vee x_1$
0	0	1	$x_3 \vee x_2 \vee \bar{x}_1$
0	1	0	$x_3 \vee \bar{x}_2 \vee x_1$
0	1	1	$x_3 \vee \bar{x}_2 \vee \bar{x}_1$
1	0	0	$\bar{x}_3 \vee x_2 \vee x_1$
1	0	1	$\bar{x}_3 \vee x_2 \vee \bar{x}_1$
1	1	0	$\bar{x}_3 \vee \bar{x}_2 \vee x_1$
1	1	1	$\bar{x}_3 \vee \bar{x}_2 \vee \bar{x}_1$



Konjunktive Normalform: Beispiel

x_3	x_2	x_1	$f(x)$
0	0	0	0
0	0	1	0
0	1	0	1
0	1	1	1
1	0	0	0
1	0	1	0
1	1	0	1
1	1	1	0

- ▶ Zeilen der Funktionstabelle \approx „invertierter“ Maxterm
 - ▶ für f sind fünf Koeffizienten der KNF gleich 0
- \Rightarrow KNF: $f(x) = (x_3 \vee x_2 \vee x_1) \wedge (x_3 \vee x_2 \vee \bar{x}_1) \wedge (\bar{x}_3 \vee x_2 \vee x_1) \wedge (\bar{x}_3 \vee x_2 \vee \bar{x}_1) \wedge (\bar{x}_3 \vee \bar{x}_2 \vee \bar{x}_1)$



Allgemeine konjunktive Form

- ▶ **konjunktive Form** (product-of-sums): die konjunktive Verknüpfung (UND) von Termen. Jeder Term besteht aus der ODER-Verknüpfung von Schaltvariablen, die entweder direkt oder negiert auftreten können
- ▶ entspricht dem Zusammenfassen („Minimierung“) von Termen aus der konjunktiven Normalform
- ▶ konjunktive Form ist nicht eindeutig (keine Normalform)

▶ Beispiel

$$\text{KNF } f(x) = (x_3 \vee x_2 \vee x_1) \wedge (x_3 \vee x_2 \vee \bar{x}_1) \wedge (\bar{x}_3 \vee x_2 \vee x_1) \wedge (\bar{x}_3 \vee x_2 \vee \bar{x}_1) \wedge (\bar{x}_3 \vee \bar{x}_2 \vee \bar{x}_1)$$

minimierte konjunktive Form

$$f(x) = (x_3 \vee x_2) \wedge (x_2 \vee x_1) \wedge (\bar{x}_3 \vee \bar{x}_1)$$



Reed-Muller-Form

- ▶ **Reed-Muller-Form:** die additive Verknüpfung aller Reed-Muller-Terme mit dem Funktionswert 1

$$f = \bigoplus_{i=1}^{2^n} \hat{f}_i \cdot RM(i)$$

- ▶ mit den Reed-Muller Basisfunktionen $RM(i)$
- ▶ Erinnerung: Addition im $GF(2)$ ist die XOR-Operation

Reed-Muller-Form: Basisfunktionen

- ▶ Basisfunktionen sind:

$\{1\}$, (0 Variablen)

$\{1, x_1\}$, (1 Variable)

$\{1, x_1, x_2, x_2x_1\}$, (2 Variablen)

$\{1, x_1, x_2, x_2x_1, x_3, x_3x_1, x_3x_2, x_3x_2x_1\}$, (3 Variablen)

...

$\{RM(n-1), x_n \cdot RM(n-1)\}$ (n Variablen)

- ▶ rekursive Bildung: bei n bit alle Basisfunktionen von $(n-1)$ -bit und zusätzlich das Produkt von x_n mit den Basisfunktionen von $(n-1)$ -bit



Reed-Muller-Form: Umrechnung

Umrechnung von gegebenem Ausdruck in Reed-Muller Form?

- ▶ Ersetzen der Negation: $\bar{a} = a \oplus 1$
- Ersetzen der Disjunktion: $a \vee b = a \oplus b \oplus ab$
- Ausnutzen von: $a \oplus a = 0$

- ▶ Beispiel

$$\begin{aligned}
 f(x_1, x_2, x_3) &= (\bar{x}_1 \vee x_2)x_3 \\
 &= (\bar{x}_1 \oplus x_2 \oplus \bar{x}_1x_2)x_3 \\
 &= ((1 \oplus x_1) \oplus x_2 \oplus (1 \oplus x_1)x_2)x_3 \\
 &= (1 \oplus x_1 \oplus x_2 \oplus x_2 \oplus x_1x_2)x_3 \\
 &= x_3 \oplus x_1x_3 \oplus x_1x_2x_3
 \end{aligned}$$



Reed-Muller-Form: Transformationsmatrix

- ▶ lineare Umrechnung zwischen Funktion f , bzw. der Funktionstabelle (distributive Normalform), und RMF
- ▶ Transformationsmatrix A kann rekursiv definiert werden (wie die RMF-Basisfunktionen)
- ▶ Multiplikation von A mit f ergibt Koeffizientenvektor r der RMF

$$r = A \cdot f, \quad \text{und} \quad f = A \cdot r$$

- ▶ weitere Details in:
Klaus von der Heide, *Vorlesung: Technische Informatik T1*,
tams.informatik.uni-hamburg.de/lectures/2004ws/vorlesung/t1
- ▶ Hinweis: Beziehung zu Fraktalen (Sierpinski-Dreieck)



Reed-Muller-Form: Transformationsmatrix (cont.)

- $r = A \cdot f$ (und $A \cdot A = I$, also $f = A \cdot r$ (!))

$$A_0 = (1)$$

$$A_1 = \begin{pmatrix} 1 & 0 \\ 1 & 1 \end{pmatrix}$$

$$A_2 = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 1 & 1 & 1 \end{pmatrix}$$

Reed-Muller-Form: Transformationsmatrix (cont.)

$$A_3 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{pmatrix}$$

...

$$A_n = \begin{pmatrix} A_{n-1} & 0 \\ A_{n-1} & A_{n-1} \end{pmatrix}$$



Reed-Muller-Form: Beispiel

x_3	x_2	x_1	$f(x)$
0	0	0	0
0	0	1	0
0	1	0	1
0	1	1	1
1	0	0	0
1	0	1	0
1	1	0	1
1	1	1	0

- ▶ Berechnung durch Rechenregeln der Boole'schen Algebra oder Aufstellen von A_3 und Ausmultiplizieren: $f(x) = x_2 \oplus x_3x_2x_1$
- ▶ häufig kompaktere Darstellung als DNF oder KNF

Reed-Muller-Form: Beispiel (cont.)

- ▶ $f(x_3, x_2, x_1) = \{0, 0, 1, 1, 0, 0, 1, 0\}$ (Funktionstabelle)
- ▶ Aufstellen von A_3 und Ausmultiplizieren

$$r = A_3 \cdot f = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 0 & 0 & 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \end{pmatrix} \cdot \begin{pmatrix} 0 \\ 0 \\ 1 \\ 1 \\ 0 \\ 0 \\ 1 \\ 0 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{pmatrix}$$

führt zur gesuchten RMF:


$$f(x_3, x_2, x_1) = r \cdot RM(3) = x_2 \oplus x_3 x_2 x_1$$



Grafische Darstellung: Entscheidungsbäume

- ▶ Darstellung einer Schaltfunktion als Baum/Graph
- ▶ jeder Knoten ist einer Variablen zugeordnet
jede Verzweigung entspricht einer *if-then-else*-Entscheidung
- ▶ vollständige Baum realisiert Funktionstabelle
- + einfaches Entfernen/Zusammenfassen redundanter Knoten
- ▶ Beispiel: Multiplexer
 $f(a, b, c) = (a \wedge \bar{c}) \vee (b \wedge c)$

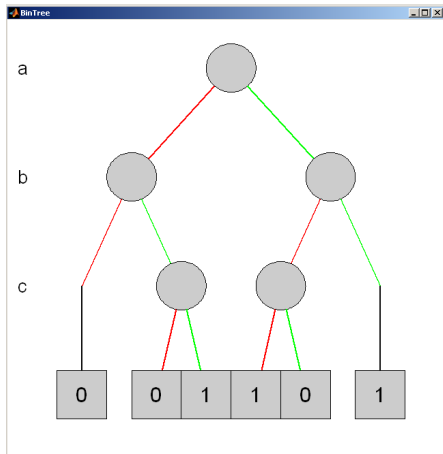
Entscheidungsbaum: Beispiel



► $f(a, b, c) = (a \wedge \bar{c}) \vee (b \wedge c)$

- rot: 0-Zweig
 grün: 1-Zweig

Entscheidungsbaum: Beispiel (cont.)



$$\blacktriangleright f(a, b, c) = (a \wedge \bar{c}) \vee (b \wedge c)$$

\Rightarrow Knoten entfernt

\blacktriangleright rot: 0-Zweig
 grün: 1-Zweig

Reduced Ordered Binary-Decision Diagrams (ROBDD)

Binäres Entscheidungsdiagramm


- ▶ Variante des Entscheidungsbaums
- ▶ vorab gewählte Variablenordnung (*ordered*)
- ▶ redundante Knoten werden entfernt (*reduced*)
- ▶ ein ROBDD ist eine Normalform für eine Funktion

- ▶ viele praxisrelevante Funktionen sehr kompakt darstellbar
 $O(n) \dots O(n^2)$ Knoten bei n Variablen
- ▶ wichtige Ausnahme: n -bit Multiplizierer ist $O(2^n)$
- ▶ derzeit das Standardverfahren zur Manipulation von
 (großen) Schaltfunktionen


ROBDD vs. Entscheidungsbaum

Entscheidungsbaum

$$f = (a b c) \vee (a \bar{b}) \vee (\bar{a} b) \vee (\bar{a} \bar{b} \bar{c})$$




ROBDD




ROBDD: Beispiele


$$f(x) = x$$



$$g = (a b) \vee c$$




$$\text{Parität } p = x_1 \oplus x_2 \oplus \dots \oplus x_n$$



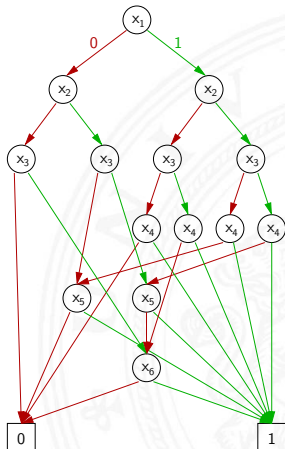
ROBDD: Problem der Variablenordnung

- Anzahl der Knoten oft stark abhängig von der Variablenordnung

$$f = x_1 x_2 \vee x_3 x_4 \vee x_5 x_6$$



$$g = x_1 x_4 \vee x_2 x_5 \vee x_3 x_6$$





Minimierung von Schaltfunktionen

- ▶ mehrere (beliebig viele) Varianten zur Realisierung einer gegebenen Schaltfunktion bzw. eines Schaltnetzes

Minimierung des Realisierungsaufwandes:

- ▶ diverse Kriterien, technologieabhängig
 - ▶ Hardwarekosten (Anzahl der Gatter)
 - ▶ Hardwareeffizienz (z.B. NAND statt XOR)
 - ▶ Geschwindigkeit (Anzahl der Stufen, Laufzeiten)
 - ▶ Testbarkeit (Erkennung von Produktionsfehlern)
 - ▶ Robustheit (z.B. ionisierende Strahlung)



Algebraische Minimierungsverfahren

- ▶ Vereinfachung der gegebenen Schaltfunktionen durch Anwendung der Gesetze der Boole'schen Algebra
- ▶ im Allgemeinen nur durch Ausprobieren
- ▶ ohne Rechner sehr mühsam
- ▶ keine allgemeingültigen Algorithmen bekannt
- ▶ Heuristische Verfahren
 - ▶ Suche nach *Primimplikanten* (= kürzeste Konjunktionsterme)
 - ▶ Quine-McCluskey-Verfahren und Erweiterungen

Algebraische Minimierung: Beispiel

- ▶ Ausgangsfunktion in DNF

$$\begin{aligned}
 y(x) = & \bar{x}_3 x_2 x_1 \bar{x}_0 \vee \bar{x}_3 x_2 x_1 x_0 \\
 & \vee x_3 \bar{x}_2 \bar{x}_1 x_0 \vee x_3 \bar{x}_2 x_1 \bar{x}_0 \\
 & \vee x_3 \bar{x}_2 x_1 x_0 \vee x_3 x_2 \bar{x}_1 x_0 \\
 & \vee x_3 x_2 x_1 \bar{x}_0 \vee x_3 x_2 x_1 x_0
 \end{aligned}$$

- ▶ Zusammenfassen benachbarter Terme liefert

$$y(x) = \bar{x}_3 x_2 x_1 \vee x_3 \bar{x}_2 x_0 \vee x_3 \bar{x}_2 x_1 \vee x_3 x_2 x_0 \vee x_3 x_2 x_1$$

- ▶ aber bessere Lösung ist möglich (weiter Umformen)

$$y(x) = x_2 x_1 \vee x_3 x_0 \vee x_3 x_1$$



Grafische Minimierungsverfahren

- ▶ Darstellung einer Schaltfunktion im KV-Diagramm
- ▶ Interpretation als disjunktive Normalform
- ▶ Zusammenfassen benachbarter Terme durch **Schleifen**
- ▶ alle 1-Terme mit möglichst wenigen Schleifen abdecken
- ▶ Ablesen der minimierten Funktion, wenn keine weiteren Schleifen gebildet werden können
- ▶ beruht auf der menschlichen Fähigkeit, benachbarte Flächen auf einen Blick zu „sehen“
- ▶ bei mehr als 6 Variablen nicht mehr praktikabel

Erinnerung: Karnaugh-Veitch-Diagramm

		x1 x0			
		00	01	11	10
x3 x2	00	0	1	3	2
	01	4	5	7	6
	11	12	13	15	14
	10	8	9	11	10

		x1 x0			
		00	01	11	10
x3 x2	00	0000	0001	0011	0010
	01	0100	0101	0111	0110
	11	1100	1101	1111	1110
	10	1000	1001	1011	1010

- ▶ 2D-Diagramm mit $2^n = 2^{n_y} \times 2^{n_x}$ Feldern
 - ▶ gängige Größen sind: 2×2 , 2×4 , 4×4
darüber hinaus: mehrere Diagramme der Größe 4×4
 - ▶ Anordnung der Indizes ist im Gray-Code (!)
- ⇒ benachbarte Felder unterscheiden sich gerade um 1 Bit

KV-Diagramme: 2...4 Variable (2×2, 2×4, 4×4)

		x0	
		0	1
x1	0	00	01
	1	10	11

		x1 x0			
		00	01	11	10
x2	0	000	001	011	010
	1	100	101	111	110



		x1 x0			
		00	01	11	10
x3 x2	00	0000	0001	0011	0010
	01	0100	0101	0111	0110
	11	1100	1101	1111	1110
	10	1000	1001	1011	1010





KV-Diagramm für Schaltfunktionen

- ▶ Funktionswerte in zugehöriges Feld im KV-Diagramm eintragen
- ▶ Werte 0 und 1
don't-care „*“ für nicht spezifizierte Werte (!)
- ▶ 2D-Äquivalent zur Funktionstabelle
- ▶ praktikabel für 3..6 Eingänge
- ▶ fünf Eingänge: zwei Diagramme a 4×4 Felder
sechs Eingänge: vier Diagramme a 4×4 Felder
- ▶ viele Strukturen „auf einen Blick“ erkennbar

KV-Diagramm: Zuordnung zur Funktionstabelle



KV-Diagramm: Eintragen aus Funktionstabelle



KV-Diagramm: Beispiel

		x1 x0			
		00	01	11	10
x3 x2	00	0	1	3	2
	01	4	5	7	6
	11	12	13	15	14
	10	8	9	11	10

		x1 x0			
		00	01	11	10
x3 x2	00	1	0	0	1
	01	0	0	0	0
	11	0	0	1	0
	10	0	0	1	0

- ▶ Beispielfunktion in DNF mit vier Termen:

$$f(x) = (\overline{x_3}x_2x_1x_0) \vee (\overline{x_3}\overline{x_2}x_1\overline{x_0}) \vee (x_3\overline{x_2}x_1x_0) \vee (x_3x_2x_1x_0)$$

- ▶ Werte aus Funktionstabelle an entsprechender Stelle ins Diagramm eintragen



Schleifen: Zusammenfassen benachbarter Terme

- ▶ benachbarte Felder unterscheiden sich um 1-Bit
- ▶ falls benachbarte Terme beide 1 sind \Rightarrow Funktion hängt an dieser Stelle nicht von der betroffenen Variable ab
- ▶ zugehörige (Min-) Terme können zusammengefasst werden


- ▶ Erweiterung auf vier benachbarte Felder (4x1 1x4 2x2)
 Erweiterung auf acht benachbarte Felder (4x2 2x4) usw.
- ▶ aber keine Dreier- Fünfergruppen, usw. (Gruppengröße 2^i)

- ▶ Nachbarschaft auch „außen herum“
- ▶ mehrere Schleifen dürfen sich überlappen

Schleifen: Ablesen der Schleifen


x1	x0	y=f(x)
0	0	0
0	1	0
1	0	1
1	1	1

$$f(x_1, x_0) = x_1$$



x2	x1	x0	y=f(x)
0	0	0	0
0	0	1	0
0	1	0	1
0	1	1	1
1	0	0	0
1	0	1	0
1	1	0	1
1	1	1	0

$$f(x_2, x_1, x_0) = \bar{x}_2 x_1 \vee x_1 \bar{x}_0$$



Schleifen: Ablesen der Schleifen (cont.)

		x1 x0			
		00	01	11	10
x3 x2	00	1	0	0	1
	01	0	0	0	0
	11	0	0	1	0
	10	0	0	1	0

		x1 x0			
		00	01	11	10
x3 x2	00	1	0	0	1
	01	0	0	0	0
	11	0	0	1	0
	10	0	0	1	0

- ▶ insgesamt zwei Schleifen möglich
- ▶ grün entspricht $(\overline{x_3 x_2 x_0}) = (\overline{x_3 x_2 x_1 x_0}) \vee (\overline{x_3 x_2 x_1 \overline{x_0}}$
 rot entspricht $(x_3 x_1 x_0) = (x_3 x_2 x_1 x_0) \vee (x_3 \overline{x_2} x_1 x_0)$
- ▶ minimierte disjunktive Form $f(x) = (\overline{x_3 x_2 x_0}) \vee (x_3 x_1 x_0)$



Schleifen: interaktive Demonstration

- ▶ Applet zur Minimierung mit KV-Diagrammen
tams.informatik.uni-hamburg.de/applets/kvd
 - 1. Auswahl oder Eingabe einer Funktion (2..6 Variablen)
 - 2. Interaktives Setzen und Erweitern von Schleifen
(click, shift+click, control+click)
 - 3. Anzeige der zugehörigen Hardwarekosten und Schaltung
-
- ▶ Achtung: andere Anordnung der Eingangsvariablen als im Skript
- ⇒ entsprechend andere Anordnung der Terme im KV-Diagramm
Prinzip bleibt aber gleich

KV-Diagramm Applet: Screenshots

KV-Diagramm-Applet

File Option Info

Java Applet Window

Edit Function
 Show Indices
 Add Loop 1 (DNF)
 Add Loop 0 (KNF)

Function y1

		i0				
i3	1	0	1	0	i1	
	1	1	1	0		
	1	1	1	0		
	1	0	0	0		
		i2				

press <CTRL> + mouseclick to DELETE this loop
 press <build Loop> to commit the Loop
 press <build Loop> to commit the Loop

KV-Diagramm-Applet

File Option Info

Java Applet Window

Edit Function
 Show Indices
 Add Loop 1 (DNF)
 Add Loop 0 (KNF)

Function y1

		i0				
i3	1	0	1	0	i1	
	1	1	1	0		
	1	1	1	0		
	1	0	0	0		
		i2				

press <CTRL> + mouseclick to DELETE this loop
 press <build Loop> to commit the Loop
 press <build Loop> to commit the Loop

KV-Diagramm-Applet

File Option Info

Java Applet Window



Edit Function
 Show Indices
 Add Loop 1 (DNF)
 Add Loop 0 (KNF)

Function y1

		i0				
i3	1	0	1	0	i1	
	1	1	1	0		
	1	1	1	0		
	1	0	0	0		
		i2				

press <CTRL> + mouseclick to DELETE this loop
 press <build Loop> to commit the Loop
 press <build Loop> to commit the Loop

KV-Diagramm Applet: zugehörige Hardwarekosten







Don't-Care Terme

- ▶ in der Praxis: viele Schaltfunktionen unvollständig definiert weil bestimmte Eingangskombinationen nicht vorkommen
- ▶ zugehörige Terme als **Don't Care** markieren
typisch: Sternchen „*“ in Funktionstabelle/KV-Diagramm
- ▶ solche Terme bei Minimierung nach Wunsch auf 0/1 setzen
- ▶ Schleifen dürfen Don't Cares enthalten
- ▶ Schleifen möglichst groß

KV-Diagramm Applet: 6 Variablen, *Don't Cares*



KV-Diagramm Applet: 6 Variablen, *Don't Cares* (cont.)



- ▶ Schaltung und Realisierungsaufwand (# Gatter, Eingänge) nach der Minimierung



Quine-McCluskey-Algorithmus

- ▶ Algorithmus zur Minimierung einer Schaltfunktion
- ▶ Notation der Terme in Tabellen, n Variablen
- ▶ Prinzip entspricht der Minimierung im KV-Diagramm aber auch geeignet für mehr als sechs Variablen
- ▶ Grundlage gängiger Minimierungsprogramme

- ▶ Sortieren der Terme nach Hamming-Distanz
- ▶ Erkennen der unverzichtbaren Terme („Primimplikanten“)
- ▶ Aufstellen von Gruppen benachbarter Terme (mit Distanz 1)
- ▶ Zusammenfassen geeigneter benachbarter Terme

Becker, Drechsler, Molitor, *Technische Informatik: Eine Einführung*

Schiffmann, Schmitz, *Technische Informatik*



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
- 12. Schaltnetze**

Definition



Gliederung (cont.)

Schaltsymbole und Schaltpläne

Hades: Editor und Simulator

Logische Gatter

Inverter, AND, OR

XOR und Parität

Multiplexer

Einfache Schaltnetze

Siebensegmentanzeige

Schaltnetze für Logische und Arithmetische Operationen

Addierer

Multiplizierer

Prioritätsencoder

Barrel-Shifter

ALU (Arithmetisch-Logische Einheit)



Gliederung (cont.)

Literatur

13. Zeitverhalten
14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Schaltnetze: Definition

- ▶ **Schaltnetz** oder auch **kombinatorische Schaltung** (*combinational logic circuit*): ein digitales System mit n -Eingängen (b_1, b_2, \dots, b_n) und m -Ausgängen (y_1, y_2, \dots, y_m) , dessen Ausgangsvariablen zu jedem Zeitpunkt nur von den aktuellen Werten der Eingangsvariablen abhängen

Beschreibung als Vektorfunktion $\vec{y} = F(\vec{b})$

- ▶ Hinweis: ein Schaltnetz darf keine Rückkopplungen enthalten
- ▶ in der Praxis können Schaltnetze nicht statisch betrachtet werden: Gatterlaufzeiten spielen eine Rolle

Elementare digitale Schaltungen

- ▶ Schaltsymbole
- ▶ Grundgatter (Inverter, AND, OR, usw.)
- ▶ Kombinationen aus mehreren Gattern

- ▶ Schaltnetze (mehrere Ausgänge)
- ▶ Beispiele

- ▶ Arithmetisch/Logische Operationen



Schaltpläne (*schematics*)

- ▶ standardisierte Methode zur Darstellung von Schaltungen
- ▶ genormte Symbole für Komponenten
 - ▶ Spannungs- und Stromquellen, Messgeräte
 - ▶ Schalter und Relais
 - ▶ Widerstände, Kondensatoren, Spulen
 - ▶ Dioden, Transistoren (bipolar, MOS)
 - ▶ **Gatter**: logische Grundoperationen (UND, ODER, usw.)
 - ▶ **Flipflops**: Speicherglieder
- ▶ Verbindungen
 - ▶ Linien für Drähte (Verbindungen)
 - ▶ Lötunkte für Drahtverbindungen
 - ▶ dicke Linien für n -bit Busse, Anzapfungen, usw.
- ▶ komplexe Bausteine ggf. hierarchisch

Schaltsymbole

DIN 40700 (ab 1976)	Schaltzeichen		Benennung
	Früher	in USA	
			UND - Glied (AND)
			ODER - Glied (OR)
			NICHT - Glied (NOT)
			Exklusiv-Oder - Glied (Exclusive-OR, XOR)
			Äquivalenz - Glied (Logic identity)
			UND - Glied mit negier- tem Ausgang (NAND)
			ODER - Glied mit negier- tem Ausgang (NOR)
			Negation eines Eingangs
			Negation eines Ausgangs

Schiffmann, Schmitz,
 Technische Informatik 1



Logische Gatter

- ▶ **Logisches Gatter** (*logic gate*): die Bezeichnung für die Realisierung einer logischen Grundfunktion als gekapselte Komponente (in einer gegebenen Technologie)
- ▶ 1 Eingang: Treiberstufe/Verstärker und Inverter (Negation)
- ▶ 2 Eingänge: AND/OR, NAND/NOR, XOR, XNOR
- ▶ 3- und mehr Eingänge: AND/OR, NAND/NOR, Parität
- ▶ Multiplexer
- ▶ mindestens Gatter für eine vollständige Basismenge erforderlich
- ▶ in Halbleitertechnologie sind NAND/NOR besonders effizient



Schaltplan-Editor und -Simulator

Spielerischer Zugang zu digitalen Schaltungen:

- ▶ mit Experimentierkasten oder im Logiksimulator
- ▶ interaktive Simulation erlaubt direktes Ausprobieren
- ▶ Animation und Visualisierung der logischen Werte
- ▶ „entdeckendes Lernen“

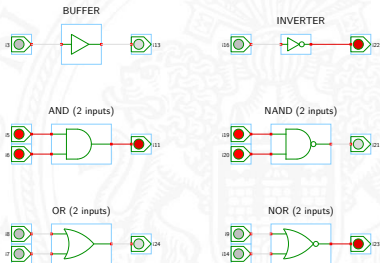
- ▶ Diglog: www.cs.berkeley.edu/~lazzaro/chipmunk
- ▶ Hades: tams.informatik.uni-hamburg.de/applets/hades/webdemos
 - ▶ Demos laufen im Browser (Java erforderlich)
 - ▶ Grundsaltungen, Gate-Level Circuits...

tams.informatik.uni-hamburg.de/applets/hades/webdemos/toc.html

Hades: Grundkomponenten

- ▶ Vorführung des Simulators
- ▶ Eingang: Schalter + Anzeige („Ipin“)
- ▶ Ausgang: Anzeige („Opin“)
- ▶ Taktgenerator
- ▶ PowerOnReset
- ▶ Anzeige / Leuchtdiode
- ▶ Siebensegmentanzeige

...



Hades: *glow-mode* Visualisierung

- ▶ Farbe einer Leitung codiert den logischen Wert
- ▶ Einstellungen sind vom Benutzer konfigurierbar
- ▶ Defaultwerte

blau	glow-mode ausgeschaltet
hellgrau	logisch-0
rot	logisch-1
orange	tri-state-Z ⇒ keine Treiber
magenta	undefined-X ⇒ Kurzschluss, ungültiger Wert
cyan	unknown-U ⇒ nicht initialisiert



Hades: Bedienung

- ▶ Menü: Anzeigeeoptionen, Edit-Befehle, usw.
- ▶ Editorfenster mit Popup-Menü für häufige Aktionen
- ▶ Rechtsklick auf Komponenten öffnet Eigenschaften/Parameter (*property-sheets*)
- ▶ optional „tooltips“ (enable im Layer-Menü)
- ▶ Simulationssteuerung: *run*, *pause*, *rewind*
- ▶ Anzeige der aktuellen Simulationszeit
- ▶ Details siehe Hades-Webseite: Kurzreferenz, Tutorial
tams.informatik.uni-hamburg.de/applets/hades/webdemos/docs.html

Gatter: Verstärker, Inverter, AND, OR

BUFFER



INVERTER



AND (2 inputs)



NAND (2 inputs)



OR (2 inputs)




NOR (2 inputs)




Grundsaltungen: De'Morgan Regel

AND (2 inputs)




OR (2 inputs)







Gatter: AND/NAND mit zwei, drei, vier Eingängen


BUFFER

INVERTER

AND (2 inputs)


NAND (2 inputs)

AND (3 inputs)

NAND (3 inputs)

AND (4 inputs)

NAND (4 inputs)


Gatter: AND mit zwölf Eingängen



AND3-AND4




NAND3-NOR4 (de-Morgan)


- ▶ in der Regel max. 4-Eingänge pro Gatter
 Grund: elektrotechnische Nachteile



Gatter: OR/NOR mit zwei, drei, vier Eingängen

BUFFER

INVERTER

OR (2 inputs)


NOR (2 inputs)

OR (3 inputs)

NOR (3 inputs)


OR (4 inputs)

NOR (4 inputs)


Komplexgatter


AOI21 (And-Or-Invert)




OAI21 (Or-And-Invert)



AOI33 (And-Or-Invert)




OAI32 (Or-And-Invert)



- ▶ in CMOS-Technologie besonders günstig realisierbar
entsprechen vom Aufwand *einem* Gatter

Gatter: XOR und XNOR

BUFFER

INVERTER

AND (2 inputs)

XOR (2 inputs)

OR (2 inputs)


XNOR (2 inputs)


XOR und drei Varianten der Realisierung


- ▶ Symbol




- ▶ AND-OR



- ▶ NAND-NAND




- ▶ mit Multiplexer




XOR zur Berechnung der Parität

- ▶ Parität, siehe „Codierung – Fehlererkennende Codes“
- ▶ 4-bit Parität



XOR zur Berechnung der Parität (cont.)

- ▶ 8-bit, bzw. 10-bit: Umschaltung odd/even
Kaskadierung über c-Eingang





2:1-Multiplexer

Umschalter zwischen zwei Dateneingängen („Wechselschalter“)

- ▶ ein Steuereingang: s
- zwei Dateneingänge: a_1 und a_0
- ein Datenausgang: y
- ▶ wenn $s = 1$ wird a_1 zum Ausgang y durchgeschaltet
- wenn $s = 0$ wird a_0 —"

s	a_1	a_0	y
0	0	0	0
0	0	1	1
0	1	0	0
0	1	1	1
1	0	0	0
1	0	1	0
1	1	0	1
1	1	1	1



2:1-Multiplexer (cont.)

- ▶ kompaktere Darstellung der Funktionstabelle durch Verwendung von * (don't care) Termen

s	a ₁	a ₀	y
0	*	0	0
0	*	1	1
1	0	*	0
1	1	*	1

s	a ₁	a ₀	y
0	*	a ₀	a ₀
1	a ₁	*	a ₁




n:1-Multiplexer

Umschalten zwischen mehreren Dateneingängen

- ▶ $\lceil \log_2(n) \rceil$ Steuereingänge: s_m, \dots, s_0
 n Dateneingänge: a_{n-1}, \dots, a_0
 ein Datenausgang: y




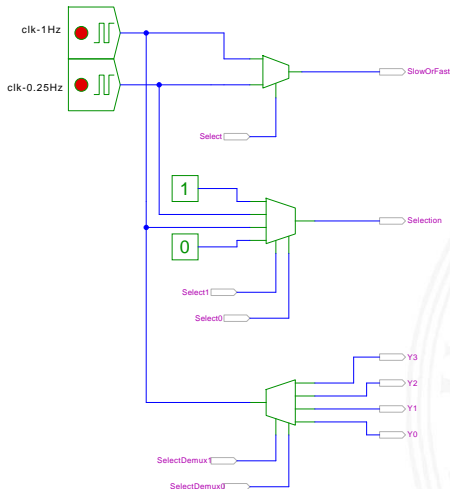
s_1	s_0	a_3	a_2	a_1	a_0	y
0	0	*	*	*	0	0
0	0	*	*	*	1	1
0	1	*	*	0	*	0
0	1	*	*	1	*	1
1	0	*	0	*	*	0
1	0	*	1	*	*	1
1	1	0	*	*	*	0
1	1	1	*	*	*	1

2:1 und 4:1 Multiplexer

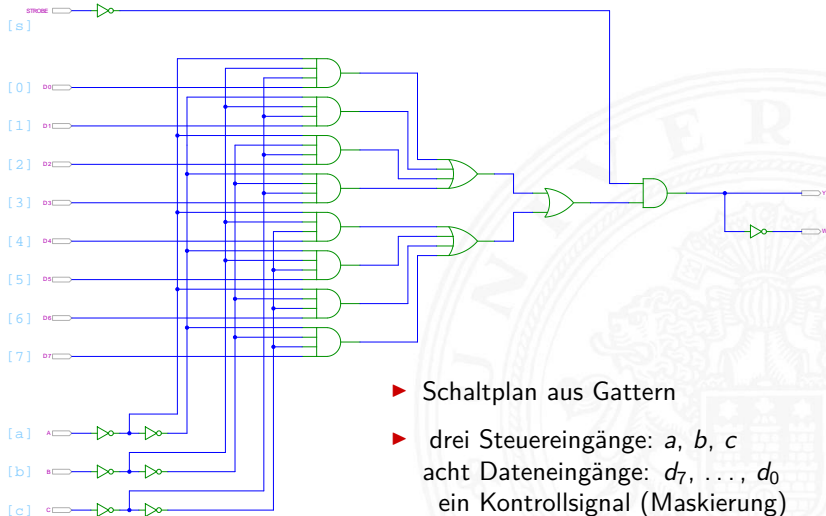


- ▶ keine einheitliche Anordnung der Dateneingänge in Schaltplänen:
höchstwertiger Eingang manchmal oben, manchmal unten

Multiplexer und Demultiplexer

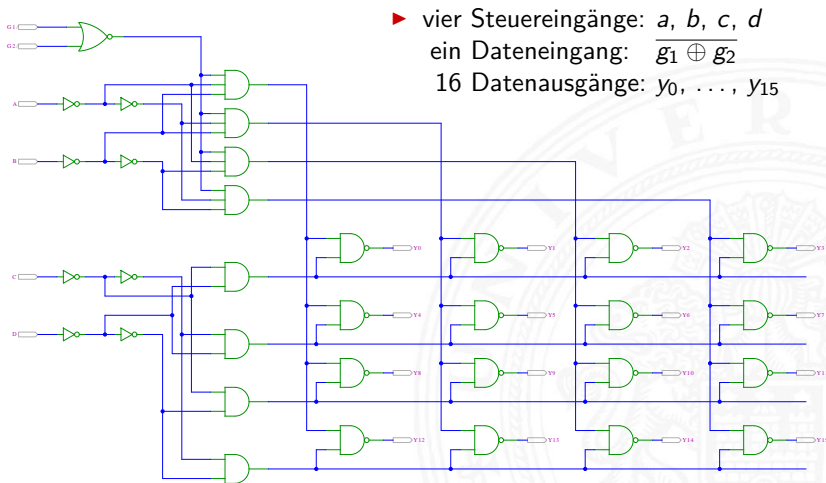


8-bit Multiplexer: Integrierte Schaltung 74151




- ▶ Schaltplan aus Gattern
- ▶ drei Steuereingänge: a , b , c
 acht Dateneingänge: d_7, \dots, d_0
 ein Kontrollsignal (Maskierung)

16-bit Demultiplexer: Integrierte Schaltung 74154



16-bit Demultiplexer: 74154 als Adressdecoder



Beispiele für Schaltnetze


- ▶ Schaltungen mit mehreren Ausgängen
- ▶ Bündelminimierung der einzelnen Funktionen

ausgewählte typische Beispiele

- ▶ „Würfel“-Decoder
- ▶ Umwandlung vom Dual-Code in den Gray-Code
- ▶ (7,4)-Hamming-Code: Encoder und Decoder
- ▶ Siebensegmentanzeige

Beispiel: „Würfel“-Decoder


Visualisierung eines Würfels mit sieben LEDs



- ▶ Eingabewert von 0...6
- ▶ Anzeige als ein bis sechs Augen, bzw. ausgeschaltet

Wert	b_2	b_1	b_0	x_1	x_2	x_3	x_4	x_5	x_6	x_7
0	0	0	0	0	0	0	0	0	0	0
1	0	0	1	0	0	0	1	0	0	0
2	0	1	0	1	0	0	0	0	0	1
3	0	1	1	1	0	0	1	0	0	1
4	1	0	0	1	0	1	0	1	0	1
5	1	0	1	1	0	1	1	1	0	1
6	1	1	0	1	1	1	0	1	1	1

Beispiel: „Würfel“-Decoder (cont.)



- ▶ Anzeige wie beim Würfel: ein bis sechs Augen
- ▶ Minimierung ergibt:

$$x_1 = x_7 = b_2 \vee b_1$$

$$x_2 = x_6 = b_0 \wedge b_1$$

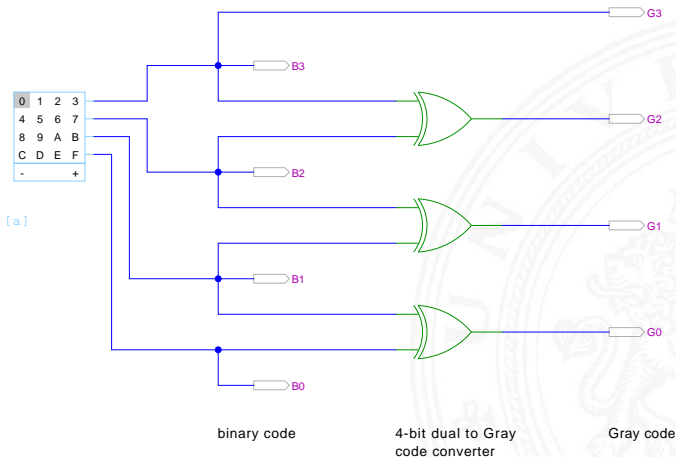
$$x_3 = x_5 = b_2$$

$$x_4 = b_0$$

links oben, rechts unten
 mitte oben, mitte unten
 rechts oben, links unten
 Zentrum

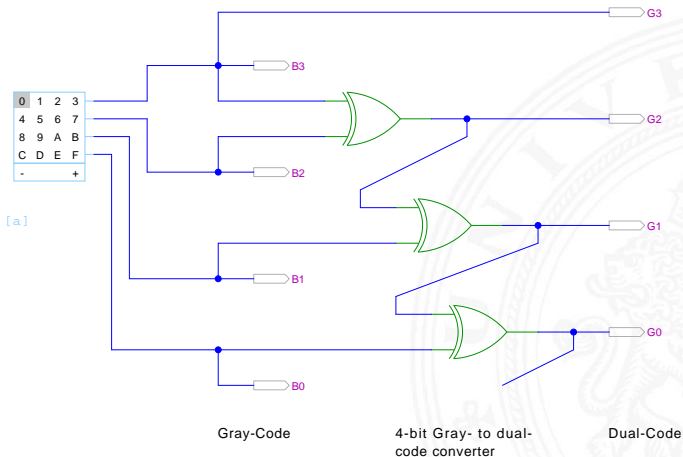
Beispiel: Umwandlung vom Dualcode in den Graycode

XOR benachbarter Bits



Beispiel: Umwandlung vom Graycode in den Dualcode

XOR-Kette



(7,4)-Hamming-Code: Encoder und Decoder

▶ Encoder

- ▶ vier Eingabebits
- ▶ Hamming-Encoder erzeugt drei Paritätsbits

▶ Übertragungskanal

- ▶ Übertragung von sieben Codebits
- ▶ Einfügen von Übertragungsfehlern durch Invertieren von Codebits mit XOR-Gattern

▶ Decoder und Fehlerkorrektur

- ▶ Decoder liest die empfangenen sieben Bits
- ▶ Syndrom-Berechnung mit XOR-Gattern und Anzeige erkannter Fehler
- ▶ Korrektur gekippter Bits

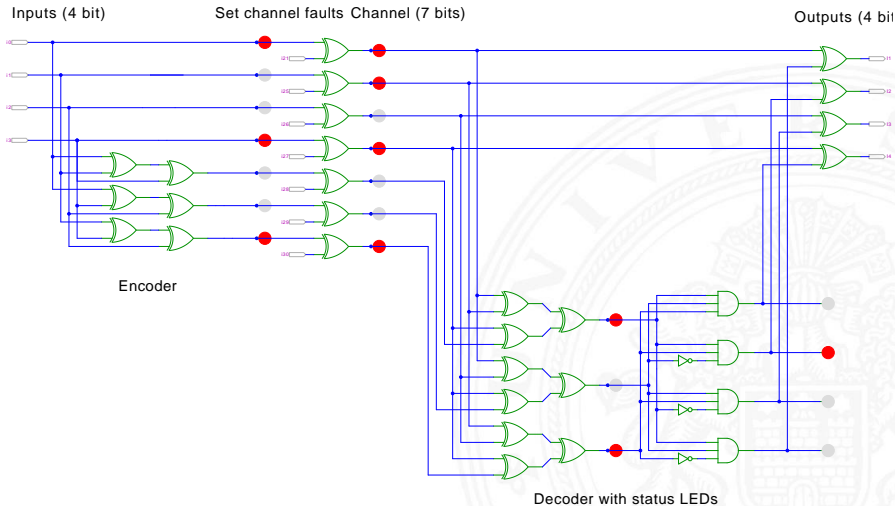
linke Seite

Mitte

rechte Seite

rechts oben

(7,4)-Hamming-Code: Encoder und Decoder (cont.)






Siebensegmentanzeige

- ▶ sieben einzelne Leuchtsegmente (z.B. Leuchtdioden)
- ▶ Anzeige stilisierter Ziffern von 0 bis 9
- ▶ auch für Hex-Ziffern: A, b, C, d E, F

- ▶ sieben Schaltfunktionen, je eine pro Ausgang
- ▶ Umcodierung von 4-bit Dualwerten in geeignete Ausgangswerte
- ▶ Segmente im Uhrzeigersinn: A (oben) bis F, G innen


- ▶ eingeschränkt auch als alphanumerische Anzeige für Ziffern und (einige) Buchstaben
 - gemischt Groß- und Kleinbuchstaben
 - Probleme mit M, N, usw.



Siebensegmentanzeige: Funktionen

- ▶ Funktionen für Hex-Anzeige, 0...F

	0	1	2	3	4	5	6	8	9	A	b	C	d	E	F
A =	1	0	1	1	0	1	1	1	1	1	0	0	0	1	1
B =	1	1	1	1	0	0	1	1	1	1	0	0	1	0	0
C =	1	1	0	1	1	1	1	1	1	1	1	0	1	0	0
D =	1	0	1	1	0	1	1	0	1	1	1	1	1	1	0
E =	1	0	1	0	0	0	1	0	1	0	1	1	1	1	1
F =	1	0	0	0	1	1	1	1	1	1	1	1	0	0	1
G =	0	0	1	1	1	1	1	0	1	1	1	1	1	1	1



- ▶ für Ziffernanzeige mit *Don't Care*-Termen

A = 1011011111*****
 B = usw.



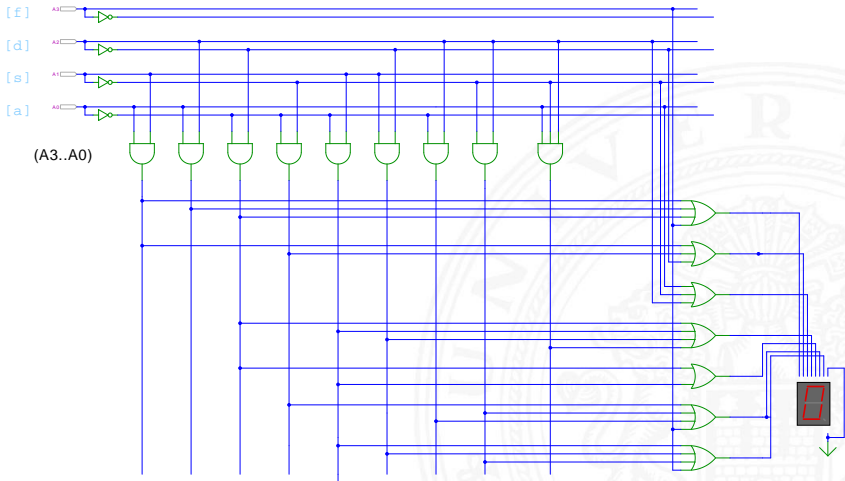
Siebensegmentanzeige: Bündelminimierung

- ▶ zum Beispiel mit sieben KV-Diagrammen. . .
- ▶ dabei versuchen, gemeinsame Terme zu finden und zu nutzen


Minimierung als Übungsaufgabe?

- ▶ nächste Folie zeigt Lösung aus Schiffmann, Schmitz
- ▶ als mehrstufige Schaltung ist günstigere Lösung möglich
siehe Knuth: *AoCP, Volume 4, Fascicle 0*, 7.1.2 (Seite 112ff)

Siebensegmentdecoder: Ziffern 0..9

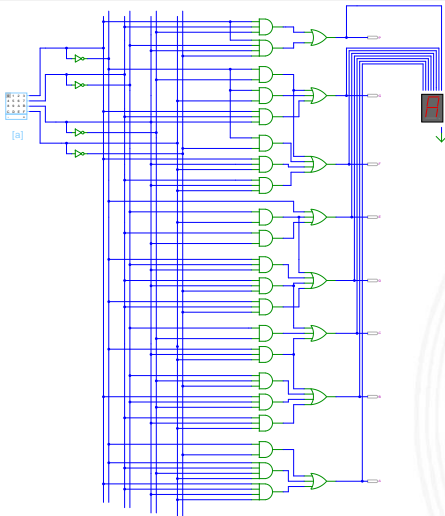


Siebensegmentdecoder: Integrierte Schaltung 7449



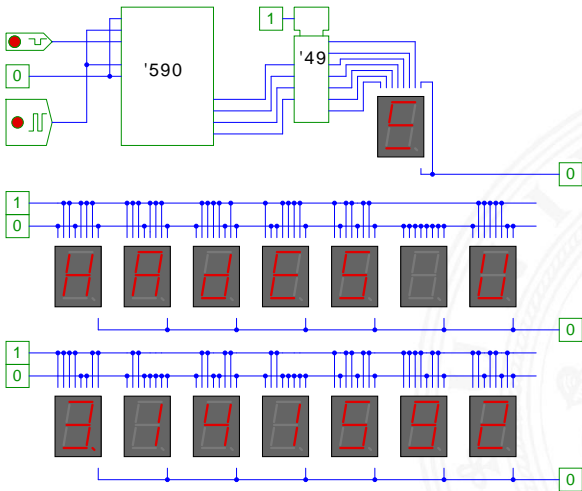
- ▶ Beispiel für eine integrierte Schaltung (IC)
- ▶ Anzeige von 0..9, Zufallsmuster für A..F, „Dunkeltastung“

Siebensegmentanzeige: Hades-Beispiele



► Buchstaben A...P

Siebensegmentanzeige: Hades-Beispiele (cont.)



Siebensegmentanzeige: mehrstufige Realisierung

Minimale Anzahl der Gatter für die Schaltung?

- ▶ Problem vermutlich nicht optimal lösbar (nicht *tractable*)
- ▶ Heuristik basierend auf „häufig“ verwendeten Teilfunktionen
- ▶ Eingänge x_1, x_2, x_3, x_4 , Ausgänge a, \dots, g

$$x_5 = x_2 \oplus x_3$$

$$x_6 = \overline{x_1} \wedge x_4$$

$$x_7 = x_3 \wedge \overline{x_6}$$

$$x_8 = x_1 \oplus x_2$$

$$x_9 = x_4 \oplus x_5$$

$$x_{10} = \overline{x_7} \wedge x_8$$

$$x_{11} = x_9 \oplus x_{10}$$

$$x_{12} = x_5 \wedge x_{11}$$

$$x_{13} = x_1 \oplus x_7$$

$$x_{14} = x_5 \oplus x_6$$

$$x_{15} = x_7 \vee x_{12}$$

$$x_{16} = x_1 \vee x_5$$

$$x_{17} = x_5 \vee x_6$$

$$x_{18} = x_9 \wedge x_{10}$$

$$x_{19} = x_3 \wedge x_9$$

$$\overline{a} = x_{20} = x_{14} \wedge \overline{x_{19}}$$

$$\overline{b} = x_{21} = x_7 \oplus x_{12}$$

$$\overline{c} = x_{22} = \overline{x_8} \wedge x_{15}$$

$$\overline{d} = x_{23} = x_9 \wedge \overline{x_{13}}$$

$$\overline{e} = x_{24} = x_6 \vee x_{18}$$

$$\overline{f} = x_{25} = \overline{x_8} \wedge x_{17}$$

$$g = x_{26} = x_7 \vee x_{16}$$

Logische und arithmetische Operationen

- ▶ Halb- und Volladdierer
- ▶ Addierertypen
 - ▶ Ripple-Carry
 - ▶ Carry-Lookahead
- ▶ Multiplizierer
- ▶ Quadratwurzel
- ▶ Barrel-Shifter
- ▶ ALU





Halbaddierer

- ▶ **Halbaddierer:** berechnet 1-bit Summe s und Übertrag c_o (*carry-out*) von zwei Eingangsbits a und b

a	b	c_o	s
0	0	0	0
0	1	0	1
1	0	0	1
1	1	1	0

$$c_o = a \wedge b$$

$$s = a \oplus b$$

Volladdierer

- Volladdierer:** berechnet 1-bit Summe s und Übertrag c_o (*carry-out*) von zwei Eingangsbits a , b sowie Eingangsübertrag c_i (*carry-in*)


a	b	c_i	c_o	s
0	0	0	0	0
0	0	1	0	1
0	1	0	0	1
0	1	1	1	0
1	0	0	0	1
1	0	1	1	0
1	1	0	1	0
1	1	1	1	1

$$c_o = ab \vee ac_i \vee bc_i = (ab) \vee (a \vee b)c_i$$


$$s = a \oplus b \oplus c_i$$

Schaltbilder für Halb- und Volladdierer

1-bit half-adder: $(COUT, S) = (A+B)$



1-bit full-adder: $(COUT, S) = (A+B+Cin)$





n-bit Addierer

▶ Summe: $s_n = a_n \oplus b_n \oplus c_n$

$$s_0 = a_0 \oplus b_0$$

$$s_1 = a_1 \oplus b_1 \oplus c_1$$

$$s_2 = a_2 \oplus b_2 \oplus c_2$$

...

$$s_n = a_n \oplus b_n \oplus c_n$$

▶ Übertrag: $c_{n+1} = (a_n b_n) \vee (a_n \vee b_n) c_n$

$$c_1 = (a_0 b_0)$$

$$c_2 = (a_1 b_1) \vee (a_1 \vee b_1) c_1$$

$$c_3 = (a_2 b_2) \vee (a_2 \vee b_2) c_2$$

...

$$c_{n+1} = (a_n b_n) \vee (a_n \vee b_n) c_n$$



n-bit Addierer (cont.)

- ▶ *n*-bit Addierer theoretisch als zweistufige Schaltung realisierbar
 - ▶ direkte und negierte Eingänge, dann AND-OR Netzwerk
 - ▶ Aufwand steigt exponentiell mit *n* an,
für Ausgang *n* sind $2^{(2n-1)}$ Minterme erforderlich
- ⇒ nicht praktikabel
- ▶ Problem: Übertrag (*carry*)

$$c_{n+1} = (a_n b_n) \vee (a_n \vee b_n) c_n$$
 rekursiv definiert

n-bit Addierer (cont.)

Diverse gängige Alternativen für Addierer

- ▶ Ripple-Carry
 - ▶ lineare Struktur
 - + klein, einfach zu implementieren
 - langsam, Laufzeit $O(n)$
- ▶ Carry-Lookahead (CLA)
 - ▶ Baumstruktur
 - + schnell
 - teuer (Flächenbedarf der Hardware)
- ▶ Mischformen: Ripple-block CLA, Block CLA, Parallel Prefix
- ▶ andere Ideen: Carry Select, Conditional Sum, Carry Skip
- ...

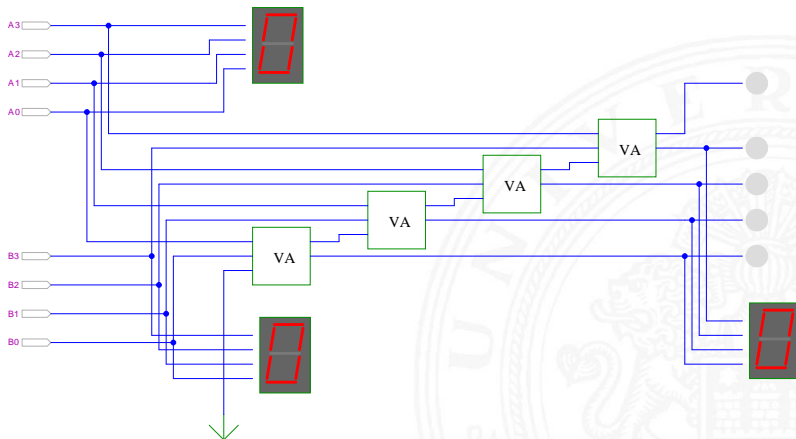


Ripple-Carry Adder

- ▶ Kaskade aus n einzelnen Volladdierern
- ▶ Carry-out von Stufe i treibt Carry-in von Stufe $i + 1$
- ▶ Gesamtverzögerung wächst mit der Anzahl der Stufen als $O(n)$


- ▶ Addierer in Prozessoren häufig im *kritischen Pfad*
- ▶ möglichst hohe Performance ist essentiell
- ▶ ripple-carry in CMOS-Technologie bis ca. 10-bit geeignet
- ▶ bei größerer Wortbreite gibt es effizientere Schaltungen

Ripple-Carry Adder: 4-bit



Ripple-Carry Adder: Hades-Beispiel mit Verzögerungen

- ▶ Kaskade aus acht einzelnen Volladdierern



- ▶ Gatterlaufzeiten in der Simulation bewusst groß gewählt
- ▶ Ablauf der Berechnung kann interaktiv beobachtet werden
- ▶ alle Addierer arbeiten parallel
- ▶ aber Summe erst fertig, wenn alle Stufen durchlaufen sind



Subtrahierer


Zweierkomplement

- ▶ $(A - B)$ ersetzt durch Addition des 2-Komplements von B
- ▶ 2-Komplement: Invertieren aller Bits und Addition von Eins
- ▶ Carry-in Eingang des Addierers bisher nicht benutzt

Subtraktion quasi „gratis“ realisierbar

- ▶ normalen Addierer verwenden
- ▶ Invertieren der Bits von B (1-Komplement)
- ▶ Carry-in Eingang auf 1 setzen (Addition von 1)
- ▶ Resultat ist $A + (\neg B) + 1 = A - B$

Subtrahierer: Beispiel (7483 – 4-bit Addierer)


 Schiffmann, Schmitz, *Technische Informatik I*



Schnelle Addierer

- ▶ Addierer in Prozessoren häufig im *kritischen Pfad*
- ▶ möglichst hohe Performance ist essentiell
- ⇒ bestimmt Taktfrequenz

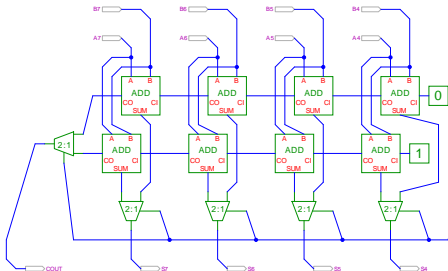
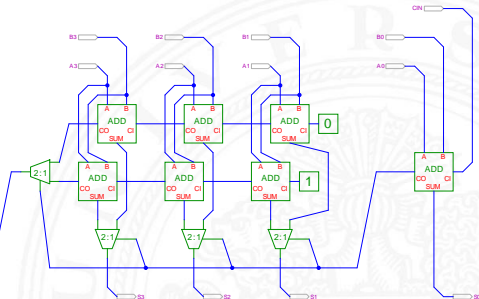
- ▶ Carry-Select Adder: Gruppen von Ripple-carry
- ▶ Carry-Lookahead Adder: Baumstruktur zur Carry-Berechnung
- ▶ ...

- ▶ über 10 Addierer „Typen“ (für 2 Operanden)
- ▶ Addition mehrerer Operanden
- ▶ Typen teilweise technologieabhängig

Carry-Select Adder: Prinzip

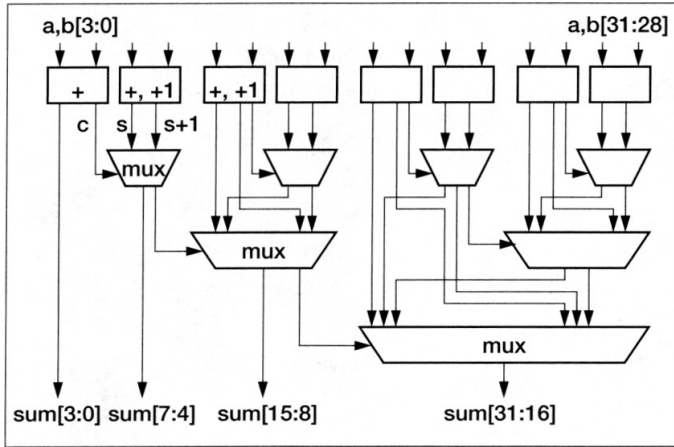
- ▶ Aufteilen des n -bit Addierers in mehrere Gruppen mit je m_i -bits
 - ▶ für jede Gruppe
 - ▶ jeweils zwei m_i -bit Addierer
 - ▶ einer rechnet mit $c_i = 0$ ($a + b$), der andere mit $c_i = 1$ ($a + b + 1$)
 - ▶ 2:1-Multiplexer mit m_i -bit wählt die korrekte Summe aus
 - ▶ Sobald der Wert von c_i bekannt ist (Ripple-Carry), wird über den Multiplexer die benötigte Zwischensumme ausgewählt
 - ▶ Das berechnete Carry-out c_o der Gruppe ist das Carry-in c_i der folgenden Gruppe
- ⇒ Verzögerung reduziert sich auf die Verzögerung eines m -bit Addierers plus die Verzögerungen der Multiplexer

Carry-Select Adder: Beispiel

8-Bit Carry-Select Adder (4 + 3 + 1 bit blocks)
4-bit Carry-Select Adder block

3-bit Carry-Select Adder block


- ▶ drei Gruppen: 1-bit, 3-bit, 4-bit
- ▶ Gruppengrößen so wählen, dass Gesamtverzögerung minimal

Carry-Select Adder: Beispiel ARM v6





Carry-Lookahead Adder: Prinzip

▶ $c_{n+1} = (a_n b_n) \vee (a_n \vee b_n) c_n$

- ▶ Einführung von Hilfsfunktionen

$$g_n = (a_n b_n)$$

$$p_n = (a_n \vee b_n)$$

$$c_{n+1} = g_n \vee p_n c_n$$


„generate carry“

„propagate carry“

- ▶ *generate*: Carry out erzeugen, unabhängig von Carry-in
 ▶ *propagate*: Carry out weiterleiten / Carry-in maskieren

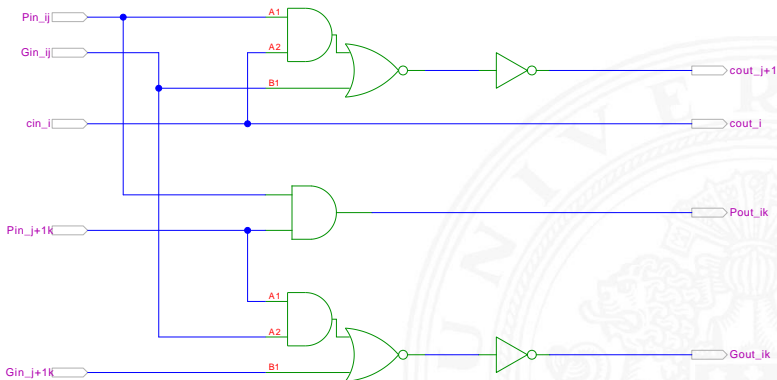
- ▶ Berechnung der g_n und p_n in einer Baumstruktur
 Tiefe des Baums ist $\log_2 N \Rightarrow$ entsprechend schnell

Carry-Lookahead Adder: SUM-Funktionsblock




- ▶ 1-bit Addierer, $s = a_i \oplus b_i \oplus c_i$
- ▶ keine Berechnung des Carry-Out
- ▶ Ausgang $g_i = a_i \wedge b_i$ liefert *generate-carry* Signal
- ▶ Ausgang $p_i = a_i \vee b_i$ liefert *propagate-carry* Signal

Carry-Lookahead Adder: CLA-Funktionsblock



Carry-Lookahead Adder: CLA-Funktionsblock (cont.)



