

IT-Grundlagen WS 2013 / 14

Studiengang Scientific Programming

RWTHAACHEN
UNIVERSITY

MATSE
Ausbildung

 **JÜLICH**
FORSCHUNGSZENTRUM

FH AACHEN
UNIVERSITY OF APPLIED SCIENCES

0 – Organisatorisches

Termine, Motivation, Inhalte der Vorlesung, Literatur, ...

Termine

Wann muss ich wo sein?

Regelmäßige Termine

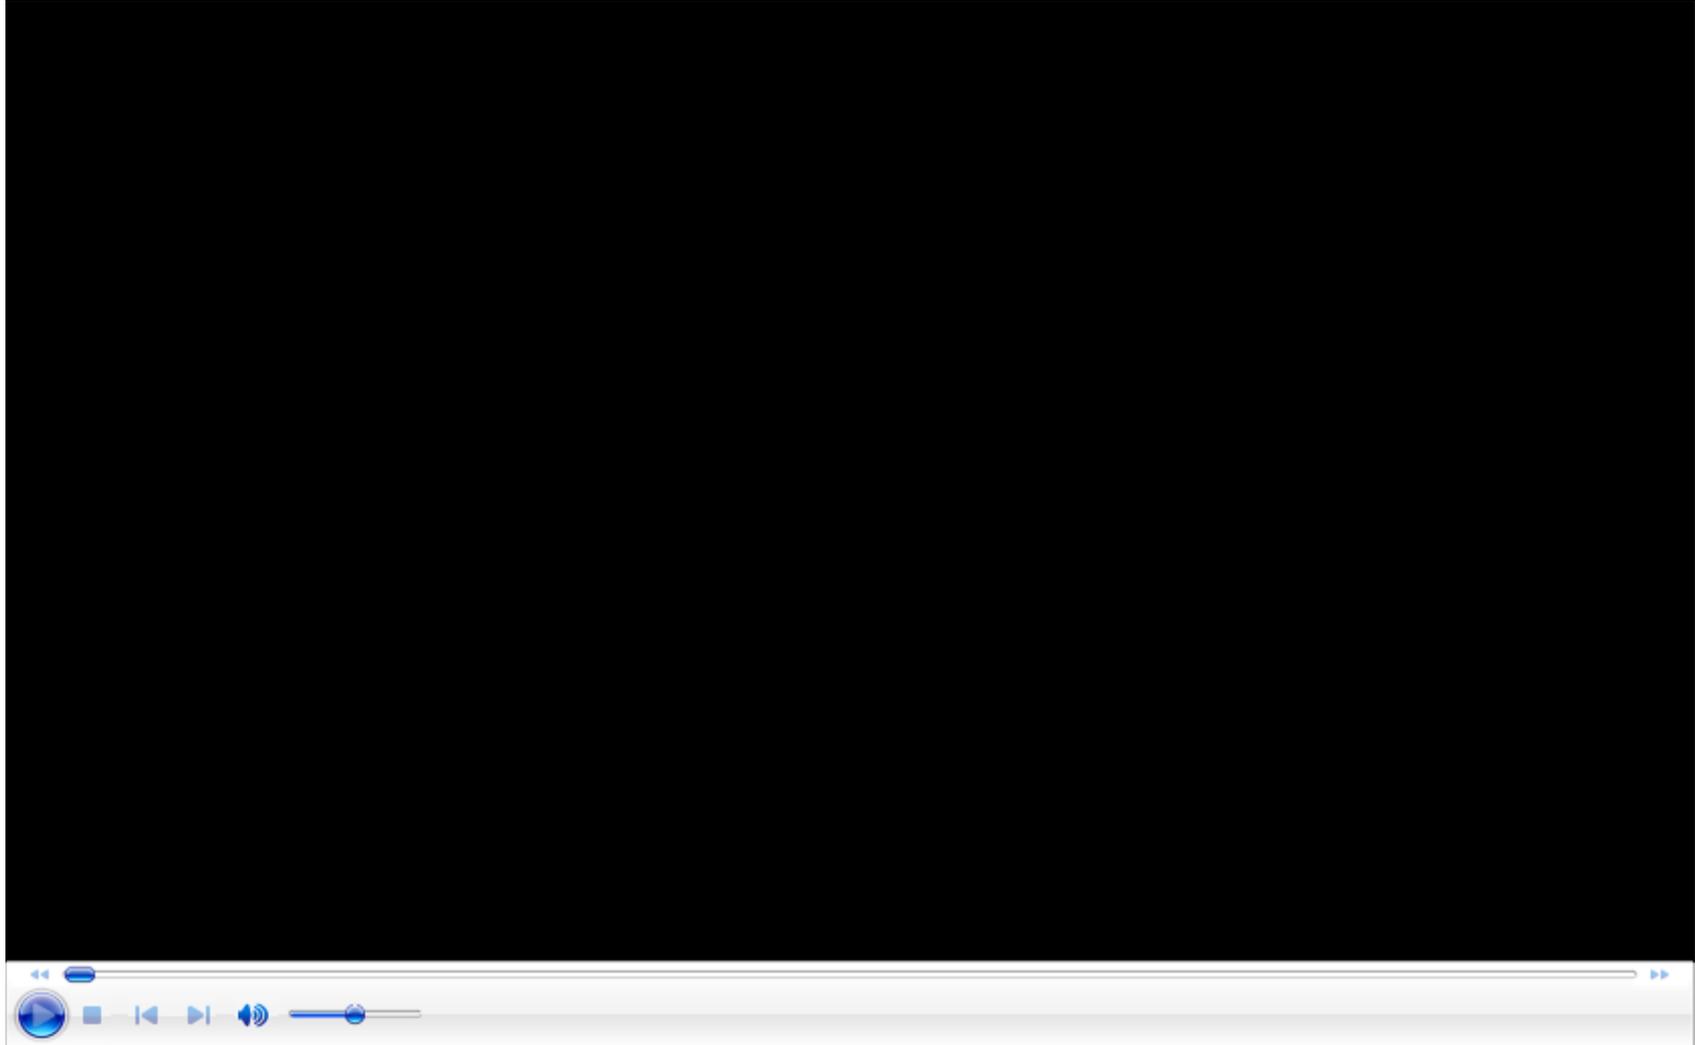
- Vorlesung: Donnerstags 08:15 – 09:15 im Hörsaal
- Übung: Ist in die Java-Übung integriert

Klausur (vorläufig)

- Freitag, 07. Februar 2014 um 09:00

Motivation

Warum sind wir hier?



Inhalte der Vorlesung

Wo IT-Grundlagen draufsteht...

1. Programmentwicklung

2. Zahlendarstellung

1. Ganze Zahlen
2. Gleitkommazahlen

3. Codierung

4. Syntax, Semantik, Grammatik

1. Formale Sprachen
2. Compiler, Linker, ...

5. Rechnerorganisation

1. Von Neumann Architektur
2. Maschinensprache

6. Ein- und Ausgabegeräte

6. Speicher
7. Caches
8. Tastatur, Bildschirm, ...

7. Betriebssysteme

6. Speicherverwaltung
7. Dateisysteme

8. Kryptologie

9. Datensicherheit

6. Definition und Risiken
7. Gesetzgebung

Literatur

- Computerarchitektur: Strukturen – Konzepte – Grundlagen
Andrew Tanenbaum / James Goodman, Prentice-Hall ISBN 3-8272-9573-4
- Wikipedia und dort genannte Quellen oder z.B. Homepages der Urheber (insbesondere, wenn nichts explizit angegeben ist)
- Sollten wir an irgendeiner Stelle die Rechte Dritter verletzt haben, bitten wir um konkrete Hinweise. Diese Zusammenstellung wird nicht kommerziell verwertet.
- Generell gilt: Viele Themen werden nur angeschnitten, die Vorlesung verstehen wir als Startpunkt für die eigene Beschäftigung mit den entsprechenden Themen.

Grundlage Folien

- U. Detert, B. Küppers, B. Kraft, B. Magrean, H. Pflug, M. Sczimarowsky, C. Terboven, A. Voß

Über mich

Wer bin ich – und wenn ja wie viele?

- Lebenslauf
 - > MATSE-Ausbildung / Bachelor-Studium: 2007 – 2010
 - > Master-Studium: 2010 – 2012
 - > Webentwickler: 2012 – 2013
 - > Dozent in der MATSE-Abteilung: seit 2013
- Interessen
 - > Kryptographie, Künstliche Intelligenz, Zahlentheorie
- Sonstige Veranstaltungen
 - > IT-Systeme, Parallelprogrammierung, Robotik (Uni Maastricht)
- Kontakt
 - > Telefon: 0241 / 80 – 24770
 - > Email: kueppers@rz.rwth-aachen.de

1 – Programmentwicklung

Entwurfsstrategien, Notationen

Lessons Learned

Muss ich mir das alles merken?