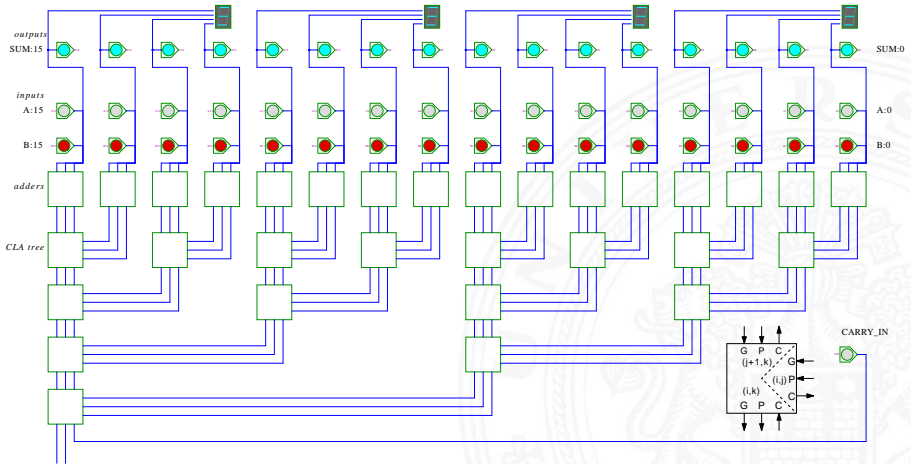
▶ Eingänge

- ▶ propagate/generate Signale von zwei Stufen
- ▶ carry-in Signal

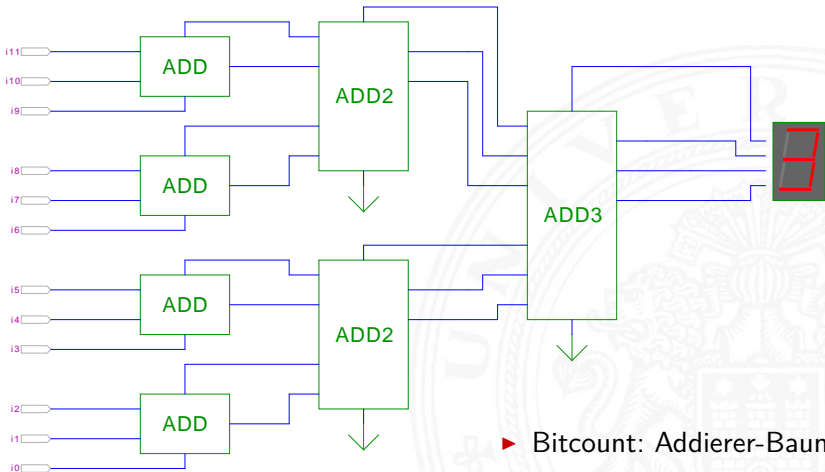
▶ Ausgänge

- ▶ propagate/generate Signale zur nächsthöheren Stufe
- ▶ carry-out Signale: Durchleiten und zur nächsthöheren Stufe

Carry-Lookahead Adder: 16-bit Addierer



Addition mehrerer Operanden





Addierer: Zusammenfassung

- ▶ Halbaddierer ($a \oplus b$)
- ▶ Volladdierer ($a \oplus b \oplus c_i$)

- ▶ Ripple-carry
 - ▶ Kaskade aus Volladdierern, einfach und billig
 - ▶ aber manchmal zu langsam, Verzögerung: $O(n)$
- ▶ Carry-select Prinzip
 - ▶ Verzögerung $O(\sqrt{n})$
- ▶ Carry-lookahead Prinzip
 - ▶ Verzögerung $O(\ln n)$

- ▶ Subtraktion durch Zweierkomplementbildung erlaubt auch Inkrement ($A++$) und Dekrement ($A--$)




Multiplizierer

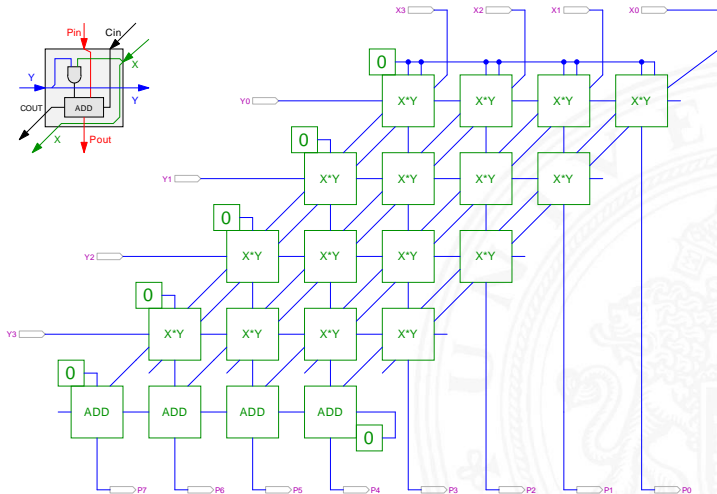
- ▶ Teilprodukte als UND-Verknüpfung des Multiplikators mit je einem Bit des Multiplikanden
- ▶ Aufaddieren der Teilprodukte mit Addierern
- ▶ Realisierung als Schaltnetz erfordert:
 - n^2 UND-Gatter (bitweise eigentliche Multiplikation)
 - n^2 Volladdierer (Aufaddieren der Teilprodukte)
- ▶ abschließend ein n -bit Addierer für die Überträge
- ▶ in heutiger CMOS-Technologie kein Problem

- ▶ alternativ: Schaltwerke (Automaten) mit sukzessiver Berechnung des Produkts in mehreren Takten durch Addition und Schieben


2x2-bit Multiplizierer – als zweistufiges Schaltnetz



4x4-bit Multiplizierer – Array



4x4-bit Quadratwurzel





Multiplizierer

weitere wichtige Themen aus Zeitgründen nicht behandelt

- ▶ *Booth-Codierung*
- ▶ *Carry-Save Adder* zur Summation der Teilprodukte
- ▶ Multiplikation von Zweierkomplementzahlen
- ▶ Multiplikation von Gleitkommazahlen

- ▶ CORDIC-Algorithmen
- ▶ bei Interesse: Literatur anschauen



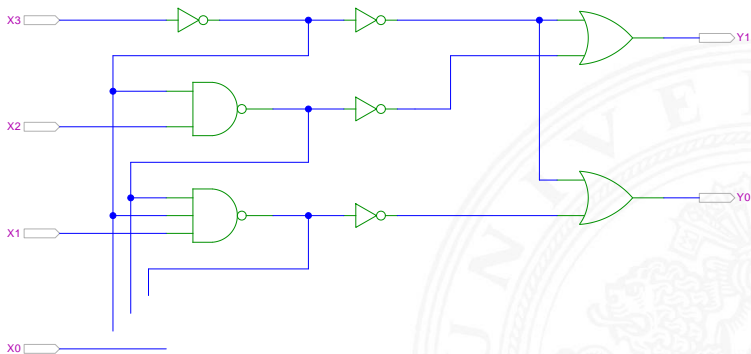
Priority Encoder

- ▶ Anwendung u.a. für Interrupt-Priorisierung
- ▶ Schaltung konvertiert n -bit Eingabe in eine Dualcodierung
- ▶ Wenn Bit n aktiv ist, werden alle niedrigeren Bits ($n - 1$), \dots , 0 ignoriert

x_3	x_2	x_1	x_0	y_1	y_0
1	*	*	*	1	1
0	1	*	*	1	0
0	0	1	*	0	1
0	0	0	*	0	0


- ▶ unabhängig von niederwertigstem Bit, x_0 kann entfallen

4:2 Prioritätsencoder




- ▶ zweistufige Realisierung
- ▶ aktive höhere Stufe blockiert alle niedrigeren Stufen

4:2 Prioritätsencoder: Kaskadierung

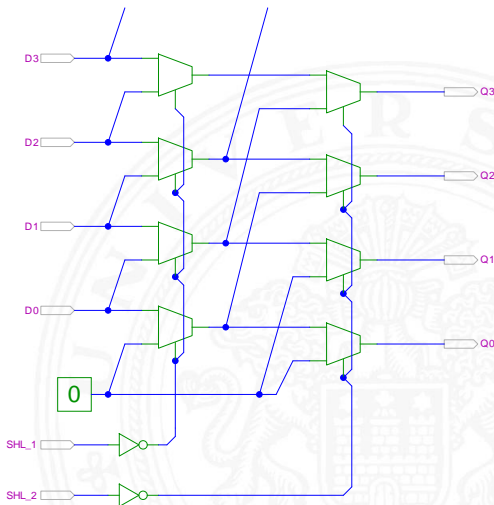


8:3 Prioritätsencoder

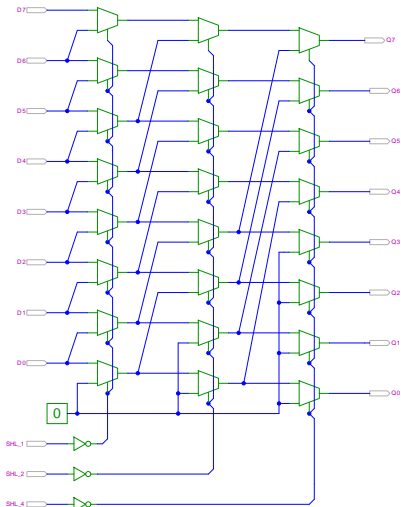


Shifter: zweistufig, shift-left um 0...3 Bits

- ▶ n -Dateneingänge D_i
- n -Datenausgänge Q_i
- ▶ 2:1 Multiplexer Kaskade
 - ▶ Stufe 0: benachbarte Bits
 - ▶ Stufe 1: übernächste Bits
 - ▶ usw.
- ▶ von rechts 0 nachschieben



8-bit Barrel-Shifter





Shift-Right, Rotate etc.

- ▶ Prinzip der oben vorgestellten Schaltungen gilt auch für alle übrigen Shift- und Rotate-Operationen
- ▶ Logic shift right: von links Nullen nachschieben
Arithmetic shift right: oberstes Bit nachschieben
- ▶ Rotate left / right: außen herausgeschobene Bits auf der anderen Seite wieder hineinschieben
- + alle Operationen typischerweise in einem Takt realisierbar
- Problem: Hardwareaufwand bei großen Wortbreiten und beliebigem Schiebe-/Rotate-Argument



Arithmetisch-Logische Einheit (ALU)

Arithmetisch-logische Einheit ALU (*Arithmetic Logic Unit*)

- ▶ kombiniertes Schaltnetz für arithmetische und logische Operationen
- ▶ das zentrale Rechenwerk in Prozessoren

Funktionsumfang variiert von Typ zu Typ

- ▶ Addition und Subtraktion 2-Komplement
- ▶ bitweise logische Operationen Negation, UND, ODER, XOR
- ▶ Schiebeoperationen shift, rotate
- ▶ evtl. Multiplikation

- ▶ Integer-Division selten verfügbar (separates Rechenwerk)

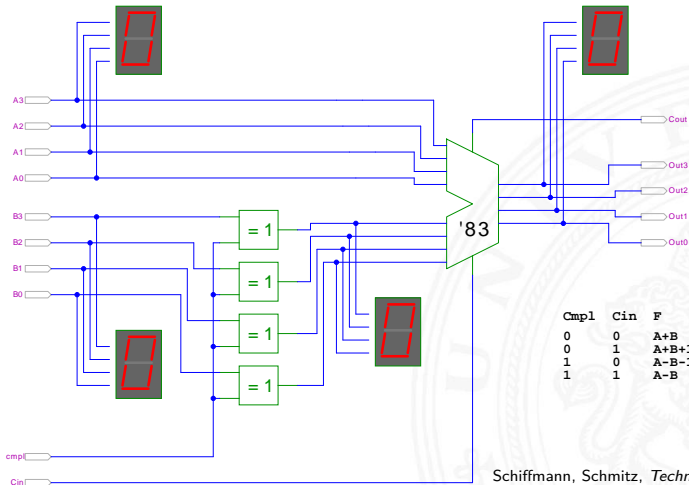


ALU: Addierer und Subtrahierer

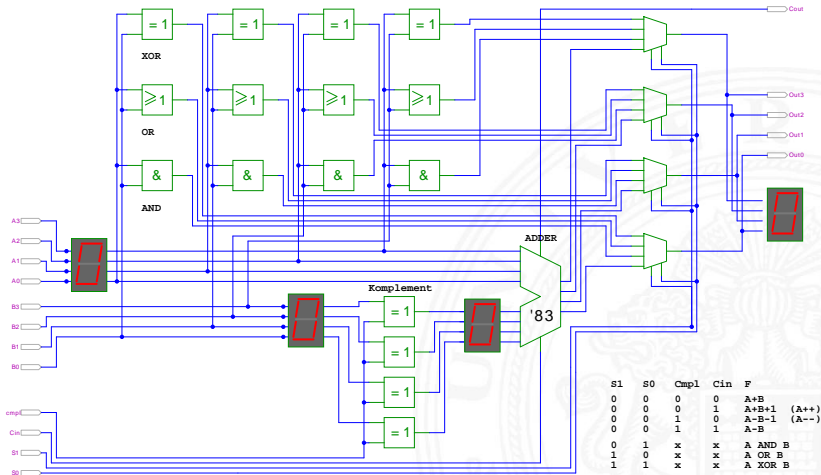
- ▶ Addition ($A + B$) mit normalem Addierer
- ▶ XOR-Gatter zum Invertieren von Operand B
- ▶ Steuerleitung *sub* aktiviert das Invertieren und den Carry-in c_i
- ▶ wenn aktiv, Subtraktion als $(A - B) = A + \neg B + 1$
- ▶ ggf. auch Inkrement ($A + 1$) und Dekrement ($A - 1$)

- ▶ folgende Folien: 7483 ist IC mit 4-bit Addierer

ALU: Addierer und Subtrahierer


 Schiffmann, Schmitz, *Technische Informatik I*

ALU: Addierer und bitweise Operationen





ALU: Prinzip


vorige Folie zeigt die „triviale“ Realisierung einer ALU

- ▶ mehrere parallele Rechenwerke für die m einzelnen Operationen
 n -bit Addierer, n -bit Komplement, n -bit OR, usw.
- ▶ Auswahl des Resultats über n -bit $m:1$ -Multiplexer

nächste Folie: Realisierung in der Praxis (IC 74181)


- ▶ erste Stufe für bitweise logische Operationen und Komplement
- ▶ zweite Stufe als Carry-lookahead Addierer
- ▶ weniger Gatter und schneller

ALU: 74181 – Aufbau



selection	logic functions	arithmetic functions
S3 S2 S1 S0	M = H	M = L, Cn=H (no carry)
L L L L	$F = !A$	$F = A$
L L L H	$F = !(A \text{ or } B)$	$F = A \text{ or } B$
L L H L	$F = !A * B$	$F = A \text{ or } !B$
L L H H	$F = !A * B$	$F = \text{MINUS } 1$
L H L L	$F = 0$	$F = A \text{ PLUS } (A * B)$
L H L H	$F = !B$	$F = (A \text{ or } B) \text{ PLUS } (A * B)$
L H H L	$F = A \text{ xor } B$	$F = A \text{ MINUS } B \text{ MINUS } 1$
L H H H	$F = A * B$	$F = (A * B) \text{ MINUS } 1$
H L L L	$F = !A \text{ or } B$	$F = A \text{ PLUS } (A * B)$
H L L H	$F = A \text{ xnor } B$	$F = A \text{ PLUS } B$
H L H L	$F = B$	$F = (A \text{ or } B) \text{ PLUS } (A * B)$
H L H H	$F = A * B$	$F = (A * B) \text{ MINUS } 1$
H H L L	$F = 1$	$F = A \text{ PLUS } A$
H H L H	$F = A \text{ or } B$	$F = (A \text{ or } B) \text{ PLUS } A$
H H H L	$F = A \text{ or } B$	$F = (A \text{ or } B) \text{ PLUS } A$
H H H H	$F = A$	$F = A \text{ MINUS } 1$
		Cn=L: PLUS 1

ALU: 74181 – Funktionstabelle

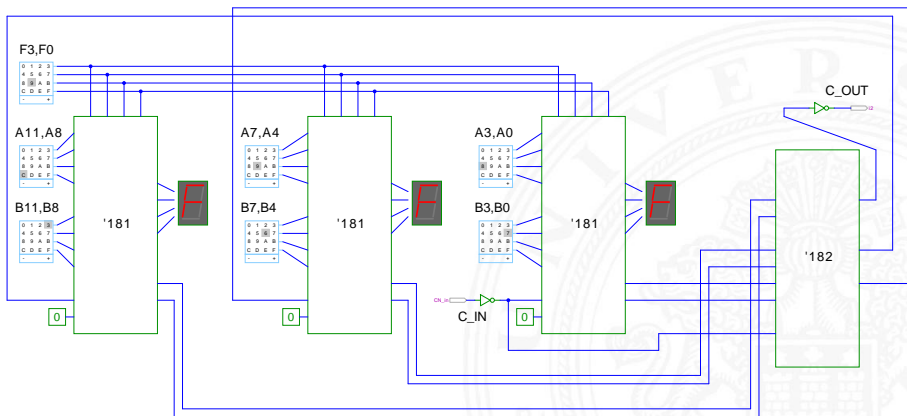


selection				logic functions	arithmetic functions
S3	S2	S1	S0	M = H	M = L, Cn=H (no carry)
L	L	L	L	$F = !A$	$F = A$
L	L	L	H	$F = !(A \text{ or } B)$	$F = A \text{ or } B$
L	L	H	L	$F = !A * B$	$F = A \text{ or } !B$
L	L	H	H	$F = !A * B$	$F = \text{MINUS } 1$
L	H	L	L	$F = 0$	$F = A \text{ PLUS } (A * B)$
L	H	L	H	$F = !B$	$F = (A \text{ or } B) \text{ PLUS } (A * !B)$
L	H	H	L	$F = A \text{ xor } B$	$F = A \text{ MINUS } B \text{ MINUS } 1$
L	H	H	H	$F = A * !B$	$F = (A * !B) \text{ MINUS } 1$
H	L	L	L	$F = !A \text{ or } B$	$F = A \text{ PLUS } (A * B)$
H	L	L	H	$F = A \text{ xor } B$	$F = A \text{ PLUS } B$
H	L	H	L	$F = B$	$F = (A \text{ or } !B) \text{ PLUS } (A * B)$
H	L	H	H	$F = A * B$	$F = (A * B) \text{ MINUS } 1$
H	H	L	L	$F = 1$	$F = A \text{ PLUS } A$
H	H	L	H	$F = A \text{ or } !B$	$F = (A \text{ or } B) \text{ PLUS } A$
H	H	H	L	$F = A \text{ or } B$	$F = (A \text{ or } !B) \text{ PLUS } A$
H	H	H	H	$F = A$	$F = A \text{ MINUS } 1$

Cn=L: PLUS 1

ALU: 74181 und 74182 CLA

12-bit ALU mit Carry-Lookahead Generator 74182





Literatur: Vertiefung

- ▶ Donald E. Knuth, *The Art of Computer Programming, Volume 4, Fascicle 0: Introduction to Combinatorial Algorithms and Boolean Functions*, Addison-Wesley, 2008
- ▶ Donald E. Knuth, *The Art of Computer Programming, Volume 4, Fascicle 1: Bitwise Tricks & Techniques, Binary Decision Diagrams*, Addison-Wesley, 2009
- ▶ Ingo Wegener, *The Complexity of Boolean Functions*, Wiley, 1987 1s2-www.cs.uni-dortmund.de/monographs/bluebook
- ▶ Bernd Becker, Rolf Drechsler, Paul Molitor, *Technische Informatik: Eine Einführung*, Pearson Studium, 2005
Besonderheit: Einführung von BDDs/ROBDDs



Interaktives Lehrmaterial

- ▶ Klaus von der Heide,
Vorlesung: Technische Informatik 1 — interaktives Skript
tams.informatik.uni-hamburg.de/lectures/2004ws/vorlesung/t1
- ▶ Norman Hendrich,
HADES — HAmBurg DEsign System
tams.informatik.uni-hamburg.de/applets/hades
KV-Diagram Simulation
tams.informatik.uni-hamburg.de/applets/kvd
- ▶ John Lazarro,
Chipmunk design tools (AnaLog, DigLog)
www.cs.berkeley.edu/~lazarro/chipmunk



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
- 13. Zeitverhalten**





Gliederung (cont.)

Modellierung Hazards

14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





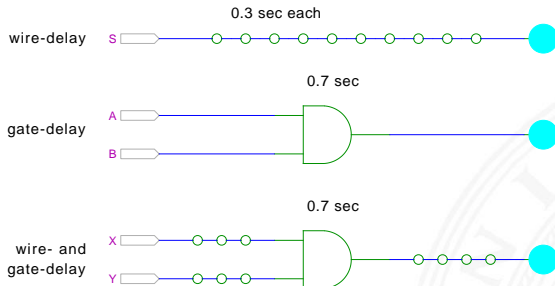
Zeitverhalten einer Schaltung: Modellierung

Wie wird das Zeitverhalten eines Schaltnetzes modelliert?

Gängige Abstraktionsebenen mit zunehmendem Detaillierungsgrad

1. algebraische Ausdrücke: keine zeitliche Abhängigkeit
2. „fundamentales Modell“: Einheitsverzögerung des algebraischen Ausdrucks um eine Zeit τ
3. individuelle Gatterverzögerungen
 - ▶ mehrere Modelle, unterschiedlich detailliert
 - ▶ Abstraktion elektrischer Eigenschaften
4. Gatterverzögerungen + Leitungslaufzeiten (geschätzt, berechnet)
5. Differentialgleichungen für Spannungen und Ströme (verschiedene „Ersatzmodelle“)

Gatterverzögerung vs. Leitungslaufzeiten



- ▶ früher: Gatterverzögerungen \gg Leitungslaufzeiten
- ▶ Schaltungen modelliert durch Gatterlaufzeiten
- ▶ aktuelle „Submicron“-Halbleitertechnologie: Leitungslaufzeiten \gg Gatterverzögerungen



Zeitverhalten

- ▶ alle folgenden Schaltungsbeispiele werden mit Gatterverzögerungen modelliert
- ▶ Gatterlaufzeiten als Vielfache einer Grundverzögerung (τ)
- ▶ aber Leitungslaufzeiten ignoriert

- ▶ mögliche Verfeinerungen
 - ▶ gatterabhängige Schaltzeiten für INV, NAND, NOR, XOR etc.
 - ▶ unterschiedliche Schaltzeiten für Wechsel: $0 \rightarrow 1$ und $1 \rightarrow 0$
 - ▶ unterschiedliche Schaltzeiten für 2-, 3-, 4-Input Gatter
 - ▶ Schaltzeiten sind abhängig von der Anzahl nachfolgender Eingänge (engl. *fanout*)



Exkurs: Lichtgeschwindigkeit und Taktraten

- ▶ Lichtgeschwindigkeit im Vakuum: $c \approx 300\,000 \text{ km/sec}$
 $\approx 30 \text{ cm/ns}$
- ▶ in Metallen und Halbleitern langsamer: $c \approx 20 \text{ cm/ns}$
- ⇒ bei 1 Gigahertz Takt: Ausbreitung um ca. 20 Zentimeter

Abschätzungen:


- ▶ Prozessor: ca. 2 cm Diagonale $\approx 10 \text{ GHz}$ Taktrate
- ▶ Platine: ca. 20 cm Kantenlänge $\approx 1 \text{ GHz}$ Takt
- ▶ UKW-Radio: 100 MHz, 2 Meter Wellenlänge
- ⇒ prinzipiell kann (schon heute) ein Signal innerhalb eines Takts nicht von einer Ecke des ICs zur Anderen gelangen



Impulsdiagramme

- ▶ **Impulsdiagramm** (engl. *waveform*): Darstellung der logischen Werte einer Schaltfunktion als Funktion der Zeit
- ▶ als Abstraktion des tatsächlichen Verlaufs
- ▶ Zeit läuft von links nach rechts
- ▶ Schaltfunktion(en): von oben nach unten aufgelistet
- ▶ Vergleichbar den Messwerten am Oszilloskop (analoge Werte) bzw. den Messwerten am Logic-State-Analyzer (digitale Werte)
- ▶ ggf. Darstellung mehrerer logischer Werte (z.B. 0,1,Z,U,X)

Impulsdiagramm: Beispiel



- ▶ im Beispiel jeweils eine „Zeiteinheit“ Verzögerung für jede einzelne logische Operation
- ▶ Ergebnis einer Operation nur, wenn die Eingaben definiert sind
- ▶ im ersten Zeitschritt noch undefinierte Werte



Hazards

- ▶ **Hazard:** die Eigenschaft einer Schaltfunktion, bei bestimmten Kombinationen der individuellen Verzögerungen ihrer Verknüpfungsglieder ein Fehlverhalten zu zeigen
- ▶ **Hazardfehler:** das aktuelle Fehlverhalten einer realisierten Schaltfunktion aufgrund eines Hazards



Hazards: Klassifikation

nach der Erscheinungsform am Ausgang


- ▶ **statisch**: der Ausgangswert soll stabil sein, es tritt aber ein Wechsel auf
- ▶ **dynamisch**: der Ausgangswert soll (einmal) wechseln, es tritt aber ein mehrfacher Wechsel auf

nach den Eingangsbedingungen, unter denen der Hazard auftritt

- ▶ **Strukturhazard**: bedingt durch die Struktur der Schaltung, auch bei Umschalten eines einzigen Eingangswertes
- ▶ **Funktionshazard**: bedingt durch die Funktion der Schaltung

Hazards: statisch vs. dynamisch

erwarteter Signalverlauf



Verlauf mit Hazard



statischer 1-Hazard

statischer 0-Hazard


dynamischer 1-Hazard

dynamischer 0-Hazard

- ▶ 1-Hazard wenn fehlerhaft der Wert 1 auftritt, und umgekehrt
- ▶ es können natürlich auch mehrfache Hazards auftreten
- ▶ Hinweis: Begriffsbildung in der Literatur nicht einheitlich




Hazards: Strukturhazard

- ▶ **Strukturhazard** wird durch die gewählte Struktur der Schaltung verursacht
- ▶ auch, wenn sich nur eine Variable ändert
- ▶ Beispiel: $f(a) = \neg a \vee (a \wedge a)$
 $\neg a$ schaltet schneller ab, als $(a \wedge a)$ einschaltet



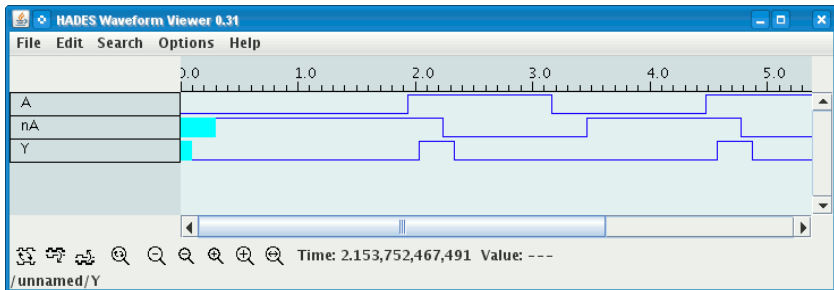
- ▶ Hazard kann durch Modifikation der Schaltung beseitigt werden
 im Beispiel mit: $f(a) = 1$

Strukturhazards: Beispiele




- ▶ logische Funktion ist $(a \wedge \bar{a}) = 0$ bzw. $(a \vee \bar{a}) = 1$
- ▶ aber ein Eingang jeweils durch Inverter verzögert
- ⇒ kurzer Impuls beim Umschalten von $0 \rightarrow 1$ bzw. $1 \rightarrow 0$

Strukturhazards: Beispiele (cont.)



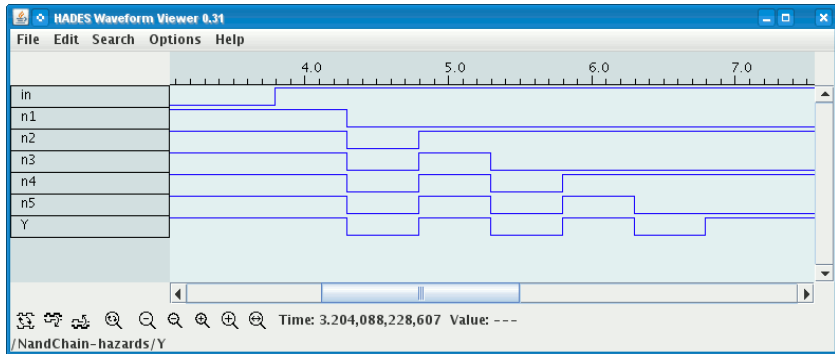
- ▶ Schaltung $(a \wedge \bar{a}) = 0$ erzeugt (statischen-1) Hazard
- ▶ Länge des Impulses abhängig von Verzögerung im Inverter
- ▶ Kette von Invertern erlaubt Einstellung der Pulslänge

Strukturhazards extrem: NAND-Kette



- ▶ alle NAND-Gatter an Eingang *in* angeschlossen
- ▶ $in = 0$ erzwingt $y_i = 1$
- ▶ Übergang *in* von 0 auf 1 startet Folge von Hazards...

Strukturhazards extrem: NAND-Kette (cont.)



- ▶ Schaltung erzeugt Folge von (dynamischen-0) Hazards
- ▶ Anzahl der Impulse abhängig von Anzahl der Gatter

Strukturhazards im KV-Diagramm

		x1 x0			
		00	01	11	10
x2	0	0	0	1	0
	1	1	1	1	0



		x1 x0			
		00	01	11	10
x2	0	0	0	1	0
	1	1	1	1	0

- ▶ Funktion $f = (x_2 \bar{x}_1) \vee (x_1 x_0)$
- ▶ realisiert in disjunktiver Form mit 2 Schleifen

Strukturhazard beim Übergang von $(x_2 \bar{x}_1 x_0)$ nach $(x_2 x_1 x_0)$

- ▶ Gatter $(x_2 \bar{x}_1)$ schaltet ab, Gatter $(x_1 x_0)$ schaltet ein
- ▶ Ausgang evtl. kurz 0, abhängig von Verzögerungen

Strukturhazards im KV-Diagramm (cont.)



Strukturhazards beseitigen

		x1 x0			
		00	01	11	10
x2	0	0	0	1	0
	1	1	1	1	0

		x1 x0			
		00	01	11	10
x2	0	0	0	1	0
	1	1	1	1	0

▶ Funktion $f = (x_2 \bar{x}_1) \vee (x_1 x_0)$



▶ realisiert in disjunktiver Form mit **3 Schleifen**

$$f = (x_2 \bar{x}_1) \vee (x_1 x_0) \vee (x_2 x_0)$$

+ Strukturhazard durch zusätzliche Schleife beseitigt

– aber höhere Hardwarekosten als bei minimierter Realisierung

Strukturhazards beseitigen (cont.)



Hazards: Funktionshazard

- ▶ **Funktionshazard** kann bei gleichzeitigem Wechsel mehrerer Eingangswerte als **Eigenschaft der Schaltfunktion** entstehen
- ▶ Problem: Gleichzeitigkeit an Eingängen
- ⇒ Funktionshazard kann nicht durch strukturelle Maßnahmen verhindert werden

- ▶ Beispiel: Übergang von $(x_2 \bar{x}_1 x_0)$ nach $(\bar{x}_2 x_1 x_0)$

		x1 x0			
		00	01	11	10
x2	0	0	0	1	0
	1	1	1	1	0

		x1 x0			
		00	01	11	10
x2	0	0	0	1	0
	1	1	1	1	0



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

14. Schaltwerke

Definition und Modelle

Synchrone (getaktete) Schaltungen

Flipflops

RS-Flipflop

D-Latch

D-Flipflop

JK-Flipflop

Hades

Zeitbedingungen

Taktsignale

Beschreibung von Schaltwerken

Entwurf von Schaltwerken

Beispiele



Gliederung (cont.)

Ampelsteuerung
Zählschaltungen
verschiedene Beispiele

Asynchrone Schaltungen

Literatur

15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie

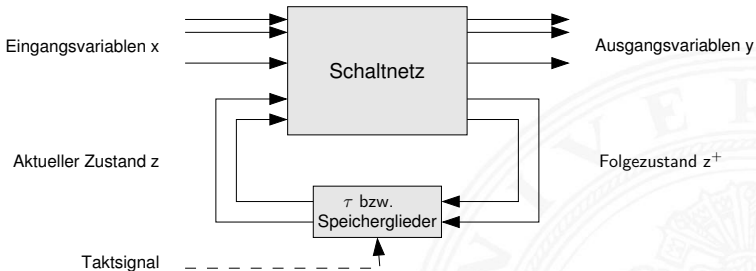




Schaltwerke


- ▶ **Schaltwerk:** Schaltung mit Rückkopplungen und Verzögerungen
- ▶ fundamental andere Eigenschaften als Schaltnetze
- ▶ Ausgangswerte nicht nur von Eingangswerten abhängig sondern auch von der Vorgeschichte
- ⇒ interner Zustand repräsentiert „Vorgeschichte“
- ▶ ggf. stabile Zustände ⇒ Speicherung von Information
- ▶ bei unvorsichtigem Entwurf: chaotisches Verhalten

Schaltwerke: Blockschaltbild



- ▶ Eingangsvariablen x und Ausgangsvariablen y
- ▶ Aktueller Zustand z
- ▶ Folgezustand z^+
- ▶ Rückkopplung läuft über Verzögerungen τ / Speicherglieder

Schaltwerke: Blockschaltbild (cont.)



zwei prinzipielle Varianten für die Zeitglieder

1. nur (Gatter-) Verzögerungen: **asynchrone** oder **nicht getaktete Schaltwerke**
2. getaktete Zeitglieder: **synchrone** oder **getaktete Schaltwerke**



Synchrone und Asynchrone Schaltwerke

- ▶ **synchrone Schaltwerke:** die Zeitpunkte, an denen das Schaltwerk von einem stabilen Zustand in einen stabilen Folgezustand übergeht, werden explizit durch ein Taktsignal (*clock*) vorgegeben
- ▶ **asynchrone Schaltwerke:** hier fehlt ein Taktgeber, Änderungen der Eingangssignale wirken sich unmittelbar aus (entsprechend der Gatterverzögerungen τ)
- ▶ potentiell höhere Arbeitsgeschwindigkeit
- ▶ aber sehr aufwendiger Entwurf
- ▶ fehleranfälliger (z.B. leicht veränderte Gatterverzögerungen durch Bauteil-Toleranzen, Spannungsschwankungen, usw.)

Theorie: Endliche Automaten

FSM – Finite State Machine

- ▶ Deterministischer Endlicher Automat mit Ausgabe
- ▶ 2 äquivalente Modelle
 - ▶ Mealy: Ausgabe hängt *von Zustand und Eingabe* ab
 - ▶ Moore: –"– *nur vom Zustand* ab
- ▶ 6-Tupel $(Z, \Sigma, \Delta, \delta, \lambda, z_0)$
 - ▶ Z Menge von Zuständen
 - ▶ Σ Eingabealphabet
 - ▶ Δ Ausgabealphabet
 - ▶ δ Übergangsfunktion $\delta : Z \times \Sigma \rightarrow Z$
 - ▶ λ Ausgabefunktion $\lambda : Z \times \Sigma \rightarrow \Delta$
 - $\lambda : Z \rightarrow \Delta$
 - ▶ z_0 Startzustand

Mealy-Modell
 Moore- –"–

Mealy-Modell und Moore-Modell

- ▶ **Mealy-Modell:** die Ausgabe hängt vom Zustand z und vom momentanen Input x ab
- ▶ **Moore-Modell:** die Ausgabe des Schaltwerks hängt nur vom aktuellen Zustand z ab


- ▶ **Ausgabefunktion:**

$y = \lambda(z, x)$	Mealy
$y = \lambda(z)$	Moore
- ▶ **Überföhrungsfunktion:** $z^+ = \delta(z, x)$ Moore und Mealy


- ▶ **Speicherglieder** oder Verzögerung τ im Rückkopplungspfad

Mealy-Modell und Moore-Modell (cont.)

► Mealy-Automat



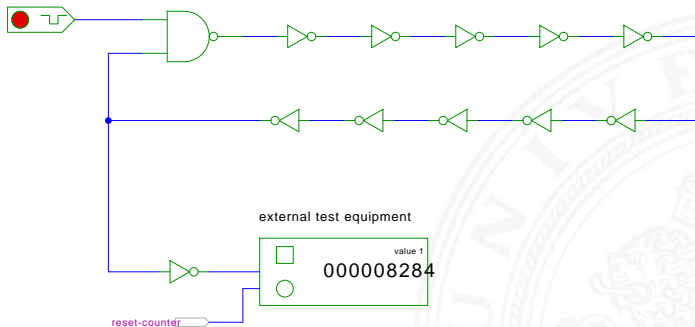
Moore-Automat



Asynchrone Schaltungen: Beispiel Ringoszillator

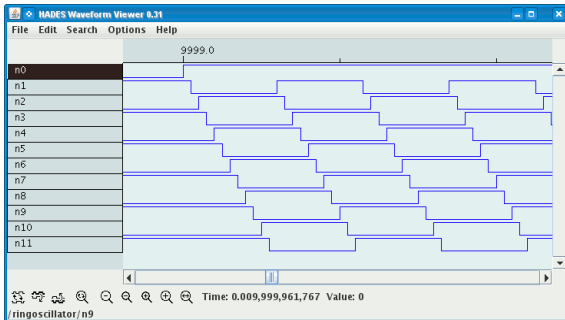
click to start/stop

odd number of inverting gates



- ▶ stabiler Zustand, solange der Eingang auf 0 liegt
- ▶ instabil sobald der Eingang auf 1 wechselt (Oszillation)

Asynchrone Schaltungen: Beispiel Ringoszillator (cont.)



- ▶ ungerade Anzahl n invertierender Gatter ($n \geq 3$)
- ▶ Start/Stop über steuerndes NAND-Gatter
- ▶ Oszillation mit maximaler Schaltfrequenz
z.B.: als Testschaltung für neue (Halbleiter-) Technologien



Asynchrone Schaltungen: Probleme

- ▶ das Schaltwerk kann stabile und nicht-stabile Zustände enthalten
- ▶ die Verzögerungen der Bauelemente sind nicht genau bekannt und können sich im Betrieb ändern
- ▶ Variation durch Umweltparameter, z.B. Temperatur, Versorgungsspannung, Alterung
- ▶ sehr schwierig, die korrekte Funktion zu garantieren
- ▶ z.B. mehrstufige Handshake-Protokolle
- ▶ in der Praxis überwiegen synchrone Schaltwerke
- ▶ Realisierung mit **Flipflops** als Zeitgliedern



Synchrone Schaltungen

- ▶ alle Rückkopplungen der Schaltung laufen über spezielle Zeitglieder: „Flipflops“
 - ▶ diese definieren / speichern einen stabilen Zustand, unabhängig von den Eingabewerten und Vorgängen im δ -Schaltnetz
 - ▶ Hinzufügen eines zusätzlichen Eingangssignals: „Takt“
 - ▶ die Zeitglieder werden über das Taktsignal gesteuert
 verschiedene Möglichkeiten: Pegel- und Flankensteuerung, Mehrphasentakte (s.u.)
- ⇒ synchrone Schaltwerke sind wesentlich einfacher zu entwerfen und zu analysieren als asynchrone Schaltungen



Zeitglieder / Flipflops

- ▶ **Zeitglieder:** Bezeichnung für die Bauelemente, die den Zustand des Schaltwerks speichern können
- ▶ **bistabile Bauelemente** (Kippglieder) oder **Flipflops**
- ▶ zwei stabile Zustände \Rightarrow speichert 1 Bit
 - 1 – Setzzustand
 - 0 – Rücksetzzustand
- ▶ Übergang zwischen Zuständen durch geeignete Ansteuerung



Flipflops

- ▶ Name für die **elementaren** Schaltwerke
- ▶ mit genau zwei Zuständen Z_0 und Z_1
- ▶ Zustandsdiagramm hat zwei Knoten und vier Übergänge (s.u.)

- ▶ Ausgang als Q bezeichnet und dem Zustand gleichgesetzt
- ▶ meistens auch invertierter Ausgang \bar{Q} verfügbar

- ▶ Flipflops sind selbst nicht getaktet
- ▶ sondern „sauber entworfene“ asynchrone Schaltwerke
- ▶ Anwendung als Verzögerungs-/Speicherelemente in getakteten Schaltwerken

Flipflops: Typen

- ▶ Basis-Flipflop
- ▶ getaktetes RS-Flipflop

- ▶ pegelgesteuertes D-Flipflop
- ▶ flankengesteuertes D-Flipflop


- ▶ JK-Flipflop
- ▶ weitere. . .

„Reset-Set-Flipflop“


„D-Latch“

„D-Flipflop“

RS-Flipflop: NAND- und NOR-Realisierung





/S	/R	Q	NQ	NAND
0	0	1	1	(forbidden)
0	1	1	0	
1	0	0	1	
1	1	Q*	NQ*	(store)




S	R	Q	NQ	NOR
0	0	Q*	NQ*	(store)
0	1	0	1	
1	0	1	0	
1	1	0	0	(forbidden)

RS-Flipflop: Varianten des Schaltbilds



NOR RS-Flipflop: Zustandsdiagramm und Flusstafel




	Eingabe [S R]			
	00	01	11	10
Zustand	Folgezustand [Q Q̄]			
00	11	01	00	10
01	01	01	00	00
11	00	00	00	00
10	10	00	00	10

stabiler Zustand

RS-Flipflop mit Takt

- ▶ RS-Basisflipflop mit zusätzlichem Takteingang C
- ▶ Änderungen nur wirksam, während C aktiv ist
- ▶ Struktur



C	S	R	Q	NQ	NOR
0	X	X	Q*	NQ*	(store)
1	0	0	Q*	NQ*	(store)
1	0	1	0	1	
1	1	0	1	0	
1	1	1	0	0	(forbidden)

Pegelgesteuertes D-Flipflop (D-Latch)


- ▶ Takteingang C
- ▶ Dateneingang D
- ▶ aktueller Zustand Q , Folgezustand Q^+

C	D	Q^+
0	0	Q
0	1	Q
1	0	0
1	1	1

- ▶ Wert am Dateneingang wird durchgeleitet, wenn das Taktsignal 1 ist \Rightarrow *high*-aktiv
 0 ist \Rightarrow *low*-aktiv

Pegelgesteuertes D-Flipflop (D-Latch) (cont.)


- ▶ Realisierung mit getaktetem RS-Flipflop und einem Inverter
 $S = D, R = \bar{D}$
- ▶ minimierte NAND-Struktur



- ▶ Symbol



D-Latch: Zustandsdiagramm und Flusstafel



Zustand [Q]	Eingabe [C D]			
	00	01	11	10
0	0	0	1	0
1	1	1	1	0

stabiler Zustand

Flankengesteuertes D-Flipflop

- ▶ Takteingang C
- ▶ Dateneingang D
- ▶ aktueller Zustand Q , Folgezustand Q^+

C	D	Q^+
0	*	Q
1	*	Q
↑	0	0
↑	1	1


- ▶ Wert am Dateneingang wird gespeichert, wenn das Taktsignal sich von 0 auf 1 ändert \Rightarrow Vorderflankensteuerung
 –"– 1 auf 0 ändert \Rightarrow Rückflankensteuerung
- ▶ Realisierung als Master-Slave Flipflop oder direkt



Master-Slave D-Flipflop

- ▶ zwei kaskadierte D-Latches
 - ▶ hinteres Latch erhält invertierten Takt
 - ▶ vorderes „Master“-Latch: low-aktiv (transparent bei $C = 0$)
hinteres „Slave“-Latch: high-aktiv (transparent bei $C = 1$)
 - ▶ vorderes Latch speichert bei Wechsel auf $C = 1$
 - ▶ wenig später (Gatterverzögerung im Inverter der Taktleitung)
übernimmt das hintere „Slave“-Latch diesen Wert
 - ▶ anschließend Input für das Slave-Latch stabil
 - ▶ Slave-Latch speichert, sobald Takt auf $C = 0$ wechselt
- ⇒ dies entspricht effektiv einer **Flankensteuerung**:
Wert an D nur relevant, kurz bevor Takt auf $C = 1$ wechselt


Master-Slave D-Flipflop (cont.)



Hades Webdemos: 16-flipflops/20-dlatch/dff

- ▶ zwei kaskadierte pegel-gesteuerte D-Latches
- $C=0$ Master aktiv (transparent)
Slave hat (vorherigen) Wert gespeichert
- $C=1$ Master speichert Wert
Slave transparent, leitet Wert von Master weiter

Vorderflanken-gesteuertes D-Flipflop



- ▶ Dateneingang D wird nur durch Takt-Vorderflanke ausgewertet
- ▶ Gatterlaufzeiten für Funktion essentiell
- ▶ Einhalten der Vorlauf- und Haltezeiten vor/nach der Taktflanke (s.u. *Zeitbedingungen*)


JK-Flipflop

- ▶ Takteingang C
- ▶ Steuereingänge J („jump“) und K („kill“)
- ▶ aktueller Zustand Q , Folgezustand Q^+


C	J	K	Q^+	Funktion
*	*	*	Q	Wert gespeichert
↑	0	0	Q	Wert gespeichert
↑	0	1	0	Rücksetzen
↑	1	0	1	Setzen
↑	1	1	\overline{Q}	Invertieren

- ▶ universelles Flipflop, sehr flexibel einsetzbar
- ▶ in integrierten Schaltungen nur noch selten verwendet

JK-Flipflop: Realisierung mit D-Flipflop



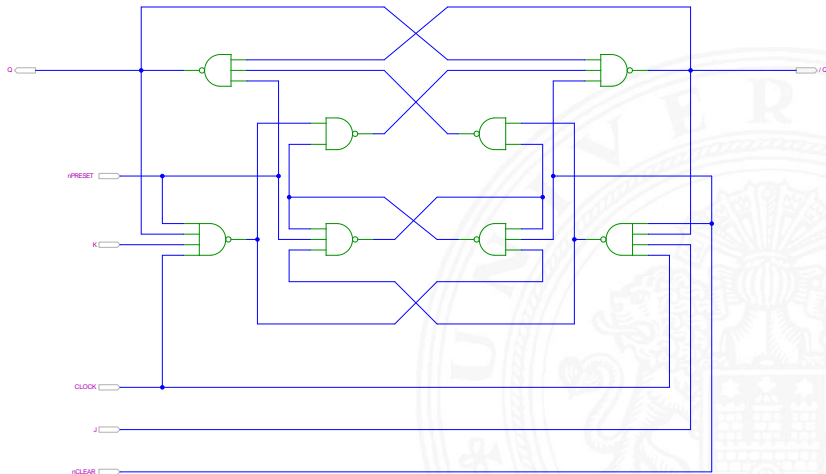
JK-Flipflop: Realisierung als Master-Slave Schaltung



Hades Webdemos: 16-flipflops/40-jkff/jkff



Achtung: Schaltung wegen Rückkopplungen schwer zu initialisieren

JK-Flipflop: tatsächliche Schaltung im IC 7476





Flipflop-Typen: Komponenten/Symbole in Hades


D-type latches




D-type flipflops



JK flipflop




metastable D-Latch (don't use!)



metastable D-flipflop (don't use!)



Flipflop-Typen: Impulsdiagramme




- ▶ pegel- und vorderflankengesteuertes Flipflop
- ▶ beide Flipflops hier mit jeweils einer Zeiteinheit Verzögerung
- ▶ am Ende undefinierte Werte wegen gleichzeitigem Wechsel von C und D (Verletzung der Zeitbedingungen)

Flipflops: Zeitbedingungen

- ▶ Flipflops werden entwickelt, um Schaltwerke einfacher entwerfen und betreiben zu können
 - ▶ Umschalten des Zustandes durch das Taktsignal gesteuert
 - ▶ aber: jedes Flipflop selbst ist ein asynchrones Schaltwerk mit kompliziertem internem Zeitverhalten
 - ▶ Funktion kann nur garantiert werden, wenn (typ-spezifische) Zeitbedingungen eingehalten werden
- ⇒ „Vorlauf- und Haltezeiten“ (*setup- / hold-time*)
- ⇒ Daten- und Takteingänge dürfen sich nie gleichzeitig ändern



Flipflops: Vorlauf- und Haltezeit

- ▶ Vorlaufzeit (oder Vorbereitungszeit, engl. *setup-time*) t_s : Zeitintervall, innerhalb dessen das Datensignal vor dem nächsten Takt bereits stabil anliegen muss
- ▶ Haltezeit (*hold-time*) t_h : Zeitintervall, innerhalb dessen das Datensignal nach einem Takt noch stabil anliegen muss



Schiffmann, Schmitz,
 Technische Informatik I, Kapitel 5

Zeitbedingungen: Eingangsvektor







Zeitbedingungen: Eingangsvektor (cont.)

- ▶ Änderungen der Eingangswerte x werden beim Durchlaufen von δ mindestens um $\tau_{\delta_{\min}}$, bzw. maximal um $\tau_{\delta_{\max}}$ verzögert
 - ▶ um die Haltezeit der Zeitglieder einzuhalten, darf x sich nach einem Taktimpuls frühestens zum Zeitpunkt $(t_1 + t_{\text{hold}} - \tau_{\delta_{\min}})$ wieder ändern
 - ▶ um die Vorlaufzeit vor dem nächsten Takt einzuhalten, muss x spätestens zum Zeitpunkt $(t_2 - t_{\text{setup}} - \tau_{\delta_{\max}})$ wieder stabil sein
- ⇒ Änderungen dürfen nur im grün markierten Zeitintervall erfolgen

Zeitbedingungen: interner Zustand



Zeitbedingungen: interner Zustand (cont.)

- ▶ zum Zeitpunkt t_1 wird ein Taktimpuls ausgelöst
 - ▶ nach dem Taktimpuls vergeht die Zeit τ_{FF} , bis die Zeitglieder (Flipflops) ihren aktuellen Eingangswert z^+ übernommen haben und als neuen Zustand z am Ausgang bereitstellen
 - ▶ die neuen Werte von z laufen durch das δ -Schaltnetz, der schnellste Pfad ist dabei $\tau_{\delta_{\min}}$ und der langsamste ist $\tau_{\delta_{\max}}$
- ⇒ innerhalb der Zeitintervalls $\tau_{FF} + \tau_{\delta_{\min}}$ bis $\tau_{FF} + \tau_{\delta_{\max}}$ ändern sich die Werte des Folgezustands z^+ grauer Bereich



Zeitbedingungen: interner Zustand (cont.)

- ▶ die Änderungen dürfen frühestens zum Zeitpunkt ($t_1 + t_{hold}$) beginnen, ansonsten würde Haltezeit verletzt
ggf. muss $\tau_{\delta_{min}}$ vergrößert werden, um diese Bedingung einhalten zu können (zusätzliche Gatterverzögerungen)
- ▶ die Änderungen müssen sich spätestens bis zum Zeitpunkt ($t_2 - t_{setup}$) stabilisiert haben (der Vorbereitungszeit der Flipflops vor dem nächsten Takt)



Maximale Taktfrequenz einer Schaltung




- ▶ aus obigen Bedingungen ergibt sich sofort die maximal zulässige Taktfrequenz einer Schaltung
- ▶ Umformen und Auflösen nach dem Zeitpunkt des nächsten Takts ergibt zwei Bedingungen

$$\Delta t \geq (\tau_{FF} + \tau_{\delta_{\max}} + \tau_{setup}) \quad \text{und}$$

$$\Delta t \geq (\tau_{hold} + \tau_{setup})$$

- ▶ falls diese Bedingung verletzt wird („Übertakten“), kann es (datenabhängig) zu Fehlfunktionen kommen

Taktsignal: Prinzip






- ▶ periodisches digitales Signal, Frequenz f bzw. Periode τ
- ▶ oft symmetrisch
- ▶ asymmetrisch für Zweiphasentakt (s.u.)





Taktsignal: Varianten

- ▶ **Pegelsteuerung:** Schaltung reagiert, während das Taktsignal den Wert 1 (bzw. 0) aufweist
- ▶ **Flankensteuerung:** Schaltung reagiert nur, während das Taktsignal seinen Wert wechselt
 - ▶ Vorderflankensteuerung: Wechsel von 0 nach 1
 - ▶ Rückflankensteuerung: —" von 1 nach 0
- ▶ Zwei- und Mehrphasentakte

Taktsignal: Varianten (cont.)




Taktsignal: Prinzip und Realität



- ▶ Werteverläufe in realen Schaltungen stark gestört
- ▶ Überschwingen/Übersprechen benachbarter Signale
- ▶ Flankensteilheit nicht garantiert (bei starker Belastung)
ggf. besondere Gatter („Schmitt-Trigger“)

Problem mit Pegelsteuerung

- ▶ während des aktiven Taktpegels werden Eingangswerte direkt übernommen
- ▶ falls invertierende Rückkopplungspfade in δ vorliegen, kommt es dann zu instabilen Zuständen (Oszillationen)





- ▶ einzelne pegelgesteuerte Zeitglieder (D-Latches) garantieren keine stabilen Zustände
- ⇒ Verwendung von je zwei pegelgesteuerten Zeitgliedern und Einsatz von Zweiphasentakt oder
- ⇒ Verwendung flankengesteuerter D-Flipflops

Zweiphasentakt

- ▶ pegelgesteuertes D-Latch ist bei aktivem Takt *transparent*
- ▶ rück-gekoppelte Werte werden sofort wieder durchgelassen
- ▶ Oszillation bei invertierten Rückkopplungen



- ▶ Reihenschaltung aus jeweils zwei D-Latches
- ▶ zwei separate Takte Φ_1 und Φ_2
 - ▶ bei Takt Φ_1 übernimmt vorderes Flipflop den Wert
 - ▶ erst bei Takt Φ_2 übernimmt hinteres Flipflop
 - ▶ vergleichbar Master-Slave Prinzip bei D-FF aus Latches

Zweiphasentakt (cont.)

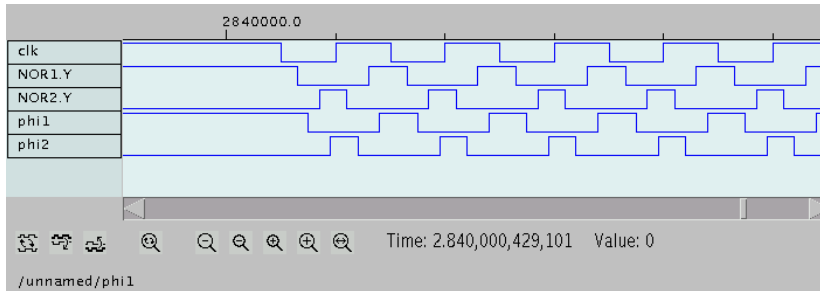

 Φ_1
 Φ_2


- ▶ nicht überlappender Takt mit Phasen Φ_1 und Φ_2
- ▶ vorderes D-Latch übernimmt Eingangswert D während Φ_1
 bei Φ_2 übernimmt das hintere D-Latch und liefert Q

Zweiphasentakt: Erzeugung



Zweiphasentakt: Erzeugung (cont.)



- ▶ Verzögerungen geeignet wählen
 - ▶ Eins-Phasen der beiden Takte c_1 und c_2 sauber getrennt
- ⇒ nicht-überlappende 2-Phasen-Taktimpulse zur Ansteuerung von Schaltungen mit 2-Phasen-Taktung



Beschreibung von Schaltwerken

- ▶ viele verschiedene Möglichkeiten
- ▶ graphisch oder textuell

- ▶ algebraische Formeln/Gleichungen
- ▶ Flusstafel und Ausgangstafel

- ▶ Zustandsdiagramm
- ▶ State-Charts (hierarchische Zustandsdiagramme)

- ▶ Programme (Hardwarebeschreibungssprachen)



Flusstafel und Ausgangstafel

- ▶ entspricht der Funktionstabelle von Schaltnetzen

- ▶ **Flusstafel:** Tabelle für die Folgezustände als Funktion des aktuellen Zustands und der Eingabewerte
 = beschreibt das δ -Schaltnetz

- ▶ **Ausgangstafel:** Tabelle für die Ausgabewerte als Funktion des aktuellen Zustands (und der Eingabewerte [Mealy-Modell])
 = beschreibt das λ -Schaltnetz



Beispiel: Ampel

- ▶ vier Zustände: {rot, rot-gelb, grün, gelb}
- ▶ Codierung beispielsweise als 2-bit Vektor (z_1, z_0)
- ▶ Flusstafel

Zustand	Codierung		Folgezustand	
	z_1	z_0	z_1^+	z_0^+
rot	0	0	0	1
rot-gelb	0	1	1	0
grün	1	0	1	1
gelb	1	1	0	0

Beispiel: Ampel (cont.)

▶ Ausgangstafel

Zustand	Codierung		Ausgänge		
	z_1	z_0	rt	ge	gr
rot	0	0	1	0	0
rot-gelb	0	1	1	1	0
grün	1	0	0	0	1
gelb	1	1	0	1	0

- ▶ Funktionstabelle für drei Schaltfunktionen
- ▶ Minimierung z.B. mit KV-Diagrammen



Zustandsdiagramm


- ▶ **Zustandsdiagramm:** Grafische Darstellung eines Schaltwerks
- ▶ je ein Knoten für jeden Zustand
- ▶ je eine Kante für jeden möglichen Übergang

- ▶ Knoten werden passend benannt
- ▶ Kanten werden mit den Eingabemustern gekennzeichnet, bei denen der betreffende Übergang auftritt

- ▶ Moore-Schaltwerke: Ausgabe wird zusammen mit dem Namen im Knoten notiert
- ▶ Mealy-Schaltwerke: Ausgabe hängt vom Input ab und wird an den Kanten notiert

siehe auch en.wikipedia.org/wiki/State_diagram

Zustandsdiagramm: Moore-Automat



Zustand




Übergang



- ▶ Ausgangswerte hängen nur vom Zustand ab
- ▶ können also im jeweiligen Knoten notiert werden
- ▶ Übergänge werden als Pfeile mit der Eingangsbelegung notiert, die den Übergang aktiviert
- ▶ ggf. Startzustand markieren (z.B. Segment, doppelter Kreis)

Zustandsdiagramm: Mealy-Automat



Zustand



Übergang

Bedingung / Ausgangswerte

- ▶ Ausgangswerte hängen nicht nur vom Zustand sondern auch von den Eingabewerten ab
- ▶ Ausgangswerte an den zugehörigen Kanten notieren
- ▶ übliche Notation: *Eingangsbelegung / Ausgangswerte*



„State-Charts“

- ▶ hierarchische Version von Zustandsdiagrammen
- ▶ Knoten repräsentieren entweder einen Zustand
- ▶ oder einen eigenen (Unter-) Automaten

- ▶ beliebte Spezifikation für komplexe Automaten, Embedded Systems, Kommunikationssysteme, etc.

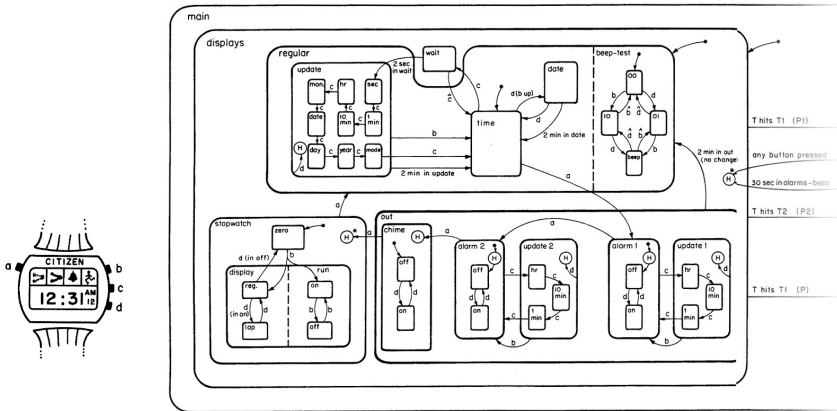
- ▶ David Harel, *Statecharts – A visual formalism for complex systems*, CS84-05, Department of Applied Mathematics, The Weizmann Institute of Science, 1984

www.wisdom.weizmann.ac.il/~dharel/SCANNED.PAPERS/Statecharts.pdf

„State-Charts“ (cont.)

► Beispiel Digitaluhr

Citizen quartz multi-alarm



Hardwarebeschreibungssprachen

- ▶ Beschreibung eines Schaltwerks als Programm:
 - ▶ normale Hochsprachen C, Java
 - ▶ spezielle Bibliotheken für normale Sprachen SystemC, Hades
 - ▶ spezielle Hardwarebeschreibungssprachen Verilog, VHDL
- ▶ Hardwarebeschreibungssprachen unterstützen Modellierung paralleler Abläufe und des Zeitverhaltens einer Schaltung
- ▶ wird hier nicht vertieft
- ▶ lediglich zwei Beispiele: D-Flipflop in Verilog und VHDL



D-Flipflop in Verilog

```

module dff (clock, reset, din, dout);
input clock, reset, din;
output dout;

reg dout;

always @(posedge clock or reset)
begin
  if (reset)
    dout = 1'b0;
  else
    dout = din;
  end
endmodule
  
```

- ▶ Deklaration eines Moduls mit seinen Ein- und Ausgängen
- ▶ Deklaration der speichernden Elemente („reg“)
- ▶ Aktivierung des Codes bei Signalwechseln („posedge clock“)

D-Flipflop in VHDL

Very High Speed Integrated Circuit Hardware Description Language

```

library ieee;
use ieee.std_logic_1164.all;

entity DFF is
port (  CLOCK      : in  std_logic;
         RESET      : in  std_logic;
         DIN        : in  std_logic;
         DOUT       : out std_logic);
end entity DFF;

architecture BEHAV of DFF is
begin
    DFF_P: process (RESET, CLOCK) is
    begin
        if RESET = '1' then
            DOUT <= '0';
        elsif rising_edge(CLOCK) then
            DOUT <= DIN;
        end if;
    end process DFF_P;
end architecture BEHAV;
    
```



Entwurf von Schaltwerken: sechs Schritte

1. Spezifikation (textuell oder graphisch, z.B. Zustandsdiagramm)
2. Aufstellen einer formalen Übergangstabelle
3. Reduktion der Zahl der Zustände
4. Wahl der Zustandscodierung und Aufstellen der Übergangstabelle
5. Minimierung der Schaltnetze
6. Überprüfung des realisierten Schaltwerks

ggf. mehrere Iterationen



Entwurf von Schaltwerken: Zustandskodierung

Vielfalt möglicher Codierungen

- ▶ binäre Codierung: minimale Anzahl der Zustände
- ▶ einschrittige Codes
- ▶ one-hot Codierung: ein aktives Flipflop pro Zustand
- ▶ applikationsspezifische Zwischenformen

- ▶ es gibt Entwurfsprogramme zur Automatisierung
- ▶ gemeinsame Minimierung des Realisierungsaufwands von Ausgangsfunktion, Übergangsfunktion und Speichergliedern



Entwurf von Schaltwerken: Probleme

Entwurf ausgehend von Funktionstabellen problemlos

- ▶ alle Eingangsbelegungen und Zustände werden berücksichtigt
- ▶ don't-care Terme können berücksichtigt werden

zwei typische Fehler bei Entwurf ausgehend vom Zustandsdiagramm

- ▶ mehrere aktive Übergänge bei bestimmten Eingangsbelegungen
⇒ Widerspruch
- ▶ keine Übergänge bei bestimmten Eingangsbelegungen
⇒ Vollständigkeit



Überprüfung der Vollständigkeit

p Zustände, Zustandsdiagramm mit Kanten $h_{ij}(x)$:
 Übergang von Zustand i nach Zustand j unter Belegung x

- ▶ für jeden Zustand überprüfen:
 kommen alle (spezifizierten) Eingangsbelegungen auch
 tatsächlich in Kanten vor?

$$\forall i : \bigvee_{j=0}^{2^p-1} h_{ij}(x) = 1$$




Überprüfung der Widerspruchsfreiheit

p Zustände, Zustandsdiagramm mit Kanten $h_{ij}(x)$:
 Übergang von Zustand i nach Zustand j unter Belegung x

- ▶ für jeden Zustand überprüfen:
 kommen alle (spezifizierten) Eingangsbelegungen nur einmal vor?

$$\forall i : \bigvee_{j,k=0, j \neq k}^{2^p-1} (h_{ij}(x) \wedge h_{ik}(x)) = 0$$

Vollständigkeit und Widerspruchsfreiheit: Beispiel



- ▶ Zustand A, Vollständigkeit: $x_1 \vee \overline{x_1}x_0 \vee \overline{x_1} = 1$ vollständig
- ▶ Zustand A, Widerspruchsfreiheit: alle Paare testen

$$x_1 \wedge \overline{x_1}x_0 = 0 \quad \text{ok}$$

$$x_1 \wedge \overline{x_1} = 0 \quad \text{ok}$$

$$\overline{x_1}x_0 \wedge \overline{x_1} \neq 0 \quad \text{für } x_1 = 0 \text{ und } x_0 = 1 \text{ beide Übergänge aktiv}$$

Entwurf von Schaltwerken: Beispiele

- ▶ Verkehrsampel
 - ▶ drei Varianten mit unterschiedlicher Zustandscodierung

- ▶ Zählschaltungen
 - ▶ einfacher Zähler, Zähler mit Enable (bzw. Stop),
 - ▶ Vorwärts-Rückwärts-Zähler, Realisierung mit JK-Flipflops und D-Flipflops

- ▶ Digitaluhr
 - ▶ BCD-Zähler

- ▶ ...

Entwurf von Schaltwerken: Ampel

Beispiel Verkehrsampel:

- ▶ drei Ausgänge: {rot, gelb, grün}
- ▶ vier Zustände: {rot, rot-gelb, grün, gelb}
- ▶ zunächst kein Eingang, feste Zustandsfolge wie oben

- ▶ Aufstellen des Zustandsdiagramms
- ▶ Wahl der Zustandskodierung
- ▶ Aufstellen der Tafeln für δ - und λ -Schaltnetz
- ▶ anschließend Minimierung der Schaltnetze
- ▶ Realisierung (je 1 D-Flipflop pro Zustandsbit) und Test

Entwurf von Schaltwerken: Ampel – Variante 1

- ▶ vier Zustände, Codierung als 2-bit Vektor (z_1, z_0)
- ▶ Fluss- und Ausgangstafel für binäre Zustandskodierung

Zustand	Codierung		Folgezustand		Ausgänge		
	z_1	z_0	z_1^+	z_0^+	rt	ge	gr
rot	0	0	0	1	1	0	0
rot-gelb	0	1	1	0	1	1	0
grün	1	0	1	1	0	0	1
gelb	1	1	0	0	0	1	0

- ▶ resultierende Schaltnetze

$$z_1^+ = (z_1 \wedge \overline{z_0}) \vee (\overline{z_1} \wedge z_0) = z_1 \oplus z_0$$


$$z_0^+ = \overline{z_0}$$

$$rt = \overline{z_1}$$

$$ge = z_0$$

$$gr = (z_1 \wedge \overline{z_0})$$

Entwurf von Schaltwerken: Ampel – Variante 1 (cont.)



Hades Webdemos: 18-fsm/10-trafficLight/ampel_41

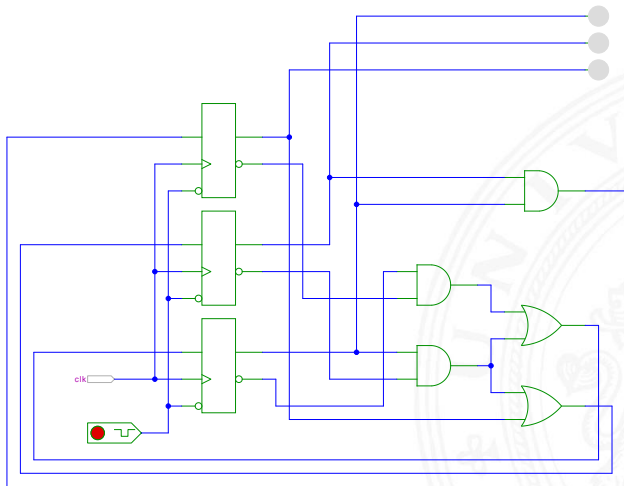
Entwurf von Schaltwerken: Ampel – Variante 2

- ▶ vier Zustände, Codierung als 3-bit Vektor (z_2, z_1, z_0)
- ▶ Zustandsbits korrespondieren mit den aktiven Lampen:
 $z_2^+ = gr$, $z_1^+ = ge$ und $z_0^+ = rt$

Zustand	Codierung			Folgezustand		
	z_2	z_1	z_0	z_2^+	z_1^+	z_0^+
reset	0	0	0	0	0	1
rot	0	0	1	0	1	1
rot-gelb	0	1	1	1	0	0
grün	1	0	0	0	1	0
gelb	0	1	0	0	0	1

- ▶ benutzt 1-bit zusätzlich für die Zustände
- ▶ dafür wird die Ausgangsfunktion λ minimal (leer)

Entwurf von Schaltwerken: Ampel – Variante 2 (cont.)



Hades Webdemos:
18-fsm/10-trafficLight/ampel_42


Entwurf von Schaltwerken: Ampel – Variante 3

- ▶ vier Zustände, Codierung als 4-bit *one-hot* Vektor (z_3, z_2, z_1, z_0)
- ▶ Beispiel für die Zustandskodierung

Zustand	Codierung				Folgezustand			
	z_3	z_2	z_1	z_0	z_3^+	z_2^+	z_1^+	z_0^+
rot	0	0	0	1	0	0	1	0
rot-gelb	0	0	1	0	0	1	0	0
grün	0	1	0	0	1	0	0	0
gelb	1	0	0	0	0	0	0	1

- ▶ 4-bit statt minimal 2-bit für die Zustände
- ▶ Übergangsfunktion δ minimal (Automat sehr schnell)
- ▶ Ausgangsfunktion λ sehr einfach

Entwurf von Schaltwerken: Ampel – Variante 3 (cont.)



Hades Webdemos: 18-fsm/10-trafficLight/ampel_44




Entwurf von Schaltwerken: Ampel – Zusammenfassung

- ▶ viele Möglichkeiten der Zustandscodierung
- ▶ Dualcode: minimale Anzahl der Zustände
- ▶ applikations-spezifische Codierungen
- ▶ One-Hot Encoding: viele Zustände, einfache Schaltnetze
- ▶ ...
- ▶ Kosten/Performance des Schaltwerks abhängig von Codierung
- ▶ Heuristiken zur Suche nach (relativem) Optimum

Zählschaltungen


- ▶ diverse Beispiele für Zählschaltungen
- ▶ Zustandsdiagramme und Flusstafeln
- ▶ Schaltbilder
- ▶ n -bit Vorwärtszähler
- ▶ n -bit Zähler mit Stop und/oder Reset
- ▶ Vorwärts/Rückwärtszähler
- ▶ synchrone und asynchrone Zähler
- ▶ Beispiel: Digitaluhr (BCD-Zähler)

2-bit Zähler: Zustandsdiagramm




- ▶ Zähler als „trivialer“ endlicher Automat

2-bit Zähler mit Enable: Zustandsdiagramm und Flusstafel




Zustand	e	\bar{e}
00	01	00
01	10	01
10	11	10
11	00	11

3-bit Zähler mit Enable, Vor-/Rückwärts



Zustand	$e v$	$e \bar{v}$	\bar{e}^*
000	001	111	000
001	010	000	001
010	011	001	010
011	100	010	011
100	101	011	100
101	110	100	101
110	111	101	110
111	000	110	111

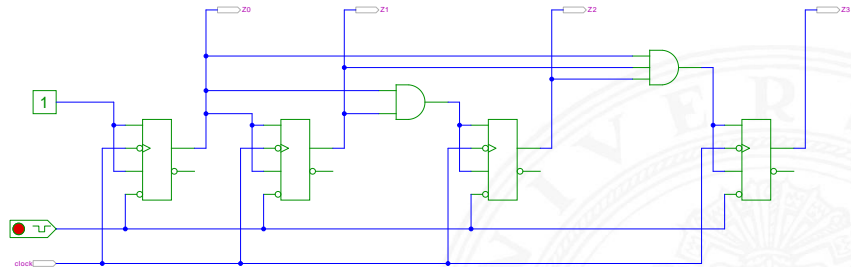
5-bit Zähler mit Reset: Zustandsdiagramm und Flusstafel



Zustand	Index der Eingabe			
	1	2	3	4
A	A	B	AF	A
B	B	C	A	A
C	C	D	B	A
D	D	E	C	A
E	E	F	D	A
F	F	G	E	A
G	G	H	F	A
H	H	I	G	A
I	I	J	H	A
J	J	K	I	A
K	K	L	J	A
L	L	M	K	A
M	M	N	L	A
N	N	O	M	A
O	O	P	N	A
P	P	Q	O	A
Q	Q	R	P	A
R	R	S	Q	A
S	S	T	R	A
T	T	U	S	A
U	U	V	T	A
V	V	W	U	A
W	W	X	V	A
X	X	Y	W	A
Y	Y	Z	X	A
Z	Z	AA	Y	A
AA	AA	AB	Z	A
AB	AB	AC	AA	A
AC	AC	AD	AB	A
AD	AD	AE	AC	A
AE	AE	AF	AD	A
AF	AF	A	AE	A

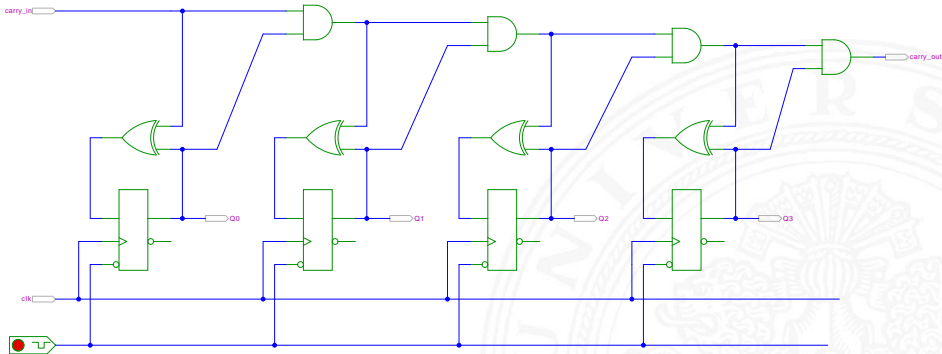
Eingabe 1: stop, 2: zählen, 3: rückwärts zählen, 4: Reset nach A

4-bit Binärzähler mit JK-Flipflops




- ▶ $J_0 = K_0 = 1$: Ausgang z_0 wechselt bei jedem Takt
- ▶ $J_i = K_i = (z_0 z_1 \dots z_{i-1})$: Ausgang z_i wechselt, wenn alle niedrigeren Stufen 1 sind

4-bit Binärzähler mit D-Flipflops (kaskadierbar)




- ▶ $D_0 = Q_0 \oplus c_{in}$ wechselt bei Takt, wenn c_{in} aktiv ist
- ▶ $D_i = Q_i \oplus (c_{in} Q_0 Q_1 \dots Q_{i-1})$ wechselt, wenn alle niedrigeren Stufen und Carry-in c_{in} 1 sind

Asynchroner n -bit Zähler/Teiler mit D-Flipflops



- ▶ $D_i = \bar{Q}_i$: jedes Flipflop wechselt bei seinem Taktimpuls
- ▶ Takteingang C_0 treibt nur das vorderste Flipflop
- ▶ $C_i = Q_{i-1}$: Ausgang der Vorgängerstufe als Takt von Stufe i
- ▶ erstes Flipflop wechselt bei jedem Takt \Rightarrow Zählrate $C_0/2$
- ▶ zweites Flipflop bei jedem zweiten Takt \Rightarrow Zählrate $C_0/4$
- ▶ n -tes Flipflop bei jedem n -ten Takt \Rightarrow Zählrate $C_0/2^n$
- ▶ sehr hohe maximale Taktrate
- **Achtung**: Flipflops schalten nacheinander, nicht gleichzeitig


Asynchrone 4-bit Vorwärts- und Rückwärtszähler



4-bit 1:2, 1:6, 1:12-Teiler mit JK-Flipflops: IC 7492

- ▶ vier JK-Flipflops
- ▶ zwei Reseteingänge
- ▶ zwei Takteingänge

- ▶ Stufe 0 separat (1:2)
- ▶ Stufen 1...3 kaskadiert (1:6)
- ▶ Zustandsfolge
 $\{000, 001, 010, 100, 101, 110\}$




4-bit Vorwärts-Rückwärtszähler mit JK-Flipflops

- ▶ Eingänge: nClk
 Enable
 Up/nDown

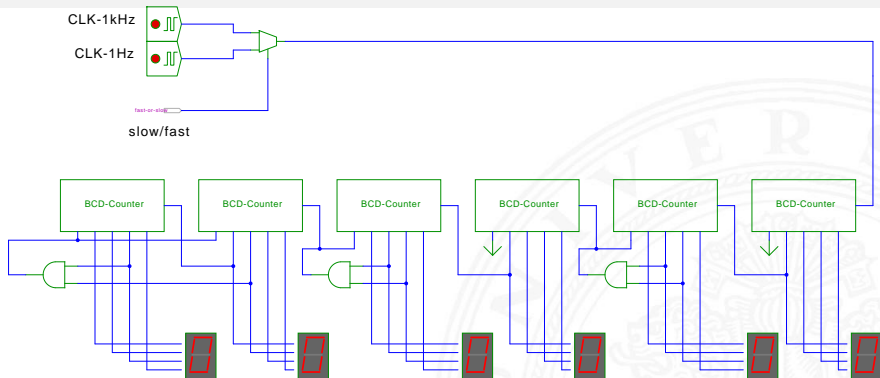
- ▶ Umschaltung der *Carry-Chain*

$$\text{up: } J_i = K_i = (E Q_0 Q_1 \dots Q_{i-1})$$

$$\text{down: } J_i = K_i = (E \overline{Q_0} \overline{Q_1} \dots \overline{Q_{i-1}})$$



Digitaluhr mit BCD-Zählern



- ▶ Stunden Minuten Sekunden (hh:mm:ss)
- ▶ async. BCD-Zähler mit Takt (rechts) und Reset (links unten)
- ▶ Übertrag 1er- auf 10er-Stelle jeweils beim Übergang 9 → 0
- ▶ Übertrag und Reset der Zehner beim Auftreten des Wertes 6



Funkgesteuerte DCF 77 Uhr

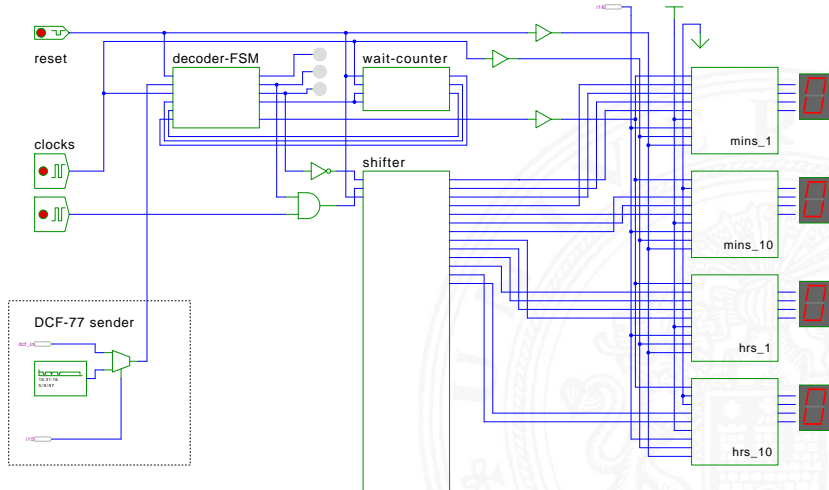
- ▶ Beispiel für eine komplexe Schaltung aus mehreren einfachen Komponenten
- ▶ mehrere gekoppelte Automaten, bzw. Zähler
- ▶ DCF 77 Zeitsignal
 - ▶ Langwelle 77,5 KHz
 - ▶ Sender nahe Frankfurt
 - ▶ ganz Deutschland abgedeckt
- ▶ pro Sekunde wird ein Bit übertragen
 - ▶ Puls mit abgesenktem Signalpegel: „Amplitudenmodulation“
 - ▶ Pulslänge: 100 ms entspricht Null, 200 ms entspricht Eins
 - ▶ Pulsbeginn ist Sekundenbeginn



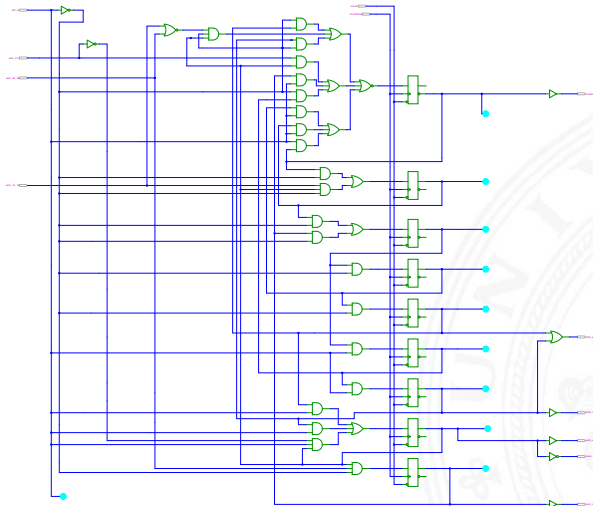
Funkgesteuerte DCF 77 Uhr (cont.)

- ▶ pro Minute werden 59 Bits übertragen
 - ▶ Uhrzeit hh:mm (implizit Sekunden), MEZ/MESZ
 - ▶ Datum dd:mm:yy, Wochentag
 - ▶ Parität
 - ▶ fehlender 60ster Puls markiert Ende einer Minute
- ▶ Decodierung der Bits nach DCF 77 Protokoll mit entsprechend entworfenem Schaltwerk
- ▶ Beschreibung z.B.: de.wikipedia.org/wiki/DCF77

Funkgesteuerte DCF 77 Uhr: Gesamtsystem



Funkgesteuerte DCF 77 Uhr: Decoder-Schaltwerk



Hades Webdemos:
45-misc/80-dcf77/DecoderFSM



Multiplex-Siebensegment-Anzeige

Ansteuerung mehrstelliger Siebensegment-Anzeigen?

- ▶ direkte Ansteuerung erfordert $7 \cdot n$ Leitungen für n Ziffern
- ▶ und je einen Siebensegment-Decoder pro Ziffer

Zeit-Multiplex-Verfahren benötigt nur $7 + n$ Leitungen

- ▶ die Anzeigen werden nacheinander nur ganz kurz eingeschaltet
- ▶ ein gemeinsamer Siebensegment-Decoder
Eingabe wird entsprechend der aktiven Ziffer umgeschaltet
- ▶ das Auge sieht die leuchtenden Segmente und „mittelt“
- ▶ ab ca. 100 Hz Frequenz erscheint die Anzeige ruhig




Multiplex-Siebensegment-Anzeige (cont.)

Hades-Beispiel: Kombination mehrerer bekannter einzelner Schaltungen zu einem komplexen Gesamtsystem

- ▶ vierstellige Anzeige
- ▶ darzustellende Werte sind im RAM (74219) gespeichert
- ▶ Zähler-IC (74590) erzeugt 2-bit Folge {00, 01, 10, 11}
- ▶ 3:8-Decoder-IC (74138) erzeugt daraus die Folge {1110, 1101, 1011, 0111} um nacheinander je eine Anzeige zu aktivieren (low-active)
- ▶ Siebensegment-Decoder-IC (7449) treibt die sieben Segmentleitungen

Multiplex-Siebensegment-Anzeige (cont.)



Hades Webdemos: 45-misc/50-displays/multiplexed-display



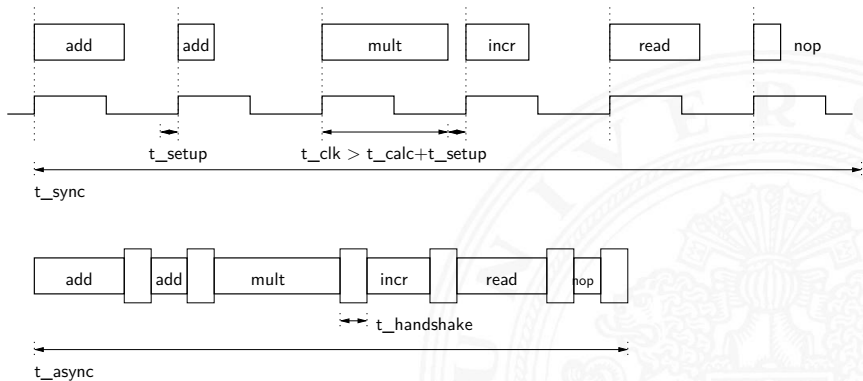
Ausblick: Asynchrone Schaltungen

- ▶ Kosten und Verzögerung pro Gatter fallen
- ▶ zentraler Takt zunehmend problematisch: Performance, Energieverbrauch, usw.
- ▶ alle Rechenwerke warten auf langsamste Komponente

Umstieg auf nicht-getaktete Schaltwerke?!

- ▶ *Handshake*-Protokolle zwischen Teilschaltungen
 - ▶ Berechnung startet, sobald benötigte Operanden verfügbar
 - ▶ Rechenwerke signalisieren, dass Ergebnisse bereitstehen
- + kein zentraler Takt notwendig \Rightarrow so schnell wie möglich
- Probleme mit Deadlocks und Initialisierung


Asynchrone Schaltungen: Performance




- ▶ synchron: Pipelining/Path-Balancing können Verschnitt verringern
- ▶ asynchron: Operationen langsamer wegen „completion detection“

Zwei-Phasen und Vier-Phasen Handshake


bundled data



dual rail




four-phase




"level"

two-phase



"edge"

four-phase





	d+	d-
empty	0	0
valid "0"	0	1
valid "1"	1	0
unused	1	1


Muller C-Gate

- ▶ asynchrones Schaltwerk
- ▶ alle Eingänge 0: Ausgang wird 0
 –"– 1: –"– 1
- ▶ wird oft in asynchronen Schaltungen benutzt

	ab			
c	00	01	11	10
0	0	0	1	0
1	0	1	1	1



Muller C-Gate: 3-Eingänge







Asynchrone Schaltungen: Micropipeline

- ▶ einfaches Modell einer generischen nicht-getakteten Schaltung
- ▶ Beispiel zum Entwurf und zur Kaskadierung
- ▶ Muller C-Gate als Speicherglieder
- ▶ beliebige Anzahl Stufen

- ▶ neue Datenwerte von links in die Pipeline einfüllen
- ▶ Werte laufen soweit nach rechts wie möglich
- ▶ solange bis Pipeline gefüllt ist

- ▶ Datenwerte werden nach rechts entnommen
- ▶ Pipeline signalisiert automatisch, ob Daten eingefüllt oder entnommen werden können


Micropipeline: Konzept



n -stufige Micropipeline vs. getaktetes Schieberegister

- ▶ lokales Handshake statt globalem Taktsignal
- ▶ Datenkapazität entspricht $2n$ -stufigem Schieberegister
- ▶ leere Latches transparent: schnelles Einfüllen
- ▶ „elastisch“: enthält $0 \dots 2n$ Datenworte

Micropipeline: Demo mit C-Gates



Hades Webdemos: 16-flipflops/80-micropipeline



Literatur: Vertiefung

- ▶ David Harel,
Statecharts, A visual formalism for complex systems,
CS84-05, Department of Applied Mathematics,
The Weizmann Institute of Science, 1984
www.wisdom.weizmann.ac.il/~dharel/SCANNED.PAPERS/Statecharts.pdf
- ▶ Neil H. E. Weste, Kamran Eshragian,
Principles of CMOS VLSI Design — A Systems Perspective,
Addison-Wesley Publishing, 1994



Interaktives Lehrmaterial

- ▶ Klaus von der Heide,
Vorlesung: Technische Informatik 1 — interaktives Skript,
Universität Hamburg, FB Informatik, 2005
tams.informatik.uni-hamburg.de/lectures/2004ws/vorlesung/t1

- ▶ Norman Hendrich,
HADES — HAmburg DEsign System,
Universität Hamburg, FB Informatik
tams.informatik.uni-hamburg.de/applets/hades



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

14. Schaltwerke

15. Grundkomponenten für Rechensysteme

Motivation

Speicherbausteine

Busse

Beispielsystem: ARM

Mikroprogrammierung

Literatur

16. VLSI-Entwurf und -Technologie

17. Rechnerarchitektur

18. Instruction Set Architecture

19. Assembler-Programmierung

20. Computerarchitektur

Gliederung (cont.)

21. Speicherhierarchie





Aufbau kompletter Rechensysteme

- ▶ bisher:
 - ▶ Gatter und Schaltnetze
 - ▶ Flipflops als einzelne Speicherglieder
 - ▶ Schaltwerke zur Ablaufsteuerung

- ▶ jetzt zusätzlich:
 - ▶ Speicher
 - ▶ Busse
 - ▶ Register-Transfer Komponenten eines Rechners
 - ▶ Ablaufsteuerung (Timing, Mikroprogrammierung)



Wiederholung: von-Neumann-Konzept

- ▶ J. Mauchly, J.P. Eckert, J. von-Neumann 1945
- ▶ System mit Prozessor, Speicher, Peripheriegeräten
- ▶ gemeinsamer Speicher für Programme und Daten
- ▶ Programme können wie Daten manipuliert werden
- ▶ Daten können als Programm ausgeführt werden
- ▶ Befehlszyklus: Befehl holen, decodieren, ausführen
- ▶ enorm flexibel
- ▶ **alle** aktuellen Rechner basieren auf diesem Prinzip
- ▶ aber vielfältige Architekturvarianten, Befehlssätze, usw.

Wiederholung: von-Neumann Rechner




Figure 1-5. The original von Neumann machine.

Fünf zentrale Komponenten:

- ▶ Prozessor mit **Steuerwerk** und **Rechenwerk** (ALU, Register)
- ▶ **Speicher**, gemeinsam genutzt für Programme und Daten
- ▶ **Eingabe-** und **Ausgabewerke**



Wiederholung: von-Neumann Rechner (cont.)

- ▶ Steuerwerk: zwei zentrale Register
 - ▶ Befehlszähler (*program counter PC*)
 - ▶ Befehlsregister (*instruction register IR*)
- ▶ Operationswerk (Datenpfad, *data-path*)
 - ▶ Rechenwerk (*arithmetic-logic unit ALU*)
 - ▶ Universalregister (mindestens 1 *Akkumulator*, typisch 8..64 Register)
 - ▶ evtl. Register mit Spezialaufgaben
- ▶ Speicher (*memory*)
 - ▶ Hauptspeicher/RAM: *random-access memory*
 - ▶ Hauptspeicher/ROM: *read-only memory* zum Booten
 - ▶ Externspeicher: Festplatten, CD/DVD, Magnetbänder
- ▶ Peripheriegeräte (Eingabe/Ausgabe, *I/O*)

Systemmodellierung

Modellierung eines digitalen Systems als Schaltung aus

▶ Speichergliedern

- ▶ Registern
- ▶ Speichern

Flipflops, Register, Registerbank
SRAM, DRAM, ROM, PLA

▶ Rechenwerken

- ▶ Addierer, arithmetische Schaltungen
- ▶ logische Operationen
- ▶ „random-logic“ Schaltnetzen

▶ Verbindungsleitungen

- ▶ Busse / Leitungsbündel
- ▶ Multiplexer und Tri-state Treiber



Speicher

- ▶ System zur Speicherung von Information
- ▶ als Feld von N Adressen mit je m bit
- ▶ typischerweise mit n -bit Adressen und $N = 2^n$
- ▶ Kapazität also $2^n \times m$ bits

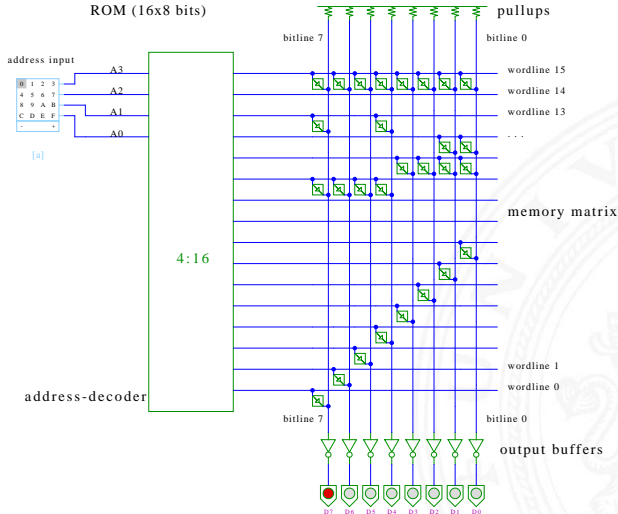
- ▶ Klassifikation:
 - ▶ Speicherkapazität
 - ▶ Schreibzugriffe möglich?
 - ▶ Schreibzugriffe auf einzelne bits/Bytes oder nur Blöcke?
 - ▶ Information flüchtig oder dauerhaft gespeichert?
 - ▶ Zugriffszeiten beim Lesen und Schreiben
 - ▶ Technologie



Speicherbausteine: Varianten

Type	Category	Erasure	Byte alterable	Volatile	Typical use
SRAM	Read/write	Electrical	Yes	Yes	Level 2 cache
DRAM	Read/write	Electrical	Yes	Yes	Main memory
ROM	Read-only	Not possible	No	No	Large volume appliances
PROM	Read-only	Not possible	No	No	Small volume equipment
EPROM	Read-mostly	UV light	No	No	Device prototyping
EEPROM	Read-mostly	Electrical	Yes	No	Device prototyping
Flash	Read/write	Electrical	No	No	Film for digital camera

ROM: Read-Only Memory





RAM: Random-Access Memory


Speicher, der im Betrieb gelesen und geschrieben werden kann

- ▶ Arbeitsspeicher des Rechners
- ▶ für Programme und Daten
- ▶ keine Abnutzungseffekte

- ▶ Aufbau als Matrixstruktur
- ▶ n Adressbits, konzeptionell 2^n Wortleitungen
- ▶ m Bits pro Wort
- ▶ Realisierung der einzelnen Speicherstellen?
 - ▶ statisches RAM: 6-Transistor Zelle
 - ▶ dynamisches RAM: 1-Transistor Zelle

SRAM
DRAM

RAM: RAS/CAS-Adressdecodierung



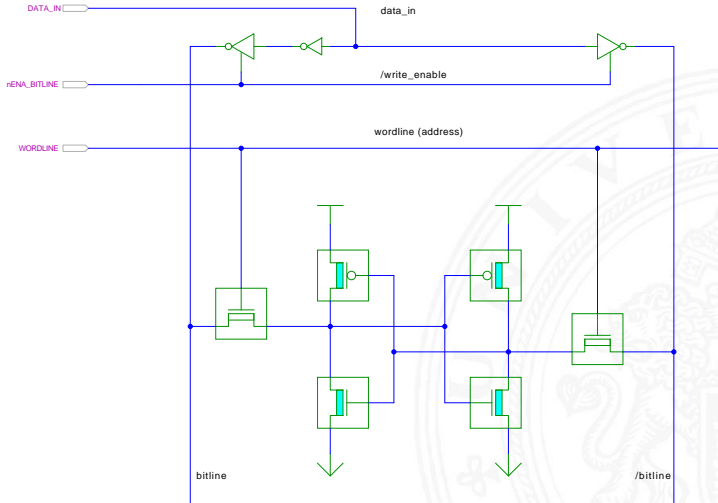
- ▶ Aufteilen der Adresse in zwei Hälften
- ▶ \overline{ras} „row address strobe“ wählt „Wordline“
- ▶ \overline{cas} „column address strobe“ – „Bitline“
- ▶ je ein $2^{(n/2)}$ -bit Decoder/Mux statt ein 2^n -bit Decoder



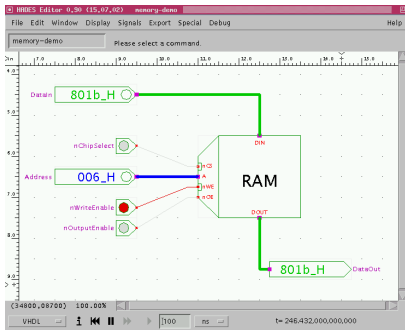
SRAM: statisches RAM

- ▶ Inhalt bleibt dauerhaft gespeichert solange Betriebsspannung anliegt
- ▶ *sechs-Transistor* Zelle zur Speicherung
 - ▶ weniger Platzverbrauch als Latches/Flipflops
 - ▶ kompakte Realisierung in CMOS-Technologie (s.u.)
 - ▶ zwei rückgekoppelte Inverter zur Speicherung
 - ▶ zwei n-Kanal Transistoren zur Anbindung an die Bitlines
- ▶ schneller Zugriff: Einsatz für Caches
- ▶ deutlich höherer Platzbedarf als DRAMs

SRAM: Sechs-Transistor Speicherstelle („6T“)



SRAM: Hades Demo



- nur aktiv wenn $nCS=0$ (chip select)
- Schreiben wenn $nWE=0$ (write enable)
- Ausgabe wenn $nOE=0$ (output enable)

```

Edit_RAM_1Kx16_hades_model rtlLib_memory_RAM00
File Edit Help
000 XXXX XXXX XXXX XXXX XXXX XXXX 801b XXXX
008 XXXX XXXX XXXX XXXX XXXX XXXX XX XXXX
010 XXXX XXXX XXXX XXXX XXXX XXXX XX XXXX
018 XXXX XXXX XXXX XXXX XXXX XXXX XX XXXX
...
098 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0a0 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0a8 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0b0 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0b8 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0c0 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0c8 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0d0 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0d8 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0e0 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0e8 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0f0 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
0f8 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
100 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
108 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
110 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
118 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
120 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
128 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
130 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
138 XXXX XXXX XXXX XXXX XXXX XXXX XXXX XXXX
    
```

Datenwort 0x801B
 in Adresse 0x006
 andere Speicherworte
 noch ungültig

tams.informatik.uni-hamburg.de/applets/hades/webdemos/50-rtlLib/40-memory/ram.html

SRAM: Beispiel IC 6116

- ▶ integrierte Schaltung, 16 Kbit Kapazität
- ▶ Organisation als 2K Worte mit je 8-bit
- ▶ 11 Adresseingänge (A10 .. A0)
- ▶ 8 Anschlüsse für gemeinsamen Daten-Eingang/-Ausgang
- ▶ 3 Steuersignale
 - ▶ \overline{CS} chip-select: Speicher nur aktiv wenn $\overline{CS} = 0$
 - ▶ \overline{WE} write-enable: Daten an gewählte Adresse schreiben
 - ▶ \overline{OE} output-enable: Inhalt des Speichers ausgeben
- ▶ interaktive Hades-Demo zum Ausprobieren

tams.informatik.uni-hamburg.de/applets/hades/webdemos/40-memories/40-ram




DRAM: dynamisches RAM

- ▶ Information wird in winzigen Kondensatoren gespeichert
- ▶ pro Bit je ein Transistor und Kondensator

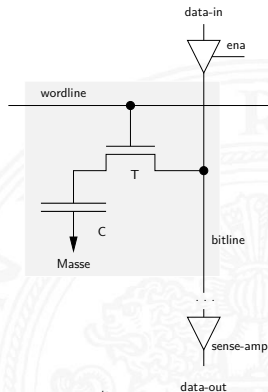
- ▶ jeder Lesezugriff entlädt den Kondensator
- ▶ *Leseverstärker* zur Messung der Spannung auf der Bitline
Schwellwertvergleich zur Entscheidung logisch 0/1

- Information muss anschließend neu geschrieben werden
- auch ohne Lese- oder Schreibzugriff ist regelmäßiger *Refresh* notwendig, wegen Selbstentladung (Millisekunden)
- 10× langsamer als SRAM
- + DRAM für hohe Kapazität optimiert, minimaler Platzbedarf

DRAM vs. SRAM



- 6 Transistoren/bit
- statisch (kein refresh)
- schnell
- 10 .. 50X DRAM-Fläche



- 1 Transistor/bit
- $C=10\text{fF}$: ~ 200.000 Elektronen
- langsam (sense-amp)
- minimale Fläche

DRAM: Stacked- und Trench-Zelle


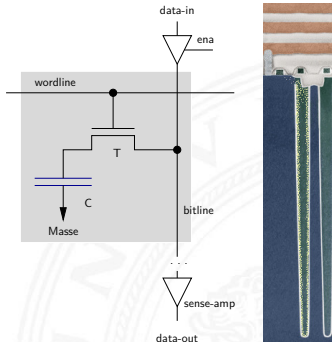


Abb. 7: Prototyp von Speicherzellen (Stapelkondensatoren) für zukünftige Speicherchips wie den Ein-Gigabit-Chip. Da für DRAM-Chips eine minimale Speicherkapazität von 25 fF notwendig ist, bringt es erhebliche Platzvorteile, die Kondensatorelemente vertikal übereinander zu stapeln. Die Dicke der Schichten beträgt etwa 50 nm. (Foto: Siemens)

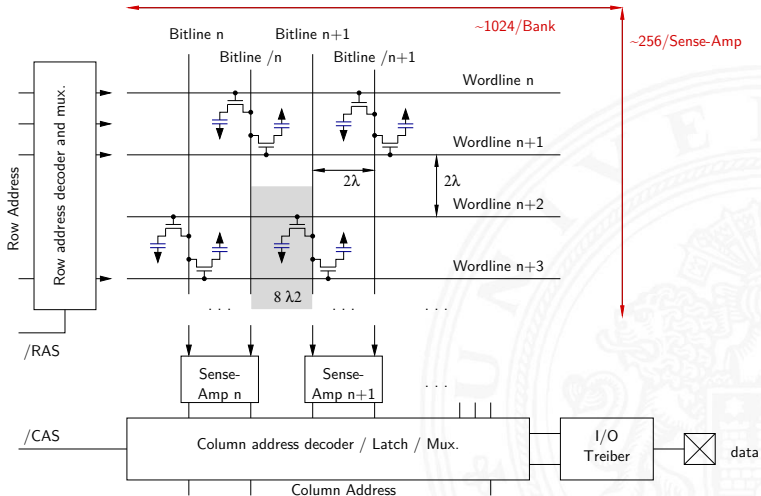


Siemens 1 Gbit DRAM

- ▶ zwei Bauformen: „stacked“ und „trench“
- ▶ Kondensatoren: möglichst kleine Fläche, Kapazität gerade ausreichend

IBM CMOS-6X embedded DRAM

DRAM: Layout



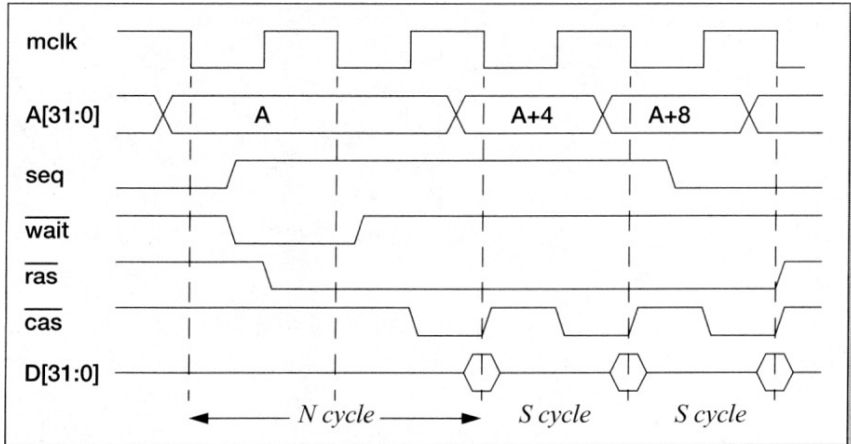
DRAM: Varianten

- ▶ veraltete Varianten
 - ▶ FPM: *fast-page mode*
 - ▶ EDO: *extended data-out*
 - ▶ ...

- ▶ heute gebräuchlich:
 - ▶ SDRAM: Ansteuerung synchron zu Taktsignal
 - ▶ DDR-SDRAM: *double-data rate* Ansteuerung wie SDRAM
 Daten werden mit steigender und fallender Taktflanke übertragen
 - ▶ DDR-2, DDR-3: Varianten mit höherer Taktrate
 aktuell Übertragungsraten bis 17 GByte/sec



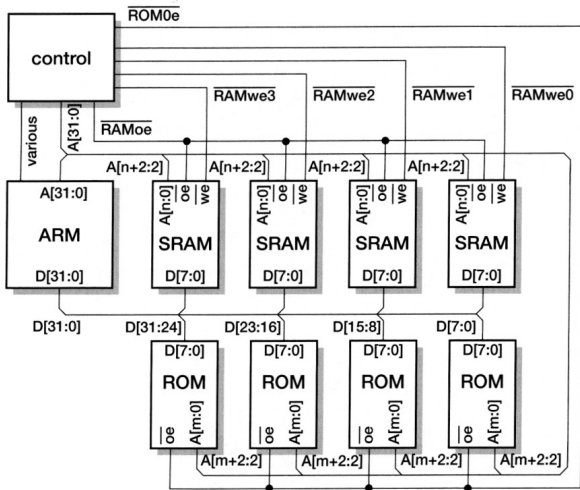
SDRAM: Lesezugriff auf sequenzielle Adressen



Flash

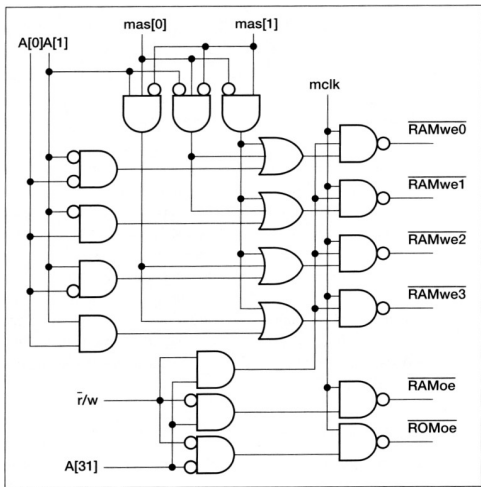
- ▶ ähnlich kompakt und kostengünstig wie DRAM
- ▶ nichtflüchtig (*non-volatile*): Information bleibt beim Ausschalten erhalten
- ▶ spezielle *floating-gate* Transistoren
 - ▶ das *floating-gate* ist komplett nach außen isoliert
 - ▶ einmal gespeicherte Elektronen sitzen dort fest
- ▶ Auslesen beliebig oft möglich, schnell
- ▶ Schreibzugriffe problematisch
 - ▶ intern hohe Spannung erforderlich (Gate-Isolierung überwinden)
 - ▶ Schreibzugriffe einer „0“ nur blockweise
 - ▶ pro Zelle nur einige 10 000... 100 000 Schreibzugriffe möglich

Typisches Speichersystem



32-bit Prozessor
 4 × 8-bit SRAMs
 4 × 8-bit ROMs

Typisches Speichersystem: Adresdecodierung

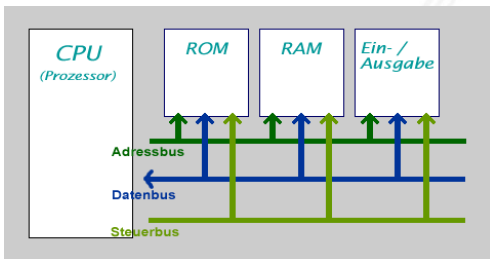


Bussysteme

- ▶ **Bus:** elektrische (und logische) Verbindung
 - ▶ mehrere Geräte
 - ▶ mehrere Blöcke innerhalb einer Schaltung
- ▶ Bündel aus Daten- und Steuersignalen
- ▶ mehrere Quellen (und mehrere Senken [lesende Zugriffe])
 - ▶ spezielle elektrische Realisierung:
Tri-State-Treiber oder Open-Drain
- ▶ Bus-Arbitrierung: wer darf, wann, wie lange senden?
 - ▶ Master-Slave
 - ▶ gleichberechtigte Knoten, Arbitrierungsprotokolle
- ▶ synchron: mit globalem Taktsignal vom „Master“-Knoten
asynchron: Wechsel von Steuersignalen löst Ereignisse aus

Bussysteme (cont.)

- ▶ typische Aufgaben
 - ▶ Kernkomponenten (CPU, Speicher...) miteinander verbinden
 - ▶ Verbindungen zu den Peripherie-Bausteinen
 - ▶ Verbindungen zu Systemmonitor-Komponenten
 - ▶ Verbindungen zwischen I/O-Controllern und -Geräten
 - ▶ ...



Bussysteme (cont.)

- ▶ viele unterschiedliche Typen, standardisiert mit sehr unterschiedlichen Anforderungen
 - ▶ High-Performance
 - ▶ einfaches Protokoll, billige Komponenten
 - ▶ Multi-Master-Fähigkeit, zentrale oder dezentrale Arbitrierung
 - ▶ Echtzeitfähigkeit, Daten-Streaming
 - ▶ wenig Leitungen bis zu Zweidraht-Bussen:
 - ▶ I²C, System-Management-Bus...
 - ▶ lange Leitungen: RS232, Ethernet...
 - ▶ Funkmedium: WLAN, Bluetooth (logische Verbindung)

Bus: Mikroprozessorsysteme

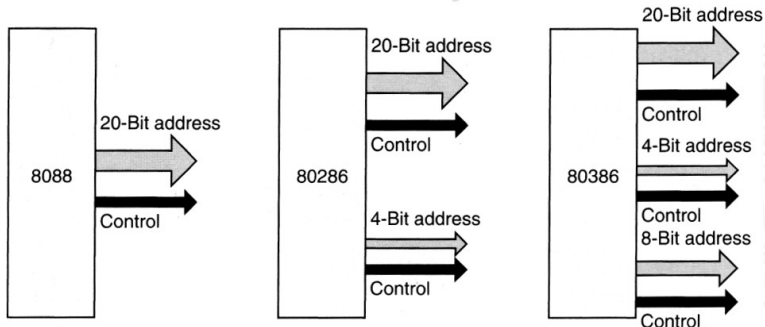
typisches n -bit Mikroprozessor-System:

- ▶ n Adress-Leitungen, also Adressraum 2^n Bytes Adressbus
- ▶ n Daten-Leitungen Datenbus

- ▶ Steuersignale Control
 - ▶ clock: Taktsignal
 - ▶ read/write: Lese-/Schreibzugriff (aus Sicht des Prozessors)
 - ▶ wait: Wartezeit/-zyklen für langsame Geräte
 - ▶ ...


- ▶ um Leitungen zu sparen, teilweise gemeinsam genutzte Leitungen sowohl für Adressen als auch Daten.
 Zusätzliches Steuersignal zur Auswahl Adressen/Daten

Adressbus: Evolution beim Intel x86



- ▶ 20-bit: 1 MiByte Adressraum
- 24-bit: 16 MiByte
- 32-bit: 4 GiByte
- ▶ alle Erweiterungen abwärtskompatibel

Synchroner Bus: Timing




A.S. Tanenbaum, *Structured Computer Organization* 3.4.4

- ▶ alle Zeiten über Taktsignal Φ gesteuert
- ▶ \overline{MREQ} -Signal zur Auswahl Speicher oder I/O-Geräte
- ▶ \overline{RD} signalisiert Lesezugriff
- ▶ Wartezyklen, solange der Speicher \overline{WAIT} aktiviert

Synchroner Bus: typische Zeit-Parameter

Symbol	Parameter	Min	Max	Unit
T_{AD}	Address output delay		4	nsec
T_{ML}	Address stable prior to \overline{MREQ}	2		nsec
T_M	\overline{MREQ} delay from falling edge of Φ in T_1		3	nsec
T_{RL}	RD delay from falling edge of Φ in T_1		3	nsec
T_{DS}	Data setup time prior to falling edge of Φ	2		nsec
T_{MH}	\overline{MREQ} delay from falling edge of Φ in T_3		3	nsec
T_{RH}	\overline{RD} delay from falling edge of Φ in T_3		3	nsec
T_{DH}	Data hold time from negation of \overline{RD}	0		nsec

Asynchroner Bus: Lesezugriff



- ▶ Steuersignale \overline{MSYN} : Master fertig
 \overline{SSYN} : Slave fertig
- ▶ flexibler für Geräte mit stark unterschiedlichen Zugriffszeiten



Bus Arbitrierung

- ▶ mehrere Komponenten wollen Übertragung initiieren
immer nur ein Transfer zur Zeit möglich
- ▶ der Zugriff muss serialisiert werden

1. zentrale Arbitrierung



- ▶ Arbitrer gewährt Bus-Requests
- ▶ Strategien
 - ▶ Prioritäten für verschiedene Geräte
 - ▶ „round-robin“ Verfahren
 - ▶ „Token“-basierte Verfahren
 - ▶ usw.

Bus Arbitrierung (cont.)

2. dezentrale Arbitrierung

- ▶ protokollbasiert
- ▶ Beispiel
 - ▶ Komponenten sehen ob Bus frei ist
 - ▶ beginnen zu senden
 - ▶ Kollisionserkennung: gesendete Daten lesen
 - ▶ ggf. Übertragung abbrechen
 - ▶ „später“ erneut versuchen
- ▶ I/O-Geräte oft höher priorisiert als die CPU
 - ▶ I/O-Zugriffe müssen schnell/sofort behandelt werden
 - ▶ Benutzerprogramm kann warten

Bus Arbitrierung (cont.)



Bus Bandbreite

- ▶ Menge an (Nutz-) Daten, die pro Zeiteinheit übertragen werden kann
- ▶ zusätzlicher Protokolloverhead \Rightarrow Brutto- / Netto-Datenrate
- ▶

RS232	50	Bit/sec	...	460	KBit/sec
I ² C	100	KBit/sec (Std.)	...	3,4	MBit/sec (High Speed)
USB	1,5	MBit/sec (1.x)	...	5	GBit/sec (3.0)
ISA	128	MBit/sec			
PCI	1	GBit/sec (2.0)	...	4,3	GBit/sec (3.0)
AGP	2,1	GBit/sec (1x)	...	16,6	GBit/sec (8x)
PCIe	250	MByte/sec (1.x)	...	1000	MByte/sec (3.0) x1...32
HyperTransport	12,8	GByte/sec (1.0)	...	51,2	GByte/sec (3.1)

Beispiel: PCI-Bus

Peripheral Component Interconnect (Intel 1991)

- ▶ 33 MHz Takt optional 64 MHz Takt
- ▶ 32-bit Bus-System optional auch 64-bit
- ▶ gemeinsame Adress-/Datenleitungen
- ▶ Arbitrierung durch Bus-Master CPU

- ▶ Auto-Konfiguration
 - ▶ angeschlossene Geräte werden automatisch erkannt
 - ▶ eindeutige Hersteller- und Geräte-Nummern
 - ▶ Betriebssystem kann zugehörigen Treiber laden
 - ▶ automatische Zuweisung von Adressbereichen und IRQs

PCI-Bus: Peripheriegeräte

```

tams12> /sbin/lspci
00:00.0 Host bridge: Intel Corporation 82Q963/Q965 Memory Controller Hub (rev 02)
00:01.0 PCI bridge: Intel Corporation 82Q963/Q965 PCI Express Root Port (rev 02)
00:1a.0 USB Controller: Intel Corporation 82801H (ICH8 Family) USB UHCI #4 (rev 02)
00:1a.1 USB Controller: Intel Corporation 82801H (ICH8 Family) USB UHCI #5 (rev 02)
00:1a.7 USB Controller: Intel Corporation 82801H (ICH8 Family) USB2 EHCI #2 (rev 02)
00:1b.0 Audio device: Intel Corporation 82801H (ICH8 Family) HD Audio Controller (rev 02)
00:1c.0 PCI bridge: Intel Corporation 82801H (ICH8 Family) PCI Express Port 1 (rev 02)
00:1c.4 PCI bridge: Intel Corporation 82801H (ICH8 Family) PCI Express Port 5 (rev 02)
00:1d.0 USB Controller: Intel Corporation 82801H (ICH8 Family) USB UHCI #1 (rev 02)
00:1d.1 USB Controller: Intel Corporation 82801H (ICH8 Family) USB UHCI #2 (rev 02)
00:1d.2 USB Controller: Intel Corporation 82801H (ICH8 Family) USB UHCI #3 (rev 02)
00:1d.7 USB Controller: Intel Corporation 82801H (ICH8 Family) USB2 EHCI #1 (rev 02)
00:1e.0 PCI bridge: Intel Corporation 82801 PCI Bridge (rev f2)
00:1f.0 ISA bridge: Intel Corporation 82801HB/HR (ICH8/R) LPC Interface Controller (rev 02)
00:1f.2 IDE interface: Intel Corporation 82801H (ICH8 Family) 4 port SATA IDE Controller (rev 02)
00:1f.3 SMBus: Intel Corporation 82801H (ICH8 Family) SMBus Controller (rev 02)
00:1f.5 IDE interface: Intel Corporation 82801H (ICH8 Family) 2 port SATA IDE Controller (rev 02)
01:00.0 VGA compatible controller: ATI Technologies Inc Unknown device 7183
01:00.1 Display controller: ATI Technologies Inc Unknown device 71a3
03:00.0 Ethernet controller: Broadcom Corporation NetXtreme BCM5754 Gigabit Ethernet PCI Express (rev 02)
    
```

PCI-Bus: Peripheriegeräte (cont.)


The screenshot shows the 'PCI (Informationen zu PCI)' window in HWINFO32. The left sidebar lists 'Informationsmodule' with 'Geräteinformationen' expanded to 'PCI'. The main area displays a list of PCI devices with columns for 'Information' and 'Wert'. The selected device is 'Intel Corporation Core Processor Integrated Memory Controller Channel 1 Thermal Control Registers' with ID '3F05.3'.

Information	Wert
> 3F05.3	Intel Corporation Core Processor Integrated Memory Controller Channel 1 Thermal Control Registers
> 3F05.2	Intel Corporation Core Processor Integrated Memory Controller Channel 1 Rank Registers
> 3F05.1	Intel Corporation Core Processor Integrated Memory Controller Channel 1 Address Registers
> 3F05.0	Intel Corporation Core Processor Integrated Memory Controller Channel 1 Control Registers
> 3F04.3	Intel Corporation Core Processor Integrated Memory Controller Channel 0 Thermal Control Registers
> 3F04.2	Intel Corporation Core Processor Integrated Memory Controller Channel 0 Rank Registers
> 3F04.1	Intel Corporation Core Processor Integrated Memory Controller Channel 0 Address Registers
> 3F04.0	Intel Corporation Core Processor Integrated Memory Controller Channel 0 Control Registers
> 3F03.4	Intel Corporation Core Processor Integrated Memory Controller Test Registers
> 3F03.1	Intel Corporation Core Processor Integrated Memory Controller Target Address Decoder
> 3F03.0	Intel Corporation Core Processor Integrated Memory Controller
> 3F02.1	Intel Corporation Core Processor QPI Physical 0
> 3F02.0	Intel Corporation Core Processor QPI Link 0
> 3F00.1	Intel Corporation Core Processor QuickPath Architecture System Address Decoder
> 3F00.0	Intel Corporation Core Processor QuickPath Architecture Generic Non-Core Registers
> 0402.0	VIA Technologies, Inc. VT8306/78 (Via I/O) IEEE 1394 OHCI Controller
> 0100.0	nVidia Corporation G98 (Quadro NVS 295)
> 001F.3	Intel Corporation 82801 SATA RAID Controller
> 001F.2	Intel Corporation 5 Series Chipset LPC Interface Controller
> 001F.0	Intel Corporation 82801 PCI Bridge
> 001D.0	Intel Corporation 5 Series/3400 Series Chipset USB2 Enhanced Host Controller
> 001C.4	Intel Corporation 5 Series/3400 Series Chipset PCI Express Root Port 5
> 001C.0	Intel Corporation 5 Series/3400 Series Chipset PCI Express Root Port 1
> 001B.0	Intel Corporation 5 Series/3400 Series Chipset High Definition Audio
> 001A.0	Intel Corporation 5 Series/3400 Series Chipset USB2 Enhanced Host Controller
> 0019.0	Intel Corporation 82578DM Gigabit Network Connection
> 0018.3	Intel Corporation 5 Series/3400 Series Chipset ICH Controller
> 0018.2	Intel Corporation 5 Series/3400 Series Chipset PT DIER Controller
> 0018.0	Intel Corporation 5 Series/3400 Series Chipset HECI Controller
> 0010.1	Intel Corporation Core Processor QPI Routing and Protocol Registers
> 0010.0	Intel Corporation Core Processor QPI Link
> 000B.2	Intel Corporation Core Processor System Control and Status Registers
> 000B.1	Intel Corporation Core Processor Semaphore and Scratchpad Registers
> 000B.0	Intel Corporation Core Processor System Management Registers
> 0003.0	Intel Corporation Core Processor PCI Express Root Port 1
> 0000.0	Intel Corporation Core Processor DM
Geräteklasse	Unclassified device (0x00)
Geräte-Unterklasse	Non-VGA unclassified device (0x00)
Geräte-Programm	Unbekannt (0x00)
Revision	0x10
Hersteller	Intel Corporation (0x0086)
Gerät	Core Processor DM (0xD131)
Subsystem	Device 0000 (0x0000 0x0000)
> Kontrolle	0x0100
> Status	0x0011
> Zwischenspeicher	0x00
> Latenz	0
> Vorrspann	0x00
> Eingehalter Selb.	0x00
> Address-Zuordnung	0
> Erweiterungs-ROM	0
> Fähigkeiten	0x89
> Interrupt	0
> Rohrer PCI-Einrich...	0

PCI-Bus: Leitungen („mandatory“)

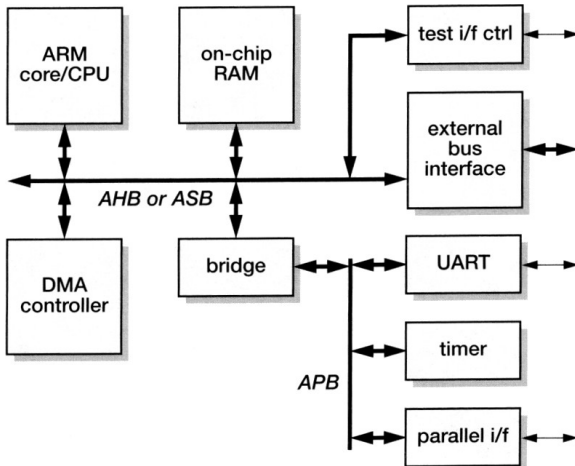
Signal	Lines	Master	Slave	Description
CLK	1			Clock (33 MHz or 66 MHz)
AD	32	×	×	Multiplexed address and data lines
PAR	1	×		Address or data parity bit
C/BE	4	×		Bus command/bit map for bytes enabled
FRAME#	1	×		Indicates that AD and C/BE are asserted
IRDY#	1	×		Read: master will accept; write: data present
IDSEL	1	×		Select configuration space instead of memory
DEVSEL#	1		×	Slave has decoded its address and is listening
TRDY#	1		×	Read: data present; write: slave will accept
STOP#	1		×	Slave wants to stop transaction immediately
PERR#	1			Data parity error detected by receiver
SERR#	1			Address parity error or system error detected
REQ#	1			Bus arbitration: request for bus ownership
GNT#	1			Bus arbitration: grant of bus ownership
RST#	1			Reset the system and all devices

RS-232: Serielle Schnittstelle



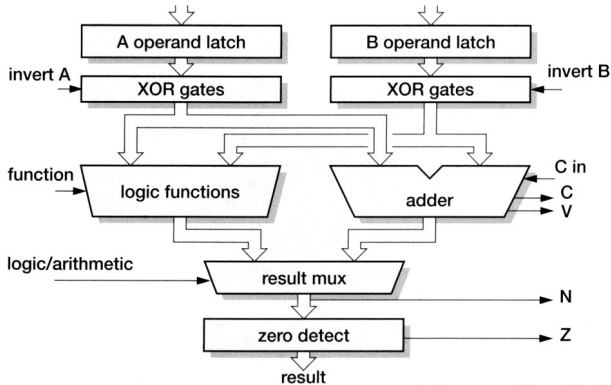
- ▶ Baudrate 300, 600, ..., 19200, 38400, 115200 bits/sec
- ▶ Anzahl Datenbits 5, 6, 7, 8
- ▶ Anzahl Stopbits 1, 2
- ▶ Parität none, odd, even
- ▶ minimal drei Leitungen: GND, TX, RX (Masse, Transmit, Receive)
- ▶ oft weitere Leitungen für erweitertes Handshake

typisches ARM SoC System



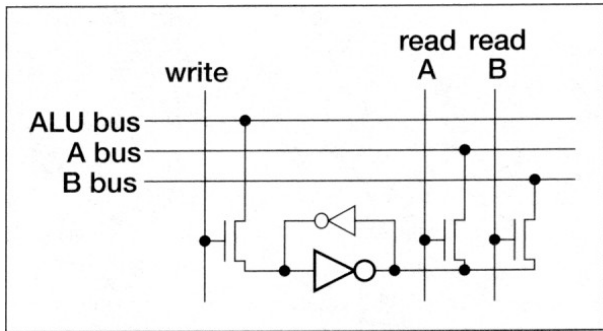
diese und viele folgende Abbildungen: S. Furber, *ARM System-on-Chip Architecture*

RT-Ebene: ALU des ARM-7 Prozessors




- ▶ Register für die Operanden A und B
- ▶ Addierer und separater Block für logische Operationen

Multi-Port-Registerbank: Zelle



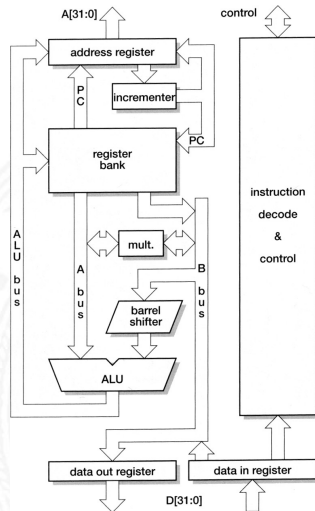
- ▶ Prinzip wie 6T-SRAM: rückgekoppelte Inverter
- ▶ mehrere (hier zwei) parallele Lese-Ports
- ▶ mehrere Schreib-Ports möglich, aber kompliziert

Multi-Port Registerbank: Floorplan/Chiplayout

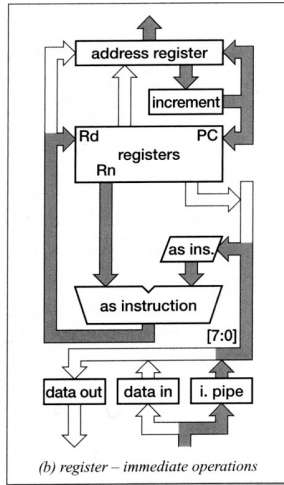
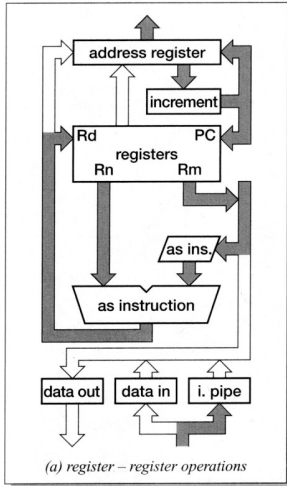


Kompletter Prozessor: ARM-3

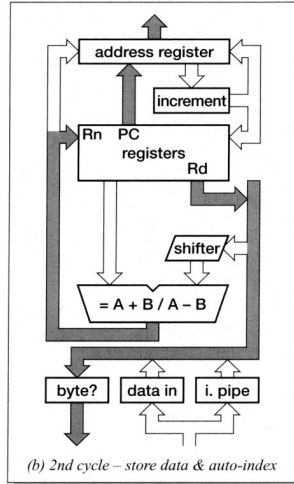
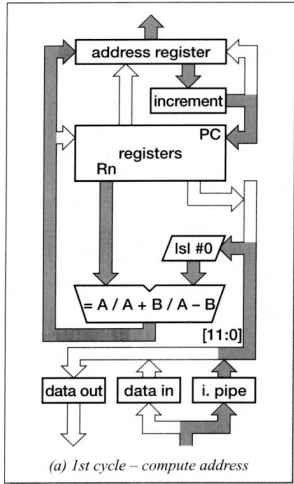
- ▶ Registerbank (inkl. Program Counter)
- ▶ Inkrementer
- ▶ Adress-Register
- ▶ ALU, Multiplizierer, Shifter
- ▶ Speicherinterface (Data-In / -Out)
- ▶ Steuerwerk



ARM-3 Datentransfer: Register-Operationen




ARM-3 Datentransfer: Store-Befehl




Ablaufsteuerung mit Mikroprogramm

- ▶ als Alternative zu direkt entworfenen Schaltwerken
- ▶ *Mikroprogrammzähler* μPC : Register für aktuellen Zustand
- ▶ μPC adressiert den Mikroprogrammspeicher μROM
- ▶ μROM konzeptionell in mehrere Felder eingeteilt
 - ▶ die verschiedenen Steuerleitungen
 - ▶ ein oder mehrere Felder für Folgezustand
 - ▶ ggf. zusätzliche Logik und Multiplexer zur Auswahl unter mehreren Folgezuständen
 - ▶ ggf. Verschachtelung und Aufruf von Unterprogrammen: „nanoProgramm“
- ▶ siehe „Praktikum Rechnerstrukturen“

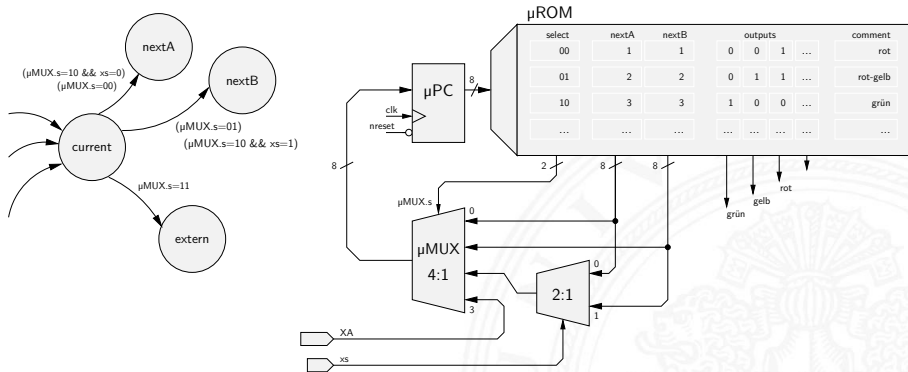
Mikrogramm: Beispiel Ampel



- μ PC adressiert das μ ROM
- "next"-Ausgang liefert den Folgezustand (Adresse 0: Wert 1, Adresse 1: Wert 2, usw)
- andere Ausgänge steuern die Schaltung (hier die Lampen der Ampel)



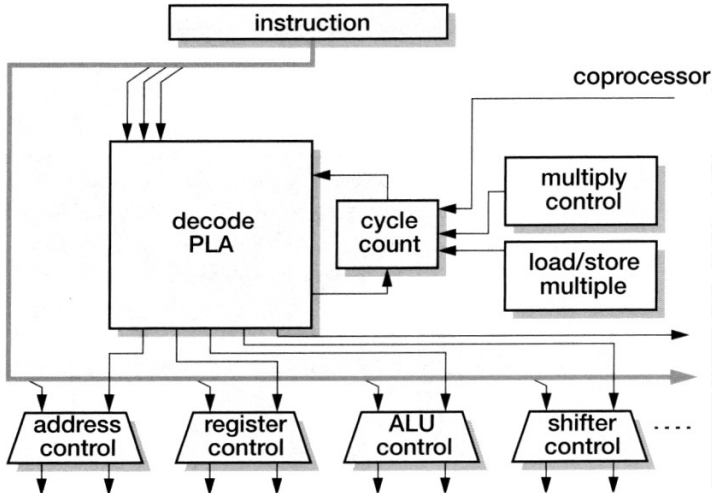
Mikroprogramm: Beispiel zur Auswahl des Folgezustands



- Multiplexer erlaubt Auswahl des μPC Werts
- "nextA", "nextB" aus dem μROM , externer "XA" Wert
- "xs" Eingang erlaubt bedingte Sprünge



Mikrogramm: Befehlsdecoder des ARM-7 Prozessors





Literatur: Quellen für die Abbildungen

- ▶ Andrew S. Tanenbaum,
Computerarchitektur: Strukturen, Konzepte, Grundlagen,
5. Auflage, Pearson Studium, 2006
- ▶ Steven Furber,
ARM System-on-Chip Architecture,
Addison-Wesley Professional, 2001
- ▶ Andreas Mäder,
Vorlesung: Rechnerarchitektur und Mikrosystemtechnik,
Universität Hamburg, FB Informatik, 2010
tams.informatik.uni-hamburg.de/lectures/2010ws/vorlesung/ram



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

14. Schaltwerke

15. Grundkomponenten für Rechensysteme

16. VLSI-Entwurf und -Technologie

Halbleitertechnologie

Halbleiter

Herstellung von Halbleitermaterial

Planarprozess

CMOS-Schaltungen

Logische Gatter

Komplexgatter

Transmission-Gate

Tristate-Treiber

Latch und Flipflop

SRAM



Gliederung (cont.)