In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können

- Programmkonzeption
 - > Wasserfallmodell
 - > Anforderungsanalyse
 - > Entwurf

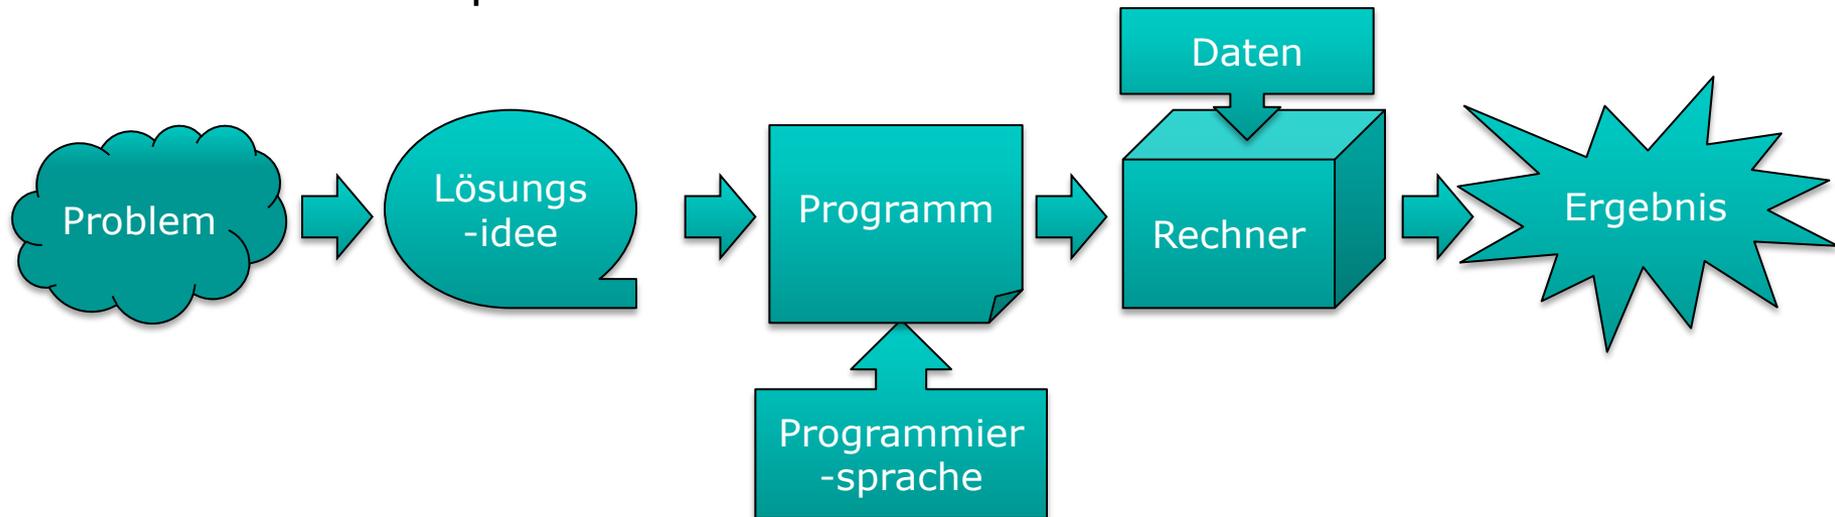
- Notationen
 - > Flussdiagramme
 - > Struktogramme

Vom Problem zur Lösung

Man nehme einen Hammer...

Definition: Programmieren

- Programmieren ist die exakte Beschreibung einer Lösungsidee in einer formalen Sprache



Drei Schritte

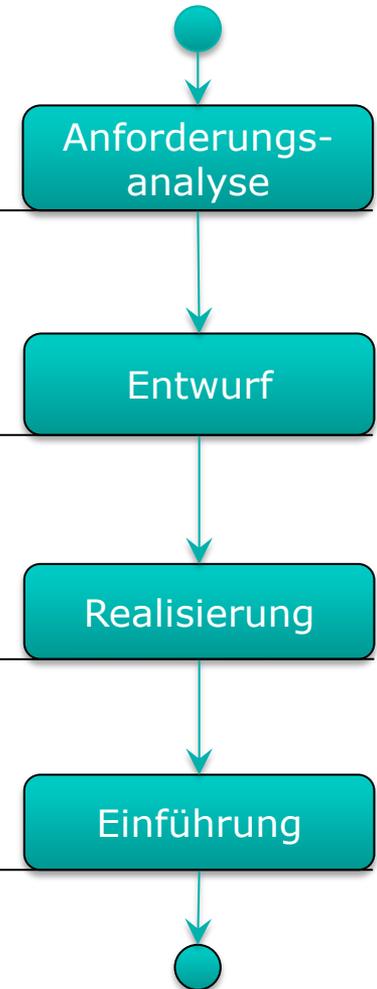
1. Analyse des Problems
2. Ausarbeitung eines Lösungs-Konzeptes
3. Formulierung der Lösung in einem Programm

Einfaches Wasserfallmodell

Wasser marsch!

Vom Problem zur Lösung

- Anforderungen abklären
- Schrittweises Ausarbeiten
- Algorithmen und Datenstrukturen entwickeln
- Installation und Inbetriebnahme



Anforderungsanalyse

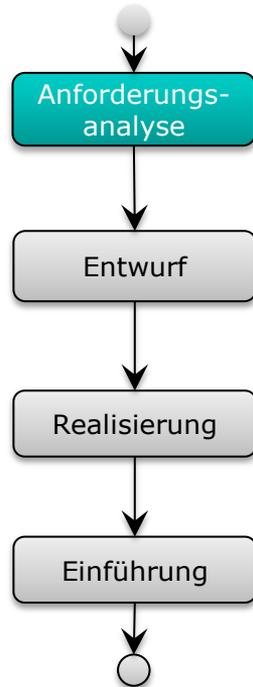
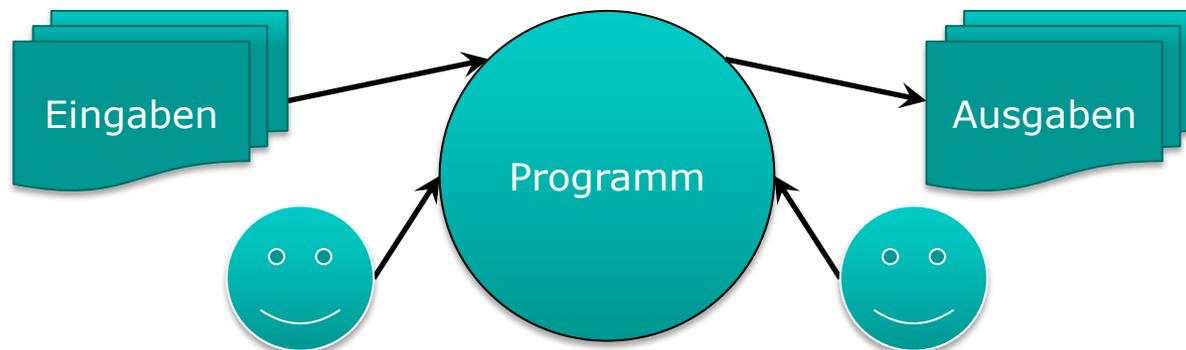
Was will mein Kunde von mir?!

Problem genau analysieren und umfassend beschreiben

- Was soll genau entwickelt werden?

Vorgehensweise zur Analyse

- Datenorientiert
 - > Welche Daten werden eingegeben?
 - > Welche Daten werden ausgegeben?
- Aktivitätsorientiert
 - > Welche Benutzer interagieren wie mit dem System?