CMOS-Herstellungsprozess
Programmierbare Logikbausteine
Entwurf Integrierter Schaltungen
Literatur

17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
21. Speicherhierarchie





Erinnerung

Das **Konzept** des Digitalrechners (von-Neumann Prinzip) ist völlig unabhängig von der Technologie:

- ▶ mechanische Rechenmaschinen
- ▶ pneumatische oder hydraulische Maschinen
- ▶ Relais, Vakuumröhren, diskrete Transistoren
- ▶ molekulare Schaltungen
- ▶ usw.

Aber:

- ▶ nur hochintegrierte Halbleiterschaltungen („VLSI“) erlauben die billige Massenfertigung mit Milliarden von Komponenten
- ▶ **Halbleiter** und **Planarprozess** sind essentielle Basistechnologien




Halbleiter

Halbleiter stehen zwischen *Leitern* (z.B.: Metalle) und *Isolatoren*.

- ▶ bei Raumtemperatur quasi nicht-leitend
- ▶ Leitfähigkeit steigt mit der Temperatur \Rightarrow Heißeleiter
- ▶ physikalische Erklärung über Bändermodell
 siehe <http://de.wikipedia.org/wiki/Halbleiter>

Kristallstruktur aus 4-wertigen Atomen

- ▶ elementare Halbleiter: Ge, Si
- ▶ Verbindungshalbleiter: GaAs, InSb



Leitung im undotierten Kristall

- ▶ Paarentstehung: Elektronen lösen sich aus Gitterverband Paar aus Elektron und „Loch“ entsteht.
- ▶ Rekombination: Elektronen und Löcher verbinden sich quasistatischer Prozess
- ▶ Eigenleitendichte n_i : temperatur- und materialabhängig

$$\text{Si} : 1,2 \cdot 10^{10} \text{ cm}^{-3}$$

$$\text{Ge} : 2,5 \cdot 10^{13} \text{ cm}^{-3}$$


$$\text{GaAs} : 1,8 \cdot 10^6 \text{ cm}^{-3}$$

$$\text{bei } 300^\circ \text{K} \approx 20^\circ \text{C}$$

Atomdichte

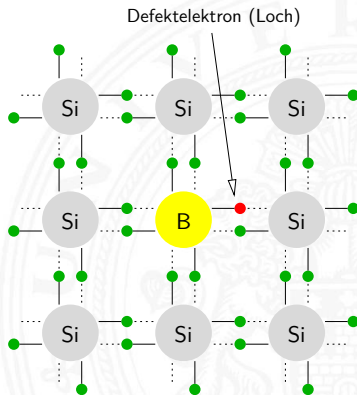

$$\text{Si} : 5 \cdot 10^{22} \text{ cm}^{-3}$$

- ▶ es gilt: $n_i^2 = n_n \cdot n_p$



Dotierung mit Fremdatomen

Ein kleiner Teil der vierwertigen Atome wird durch fünf- oder dreiwertige Atome ersetzt.



Dotierung mit Fremdatomen (cont.)

- ▶ Donatoren, Elektronenspender: Phosphor, Arsen, Antimon
- ▶ Akzeptoren: Bor, Aluminium, Gallium, Indium

Dotierungsdichten	Stärke	Fremdatome [cm^{-3}]
	schwach n^-, p^-	$10^{15} \dots 10^{16}$
	mittel n, p	$10^{16} \dots 10^{19}$
	stark n^+, p^+	$10^{19} \dots$

- ▶ Beweglichkeit μ : materialspezifische Größe

$T = 300^\circ K$		Si	Ge	GaAs	[$cm^2/(Vs)$]
Elektronen μ_n		1500	3900	8500	
Löcher μ_p		450	1500	400	

- ▶ Leitfähigkeit: ergibt sich aus Material, Beweglichkeit und Ladungsträgerdichte(n)

$$K = e(n_n \mu_n + n_p \mu_p)$$




Dotierung mit Fremdatomen (cont.)

- ▶ selbst bei hoher Dotierung ist die Leitfähigkeit um Größenordnungen geringer als bei Metallen
 - Si** 1 freier Ladungsträger pro 500 Atome ($10^{19}/5 \cdot 10^{22}$)
 - Met** mindestens 1 Ladungsträger pro Atom
- ▶ Majoritätsträger: Ladungsträger in Überzahl (i.d.R. Dotierung)
 Minoritätsträger: Ladungsträger in Unterzahl
 $n_i^2 = n_n \cdot n_p$

Herstellung von Halbleitermaterial

Übersicht in: <http://de.wikipedia.org/wiki/Silicium>





Rohsilizium


- ▶ Siliziumoxid (SiO_2): Sand, Kies. . .
ca. 20% der Erdkruste
- ▶ Herstellung im Lichtbogenofen: Siliziumoxid + Koks
 $SiO_2 + 2C \rightarrow Si + 2CO$
- ▶ amorphe Struktur, polykristallin
- ▶ noch ca. 2% Verunreinigungen (Fe, Al. . .)



Solarsilizium

Ziel: Fremdatome aus dem Silizium entfernen

1. Chemische Bindung des Siliziums



Reaktion mit Salzsäure erzeugt

$SiHCl_3$ Trichlorsilan

$SiCl_4$ Siliziumchlorid (10%)

SiH_2Cl_4 div. andere Chlorsilane/Silane


$FeCl_2, AlCl_3$ div. Metallchloride

2. Verschiedene Kondensations- und Destillationsschritte trennen
 Fremdverbindungen ab, hochreines Trichlorsilan entsteht
 < 1ppm Verunreinigungen

Solarsilizium (cont.)


3. CVD (Chemical Vapour Deposition) zur Abscheidung des

Trichlorsilans zu elementarem Silizium



⇒ polykristallines Silizium

< 0,1ppm Verunreinigungen





Siliziumeinkristall

Weitere Ziele



- ▶ Einkristalline Struktur erzeugen
- ▶ Reinheit für Halbleiterherstellung erhöhen
<, \ll 1ppb
- ▶ ggf. Dotierung durch Fremdatome einbringen

Es gibt dazu mehrere technische Verfahren, bei denen das polykristalline Silizium geschmolzen wird und sich monokristallin an einen Impfkristall anlagert.




Siliziumeinkristall (cont.)

Czochralski-Verfahren (Tiegelziehverfahren)




Siliziumeinkristall (cont.)

Zonenschmelz- / Zonenziehverfahren



Wafer


- ▶ weitere Bearbeitungsschritte:
zersägen, schleifen, läppen, ätzen, polieren
- ▶ Durchmesser bis 30 cm
 2014: 45 cm
- Dicke < 1mm
- Rauhgigkeit \approx nm
- ▶ Markieren: Kerben, Lasercodes. ...
früher „flats“



Technologien

Technologien zur Erstellung von Halbleiterstrukturen

- ▶ Epitaxie: Aufwachsen von Schichten
- ▶ Oxidation von Siliziumoberflächen: SiO_2 als Isolator
- ▶ Strukturierung durch Lithografie
- ▶ Dotierung des Kristalls durch Ionenimplantation oder Diffusion
- ▶ Ätzprozesse: Abtragen von Schichten





Technologien (cont.)

Links



- ▶ <http://www.halbleiter.org>
- ▶ <http://www.siliconfareast.com>
- ▶ <http://www2.renesas.com/fab/en>
- ▶ http://en.wikipedia.org/wiki/Semiconductor_device_fabrication
- ▶ <http://de.wikipedia.org/wiki/Halbleitertechnik>

Lithografie

Übertragung von Strukturen durch einen Belichtungsprozess

1. Lack Auftragen (Aufschleudern)

- ▶ Positivlacke: hohe Auflösung \Rightarrow MOS
- ▶ Negativlacke: robust, thermisch stabil





Lithografie (cont.)

2. „Belichten“

- ▶ Maskenverfahren: 1:1 Belichtung, Step-Verfahren
UV-Lichtquelle
- ▶ Struktur direkt schreiben: Elektronen- / Ionenstrahl
- ▶ andere Verfahren: Röntgenstrahl- / EUV-Lithografie

3. Entwickeln, Härten, Lack entfernen

- ▶ je nach Lack verschiedene chemische Reaktionsschritte
- ▶ Härtung durch Temperatur

... weitere Schritte des **Planarprozess**



Dotierung

Fremdatome in den Siliziumkristall einbringen



► Diffusion

- Diffusionsofen
- gaußförmiges Dotierungsprofil

Konzentration der Dotieratome nimmt ab



Dotierung (cont.)






Dotierung (cont.)

- ▶ Ionenimplantation
 - ▶ „Beschuss“ mit Ionen
 - ▶ Beschleunigung der Ionen im elektrischen Feld
 - ▶ Über die Energie der Ionen kann die Eindringtiefe sehr genau eingestellt werden
 - ▶ „Temperung“ notwendig: Erhitzen des Einkristalls zur Neuorganisation des Kristallgitters

Dotierung (cont.)

Ionenimplantation

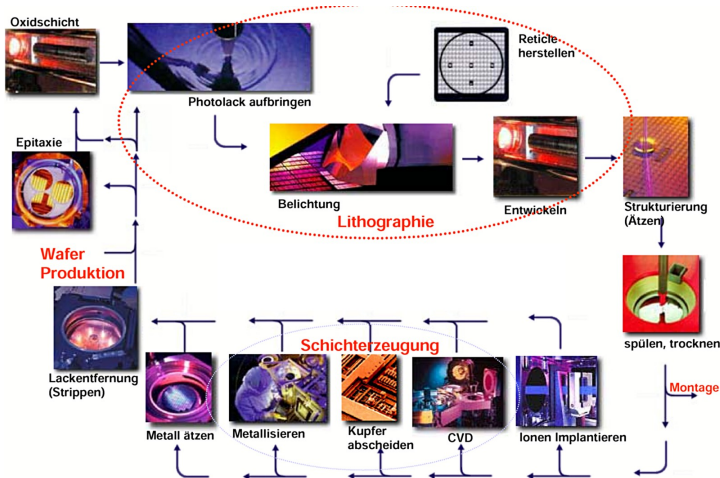




Planarprozess

- ▶ Der zentrale Ablauf bei der Herstellung von Mikroelektronik
- ▶ Ermöglicht die gleichzeitige Fertigung aller Komponenten auf dem Wafer
- ▶ Schritte
 1. Vorbereiten / Beschichten des Wafers:
Oxidation, CVD, Aufdampfen, Sputtern...
 2. Strukturieren durch Lithografie
 3. Übertragen der Strukturen durch Ätzprozesse
 4. Modifikation des Materials: Dotierung, Oxidation
 5. Vorbereitung für die nächsten Prozessschritte...

Planarprozess (cont.)




MOS-Transistor

- ▶ MOS: Metal Oxide Semiconductor
 FET : Feldeffekttransistor
 - ▶ <http://olli.informatik.uni-oldenburg.de/weTEiS/weteis/tutorium.htm>
 - ▶ <http://de.wikipedia.org/wiki/Feldeffekttransistor>
 - ▶ <http://de.wikipedia.org/wiki/MOSFET>
- ▶ unipolarer Transistor: nur eine Art von Ladungsträgern, die Majoritätsträger, ist am Stromfluss beteiligt im Gegensatz zu Bipolartransistoren
 siehe z.B.: U. Tietze, C. Schenk, *Halbleiter-Schaltungstechnik*

MOS-Transistor (cont.)


- ▶ Anschlüsse: **Source** Quelle der Ladungsträger
- Gate** steuert den Stromfluss
- Drain** Senke der Ladungsträger
- Bulk** siehe „Herstellungstechnik“




N. Reifschneider,
 CAE-gestützte IC-Entwurfsmethoden

MOS-Transistor (cont.)

- Funktionsweise: die Ladung des Gates erzeugt ein elektrisches Feld. Durch Inversion werden Ladungsträger unterhalb des Gates verdrängt und ein leitender Kanal zwischen Source und Drain entsteht.



MOS-Transistor (cont.)




- ▶ Raumladungszone: neutral, keine freien Ladungsträger
- ▶ Schwellspannung U_P : abhängig von der Dotierungsdichte, den Parametern des MOS-Kondensators (Dicke und Material der Gate-Isolationsschicht)...


U_P möglichst klein: 0,3...0,8 V früher: deutlich mehr

MOS-Transistor (cont.)

- ▶ $U_{DS} \ll U_{GS} - U_P$ normaler Betrieb (Triodenbereich)




- ▶ $U_{DS} = U_{GS} - U_P$ Kanalabschnürung
 Spannungsabfall zwischen S und D durch den Kanalwiderstand



MOS-Transistor (cont.)


- ▶ $U_{DS} > U_{GS} - U_P$ Kanalverkürzung (Sättigungsbereich)
 Der Kanal wird weiter verkürzt, die Spannung U_{DS} bewirkt ein virtuell größeres Drain durch Inversion.
 I_D wächst nur noch minimal.



- ⇒ kurze Kanäle aktueller Submikronprozesse können allein durch hohe Spannungen U_{DS} leitend werden (Durchgreifbetrieb)
- ⇒ einer der Gründe für sinkende Versorgungsspannungen




MOS-Transistor (cont.)

► Kennlinienfeld






MOS-Transistor: Schaltsymbole

P-Kanal



N-Kanal



selbstleitend
Verarmungs-

selbstsperrend
Anreicherungstyp



CMOS-Technologie

Complementary Metal-Oxide Semiconductor: die derzeit dominierende Technologie für alle hochintegrierten Schaltungen

- ▶ Schaltungsprinzip nutzt n-Kanal und p-Kanal Transistoren
- ▶ alle elementaren Gatter verfügbar
- ▶ effiziente Realisierung von *Komplexgattern*
- ▶ *Transmission-Gate* als elektrischer Schalter
- ▶ effiziente Realisierung von Flipflops und Speichern

- + sehr hohe Integrationsdichte möglich, gut skalierbar
- + sehr schnelle Schaltgeschwindigkeit der Gatter
- + sehr geringer Stromverbrauch pro Gatter möglich
- + Integration von digitalen und analogen Komponenten

CMOS: Überblick

- ▶ Schaltungsprinzip
- ▶ Inverter und nicht-invertierender Verstärker
- ▶ NAND, NAND3, NOR (und AND, OR)
- ▶ XOR

- ▶ Komplexgatter
- ▶ Transmission-Gate

- ▶ Beispiele für Flipflops
- ▶ SRAM





CMOS: Schaltungsprinzip von „static CMOS“

- ▶ Transistoren werden als Schalter betrachtet
- ▶ zwei zueinander **komplementäre** Zweige der Schaltung
 - ▶ n-Kanal Transistoren zwischen Masse und Ausgang y *1 on*
 - ▶ p-Kanal – V_{dd} und Ausgang y *0 on*
- ▶ p-Kanal Zweig komplementär („dualer Graph“) zu n-Kanal Zweig:
 jede Reihenschaltung von Elementen wird durch eine Parallelschaltung ersetzt (und umgekehrt)
- ▶ immer ein direkt leitender Pfad von entweder V_{dd} („1“) oder Masse / Gnd („0“) zum Ausgang
- ▶ niemals ein direkt leitender Pfad von V_{dd} nach Masse
- ▶ kein statischer Stromverbrauch im Gatter

Inverter

Funktionsweise



- ▶ selbstsperrende p- und n-Kanal Transistoren
 - ▶ komplementär beschaltet
 - ▶ Ausgang: Pfad über p-Transistoren zu V_{dd}
 —"— n-Transistoren zu Gnd
 - ▶ genau *einer* der Pfade leitet
- ▶ Eingang $Trans_P$ $Trans_N$ Ausgang
-
- $a = 0 \rightarrow$ leitet / sperrt \rightarrow über T_P mit V_{dd} verbunden = 1
- $a = 1 \rightarrow$ sperrt / leitet \rightarrow über T_N mit Gnd verbunden = 0



Inverter (cont.)

Leistungsaufnahme


1. $U_{in} = 0$, bzw. V_{dd} : Sperrstrom, nur μA
 \Rightarrow niedrige statische Leistungsaufnahme
2. Querstrom beim Umschalten:
 kurzfristig leiten beide Transistoren
 \Rightarrow Forderung nach steilen Flanken
3. Kapazitive Last: Fanout-Gates
 Energie auf Gate(s): $W = \frac{1}{2} C_T V_{dd}^2$
 Verlustleistung $_{(0/1/0)}$: $P = C_T V_{dd}^2 \cdot f$





Transfercharakteristik

Hades: n- und p-Kanal Transistor, Inverter, Verstärker

n-channel transistor




p-channel transistor



inverter


$$Y = \neg A$$



non-inverting
buffer

$$Y = \neg \neg A = A$$



NAND- und AND-Gatter



- ▶ NAND: n-Transistoren in Reihe, p-Transistoren parallel
- ▶ AND: Kaskade aus NAND und Inverter

tams.informatik.uni-hamburg.de/applets/hades/webdemos/05-switched/40-cmos


NAND- und AND-Gatter (cont.)




- ▶ n-Transistoren in Reihe, p-Transistoren parallel
- ▶ normalerweise max. 4 Transistoren in Reihe (Spannungsabfall)

NOR- und OR-Gatter

NOR2



OR2



- ▶ Struktur komplementär zum NAND/AND
- ▶ n-Transistoren parallel, p-Transistoren in Reihe
- ▶ p-Transistoren schalten träge: etwas langsamer als NAND

CMOS-Technologie: Demos

CMOS 3-Input NAND gate demo: $Y = \overline{(A \wedge B \wedge C)}$
 [Click near inputs to toggle input voltages:]

Colors: 1 [+5V] 0 [0V] [Z (floating)] [Short-circuit]

C	B	A	Y
0	0	0	1
0	0	1	1
0	1	0	1
0	1	1	1
1	0	0	1
1	0	1	1
1	1	0	1
1	1	1	0

- ▶ Interaktive Demonstration der CMOS-Grundgatter (Java)
<http://tams.informatik.uni-hamburg.de/applets/cmos/>

CMOS: Komplexgatter

Gatterfunktionen

- ▶ Schaltungen: *negierte monotone boole'sche Funktionen*
- ▶ Beliebiger schaltalgebraischer Ausdruck *ohne Negation*: \vee, \wedge
- ▶ Negation des gesamten Ausdrucks: Ausgang *immer* negiert
- ▶ je Eingang: ein Paar p-/n-Kanal Transistoren
- ▶ Dualitätsprinzip: n- und p-Teil des Gatters

n-Teil	p-Teil	Logik, ohne Negation
seriell \Leftrightarrow parallel	$\equiv \wedge /$	und
parallel \Leftrightarrow seriell	$\equiv \vee /$	oder

CMOS: Komplexgatter (cont.)

► Konstruktion

1. n-Teil aus Ausdruck ableiten
beliebige Parallel- und Serienschaltung der n-Transistoren
2. p-Teil dual dazu entwickeln
komplementäre Seriell- und Parallelschaltung der p-Transistoren
 - typischerweise max. 4 Transistoren in Reihe

► viele invertierende logische Funktionen effizient realisierbar

► Schaltungslayout automatisch synthetisierbar

► zwei gängige Varianten

- AOI-Gatter („AND-OR-invert“)
- OAI-Gatter („OR-AND-invert“)

Komplexgatter

Beispiel: $\overline{(a \wedge b \wedge c) \vee d \vee (e \wedge f)}$

„AOI321-Gatter“, AND-OR-INVERT Struktur

- ▶ AND-Verknüpfung von (a,b,c)
- ▶ AND-Verknüpfung von (e,f)
- ▶ NOR-Verknüpfung der drei Terme

- ▶ direkte Realisierung hätte $(6+2)+(0)+(4+2)+6$ Transistoren
- ▶ Komplexgatter mit 12 Transistoren



Komplexgatter (cont.)


Beispiel: $\overline{(a \wedge b \wedge c) \vee d \vee (e \wedge f)}$






Komplexgatter (cont.)

Beispiel: $\overline{(a \wedge b \wedge c)} \vee d \vee (e \wedge f)$




Komplexgatter (cont.)

Beispiel: $\overline{(a \wedge b \wedge c) \vee d \vee (e \wedge f)}$





Komplexgatter (cont.)

Beispiel: $\overline{(a \wedge b \wedge c) \vee d \vee (e \wedge f)}$





Komplexgatter (cont.)

Beispiel: $\overline{(a \wedge b \wedge c)} \vee d \vee (e \wedge f)$




Komplexgatter (cont.)

Beispiel: $\overline{(a \wedge b \wedge c) \vee d \vee (e \wedge f)}$




Komplexgatter (cont.)

Beispiel: $\overline{(a \wedge b \wedge c)} \vee d \vee (e \wedge f)$



Komplexgatter (cont.)


Beispiel: $\overline{(a \wedge b \wedge c) \vee d \vee (e \wedge f)}$





Transmission-Gate

Transmissions-Gatter (*transmission gate, t-gate*)

- ▶ Paar aus je einem n- und p-Kanal MOS-Transistor
- ▶ symmetrische Anordnung
- ▶ Ansteuerung der Gate-Elektroden mit invertierter Polarität
- ⇒ entweder beide Transistoren leiten, oder beide sperren
- ▶ Funktion entspricht **elektrisch gesteuertem Schalter**
- ▶ effiziente Realisierung vieler Schaltungen




Transmission-Gate (cont.)



 $C = 0$

 $C = 1$


elektrisch gesteuerter Schalter:

- ▶ $C = 0$: keine Verbindung von A nach B
- $C = 1$: leitende Verbindung von A nach B
- ▶ symmetrisch in beide Richtungen



Transmission-Gate: Demo

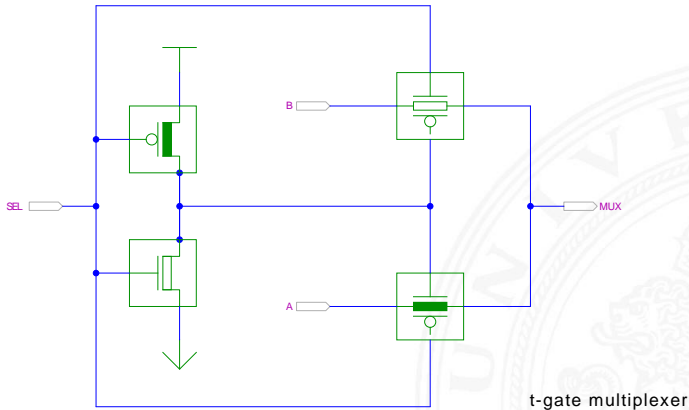


tgate demonstration

- ▶ Werte A und B anlegen, Treiber mit enable-Signalen aktivieren
- ▶ Gatter mit S ein- oder ausschalten


tams.informatik.uni-hamburg.de/applets/hades/webdemos/05-switched/40-cmos/tgate.html

T-Gate Multiplexer



- ▶ kompakte Realisierung (4 bzw. 6 Transistoren)
- ▶ Eingänge *a* und *b* nicht verstärkt \Rightarrow nur begrenzt kaskadierbar

T-Gate XOR-Gatter




- ▶ kompakte Realisierung des XOR (nur 6 Transistoren)
- ▶ Eingang b nicht verstärkt \Rightarrow nur begrenzt kaskadierbar

Tristate-Treiber

Bussysteme

- ▶ Quellen: „Bustreiber“
- ▶ Senken : Gattereingänge
- ▶ Probleme
 - ▶ *Kurzschluss*
 - ▶ *offene Eingänge*

⇒ Tristate




Tristate-Treiber (cont.)

Beispiel: Tristate-Inverter

Funktionsweise

- ▶ Ausgang elektrisch trennen
z.B. mit Transmission-Gate
- ▶ 3-Pegel: 0, 1, *Z hochohmig*





- ▶

Enable	Verbindung	Ausgang
$en = 0$	→ getrennt	→ $bus = Z$ hochohmig
$en = 1$	→ geschlossen	→ $bus = \neg a$ $f(a)$

Tristate-Treiber (cont.)

Tristate-Bussystem

- ▶ *pull-up/-down* Widerstand R (offene Eingänge)
- ▶ nur **genau ein** Treiber gleichzeitig aktiv





Latch / Flipflop: Speichertechnik

Methoden der Implementation

1. statisch

- ▶ Speicherung: Rückkopplung von (statischen) Gattern
siehe: „Schaltwerke – Flipflops“
- + taktunabhängig
- + sicher

2. quasi-statisch

- ▶ Speicherung: Rückkopplung von Gattern
- ▶ Transmission-Gates als Multiplexer
- + taktunabhängig
- + kleiner



Latch / Flipflop: Speichertechnik (cont.)

3. dynamisch


- ▶ Speicherung: Gate-Kapazitäten
- ▶ verschiedene Taktschemata/Schaltungsvarianten
- muss getaktet werden
- schwieriger zu Entwerfen (wegen Taktschema)
- + Integration in Datenpfade (arithmetische Pipelines)
- + sehr hohe Taktfrequenzen
- + sehr klein

D-Latch: quasi-statisch

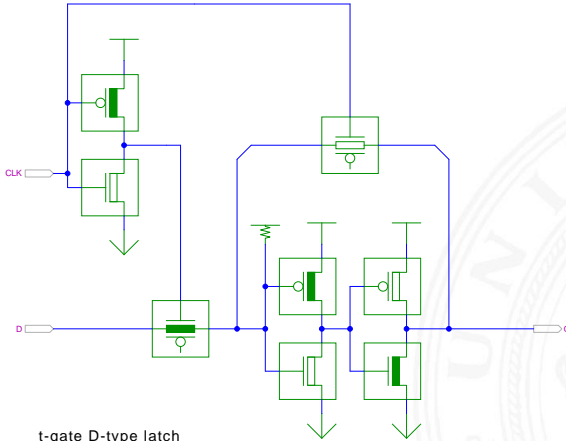
► Transmission-Gates als Schalter

$C = 1$ Transparent: Eingang über die Inverter zum Ausgang

$C = 0$ Speicherung: Rückkopplungspfad aktiv



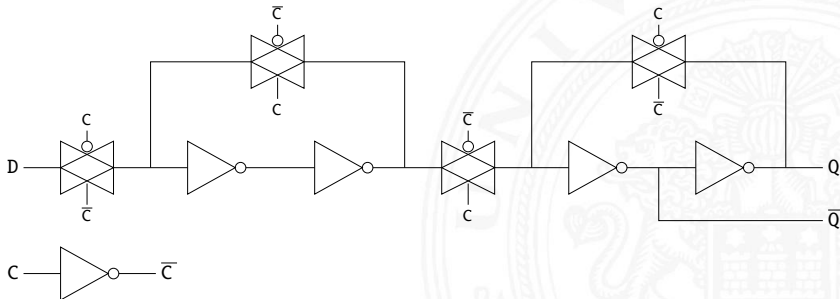
D-Latch: quasi-statisch (cont.)



D-Flipflop: quasi-statisch

- ▶ Aufbau aus zwei Latches
- ▶ Vorderflanke: low-Transparent + high-Transparent


D-FF, vorderflankengest.



dynamische Speicherung

Schaltungsprinzip

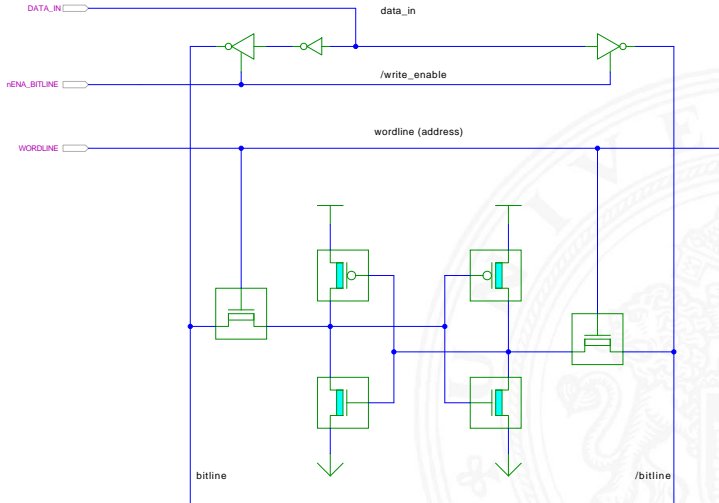
- ▶ Speicherung auf Gate-Kapazitäten



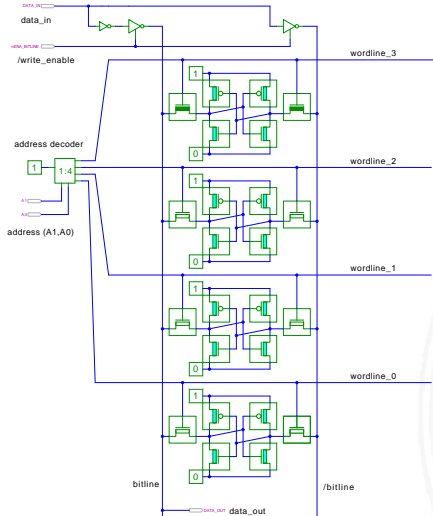
- ▶ viele unterschiedliche Taktschemata/Funktionsweisen
- ▶ Verbindung mit Logikgattern möglich
 ⇒ arithmetische Pipelines

... aus Zeitgründen nicht weiter vertieft

SRAM: Sechs-Transistor Speicherstelle („6T“)



Prinzip des SRAM




CMOS Prozessschritte: Inverter

Ein n-Wannen Prozesses

Weste, Eshragian, *Principles of CMOS VLSI Design*


1. Ausgangsmaterial: p-dotiertes Substrat
2. n-Wanne



- ▶ Dotierung für p-Kanal Transistoren
- ▶ Herstellung: Ionenimplantation oder Diffusion

CMOS Prozessschritte: Inverter (cont.)


3. „aktive“ Fläche / Dünnoxid



- ▶ Spätere Gates und $p^+/-n^+$ -Gebiete
- ▶ Herstellung: Epitaxie SiO_2 und Abdeckung mit Si_3N_4

CMOS Prozessschritte: Inverter (cont.)


4. p-Kanalstopp



- ▶ Begrenzt n-Kanal Transistoren
 - ▶ p-Wannen Maske, bzw. \neg n-Wanne
 - ▶ Maskiert durch Resist und Si_3N_4
 - ▶ Substratbereiche in denen keine n-Transistoren sind
 - ▶ Herstellung: p^+ -Implant (Bor)
- ▶ n-Kanalstopp aktueller Prozesse: analog dazu

CMOS Prozessschritte: Inverter (cont.)

5. Resist entfernen
6. Feldoxid aufwachsen – SiO_2




- ▶ LOCOS: **L**ocal **O**xidation of **S**ilicon
- ▶ Maskiert durch Si_3N_4
- ▶ Wächst auch lateral unter Si_3N_4/SiO_2 (aktive) Bereiche
 engl. *bird's beak*
- ▶ Der aktive Bereich wird kleiner als vorher maskiert
- ▶ Herstellung: Epitaxie und Oxidation
- ▶ Problem: nicht plane Oberfläche

CMOS Prozessschritte: Inverter (cont.)

7. Si_3N_4 entfernen, Gateoxid bleibt SiO_2
8. Transistor Schwellspannungen „justieren“
 - ▶ Meist wird das Polysilizium zusätzlich n^+ dotiert
Grund: bessere Leitfähigkeit
 - ▶ Problem: $U_D(T_N) \approx 0,5 \dots 0,7 \text{ V}$
 $U_D(T_P) \approx -1,5 \dots -2,0 \text{ V}$
 - ▶ Maske: n-Wanne, bzw. p-Wanne
 - ▶ Herstellung: Epitaxie einer leicht negativ geladenen Schicht an der Substratoberfläche

CMOS Prozessschritte: Inverter (cont.)


9. Polysilizium Gate



- ▶ Herstellung: Epitaxie von Polysilizium, Ätzen nach Planarprozess

CMOS Prozessschritte: Inverter (cont.)

10. n^+ -Diffusion





- ▶ Erzeugt Source und Drain der n-Kanal Transistoren
- ▶ Maskiert durch aktiven Bereich, n^+ -Maske und Polysilizium
 ⇒ Selbstjustierung
- ▶ Dotiert auch das Polysilizium Gate leicht (s.o.)
- ▶ Herstellung: Ionenimplantation, durchdringt Gateoxid

CMOS Prozessschritte: Inverter (cont.)


Zusätzliche Schritte bei der Source/Drain Herstellung

- ▶ Problem „Hot-Carrier“ Effekte (schnelle Ladungsträger): Stoßionisation, Gateoxid wird durchdrungen...
- ▶ Lösung: z.B. LDD (**L**ightly **D**oped **D**rain)
 - a. „flaches“ n-LDD Implant
 - b. zusätzliches SiO_2 über Gate aufbringen (*spacer*)
 - c. „normales“ n^+ -Implant
 - d. Spacer SiO_2 entfernen



CMOS Prozessschritte: Inverter (cont.)

11. p^+ -Diffusion




- ▶ Erzeugt Source und Drain der p-Kanal Transistoren
- ▶ Maskiert durch aktiven Bereich, p^+ -Maske und Polysilizium
 ⇒ Selbstjustierung
- ▶ teilweise implizite p^+ -Maske = \neg n^+ -Maske
- ▶ wenig schnelle Ladungsträger (Löcher), meist keine LDD-Schritte
- ▶ Herstellung: Ionenimplantation, durchdringt Gateoxid

CMOS Prozessschritte: Inverter (cont.)

12. SiO_2 aufbringen, Feldoxid

- ▶ Strukturen isolieren
- ▶ Herstellung: Epitaxie


13. Kontaktlöcher



- ▶ Verbindet (spätere) Metallisierung mit Polysilizium oder Diffusion
- ▶ Anschlüsse der Transistoren: Gate, Source, Drain
- ▶ Herstellung: Ätzprozess

CMOS Prozessschritte: Inverter (cont.)

14. Metallverbindung



- ▶ Erzeugt Anschlüsse im Bereich der Kontaktlöcher
- ▶ Herstellung: Metall aufdampfen, Ätzen nach Planarprozess

15. weitere Metalllagen

- ▶ Weitere Metallisierungen, bis zu $7 \times$ Metall
- ▶ Schritte: 12. bis 14. wiederholen

CMOS Prozessschritte: Inverter (cont.)


16. Passivierung

- ▶ Chipoberfläche abdecken, Plasmanitridschicht

17. Pad-Kontakte öffnen


Zahlreiche Erweiterungen für Submikron CMOS-Prozesse

- ▶ „vergrabene“ Layer
 - ▶ verbessern elektrische Eigenschaften
 - ▶ Bipolar-Transistoren
 - ▶ Analog-Schaltungen
- ▶ Gate Spacer, seitlich SiO_2
- ▶ Silizidoberflächen: verringern Kontaktwiderstand zu Metallisierung



CMOS Prozessschritte: Inverter (cont.)

► Kupfer Metallisierung



Tungsten
Local Interconnect

Copper 6

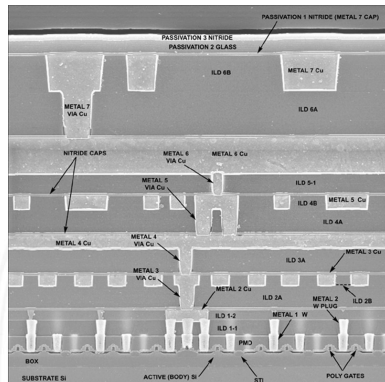
Copper 5

Copper 4

Copper 3

Copper 2




Copper 1



► high-k Dielektrika: Gate-Isolierung dicker, weniger Leckströme

CMOS Prozessschritte: Inverter (cont.)

- „gestrecktes“ Silizium: höhere Beweglichkeit



Programmierbare Logikbausteine

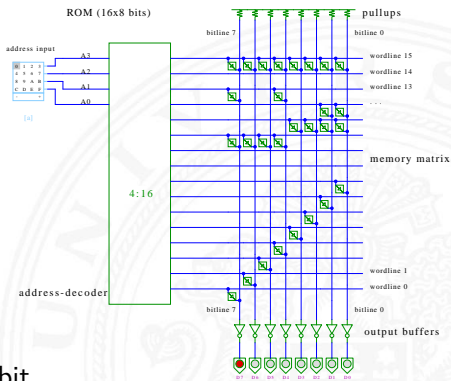
Kompromiss zwischen fest aufgebauter Hardware und Software-basierten Lösungen auf Computern

- ▶ Realisierung anwendungsspezifischer Funktionen und Systeme
 - ▶ gute bis sehr gute Performance
 - ▶ hoher Entwurfsaufwand
 - ▶ vom Anwender (evtl. mehrfach) programmierbar

- ▶ Klassifikation nach Struktur und Komplexität
 - ▶ PROM Programmable Read-Only Memory
 - ▶ PAL Programmable Array Logic
 - ▶ GAL Generic Array Logic
 - ▶ PLA Programmable Logic Array
 - ▶ CPLD Complex Programmable Logic Device
 - ▶ FPGA Field-Programmable Gate Array
 - ▶ ...

PROM: Programmable Read-Only Memory

- ▶ UND-ODER Struktur
 - ▶ UND-Array
 - ▶ fest
 - ▶ voll auscodiert: 2^n Terme
 - ▶ ODER-Terme
 - ▶ programmierbar
-
- ▶ auch: „LUT“ (look-up table)
 - ▶ Hades Beispiel: $n = 4$, 16×8 bit





PAL: Programmable Array Logic

- ▶ disjunktive Form: UND-ODER Struktur
- ▶ UND-Ausgänge fest an die ODER-Eingänge angeschlossen
- ▶ Eingänge direkt und invertiert in die UND-Terme geführt
- ▶ Verknüpfungen der Eingänge zu den UND-Termen programmierbar

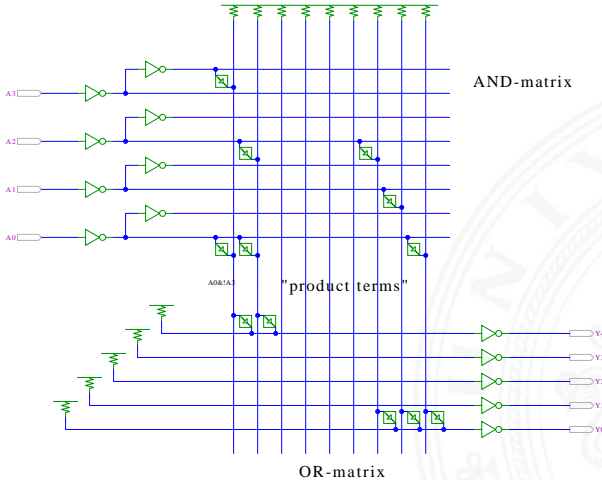
- ▶ heute durch GAL ersetzt (s.u.)



PLA: Programmable Logic Array

- ▶ disjunktive Form: logische UND-ODER Struktur
 - ▶ Eingänge direkt und invertiert in die UND-Terme geführt
 - ▶ Verknüpfungen Eingänge UND-Terme
 - ▶ Verknüpfungen UND-Ausgänge zu ODER-Eingängen programmierbar
- + in NMOS-Technologie sehr platzsparend realisierbar als NOR-NOR Matrix (de-Morgan Regel)
- statischer Stromverbrauch
 - in CMOS-Technologie kaum noch verwendet

PLA: Programmable Logic Array (cont.)



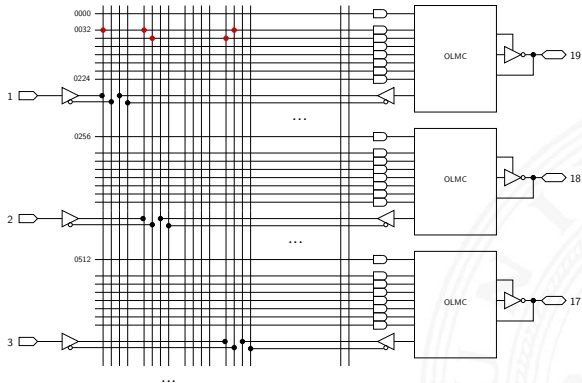
Hades Webdemos: 42-programmable/10-pla/pla.html



GAL: Generic Array Logic

- ▶ disjunktive UND-ODER Struktur
- ▶ externe Eingänge und Ausgangswerte direkt/invertiert
- ▶ „Fuses“ verbinden Eingangswerte mit den AND-Termen
- ▶ programmierbare Ausgabezellen (OLMC)
mit je einem D-Flipflop
- ▶ Output-Enable über AND-OR Matrix steuerbar
- ▶ drei Optionen
 - ▶ synchron/kombinatorisch (Flipflop nutzen oder umgehen)
 - ▶ Polarität des Eingangs (D oder \overline{D} speichern)
 - ▶ Polarität des Ausgangs (Q oder \overline{Q} ausgeben)
- ▶ Beispiel: GAL16V8 mit 8 Ausgabezellen, je 7+1 OR-Terme pro Ausgabezelle, 32 Eingänge pro Term

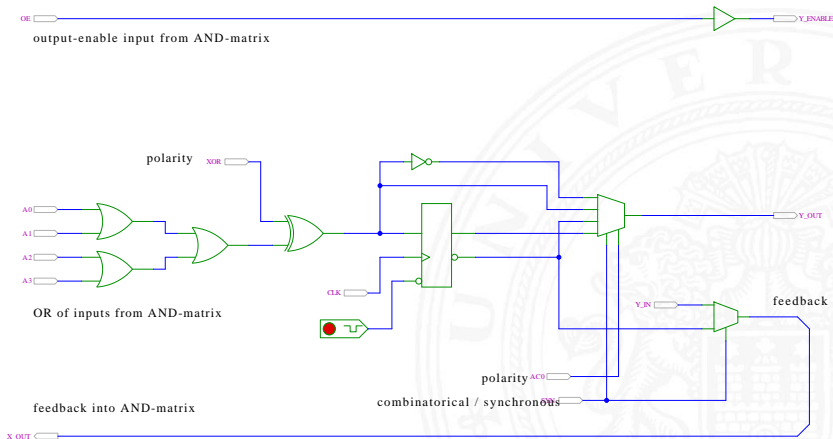
GAL: Blockschaltbild (Ausschnitt)



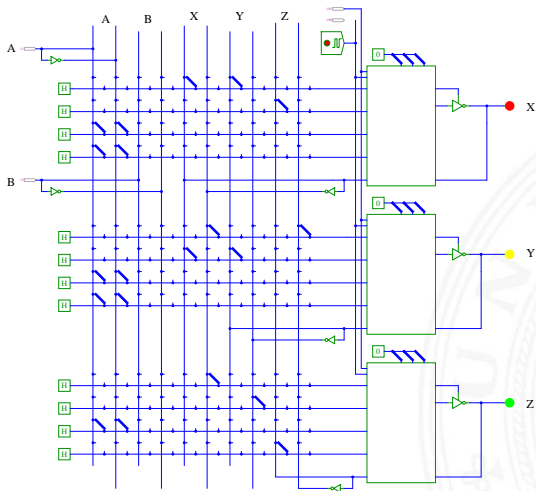
- ▶ programmierbare Sicherungen durchnummeriert
- ▶ kompakte Darstellung der UND-Terme: je eine Zeile
- ▶ Beispiel: zweiter Term (ab 0032) $y = 1 \vee 2 \vee \bar{3}$

GAL: Ausgabezelle mit Flipflop

OLMC: Output-Logic-Macrocell



GAL: Beispiel Ampel





FPGA: Field-Programmable Gate-Array

Sammelbegriff für „große“ anwenderprogrammierbare Schaltungen

- ▶ Matrix von kleineren programmierbaren Zellen, beispielsweise
 - ▶ SRAM als Lookup für Funktionen
 - ▶ programmierbare Register
 - ▶ carry-lookahead Logik
- ▶ Multiplexer-Netzwerk als programmierbare Verbindung
- ▶ zusätzliche „Makrozellen“
 - ▶ Multiplizierer
 - ▶ eingebettete Prozessorkerne
- ▶ IO-Zellen
 - ▶ schnelle serielle Kommunikation
 - ▶ PLLs (programmierbare Taktgeneratoren)




FPGA: Field-Programmable Gate-Array (cont.)

- ▶ generierte Komponenten: ROM, RAM, FIFO...
- ▶ vorgefertigte IP-Blöcke („*Intellectual Property*“)
 - ▶ Netzwerkprotokolle
 - ▶ Speichercontroller
 - ▶ Bussysteme
 - ▶ ...
- ▶ Komplexität
 - ▶ $\approx 1\,200$ nutzbare I/O
 - ▶ ≈ 15 Mio. Gatteräquivalente (2 input NOR)
 - ▶ ≈ 1 GHz
- ▶ Xilinx, Altera, weitere Hersteller

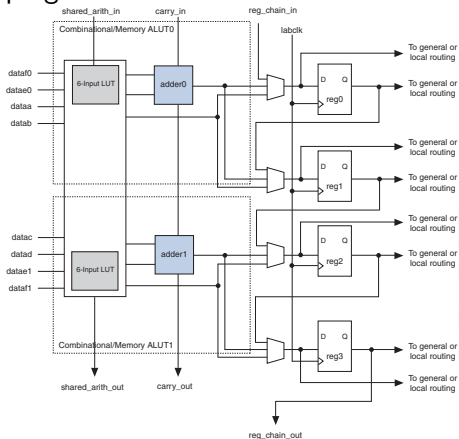
FPGA: Beispiel Altera

Verbindungsnetzwerk




FPGA: Beispiel Altera (cont.)

programmierbarer Block



FPGA: Beispiel Altera (cont.)



Prototypenplatine



Entwurf Integrierter Schaltungen

besonders anspruchsvoller Bereich der Informatik

- ▶ Halbleiterfertigung benötigt vorab sämtliche Geometriedaten
- ▶ spätere Änderungen eines Chips nicht möglich
- ▶ Durchlauf aller Fertigungsschritte dauert Wochen bis Monate
- ▶ Entwürfe müssen komplett fehlerfrei sein

- ▶ spezielle Hardware-/System-Beschreibungssprachen
- ▶ Simulation des Gesamtsystems
- ▶ Analyse des Zeitverhaltens
- ▶ ggf. Emulation/Prototyping mit FPGAs

- ▶ Kombination von Hardware- oder Softwarerealisierung von Teilfunktionen, sog. **HW/SW-Codesign**



Entwurfsablauf


Wasserfallmodell

- ▶ Lastenheft
- ▶ Verhaltensmodell (Software)
- ▶ Aufteilung in HW- und SW-Komponenten
- ▶ funktionale Simulation/Emulation und Test
- ▶ Synthese oder manueller Entwurf der HW, Floorplan
- ▶ Generieren der „Netzliste“ (logische Struktur)
- ▶ Simulation mit Überprüfung der Gatter-/Leitungslaufzeiten
- ▶ Generieren und Optimierung des Layouts („Tapeout“)

Abstraktion im VLSI-Entwurf


Abstraktionsebenen

- keine einheitliche Bezeichnung in der Literatur
- ▶ **Architekturebene**
 - ▶ Funktion/Verhalten Leistungsanforderungen
 - ▶ Struktur Netzwerk
aus Prozessoren, Speicher, Busse, Controller...
 - ▶ Nachrichten Programme, Protokolle
 - ▶ Geometrie Systempartitionierung




Abstraktion im VLSI-Entwurf (cont.)

- ▶ Hauptblockebene (Algorithmenebene, funktionale Ebene)
 - ▶ Funktion/Verhalten Algorithmen, formale Funktionsmodelle
 - ▶ Struktur Blockschaltbild
 - aus Hardwaremodule, Busse...
 - ▶ Nachrichten Protokolle
 - ▶ Geometrie Cluster



Abstraktion im VLSI-Entwurf (cont.)

- ▶ Register-Transfer Ebene
 - ▶ Funktion/Verhalten Daten- und Kontrollfluss, Automaten...
 - ▶ Struktur RT-Diagramm
aus Register, Multiplexer, ALUs...
 - ▶ Nachrichten Zahlencodierungen, Binärworte...
 - ▶ Geometrie Floorplan




Abstraktion im VLSI-Entwurf (cont.)

- ▶ Logikebene (Schaltwerkebene)
 - ▶ Funktion/Verhalten Boole'sche Gleichungen
 - ▶ Struktur
 aus Gatternetzliste, Schematic
 - Gatter, Flipflops, Latches...
 - ▶ Nachrichten Bit
 - ▶ Geometrie Moduln




Abstraktion im VLSI-Entwurf (cont.)

- ▶ elektrische Ebene (Schaltkreisebene)
 - ▶ Funktion/Verhalten Differentialgleichungen
 - ▶ Struktur elektrisches Schaltbild
 - aus Transistoren, Kondensatoren...
 - ▶ Nachrichten Ströme, Spannungen
 - ▶ Geometrie Polygone, Layout → physikalische Ebene

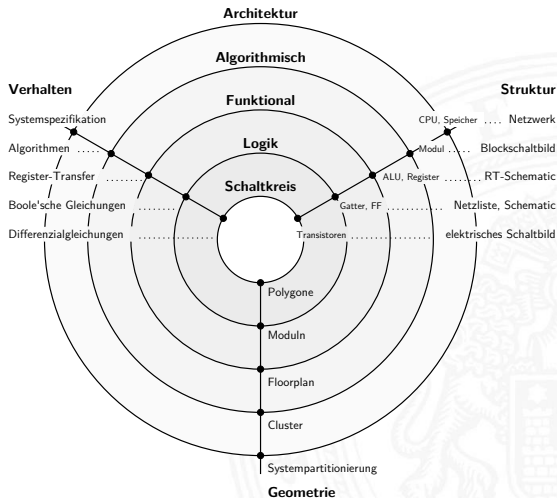


Abstraktion im VLSI-Entwurf (cont.)

- ▶ physikalische Ebene (geometrische Ebene)
 - ▶ Funktion/Verhalten partielle DGL
 - ▶ Struktur Dotierungsprofile



Y-Diagramm



D. Gajski, R. Kuhn 1983:
 „New VLSI Tools“



Y-Diagramm (cont.)

drei unterschiedliche Aspekte/Dimensionen:

- 1 Verhalten
 - 2 Struktur (logisch)
 - 3 Geometrie (physikalisch)
- ▶ Start möglichst abstrakt, z.B. als Verhaltensbeschreibung
 - ▶ Ende des Entwurfsprozesses ist vollständige IC Geometrie für die Halbleiterfertigung (Planarprozess)
 - ▶ Entwurfsprogramme („EDA“, *Electronic Design Automation*) unterstützen den Entwerfer: setzen Verhalten in Struktur und Struktur in Geometrien um



Entwurfstile


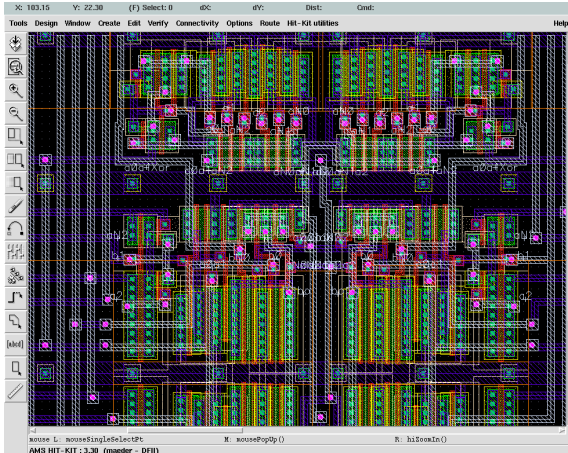
Was ist die „beste“ Realisierung einer gewünschten Funktionalität?

- ▶ mehrere konkurrierende Kriterien
 - ▶ Performance, Chipfläche, Stromverbrauch
 - ▶ Stückkosten vs. Entwurfsaufwand und Entwurfskosten
 - ▶ Zeitbedarf bis zur ersten Auslieferung und ggf. für Designänderungen
 - ▶ Schutz von Intellectual-Property
 - ▶ ...
- ▶ vier gängige Varianten
 - ▶ Full-custom Schaltungen
 - ▶ Semi-custom Bausteine: Standardzellen, Gate-Arrays
 - ▶ Anwenderprogrammierbare Bausteine: FPGA, PAL/GAL, ROM
 - ▶ Software auf von-Neumann Rechner: RAM, ROM

Full-custom / „Vollkunden-Entwurf“

- ▶ vollständiger Entwurf der gesamten Geometrie eines Chips
- ▶ jeder Transistor einzeln „maßgeschneidert“ und platziert
- ▶ vorgegeben sind lediglich die Entwurfsregeln (*design-rules*) des Herstellungsprozesses (Strukturbreite, Mindestabstände, usw.)
- ▶ oft Verwendung von Teilschaltungen/Makros des Herstellers
- ▶ minimale Fläche, beste Performance, kleinster Stromverbrauch
- ▶ geringste Stückkosten bei der Produktion
- ▶ aber höchste Entwurfs- und Maskenkosten
- ▶ erste Prototypen erst nach Durchlaufen aller Maskenschritte
- ▶ nur bei Massenprodukten wirtschaftlich \gg 100 000 Stück
z.B. Speicherbausteine (SRAM, DRAM), gängige Prozessoren

Full-custom / „Vollkunden-Entwurf“ (cont.)




Semi-custom: Standardzell-Entwurf


- ▶ Entwurf der Schaltung mit vorhandenen Grundkomponenten
 - ▶ Basisbibliothek mit Gattern und Flipflops
 - ▶ teilweise (konfigurierbare) ALUs, Multiplizierer
 - ▶ Generatoren für Speicher
- ▶ Entwurfsregeln sind der Bibliothek berücksichtigt
- ▶ Platzierung der Komponenten und Verdrahtung
- ▶ kleine Chipfläche, gute Performance, niedriger Stromverbrauch
- ▶ geringe Stückkosten
- ▶ hohe Maskenkosten (alle Masken erforderlich)
- ▶ erste Prototypen erst nach Durchlaufen aller Maskenschritte
- ▶ nur bei größeren Stückzahlen wirtschaftlich $\gg 10\,000$ Stück

Semi-custom: Standardzell-Entwurf (cont.)

Schematic




Zell-Layout



Semi-custom: Standardzell-Entwurf (cont.)

Standardzell Layout





Semi-custom: Gate-Arrays

- ▶ Schaltung mit Gattern/Transistoren an festen Positionen
- ▶ Entwurf durch Verdrahten der vorhandenen Transistoren
- ▶ überzählige Transistoren werden nicht angeschlossen

- ▶ mittlere Chipfläche, Performance und Stromverbrauch
- ▶ mittlere Stückkosten
- ▶ mittlere Maskenkosten (nur Verdrahtung kundenspezifisch)
- ▶ Prototypen schnell verfügbar (nur Verdrahtung)

- ▶ ab mittleren Stückzahlen wirtschaftlich $> 1\,000$ Stück
- ▶ werden von großen FPGAs verdrängt

FPGA: Field-Programmable Gate-Arrays

- ▶ Hunderte/Tausende von konfigurierbaren Funktionsblöcken
- ▶ Verschaltung dieser Blöcke vom Anwender programmierbar
- ▶ Entwurfsprogramme setzen Beschreibung des Anwenders auf die Hardware-Blöcke und deren Verschaltung um
- ▶ derzeit bis ca. 15 Mio. Gatter-Äquivalente möglich
- ▶ Taktfrequenzen bis max. GHz, typisch 100 MHz-Bereich
- ▶ zwei dominierende Hersteller: Xilinx, Altera

- ▶ nicht benutzte Blöcke liegen brach
- ▶ Schaltung kann in Minuten neu programmiert/verbessert werden

- ▶ optimal für geringe Stückzahlen, ca. 10...1 000 Stück



FPGA selbstgemacht: Projekt 64-189

Ideen für einen Mikrochip? Zum Beispiel für Bildverarbeitung, 3D-Algorithmen, Parallelverarbeitung, usw.

- ▶ Hereinschnuppern: *Projekt 64-189 Entwurf eines Mikrorechners*
 - ▶ eigenen Prozessor mit Befehlssatz etc. entwerfen und auf FPGA Prototypenplatine realisieren
 - ▶ Demo-Boards von Altera und Xilinx und Entwurfssoftware sind bei uns am Fachbereich verfügbar
- ⇒ einfach bei TAMS oder TIS vorbeischaun



Literatur: Quellen für die Abbildungen

- ▶ Andreas Mäder,
Vorlesung: Rechnerarchitektur und Mikrosystemtechnik,
Universität Hamburg, FB Informatik, 2010
tams.informatik.uni-hamburg.de/lectures/2010ws/vorlesung/ram
- ▶ Norbert Reifschneider,
CAE-gestützte IC-Entwurfsmethoden,
Prentice Hall, 1998
- ▶ Neil H. E. Weste, Kamran Eshragian,
Principles of CMOS VLSI Design — A Systems Perspective,
Addison-Wesley Publishing, 1994



Literatur: Vertiefung

- ▶ Reiner Hartenstein,
Standort Deutschland: Wozu noch Mikro-Chips,
IT-Press Verlag, 1994 (vergriffen)
- ▶ Gabriela Nicolescu, Pieter J. Mosterman,
Model-Based Design for Embedded Systems, CRC Press, 2010
- ▶ Carver Mead, Lynn Conway,
Introduction to VLSI Systems, Addison-Wesley, 1980
- ▶ Giovanni de Micheli,
Synthesis and Optimization of Digital Circuits,
McGraw-Hill, 1994
- ▶ Ulrich Tietze, Christoph Schenk,
Halbleiter-Schaltungstechnik, Springer-Verlag, 2009



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

- 14. Schaltwerke
- 15. Grundkomponenten für Rechensysteme
- 16. VLSI-Entwurf und -Technologie
- 17. Rechnerarchitektur**
 - Motivation
 - Beschreibungsebenen
 - Wie rechnet ein Rechner?
- 18. Instruction Set Architecture
- 19. Assembler-Programmierung
- 20. Computerarchitektur
- 21. Speicherhierarchie





Was ist Rechnerarchitektur?

Definitionen

1. *The term architecture is used here to describe the attributes of a system as seen by the programmer, i.e., the conceptual structure and functional behaviour, as distinct from the organization and data flow and control, the logical and the physical implementation. [Amdahl, Blaauw, Brooks]*
2. *The study of computer architecture is the study of the organization and interconnection of components of computer systems. Computer architects construct computers from basic building blocks such as memories, arithmetic units and buses.*



Was ist Rechnerarchitektur? (cont.)