Entwurf

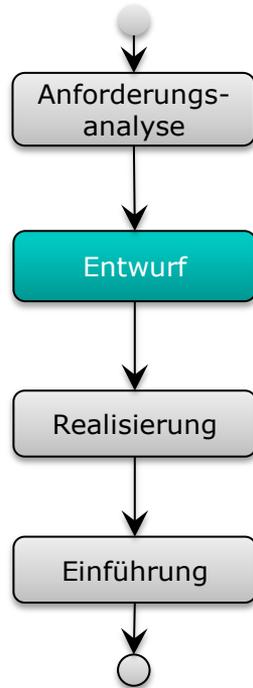
Aus Groß mach Klein

Formulierung des Gesamtproblems

- Überblick über System und relevanten Kontext
 - > Ohne Details
 - > Aus technischer Sicht

Zerlegung des Gesamtproblems in Teilprobleme

- Reduzierung der Komplexität
- Entwurfsstrategien
 - > Top-Down
 - > Bottom-Up
 - > Mischformen



Top-Down

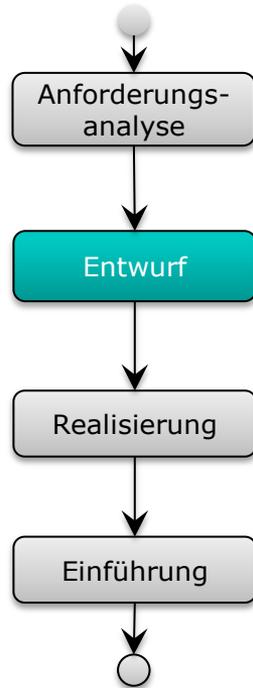
Hinab in die Untiefen

Vom Ganzen zu seinen Teilen

- Schrittweise Detailierung und Verfeinerung des Problems
- Formulierung von Teilproblemen (Modularisierung)
- Problemlösung erst nach Erreichen eines bestimmten Detailgrades

Beispiel: Hausbau

- „Ja, so mit vier Wänden halt“



Bottom-Up

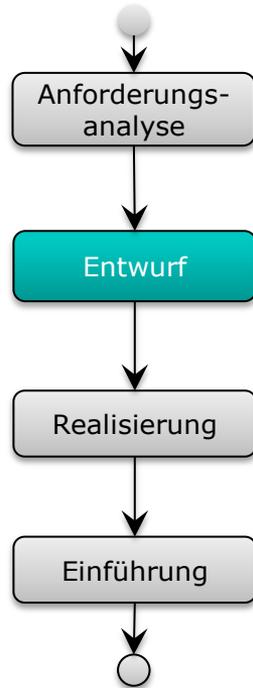
Hoch hinaus

Aus einzelnen Teilen ein Ganzes zusammenbauen

- Identifikation von elementaren Bausteinen
- Schrittweises Zusammensetzen der Bausteine
- Gesamtlösung entsteht zuletzt

Beispiel: Hausbau

- „Wie auch immer die Räume aussehen: Ich brauche LAN-Buchsen in jedem Raum“



Vor- und Nachteile

Top-Down vs. Bottom-Up

	Top-Down	Bottom-Up
Vorteile	<ul style="list-style-type: none">• Kleine Teilprobleme leichter zu lösen• Einschätzung des Arbeitsfortschritts	<ul style="list-style-type: none">• Gute Möglichkeit zur Wiederverwendung bestehender Bausteine• Technische Realisierung an der Basis früh betrachtet
Nachteile	<ul style="list-style-type: none">• Bei einer großen Zahl von Modulen erschwerte Wirkungskontrolle• Gefahr technische Basis zu spät zu betrachten	<ul style="list-style-type: none">• Gesamtproblem erst spät betrachtet• Sichtweise im Entwurf teilweise unvollständig

Notationen für den Entwurf Anforderungsanalyse und jetzt?

Beschreibung der Analyseergebnisse im Entwicklungsprozess

- In standardisierter Form
- Für jede Phase eigene Notationen verfügbar
- Meistens grafisch
- Möglichst kompakt, lesbar und eindeutig

Motivation

- Dokumentation der Analysearbeit
 - > Anforderungen
 - > Schnittstellen
 - > Arbeitsschritte
 - > Standard- und Sonderfälle
- Abstimmung mit Teammitgliedern und Kunden
- Grundlagen für folgende Phasen

Notationen für den Entwurf

Grundlegende Grundlagen

Beispiele für Notationen

- Textuell

- > Pseudocode:

- Zuweisung:

- Setze x auf den Wert von a

- $x \leftarrow a$

- Vergleich:

- Ist y gleich 0?

- $y = 0$

- Ist y ungleich 0?

- $y \neq 0$

- Grafisch

- > Flussdiagramme

- > Struktogramme

- > Unified Modeling Language (UML)

Pseudocode

Wie war das nochmal mit dem ggT?

Es soll $\text{ggT}(a, b)$ berechnet werden

1. $x \leftarrow a$
 $y \leftarrow b$

2. Wenn $y \neq 0$, dann

I. $r \leftarrow x - \left\lfloor \frac{x}{y} \right\rfloor * y$

II. $x \leftarrow y$

III. $y \leftarrow r$

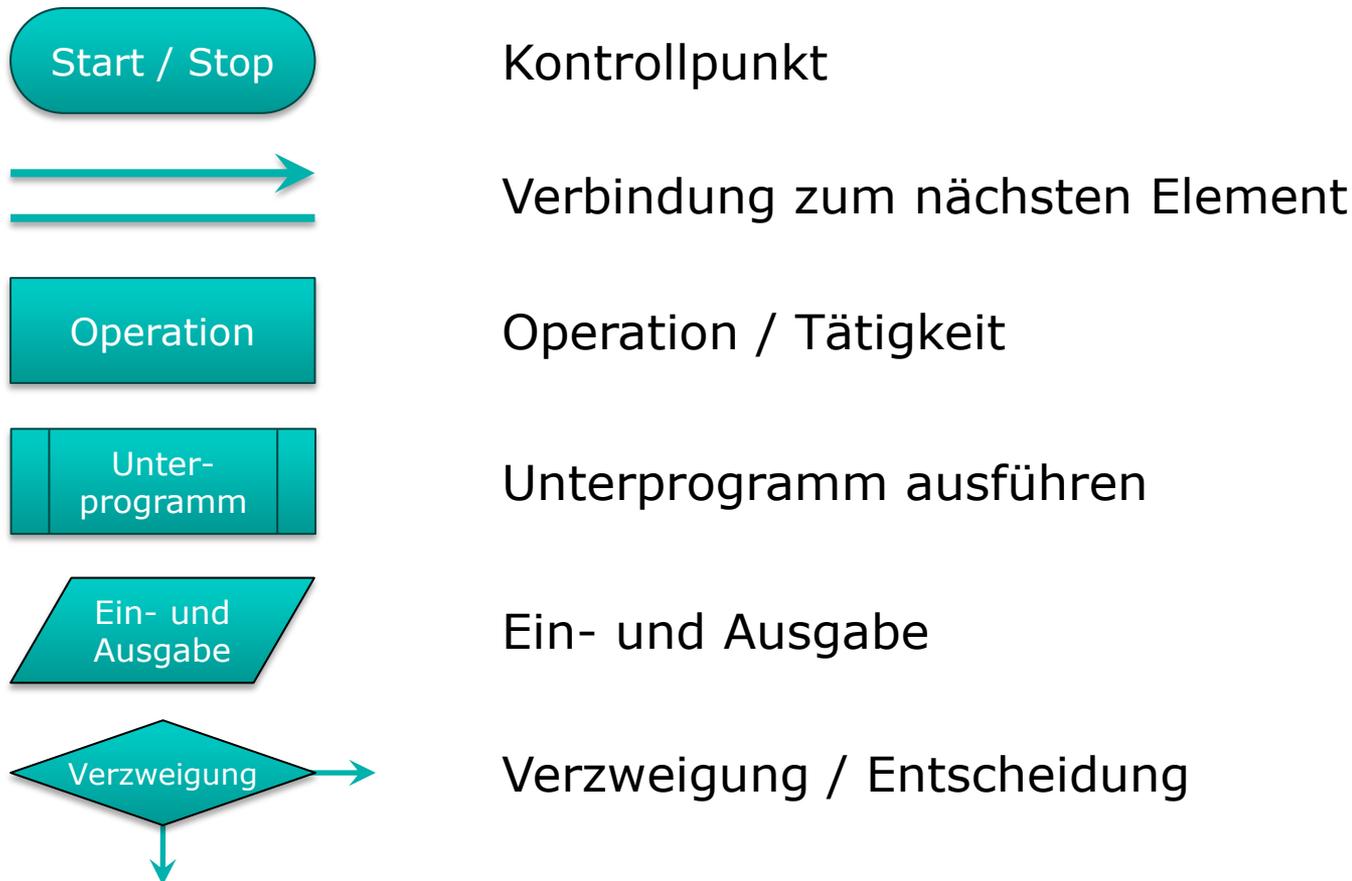
IV. Wiederhole Schritt 2

3. $\text{ggT} \leftarrow x$

Flussdiagramme (DIN 66001)