From these building blocks the computer architect can construct anyone of a number of different types of computers, ranging from the smallest hand-held pocket-calculator to the largest ultra-fast super computer. The functional behaviour of the components of one computer are similar to that of any other computer, whether it be ultra-small or ultra-fast.

By this we mean that a memory performs the storage function, an adder does addition, and an input/output interface passes data from a processor to the outside world, regardless of the nature of the computer in which they are embedded. The major differences between computers lie in the way of the modules are connected together, and the way the computer system is controlled by the programs. In short, computer architecture is the discipline devoted to the design of highly specific and individual computers from a collection of common building blocks. [Stone]

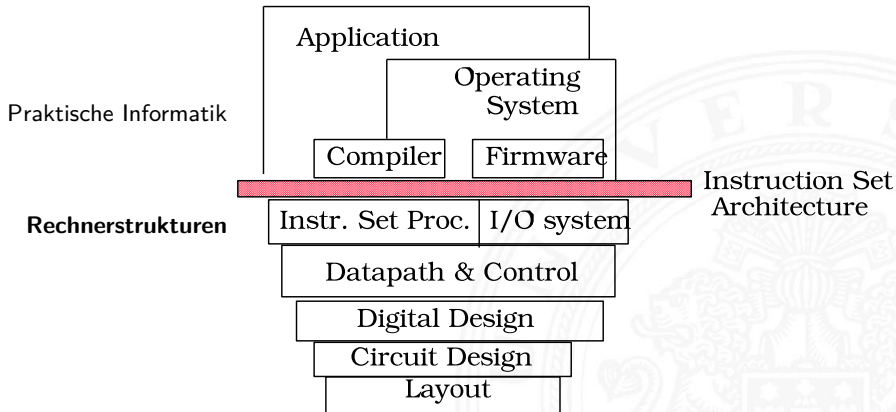


Was ist Rechnerarchitektur? (cont.)

Zwei Aspekte der Rechnerarchitektur


1. Operationsprinzip: das funktionelle Verhalten der Architektur
 - = Programmierschnittstelle
 - = ISA – **I**nstruction **S**et **A**rchitecture
Befehlssatzarchitektur
 - = Maschinenorganisation
2. Hardwarestruktur: beschrieben durch Art und Anzahl der Hardware-Betriebsmittel sowie die sie verbindenden Kommunikationseinrichtungen
 - = Implementierung: welche Einheiten, wie verbunden. . .
 - = beispielsweise „von-Neumann“ Architektur

Schnittstelle zur praktischen Informatik




Beschreibungsebenen


- ▶ Schichten-Ansicht: Software – Hardware



- ▶ Abstraktionen durch Betriebssystem



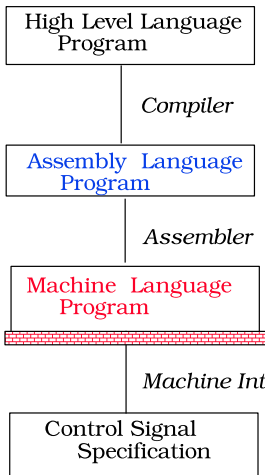
Das Kompilierungssystem



⇒ verschiedene Repräsentationen des Programms

- ▶ Hochsprache
- ▶ Assembler
- ▶ Maschinsprache

Das Kompilierungssystem (cont.)



```
temp = v[k];
v[k] = v[k+1];
v[k+1] = temp;
```

```
lw $15, 0($2)
lw $16, 4($2)
sw $16, 0($2)
sw $15, 4($2)
```

```
0000 1001 1100 0110 1010 1111 0101 1000
1010 1111 0101 1000 0000 1001 1100 0110
1100 0110 1010 1111 0101 1000 0000 1001
0101 1000 0000 1001 1100 0110 1010 1111
```

```
ALUOP[0:3] <= InstReg[9:11] & MASK
```

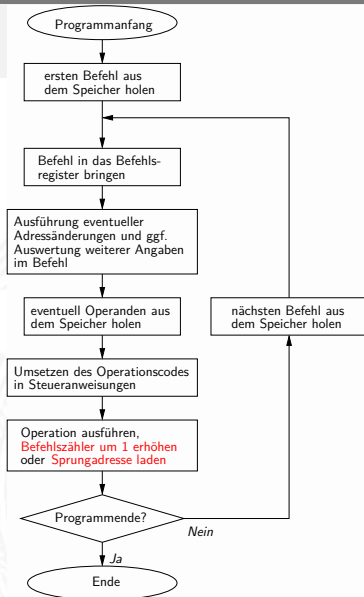


Wie rechnet ein Rechner?

- ▶ Architektur im Sinne von „Hardwarestruktur“
 beispielsweise als von-Neumann Architektur
 - ▶ „Choreografie“ der Funktionseinheiten?
 - ▶ wie kommuniziert man mit Rechnern?
 - ▶ was passiert beim Einschalten des Rechners?
- ▶ Erweiterungen des von-Neumann Konzepts
 - ▶ *parallele*, statt sequentieller Befehlsabarbeitung
 Stichwort: superskalare Prozessoren
 - ▶ dynamisch veränderte Abarbeitungsreihenfolge
 Stichwort: „*out-of-order execution*“
 - ▶ getrennte Daten- und Instruktionsspeicher
 Stichwort: *Harvard-Architektur*
 - ▶ *Speicherhierarchie*, Caches etc.

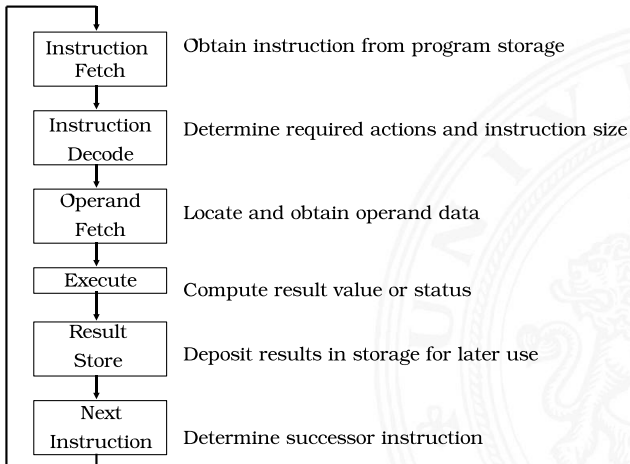
Programmverarbeitung

- ▶ von-Neumann Architektur
 - ▶ Programm als Sequenz elementarer Anweisungen (Befehle)
 - ▶ als Bitvektoren im Speicher codiert
 - ▶ Interpretation (Operanden, Befehle und Adressen) ergibt sich aus dem Kontext (der Adresse)
 - ▶ zeitsequenzielle Ausführung der Instruktionen

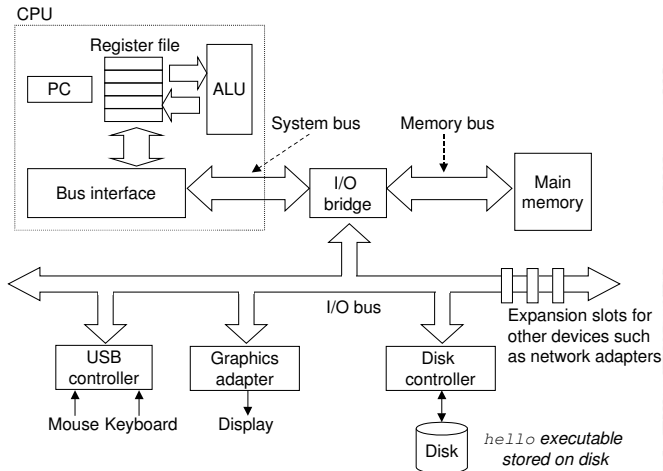


Programmverarbeitung (cont.)

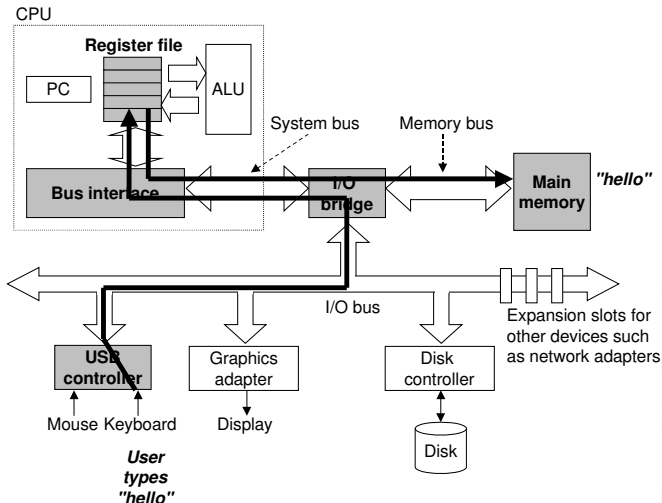
► Ausführungszyklus



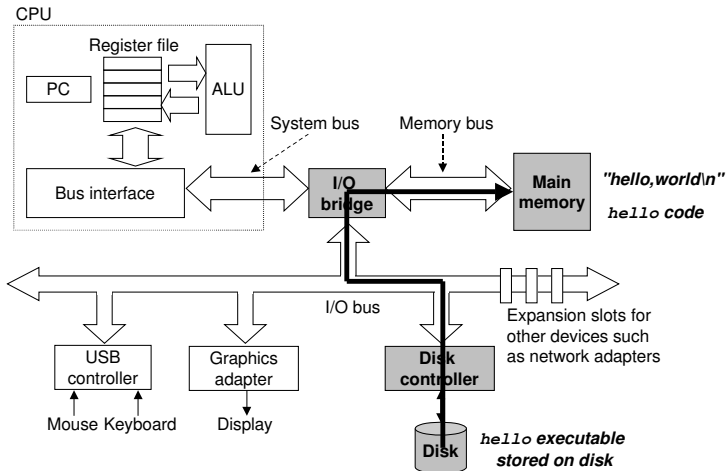
Hardwareorganisation eines typischen Systems



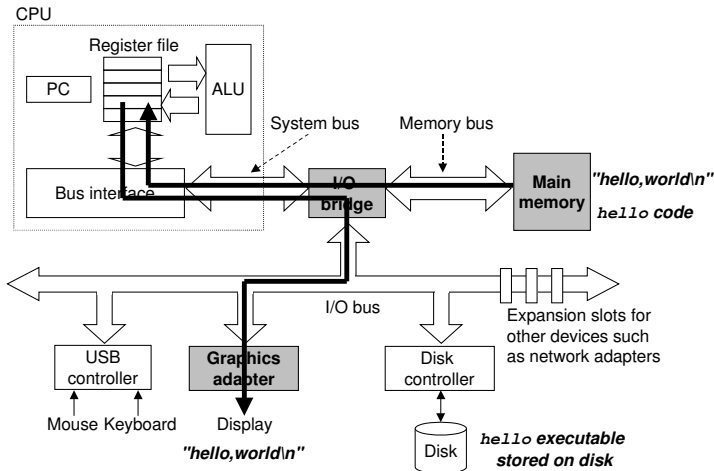
Programmausführung: 1. Benutzereingabe



Programmausführung: 2. Programm laden



Programmausführung: 3. Programmlauf





Boot-Prozess

Was passiert beim Einschalten des Rechners?

- ▶ Chipsatz erzeugt Reset-Signale für alle ICs
- ▶ Reset für die zentralen Prozessor-Register (PC, ...)
- ▶ PC wird auf Startwert initialisiert (z.B. 0xFFFF FFEF)
- ▶ Befehlszyklus wird gestartet
- ▶ Prozessor greift auf die Startadresse zu
dort liegt ein ROM mit dem Boot-Programm
- ▶ Initialisierung und Selbsttest des Prozessors
- ▶ Löschen und Initialisieren der Caches
- ▶ Konfiguration des Chipsatzes
- ▶ Erkennung und Initialisierung von I/O-Komponenten
- ▶ Laden des Betriebssystems



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

- 14. Schaltwerke
- 15. Grundkomponenten für Rechensysteme
- 16. VLSI-Entwurf und -Technologie
- 17. Rechnerarchitektur
- 18. Instruction Set Architecture**
 - Speicherorganisation
 - Befehlssatz
 - Befehlsformate
 - Adressierungsarten
 - Intel x86-Architektur
- 19. Assembler-Programmierung
- 20. Computerarchitektur
- 21. Speicherhierarchie





Befehlssatzarchitektur – ISA

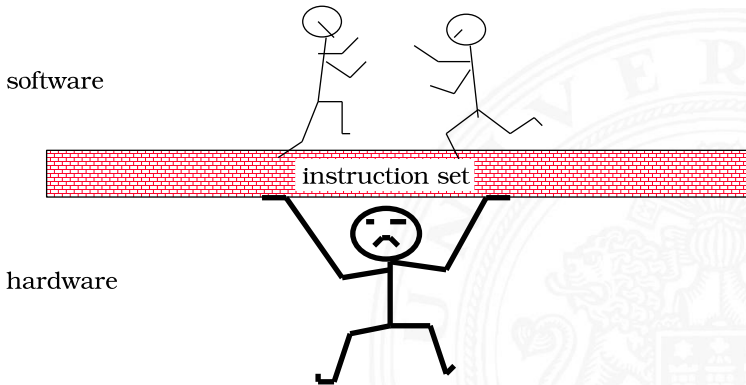
ISA – **I**nstruction **S**et **A**rchitecture

⇒ alle für den Programmierer sichtbaren Attribute eines Rechners

- ▶ der (konzeptionellen) Struktur
 - ▶ Funktionseinheiten der Hardware:
Recheneinheiten, Speichereinheiten, Verbindungssysteme, ...
- ▶ des Verhaltens
 - ▶ Organisation des programmierbaren Speichers
 - ▶ Datentypen und Datenstrukturen: Codierungen und Darstellungen
 - ▶ Befehlssatz
 - ▶ Befehlsformate
 - ▶ Modelle für Befehls- und Datenzugriffe
 - ▶ Ausnahmebedingungen

Befehlssatzarchitektur – ISA (cont.)

- ▶ Befehlssatz: die zentrale Schnittstelle





Merkmale der Instruction Set Architecture

- | | |
|---|--|
| ▶ Speichermodell | Wortbreite, Adressierung, ... |
| ▶ Rechnerklasse | Stack-/Akku-/Registermaschine |
| ▶ Registersatz | Anzahl und Art der Rechenregister |
| ▶ Befehlssatz | Definition aller Befehle |
| ▶ Art, Zahl der Operanden | Anzahl/Wortbreite/Reg./Speicher |
| ▶ Ausrichtung der Daten | Alignment/Endianness |
| ▶ Ein- und Ausgabe, Unterbrechungsstruktur (Interrupts) | |
| ▶ Systemsoftware | Loader, Assembler,
Compiler, Debugger |

Artenvielfalt von „Embedded Architekturen“



Prozessor	4..32 bit	8 bit	-	16..32 bit	32 bit	32 bit	32 bit	8..64 bit	..32 bit
Speicher	1K..1M	< 8K	< 1K	1..64M	1..64M	< 512M	8..64M	1K..10M	< 64M
ASICs	1 uC	1 uC	1 ASIC	1 uP ASIP	DSPs	1 uP, 3 DSP	1 uP, DSP	~ 100 uC, uP, DSP	uP, ASIP
Netzwerk	cardIO	-	RS232	diverse	GSM	MIDI	V.90	CAN,...	I2C,...
Echtzeit	nein	nein	soft	soft	hard	soft	hard	hard	hard
Safety	keine	mittel	keine	gering	gering	gering	gering	hoch	hoch

- ▶ riesiges Spektrum: 4..64 bit Prozessoren, DSPs, digitale/analoge ASICs, ...
- ▶ Sensoren/Aktoren: Tasten, Displays, Druck, Temperatur, Antennen, CCD, ...
- ▶ Echtzeit-, Sicherheits-, Zuverlässigkeitsanforderungen

Speicherorganisation

- ▶ Wortbreite, Größe / Speicherkapazität
- ▶ „Big Endian“ / „Little Endian“
- ▶ „Alignment“
- ▶ „Memory-Map“
- ▶ Beispiel: PC mit Windows

- ▶ spätere Themen
 - ▶ Cache-Organisation für schnelleren Zugriff
 - ▶ Virtueller Speicher für Multitasking
 - ▶ MESI-Protokoll für Multiprozessorsysteme
 - ▶ Synchronisation in Multiprozessorsystemen



Wortbreite

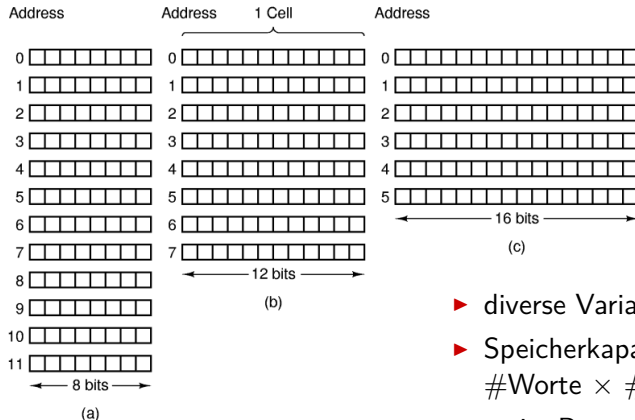
- ▶ Speicherwortbreiten historisch wichtiger Computer

Computer	Bits/cell
Burroughs B1700	1
IBM PC	8
DEC PDP-8	12
IBM 1130	16
DEC PDP-15	18
XDS 940	24
Electrologica X8	27
XDS Sigma 9	32
Honeywell 6180	36
CDC 3600	48
CDC Cyber	60

- ▶ heute dominieren 8/16/32/64-bit Systeme
- ▶ erlaubt 8-bit ASCII, 16-bit Unicode, 32-/64-bit Floating-Point
- ▶ Beispiel x86: „byte“, „word“, „double word“, „quad word“


Hauptspeicherorganisation

Drei Organisationsformen eines 96-bit Speichers




- ▶ diverse Varianten möglich
- ▶ Speicherkapazität:
 $\# \text{Worte} \times \# \text{Bits/Wort}$
- ▶ meist Byte-adressiert

Big- vs. Little Endian



- ▶ Anordnung einzelner Bytes in einem Wort (hier 32 bit)
 - ▶ Big Endian: MSB kommt zuerst, gut für Strings
 - ▶ Little Endian: LSB kommt zuerst, gut für Zahlen
- ▶ beide Varianten haben Vor- und Nachteile
- ▶ ggf. Umrechnung zwischen beiden Systemen notwendig

„Misaligned“ Zugriff



- ▶ Beispiel: 8-Byte-Wort in Little Endian Speicher
 - (a) „aligned“ bezüglich Speicherwort
 - (b) „nonaligned“ an Byte-Adresse 12
- ▶ Speicher wird (meistens) Byte-weise adressiert
 aber Zugriffe lesen/schreiben jeweils ein ganzes Wort
- ⇒ was passiert bei „krummen“ (misaligned) Adressen?
 - ▶ automatische Umsetzung auf mehrere Zugriffe (x86)
 - ▶ Programmabbruch (MIPS)



Memory Map

- ▶ CPU kann im Prinzip alle möglichen Adressen ansprechen
 - ▶ in der Regel: **kein voll ausgebauter Speicher**
32 bit Adresse entsprechen 4 GiB Hauptspeicher, 64 bit ...
 - ▶ Aufteilung in RAM und ROM-Bereiche
 - ▶ ROM mindestens zum Booten notwendig
 - ▶ zusätzliche Speicherbereiche für „memory mapped“ I/O
- ⇒ „Memory Map“
- ▶ Adressdecoder
 - ▶ Hardwareeinheit
 - ▶ Zuordnung von Adressen zu „realem“ Speicher

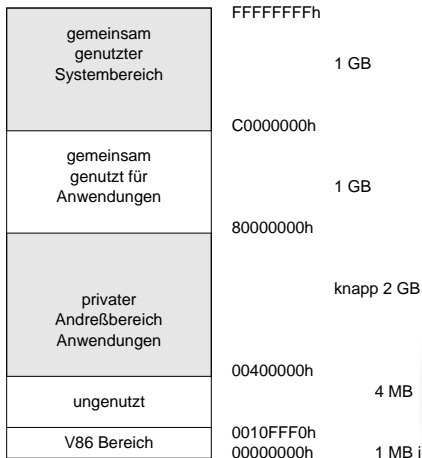


Memory Map: typ. 16-bit System

- ▶ 16-bit erlaubt 64K Adressen: 0x0000...0xFFFF
- ▶ ROM-Bereich für Boot / Betriebssystemkern
- ▶ RAM-Bereich für Hauptspeicher
- ▶ RAM-Bereich für Interrupt-Tabelle
- ▶ I/O-Bereiche für serielle / parallel Schnittstellen
- ▶ I/O-Bereiche für weitere Schnittstellen

Demo und Beispiele: im Praktikum (64-042)

Memory Map: Windows 9x



- ▶ DOS-Bereich immer noch für Boot / Geräte (VGA) reserviert
- ▶ Kernel, Treiber, usw. im oberen 1 GiB-Bereich
- ▶ 2 GiB für Anwendungen

Memory Map: Windows 9x (cont.)

[00000000 - 0009FFFF]	Systemplatine
[000A0000 - 000BFFFF]	Intel(R) Q963/Q965 PCI Express Root Port - 2991
[000A0000 - 000BFFFF]	PCI-Bus
[000A0000 - 000BFFFF]	Radeon X1300/X1550 Series
[000C0000 - 000D3FFF]	Systemplatine
[000C0000 - 000EFFFF]	PCI-Bus
[000F0000 - 000FFFFFF]	PCI-Bus
[000F0000 - 000FFFFFF]	Systemplatine
[00100000 - 00FFFFFF]	Systemplatine
[01000000 - 7FDFFBFF]	Systemplatine
[80000000 - DFFFFFFF]	PCI-Bus
[C0000000 - CFFFFFFF]	Intel(R) Q963/Q965 PCI Express Root Port - 2991
[C0000000 - CFFFFFFF]	Radeon X1300/X1550 Series

- ▶ 32-bit Adressen, 4 GiByte Adressraum
- ▶ Aufteilung 2 GiB für Programme, obere 1+1 GiB für Windows
- ▶ Beispiel der Zuordnung, diverse Bereiche für I/O reserviert

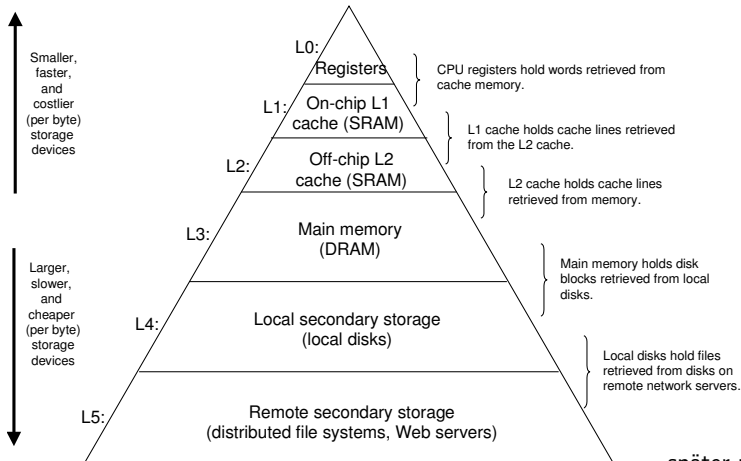
Memory Map: Windows 9x (cont.)

I/O-Speicherbereiche

	[00000378 - 0000037F] ECP-Druckeranschluss (LPT1)
	[00000380 - 000003BB] Hauptplatinenressourcen
	[00000380 - 000003BB] Intel(R) Q963/Q965 PCI Express Root Port - 2991
	[00000380 - 000003BB] Radeon X1300/X1550 Series
	[000003C0 - 000003DF] Intel(R) Q963/Q965 PCI Express Root Port - 2991
	[000003C0 - 000003DF] Radeon X1300/X1550 Series
	[000003C0 - 000003E7] Hauptplatinenressourcen
	[000003F0 - 000003F5] Standard-Diskettenlaufwerkcontroller
	[000003F6 - 000003F7] Hauptplatinenressourcen
	[000003F7 - 000003F7] Standard-Diskettenlaufwerkcontroller
	[000003F8 - 000003FF] Kommunikationsanschluss (COM1)
	[00000400 - 000004CF] Hauptplatinenressourcen
	[000004D0 - 000004D1] Programmierbarer Interruptcontroller

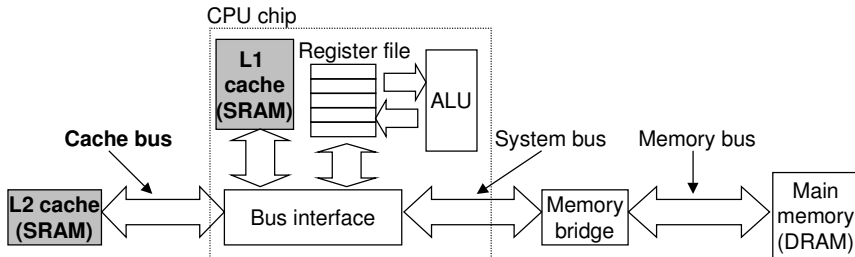
- ▶ x86 I/O-Adressraum gesamt nur 64 KiByte
- ▶ je nach Zahl der I/O-Geräte evtl. fast voll ausgenutzt
- ▶ Adressen vom BIOS zugeteilt

Speicherhierarchie



später mehr...

Cache-Speicher



- ▶ verschiedene Strategien
 - ▶ Welche Daten sollen in Cache?
 - ▶ Welche werden aus Cache entfernt?
- ▶ Abbildungsvorschriften (direct-mapped, n-fach assoziativ)
- ▶ Organisationsformen

Der Speicher ist wichtig

- ▶ Speicher ist nicht unbegrenzt
 - ▶ muss zugeteilt und verwaltet werden
 - ▶ viele Anwendungen werden vom Speicher dominiert
- ▶ Fehler, die auf Speicher verweisen, sind besonders gefährlich
 - ▶ Auswirkungen sind sowohl zeitlich als auch räumlich entfernt
- ▶ Speicherleistung ist nicht gleichbleibend
Wechselwirkungen: Speichersystem \Leftrightarrow Programme
 - ▶ „Cache“- und „Virtual“-Memory Auswirkungen können Performance/Programmleistung stark beeinflussen
 - ▶ Anpassung des Programms an das Speichersystem kann Geschwindigkeit bedeutend verbessern



ISA-Merkmale des Prozessors

- ▶ Befehlszyklus
- ▶ Befehlsklassen
- ▶ Registermodell
- ▶ n-Adress Maschine
- ▶ Adressierungsarten



Befehlszyklus

- ▶ Prämisse: von-Neumann Prinzip
 - ▶ Daten und Befehle im gemeinsamen Hauptspeicher
- ▶ Abarbeitung des Befehlszyklus in Endlosschleife
 - ▶ Programmzähler PC adressiert den Speicher
 - ▶ gelesener Wert kommt in das Befehlsregister IR
 - ▶ Befehl decodieren
 - ▶ Befehl ausführen
 - ▶ nächsten Befehl auswählen
- ▶ minimal benötigte Register

PC	Program Counter	Adresse des Befehls
IR	Instruction Register	aktueller Befehl
R0. . . R31	Registerbank	Rechenregister (Operanden)



Instruction Fetch

„Befehl holen“ Phase im Befehlszyklus

1. Programmzähler (PC) liefert Adresse für den Speicher
 2. Lesezugriff auf den Speicher
 3. Resultat wird im Befehlsregister (IR) abgelegt
 4. Programmzähler wird inkrementiert
- ▶ Beispiel für 32 bit RISC mit 32 bit Befehlen
 - ▶ $IR = MEM[PC]$
 - ▶ $PC = PC + 4$
 - ▶ bei CISC-Maschinen evtl. weitere Zugriffe notwendig, abhängig von der Art (und Länge) des Befehls



Instruction Decode

„Befehl decodieren“ Phase im Befehlszyklus

- ▷ Befehl steht im Befehlsregister IR
- 1. Decoder entschlüsselt Opcode und Operanden
- 2. leitet Steuersignale an die Funktionseinheiten
- 3. Programmzähler wird inkrementiert



Instruction Execute

„Befehl ausführen“ Phase im Befehlszyklus

- ▷ Befehl steht im Befehlsregister IR
- ▷ Decoder hat Opcode und Operanden entschlüsselt
- ▷ Steuersignale liegen an Funktionseinheiten
- 1. Ausführung des Befehls durch Aktivierung der Funktionseinheiten
 - ▶ Details abhängig von der Art des Befehls
 - ▶ Ausführungszeit —
 - ▶ Realisierung
 - ▶ fest verdrahtete Hardware
 - ▶ mikroprogrammiert

Welche Befehle braucht man?

Befehlsklassen

- ▶ arithmetische Operationen
 - logische Operationen
 - schiebe Operationen
- ▶ Vergleichsoperationen
- ▶ Datentransfers
- ▶ Programm-Kontrollfluss
- ▶ Maschinensteuerung

Beispiele

add, sub, inc, dec, mult, div
 and, or, xor
 shl, sra, srl, ror
 cmpeq, cmpgt, cmplt
 load, store, I/O
 jump, jmqeq, branch, call, return
 trap, halt, (interrupt)

CISC – Complex Instruction Set Computer

- ▶ Computer-Architekturen mit irregulärem, komplexem Befehlssatz
- ▶ typische Merkmale
 - ▶ sehr viele Befehle, viele Datentypen
 - ▶ komplexe Befehlskodierung, Befehle variabler Länge
 - ▶ viele Adressierungsarten
 - ▶ Mischung von Register- und Speicheroperanden
 - ⇒ komplexe Befehle mit langer Ausführungszeit
 - Problem: Compiler benutzen solche Befehle gar nicht
- ▶ Motivation
 - ▶ aus der Zeit der ersten Großrechner, 60er Jahre
 - ▶ Assemblerprogrammierung: Komplexität durch viele (mächtige) Befehle umgehen
- ▶ Beispiele: Intel 80x86, Motorola 68K, DEC Vax



RISC – Reduced Instruction Set Computer

- ▶ Oberbegriff für moderne Rechnerarchitekturen entwickelt ab ca. 1980 bei IBM, Stanford, Berkeley
- ▶ auch bekannt unter: „Regular Instruction Set Computer“
- ▶ typische Merkmale
 - ▶ reguläre Struktur, z.B. 32-bit Wortbreite, 32-bit Befehle
 - ▶ nur ein-Wort Befehle
 - ▶ alle Befehle in einem Taktschritt ausführbar
 - ▶ „Load-Store“ Architektur, keine Speicheroperanden
 - ▶ viele universelle Register, keine Spezialregister
 - ▶ optimierende Compiler statt Assemblerprogrammierung
- ▶ Beispiele: IBM 801, MIPS, SPARC, DEC Alpha, ARM
- ▶ Diskussion und Details CISC vs. RISC später



Befehls-Decodierung


- ▷ Befehlsregister IR enthält den aktuellen Befehl
- ▷ z.B. einen 32-bit Wert

0	1	0	0	1	1	1	0	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0
															31																0			

Wie soll die Hardware diesen Wert interpretieren?

- ▶ direkt in einer Tabelle nachschauen (Mikrocode-ROM)
- ▶ Problem: Tabelle müsste 2^{32} Einträge haben
- ⇒ Aufteilung in Felder: Opcode und Operanden
- ⇒ Decodierung über mehrere, kleine Tabellen
- ⇒ unterschiedliche Aufteilung für unterschiedliche Befehle:
Befehlsformate

Befehlsformate



- ▶ Befehlsformat: Aufteilung in mehrere Felder
 - ▶ Opcode eigentlicher Befehl
 - ▶ ALU-Operation add/sub/incr/shift/usw.
 - ▶ Register-Indizes Operanden / Resultat
 - ▶ Speicher-Adressen für Speicherzugriffe
 - ▶ Immediate-Operanden Werte direkt im Befehl
- ▶ Lage und Anzahl der Felder abhängig vom Befehlssatz



Befehlsformat: drei Beispielarchitekturen

- ▶ MIPS: Beispiel für 32-bit RISC Architekturen
 - ▶ alle Befehle mit 32-bit codiert
 - ▶ nur 3 Befehlsformate (R, I, J)
- ▶ D*CORE: Beispiel für 16-bit Architektur
 - ▶ siehe RS-Praktikum (64-042) für Details
- ▶ Intel x86: Beispiel für CISC-Architekturen
 - ▶ irreguläre Struktur, viele Formate
 - ▶ mehrere Codierungen für einen Befehl
 - ▶ 1-Byte. . . 36-Bytes pro Befehl

Befehlsformat: Beispiel MIPS

- ▶ festes Befehlsformat
 - ▶ alle Befehle sind 32 Bit lang
- ▶ Opcode-Feld ist immer 6-bit breit
 - ▶ codiert auch verschiedene Adressierungsmodi

wenige Befehlsformate

- ▶ R-Format
 - ▶ Register-Register ALU-Operationen
- ▶ I-/J-Format
 - ▶ Lade- und Speicheroperationen
 - ▶ alle Operationen mit unmittelbaren Operanden
 - ▶ Jump-Register
 - ▶ Jump-and-Link-Register



MIPS: Übersicht

„Microprocessor without Interlocked Pipeline Stages“

- ▶ entwickelt an der Univ. Stanford, seit 1982
- ▶ Einsatz: eingebettete Systeme, SGI Workstations/Server

- ▶ klassische 32-bit RISC Architektur
- ▶ 32-bit Wortbreite, 32-bit Speicher, 32-bit Befehle
- ▶ 32 Register: R0 ist konstant Null, R1...R31 Universalregister
- ▶ Load-Store Architektur, nur base+offset Adressierung

- ▶ sehr einfacher Befehlssatz, 3-Adress-Befehle
- ▶ keinerlei HW-Unterstützung für „komplexe“ SW-Konstrukte
- ▶ SW muss sogar HW-Konflikte („Hazards“) vermeiden
- ▶ Koprozessor-Konzept zur Erweiterung

MIPS: Registermodell

- ▶ 32 Register, R0...R31, jeweils 32-bit
- ▶ R1 bis R31 sind Universalregister
- ▶ R0 ist konstant Null (ignoriert Schreiboperationen)
 - ▶ R0 Tricks

$R5 = -R5$	<code>sub</code>	<code>R5, R0, R5</code>
$R4 = 0$	<code>add</code>	<code>R4, R0, R0</code>
$R3 = 17$	<code>addi</code>	<code>R3, R0, 17</code>
$\text{if } (R2 == 0)$	<code>bne</code>	<code>R2, R0, label</code>
- ▶ keine separaten Statusflags
- ▶ Vergleichsoperationen setzen Zielregister auf 0 bzw. 1

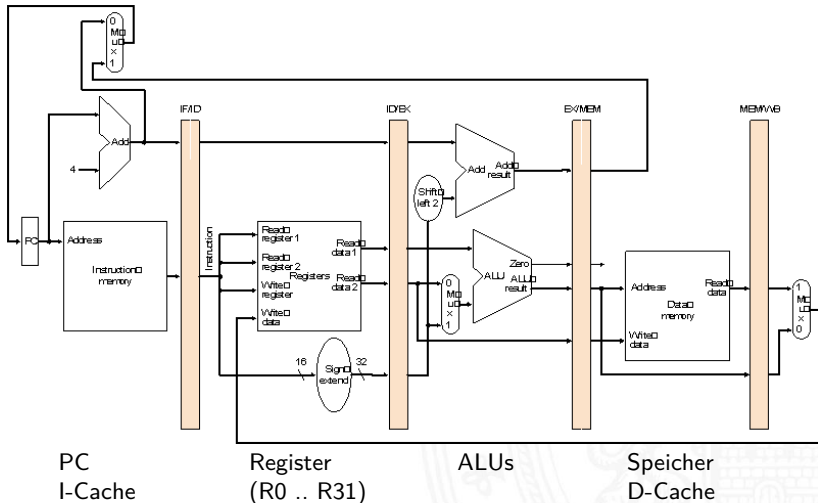
$R1 = (R2 < R3)$	<code>slt</code>	<code>R1, R2, R3</code>
------------------	------------------	-------------------------



MIPS: Befehlssatz


- ▶ Übersicht und Details: David A. Patterson, John L. Hennessy, *Computer Organization and Design : the hardware/software interface*
- ▶ dort auch hervorragende Erläuterung der Hardwarestruktur
- ▶ klassische fünf-stufige Befehlspipeline
 - ▶ Instruction-Fetch Befehl holen
 - ▶ Decode Decodieren und Operanden holen
 - ▶ Execute ALU-Operation oder Adressberechnung
 - ▶ Memory Speicher lesen oder schreiben
 - ▶ Write-Back Resultat in Register speichern

MIPS: Hardwarestruktur



Befehlsformat: Beispiel MIPS


Befehl im R-Format



- ▶ op: Opcode Typ des Befehls 0 = „alu-op“
 - rs: source register 1 erster Operand 23 = „r23“
 - rt: source register 2 zweiter Operand 30 = „r30“
 - rd: destination register Zielregister 3 = „r3“
 - shift: shift amount (optionales Shiften) 0 = „0“
 - funct: ALU function Rechenoperation 34 = „sub“
- ⇒ r3 = r23 - r30 sub r3, r23, r30

Befehlsformat: Beispiel MIPS

Befehl im I-Format



- | | | | |
|-------|----------------------|-----------------|-----------|
| ▶ op: | Opcode | Typ des Befehls | 35 = „lw“ |
| rs: | destination register | Zielregister | 8 = „r8“ |
| rt: | base register | Basisadresse | 5 = „r5“ |
| addr: | address offset | Offset | 6 = „6“ |
- ⇒ $r8 = \text{MEM}[r5 + \text{addr}]$
- lw r8, addr(r5)

Befehlsformat: Beispiel M*CORE



- ▶ 32-bit RISC Architektur, Motorola 1998
- ▶ besonders einfaches Programmiermodell
 - ▶ Program Counter PC
 - ▶ 16 Universalregister R0...R15
 - ▶ Statusregister C („carry flag“)
 - ▶ 16-bit Befehle (um Programmspeicher zu sparen)
- ▶ Verwendung
 - ▶ häufig in Embedded-Systems
 - ▶ „smart cards“




D*CORE

- ▶ ähnlich M*CORE
- ▶ gleiches Registermodell, aber nur 16-bit Wortbreite
 - ▶ Program Counter PC
 - ▶ 16 Universalregister R0...R15
 - ▶ Statusregister C („carry flag“)
- ▶ Subset der Befehle, einfachere Codierung
- ▶ vollständiger Hardwareaufbau in Hades verfügbar oder Simulator mit Assembler (winT3asm.exe / t3asm.jar)




D*CORE: Registermodell



- 16 Universalregister
- Programmzähler
- 1 Carry-Flag



- Befehlsregister



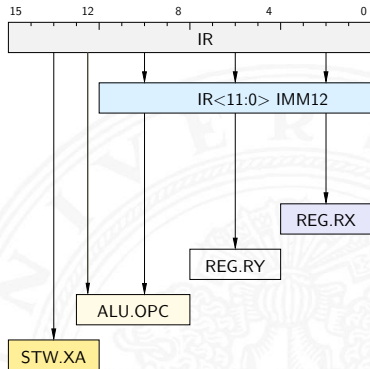
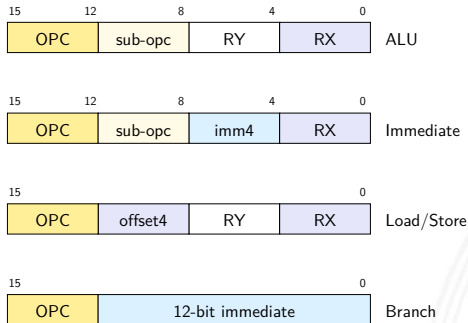
- Bus-Interface

▶ sichtbar für Programmierer: R0...R15, PC und C

D*CORE: Befehlssatz

mov	move register
addu, addc	Addition (ohne, mit Carry)
subu	Subtraktion
and, or xor	logische Operationen
lsl, lsr, asr	logische, arithmetische Shifts
cmpe, cmpne, ...	Vergleichsoperationen
movi, addi, ...	Operationen mit Immediate-Operanden
ldw, stw	Speicherzugriffe, load/store
br, jmp	unbedingte Sprünge
bt, bf	bedingte Sprünge
jsr	Unterprogrammaufruf
trap	Software interrupt
rfi	return from interrupt

D*CORE: Befehlsformate



- ▶ 4-bit Opcode, 4-bit Registeradressen
- ▶ einfaches Zerlegen des Befehls in die einzelnen Felder



Adressierungsarten

- ▶ Woher kommen die Operanden / Daten für die Befehle?
 - ▶ Hauptspeicher, Universalregister, Spezialregister
 - ▶ Wie viele Operanden pro Befehl?
 - ▶ 0- / 1- / 2- / 3-Adress-Maschinen
 - ▶ Wie werden die Operanden adressiert?
 - ▶ immediate / direkt / indirekt / indiziert / autoinkrement / usw.
- ⇒ wichtige Unterscheidungsmerkmale für Rechnerarchitekturen
- ▶ Zugriff auf Hauptspeicher: $\approx 100\times$ langsamer als Registerzugriff
 - ▶ möglichst Register statt Hauptspeicher verwenden (!)
 - ▶ „load/store“-Architekturen

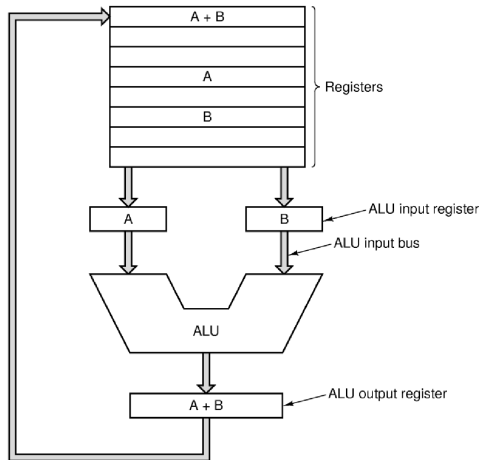


Beispiel: Add-Befehl

- ▷ Rechner soll „rechnen“ können
- ▷ typische arithmetische Operation nutzt 3 Variablen
Resultat, zwei Operanden: $X = Y + Z$
add r2, r4, r5 reg2 = reg4 + reg5
„addiere den Inhalt von R4 und R5
und speichere das Resultat in R2“
- ▶ woher kommen die Operanden?
- ▶ wo soll das Resultat hin?
 - ▶ Speicher
 - ▶ Register
- ▶ entsprechende Klassifikation der Architektur

Datenpfad

- ▶ Register (-bank)
 - ▶ liefern Operanden
 - ▶ speichern Resultate
- ▶ interne Hilfsregister
- ▶ ALU, typ. Funktionen:
 - ▶ add, add-carry, sub
 - ▶ and, or, xor
 - ▶ shift, rotate
 - ▶ compare
 - ▶ (floating point ops.)



Woher kommen die Operanden?



- ▶ typische Architektur
 - ▶ von-Neumann Prinzip: alle Daten im Hauptspeicher
 - ▶ 3-Adress-Befehle: zwei Operanden, ein Resultat

⇒ „Multiport-Speicher“: mit drei Ports?

- ▶ sehr aufwändig, extrem teuer, trotzdem langsam

⇒ Register im Prozessor zur Zwischenspeicherung!

- ▶ Datentransfer zwischen Speicher und Registern
 - Load* $reg = MEM[addr]$
 - Store* $MEM[addr] = reg$
- ▶ RISC: Rechenbefehle arbeiten *nur* mit Registern
- ▶ CISC: gemischt, Operanden in Registern oder im Speicher



n-Adress Maschine $n = \{3 \dots 0\}$

- 3-Adress Format
 - ▶ $X = Y + Z$
 - ▶ sehr flexibel, leicht zu programmieren
 - ▶ Befehl muss 3 Adressen codieren
- 2-Adress Format
 - ▶ $X = X + Z$
 - ▶ eine Adresse doppelt verwendet:
für Resultat und einen Operanden
 - ▶ Format wird häufig verwendet
- 1-Adress Format
 - ▶ $ACC = ACC + Z$
 - ▶ alle Befehle nutzen das Akkumulator-Register
 - ▶ häufig in älteren / 8-bit Rechnern
- 0-Adress Format
 - ▶ $TOS = TOS + NOS$
 - ▶ Stapelspeicher: *top of stack, next of stack*
 - ▶ Adressverwaltung entfällt
 - ▶ im Compilerbau beliebt



Beispiel: n-Adress Maschine

Beispiel: $Z = (A-B) / (C + D * E)$

Hilfsregister: T

3-Adress-Maschine

```
sub Z, A, B
mul T, D, E
add T, T, C
div Z, Z, T
```

2-Adress-Maschine

```
mov Z, A
sub Z, B
mov T, D
mul T, E
add T, C
div Z, T
```

1-Adress-Maschine

```
load D
mul E
add C
stor Z
load A
sub B
div Z
stor Z
```

0-Adress-Maschine

```
push D
push E
mul
push C
add
push A
push B
sub
div
pop Z
```



Beispiel: Stack-Maschine / 0-Adress Maschine

Beispiel: $Z = (A-B) / (C + D * E)$

0-Adress-Maschine

push D

push E

mul

push C

add


push A

push B

sub

div

pop Z



Adressierungsarten

- ▶ „immediate“
 - ▶ Operand steht direkt im Befehl
 - ▶ kein zusätzlicher Speicherzugriff
 - ▶ aber Länge des Operanden beschränkt
- ▶ „direkt“
 - ▶ Adresse des Operanden steht im Befehl
 - ▶ keine zusätzliche Adressberechnung
 - ▶ ein zusätzlicher Speicherzugriff
 - ▶ Adressbereich beschränkt
- ▶ „indirekt“
 - ▶ Adresse eines Pointers steht im Befehl
 - ▶ erster Speicherzugriff liest Wert des Pointers
 - ▶ zweiter Speicherzugriff liefert Operanden
 - ▶ sehr flexibel (aber langsam)



Adressierungsarten (cont.)

- ▶ „register“
 - ▶ wie Direktmodus, aber Register statt Speicher
 - ▶ 32 Register: benötigen 5 bit im Befehl
 - ▶ genug Platz für 2- oder 3-Adress Formate
- ▶ „register-indirekt“
 - ▶ Befehl spezifiziert ein Register
 - ▶ mit der Speicheradresse des Operanden
 - ▶ ein zusätzlicher Speicherzugriff
- ▶ „indiziert“
 - ▶ Angabe mit Register und Offset
 - ▶ Inhalt des Registers liefert Basisadresse
 - ▶ Speicherzugriff auf (Basisadresse+offset)
 - ▶ ideal für Array- und Objektzugriffe
 - ▶ Hauptmodus in RISC-Rechnern (auch: „Versatz-Modus“)


Immediate-Adressierung



1-Wort Befehl

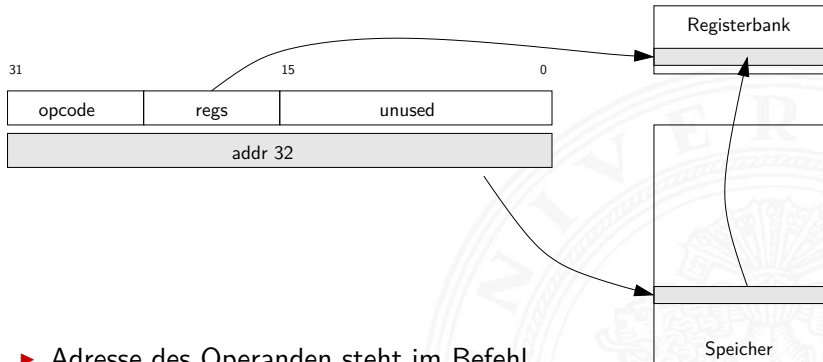


2-Wort Befehl



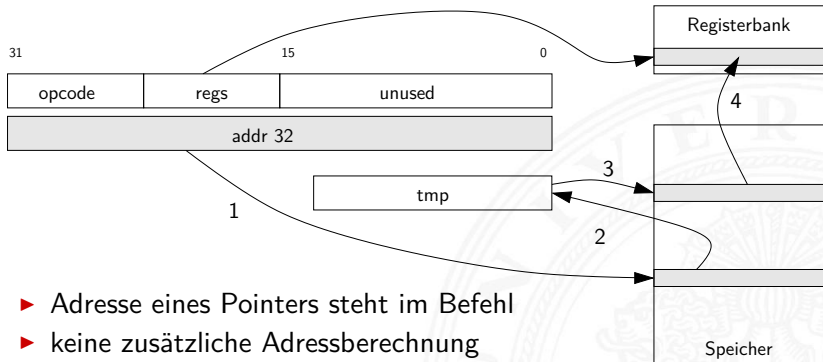
- ▶ Operand steht direkt im Befehl, kein zusätzlicher Speicherzugriff
- ▶ Länge des Operanden $<$ (Wortbreite - Opcodebreite)
- ▶ Darstellung größerer Zahlenwerte
 - ▶ 2-Wort Befehle (x86)
zweites Wort für Immediate-Wert
 - ▶ mehrere Befehle (MIPS, SPARC)
z.B. obere/untere Hälfte eines Wortes
 - ▶ Immediate-Werte mit zusätzlichem Shift (ARM)

Direkte Adressierung



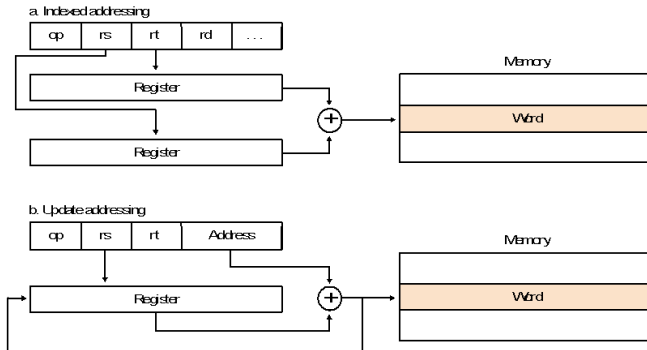
- ▶ Adresse des Operanden steht im Befehl
- ▶ keine zusätzliche Adressberechnung
- ▶ ein zusätzlicher Speicherzugriff: z.B. $R3 = \text{MEM}[\text{addr}32]$
- ▶ Adressbereich beschränkt, oder 2-Wort Befehl (wie Immediate)

Indirekte Adressierung



- ▶ Adresse eines Pointers steht im Befehl
- ▶ keine zusätzliche Adressberechnung
- ▶ zwei zusätzliche Speicherzugriffe:
z.B. `tmp = MEM[addr32 ; R3 = MEM[tmp]`
- ▶ typische CISC-Adressierungsart, viele Taktzyklen
- ▶ kommt bei RISC-Rechnern nicht vor


Indizierte Adressierung



- ▶ indizierte Adressierung, z.B. für Arrayzugriffe
 - ▶ $\text{addr} = (\text{Basisregister}) + (\text{Sourceregister})$
 - ▶ $\text{addr} = (\text{Sourceregister}) + \text{offset};$
 Sourceregister = addr

weitere Adressierungsarten

1. Immediate addressing




(immediate)

2. Register addressing




(register direct)

3. Base addressing





(index + offset)

4. PC-relative addressing



(PC + offset)

5. Pseudodirect addressing



(PC | offset)



typische Adressierungsarten

welche Adressierungsarten / Varianten sind üblich?

- ▶ 0-Adress (Stack-) Maschine Java virtuelle Maschine
- ▶ 1-Adress (Akkumulator) Maschine 8-bit Mikrokontroller
einige x86 Befehle
- ▶ 2-Adress Maschine 16-bit Rechner
einige x86 Befehle
- ▶ 3-Adress Maschine 32-bit RISC

- ▶ CISC Rechner unterstützen diverse Adressierungsarten
- ▶ RISC meistens nur indiziert mit offset



Intel x86-Architektur

- ▶ übliche Bezeichnung für die Intel-Prozessorfamilie
- ▶ von 8086, 80286, 80386, 80486, Pentium... Pentium-IV, Core 2, Core-i*
- ▶ eigentlich „IA-32“ (Intel architecture, 32-bit)... „IA-64“
- ▶ irreguläre Struktur: CISC
- ▶ historisch gewachsen: diverse Erweiterungen (MMX, SSE, ...)
- ▶ Abwärtskompatibilität: IA-64 mit IA-32 Emulation
- ▶ ab 386 auch wie reguläre 8-Register Maschine verwendbar


Hinweis: niemand erwartet, dass Sie sich alle Details merken

Intel x86: Evolution

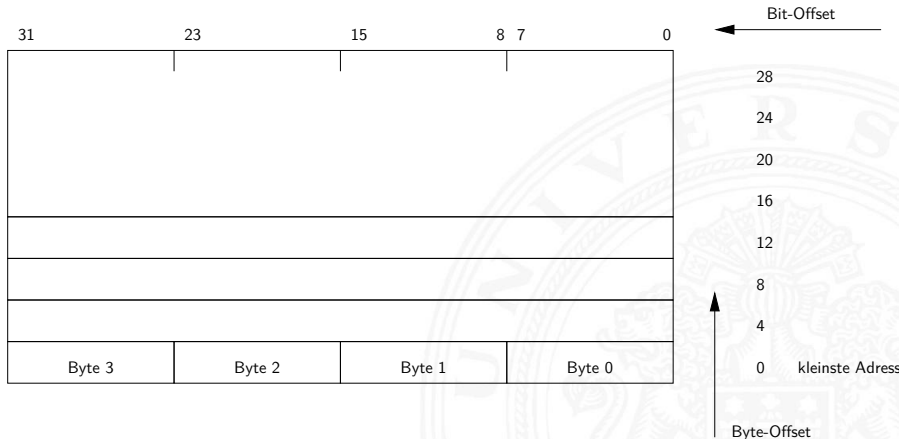
Chip	Datum	MHz	Transistoren	Speicher	Anmerkungen
4004	4/1971	0,108	2 300	640	erster Mikroprozessor auf einem Chip
8008	4/1972	0,108	3 500	16 KiB	erster 8-bit Mikroprozessor
8080	4/1974	2	6 000	64 KiB	„general-purpose“ CPU auf einem Chip
8086	6/1978	5–10	29 000	1 MiB	erste 16-bit CPU auf einem Chip
8088	6/1979	5–8	29 000	1 MiB	Einsatz im IBM-PC
80286	2/1982	8–12	134 000	16 MiB	„Protected-Mode“
80386	10/1985	16–33	275 000	4 GiB	erste 32-Bit CPU
80486	4/1989	25-100	1,2M	4 GiB	integrierter 8K Cache
Pentium	3/1993	60–233	3,1M	4 GiB	zwei Pipelines, später MMX
Pentium Pro	3/1995	150–200	5,5M	4 GiB	integrierter first und second-level Cache
Pentium II	5/1997	233–400	7,5M	4 GiB	Pentium Pro plus MMX
Pentium III	2/1999	450–1 400	9,5–44M	4 GiB	SSE-Einheit
Pentium IV	11/2000	1 300–3 600	42–188M	4 GiB	Hyperthreading
Core-2	5/2007	1 600–3 200	143–410M	4 GiB	64-bit Architektur, Mehrkernprozessoren
Core-i*	11/2008	2,500–3,600	> 700M	64 GiB	Taktanpassung (Turbo Boost)
...					

Beispiel: Core i7-960 Prozessor

Taktfrequenz	bis 3,46 GHz
Anzahl der Cores	4 (× 2 Hyperthreading)
QPI Durchsatz (quick path interconnect)	4,8 GT/s
Bus Interface	64 Bits
L1 Cache	4x (32 kB I + 32 kB D)
L2 Cache	4x 256 kB (I+D)
L3 Cache	8192 kB (I+D)
Prozess	45 nm
Versorgungsspannung	0,8 - 1,375V
Wärmeabgabe	~ 130 W
Performance (SPECint 2006)	~ 38
Quellen: ark.intel.com , www.spec.org	



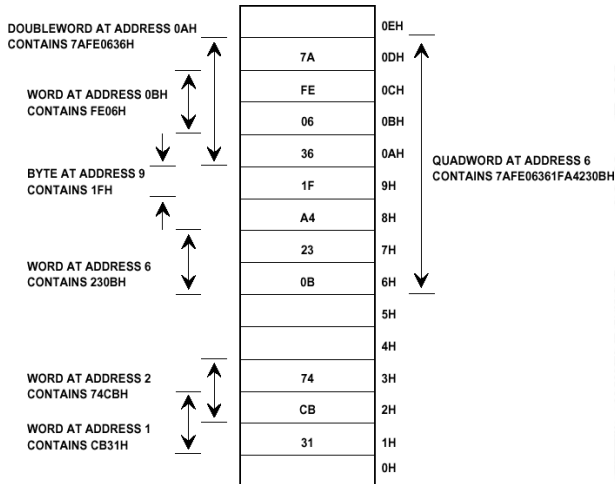
x86: Speichermodell



- ▶ „little endian“: LSB eines Wortes bei der kleinsten Adresse

x86: Speichermodell (cont.)

- ▶ Speicher voll byte-adressierbar
- ▶ misaligned Zugriffe langsam
- ▶ Beispiel zeigt
 - ▶ Byte
 - ▶ Word
 - ▶ Doubleword
 - ▶ Quadword



x86: Register

31	15	0
EAX	AX	AH AL
ECX	CX	CH CL
EDX	DX	DH DL
EBX	BX	BH BL
ESP	SP	
EBP	BP	
ESI	SI	
EDI	DI	
	CS	
	SS	
	DS	
	ES	
	FS	
	GS	
EIP	IP	
EFLAGS		

accumulator

count: String, Loop

data, multiply/divide

base addr

stackptr

base of stack segment

index, string src

index, string dst

code segment

stack segment

data segment

extra data segment

PC


status



8086

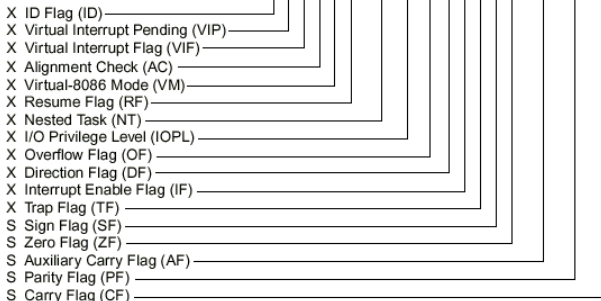


Exx ab 386



FP Status

x86: EFLAGS Register



- S Indicates a Status Flag
- C Indicates a Control Flag
- X Indicates a System Flag

Reserved bit positions. DO NOT USE.
 Always set to values previously read.

x86: Datentypen

bytes

word

doubleword

quadword

integer

(2-complement b/w/dw/qw)

ordinal

(unsigned b/w/dw/qw)

BCD

(one digit per byte, multiple bytes)

packed BCD

(two digits per byte, multiple bytes)

near pointer

(32 bit offset)

far pointer




(16 bit segment + 32 bit offset)

bit field

bit string

byte string

float / double / extended





x86: Befehlssatz

Datenzugriff	<code>mov, xchg</code>
Stack-Befehle	<code>push, pusha, pop, popa</code>
Typumwandlung	<code>cwd, cdq, cbw (byte→word), movsx,...</code>
Binärarithmetik	<code>add, adc, inc, sub, sbb, dec, cmp, neg,...</code>
	<code>mul, imul, div, idiv,...</code>
Dezimalarithmetik	(packed/unpacked BCD) <code>daa, das, aaa,...</code>
Logikoperationen	<code>and, or, xor, not, sal, shr, shr,...</code>
Sprungbefehle	<code>jmp, call, ret, int, iret, loop, loopne,...</code>
String-Operationen	<code>movs, cmpls, scas, load, stos,...</code>
„high-level“	<code>enter (create stack frame),...</code>
diverses	<code>lahf (load AH from flags),...</code>
Segment-Register	<code>far call, far ret, lds (load data pointer)</code>

- ▶ CISC: zusätzlich diverse Ausnahmen/Spezialfälle

x86: Befehlsformate

- ▶ außergewöhnlich komplexes Befehlsformat
 1. prefix repeat / segment override / etc.
 2. opcode eigentlicher Befehl
 3. register specifier Ziel / Quellregister
 4. address mode specifier diverse Varianten
 5. scale-index-base Speicheradressierung
 6. displacement Offset
 7. immediate operand

- ▶ außer dem Opcode alle Bestandteile optional
- ▶ unterschiedliche Länge der Befehle, von 1... 36 Bytes

- ⇒ extrem aufwändige Decodierung
- ⇒ CISC – **C**omplex **I**nstruction **S**et **C**omputer


x86: Befehlsformat-Modifizier („prefix“)

- ▶ alle Befehle können mit Modifiern ergänzt werden


segment override	Adresse aus angewähltem Segmentregister
address size	Umschaltung 16/32-bit Adresse
operand size	Umschaltung 16/32-bit Operanden
repeat	Stringoperationen: für alle Elemente
lock	Speicherschutz bei Multiprozessorsystemen

x86 Befehlskodierung: Beispiele


a. JE EIP + displacement




b. CALL



c. MOV EBX, [EDI + 45]



d. PUSH ESI



e. ADD EAX, #8765



f. TEST EDX, #42



- ▶ 1 Byte. . . 36 Bytes
- ▶ vollkommen irregulär
- ▶ w: Auswahl 16/32 bit

x86 Befehlskodierung: Beispiele (cont.)