Alles ist im Fluss

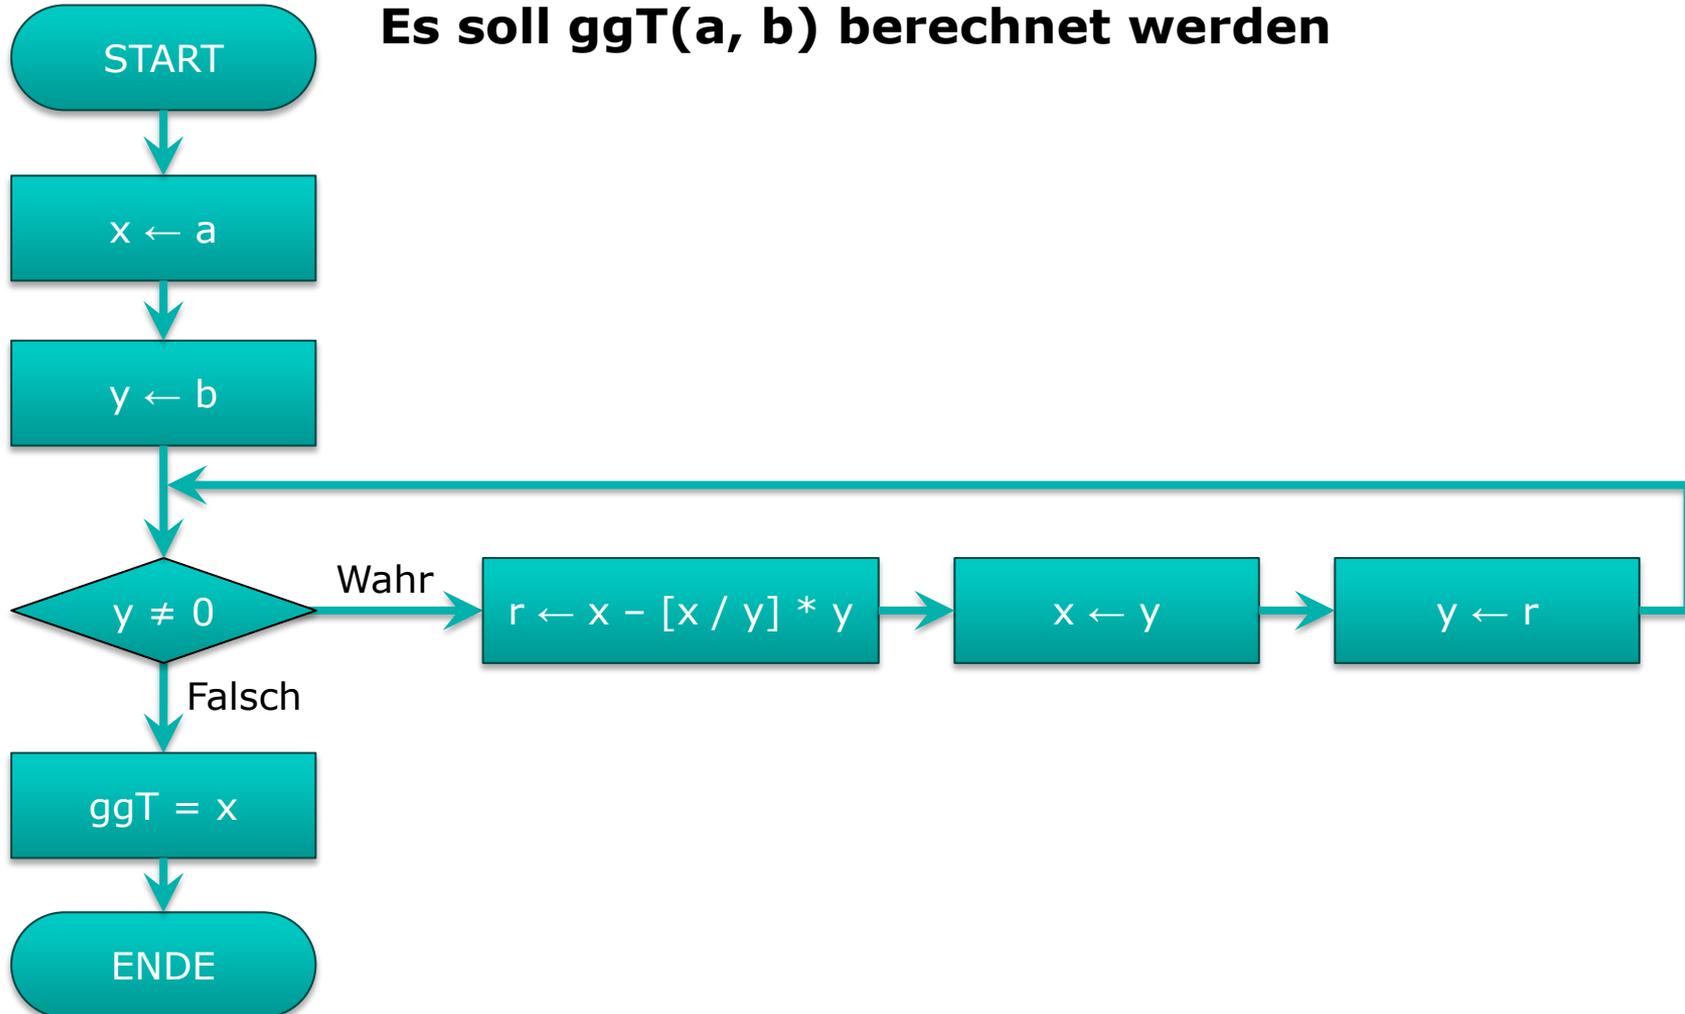
Flussdiagramme verwenden im Hauptsächlichen folgende Elemente