Instruction	Function
JE name	If equal (CC) EIP = name; \square EIP - 128 \leq name < EIP + 128
JMP name	{EIP = NAME};
CALL name	SP = SP - 4; M[SP] = EIP + 5; EIP = name;
MOVW EBX,[EDI + 45]	EBX = M [EDI + 45]
PUSH ESI	SP = SP - 4; M[SP] = ESI
POP EDI	EDI = M[SP]; SP = SP + 4
ADD EAX,#6765	EAX = EAX + 6765
TEST EDX,#42	Set condition codea (flags) with EDX & 42
MOVSL	M[EDI] = M[ESI]; \square EDI = EDI + 4; ESI = ESI + 4

x86: Assembler-Beispiel print(...)

```

addr opcode    assembler                                c  quellcode
-----
                                .file      "hello.c"
                                .text
0000 48656C6C    .string    "Hello x86!\n\n"
                                6F207838
                                36210A00
                                .text
                                print:
0000 55           pushl %ebp                                | void print( char* s ) {
0001 89E5        movl %esp,%ebp
0003 53         pushl %ebx
0004 8B5D08     movl 8(%ebp),%ebx
0007 803B00     cmpb $0,(%ebx)                            | while( *s != 0 ) {
000a 7418       je .L18
                                .align 4
                                .L19:
000c A100000000  movl stdout,%eax                          |      putc( *s, stdout );
0011 50         pushl %eax
0012 0FBE03    movsbl (%ebx),%eax
0015 50         pushl %eax
0016 E8FCFFFF    call _IO_putc
                                FF
001b 43         incl %ebx                                  |      s++;
001c 83C408     addl $8,%esp                               |  }
001f 803B00     cmpb $0,(%ebx)
0022 75E8     jne .L19
                                .L18:
0024 8B5DFC     movl -4(%ebp),%ebx                        | }
0027 89EC     movl %ebp,%esp
0029 5D     popl %ebp
002a C3     ret
    
```

x86: Assembler-Beispiel main(...)

addr	opcode	assembler	c quellcode

		.Lf1:	
		.Lscope0:	
002b	908D7426	.align 16	
	00		
		main:	
0030	55	pushl %ebp	int main(int argc, char** argv) {
0031	89E5	movl %esp,%ebp	
0033	53	pushl %ebx	
0034	BB00000000	movl \$.LC0,%ebx	print("Hello x86!\n");
0039	803D0000	cmpl \$0, .LC0	
	00000000		
0040	741A	je .L26	
0042	89F6	.align 4	
		.L24:	
0044	A100000000	movl stdout,%eax	
0049	50	pushl %eax	
004a	0FBE03	movsbl (%ebx),%eax	
004d	50	pushl %eax	
004e	E8FCFFFFFF	call _IO_putc	
0053	43	incl %ebx	
0054	83C408	addl \$8,%esp	
0057	803B00	cmpl \$0,(%ebx)	
005a	75E8	jne .L24	
		.L26:	
005c	31C0	xorl %eax,%eax	return 0;
005e	8B5DFC	movl -4(%ebp),%ebx	}
0061	89EC	movl %ebp,%esp	
0063	5D	popl %ebp	
0064	C3	ret	



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

- 14. Schaltwerke
- 15. Grundkomponenten für Rechensysteme
- 16. VLSI-Entwurf und -Technologie
- 17. Rechnerarchitektur
- 18. Instruction Set Architecture
- 19. **Assembler-Programmierung**

Motivation

Grundlagen der Assemblerebene

Assembler und Disassembler

x86 Assemblerprogrammierung

Elementare Befehle und Adressierungsarten

Arithmetische Operationen

Kontrollfluss



Gliederung (cont.)


Sprungbefehle und Schleifen
Mehrfachverzweigung (Switch)
Funktionsaufrufe und Stack
Grundlegende Datentypen

20. Computerarchitektur

21. Speicherhierarchie




Das Kompilierungssystem



⇒ verschiedene Repräsentationen des Programms

- ▶ Hochsprache
- ▶ Assembler
- ▶ Maschinsprache

Das Kompilierungssystem (cont.)



```
temp = v[k];
v[k] = v[k+1];
v[k+1] = temp;
```

```
lw $15, 0($2)
lw $16, 4($2)
sw $16, 0($2)
sw $15, 4($2)
```

```
0000 1001 1100 0110 1010 1111 0101 1000
1010 1111 0101 1000 0000 1001 1100 0110
1100 0110 1010 1111 0101 1000 0000 1001
0101 1000 0000 1001 1100 0110 1010 1111
```

```
ALUOP[0:3] <= InstReg[9:11] & MASK
```



Warum Assembler?

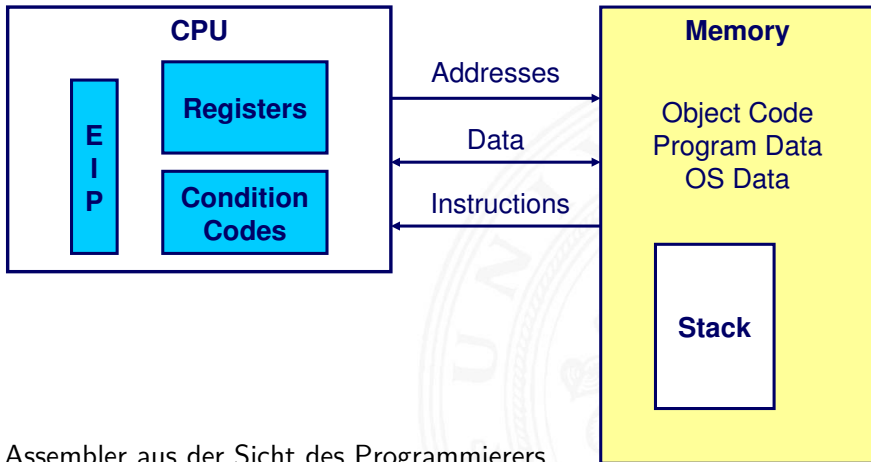
Programme werden nur noch selten in Assembler geschrieben

- ▶ Programmentwicklung in Hochsprachen weit produktiver
- ▶ Compiler/Tools oft besser als handcodierter Assembler

aber Grundwissen bleibt trotzdem unverzichtbar

- ▶ Verständnis des Ausführungsmodells auf der Maschinenebene
- ▶ Programmverhalten bei Fehlern / Debugging
- ▶ Programmleistung verstärken
 - ▶ Ursachen für Programm-Ineffizienz verstehen
 - ▶ effiziente „maschinengerechte“ Datenstrukturen / Algorithmen
- ▶ Systemsoftware implementieren
 - ▶ Compilerbau: Maschinencode als Ziel
 - ▶ Betriebssysteme implementieren (Prozesszustände verwalten)
 - ▶ Gerätetreiber schreiben

Assembler-Programmierung



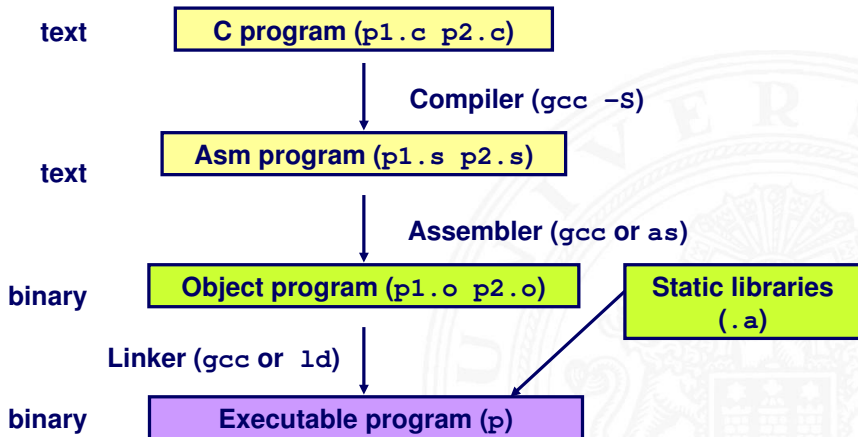
Assembler aus der Sicht des Programmierers



Beobachtbare Zustände (Assemblersicht)

- ▶ Programmzähler (*Instruction Pointer* EIP)
 - ▶ Adresse der nächsten Anweisung
- ▶ Registerbank
 - ▶ häufig benutzte Programmdate
- ▶ Zustandscodes
 - ▶ gespeicherte Statusinformationen über die letzte arithmetische Operation
 - ▶ für bedingte Sprünge benötigt (*Conditional Branch*)
- ▶ Speicher
 - ▶ byteweise adressierbares Array
 - ▶ Code, Nutzerdaten, (einige) OS Daten
 - ▶ beinhaltet Kellerspeicher zur Unterstützung von Abläufen

Umwandlung von C in Objektcode





Kompilieren zu Assemblercode

code.c

```
int sum(int x, int y)
{
    int t = x+y;
    return t;
}
```

code.s

```
_sum:
    pushl %ebp
    movl %esp,%ebp
    movl 12(%ebp),%eax
    addl 8(%ebp),%eax
    movl %ebp,%esp
    popl %ebp
    ret
```

- ▶ Befehl `gcc -O -S code.c`
- ▶ Erzeugt `code.s`



Assembler Charakteristika

Datentypen

- ▶ Ganzzahl- Daten mit 1, 2 oder 4 Bytes
 - ▶ Datenwerte
 - ▶ Adressen (*pointer*)
- ▶ Gleitkomma-Daten mit 4, 8 oder 10/12 Bytes
- ▶ keine Aggregattypen wie Arrays oder Strukturen
 - ▶ nur fortlaufend adressierbare Byte im Speicher



Assembler Charakteristika (cont.)

Primitive Operationen

- ▶ arithmetische/logische Funktionen auf Registern und Speicher
- ▶ Datentransfer zwischen Speicher und Registern
 - ▶ Daten aus Speicher in Register laden
 - ▶ Registerdaten im Speicher ablegen
- ▶ Kontrolltransfer
 - ▶ unbedingte / Bedingte Sprünge
 - ▶ Unterprogrammaufrufe: Sprünge zu/von Prozeduren



Objektcode

- ▶ 13 bytes
- ▶ Instruktionen: 1-, 2- oder 3 bytes
- ▶ Startadresse: `0x401040`

`0x401040 <sum> :`

`0x55`

`0x89`

`0xe5`

`0x8b`

`0x45`

`0x0c`

`0x03`

`0x45`

`0x08`

`0x89`

`0xec`

`0x5d`

`0xc3`



Assembler und Linker

Assembler

- ▶ übersetzt `.s` zu `.o`
- ▶ binäre Codierung jeder Anweisung
- ▶ (fast) vollständiges Bild des ausführbaren Codes
- ▶ Verknüpfungen zwischen Code in verschiedenen Dateien fehlen

Linker / Binder

- ▶ löst Referenzen zwischen Dateien auf
- ▶ kombiniert mit statischen Laufzeit-Bibliotheken
 - ▶ z.B. Code für `malloc`, `printf`
- ▶ manche Bibliotheken sind *dynamisch* verknüpft
 - ▶ Verknüpfung wird zur Laufzeit erstellt



Beispiel: Maschinenbefehl

▶ C-Code

```
int t = x+y;
```

- ▶ addiert zwei Ganzzahlen mit Vorzeichen

▶ Assembler

- ▶ Addiere zwei 4-byte Integer
 - ▶ long Wörter (für gcc)
 - ▶ keine signed/unsigned Unterscheidung

```
addl 8(%ebp), %eax
```

▶ Operanden

x: Register %eax
 y: Speicher M[%ebp+8]
 t: Register %eax
 Ergebnis in %eax

**Similar to
 expression**

x += y

▶ Objektcode

- ▶ 3-Byte Befehl
- ▶ Speicheradresse 0x401046

```
0x401046: 03 45 08
```

Objektcode Disassembler: objdump

```

00401040 <_sum>:
   0:      55                push   %ebp
   1:      89 e5             mov    %esp,%ebp
   3:      8b 45 0c          mov    0xc(%ebp),%eax
   6:      03 45 08          add   0x8(%ebp),%eax
   9:      89 ec             mov    %ebp,%esp
  b:      5d                pop    %ebp
  c:      c3                ret
  d:      8d 76 00          lea   0x0(%esi),%esi
    
```

- ▶ `objdump -d ...`
 - ▶ Werkzeug zur Untersuchung des Objektcodes
 - ▶ rekonstruiert aus Binärcode den Assemblercode
 - ▶ kann auf vollständigem, ausführbarem Programm (a.out) oder einer .o Datei ausgeführt werden

Alternativer Disassembler: gdb

Object

```

0x401040:
  0x55
  0x89
  0xe5
  0x8b
  0x45
  0x0c
  0x03
  0x45
  0x08
  0x89
  0xec
  0x5d
  0xc3
    
```

Disassembled

```

0x401040 <sum>:      push   %ebp
0x401041 <sum+1>:     mov    %esp,%ebp
0x401043 <sum+3>:     mov    0xc(%ebp),%eax
0x401046 <sum+6>:     add   0x8(%ebp),%eax
0x401049 <sum+9>:     mov    %ebp,%esp
0x40104b <sum+11>:    pop   %ebp
0x40104c <sum+12>:    ret
0x40104d <sum+13>:    lea   0x0(%esi),%esi
    
```

gdb Debugger

```

gdb p
disassemble sum
  ■ Disassemble procedure
x/13b sum
  ■ Examine the 13 bytes starting at sum
    
```


Was kann „disassembliert“ werden?

```

% objdump -d WINWORD.EXE

WINWORD.EXE:      file format pei-i386

No symbols in "WINWORD.EXE".
Disassembly of section .text:

30001000 <.text>:
30001000:  55                push    %ebp
30001001:  8b ec            mov     %esp, %ebp
30001003:  6a ff            push   $0xffffffff
30001005:  68 90 10 00 30  push   $0x30001090
3000100a:  68 91 dc 4c 30  push   $0x304cdc91
    
```

- ▶ alles, was als ausführbarer Code interpretiert werden kann
- ▶ Disassembler untersucht Bytes und rekonstruiert Assemblerquelle



x86 Assemblerprogrammierung

- ▶ Adressierungsarten
- ▶ arithmetische Operationen
- ▶ Statusregister
- ▶ Umsetzung von Programmstrukturen



Datentransfer „move“

- ▶ Format: `movl <src>, <dst>`
- ▶ transferiert ein 4-Byte „long“ Wort
- ▶ sehr häufige Instruktion

- ▶ Typ der Operanden
 - ▶ Immediate: Konstante, ganzzahlig
 - ▶ wie C-Konstante, aber mit dem Präfix \$
 - ▶ z.B., \$0x400, \$-533
 - ▶ codiert mit 1, 2 oder 4 Bytes
 - ▶ Register: 8 Ganzzahl-Registern
 - ▶ %esp und %ebp für spezielle Aufgaben reserviert
 - ▶ z.T. andere Spezialregister für andere Anweisungen
 - ▶ Speicher: 4 konsekutive Speicherbytes
 - ▶ Zahlreiche Adressmodi



movl Operanden-Kombinationen

	Source	Destination	C Analogon
movl	<i>Imm</i>	<i>Reg</i> <code>movl \$0x4, %eax</code>	<code>temp = 0x4;</code>
		<i>Mem</i> <code>movl \$-147, (%eax)</code>	<code>*p = -147;</code>
	<i>Reg</i>	<i>Reg</i> <code>movl %eax, %edx</code>	<code>temp2 = temp1;</code>
		<i>Mem</i> <code>movl %eax, (%edx)</code>	<code>*p = temp;</code>
	<i>Mem</i>	<i>Reg</i> <code>movl (%eax), %edx</code>	<code>temp = *p;</code>



Elementare Befehle und Adressierungsarten

- ▶ Normal: $(R) \rightarrow \text{Mem}[\text{Reg}[R]]$
 - ▶ Register R spezifiziert die Speicheradresse
 - ▶ Beispiel: `movl (%ecx), %eax`
- ▶ Displacement: $D(R) \rightarrow \text{Mem}[\text{Reg}[R]+D]$
 - ▶ Register R
 - ▶ Konstantes „Displacement“ D spezifiziert den „offset“
 - ▶ Beispiel: `movl 8(%ebp), %edx`



Beispiel: einfache Adressierungsmodi

```

void swap(int *xp, int *yp)
{
    int t0 = *xp;
    int t1 = *yp;
    *xp = t1;
    *yp = t0;
}
    
```

swap:

```

pushl %ebp
movl %esp, %ebp
pushl %ebx
    
```

} Set Up

```

movl 12(%ebp), %ecx
movl 8(%ebp), %edx
movl (%ecx), %eax
movl (%edx), %ebx
movl %eax, (%edx)
movl %ebx, (%ecx)
    
```

} Body

```

movl -4(%ebp), %ebx
movl %ebp, %esp
popl %ebp
ret
    
```

} Finish



indizierte Adressierung

▶ gebräuchlichste Form

- ▶ $\text{Imm}(\text{Rb}, \text{Ri}, \text{S}) \rightarrow \text{Mem}[\text{Reg}[\text{Rb}] + \text{S} * \text{Reg}[\text{Ri}] + \text{Imm}]$
 - ▶ $\langle \text{Imm} \rangle$ Offset
 - ▶ $\langle \text{Rb} \rangle$ Basisregister: eins der 8 Integer-Registern
 - ▶ $\langle \text{Ri} \rangle$ Indexregister: jedes außer %esp
%ebp grundsätzlich möglich, jedoch unwahrscheinlich
 - ▶ $\langle \text{S} \rangle$ Skalierungsfaktor 1, 2, 4 oder 8

▶ spezielle Fälle

- ▶ $(\text{Rb}, \text{Ri}) \rightarrow \text{Mem}[\text{Reg}[\text{Rb}] + \text{Reg}[\text{Ri}]]$
- ▶ $\text{Imm}(\text{Rb}, \text{Ri}) \rightarrow \text{Mem}[\text{Reg}[\text{Rb}] + \text{Reg}[\text{Ri}] + \text{Imm}]$
- ▶ $(\text{Rb}, \text{Ri}, \text{S}) \rightarrow \text{Mem}[\text{Reg}[\text{Rb}] + \text{S} * \text{Reg}[\text{Ri}]]$

Beispiel: Adressberechnung

<code>%edx</code>	<code>0xf000</code>
<code>%ecx</code>	<code>0x100</code>

Expression	Computation	Address
<code>0x8(%edx)</code>	<code>0xf000 + 0x8</code>	<code>0xf008</code>
<code>(%edx,%ecx)</code>	<code>0xf000 + 0x100</code>	<code>0xf100</code>
<code>(%edx,%ecx,4)</code>	<code>0xf000 + 4*0x100</code>	<code>0xf400</code>
<code>0x80(,%edx,2)</code>	<code>2*0xf000 + 0x80</code>	<code>0x1e080</code>



Arithmetische Operationen

► binäre Operatoren

Format

`addl Src, Dest`

`subl Src, Dest`

`imull Src, Dest`

`sall Src, Dest`

`sarl Src, Dest`

`shrl Src, Dest`

`xorl Src, Dest`

`andl Src, Dest`

`orl Src, Dest`

Computation

$Dest = Dest + Src$

$Dest = Dest - Src$

$Dest = Dest * Src$

$Dest = Dest \ll Src$ also called `shll`

$Dest = Dest \gg Src$ Arithmetic

$Dest = Dest \gg Src$ Logical

$Dest = Dest \wedge Src$

$Dest = Dest \& Src$

$Dest = Dest | Src$



Arithmetische Operationen (cont.)

► unäre Operatoren

Format

`incl Dest`

`decl Dest`

`negl Dest`

`notl Dest`

Computation

$Dest = Dest + 1$

$Dest = Dest - 1$

$Dest = - Dest$

$Dest = \sim Dest$



Beispiel: arithmetische Operationen

```
int arith
  (int x, int y, int z)
{
  int t1 = x+y;
  int t2 = z+t1;
  int t3 = x+4;
  int t4 = y * 48;
  int t5 = t3 + t4;
  int rval = t2 * t5;
  return rval;
}
```

arith:

```
pushl %ebp
movl %esp,%ebp
```

} Set
Up

```
movl 8(%ebp),%eax
movl 12(%ebp),%edx
leal (%edx,%eax),%ecx
leal (%edx,%edx,2),%edx
sall $4,%edx
addl 16(%ebp),%ecx
leal 4(%edx,%eax),%eax
imull %ecx,%eax
```


} Body

```
movl %ebp,%esp
popl %ebp
ret
```

} Finish

Beispiel: arithmetische Operationen (cont.)

```
int arith
  (int x, int y, int z)
{
  int t1 = x+y;
  int t2 = z+t1;
  int t3 = x+4;
  int t4 = y * 48;
  int t5 = t3 + t4;
  int rval = t2 * t5;
  return rval;
}
```



```
movl 8(%ebp), %eax    # eax = x
movl 12(%ebp), %edx   # edx = y
leal (%edx, %eax), %ecx # ecx = x+y (t1)
leal (%edx, %edx, 2), %edx # edx = 3*y
sall $4, %edx        # edx = 48*y (t4)
addl 16(%ebp), %ecx   # ecx = z+t1 (t2)
leal 4(%edx, %eax), %eax # eax = 4+t4+x (t5)
imull %ecx, %eax     # eax = t5*t2 (rval)
```

Beispiel: logische Operationen

```
int logical(int x, int y)
{
    int t1 = x^y;
    int t2 = t1 >> 17;
    int mask = (1<<13) - 7;
    int rval = t2 & mask;
    return rval;
}
```

$$2^{13} = 8192, 2^{13} - 7 = 8185$$

```
movl 8(%ebp), %eax
xorl 12(%ebp), %eax
sarl $17, %eax
andl $8185, %eax
```

logical:

```
pushl %ebp
movl %esp, %ebp
```

} Set
Up

```
movl 8(%ebp), %eax
xorl 12(%ebp), %eax
sarl $17, %eax
andl $8185, %eax
```

} Body

```
movl %ebp, %esp
popl %ebp
ret
```

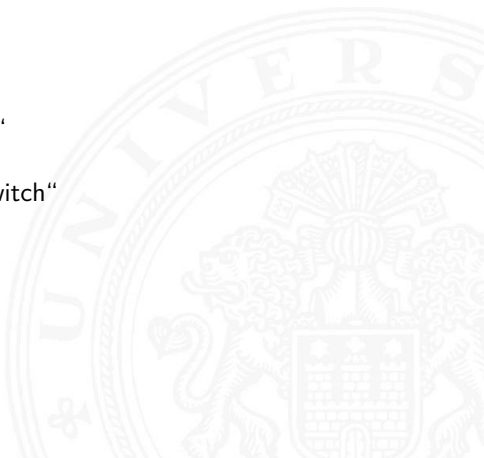
} Finish

```
eax = x
eax = x^y    (t1)
eax = t1>>17 (t2)
eax = t2 & 8185
```



Kontrollfluss / Programmstrukturen

- ▶ Zustandscodes
 - ▶ Setzen
 - ▶ Testen
- ▶ Ablaufsteuerung
 - ▶ Verzweigungen: „If-then-else“
 - ▶ Schleifen: „Loop“-Varianten
 - ▶ Mehrfachverzweigungen: „Switch“



Zustandscodes

▶ vier relevante „Flags“ im Statusregister

- ▶ CF Carry Flag
- ▶ SF Sign Flag
- ▶ ZF Zero Flag
- ▶ OF Overflow Flag

1. implizite Aktualisierung durch arithmetische Operationen

▶ Beispiel: `addl <src>, <dst>` in C: `t=a+b`

- ▶ CF höchstwertiges Bit generiert Übertrag: Unsigned-Überlauf
- ▶ ZF wenn $t = 0$
- ▶ SF wenn $t < 0$
- ▶ OF wenn das Zweierkomplement überläuft

$(a > 0 \ \&\& \ b > 0 \ \&\& \ t < 0) \ || \ (a < 0 \ \&\& \ b < 0 \ \&\& \ t \geq 0)$



Zustandscodes (cont.)

2. explizites Setzen durch Vergleichsoperation

- ▶ Beispiel: `cmpl <src2>, <src1>`
 wie Berechnung von $\langle src1 \rangle - \langle src2 \rangle$ (`subl <src2>, <src1>`)
 jedoch ohne Abspeichern des Resultats
- ▶ CF höchstwertiges Bit generiert Übertrag
- ▶ ZF setzen wenn $src1 = src2$
- ▶ SF setzen wenn $(src1 - src2) < 0$
- ▶ OF setzen wenn das Zweierkomplement überläuft
 $(a > 0 \ \&\& \ b < 0 \ \&\& \ (a - b) < 0) \ ||$
 $(a < 0 \ \&\& \ b > 0 \ \&\& \ (a - b) \geq 0)$



Zustandscodes (cont.)

3. explizites Setzen durch Testanweisung

- ▶ Beispiel: `testl <src2>, <src1>`
wie Berechnung von `<src1> & <src2>` (`andl <src2>, <src1>`)
jedoch ohne Abspeichern des Resultats
- ⇒ hilfreich, wenn einer der Operanden eine Bitmaske ist

- ▶ ZF setzen wenn $src1 \& src2 = 0$
- ▶ SF setzen wenn $src1 \& src2 < 0$

Zustandscodes lesen

set.. Anweisungen

- Kombinationen von Zustandscodes setzen einzelnes Byte

SetX	Condition	Description
sete	ZF	Equal / Zero
setne	\sim ZF	Not Equal / Not Zero
sets	SF	Negative
setns	\sim SF	Nonnegative
setg	\sim (SF [^] OF) & \sim ZF	Greater (Signed)
setge	\sim (SF [^] OF)	Greater or Equal (Signed)
setl	(SF [^] OF)	Less (Signed)
setle	(SF [^] OF) ZF	Less or Equal (Signed)
seta	\sim CF & \sim ZF	Above (unsigned)
setb	CF	Below (unsigned)

Beispiel: Zustandscodes lesen

- ▶ ein-Byte Zieloperand (Register, Speicher)
- ▶ meist kombiniert mit `movzbl` (Löschen hochwertiger Bits)

```
int gt (int x, int y)
{
    return x > y;
}
```

```
movl 12(%ebp),%eax # eax = y
cmpl %eax,8(%ebp) # Compare x : y
setg %al          # al = x > y
movzbl %al,%eax  # Zero rest of %eax
```

<code>%eax</code>	<code>%ah</code>	<code>%al</code>
<code>%edx</code>	<code>%dh</code>	<code>%dl</code>
<code>%ecx</code>	<code>%ch</code>	<code>%cl</code>
<code>%ebx</code>	<code>%bh</code>	<code>%bl</code>
<code>%esi</code>		
<code>%edi</code>		
<code>%esp</code>		
<code>%ebp</code>		



Sprungbefehle („Jump“)

j.. Anweisungen

- ▶ unbedingter- / bedingter Sprung (abhängig von Zustandscode)

jX	Condition	Description
jmp	1	Unconditional
je	ZF	Equal / Zero
jne	~ZF	Not Equal / Not Zero
js	SF	Negative
jns	~SF	Nonnegative
jg	~(SF^OF) & ~ZF	Greater (Signed)
jge	~(SF^OF)	Greater or Equal (Signed)
j1	(SF^OF)	Less (Signed)
jle	(SF^OF) ZF	Less or Equal (Signed)
ja	~CF & ~ZF	Above (unsigned)
jb	CF	Below (unsigned)

Beispiel: bedingter Sprung („Conditional Branch“)

```
int max(int x, int y)
{
    if (x > y)
        return x;
    else
        return y;
}
```

_max:

```
pushl %ebp
movl %esp,%ebp
```

} Set
Up

```
movl 8(%ebp),%edx
movl 12(%ebp),%eax
cmpl %eax,%edx
jle L9
movl %edx,%eax
```

} Body

L9:

```
movl %ebp,%esp
popl %ebp
ret
```

} Finish



Beispiel: bedingter Sprung („Conditional Branch“) (cont.)

```
int goto_max(int x, int y)
{
    int rval = y;
    int ok = (x <= y);
    if (ok)
        goto done;
    rval = x;
done:
    return rval;
}
```

- ▶ C-Code mit goto
- ▶ entspricht mehr dem Assemblerprogramm
- ▶ schlechter Programmierstil (!)

```
movl 8(%ebp), %edx    # edx = x
movl 12(%ebp), %eax   # eax = y
cmpl %eax, %edx      # x : y
jle L9                # if <= goto L9
movl %edx, %eax       # eax = x } Skipped when x ≤ y
L9:                   # Done:
```



Beispiel: „Do-While“ Schleife

▶ C Code

```
int fact_do
(int x)
{
    int result = 1;
    do {
        result *= x;
        x = x-1;
    } while (x > 1);
    return result;
}
```

goto Version

```
int fact_goto(int x)
{
    int result = 1;
loop:
    result *= x;
    x = x-1;
    if (x > 1)
        goto loop;
    return result;
}
```

- ▶ Rückwärtssprung setzt Schleife fort
- ▶ wird nur ausgeführt, wenn „while“ Bedingung gilt



Beispiel: „Do-While“ Schleife (cont.)

```
int fact_goto
(int x)
{
    int result = 1;
loop:
    result *= x;
    x = x-1;
    if (x > 1)
        goto loop;
    return result;
}
```

```
_fact_goto:
    pushl %ebp                # Setup
    movl %esp,%ebp          # Setup
    movl $1,%eax            # eax = 1
    movl 8(%ebp),%edx        # edx = x

L11:
    imull %edx,%eax         # result *= x
    decl %edx                # x--
    cmpl $1,%edx            # Compare x : 1
    jg L11                   # if > goto loop

    movl %ebp,%esp          # Finish
    popl %ebp               # Finish
    ret                      # Finish
```

Register

`%edx` x

`%eax` result



„Do-While“ Übersetzung

C Code

```
do
    Body
while (Test);
```

Goto Version

```
loop:
    Body
    if (Test)
        goto loop
```

- ▶ beliebige Folge von C Anweisungen als Schleifenkörper
- ▶ Abbruchbedingung ist zurückgelieferter Integer Wert
 - ▶ = 0 entspricht Falsch
 - ▶ $\neq 0$ —"– Wahr

„While“ Übersetzung

C Code

```
while (Test)
    Body
```



Do-While Version

```
if (!Test)
    goto done;
do
    Body
    while (Test);
done:
```



Goto Version

```
if (!Test)
    goto done;
loop:
    Body
    if (Test)
        goto loop;
done:
```

„For“ Übersetzung

For Version

```
for (Init; Test; Update )
    Body
```

While Version

```
Init;
while (Test) {
    Body
    Update ;
}
```

Do-While Version

```
Init;
if (!Test)
    goto done;
do {
    Body
    Update ;
} while (Test)
done:
```

Goto Version

```
Init;
if (!Test)
    goto done;
loop:
    Body
    Update ;
    if (Test)
        goto loop;
done:
```

Mehrfachverzweigungen „Switch“

- ▶ Implementierungsoptionen
 1. Serie von Bedingungen
 - + gut bei wenigen Alternativen
 - langsam bei vielen Fällen
 2. Sprungtabelle „Jump Table“
 - ▶ Vermeidet einzelne Abfragen
 - ▶ möglich falls Alternativen kleine ganzzahlige Konstanten sind
- ▶ Compiler (gcc) wählt eine der beiden Varianten entsprechend der Fallstruktur

Anmerkung: im Beispielcode fehlt „Default“

```
typedef enum
{ADD, MULT, MINUS, DIV, MOD, BAD}
op_type;

char unparse_symbol(op_type op)
{
    switch (op) {
        case ADD :
            return '+';
        case MULT:
            return '*';
        case MINUS:
            return '-';
        case DIV:
            return '/';
        case MOD:
            return '%';
        case BAD:
            return '?';
    }
}
```

Sprungtabelle

Switch Form

```

switch(op) {
  case val_0:
    Block 0
  case val_1:
    Block 1
    . . .
  case val_n-1:
    Block n-1
}
    
```

Jump Table

jtab:

Targ0
Targ1
Targ2
⋮
⋮
⋮
Targn-1

Jump Targets

Targ0: Code Block 0

Targ1: Code Block 1

Targ2: Code Block 2

⋮

Targn-1: Code Block n-1

Approx. Translation

```

target = JTab[op];
goto *target;
    
```

► Vorteil: k -fach Verzweigung in $\mathcal{O}(1)$ Operationen

Beispiel: „Switch“

Branching Possibilities

```
typedef enum
{ADD, MULT, MINUS, DIV, MOD, BAD}
  op_type;

char unparse_symbol(op_type op)
{
    switch (op) {
        . . .
    }
}
```

Setup:

```
unparse_symbol:
    pushl %ebp                # Setup
    movl %esp,%ebp          # Setup
    movl 8(%ebp),%eax        # eax = op
    cmpl $5,%eax            # Compare op : 5
    ja .L49                  # If > goto done
    jmp *.L57(,%eax,4)       # goto Table[op]
```

Enumerated Values

ADD	0
MULT	1
MINUS	2
DIV	3
MOD	4
BAD	5

Beispiel: „Switch“ (cont.)

Erklärung des Assemblers

- ▶ symbolische Label
 - ▶ Assembler übersetzt Label der Form `.L...` in Adressen
- ▶ Tabellenstruktur
 - ▶ jedes Ziel benötigt 4 Bytes
 - ▶ Basisadresse bei `.L57`
- ▶ Sprünge
 - ▶ `jmp .L49` als Sprungziel
 - ▶ `jmp *.L57(,%eax, 4)`
 - ▶ Sprungtabell ist mit Label `.L57` gekennzeichnet
 - ▶ Register `%eax` speichert `op`
 - ▶ Skalierungsfaktor 4 für Tabellenoffset
 - ▶ Sprungziel: effektive Adresse `.L57 + op × 4`

Beispiel: „Switch“ (cont.)

Table Contents

```
.section .rodata
    .align 4
.L57:
    .long .L51 #Op = 0
    .long .L52 #Op = 1
    .long .L53 #Op = 2
    .long .L54 #Op = 3
    .long .L55 #Op = 4
    .long .L56 #Op = 5
```

Enumerated Values

ADD	0
MULT	1
MINUS	2
DIV	3
MOD	4
BAD	5

Targets & Completion

```
.L51:
    movl $43,%eax # '+'
    jmp .L49
.L52:
    movl $42,%eax # '*'
    jmp .L49
.L53:
    movl $45,%eax # '-'
    jmp .L49
.L54:
    movl $47,%eax # '/'
    jmp .L49
.L55:
    movl $37,%eax # '%'
    jmp .L49
.L56:
    movl $63,%eax # '?'
    # Fall Through to .L49
```


Sprungtabelle aus Binärcode Extrahieren

Contents of section `.rodata`:

```

8048bc0 30870408 37870408 40870408 47870408 0...7...@...G...
8048bd0 50870408 57870408 46616374 28256429 P...W...Fact(%d)
8048be0 203d2025 6c640a00 43686172 203d2025 = %ld..Char = %
...
    
```

- ▶ im read-only Datensegment gespeichert (`.rodata`)
 - ▶ dort liegen konstante Werte des Codes
- ▶ kann mit `objdump` untersucht werden


```
objdump code-examples -s --section=.rodata
```

 - ▶ zeigt alles im angegebenen Segment
 - ▶ schwer zu lesen (!)
 - ▶ Einträge der Sprungtabelle in umgekehrter Byte-Anordnung
z.B: `30870408` ist eigentlich `0x08048730`

Zusammenfassung – Assembler

- ▶ C Kontrollstrukturen
 - ▶ „if-then-else“
 - ▶ „do-while“, „while“, „for“
 - ▶ „switch“
- ▶ Assembler Kontrollstrukturen
 - ▶ „Jump“
 - ▶ „Conditional Jump“
- ▶ Compiler
 - ▶ erzeugt Assembler Code für komplexere C Kontrollstrukturen
 - ▶ alle Schleifen in „do-while“ / „goto“ Form konvertieren
 - ▶ Sprungtabellen für Mehrfachverzweigungen „case“




Zusammenfassung – Assembler (cont.)

- ▶ Bedingungen CISC-Rechner
 - ▶ typisch Zustandscode-Register (wie die x86-Architektur)
- ▶ Bedingungen RISC-Rechner
 - ▶ keine speziellen Zustandscode-Register
 - ▶ stattdessen werden Universalregister benutzt um Zustandsinformationen zu speichern
 - ▶ spezielle Vergleichs-Anweisungen
 z.B. DEC-Alpha: `cmple $16, 1, $1`
 setzt Register \$1 auf 1 wenn Register $\$16 \leq 1$

x86 Stack (Kellerspeicher)


- ▶ Speicherregion
- ▶ Zugriff mit Stackoperationen
- ▶ wächst in Richtung niedrigerer Adressen
- ▶ Register `%esp` („Stack-Pointer“)
 - ▶ aktuelle Stack-Adresse
 - ▶ oberstes Element



Stack: Push

`pushl <src>`


- ▶ holt Operanden aus `<src>`
- ▶ dekrementiert `%esp` um 4
- ▶ speichert den Operanden unter der von `%esp` vorgegebenen Adresse




Stack: Pop

`popl <dst>`


- ▶ liest den Operanden unter der von `%esp` vorgegebenen Adresse
- ▶ inkrementiert `%esp` um 4
- ▶ schreibt gelesenen Wert in `<dst>`







Beispiele: Stack-Operationen



`pushl %eax`



`popl %edx`





Prozeduraufruf

- ▶ Stack zur Unterstützung von `call` und `ret`
- ▶ Prozeduraufruf: `call <label>`
 - ▶ Rücksprungadresse auf Stack („Push“)
 - ▶ Sprung zu `<label>`
- ▶ Wert der Rücksprungadresse
 - ▶ Adresse der auf den `call` folgenden Anweisung
 - ▶ Beispiel:


```


804854e:  e8 3d 06 00 00  ;call 8048b90
8048553:  50                ;pushl %eax
<main>    ...             ;...
8048b90:                ;Prozedureinsprung
<proc>    ...             ;...
...      ret         ;Rücksprung
                    
```
 - ▶ Rücksprungadresse `0x8048553`
- ▶ Rücksprung `ret`
 - ▶ Rücksprungadresse vom Stack („Pop“)
 - ▶ Sprung zu dieser Adresse

Beispiel: Prozeduraufruf

► Prozeduraufruf call

```

804854e: e8 3d 06 00 00    call 8048b90 <main>
8048553: 50                pushl %eax
    
```




%eip is program counter

Beispiel: Prozeduraufruf (cont.)

► Prozedurrücksprung ret

8048591: c3

ret



%eip is program counter



Stack-basierende Sprachen

- ▶ Sprachen, die Rekursion unterstützen
 - ▶ z.B.: C, Pascal, Java
 - ▶ Code muss „Reentrant“ sein
 - ▶ erlaubt mehrfache, simultane Instanziierungen einer Prozedur
 - ▶ Ort, um den Zustand jeder Instanziierung zu speichern
 - ▶ Argumente
 - ▶ lokale Variable
 - ▶ Rücksprungsadresse
- ▶ Stack Verfahren
 - ▶ Zustandsspeicher für Aufrufe
 - ▶ zeitlich limitiert: von `call` bis `ret`
 - ▶ aufgerufenes Unterprogramm („Callee“) wird vor aufrufendem Programme („Caller“) beendet
- ▶ Stack „Frame“
 - ▶ Bereich/Zustand einer einzelnen Prozedur-Instanziierung



Stack-Frame

- ▶ Inhalt
 - ▶ Parameter
 - ▶ lokale Variablen
 - ▶ Rücksprungadresse
 - ▶ temporäre Daten
- ▶ Verwaltung
 - ▶ bei Aufruf wird Speicherbereich zugeteilt
 - ▶ bei Return –"– freigegeben
- ▶ Adressenverweise („Pointer“)
 - ▶ Stackpointer %esp gibt das obere Ende des Stacks an
 - ▶ Framepointer %ebp gibt den Anfang des aktuellen Frame an

„Setup“ Code
 „Finish“ Code

Beispiel: Stack-Frame

Code Structure

```

yoo (...)
{
    .
    .
    who ();
    .
    .
}
    
```


```

who (...)
{
    . . .
    amI ();
    . . .
    amI ();
    . . .
}
    
```

```

amI (...)
{
    .
    .
    amI ();
    .
    .
}
    
```


Call Chain




Beispiel: Stack-Frame (cont.)




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain




Beispiel: Stack-Frame (cont.)




Call Chain



Beispiel: Stack-Frame (cont.)



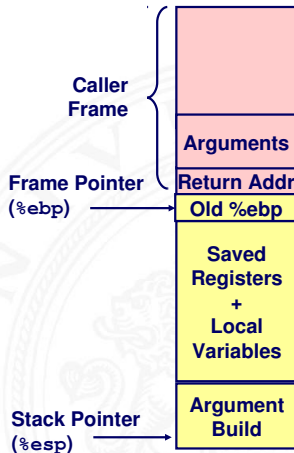
Call Chain



x86/Linux Stack-Frame

aktueller Stack-Frame

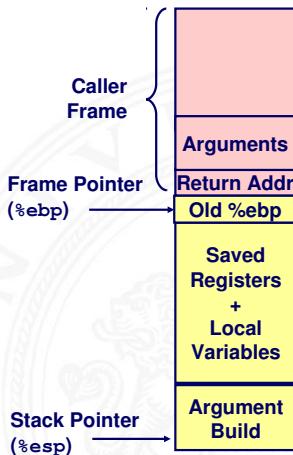
- ▶ von oben nach unten organisiert
„Top“ . . . „Bottom“
- ▶ Parameter für weitere Funktion
die aufgerufen wird `call`
- ▶ lokale Variablen
 - ▶ wenn sie nicht in Registern gehalten
werden können
- ▶ gespeicherter Registerkontext
- ▶ Zeiger auf vorherigen Frame



x86/Linux Stack-Frame (cont.)

„Caller“ Stack-Frame

- ▶ Rücksprungadresse
 - ▶ von call-Anweisung erzeugt
- ▶ Argumente für aktuellen Aufruf



Register Sicherungskonventionen

- ▶ yoo („Caller“) ruft Prozedur who („Callee“) auf

```

yoo:
    . . .
    movl $15213, %edx
    call who
    addl %edx, %eax
    . . .
    ret
    
```

```


who:
    . . .
    movl 8(%ebp), %edx
    addl $91125, %edx
    . . .
    ret
    
```

- ▶ kann who Register für vorübergehende Speicherung benutzen?
 - ▶ Inhalt von %edx wird von who überschrieben
- ⇒ zwei mögliche Konventionen
 - ▶ „Caller-Save“
yoo speichert in seinen Frame vor Prozeduraufruf
 - ▶ „Callee-Save“
who speichert in seinen Frame vor Benutzung

x86/Linux Register Verwendung

Integer Register

- ▶ zwei werden speziell verwendet
 - ▶ %ebp, %esp
- ▶ „Callee-Save“ Register
 - ▶ %ebx, %esi, %edi
 - ▶ alte Werte werden vor Verwendung auf dem Stack gesichert
- ▶ „Caller-Save“ Register
 - ▶ %eax, %edx, %ecx
 - ▶ “Caller” sichert diese Register
- ▶ Register %eax speichert auch den zurückgelieferten Wert






Beispiel: Rekursive Fakultät

```
int rfact(int x)
{
    int rval;
    if (x <= 1)
        return 1;
    rval = rfact(x-1);
    return rval * x;
}
```


- ▶ `%eax`
 - ▶ benutzt ohne vorheriges Speichern
- ▶ `%ebx`
 - ▶ am Anfang speichern
 - ▶ am Ende zurückschreiben

```
.globl rfact
.type
rfact,@function
rfact:
    pushl %ebp
    movl %esp,%ebp
    pushl %ebx
    movl 8(%ebp),%ebx
    cmpl $1,%ebx
    jle .L78
    leal -1(%ebx),%eax
    pushl %eax
    call rfact
    imull %ebx,%eax
    jmp .L79
.align 4
.L78:
    movl $1,%eax
.L79:
    movl -4(%ebp),%ebx
    movl %ebp,%esp
    popl %ebp
    ret
```

Beispiel: rfact – Stack „Setup“



```
rfact:
    pushl %ebp
    movl %esp,%ebp
    pushl %ebx
```



Beispiel: rfact – Rekursiver Aufruf

Recursion

```

movl 8(%ebp),%ebx    # ebx = x
cmpl $1,%ebx        # Compare x : 1
jle .L78             # If <= goto Term
leal -1(%ebx),%eax   # eax = x-1
pushl %eax           # Push x-1
call rfact           # rfact(x-1)
imull %ebx,%eax      # rval * x
jmp .L79             # Goto done
.L78:                # Term:
movl $1,%eax         # return val = 1
.L79:                # Done:
    
```

```

int rfact(int x)
{
    int rval;
    if (x <= 1)
        return 1;
    rval = rfact(x-1) ;
    return rval * x;
}
    
```

Registers


%ebx Stored value of x

%eax


- Temporary value of x-1
- Returned value from rfact(x-1)
- Returned value from this call

Beispiel: rfact – Rekursion


```
leal -1(%ebx), %eax
```



```
pushl %eax
```





```
call rfact
```




Beispiel: rfact – Ergebnisübergabe

Return from Call



Assume that `rfact(x-1)` returns `(x-1)!` in register `%eax`




```
imull %ebx,%eax
```



Beispiel: rfact – Stack „Finish“

```

movl -4(%ebp), %ebx
movl %ebp, %esp
popl %ebp
ret
    
```





Zeiger auf Adresse / *call by reference*

- ▶ Variable der aufrufenden Funktion soll modifiziert werden
- ⇒ Adressenverweis (*call by reference*)
- ▶ Beispiel: sfact

Recursive Procedure

```
void s_helper
(int x, int *accum)
{
    if (x <= 1)
        return;
    else {
        int z = *accum * x;
        *accum = z;
        s_helper (x-1, accum);
    }
}
```

Top-Level Call


```
int sfact(int x)
{
    int val = 1;
    s_helper(x, &val);
    return val;
}
```

Beispiel: sfact

Initial part of sfact

```

_sfact:
    pushl %ebp      # Save %ebp
    movl %esp,%ebp # Set %ebp
    subl $16,%esp  # Add 16 bytes
    movl 8(%ebp),%edx # edx = x
    movl $1,-4(%ebp) # val = 1
    
```



- ▶ lokale Variable val auf Stack speichern
 - ▶ Pointer auf val
 - ▶ berechnen als $-4(\%ebp)$
- ▶ Push val auf Stack
 - ▶ zweites Argument
 - ▶ `movl $1, -4(%ebp)`

```

int sfact(int x)
{
    int val = 1;
    s_helper(x, &val);
    return val;
}
    
```

Beispiel: `sfact` – Pointerübergabe bei Aufruf

Calling `s_helper` from `sfact`


```

leal -4(%ebp),%eax # Compute &val
pushl %eax         # Push on stack
pushl %edx         # Push x
call s_helper      # call
movl -4(%ebp),%eax # Return val
. . .             # Finish
    
```

```

int sfact(int x)
{
    int val = 1;
    s_helper(x, &val);
    return val;
}
    
```


Stack at time of call



Beispiel: sfact – Benutzung des Pointers

```

void s_helper
(int x, int *accum)
{
    . . .
    int z = *accum * x;
    *accum = z;
    . . .
}
    
```



```

. . .
movl %ecx,%eax    # z = x
imull (%edx),%eax # z *= *accum
movl %eax, (%edx) # *accum = z
. . .
    
```

- ▶ Register %ecx speichert x
- ▶ Register %edx mit Zeiger auf accum

Zusammenfassung: Stack

- ▶ Stack ermöglicht Rekursion
 - ▶ lokaler Speicher für jede Prozedur(aufruf) Instanz
 - ▶ Instanziierungen beeinflussen sich nicht
 - ▶ Adressierung lokaler Variablen und Argumente kann relativ zu Stackposition (Framepointer) sein
 - ▶ grundlegendes (Stack-) Verfahren
 - ▶ Prozeduren terminieren in umgekehrter Reihenfolge der Aufrufe
- ▶ x86 Prozeduren sind Kombination von Anweisungen + Konventionen
 - ▶ call / ret Anweisungen
 - ▶ Konventionen zur Registerverwendung
 - ▶ „Caller-Save“ / „Callee-Save“
 - ▶ %ebp und %esp
 - ▶ festgelegte Organisation des Stack-Frame

Grundlegende Datentypen

▶ Ganzzahl (Integer)

- ▶ wird in allgemeinen Registern gespeichert
- ▶ abhängig von den Anweisungen: *signed/unsigned*

Intel	GAS	Bytes	C
byte	b	1	[unsigned] char
word	w	2	[unsigned] short
double word	l	4	[unsigned] int

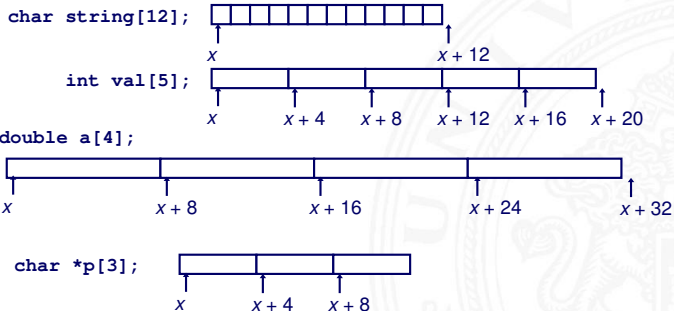
▶ Gleitkomma (Floating Point)

- ▶ wird in Gleitkomma-Registern gespeichert

Intel	GAS	Bytes	C
Single	s	4	float
Double	l	8	double
Extended	t	10/12	long double


Array: Allokation / Speicherung

- ▶ `T A[N];`
 - ▶ Array A mit Daten von Typ T und N Elementen
 - ▶ fortlaufender Speicherbereich von $N \times \text{sizeof}(T)$ Bytes



Array: Zugriffskonvention

- ▶ `T A[N];`
 - ▶ Array A mit Daten von Typ T und N Elementen
 - ▶ Bezeichner A zeigt auf erstes Element des Arrays: Element 0




Reference Type Value

<code>val[4]</code>	<code>int</code>		3
<code>val</code>	<code>int *</code>		x
<code>val+1</code>	<code>int *</code>		x+4
<code>&val[2]</code>	<code>int *</code>		x+8
<code>val[5]</code>	<code>int</code>		??
<code>*(val+1)</code>	<code>int</code>		5
<code>val + i</code>	<code>int *</code>		x+4 i

Beispiel: einfacher Arrayzugriff

```
typedef int zip_dig[5];

zip_dig cmu = { 1, 5, 2, 1, 3 };
zip_dig mit = { 0, 2, 1, 3, 9 };
zip_dig ucb = { 9, 4, 7, 2, 0 };
```





Beispiel: einfacher Arrayzugriff (cont.)

- ▶ Register `%edx`: Array Startadresse
`%eax`: Array Index
 - ▶ Adressieren von $4 \times \%eax + \%edx$
- ⇒ Speicheradresse `(%edx,%eax,4)`

```
int get_digit
(zip_dig z, int dig)
{
    return z[dig];
}
```

Memory Reference Code

```
# %edx = z
# %eax = dig
movl (%edx,%eax,4),%eax # z[dig]
```

- ▶ keine Bereichsüberprüfung („*bounds checking*“)
- ▶ Verhalten außerhalb des Indexbereichs ist Implementierungsabhängig



Beispiel: Arrayzugriff mit Schleife

▶ Originalcode

```
int zd2int(zip_dig z)
{
    int i;
    int zi = 0;
    for (i = 0; i < 5; i++) {
        zi = 10 * zi + z[i];
    }
    return zi;
}
```

▶ transformierte Version: gcc

- ▶ Laufvariable i eliminiert
- ▶ aus Array-Code wird Pointer-Code
- ▶ in „do-while“ Form
- ▶ Test bei Schleifeneintritt unnötig

```
int zd2int(zip_dig z)
{
    int zi = 0;
    int *zend = z + 4;
    do {
        zi = 10 * zi + *z;
        z++;
    } while(z <= zend);
    return zi;
}
```

Beispiel: Arrayzugriff mit Schleife (cont.)

- ▶ Register `%ecx:z`
`%edx:zi`
`%eax:zend`
- ▶ `*z + 2*(zi+4*zi)`
 ersetzt `10*zi + *z`
- ▶ `z++` Inkrement: `+4`

```
int zd2int(zip_dig z)
{
    int zi = 0;
    int *zend = z + 4;
    do {
        zi = 10 * zi + *z;
        z++;
    } while(z <= zend);
    return zi;
}
```

```
# %ecx = z
xorl %eax,%eax           # zi = 0
leal 16(%ecx),%ebx       # zend = z+4
.L59:
leal (%eax,%eax,4),%edx  # 5*zi
movl (%ecx),%eax        # *z
addl $4,%ecx            # z++
leal (%eax,%edx,2),%eax  # zi = *z + 2*(5*zi)
cmpl %ebx,%ecx          # z : zend
jle .L59                # if <= goto loop
```



Strukturen

- ▶ Allokation eines zusammenhängenden Speicherbereichs
- ▶ Elemente der Struktur über Bezeichner referenziert
- ▶ verschiedene Typen der Elemente sind möglich

```
struct rec {
    int i;
    int a[3];
    int *p;
};
```

Memory Layout




```
void
set_i(struct rec *r,
      int val)
{
    r->i = val;
}
```

Assembly

```
# %eax = val
# %edx = r
movl %eax, (%edx)    # Mem[r] = val
```

Strukturen: Zugriffskonventionen

- ▶ Zeiger auf Byte-Array für Zugriff auf Struktur(element) r
- ▶ Compiler bestimmt Offset für jedes Element



```
struct rec {
    int i;
    int a[3];
    int *p;
};
```

```
int *
find_a
(struct rec *r, int idx)
{
    return &r->a[idx];
}
```

```
# %ecx = idx
# %edx = r
leal 0(,%ecx,4),%eax # 4*idx
leal 4(%eax,%edx),%eax # r+4*idx+4
```



Beispiel: Strukturreferenzierung

```

struct rec {
    int i;
    int a[3];
    int *p;
};
    
```

```

void
set_p(struct rec *r)
{
    r->p =
        &r->a[r->i];
}
    
```



```

# %edx = r
movl (%edx),%ecx      # r->i
leal 0(,%ecx,4),%eax  # 4*(r->i)
leal 4(%edx,%eax),%eax # r+4+4*(r->i)
movl %eax,16(%edx)   # Update r->p
    
```



Ausrichtung der Datenstrukturen (*Alignment*)

- ▶ Datenstrukturen an Wortgrenzen ausrichten
 - double- / quad-word
 - ▶ sonst Problem
 - ineffizienter Zugriff über Wortgrenzen hinweg
 - virtueller Speicher und Caching
- ⇒ Compiler erzeugt „Lücken“ zur richtigen Ausrichtung
- ▶ typisches Alignment (IA32)


Länge	Typ		Windows	Linux
1 Byte	char	keine speziellen Verfahren		
2 Byte	short	Adressbits:	...0	...0
4 Byte	int, float, char *	–"–	...00	...00
8 Byte	double	–"–	...000	...00
12 Byte	long double	–"–	–	...00



Beispiel: Structure Alignment

```

struct S1 {
    char c;
    int i[2];
    double v;
} *p;
    
```





Zusammenfassung: Datentypen

- ▶ Arrays
 - ▶ fortlaufend zugeteilter Speicher
 - ▶ Adressverweis auf das erste Element
 - ▶ keine Bereichsüberprüfung (*Bounds Checking*)
- ▶ Compileroptimierungen
 - ▶ Compiler wandelt Array-Code in Pointer-Code um
 - ▶ verwendet Adressierungsmodi um Arrayindizes zu skalieren
 - ▶ viele Tricks, um die Array-Indizierung in Schleifen zu verbessern
- ▶ Strukturen
 - ▶ Bytes werden in der ausgewiesenen Reihenfolge zugeteilt
 - ▶ ggf. Leerbytes, um die richtige Ausrichtung zu erreichen




Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten



Gliederung (cont.)

- 14. Schaltwerke
- 15. Grundkomponenten für Rechensysteme
- 16. VLSI-Entwurf und -Technologie
- 17. Rechnerarchitektur
- 18. Instruction Set Architecture
- 19. Assembler-Programmierung
- 20. Computerarchitektur**
 - Befehlssätze / ISA
 - Sequenzielle Befehlsabarbeitung
 - Pipelining
 - Superskalare Prozessoren
 - Beispiele
- 21. Speicherhierarchie





Bewertung der ISA

Kriterien für einen *guten* Befehlssatz

- ▶ vollständig: alle notwendigen Instruktionen verfügbar
- ▶ orthogonal: keine zwei Instruktionen leisten das Gleiche
- ▶ symmetrisch: z.B. Addition \Leftrightarrow Subtraktion
- ▶ adäquat: technischer Aufwand entsprechend zum Nutzen
- ▶ effizient: kurze Ausführungszeiten

Statistiken zeigen: Dominanz der einfachen Instruktionen



Bewertung der ISA (cont.)

► x86-Prozessor

	Anweisung	Ausführungshäufigkeit %
1.	load	22 %
2.	conditional branch	20 %
3.	compare	16 %
4.	store	12 %
5.	add	8 %
6.	and	6 %
7.	sub	5 %
8.	move reg-reg	4 %
9.	call	1 %
10.	return	1 %
	Total	96 %


Bewertung der ISA (cont.)

Instruction	compress	eqntott	espresso	gcc (cc1)	li	Int. average
load	20.8%	18.5%	21.9%	24.9%	23.3%	22%
store	13.8%	3.2%	8.3%	16.6%	18.7%	12%
add	10.3%	8.8%	8.15%	7.6%	6.1%	8%
sub	7.0%	10.6%	3.5%	2.9%	3.6%	5%
mul				0.1%		0%
div						0%
compare	8.2%	27.7%	15.3%	13.5%	7.7%	16%
mov reg-reg	7.9%	0.6%	5.0%	4.2%	7.8%	4%
load imm	0.5%	0.2%	0.6%	0.4%		0%
cond. branch	15.5%	28.6%	18.9%	17.4%	15.4%	20%
uncond. branch	1.2%	0.2%	0.9%	2.2%	2.2%	1%
call	0.5%	0.4%	0.7%	1.5%	3.2%	1%
return, jmp indirect	0.5%	0.4%	0.7%	1.5%	3.2%	1%
shift	3.8%		2.5%	1.7%		1%
and	8.4%	1.0%	8.7%	4.5%	8.4%	6%
or	0.6%		2.7%	0.4%	0.4%	1%
other (xor, not, ...)	0.9%		2.2%	0.1%		1%
load FP						0%
store FP						0%
add FP						0%
sub FP						0%
mul FP						0%
div FP						0%
compare FP						0%
mov reg-reg FP						0%
other (abs, sqrt, ...)						0%


Figure D.15 80x86 instruction mix for five SPECint92 programs.

Bewertung der ISA (cont.)

► MIPS-Prozessor



SPECint2000 (96%)



SPECfp2000 (97%)



Bewertung der ISA (cont.)

- ▶ ca. 80 % der Berechnungen eines typischen Programms verwenden nur ca. 20 % der Instruktionen einer CPU
 - ▶ am häufigsten gebrauchten Instruktionen sind einfache Instruktionen: load, store, add. . .
- ⇒ Motivation für RISC



CISC – Befehlssätze

Complex Instruction Set Computer

- ▶ aus der Zeit der ersten Großrechner, 60er Jahre
- ▶ Programmierung auf Assemblerebene
- ▶ Komplexität durch sehr viele (mächtige) Befehle umgehen

CISC Befehlssätze

- ▶ Instruktionssätze mit mehreren hundert Befehlen (> 300)
- ▶ sehr viele Adressierungsarten, -Kombinationen
- ▶ verschiedene, unterschiedlich lange Instruktionsformate
- ▶ fast alle Befehle können auf Speicher zugreifen
 - ▶ mehrere Schreib- und Lesezugriffe pro Befehl
 - ▶ komplexe Adressberechnung

CISC – Befehlssätze (cont.)

- ▶ Stack-orientierter Befehlssatz
 - ▶ Übergabe von Argumenten
 - ▶ Speichern des Programmzählers
 - ▶ explizite „Push“ und „Pop“ Anweisungen
- ▶ Zustandscodes („Flags“)
 - ▶ gesetzt durch arithmetische und logische Anweisungen

Konsequenzen

- + nah an der Programmiersprache, einfacher Assembler
- + kompakter Code: weniger Befehle holen, kleiner I-Cache
- Pipelining schwierig
- Ausführungszeit abhängig von: Befehl, Adressmodi...
- Instruktion holen schwierig, da variables Instruktionsformat
- Speicherhierarchie schwer handhabbar: Adressmodi



CISC – Mikroprogrammierung

- ▶ ein Befehl kann nicht in einem Takt abgearbeitet werden
 - ⇒ Unterteilung in Mikroinstruktionen ($\approx 5 \dots 7$)
 - ▶ Ablaufsteuerung durch endlichen Automaten
 - ▶ meist als ROM (RAM) implementiert, das *Mikroprogrammwort* beinhaltet
1. horizontale Mikroprogrammierung
- ▶ langes Mikroprogrammwort (ROM-Zeile)
 - ▶ steuert direkt alle Operationen
 - ▶ Spalten entsprechen: Kontrollleitungen und Folgeadressen

CISC – Mikroprogrammierung (cont.)

2. vertikale Mikroprogrammierung

- ▶ kurze Mikroprogrammworter
- ▶ Spalten enthalten Mikrooperationscode
- ▶ mehrstufige Decodierung für Kontrollleitungen

+ CISC-Befehlssatz mit wenigen Mikrobefehlen realisieren

+ bei RAM: Mikrobefehlssatz austauschbar

– (mehrstufige) ROM/RAM Zugriffe: zeitaufwändig

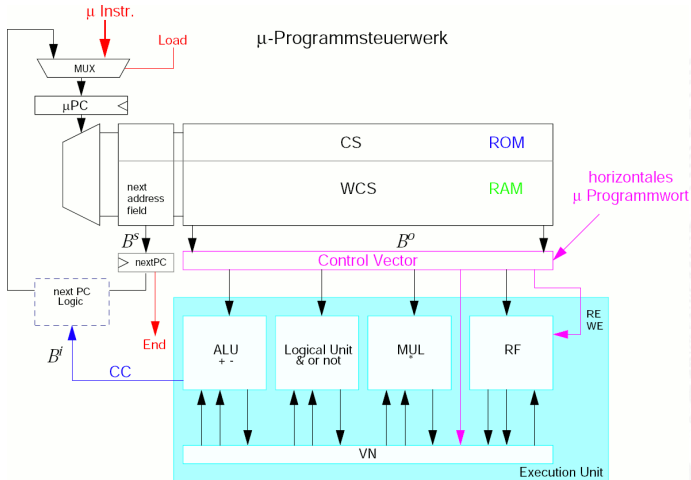


▶ horizontale Mikroprog.

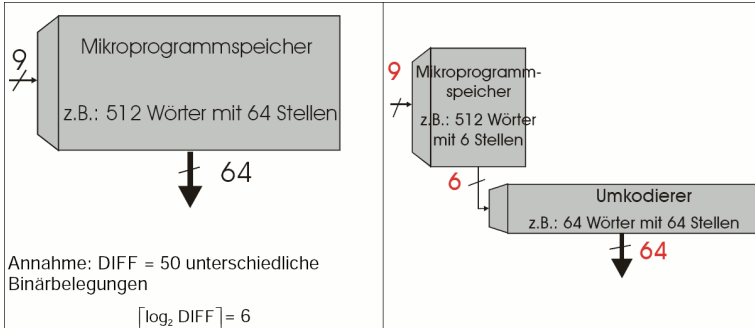


▶ vertikale Mikroprog.

horizontale Mikroprogrammierung



vertikale Mikroprogrammierung



◀ Mikroprogrammierung

RISC – Befehlssätze

Reduced Instruction Set Computer

- ▶ Grundidee: Komplexitätsreduktion in der CPU
- ▶ internes Projekt bei IBM, seit den 80er Jahren: „RISC-Boom“
 - ▶ von Hennessy (Stanford) und Patterson (Berkeley) publiziert
- ▶ Hochsprachen und optimierende Compiler
- ⇒ kein Bedarf mehr für mächtige Assemblerbefehle
- ⇒ pro Assemblerbefehl muss nicht mehr „möglichst viel“ lokal in der CPU gerechnet werden (CISC Mikroprogramm)

RISC – Befehlssätze (cont.)

RISC Befehlssätze

- ▶ reduzierte Anzahl einfacher Instruktionen (z.B. 128)
 - ▶ benötigen in der Regel mehr Anweisungen für eine Aufgabe
 - ▶ werden aber mit kleiner, schneller Hardware ausgeführt
- ▶ Register-orientierter Befehlssatz
 - ▶ viele Register (üblicherweise ≥ 32)
 - ▶ Register für Argumente, „Return“-Adressen, Zwischenergebnisse
- ▶ Speicherzugriff *nur* durch „Load“ und „Store“ Anweisungen
- ▶ alle anderen Operationen arbeiten auf Registern
- ▶ keine Zustandscodes (Flag-Register)
 - ▶ Testanweisungen speichern Resultat direkt im Register



RISC – Befehlssätze (cont.)

Konsequenzen

- + fest-verdrahtete Logik, kein Mikroprogramm
- + einfache Instruktionen, wenige Adressierungsarten
- + Pipelining gut möglich
- + Cycles per Instruction = 1
in Verbindung mit Pipelining: je Takt (mind.) ein neuer Befehl
- längerer Maschinencode
- viele Register notwendig
- ▶ optimierende Compiler nötig / möglich
- ▶ High-performance Speicherhierarchie notwendig

CISC vs. RISC

ursprüngliche Debatte

- ▶ streng geteilte Lager
- ▶ pro CISC: einfach für den Compiler; weniger Code Bytes
- ▶ pro RISC: besser für optimierende Compiler;
schnelle Abarbeitung auf einfacher Hardware

aktueller Stand

- ▶ Grenzen verwischen
 - ▶ RISC-Prozessoren werden komplexer
 - ▶ CISC-Prozessoren weisen RISC-Konzepte oder gar RISC-Kern auf
- ▶ für Desktop Prozessoren ist die Wahl der ISA kein Thema
 - ▶ Code-Kompatibilität ist sehr wichtig!
 - ▶ mit genügend Hardware wird alles schnell ausgeführt
- ▶ eingebettete Prozessoren: eindeutige RISC-Orientierung
 - + kleiner, billiger, weniger Leistungsverbrauch




ISA Design heute

- ▶ Restriktionen durch Hardware abgeschwächt
- ▶ Code-Kompatibilität leichter zu erfüllen
 - ▶ Emulation in Firm- und Hardware
- ▶ Intel bewegt sich weg von IA-32
 - ▶ erlaubt nicht genug Parallelität
- ▶ hat IA-64 eingeführt („Intel Architecture 64-bit“)
 - ⇒ neuer Befehlssatz mit expliziter Parallelität (EPIC)
 - ⇒ 64-bit Wortgrößen (überwinden Adressraumlimits)
 - ⇒ benötigt hoch entwickelte Compiler

Sequenzielle Hardwarestruktur

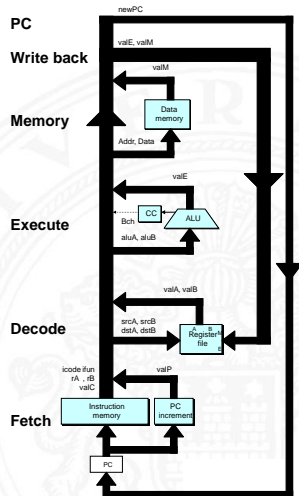
- ▶ **interner Zustand**
 - ▶ Programmzähler Register PC
 - ▶ Zustandscode Register CC
 - ▶ Registerbank
 - ▶ Speicher
 - ▶ gemeinsamer Speicher für Daten und Anweisungen

- ▶ **von-Neumann Abarbeitung**
 - ▶ Befehl aus Speicher laden
PC enthält Adresse
 - ▶ Verarbeitung durch die Stufen
 - ▶ Programmzähler aktualisieren




Sequenzielle Befehlsabarbeitung

- ▶ Befehl holen „Fetch“
 - ▶ Anweisung aus Speicher lesen
- ▶ Befehl decodieren „Decode“
 - ▶ Befehlsregister interpretieren
 - ▶ Operanden holen
- ▶ Befehl ausführen „Execute“
 - ▶ berechne Wert oder Adresse
- ▶ Speicherzugriff „Memory“
 - ▶ Daten lesen oder schreiben
- ▶ Registerzugriff „Write Back“
 - ▶ in Registerbank schreiben
- ▶ Programmzähler aktualisieren
 - ▶ inkrementieren –oder–
 - ▶ Speicher-/Registerinhalt bei Sprung



Pipelining / Fließbandverarbeitung



Grundidee

- ▶ Operation F kann in Teilschritte zerlegt werden
- ▶ jeder Teilschritt f_i braucht ähnlich viel Zeit
- ▶ alle Teilschritte f_i können parallel zueinander ausgeführt werden
- ▶ Trennung der Pipelinestufen („stage“) durch Register
- ▶ Zeitbedarf für Teilschritt $f_i \gg$ Zugriffszeit auf Register (t_{co})



Pipelining / Fließbandverarbeitung (cont.)

Pipelining-Konzept

- ▶ Prozess in unabhängige Abschnitte aufteilen
- ▶ Objekt sequenziell durch diese Abschnitte laufen lassen
- ▶ zu jedem gegebenen Zeitpunkt werden zahlreiche Objekte bearbeitet

Konsequenz

- ▶ lässt Vorgänge gleichzeitig ablaufen
- ▶ „Real-World Pipelines“: Autowaschanlagen

Pipelining / Fließbandverarbeitung (cont.)


Arithmetische Pipelines

- ▶ Idee: lange Berechnung in Teilschritte zerlegen
wichtig bei komplizierteren arithmetischen Operationen
 - ▶ die sonst sehr lange dauern (weil ein großes Schaltnetz)
 - ▶ die als Schaltnetz extrem viel Hardwareaufwand erfordern
 - ▶ Beispiele: Multiplikation, Division, Fließkommaoperationen...
- + Erhöhung des Durchsatzes, wenn Berechnung mehrfach hintereinander ausgeführt wird

(RISC) Prozessorpipelines

- ▶ Idee: die Phasen der von-Neumann Befehlsabarbeitung (Befehl holen, Befehl decodieren ...) als Pipeline implementieren


Berechnungsbeispiel: ohne Pipeline



System

- ▶ Verarbeitung erfordert 300 ps
- ▶ weitere 20 ps um das Resultat im Register zu speichern
- ▶ Zykluszeit: mindestens 320 ps

Berechnungsbeispiel: Version mit 3-stufiger Pipeline




System


- ▶ Kombinatorische Logik in 3 Blöcke zu je 100 ps aufgeteilt
- ▶ neue Operation, sobald vorheriger Abschnitt durchlaufen wurde
 ⇒ alle 120 ps neue Operation
- ▶ allgemeine Latenzzunahme
 ⇒ 360 ps von Start bis Ende

Funktionsweise der Pipeline

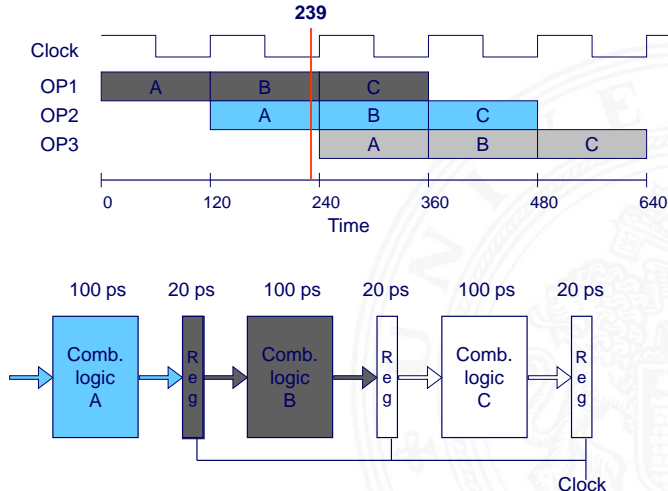
▶ ohne Pipeline



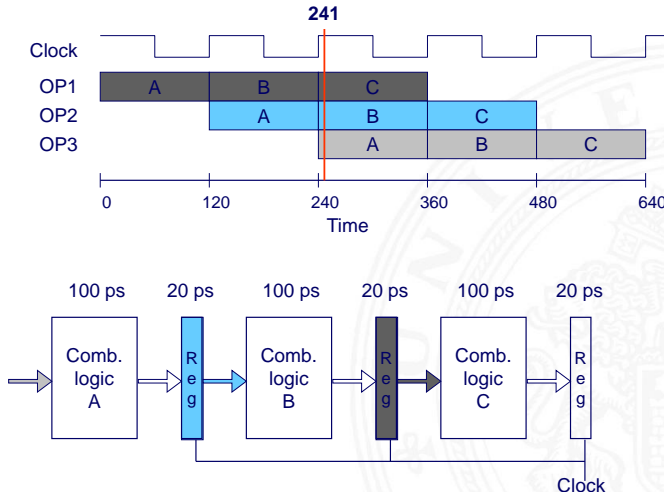
▶ 3-stufige Pipeline





Beispiel: 3-stufige Pipeline





Beispiel: 3-stufige Pipeline



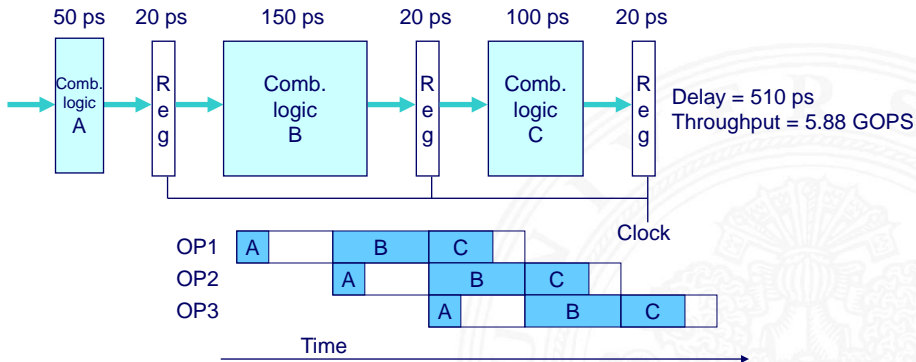
Beispiel: 3-stufige Pipeline



Beispiel: 3-stufige Pipeline




Probleme: nicht uniforme Verzögerungen



- ▶ größte Verzögerung bestimmt Taktfrequenz

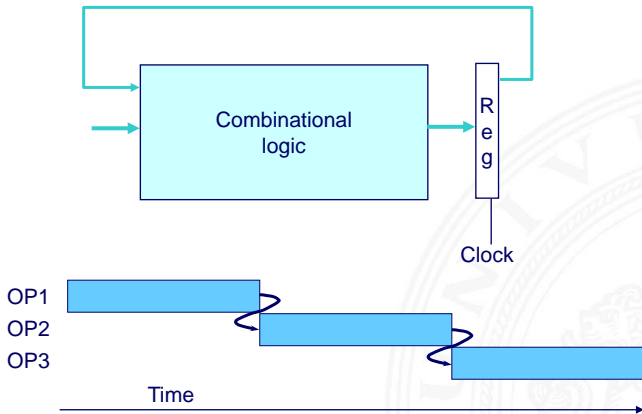
Probleme: Register „Overhead“



- ▶ registerbedingter Overhead wächst mit Pipelinelänge
- ▶ (anteilige) Taktzeit für das Laden der Register

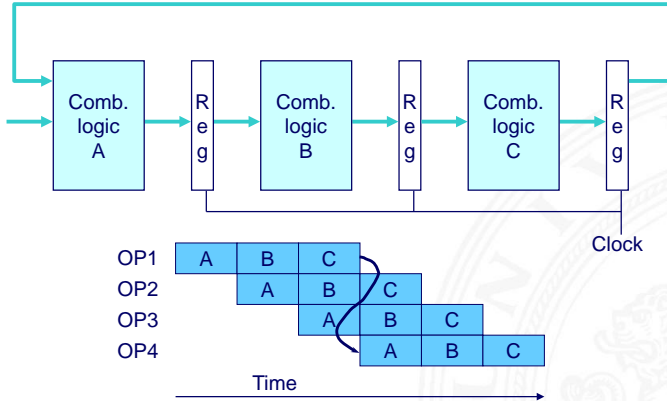
	Overhead	Taktperiode
1-Register:	6,25%	20 ps
3-Register:	16,67%	20 ps
6-Register:	28,57%	20 ps

Probleme: Datenabhängigkeiten / „Daten Hazards“



- ▶ jede Operation hängt vom Ergebnis der Vorhergehenden ab

Probleme: Datenabhängigkeiten / „Daten Hazards“ (cont.)



- ⇒ Resultat-Feedback kommt zu spät für die nächste Operation
- ⇒ Pipelining ändert Verhalten des gesamten Systems

RISC Pipelining

Schritte der RISC Befehlsabarbeitung (von ISA abhängig)

- ▶ **IF** **I**nstruction **F**etch
 Instruktion holen, in Befehlsregister laden

- ID** **I**nstruction **D**ecode
 Instruktion decodieren

- OF** **O**perand **F**etch
 Operanden aus Registern holen


- EX** **E**xecute
 ALU führt Befehl aus

- MEM** **M**emory access
 Speicherzugriff bei Load-/Store-Befehlen

- WB** **W**rite **B**ack
 Ergebnisse in Register zurückschreiben

RISC Pipelining (cont.)

- ▶ je nach Instruktion sind 3-5 dieser Schritte notwendig
- ▶ Beispiel *ohne* Pipelining:




Patterson, Hennessy, *Computer Organization and Design*

RISC Pipelining (cont.)

Pipelining in Prozessoren

- ▶ Beispiel *mit* Pipelining:




Patterson, Hennessy, *Computer Organization and Design*

- ▶ Befehle überlappend ausführen
- ▶ Register trennen Pipelinestufen

RISC Pipelining (cont.)

- ▶ RISC ISA: Pipelining wird direkt umgesetzt

Pipelinstufen



- ▶ MIPS-Architektur (aus Patterson, Hennessy)

▶ MIPS ohne Pipeline

▶ MIPS Pipeline

▶ Pipeline Schema


- ▶ Bryant, O'Hallaron, *Computer systems*

▶ Pipeline – Register

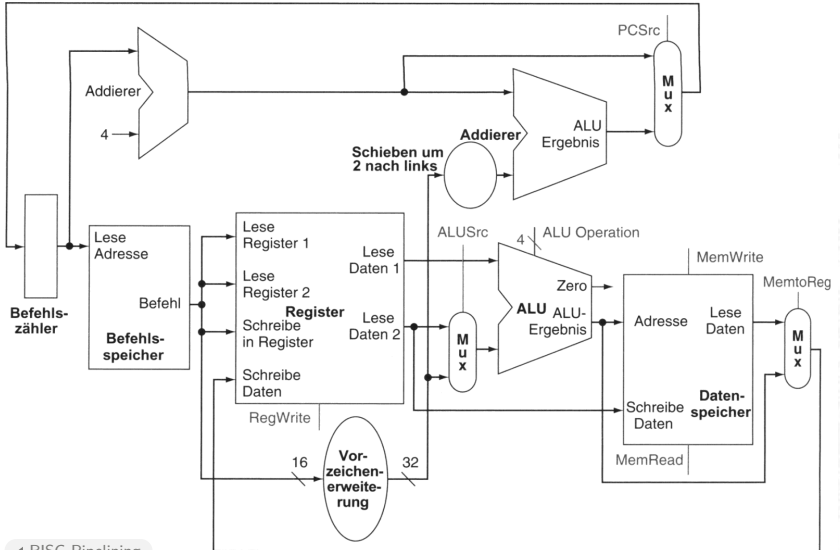
▶ Pipeline – Architektur

RISC Pipelining (cont.)

- ▶ CISC ISA (x86): Umsetzung der CISC Befehle in Folgen RISC-ähnlicher Anweisungen



- + CISC-Software bleibt lauffähig
- + Befehlssatz wird um neue RISC Befehle erweitert



◀ RISC Pipelining

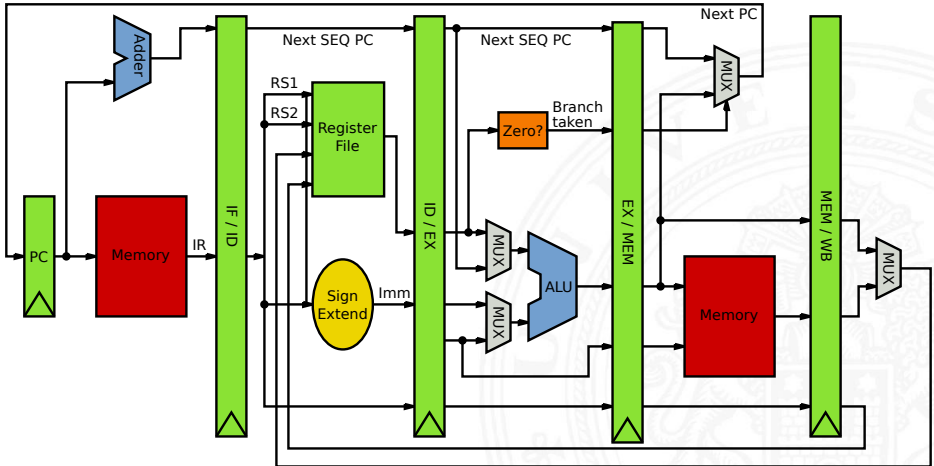
Instruction Fetch
IF

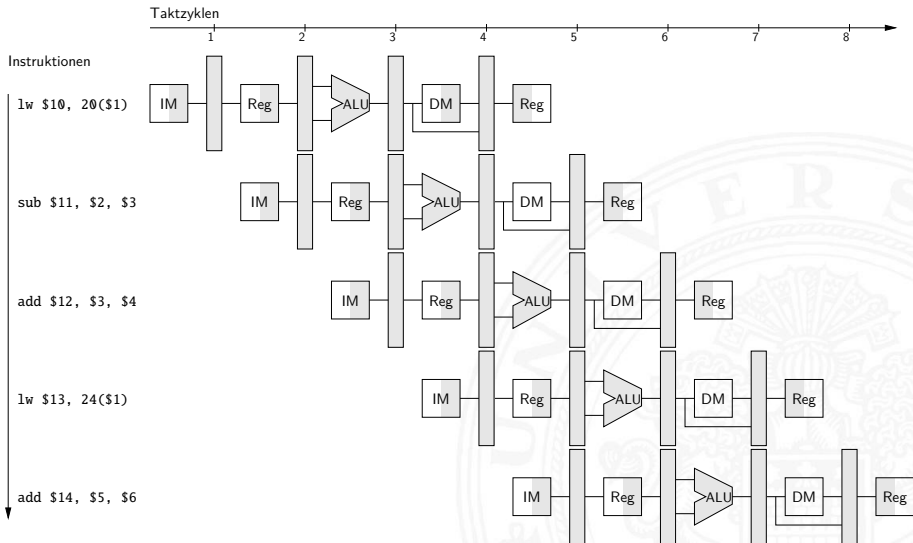
Instruction Decode
Register Fetch
ID

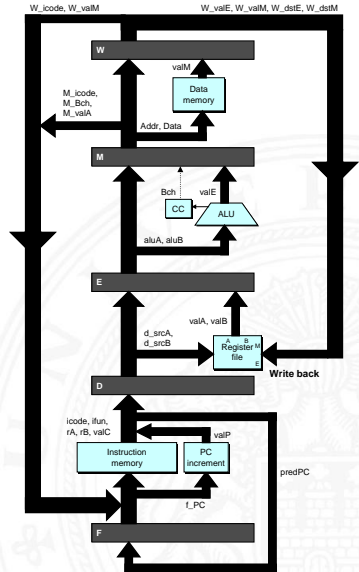
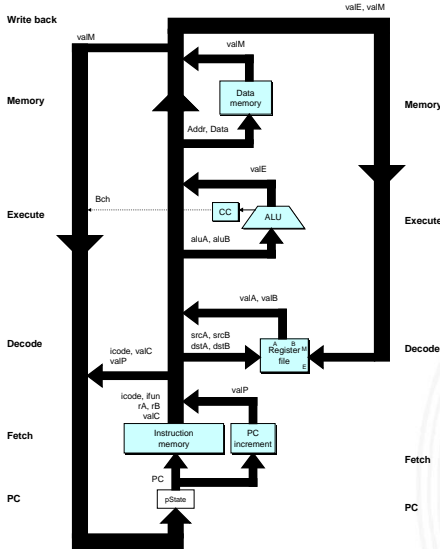
Execute
Address Calc.
EX

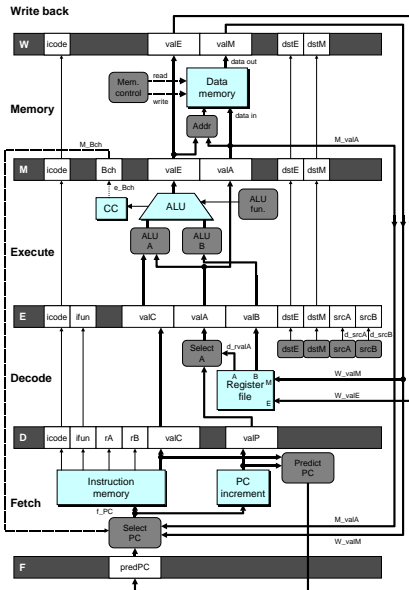
Memory Access
MEM

Write Back
WB











Prozessorpipeline – Begriffe

Begriffe

- ▶ **Pipeline-Stage:** einzelne Stufe der Pipeline
- ▶ **Pipeline Machine Cycle:**
Instruktion kommt einen Schritt in Pipeline weiter
- ▶ **Durchsatz:** Anzahl der Instruktionen, die in jedem Takt abgeschlossen werden
- ▶ **Latenz:** Zeit, die eine Instruktion benötigt, um alle Pipelinestufen zu durchlaufen



Prozessorpipeline – Bewertung

Vor- und Nachteile

- + Pipelining ist für den Programmierer nicht sichtbar!
- + höherer Instruktionsdurchsatz \Rightarrow bessere Performanz
- Latenz wird nicht verbessert, bleibt bestenfalls gleich
- Pipeline Takt limitiert durch langsamste Pipelinestufe
unausgewogene Pipelinestufen reduzieren den Takt und damit die Performanz
- zusätzliche Zeiten, um Pipeline zu füllen bzw. zu leeren



Prozessorpipeline – Speed-Up

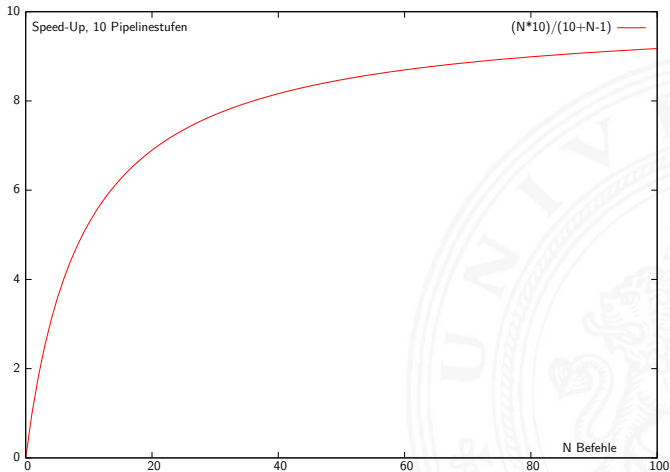
Pipeline Speed-Up

- ▶ N Instruktionen; K Pipelinestufen
- ▶ ohne Pipeline: $N \cdot K$ Taktzyklen
- ▶ mit Pipeline: $K + N - 1$ Taktzyklen
- ▶ Speed-Up = $\frac{N \cdot K}{K + N - 1}$, $\lim_{N \rightarrow \infty} S = K$

⇒ ein großer Speed-Up wird erreicht durch

1. große Pipelinetiefe: K
2. lange Instruktionssequenzen: N

Prozessorpipeline – Speed-Up (cont.)



Prozessorpipeline – Dimensionierung

Dimensionierung der Pipeline

- ▶ Längere Pipelines
- ▶ Pipelinestufen in den Einheiten / den ALUs (*superskalar*)
- ⇒ größeres K wirkt sich direkt auf den Durchsatz aus
- ⇒ weniger Logik zwischen den Registern, höhere Taktfrequenzen
- ▶ Beispiele

CPU	Pipelinestufen	Taktfrequenz [MHz]
Pentium	5	300
Motorola G4	4	500
Motorola G4e	7	1000
Pentium II/III	12	1400
Athlon XP	10/15	2500
Athlon 64, Opteron	12/17	≤ 3000
Pentium 4	20	≤ 5000

Prozessorpipeline – Auswirkungen

Architekturentscheidungen, die sich auf das Pipelining auswirken

gut für Pipelining

- ▶ gleiche Instruktionslänge
- ▶ wenige Instruktionsformate
- ▶ Load/Store Architektur

BASIC INSTRUCTION FORMATS

R	opcode	rs	rt	rd	shamt	funct	
	31	26 25	21 20	16 15	11 10	6 5	
							0

I	opcode	rs	rt	immediate	
	31	26 25	21 20	16 15	
					0

J	opcode	address	
	31	26 25	
			0

FLOATING-POINT INSTRUCTION FORMATS

FR	opcode	fnt	ft	fs	fd	funct	
	31	26 25	21 20	16 15	11 10	6 5	
							0

FI	opcode	fnt	ft	immediate	
	31	26 25	21 20	16 15	
					0

MIPS-Befehlsformate



Prozessorpipeline – Auswirkungen (cont.)

schlecht für Pipelining: *Pipelinekonflikte / -Hazards*

- ▶ Strukturkonflikt: gleichzeitiger Zugriff auf eine Ressource durch mehrere Pipelinestufen
- ▶ Datenkonflikt: Ergebnisse von Instruktionen werden innerhalb der Pipeline benötigt
- ▶ Steuerkonflikt: Sprungbefehle in der Pipelinesequenz

sehr schlecht für Pipelining

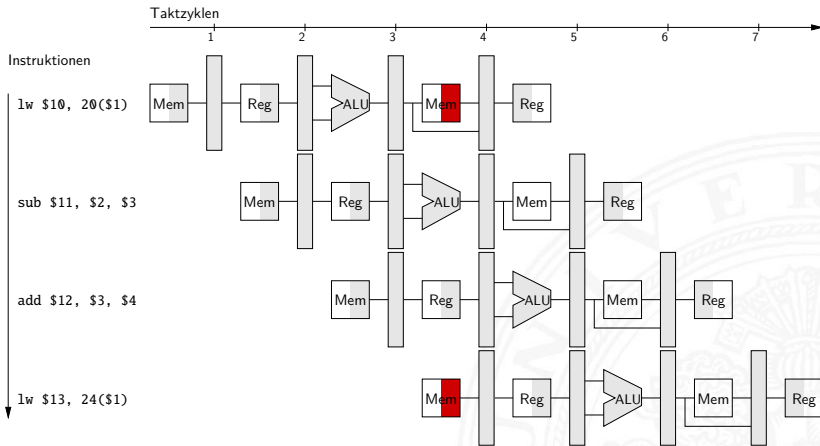
- ▶ Unterbrechung des Programmkontexts: Interrupt, System-Call, Exception. . .
- ▶ (Performanz-) Optimierungen mit „Out-of-Order Execution“ etc.

Pipeline Strukturkonflikte

Strukturkonflikt / Structural Hazard

- ▶ mehrere Stufen wollen gleichzeitig auf eine Ressource zugreifen
 - ▶ Beispiel: gleichzeitiger Zugriff auf Speicher
- ⇒ Mehrfachauslegung der betreffenden Ressourcen
- ▶ Harvard-Architektur vermeidet Strukturkonflikt aus Beispiel
 - ▶ Multi-Port Register
 - ▶ mehrfach vorhandene Busse und Multiplexer...

▶ Beispiel



◀ Strukturkonflikte

Pipeline Datenkonflikte

Datenkonflikt / Data Hazard

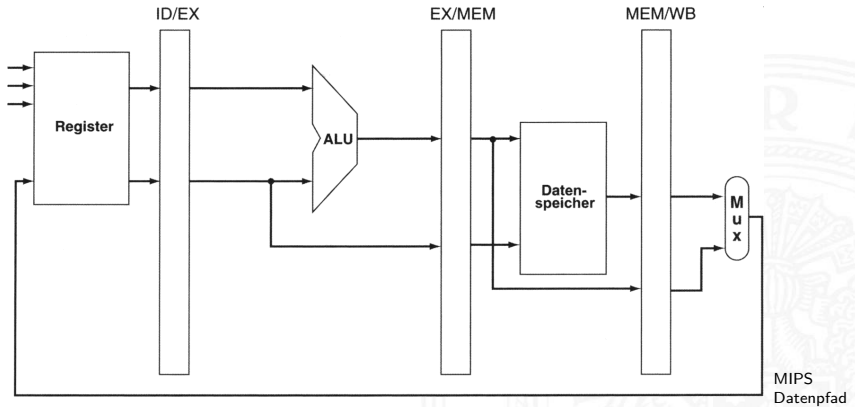
- ▶ eine Instruktion braucht die Ergebnisse einer vorhergehenden, diese wird aber noch in der Pipeline bearbeitet
- ▶ Datenabhängigkeiten der Stufe „Befehl ausführen“

▶ Beispiel


Forwarding

- ▶ kann Datenabhängigkeiten auflösen, s. Beispiel
- ▶ extra Hardware: „*Forwarding-Unit*“
- ▶ Änderungen in der Pipeline Steuerung
- ▶ neue Datenpfade und Multiplexer

Pipeline Datenkonflikte (cont.)



Pipeline Datenkonflikte (cont.)



Pipeline Datenkonflikte (cont.)

Rückwärtsabhängigkeiten

- ▶ spezielle Datenabhängigkeit
- ▶ Forwarding-Technik funktioniert nicht, da die Daten erst *später* zur Verfügung stehen
 - ▶ bei längeren Pipelines
 - ▶ bei Load-Instruktionen (s.u.)

▶ Beispiel

Auflösen von Rückwärtsabhängigkeiten

1. Softwarebasiert, durch den Compiler, Reihenfolge der Instruktionen verändern
 - ▶ andere Operationen (ohne Datenabhängigkeiten) vorziehen
 - ▶ nop-Befehl(e) einfügen

▶ Beispiel



Pipeline Datenkonflikte (cont.)


2. „Interlocking“


▶ Beispiel


- ▶ zusätzliche (Hardware) Kontrolleinheit
- ▶ verschiedene Strategien
- ▶ in Pipeline werden keine neuen Instruktionen geladen
- ▶ Hardware erzeugt: Pipelineleerlauf / „*pipeline stall*“

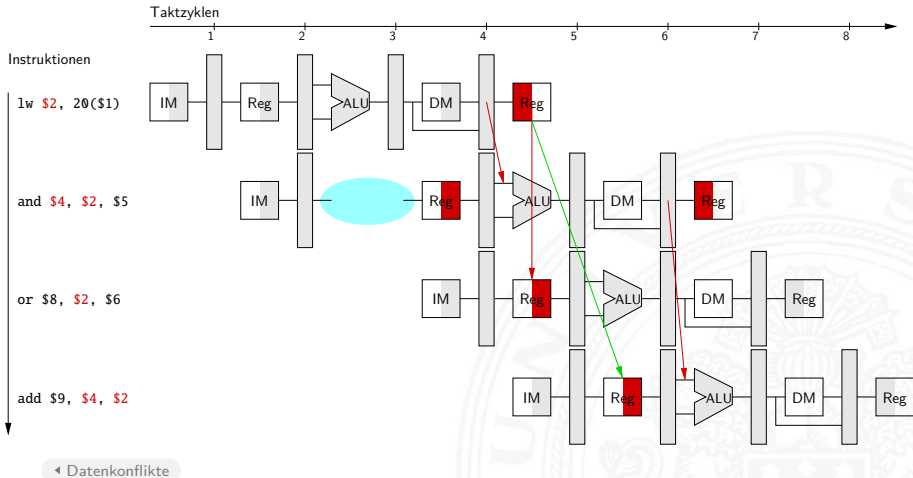
„Scoreboard“

- ▶ Hardware Einheit zur zentralen Hazard-Erkennung und -Auflösung
- ▶ Verwaltet Instruktionen, benutzte Einheiten und Register der Pipeline











Pipeline Steuerkonflikte

Steuerkonflikt / Control Hazard

- ▶ Sprungbefehle unterbrechen den sequenziellen Ablauf der Instruktionen
- ▶ Problem: Instruktionen die auf (bedingte) Sprünge folgen, werden in die Pipeline geschoben, bevor bekannt ist, ob verzweigt werden soll
- ▶ Beispiel: bedingter Sprung

▶ Beispiel



Pipeline Steuerkonflikte (cont.)

Lösungsmöglichkeiten für Steuerkonflikte

- ▶ ad-hoc Lösung: „Interlocking“ erzeugt Pipelineleerlauf
 - ineffizient: ca. 19% der Befehle sind Sprünge
- 1. Annahme: nicht ausgeführter Sprung / „untaken branch“
 - + kaum zusätzliche Hardware
 - im Fehlerfall
 - ▶ Pipelineleerlauf
 - ▶ Pipeline muss geleert werden / „flush instructions“
- 2. Sprungentscheidung „vorverlegen“
 - ▶ Software: Compiler zieht andere Instruktionen vor
Verzögerung nach Sprungbefehl / „delay slots“
 - ▶ Hardware: Sprungentscheidung durch Zusatz-ALU
(nur Vergleiche) während Befehlsdecodierung (z.B. MIPS)

Pipeline Steuerkonflikte (cont.)

3. Sprungvorhersage / „branch prediction“

- ▶ Beobachtung: ein Fall tritt häufiger auf:
Schleifendurchlauf, Datenstrukturen durchsuchen etc.
- ▶ mehrere Vorhersageverfahren; oft miteinander kombiniert
- + hohe Trefferquote: bis 90 %

Statische Sprungvorhersage (softwarebasiert)


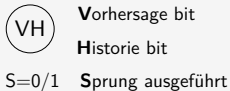

- ▶ Compiler erzeugt extra Bit in Opcode des Sprungbefehls
- ▶ Methoden: Codeanalyse, Profiling...

Dynamische Sprungvorhersage (hardwarebasiert)

- ▶ Sprünge durch Laufzeitinformation vorhersagen:
Wie oft wurde der Sprung in letzter Zeit ausgeführt?
- ▶ viele verschiedene Verfahren:
History-Bit, 2-Bit Prädiktor, korrelationsbasierte Vorhersage,
Branch History Table, Branch Target Cache...

Pipeline Steuerkonflikte (cont.)

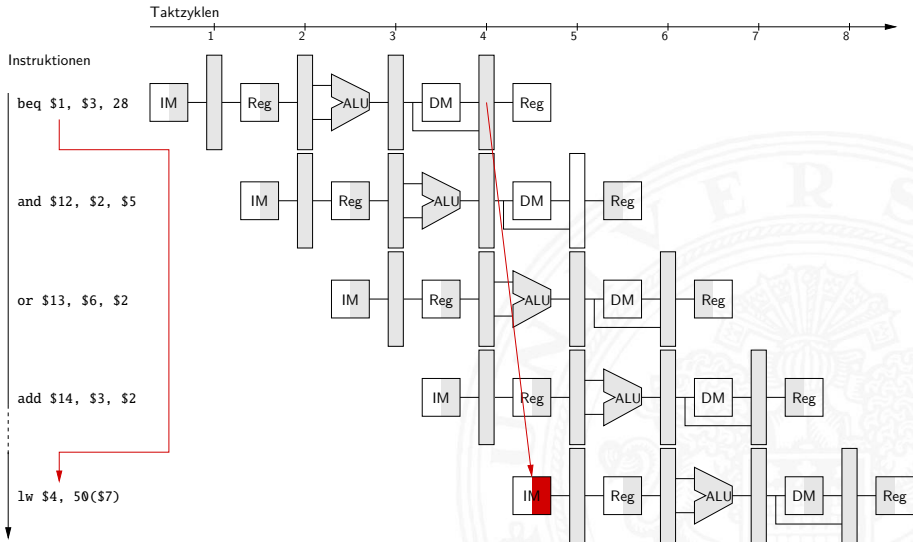
- Beispiel: 2-Bit Sprungvorhersage + Branch Target Cache





Pipeline Steuerkonflikte (cont.)

- ▶ Schleifen abrollen / „Loop unrolling“
 - ▶ zusätzliche Maßnahme zu allen zuvor skizzierten Verfahren
 - ▶ bei statische Schleifenbedingung möglich
 - ▶ Compiler iteriert Instruktionen in der Schleife (teilweise)
 - längerer Code
 - + Sprünge und Abfragen entfallen
 - + erzeugt sehr lange Codesequenzen ohne Sprünge
 - ⇒ Pipeline kann optimal ausgenutzt werden



◀ Steuerkonflikte



Superskalare Prozessoren

- ▶ Superskalare CPUs besitzen mehrere Recheneinheiten: 4...10
- ▶ In jedem Takt werden (dynamisch) mehrere Instruktionen eines konventionell linearen Instruktionsstroms abgearbeitet: $CPI < 1$ ILP (Instruction **L**evel **P**arallelism) ausnutzen!
- ▶ Hardware verteilt initiierte Instruktionen auf Recheneinheiten
- ▶ Pro Takt kann *mehr als eine* Instruktion initiiert werden
Die Anzahl wird dynamisch von der Hardware bestimmt:
0... „*Instruction Issue Bandwidth*“
- + sehr effizient, alle modernen CPUs sind superskalar
- Abhängigkeiten zwischen Instruktionen sind der Engpass, das Problem der Hazards wird verschärft



Superskalar – Datenabhängigkeiten

Datenabhängigkeiten

- ▶ RAW – **R**ead **A**fter **W**rite
Instruktion I_x darf Datum erst lesen, wenn I_{x-n} geschrieben hat
- ▶ WAR – **W**rite **A**fter **R**ead
Instruktion I_x darf Datum erst schreiben, wenn I_{x-n} gelesen hat
- ▶ WAW – **W**rite **A**fter **W**rite
Instruktion I_x darf Datum erst überschreiben, wenn I_{x-n} geschrieben hat



Superskalar – Datenabhängigkeiten (cont.)

Datenabhängigkeiten superskalarer Prozessoren

- ▶ RAW: echte Abhängigkeit; Forwarding ist kaum möglich und in superskalaren Pipelines extrem aufwändig
- ▶ WAR, WAW: „*Register Renaming*“ als Lösung

„*Register Renaming*“

- ▶ Hardware löst Datenabhängigkeiten innerhalb der Pipeline auf
- ▶ Zwei Registersätze sind vorhanden
 1. Architektur-Register: „logische Register“ der ISA
 2. viele Hardware-Register: „Rename Register“
 - ▶ dynamische Abbildung von ISA- auf Hardware-Register

Superskalar – Datenabhängigkeiten (cont.)

► Beispiel


Originalcode	nach Renaming
<code>tmp = a + b;</code>	<code>tmp1 = a + b;</code>
<code>res1 = c + tmp;</code>	<code>res1 = c + tmp1;</code>
<code>tmp = d + e;</code>	<code>tmp2 = d + e;</code>
<code>res2 = tmp - f;</code>	<code>res2 = tmp2 - f;</code>
	<code>tmp = tmp2;</code>

Parallelisierung des modifizierten Codes

```
tmp1 = a + b;      tmp2 = d + e;
res1 = c + tmp1;  res2 = tmp2 - f;  tmp = tmp2;
```

Superskalar – Pipeline

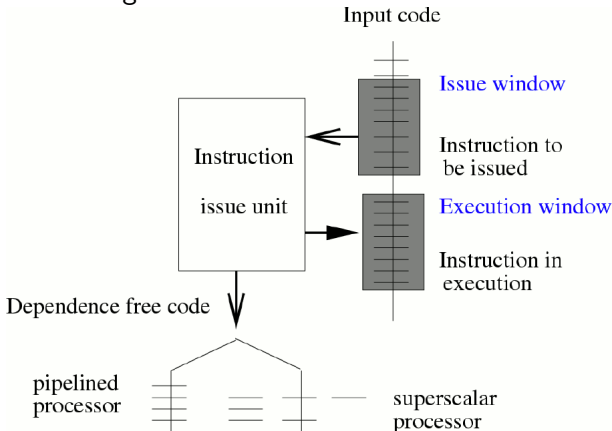
Aufbau der superskalaren Pipeline



- ▶ lange Pipelines mit vielen Phasen: Fetch (Prefetch, Predecode), Decode / Register-Renaming, Issue, Dispatch, Execute, Retire (Commit, Complete / Reorder), Write-Back
- ▶ je nach Implementation unterschiedlich aufgeteilt
- ▶ entscheidend für superskalare Architektur sind die Schritte vor den ALUs: Issue, Dispatch \Rightarrow *out-of-order* Ausführung
 nach "-" : Retire \Rightarrow *in-order* Ergebnisse


Superskalar – Pipeline (cont.)

Scheduling der Instruktionen



Superskalar – Pipeline (cont.)

- ▶ Dynamisches Scheduling erzeugt *out-of-order* Reihenfolge der Instruktionen
- ▶ Issue: globale Sicht
 Dispatch: getrennte Ausschnitte in „Reservation Stations“



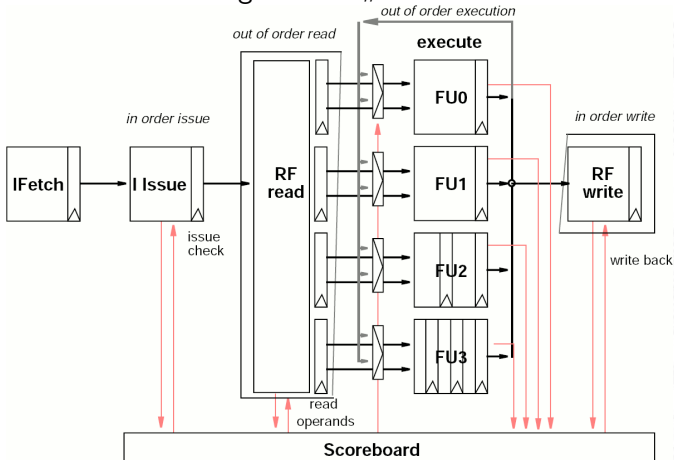
Superskalar – Pipeline (cont.)

Reservation Station für jede Funktionseinheit

- ▶ speichert: initiierte Instruktionen die auf Recheneinheit warten
 - ▶ –"– zugehörige Operanden
 - ▶ –"– ggf. Zusatzinformation
 - ▶ Instruktion bleibt blockiert, bis alle Parameter bekannt sind und wird dann an die zugehörige ALU weitergeleitet
- ▶ Dynamisches Scheduling: zuerst '67 in IBM 360 (Robert Tomasulo)
 - ▶ Forwarding
 - ▶ Registerumbenennung und Reservation Stations

Superskalar – Scoreboard

Zentrale Verwaltungseinheit: „Scoreboard“





Superskalar – Scoreboard (cont.)

Scoreboard erlaubt das Management mehrerer Ausführungseinheiten

- ▶ out-of-order Ausführung von Mehrzyklusbefehlen
- ▶ Auflösung aller Struktur- und Datenkonflikte:
RAW, WAW, WAR

Einschränkungen

- ▶ single issue (nicht superskalar)
- ▶ in-order issue
- ▶ keine Umbenennungen; also Leerzyklen bei WAR- und WAW-Konflikten
- ▶ kein Forwarding, daher Zeitverlust bei RAW-Konflikten



Superskalar – Retire-Stufe

„Retire“

- ▶ erzeugt wieder *in-order* Reihenfolge
- ▶ FIFO: Reorder-Buffer
- ▶ commit: „richtig ausgeführte“ Instruktionen gültig machen
- ▶ abort: Sprungvorhersage falsch
Instruktionen verwerfen



Probleme superskalarer Pipelines

Spezielle Probleme superskalarer Pipelines

- weitere Hazard-Möglichkeiten
 - ▶ die verschiedenen ALUs haben unterschiedliche Latenzzeiten
 - ▶ Befehle „warten“ in den Reservation Stations
- ⇒ Datenabhängigkeiten können sich mit jedem Takt ändern
- Kontrollflussabhängigkeiten: Anzahl der Instruktionen zwischen bedingten Sprüngen limitiert Anzahl parallelisierbarer Instruktion
- ⇒ „Loop Unrolling“ wichtig
 - + optimiertes (dynamisches) Scheduling: Faktor 3 möglich



Software Pipelining

Softwareunterstützung für Pipelining superskalarer Prozessoren

- ▶ Codeoptimierungen beim Compilieren: Ersatz für, bzw. Ergänzend zu der Pipelineunterstützung durch Hardware
- ▶ Compiler hat „globalen“ Überblick
⇒ zusätzliche Optimierungsmöglichkeiten
- ▶ symbolisches Loop Unrolling
- ▶ Loop Fusion
- ▶ ...

Superskalar – Interrupts

Exceptions, Interrupts und System-Calls

- ▶ Interruptbehandlung ist wegen der Vielzahl paralleler Aktionen und den Abhängigkeiten innerhalb der Pipelines extrem aufwändig
 - ▶ da unter Umständen noch Pipelineaktionen beendet werden müssen, wird *zusätzliche Zeit* bis zur Interruptbehandlung benötigt
 - ▶ wegen des Register-Renaming muss sehr viel *mehr Information* gerettet werden als nur die ISA-Register
- ▶ Prinzip der Interruptbehandlung
 - ▶ keine neuen Instruktionen mehr initiieren
 - ▶ warten bis Instruktionen des Reorder-Buffers abgeschlossen sind

Superskalar – Interrupts (cont.)

- ▶ Verfahren ist von der „Art“ des Interrupt abhängig
 - ▶ Precise-Interrupt: Pipelineaktivitäten komplett Beenden
 - ▶ Imprecise-Interrupt: wird als verzögerter Sprung (Delayed-Branching) in Pipeline eingebracht
 Zusätzliche Register speichern Information über Instruktionen die in der Pipeline nicht abgearbeitet werden können (z.B. weil sie den Interrupt ausgelöst haben)
- ▶ Definition: Precise-Interrupt
 - ▶ Programmzähler (PC) zur Interrupt auslösenden Instruktion ist bekannt
 - ▶ Alle Instruktionen bis zur PC-Instruktion wurden vollständig ausgeführt
 - ▶ Keine Instruktion nach der PC-Instruktion wurde ausgeführt
 - ▶ Ausführungszustand der PC-Instruktion ist bekannt



Ausnahmebehandlung

Ausnahmebehandlung („Exception Handling“)

- ▶ Pipeline kann normalen Ablauf nicht fortsetzen
- ▶ Ursachen
 - ▶ „Halt“ Anweisung
 - ▶ ungültige Adresse für Anweisung oder Daten
 - ▶ ungültige Anweisung
 - ▶ Pipeline Kontrollfehler
- ▶ erforderliches Vorgehen
 - ▶ einige Anweisungen vollenden
Entweder aktuelle oder vorherige (hängt von Ausnahmetyp ab)
 - ▶ andere verwerfen
 - ▶ „Exception Handler“ aufrufen: spez. Prozeduraufruf

Pentium 4 / NetBurst Architektur

- ▶ superskalare Architektur (mehrere ALUs)
- ▶ CISC-Befehle werden dynamisch in „ μ OPs“ (1...3) umgesetzt
- ▶ Ausführung der μ OPs mit „Out of Order“ Maschine, wenn
 - ▶ Operanden verfügbar sind
 - ▶ funktionelle Einheit (ALU) frei ist
- ▶ Ausführung wird durch „Reservation Stations“ kontrolliert
 - ▶ beobachtet die Datenabhängigkeiten zwischen μ OPs
 - ▶ teilt Ressourcen zu
- ▶ „Trace“ Cache
 - ▶ ersetzt traditionellen Anweisungs-cache
 - ▶ speichert Anweisungen in decodierter Form: Folgen von μ OPs
 - ▶ reduziert benötigte Rate für den Anweisungsdecoder

Pentium 4 / NetBurst Architektur (cont.)

- ▶ „Double pumped“ ALUs (2 Operationen pro Taktzyklus)
- ▶ große Pipelinelänge \Rightarrow sehr hohe Taktfrequenzen

Basic Pentium III Processor Misprediction Pipeline									
1	2	3	4	5	6	7	8	9	10
Fetch	Fetch	Decode	Decode	Decode	Rename	ROB Rd	Rdy/Sch	Dispatch	Exec

Basic Pentium 4 Processor Misprediction Pipeline																			
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
TC	Nxt IP	TC	Fetch	Drive	Alloc	Rename	Que	Sch	Sch	Sch	Disp	Disp	RF	RF	Ex	Figs	Br Ck	Drive	

- ▶ umfangreiches Material von Intel unter:
ark.intel.com, techresearch.intel.com

Pentium 4 / NetBurst Architektur (cont.)

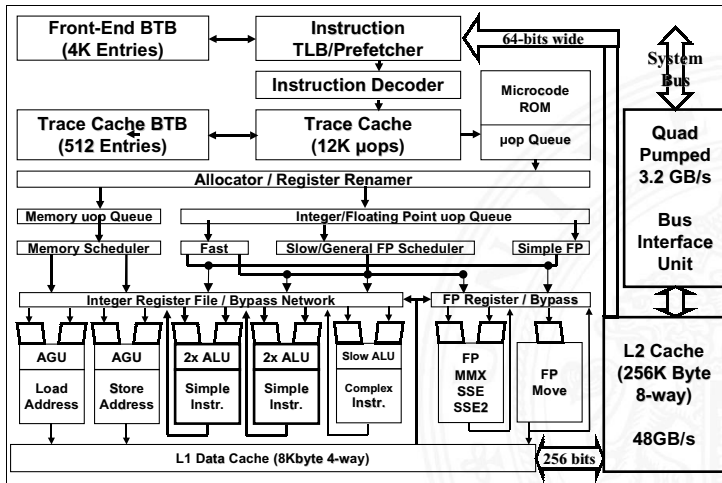
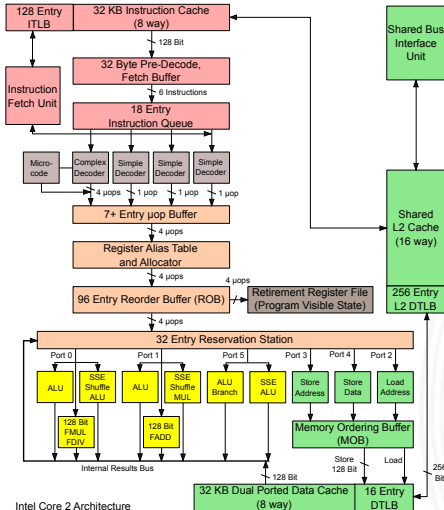


Figure 4: Pentium® 4 processor microarchitecture

Core 2 Architektur



Intel Core 2 Architecture



Gliederung

1. Einführung
2. Digitalrechner
3. Moore's Law
4. Information
5. Zahldarstellung
6. Arithmetik
7. Textcodierung
8. Boole'sche Algebra
9. Logische Operationen
10. Codierung
11. Schaltfunktionen
12. Schaltnetze
13. Zeitverhalten





Gliederung (cont.)

14. Schaltwerke
15. Grundkomponenten für Rechensysteme
16. VLSI-Entwurf und -Technologie
17. Rechnerarchitektur
18. Instruction Set Architecture
19. Assembler-Programmierung
20. Computerarchitektur
- 21. Speicherhierarchie**

Speichertypen

- Halbleiterspeicher

- Festplatten

- spezifische Eigenschaften

Motivation



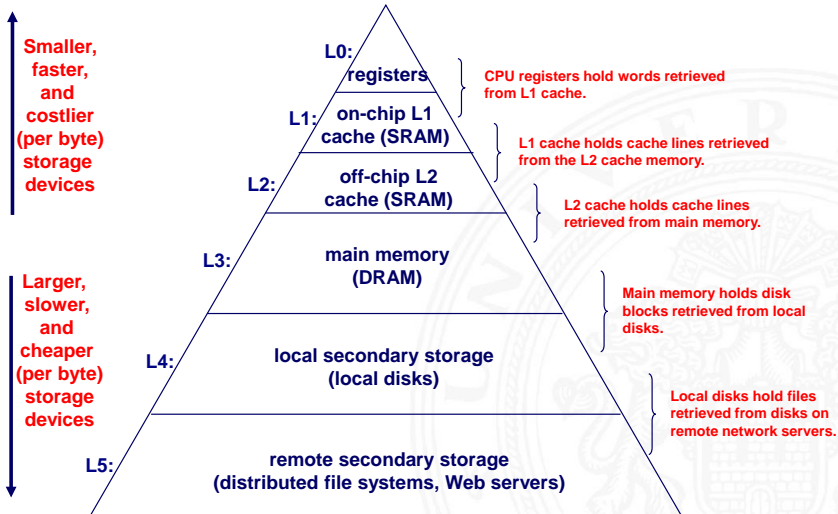


Gliederung (cont.)

Cache Speicher
Virtueller Speicher
 Beispiel: Pentium und Linux




Speicherhierarchie: Konzept



Random-Access Memory / RAM

- ▶ RAM ist als Chip gepackt
- ▶ Grundspeichereinheit ist eine Zelle (ein Bit pro Zelle)
- ▶ Viele RAM Chips bilden einen Speicher





Random-Access Memory / RAM (cont.)

Statischer RAM (SRAM)

- ▶ jede Zelle speichert Bits mit einer 6-Transistor Schaltung
- ▶ speichert Wert solange er mit Energie versorgt wird
- ▶ relativ unanfällig gegen Störungen wie elektrische Brummspannungen
- ▶ schneller und teurer als DRAM

Dynamischer RAM (DRAM)

- ▶ jede Zelle speichert Bits mit einem Kondensator und einem Transistor
- ▶ der Wert muss alle 10-100 ms aufgefrischt werden
- ▶ anfällig für Störungen
- ▶ langsamer und billiger als SRAM

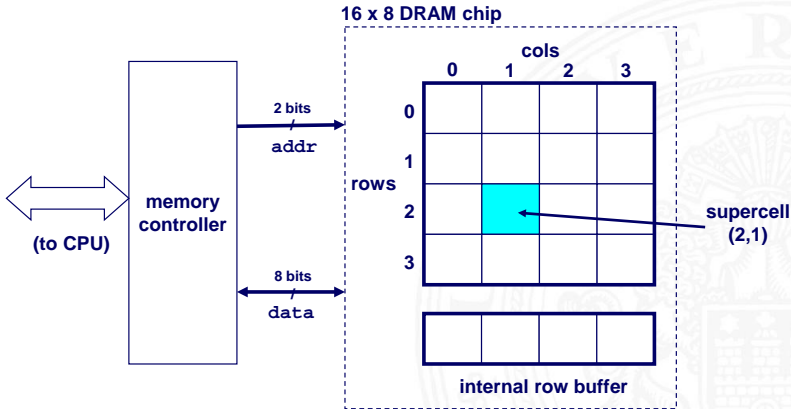
SRAM vs. DRAM

	SRAM	DRAM
Zugriffszeit	5... 50 ns	60... 100 ns t_{rac} 20... 300 ns t_{cac} 110... 180 ns t_{cyc}
Leistungsaufnahme	200... 1300 mW	300... 600 mW
Speicherkapazität	< 72 Mbit	< 4 Gbit
Preis	10 €/Mbit	0,2 Ct./Mbit

	Tran. per bit	Access time	Persist?	Sensitive?	Cost	Applications
SRAM	6	1X	Yes	No	100x	cache memories
DRAM	1	10X	No	Yes	1X	Main memories, frame buffers

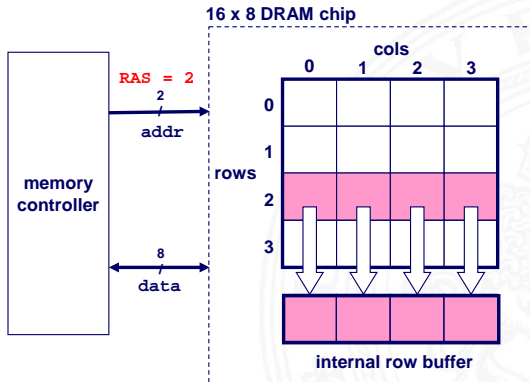
DRAM Organisation

- ▶ $(d \times w)$ DRAM: organisiert als d -Superzellen mit w -bits



Lesen der DRAM Zelle (2,1)


- 1.a „Row Access Strobe“ (RAS) wählt Zeile 2
- 1.b Zeile aus DRAM Array in Zeilenpuffer („Row Buffer“) kopieren



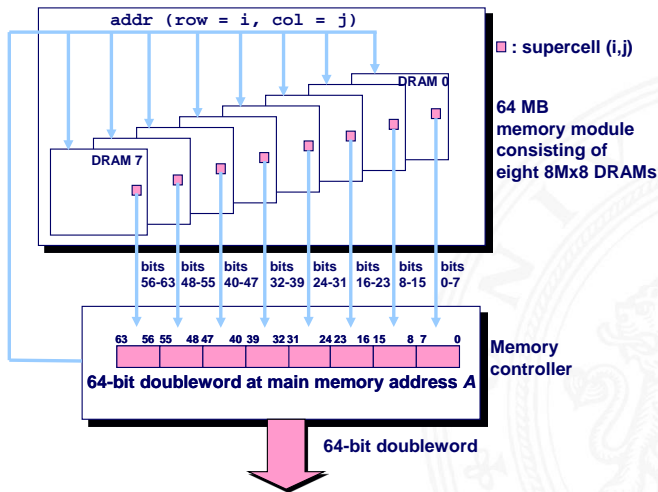
Lesen der DRAM Zelle (2,1) (cont.)

2.a „Column Access Strobe“ (CAS) wählt Spalte 1

2.b Superzelle (2,1) aus Buffer lesen und auf Datenleitungen legen



Speichermodule



Nichtflüchtige Speicher

- ▶ DRAM und SRAM sind flüchtige Speicher
 - ▶ Informationen gehen beim Abschalten verloren
- ▶ nichtflüchtige Speicher speichern Werte selbst wenn sie spannungslos sind
 - ▶ allgemeiner Name ist „Read-Only-Memory“ (ROM)
 - ▶ irreführend, da einige ROMs auch verändert werden können
- ▶ Arten von ROMs
 - ▶ PROM: programmierbarer ROM
 - ▶ EPROM: „Eraseable Programmable ROM“ löscher (UV Licht), programmierbar
 - ▶ EEPROM: „Electrically Eraseable PROM“ elektrisch löscherbarer PROM
 - ▶ Flash Speicher



Nichtflüchtige Speicher (cont.)


Anwendungsbeispiel: nichtflüchtige Speicher

- ▶ Firmware
- ▶ Programm wird in einem ROM gespeichert
 - ▶ Boot Code, BIOS („Basic Input/Output System“)
 - ▶ Grafikkarten, Festplattencontroller

Bussysteme verbinden CPU und Speicher


- ▶ Busse
 - ▶ Bündel paralleler Leitungen
 - ▶ es gibt mehr als einen Treiber \Rightarrow Tristate-Treiber
- ▶ Busse im Rechner
 - ▶ zur Übertragung von Adressen, Daten und Kontrollsignalen
 - ▶ werden üblicherweise von mehreren Geräten genutzt

CPU chip




lesender Speicherzugriff

1. CPU legt Adresse A auf den Speicherbus



lesender Speicherzugriff (cont.)


- 2.a Hauptspeicher liest Adresse A vom Speicherbus
 2.b -- ruft das Wort x unter der Adresse A ab
 2.c -- legt das Wort x auf den Bus



lesender Speicherzugriff (cont.)


3.a CPU liest Wort x vom Bus

3.b `--` kopiert Wert x in Register `%eax`




schreibender Speicherzugriff

- 1 CPU legt die Adresse A auf den Bus
- 2.b Hauptspeicher liest Adresse
- 2.c --" wartet auf Ankunft des Datenworts



schreibender Speicherzugriff (cont.)


3. CPU legt Datenwort y auf den Bus



schreibender Speicherzugriff (cont.)

4.a Hauptspeicher liest Datenwort y vom Bus


4.b —"— speichert Datenwort y unter Adresse A



Speicheranbindung – DMA


DMA – **D**irect **M**emory **A**ccess

- ▶ eigener Controller zum Datentransfer
- + Speicherzugriffe unabhängig von der CPU
- + CPU kann lokal (Register und Cache) weiterrechnen




Festplattengeometrie

- ▶ Platten mit jeweils zwei Oberflächen („surfaces“)
- ▶ konzentrische Ringe der Oberfläche bilden Spuren („tracks“)
- ▶ Spur unterteilt in Sektoren („sectors“), durch Lücken („gaps“) getrennt



Festplattengeometrie (cont.)

- ▶ untereinander liegende Spuren (mehrerer Platten) bilden einen Zylinder





Festplattenkapazität

- ▶ Kapazität: Höchstzahl speicherbarer Bits
- ▶ bestimmende technologische Faktoren
 - ▶ Aufnahmedichte [bits/in]: # Bits / 1-Inch Segment einer Spur
 - ▶ Spurdichte [tracks/in]: # Spuren / 1-Inch (radial)
 - ▶ Flächendichte [bits/in²]: Aufnahme- × Spurdichte
- ▶ Spuren unterteilt in getrennte Zonen („Recording Zones“)
 - ▶ jede Spur einer Zone hat gleichviel Sektoren
(festgelegt durch die Ausdehnung der innersten Spur)
 - ▶ jede Zone hat unterschiedlich viele Sektoren/Spuren

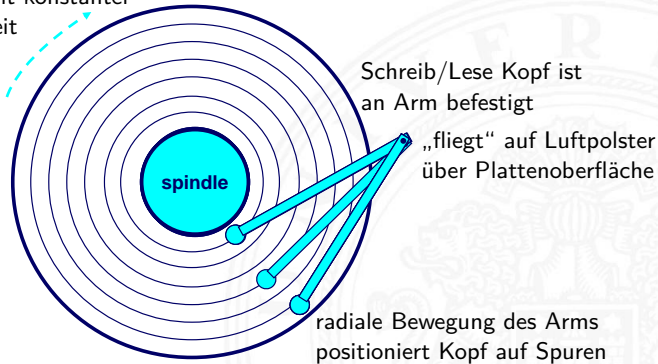


Festplattenkapazität (cont.)

- ▶ Kapazität = Bytes/Sektor \times \emptyset Sektoren/Spur \times
Spuren/Oberfläche \times Oberflächen/Platten \times
Platten/Festplatte
 - ▶ Beispiel
 - ▶ 512 Bytes/Sektor
 - ▶ 300 Sektoren/Spuren (im Durchschnitt)
 - ▶ 20 000 Spuren/Oberfläche
 - ▶ 2 Oberflächen/Platten
 - ▶ 5 Platten/Festplatte
- \Rightarrow Kapazität = $512 \times 300 \times 20\,000 \times 2 \times 5$
 $= 30\,720\,000\,000 = 30,72 \text{ GB}$


Festplatten-Operation

- ▶ Ansicht einer Platte
Umdrehung mit konstanter
Geschwindigkeit



Festplatten-Operation (cont.)