Flussdiagramme

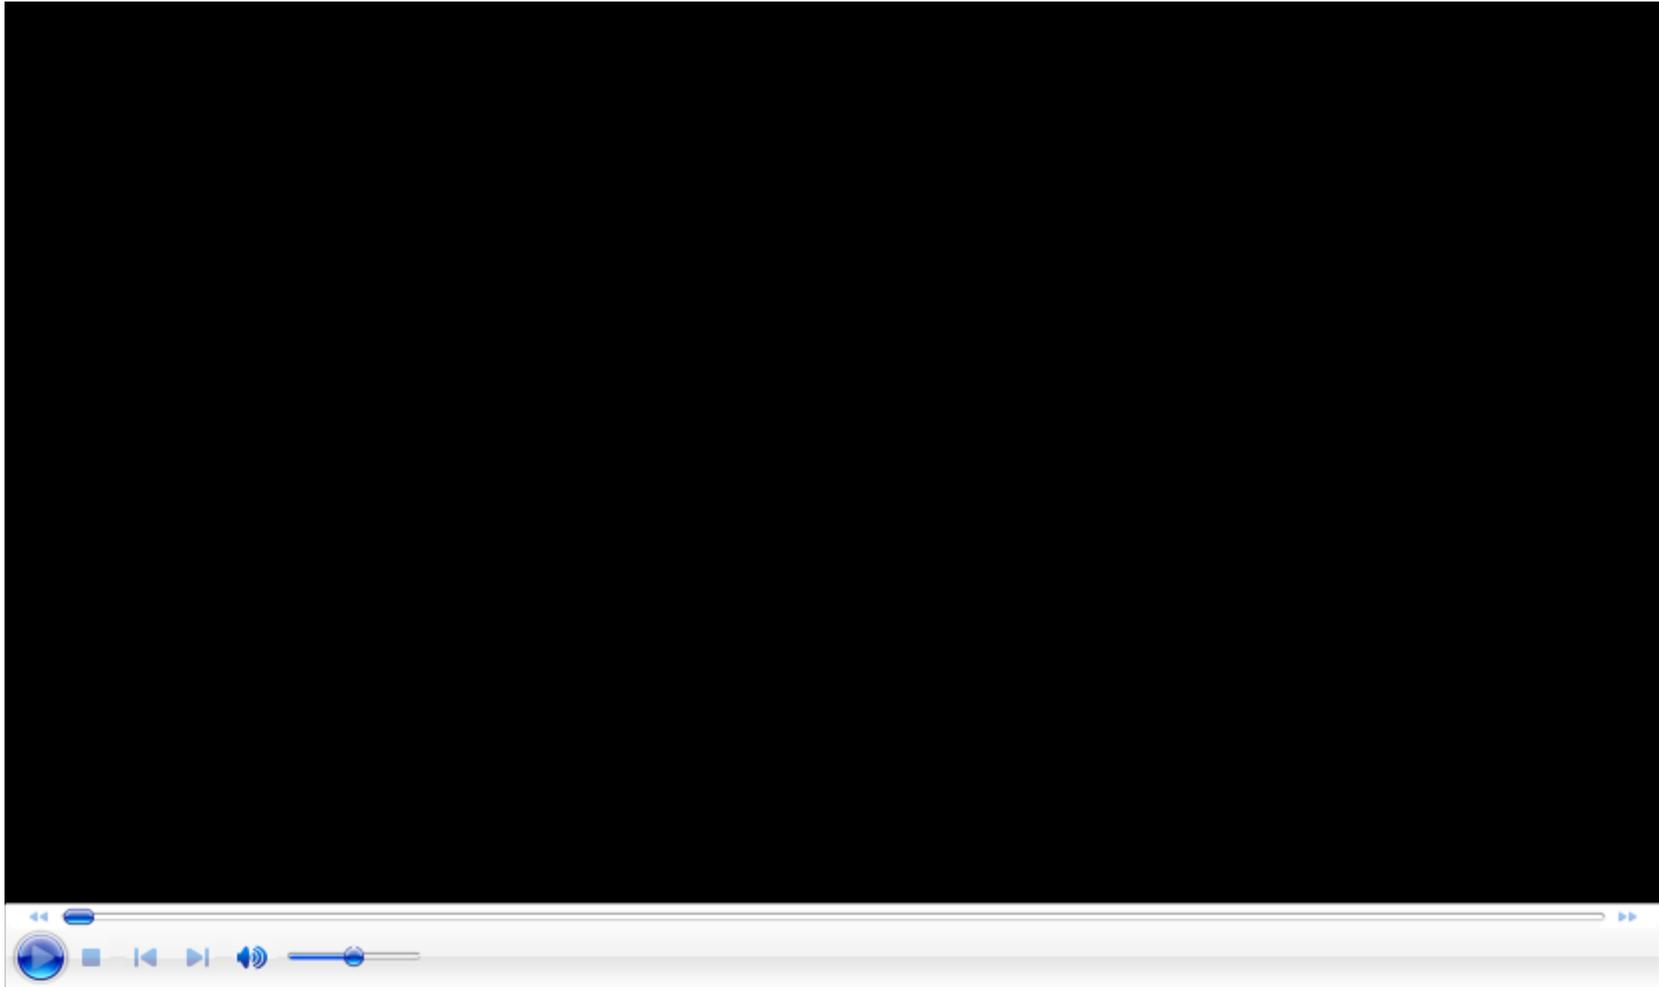
Und wieder der ggT

Es soll $\text{ggT}(a, b)$ berechnet werden



Flussdiagramme

Ein anschauliches Beispiel



Struktogramme (DIN 66 261)

Nassi-Shneiderman-Diagramme

Motivation

- Flussdiagramme sind fehleranfällig und unübersichtlich
- Beschränkung der Verzweigung und Reduzierung des Umfangs

Konventionen

- Ein Eingang, ein Ausgang
- Umfang maximal eine Seite
- Rücksprünge werden vermieden
- Pro Modul ein Diagramm

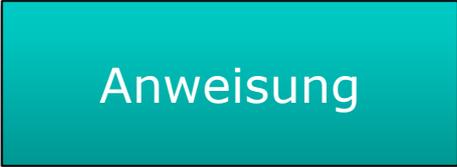


Struktogramme

Anweisungen

Darstellung *eines* Verarbeitungsschrittes

- Beispiel:
 - > Wertzuweisung
 - > Ein- und Ausgabeanweisungen
 - > Unterprogrammaufrufe



Anweisung

Struktogramme

Bedingung und Auswahl

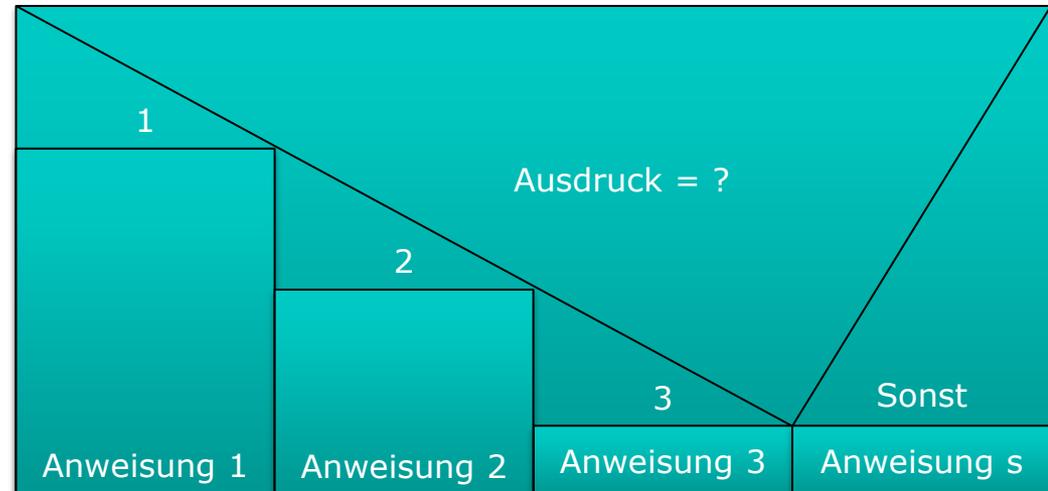
Verzweigungen in Programmen

- „If-Else“ in Java



Mehrfachverzweigungen

- „Switch-Case“ in Java

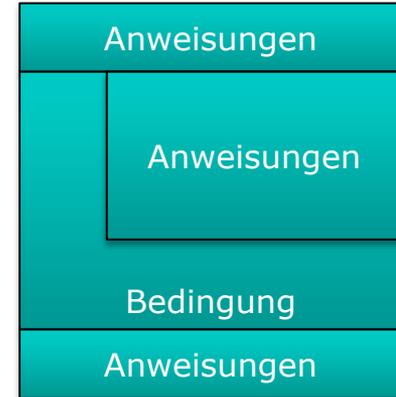


Struktogramme

Schleifen

Fußgesteuerte Schleifen

- Anweisungen werden mindestens einmal ausgeführt
- „Do-While“ in Java



Kopfgesteuerte Schleifen

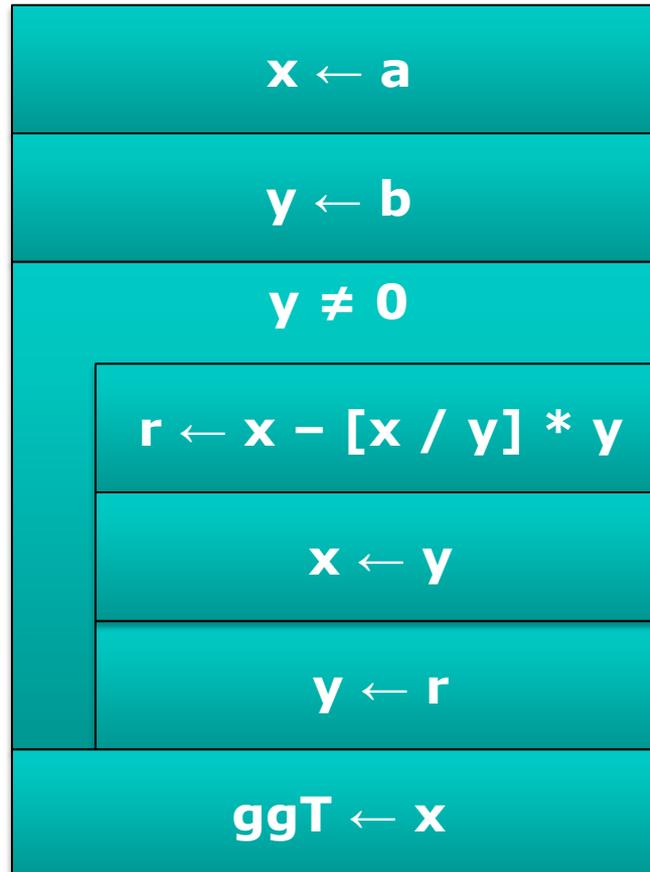
- Anweisungen werden auch beim ersten Mal erst nach Prüfung der Bedingung ausgeführt
- „While“ oder „For“ in Java



Struktogramme

Überraschung: der ggT

Es soll $\text{ggT}(a, b)$ berechnet werden



Wasserfallmodell

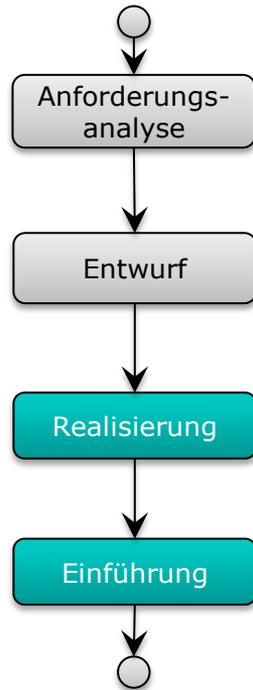
Realisierung & Einführung

Realisierung

- Umsetzung des Entwurfs in einer konkreten Programmiersprache
- Gewählte Programmiersprache abhängig vom Einsatzzweck
 - > z.B. Java & C# für Desktopapplikationen
 - > z.B. Assembler & C++ für hardwarenahe Applikationen
 - > z.B. PHP & ASP für Webanwendungen
 - > ...