- ▶ Ansicht mehrerer Platten



Schreib/Lese Köpfe werden gemeinsam auf Zylindern positioniert



Festplatten-Zugriffszeit

Durchschnittliche (avg) Zugriffszeit auf einen Zielsektor wird angenähert durch

$$\blacktriangleright T_{Zugriff} = T_{avgSuche} + T_{avgRotationslatenz} + T_{avgTransfer}$$

Suchzeit ($T_{avgSuche}$)

- ▶ Zeit in der Schreib-Lese Köpfe („heads“) über den Zylinder mit dem Targetsektor positioniert werden
- ▶ üblicherweise $T_{avgSuche} = 8 \text{ ms}$

Festplatten-Zugriffszeit (cont.)

Rotationslatenzzeit ($T_{avgRotationslatenz}$)

- ▶ Wartezeit, bis das erste Bit des Targetsektors unter dem Schreib-Lese-Kopf durchrotiert
- ▶ $T_{avgRotationslatenz} = 1/2 \times 1/RPMs \times 60 \text{ Sek}/1 \text{ Min}$

Transferzeit ($T_{avgTransfer}$)

- ▶ Zeit, in der die Bits des Targetsektors gelesen werden
- ▶ $T_{avgTransfer} = 1/RPM \times 1/(\text{Durchschn. \# Sektoren/Spur}) \times 60 \text{ Sek}/1 \text{ Min}$

Festplatten-Zugriffszeit (cont.)

Beispiel für Festplatten-Zugriffszeit

- ▶ Umdrehungszahl = 7 200 RPM („Rotations per Minute“)
- ▶ Durchschnittliche Suchzeit = 8 ms
- ▶ Avg # Sektoren/Spur = 400

⇒ $T_{avgRotationslatenz}$

$$= 1/2 \times (60 \text{ Sek}/7\,200 \text{ RPM}) \times 1\,000 \text{ ms/Sek} = 4 \text{ ms}$$

⇒ $T_{avgTransfer}$

$$= 60/7\,200 \text{ RPM} \times 1/400 \text{ Sek/Spur} \times 1\,000 \text{ ms/Sek} = 0,02 \text{ ms}$$

⇒ $T_{avgZugriff}$

$$= 8 \text{ ms} + 4 \text{ ms} + 0,02 \text{ ms}$$



Festplatten-Zugriffszeit (cont.)

Fazit

- ▶ Zugriffszeit wird von Suchzeit und Rotationslatenzzeit dominiert
- ▶ erstes Bit eines Sektors ist das „teuerste“, der Rest ist quasi umsonst
- ▶ SRAM Zugriffszeit ist ca. 4 ns DRAM ca. 60 ns
- ▶ Kombination aus Zugriffszeit und Datentransfer
 - ▶ Festplatte ist ca. 40 000 mal langsamer als SRAM
 - ▶ 2 500 mal langsamer als DRAM

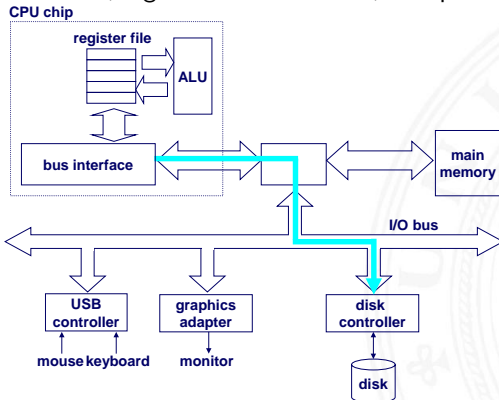


Logische Festplattenblöcke

- ▶ simple, abstrakte Ansicht der komplexen Sektorengeometrie
 - ▶ verfügbare Sektoren werden als Sequenz logischer Blöcke der Größe b modelliert $(0,1,2,\dots,n)$
- ▶ Abbildung der logischen Blöcke auf die tatsächlichen (physikalischen) Sektoren
 - ▶ durch Hard-/Firmware Einheit (Festplattencontroller)
 - ▶ konvertiert logische Blöcke zu Tripeln (Oberfläche, Spur, Sektor)
- ▶ Controller kann für jede Zone Ersatzzylinder bereitstellen
 - ⇒ Unterschied: „formatierte Kapazität“ und „maximale Kapazität“

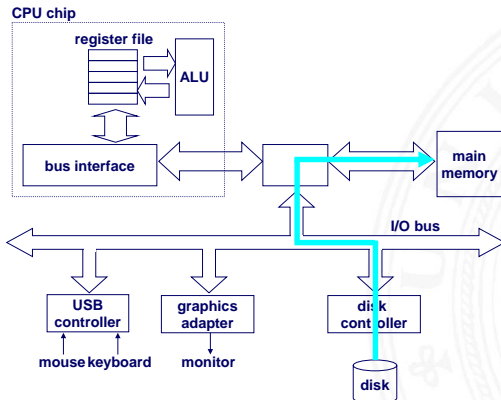
Lesen eines Festplattensektors

1. CPU initiiert Lesevorgang von Festplatte auf Port (Adresse) des Festplattencontrollers wird geschrieben
 - ▶ Befehl, logische Blocknummer, Zielspeicheradresse



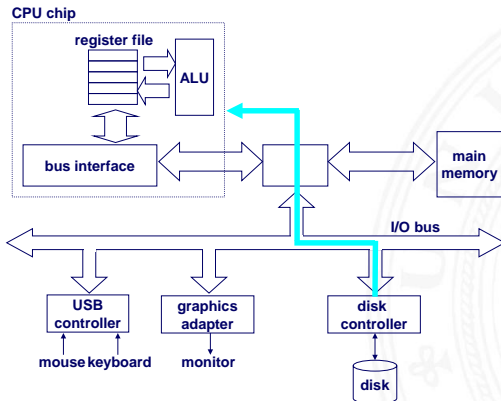
Lesen eines Festplattensektors (cont.)

2. Festplattencontroller liest den Sektor aus
3. —"— führt DMA-Zugriff auf Hauptspeicher aus




Lesen eines Festplattensektors (cont.)

4. Festplattencontroller löst Interrupt aus



Eigenschaften der Speichertypen


► Speicher	Vorteile	Nachteile
Register	sehr schnell	sehr teuer
SRAM	schnell	teuer, große Chips
DRAM	hohe Integration	Refresh nötig, langsam
Platten	billig, Kapazität	sehr langsam, mechanisch
► Beispiel	Hauptspeicher	Festplatte
Latenz	8 ns	4 ms
Bandbreite	≈ 38,4 GByte/sec (triple Channel)	≈ 750 MByte/sec (typisch < 300)
Kosten	1 GByte, 5 €	1 TByte, 40 € (4 Ct./GByte)



Speicherhierarchie

Motivation

- ▶ Geschwindigkeit der Prozessoren
- ▶ Kosten für den Speicherplatz
- ▶ permanente Speicherung
 - ▶ magnetisch
 - ▶ optisch
 - ▶ mechanisch



Speicherhierarchie (cont.)

Fundamentale Eigenschaften von Hard- und Software

- ▶ schnelle vs. langsame Speichertechnologie

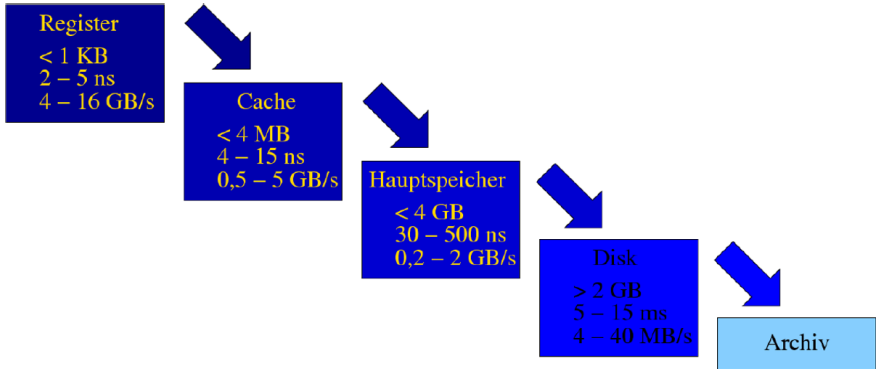
schnell	:	hohe	Kosten/Byte	geringe	Kapazität
langsam	:	geringe	—"–	hohe	—"–
- ▶ Abstand zwischen CPU und Hauptspeichergeschwindigkeit vergrößert sich
- ▶ Lokalität der Programme wichtig
 - ▶ kleiner Adressraum im Programmkontext
 - ▶ gut geschriebene Programme haben meist eine gute Lokalität

⇒ Motivation für spezielle Organisation von Speichersystemen
Speicherhierarchie

Speicherhierarchie (cont.)

Cache Type	What Cached	Where Cached	Latency (cycles)	Managed By
Registers	4-byte word	CPU registers	0	Compiler
TLB	Address translations	On-Chip TLB	0	Hardware
L1 cache	32-byte block	On-Chip L1	1	Hardware
L2 cache	32-byte block	Off-Chip L2	10	Hardware
Virtual Memory	4-KB page	Main memory	100	Hardware+ OS
Buffer cache	Parts of files	Main memory	100	OS
Network buffer cache	Parts of files	Local disk	10,000,000	AFS/NFS client
Browser cache	Web pages	Local disk	10,000,000	Web browser
Web cache	Web pages	Remote server disks	1,000,000,000	Web proxy server

Verwaltung der Speicherhierarchie






Verwaltung der Speicherhierarchie (cont.)

Verwaltung der Speicherhierarchie

- ▶ Register \leftrightarrow Memory
 - ▶ Compiler
 - ▶ Assembler-Programmierer
- ▶ Cache \leftrightarrow Memory
 - ▶ Hardware
- ▶ Memory \leftrightarrow Disk
 - ▶ Hardware und Betriebssystem (Paging)
 - ▶ Programmierer (Files)

Cache

- ▶ „Memory Wall“: DRAM zu langsam für CPU






Cache (cont.)

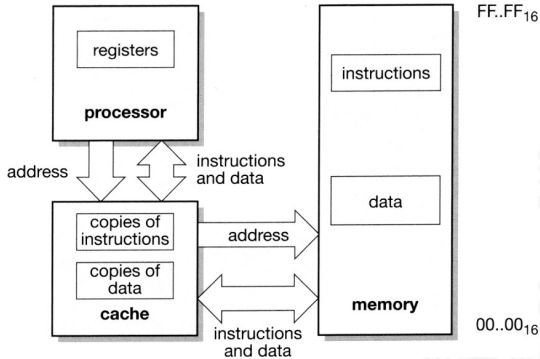
- ⇒ Cache als schneller Zwischenspeicher zum Hauptspeicher
 - ▶ technische Realisierung: SRAM
 - ▶ transparenter Speicher
 - ▶ Cache ist für den Programmierer nicht sichtbar!
 - ▶ wird durch Hardware verwaltet
 - ▶ <http://de.wikipedia.org/wiki/Cache>
<http://en.wikipedia.org/wiki/Cache>
 - ▶ enthält Hauptspeicherblöcke mit erhöhter Zugriffswahrscheinlichkeit
 - ▶ CPU referenziert Adresse
 - ▶ parallele Suche in L1 (level 1), L2... und Hauptspeicher
 - ▶ erfolgreiche Suche liefert Datum, Abbruch laufender Suchen

Cache (cont.)

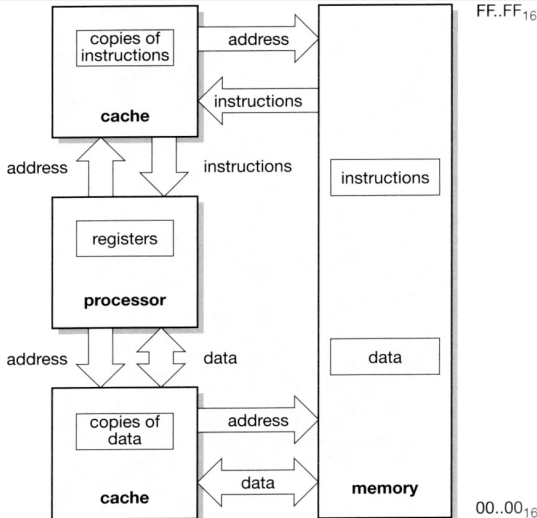




gemeinsamer Cache / „unified Cache“

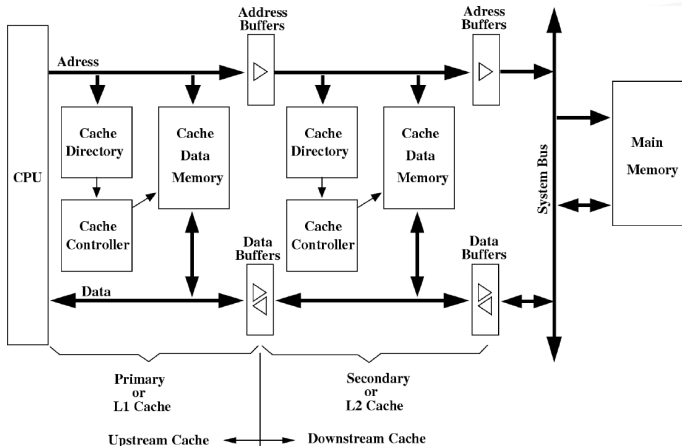


separate Instruction-/Data Caches



Cache – Position

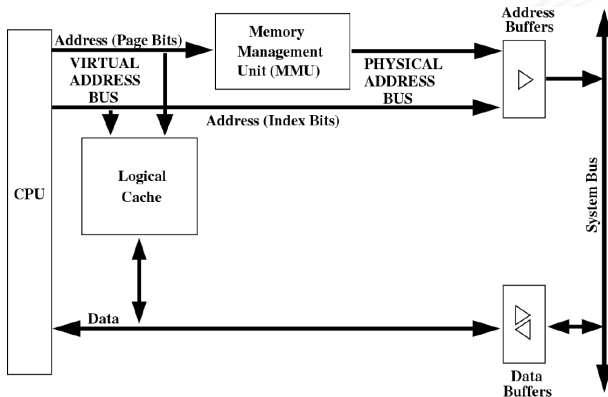
► First- und Second-Level Cache



Cache – Position (cont.)

► Virtueller Cache

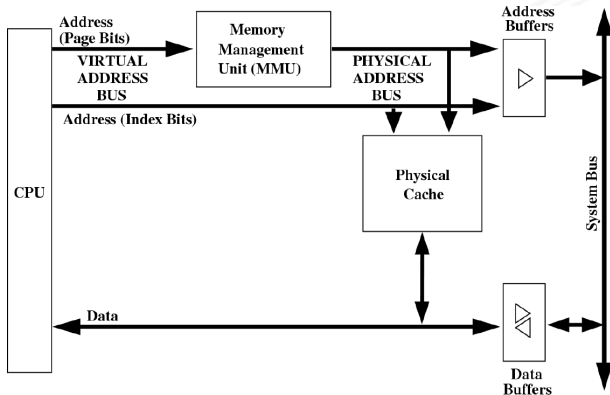
- + Adressumrechnung durch MMU oft nicht nötig
- Cache leeren bei Kontextwechseln



Cache – Position (cont.)

► Physikalischer Cache

- + Cache muss nie geleert werden
- Adressumrechnung durch MMU immer nötig





Cache – Position (cont.)

- ▶ typische Cache Organisation
 - ▶ First-Level Cache: getrennte Instruktions- und Daten-Caches
 - ▶ Second-Level Cache: gemeinsamer Cache je Prozessorkern
 - ▶ Third-Level Cache: gemeinsamer Cache für alle Prozessorkerne
- ▶ bei mehreren Prozessoren / Prozessorkernen \Rightarrow Cache-Kohärenz wichtig
 - ▶ gemeinsam genutzte Daten konsistent halten (s.u.)



Cache – Strategie

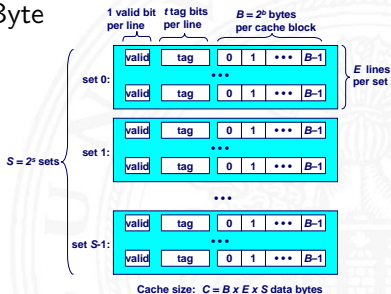
Cachestrategie: *Welche Daten sollen in den Cache?*

Diejenigen, die bald wieder benötigt werden!

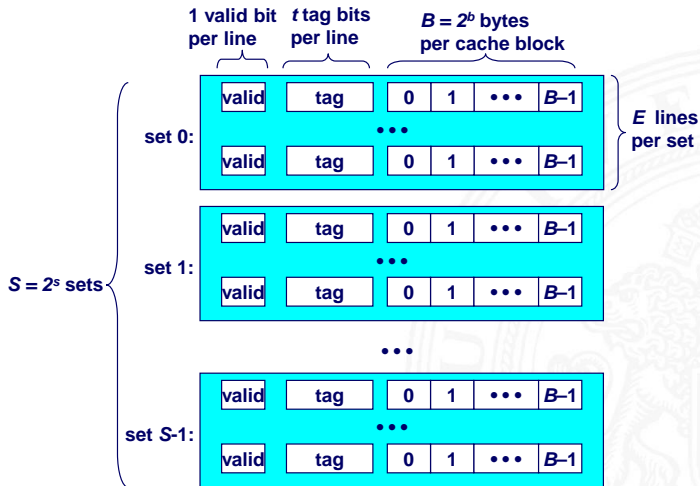
- ▶ *temporale Lokalität:*
die Daten, die zuletzt häufig gebraucht wurden
- ▶ *räumliche Lokalität:*
die Daten, die nahe den zuletzt gebrauchten liegen
- ▶ verschiedene Platzierungs-, Ersetzungs- und
Rückschreibestrategien für den Cache

Cache Organisation

- ▶ Cache ist ein Array von Speicher-Bereichen („sets“)
- ▶ jeder Bereich enthält eine oder mehrere Zeilen
- ▶ jede Zeile enthält einen Datenblock
- ▶ jeder Block enthält mehrere Byte

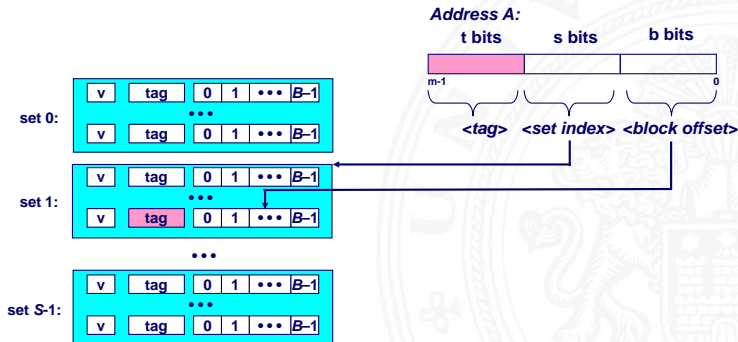


Cache Organisation (cont.)



Adressierung von Caches

- ▶ Adressteil $\langle set\ index \rangle$ von A bestimmt Bereich („set“)
- ▶ Adresse A ist im Cache, wenn
 1. Adressteil $\langle tag \rangle$ von $A =$ „tag“ Bits des Bereichs
 2. Cache-Zeile ist als gültig markiert („valid“)






Cache – Organisation

- ▶ *Welchen Platz im Cache belegt ein Datum des Hauptspeichers?*
- ▶ drei Verfahren
 - direkt abgebildet / direct mapped** jeder Speicheradresse ist genau eine Cache-Speicherzelle zugeordnet
 - n-fach bereichsassoziativ / set associative** jeder Speicheradresse ist eine von E möglichen Cache-Speicherzellen zugeordnet
 - voll-assoziativ** jeder Speicheradresse kann jede beliebige Cache-Speicherzelle zugeordnet werden


Cache: direkt abgebildet / „direct mapped“

- ▶ jeder Adresse ist genau eine Speicherzelle im Cache zugeordnet



Cache: direkt abgebildet / „direct mapped“ (cont.)

- ▶ verfügt über genau 1 Zeile pro Bereich S Bereiche (**S**ets)




- + einfachste Cache-Art
- + große Caches möglich
- Effizienz, z.B. Zugriffe auf $A, A + n \cdot S \dots$

Cache: direkt abgebildet / „direct mapped“ (cont.)


Zugriff auf direkt abgebildete Caches

1. Bereichsauswahl durch Bits (*set index*)




Cache: direkt abgebildet / „direct mapped“ (cont.)

2. $\langle \text{valid} \rangle$: sind die Daten gültig?
3. „Line matching“: stimmt $\langle \text{tag} \rangle$ überein?
4. Wortselektion extrahiert Wort unter Offset $\langle \text{block offset} \rangle$




Cache: direkt abgebildet / „direct mapped“ (cont.)

Prinzip



Cache: bereichsassoziativ / „set associative“

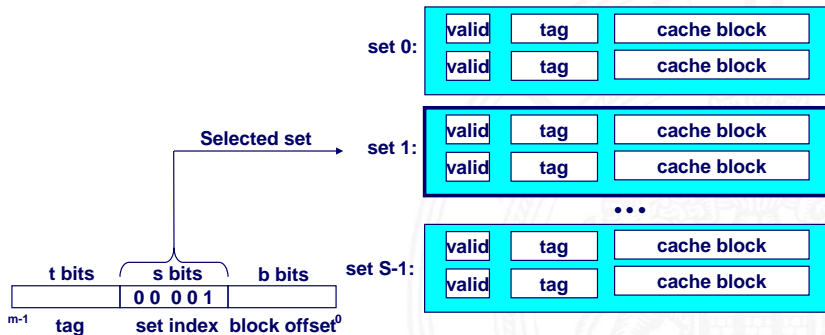
- ▶ jeder Speicheradresse ist ein Bereich S mit mehreren (E) Cachezeilen zugeordnet
- ▶ n -fach assoziative Caches: $E=2, 4, \dots$
 „2-way set associative cache“, „4-way...“



Cache: bereichsassoziativ / „set associative“ (cont.)

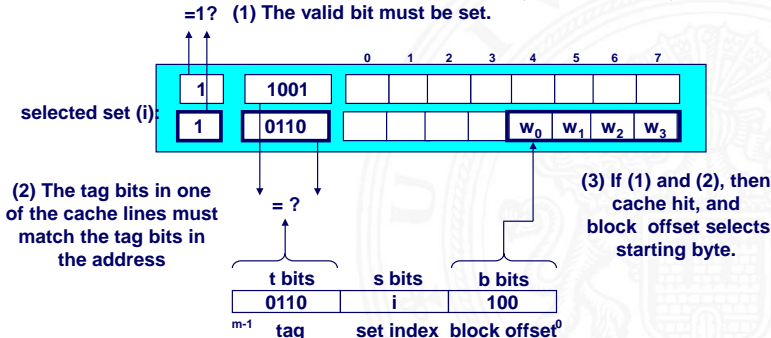
Zugriff auf n-fach assoziative Caches

1. Bereichsauswahl durch Bits (*set index*)



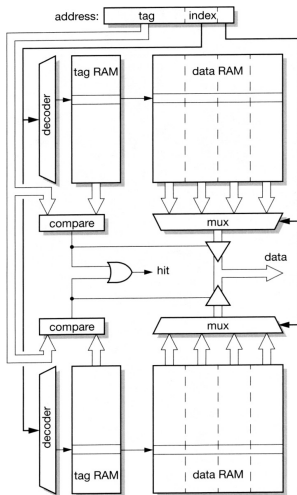
Cache: bereichsassoziativ / „set associative“ (cont.)

- „Line matching“: Cache-Zeile mit passendem $\langle tag \rangle$ finden?
 dazu Vergleich aller „tags“ des Bereichs $\langle set\ index \rangle$
- $\langle valid \rangle$: sind die Daten gültig?
- Wortselektion extrahiert Wort unter Offset $\langle block\ offset \rangle$



Cache: bereichsassoziativ / „set associative“ (cont.)


Prinzip



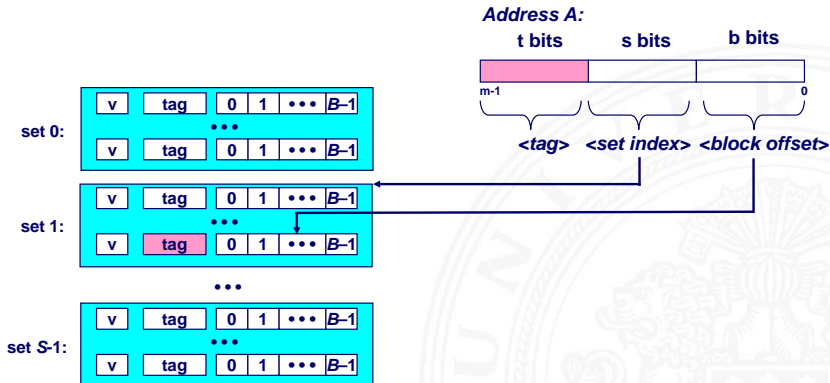


Cache: voll-assoziativ

- ▶ jeder Adresse des Speichers kann jede beliebige Cachezeile zugeordnet werden
- ▶ Spezialfall: nur ein Cachebereich S
- benötigt E -Vergleicher
- nur für sehr kleine Caches realisierbar



Cache – Dimensionierung



► Parameter: S , B , E



Cache – Dimensionierung (cont.)

- ▶ Cache speichert immer größere Blöcke / „Cache-Line“
- ▶ Wortauswahl durch $\langle \text{block offset} \rangle$ in Adresse
- + nutzt räumliche Lokalität aus
- + Breite externe Datenbusse
- + nutzt Burst-Adressierung des Speichers: Adresse nur für erstes Wort vorgeben, dann automatisches Inkrement
- + kürzere interne Cache-Adressen


Cache – Dimensionierung (cont.)

Cache- und Block-Dimensionierung



- ▶ Blockgröße klein, viele Blöcke
 - + kleinere Miss-Penalty
 - + temporale Lokalität
 - räumliche Lokalität
- ▶ Blockgröße groß, wenig Blöcke
 - größere Miss-Penalty
 - temporale Lokalität
 - + räumliche Lokalität

Cache – Dimensionierung (cont.)




- ▶ Block-Size: 32...128 Byte
- L1-Cache: 4...256 KByte
- L2-Cache: 256...4096 KByte



Cache – Dimensionierung (cont.)

- ▶ zusätzliche Software-Optimierungen
 - ▶ Ziel: Cache Misses reduzieren
 - ▶ Schleifen umsortieren, verschmelzen...
 - ▶ Datenstrukturen zusammenfassen...





Cache Ersetzungsstrategie

Wenn der Cache gefüllt ist, welches Datum wird entfernt?

- ▶ zufällige Auswahl
- ▶ **LRU** (**L**east **R**ecently **U**sed):
der „älteste“ nicht benutzte Cache Eintrag
 - ▶ echtes LRU als Warteschlange realisiert
 - ▶ Pseudo LRU mit baumartiger Verwaltungsstruktur:
Zugriff wird paarweise mit einem Bit markiert,
die Paare wieder zusammengefasst usw.
- ▶ **LFU** (**L**east **F**requently **U**sed):
der am seltensten benutzte Cache Eintrag
 - ▶ durch Zugriffszähler implementiert



Cache Schreibstrategie

Wann werden modifizierte Daten des Cache zurückgeschrieben?

- ▶ **Write-Through:** beim Schreiben werden Daten sofort im Cache und im Hauptspeicher modifiziert
 - + andere Bus-Master sehen immer den „richtigen“ Speicherinhalt:
Cache-Kohärenz
 - Werte werden unnötig oft in Speicher zurückgeschrieben
- ▶ **Write-Back:** erst in den Speicher schreiben, wenn Datum des Cache ersetzt werden würde
 - + häufig genutzte Werte (z.B. lokale Variablen) werden nur im Cache modifiziert
 - Cache-Kohärenz ist nicht gegeben
 - ⇒ spezielle Befehle für „Cache-Flush“
 - ⇒ „non-cacheable“ Speicherbereiche



Cache Kohärenz

- ▶ Daten zwischen Cache und Speicher konsistent halten
- ▶ notwendig wenn auch andere Einheiten (Bus-Master) auf Speicher zugreifen können (oder Mehrprozessorsysteme!)
- ▶ Harvard-Architektur hat getrennte Daten- und Instruktions-Speicher: einfacherer Instruktions-Cache
 - ▶ Instruktionen sind read-only
 - ▶ kein Cache-Kohärenz Problem
- ▶ „Snooping“
 - ▶ Cache „lauscht“ am Speicherbus
 - ▶ externer Schreibzugriff \Rightarrow Cache aktualisieren / ungültig machen
 - ▶ externer Lesezugriff \Rightarrow Cache liefert Daten

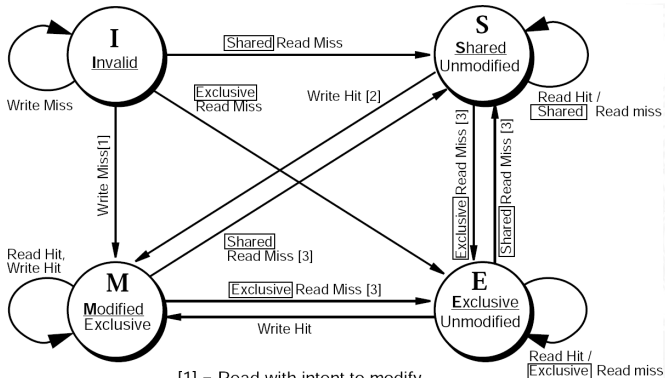


Cache Kohärenz (cont.)

- ▶ MESI Protokoll
 - ▶ besitzt zwei Statusbits für die Protokollzustände
 - ▶ **M**odified: Inhalte der Cache-Line wurden modifiziert
 - ▶ **E**xclusive unmodified: Cache-Line „gehört“ dieser CPU, nicht modifiz.
 - ▶ **S**hared unmodified: Inhalte sind in mehreren Caches vorhanden
 - ▶ **I**nvalid: ungültiger Inhalt, Initialzustand

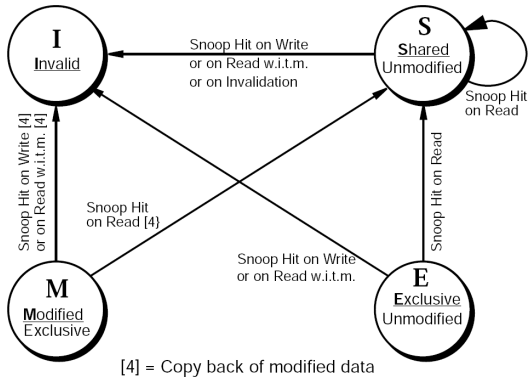
Cache Kohärenz (cont.)

► Zustandsübergänge für „Bus Master“ CPU



Cache Kohärenz (cont.)

- Zustandsübergänge für "Snooping" CPU



Optimierung der Cachezugriffe

- ▶ Mittlere Speicherzugriffszeit = $T_{Hit} + R_{Miss} \cdot T_{Miss}$
- ⇒ Verbesserung der Cache Performanz durch kleinere T_{Miss} am einfachsten zu realisieren
 - ▶ mehrere Cache Ebenen
 - ▶ Critical Word First: bei großen Cache Blöcken (mehrere Worte) gefordertes Wort zuerst holen und gleich weiterleiten
 - ▶ Read-Miss hat Priorität gegenüber Write-Miss
⇒ Zwischenspeicher für Schreiboperationen (Write Buffer)
 - ▶ Merging Write Buffer: aufeinanderfolgende Schreiboperationen zwischenspeichern und zusammenfassen
 - ▶ Victim Cache: kleiner voll-assoziativer Cache zwischen direct-mapped Cache und nächster Ebene „sammelt“ verdrängte Cache Einträge



Optimierung der Cachezugriffe (cont.)

- ⇒ Verbesserung der Cache Performanz durch kleinere R_{Miss}
 - ▶ größere Caches (– mehr Hardware)
 - ▶ höhere Assoziativität (– langsamer)
- ⇒ Optimierungstechniken
 - ▶ Software Optimierungen
 - ▶ Prefetch: Hardware (Stream Buffer)
Software (Prefetch Operationen)
 - ▶ Cache Zugriffe in Pipeline verarbeiten
 - ▶ Trace Cache: im Instruktions-Cache werden keine Speicherinhalte, sondern ausgeführte Sequenzen (*trace*) einschließlich ausgeführter Sprünge gespeichert

Beispiel: NetBurst Architektur (Pentium 4)

Chiplayout

ARM7 / ARM10


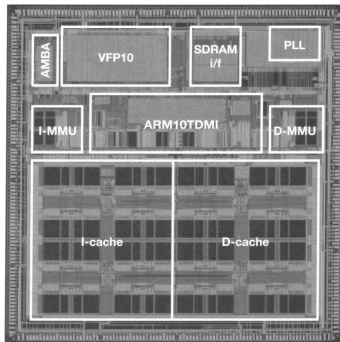


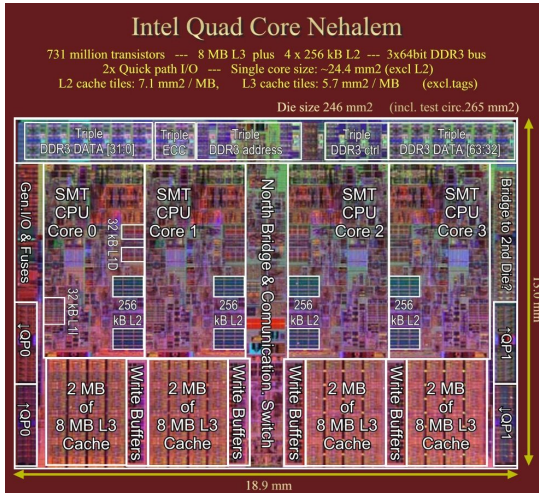
Photo courtesy of Intel Corp.




© ARM Limited

- ▶ IBOX: Steuerwerk (instruction fetch und decode)
- EBOX: Operationswerk, ALU, Register (execute)
- IMMU/DMMU: Virtueller Speicher (instruction/data TLBs)
- ICACHE: Instruction Cache
- DCACHE: Data Cache

Chiplayout (cont.)



Chiplayout (cont.)





Cache vs. Programmcode

Programmierer kann für maximale Cacheleistung optimieren

- ▷ Datenstrukturen werden fortlaufend alloziert
 1. durch entsprechende Organisation der Datenstrukturen
 2. durch Steuerung des Zugriffs auf die Daten
 - ▶ Geschachtelte Schleifenstruktur
 - ▶ Blockbildung ist eine übliche Technik

Systeme bevorzugen einen *Cache-freundlichen* Code

- ▶ Erreichen der optimalen Leistung ist plattformspezifisch
 - ▶ Cachegrößen, Zeilengrößen, Assoziativität etc.
- ▶ generelle Empfehlungen
 - ▶ „working set“ klein ⇒ zeitliche Lokalität
 - ▶ kleine Adressfortschaltungen („strides“) ⇒ räumliche Lokalität

Virtueller Speicher – Motivation

Speicher-Paradigmen

- ▶ Programmierer
 - ▶ ein großer Adressraum
 - ▶ linear adressierbar
- ▶ Betriebssystem
 - ▶ eine Menge laufender Tasks / Prozesse
 - ▶ read-only Instruktionen
 - ▶ read-write Daten

Konsequenz


virtueller Speicher umfasst drei Aspekte der (teilweise) widersprüchlichen Anforderungen an „Speicher“



Virtueller Speicher – Motivation (cont.)


1. Benutzung der Festplatte als *zusätzlichen* Hauptspeicher
 - ▶ Prozessadressraum kann physikalische Speichergröße übersteigen
 - ▶ Summe der Adressräume mehrerer Prozesse kann physikalischen Speicher übersteigen
2. Vereinfachung der Speicherverwaltung
 - ▶ viele Prozesse liegen im Hauptspeicher
 - ▶ jeder Prozess mit seinem eigenen Adressraum (0...n)
 - ▶ nur *aktiver* Code und Daten sind tatsächlich im Speicher
 - ▶ bedarfsabhängige, dynamische Speicherzuteilung
3. Bereitstellung von Schutzmechanismen
 - ▶ ein Prozess kann einem anderen nicht beeinflussen
 - ▶ sie operieren in verschiedenen Adressräumen
 - ▶ Benutzerprozess hat keinen Zugriff auf privilegierte Informationen
 - ▶ jeder virtuelle Adressraum hat eigene Zugriffsrechte

Festplatte „erweitert“ Hauptspeicher



- ▶ Vollständiger Adressraum zu groß \Rightarrow DRAM ist *Cache*
 - ▶ 32-bit Adressen: $\approx 4 \times 10^9$ Byte 4 Milliarden
 - ▶ 64-bit Adressen: $\approx 16 \times 10^{16}$ Byte 16 Quintillionen
 - ▶ Speichern auf Festplatte ist $\approx 125\times$ billiger als im DRAM
 - ▶ 1 TiB DRAM: ≈ 5000 €
 - ▶ 1 TiB Festplatte: ≈ 40 €
- \Rightarrow kostengünstiger Zugriff auf große Datenmengen

Ebenen in der Speicherhierarchie




	Register	Cache	Memory	Disk Memory
size:	64 B	32 KB-12MB	8 GB	2 TB
speed:	300 ps	1 ns	8 ns	4 ms
\$/Mbyte:		5€/MB	5€/GB	4 Ct./GB
line size:	16 B	64 B	4 KB	

larger, slower, cheaper



Ebenen in der Speicherhierarchie (cont.)

- ▶ Hauptspeicher als Cache für den Plattenspeicher




- ▶ Parameter der Speicherhierarchie

	1st-Level Cache	virtueller Speicher
Blockgröße	16-128 Byte	4-64 kByte
Hit-Dauer	1-2 Zyklen	40-100 Zyklen
Miss Penalty	8-100 Zyklen	70.000-6.000.000 Zyklen
Miss Rate	0,5-10 %	0,00001-0,001 %
Speichergröße	8-64 kByte	16-8192 MByte




Ebenen in der Speicherhierarchie (cont.)

- ▶ DRAM vs. Festplatte ist extremer als SRAM vs. DRAM
 - ▶ Zugriffswartezeiten
 - ▶ DRAM $\approx 10\times$ langsamer als SRAM
 - ▶ Festplatte $\approx 500\,000\times$ langsamer als DRAM
- ⇒ Nutzung der räumlichen Lokalität wichtig
 - ▶ erstes Byte $\approx 500\,000\times$ langsamer als nachfolgende Bytes



Prinzip des virtuellen Speichers

- ▶ jeder Prozess besitzt seinen eigenen virtuellen Adressraum
- ▶ Kombination aus Betriebssystem und Hardwareeinheiten
- ▶ MMU – **M**emory **M**anagement **U**nit



- ▶ Umsetzung von virtuellen zu physischen Adressen, Programm-Relokation




Prinzip des virtuellen Speichers (cont.)

- ▶ Umsetzungstabellen werden vom Betriebssystem verwaltet
- ▶ wegen des Speicherbedarfs der Tabellen beziehen sich diese auf größere Speicherblöcke (*Segmente* oder *Seiten*)
- ▶ Umgesetzt wird nur die Anfangsadresse, der Offset innerhalb des Blocks bleibt unverändert
- ▶ Blöcke dieses virtuellen Adressraums können durch Betriebssystem auf Festplatte ausgelagert werden
 - ▶ Windows: Auslagerungsdatei
 - ▶ Unix/Linux: swap Partition und -Datei(en)
- ▶ Konzepte zur Implementation virtuellen Speichers
 - ▶ *Segmentierung*
 - ▶ Speicherzuordnung durch *Seiten* („*Paging*“)
 - ▶ gemischte Ansätze (Standard bei: Desktops, Workstations. . .)

Virtueller Speicher: Segmentierung

- ▶ Unterteilung des Adressraums in kontinuierliche Bereiche *variabler Größe*




Virtueller Speicher: Segmentierung (cont.)

- ▶ Idee: Trennung von Instruktionen, Daten und Stack
- ⇒ Abbildung von *Programmen* in den *Hauptspeicher*
- + Inhalt der Segmente: logisch zusammengehörige Daten
- + getrennte Zugriffsrechte, Speicherschutz
- + exakte Prüfung der Segmentgrenzen
- Segmente könne sehr groß werden
- Ein- und Auslagern von Segmenten kann sehr lange dauern
- „Verschnitt“, **Memory Fragmentation**

Virtueller Speicher: Paging / Seitenadressierung

- ▶ Unterteilung des Adressraums in Blöcke *fester* Größe = Seiten
 Abbildung auf Hauptspeicherblöcke = Kacheln




Virtueller Speicher: Paging / Seitenadressierung (cont.)

- ⇒ Abbildung von *Adressen* in den *virtuellen Speicher*
- + Programme können größer als der Hauptspeicher sein
- + Programme können an beliebige physikalischen Adressen geladen werden, unabhängig von der Aufteilung des physikalischen Speichers
- + feste Seitengröße: einfache Verwaltung in Hardware
- + Zugriffsrechte für jede Seite (read/write, User/Supervisor)
- + gemeinsam genutzte Programmteile/-Bibliotheken können sehr einfach in das Konzept integriert werden
 - ▶ Windows: `.dll`-Dateien
 - ▶ Unix/Linux: `.so`-Dateien

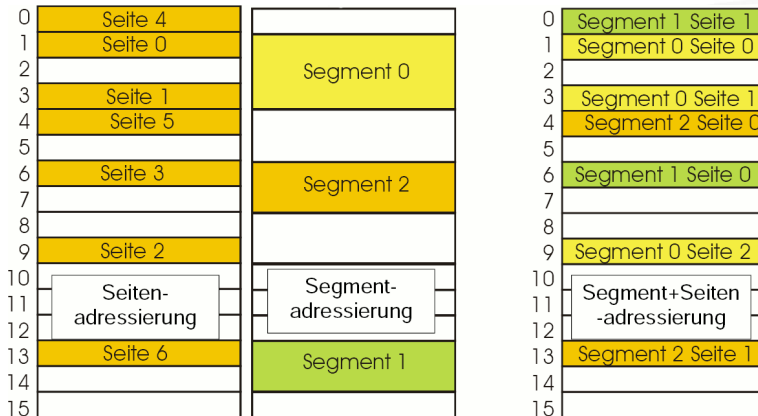
Virtueller Speicher: Paging / Seitenadressierung (cont.)

- ▶ große Miss-Penalty (Nachladen von der Platte)
 - ⇒ Seiten sollten relativ groß sein: 4 oder 8 kByte
- Speicherplatzbedarf der Seitentabelle viel virtueller Speicher, 4 kByte Seitengröße
 - = sehr große Pagetable
 - ⇒ Hash-Verfahren (*inverted page tables*)
 - ⇒ mehrstufige Verfahren





Virtueller Speicher: Segmentierung + Paging

aktuell = Mischung: Segmentierung und Paging (seit 1386)



Seitenfehler

- ▶ Seiten-Tabelleneintrag: Startadresse der virt. Seite auf Platte
- ▶ Daten von Festplatte in Speicher laden:
 - ▶ Aufruf des „Exception handler“ des Betriebssystems
 - ▶ laufender Prozess wird unterbrochen, andere können weiterlaufen
 - ▶ Betriebssystem kontrolliert die Platzierung der neuen Seite im Hauptspeicher (Ersetzungsstrategien) etc.



Seitenfehler (cont.)

Behandlung des Seitenfehlers

1. Prozessor signalisiert DMA-Controller

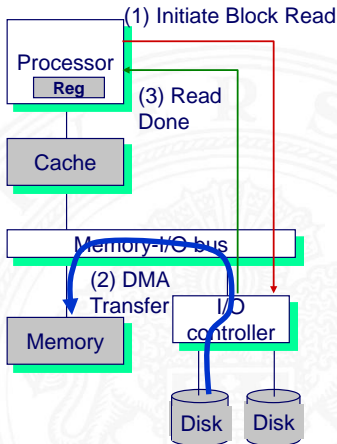
- ▶ lies Block der Länge P ab Festplattenadresse X
- ▶ speichere Daten ab Adresse Y in Hauptspeicher

2. Lesezugriff erfolgt als

- ▶ Direct Memory Access (DMA)
- ▶ Kontrolle durch I/O Controller

3. I/O Controller meldet Abschluss

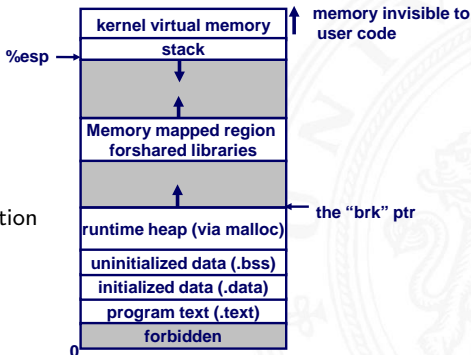
- ▶ Gibt Interrupt an den Prozessor
- ▶ Betriebssystem lässt unterbrochenen Prozess weiterlaufen



Separate virtuelle Adressräume

Mehrere Prozesse können im physikalischen Speicher liegen

- ▶ Wie werden Adresskonflikte gelöst?
- ▶ Was passiert, wenn Prozesse auf dieselbe Adresse zugreifen?

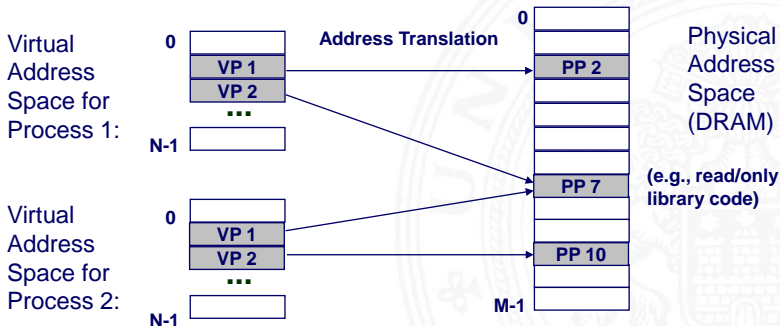


Linux x86
 Speicherorganisation

Separate virtuelle Adressräume (cont.)

Auflösung der Adresskonflikte


- ▶ jeder Prozess hat seinen eigenen virtuellen Adressraum
- ▶ Betriebssystem kontrolliert wie virtuelle Seiten auf den physikalischen Speicher abgebildet werden



Virtueller Speicher – Adressumsetzung

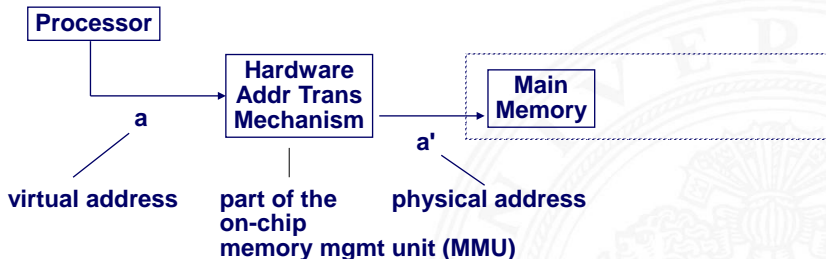
▶ Parameter

- ▶ $P = 2^p$ = Seitengröße (Bytes)
- ▶ $N = 2^n$ = Limit der virtuellen Adresse
- ▶ $M = 2^m$ = Limit der physikalischen Adresse



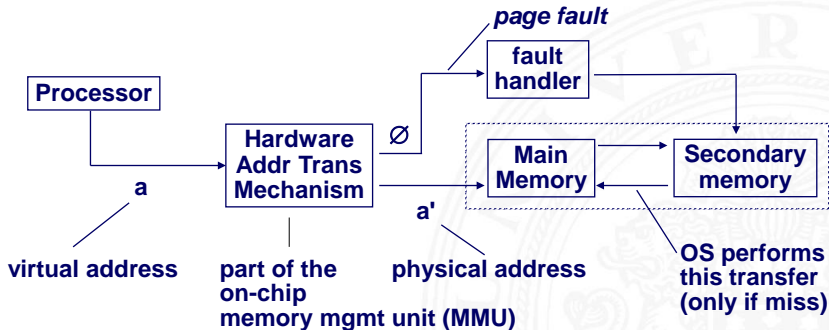
Virtueller Speicher – Adressumsetzung (cont.)

- ▶ virtuelle Adresse: Hit

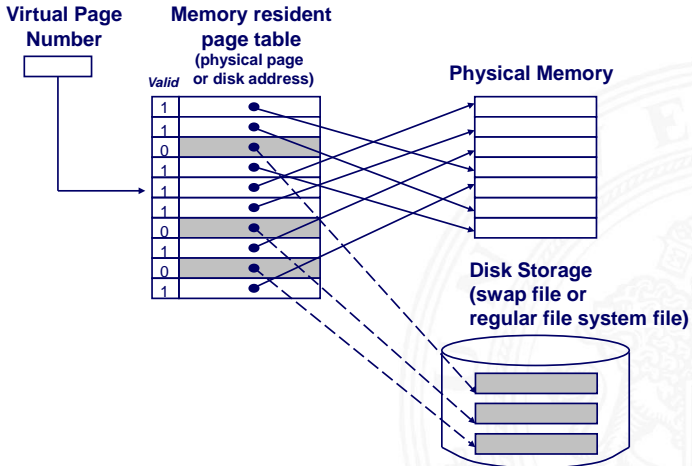


Virtueller Speicher – Adressumsetzung (cont.)

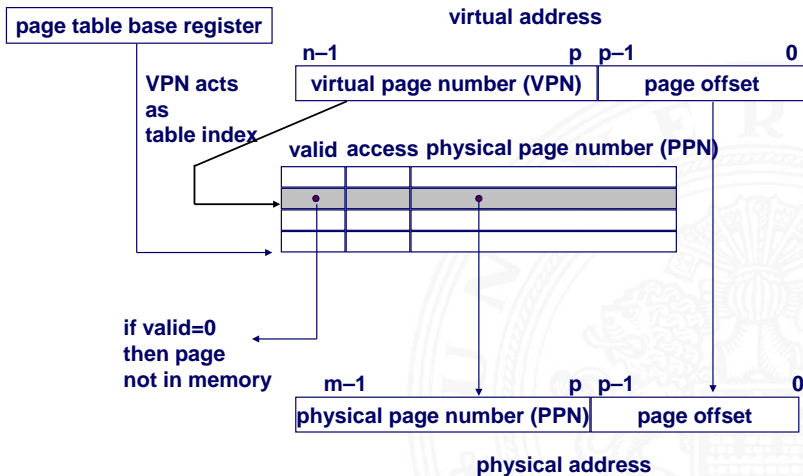
- ▶ virtuelle Adresse: Miss



Seiten-Tabelle




Seiten-Tabelle (cont.)



Seiten-Tabelle (cont.)

- ▶ separate Seiten-Tabelle für jeden Prozess
- ▶ VPN („Virtual Page Number“) bildet den Index der Seiten-Tabelle \Rightarrow zeigt auf Seiten-Tabelleneintrag
- ▶ Seiten-Tabelleneintrag liefert Informationen über die Seite
- ▶ Daten im Hauptspeicher: valid-Bit
 - ▶ valid-Bit = 1: die Seite ist im Speicher \Rightarrow benutze physikalische Seitennummer („Physical Page Number“) zur Adressberechnung
 - ▶ valid-Bit = 0: die Seite ist auf der Festplatte \Rightarrow Seitenfehler



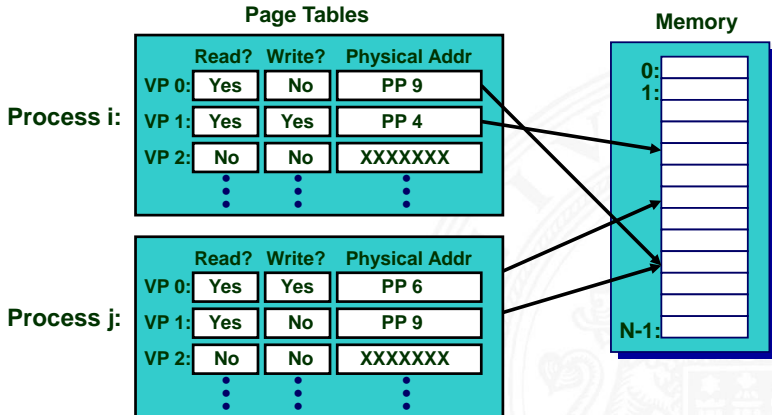


Zugriffsrechte


Schutzüberprüfung

- ▶ Zugriffsrechtefeld gibt Zugriffserlaubnis an
 - ▶ z.B. read-only, read-write, execute-only
 - ▶ typischerweise werden zahlreiche Schutzmodi unterstützt
- ▶ Schutzrechteverletzung wenn Prozess/Benutzer nicht die nötigen Rechte hat
- ▶ bei Verstoß erzwingt die Hardware den Schutz durch das Betriebssystem („Trap“ / „Exception“)

Zugriffsrechte (cont.)



Integration von virtuellem Speicher und Cache



Die meisten Caches werden *physikalisch adressiert*

- ▶ Zugriff über physikalische Adressen
- ▶ mehrere Prozesse können, gleichzeitig Blöcke im Cache haben
- ▶ —"– sich Seiten teilen
- ▶ Cache muss sich nicht mit Schutzproblemen befassen
 - ▶ Zugriffsrechte werden als Teil der Adressumsetzung überprüft

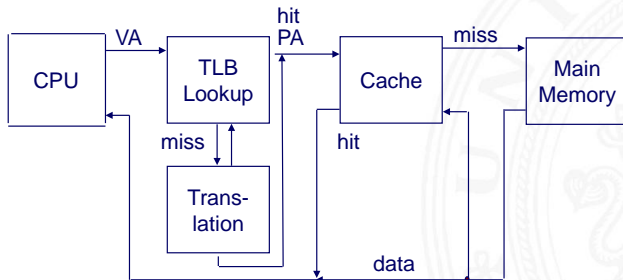
Die Adressumsetzung wird vor dem Cache „Lookup“ durchgeführt

- ▶ kann selbst Speicherzugriff (auf den PTE) beinhalten
- ▶ Seiten-Tabelleneinträge können auch gecacht werden

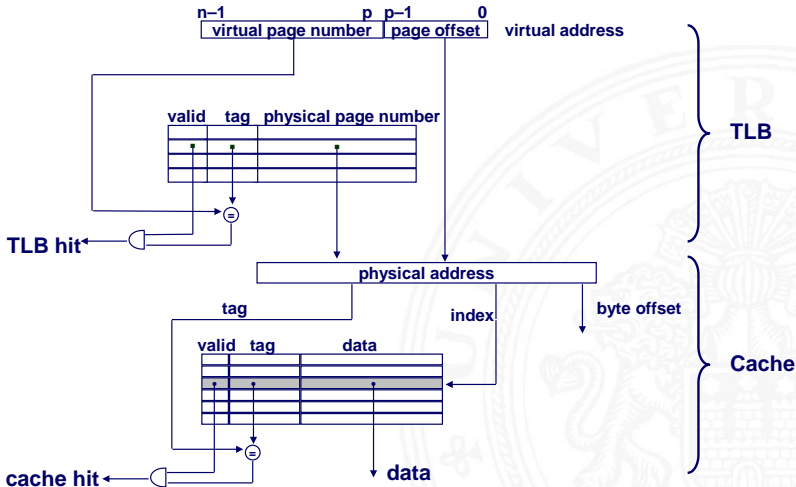
TLB / „Translation Lookaside Buffer“

Beschleunigung der Adressumsetzung für virtuellen Speicher

- ▶ kleiner Hardware Cache in MMU (Memory Management Unit)
- ▶ bildet virtuelle Seitenzahlen auf physikalische ab
- ▶ enthält komplette Seiten-Tabelleneinträge für wenige Seiten




TLB / „Translation Lookaside Buffer“ (cont.)

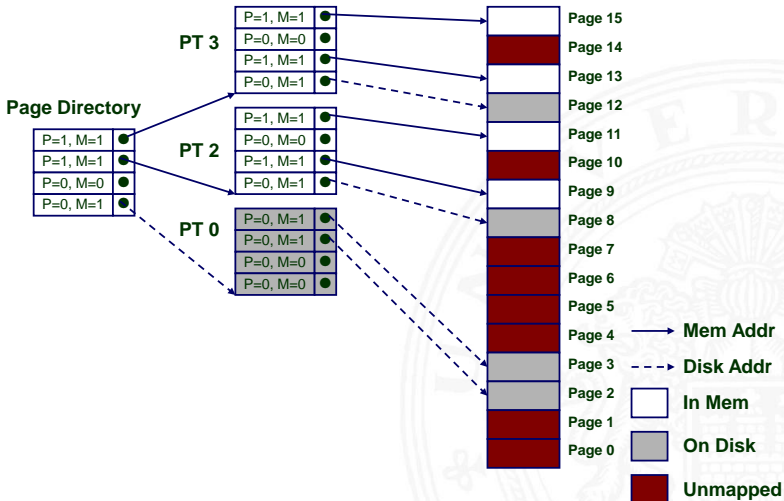


mehrstufige Seiten-Tabellen

- ▶ Gegeben
 - ▶ 4 KiB (2^{12}) Seitengröße
 - ▶ 32-Bit Adressraum
 - ▶ 4-Byte PTE („Page Table Entry“) Seitentabelleneintrag
- ▶ Problem
 - ▶ erfordert 4 MiB Seiten-Tabelle
 - ▶ 2^{20} Bytes
- ⇒ übliche Lösung
 - ▶ mehrstufige Seiten-Tabellen („multi-level“)
 - ▶ z.B. zweistufige Tabelle (Pentium P6)
 - ▶ Ebene-1: 1024 Einträge → Ebene-2 Tabelle
 - ▶ Ebene-2: 1024 Einträge → Seiten

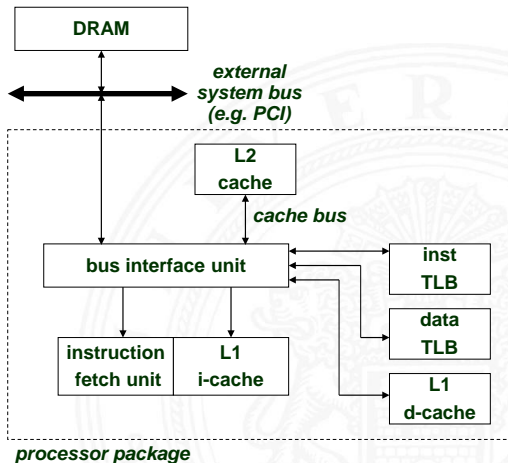


mehrstufige Seiten-Tabellen (cont.)

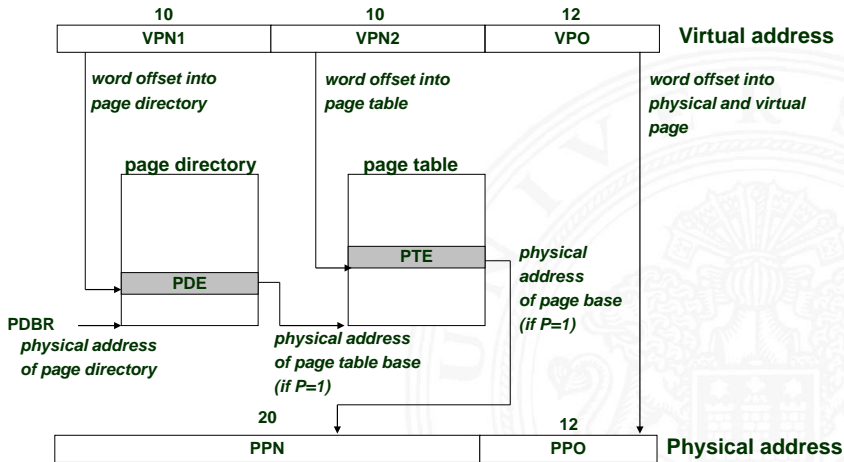


Beispiel: Pentium und Linux

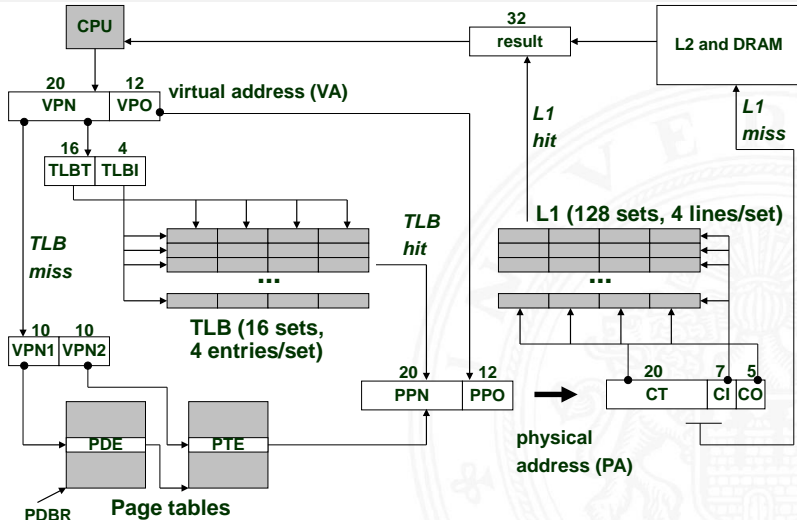
- ▶ 32-bit Adressraum
- ▶ 4 KB Seitengröße
- ▶ L1, L2 TLBs
 - 4fach assoziativ
- ▶ Instruktionen TLB
 - 32 Einträge
 - 8 Sets
- ▶ Daten TLB
 - 64 Einträge
 - 16 Sets
- ▶ L1 I-Cache, D-Cache
 - 16 KB
 - 32 B Cacheline
 - 128 Sets
- ▶ L2 Cache
 - Instr.+Daten zusammen
 - 128 KB ... 2 MB



Beispiel: Pentium und Linux (cont.)



Beispiel: Pentium und Linux (cont.)





Zusammenfassung

Cache Speicher

- ▶ Dient nur zur Beschleunigung
- ▶ Verhalten unsichtbar für Anwendungsprogrammierer und OS
- ▶ Komplette in Hardware implementiert



Zusammenfassung (cont.)

Virtueller Speicher

- ▶ Ermöglicht viele Funktionen des Betriebssystems
 - ▶ Prozesse erzeugen („exec“ / „fork“)
 - ▶ Taskwechsel
 - ▶ Schutzmechanismen
- ▶ Implementierung mit Hardware und Software
 - ▶ Software verwaltet die Tabellen und Zuteilungen
 - ▶ Hardwarezugriff auf die Tabellen
 - ▶ Hardware-Caching der Einträge (TLB)

Zusammenfassung (cont.)

- ▶ Sicht des Programmierers
 - ▶ großer „flacher“ Adressraum
 - ▶ kann große Blöcke benachbarter Adressen zuteilen
 - ▶ Prozessor „besitzt“ die gesamte Maschine
 - ▶ hat privaten Adressraum
 - ▶ bleibt unberührt vom Verhalten anderer Prozesse
- ▶ Sicht des Systems
 - ▶ Virtueller Adressraum von Prozessen durch Abbildung auf Seiten
 - ▶ muss nicht fortlaufend sein
 - ▶ wird dynamisch zugeteilt
 - ▶ erzwingt Schutz bei Adressumsetzung
 - ▶ Betriebssystem verwaltet viele Prozesse gleichzeitig
 - ▶ ständiger Wechsel zwischen Prozessen
 - ▶ vor allem wenn auf Ressourcen gewartet werden muss