Einführung

- Auslieferung, Installation und Inbetriebnahme der Software beim Kunden
- Genauer Umfang vom Vertrag abhängig



2 – Zahlendarstellungen

Ganze Zahlen, Negative ganze Zahlen, Gleitkommazahlen

Lessons Learned

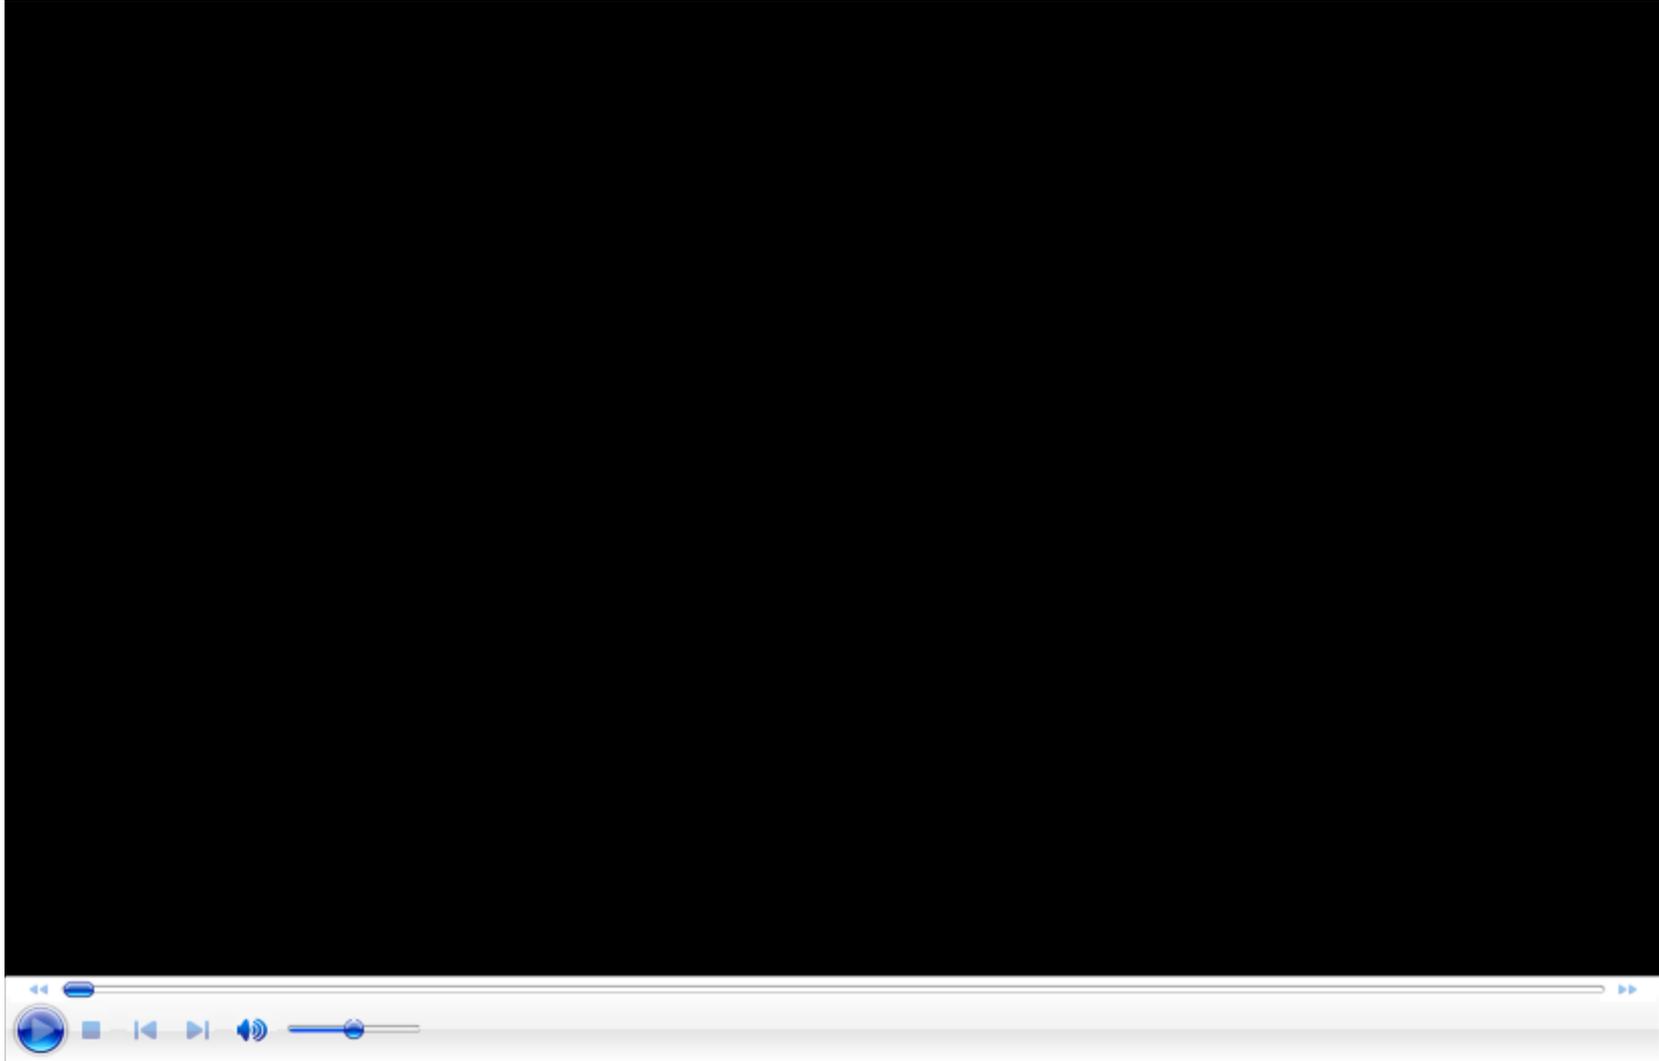
Muss ich mir das alles merken?

In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können

- Zahlensysteme
 - > Dezimal-, Binär, Hexadezimalsystem
 - > Umrechnungen zwischen diesen Zahlensystemen
- Zahlendarstellungen
 - > Darstellung ganzer Zahlen
 - > Darstellung von und Rechnen mit negativen ganzen Zahlen
 - > Darstellung von und Rechnen mit Gleitkommazahlen

Zahlen

Ein anschauliches Beispiel



Zahlen

Herr Ober, Zahlen, bitte!

243
1001001
2201
73
133
49
111
1021
3G
4D

Zahlen

Herr Ober, Zahlen, bitte!

243_5

1001001_2

2201_3

49_{16}

73_{10}

133_7

111_8

1021_4

$3G_{19}$

$4D_{15}$

Zahlen

Grundlegende Grundlagen

Jede natürliche Zahl lässt sich in eindeutiger Weise darstellen

$$n_B = \sum_{i=0}^r B^i * d_i$$

Dabei ist...

- B die **Basis** ($B > 1$)
 - > Dezimalsystem: $B = 10$
 - > Binärsystem: $B = 2$
- d_i die Ziffer an einer **wertigen Stelle** ($0 \leq d_i < B, d_r > 0$)
 - > Im Dezimalsystem: Einer, Zehner, Hunderter, ...
- r die „Länge“ der Zahl ($r \in \mathbb{N}$)
 - > r gibt die höchste wertige Stelle an (Anzahl Stellen = $r + 1$)

Zahlen

Ein Beispiel

Es soll die Zahl 73_{10} näher betrachtet werden.

Informelle Zerlegung der Zahl

- 7 Zehner, 3 Einer

Ein wenig formeller:

- $n_B = B^0 * d_0 + B^1 * d_1$
- $B = 10$
- $d = \{d_0 = 3, d_1 = 7\}$
- $73_B = 10^0 * 3 + 10^1 * 7$
- Damit ist $r = 1$

$$n_B = \sum_{i=0}^r B^i * d_i$$

Zahlensysteme

Einige Beispiele

Zahlensystem	Basis	Wertebereich (Ziffern)	Beispiel
dezimal	10	$\{0,1,2,\dots,8,9\}$	73_{10}
binär	2	$\{0,1\}$	$1001001_2 = 73_{10}$
hexadezimal	16	$\{0,\dots,9,A,\dots,F\}$	$49_{16} = 73_{10}$

Warum verwenden Computer andere Zahlensysteme (Binär-, Hexadezimalsystem) und nicht das Dezimalsystem?

- Interne Repräsentation des Binärsystems sehr einfach
 - > Vereinfacht: Strom an = 1, Strom aus = 0
- Binärsystem für den Menschen schnell unlesbar
 - > Hexadezimalsystem guter Kompromiss aus begrenztem Ziffernvorrat und Zahlenlänge
 - > Hexadezimalsystem und Binärsystem sind sehr leicht ineinander umzurechnen
- Beispiel:
 - > Binär: 1101010100010011000100_2
 - > Hexadezimal: $3544C4_{16}$

Zahlensysteme

There and back again

Umrechnung: Ins Dezimalsystem

- Einfaches Aufaddieren der einzelnen Stellen unter Berücksichtigung der jeweiligen Wertigkeit

Beispiele

- Binärsystem

$$> 1001001_2 = 1_{10} * (2_{10})^0 + 1_{10} * (2_{10})^3 + 1_{10} * (2_{10})^6 = 1_{10} + 8_{10} + 64_{10} = 73_{10}$$

- Hexadezimalsystem

$$> 49_{16} = 9 * (16_{10})^0 + 4_{10} * (16_{10})^1 = 9_{10} + 64_{10} = 73_{10}$$

Zahlensysteme

There and back again

Umrechnung: Dezimalsystem ins Binärsystem – Methode 1

- Informeller Ansatz:
 1. Suche größte Stelle im Binärsystem, die in die Dezimalzahl „hineinpasst“, und subtrahiere diese
 2. Wiederhole das Vorgehen solange mit dem Rest der Subtraktion, bis sich kein Rest mehr ergibt
 3. Fülle - falls nötig - Lücken und niederwertige Stellen mit Nullen auf
- Beispiel: Umrechnung der 73_{10}

$$\begin{array}{ll} > 73 - 2^6 = 9 & \rightarrow 1 \\ 9 - 2^5 < 0 & \rightarrow 0 \\ 9 - 2^4 < 0 & \rightarrow 0 \\ 9 - 2^3 = 1 & \rightarrow 1 \\ 1 - 2^2 < 0 & \rightarrow 0 \\ 1 - 2^1 < 0 & \rightarrow 0 \\ 1 - 2^0 = 0 & \rightarrow 1 \end{array}$$


$$73_{10} = 1001001_2$$

Zahlensysteme

There and back again

Umrechnung: Dezimalsystem ins Binärsystem – Methode 2

- Informeller Ansatz:
 1. Teile die Dezimalzahl durch 2 unter Berücksichtigung des Rests
 2. Wiederhole das Vorgehen solange mit dem Ergebnis der Division, bis sich 0 als Ergebnis ergibt

- Beispiel: Umrechnung der 73_{10}

>	$73:2 = 36$	Rest 1	↑
	$36:2 = 18$	Rest 0	
	$18:2 = 9$	Rest 0	
	$9:2 = 4$	Rest 1	
	$4:2 = 2$	Rest 0	
	$2:2 = 1$	Rest 0	
	$1:2 = 0$	Rest 1	

$$73_{10} = 1001001_2$$

Zahlensysteme

There and back again

Umrechnung: Dezimalsystem ins Hexadezimalsystem

- Umrechnung funktioniert prinzipiell genau, wie die Umrechnung ins Binärsystem
- Umrechnung mit Subtraktion allerdings deutlich komplizierter, deswegen hier Beschränkung auf Umrechnung mit Division
- Beispiel: Umrechnung der 73_{10}

$$\begin{array}{l} > 73:16 = 4 \quad \text{Rest } 9 \\ \quad 4:16 = 0 \quad \text{Rest } 4 \end{array} \quad \uparrow$$

$$73_{10} = 49_{16}$$

Zahlensysteme

There and back again

Umrechnung: Binärsystem ins Hexadezimalsystem

- Vorüberlegung
 - > 16 ist selbst zur Basis 2 darstellbar: $16 = 2^4$
 - > Umrechnung nutzt diesen Zusammenhang aus
- Die Umrechnung
 - > Die Binärzahl wird von rechts beginnend in Gruppen von 4 Ziffern gruppiert; nötigenfalls mit führenden Nullen auffüllen
 - > Jede Gruppe kann direkt in eine hexadezimale Ziffer umgerechnet werden
- Beispiel: Umrechnung von 1001001_2
 - > Gruppierung: 0100_2 1001_2
 - > Umrechnung: 4_{16} 9_{16}
 - > Ergebnis: 49_{16}

Zahlensysteme

There and back again

Umrechnung: Hexadezimalsystem ins Binärsystem

- Die Umrechnung macht sich denselben Zusammenhang zu Nutze, wie die Umrechnung in die Gegenrichtung
- Beispiel: Umrechnung von 49_{16}
 - > Betrachtung einzelner Ziffern:
 4_{16} 9_{16}
 - > Umrechnung:
 0100_2 1001_2
 - > Ergebnis:
 1001001_2

Zahlensysteme

Übungen



Binär	Dezimal	Hexadezimal
101010		
	37	
		AC

Zahlensysteme

Übungen



Binär	Dezimal	Hexadezimal
101010	42	2A
100101	37	25
10101100	172	AC

Negative Zahlen

Warum denn so negativ?

Positive ganze Zahlen lassen sich in einem Computer sehr einfach im Binärsystem darstellen, aber ...

Wie lassen sich negative ganze Zahlen in einem Computer darstellen?

Negative Zahlen

Warum denn so negativ?

Mögliche Lösungen

- Darstellung durch Betrag und Vorzeichen
- Darstellung im 1-Komplement
- Darstellung im 2-Komplement

Negative Zahlen

Betrag und Vorzeichen

Eine Stelle im Dualsystem wird für das Vorzeichen verwendet

- Das höchstwertige Bit (= das Bit ganz links) wird zur Darstellung des Vorzeichens verwendet
- Wert des Bits für eine ...
 - > ... positive Zahl: 0
 - > ... negative Zahl: 1
- Beispiel: Darstellung von $+73_{10}$ und -73_{10}
 - > $+73_{10} = 01001001_2$
 - > $-73_{10} = 11001001_2$

Negative Zahlen

Betrag und Vorzeichen

Die Darstellung negativer Zahlen mit einem Vorzeichenbit hat mehrere Nachteile

- Es gibt zwei Darstellungen der Null
 - > $+0 = (0, 0, \dots, 0)$ und $-0 = (1, 0, \dots, 0)$
 - > Es wird Platz für eine Zahl verschwendet
- Das Rechnen mit diesen Zahlen funktioniert nicht gut
 - > Die Subtraktion lässt sich nicht auf die Addition zurückführen
 - > Zusätzlicher Aufwand für eine eigene Subtraktion
 - > Beispiel: $0001_2 - 0001_2 \stackrel{?}{=} 0001_2 + (-0001_2)$

$$\begin{array}{r} 0001_2 \\ - 0001_2 \\ \hline = 0000_2 \end{array}$$

$$\begin{array}{r} 0001_2 \\ + 1001_2 \\ \hline = 1010_2 \end{array}$$

Negative Zahlen

Das 1-Komplement

Das 1-Komplement („logische Komplementbildung“) einer Binärzahl wird durch stellenweises invertieren gebildet

- Die Subtraktion kann in diesem Fall auf die Addition zurückgeführt werden

- Beispiel: $0001_2 - 0001_2 \stackrel{?}{=} 0001_2 + (-0001_2)$

$$\begin{array}{r} 0001_2 \\ - 0001_2 \\ = 0000_2 \end{array}$$

$$\begin{array}{r} 0001_2 \\ + 1110_2 \\ = 1111_2 \end{array}$$

- Auch in diesem Fall gibt es wieder zwei Nullen
> $+0 = (0, 0, \dots, 0)$ und $-0 = (1, 1, \dots, 1)$

Negative Zahlen

Das 1-Komplement

Aber auch das Rechnen mit dem 1-Komplement ist manchmal umständlich

- Tritt bei einer Subtraktion ein Überlauf auf, so muss dieser ignoriert werden und stattdessen eine „1“ addiert werden
- Beispiel: Es soll $12_{10} - 8_{10}$ berechnet werden
 - > Umrechnung
 - > $12_{10} = 1100_2$
 - > $-8_{10} = 0111_2$
 - > Berechnung

$$\begin{array}{r} 1100_2 \\ + 0111_2 \\ \hline 10011_2 \end{array}$$
 - > Beachtung des Sonderfalls
 - > Überlauf ignorieren: $10011_2 \rightarrow 0011_2$
 - > „1“ addieren: $0011_2 + 0001_2 = 0100_2$

Negative Zahlen

Das 2-Komplement

Das 2-Komplement („arithmetische Komplementbildung“) einer Binärzahl wird durch stellenweises invertieren und anschließendes addieren einer „1“ gebildet

- Die Subtraktion kann auch in diesem Fall auf die Addition zurückgeführt werden

• Beispiel: $0001_2 - 0001_2 \stackrel{?}{=} 0001_2 + (-0001_2)$

$$\begin{array}{r} 0001_2 \\ - 0001_2 \\ \hline = 0000_2 \end{array}$$

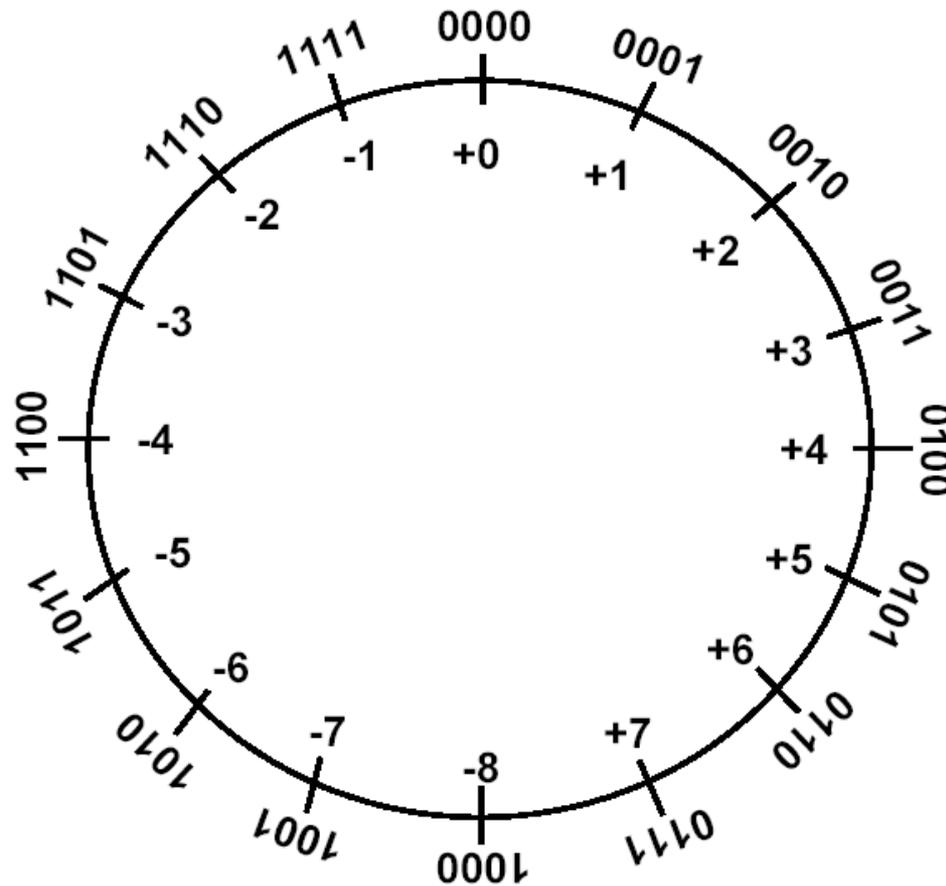
$$\begin{array}{r} 0001_2 \\ + 1111_2 \\ \hline = 10000_2 \end{array}$$

- Anmerkungen
 - > Es existiert nur noch eine Null
 - > Das Vorzeichen ist am führenden Bit erkennbar
 - > Der Überlauf wird ignoriert

Negative Zahlen

Das 2-Komplement

Das 2-Komplement kann wie folgt grafisch dargestellt werden



Negative Zahlen

Übung



Betrag & Vorzeichen	1-Komplement	2-Komplement
10001		
	1000	
		1011

Negative Zahlen

Übung



Betrag & Vorzeichen	1-Komplement	2-Komplement
10001	1110	1111
10111	1000	1001
10101	1010	1011

Kommazahlen

Bart, komma her! – Komma Du her! – Achja?!

Es gibt prinzipiell zwei verschiedene Arten von Kommazahlen in einem Computersystem

- Festkommazahlen
 - > Zahlen mit einer festen Anzahl von Stellen vor und hinter dem Komma bei fester Anzahl von Bits
 - > Darstellung über negative Zweierpotenzen
 - > Addition und Subtraktion funktioniert analog zur Addition und Subtraktion ganzer Zahlen
 - > Beispiel: $2.5_{10} + 0.25_{10} = 10.10_2 + 00.01_2 = 10.11_2$
- Gleitkommazahlen
 - > Zahlen mit variabler Genauigkeit, d.h. Stellen hinter dem Komma, bei fester Anzahl von Bits
 - > Addition und Subtraktion müssen speziell definiert werden

Kommazahlen

Gleitkommazahlen und IEEE

Die Darstellung von Gleitkommazahlen mit Bits und Bytes wird über die IEEE 754 Norm geregelt

- Es gibt einfache Genauigkeit mit 32 Bits und doppelte Genauigkeit mit 64 Bits
- Die Bits werden für verschiedene Teile der Zahl verwendet
 - > Vorzeichen S
 - > Exponent E
 - > Mantisse M
- Die Darstellung erfolgt immer zur Basis 2 in folgender Form

$$x = s * m * 2^e$$

Kommazahlen

Gleitkommazahlen und IEEE

Aus technischen Gründen werden nicht die Werte gespeichert, aus denen die Zahl tatsächlich berechnet wird

- Die „echten“ Werte müssen aus den gespeicherten Werten S , E und M und einem festen Wert b berechnet werden

$$x = s * m * 2^e$$

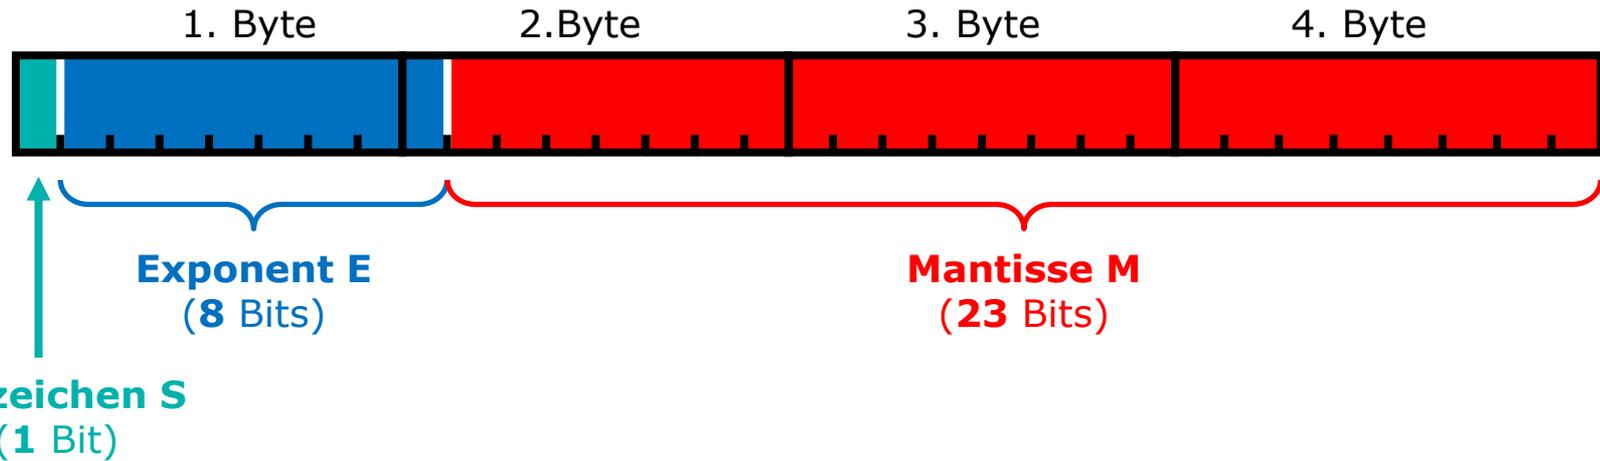
$$s = (-1)^s$$

$$e = E - b$$

$$m = 1, M$$

Gleitkommazahlen

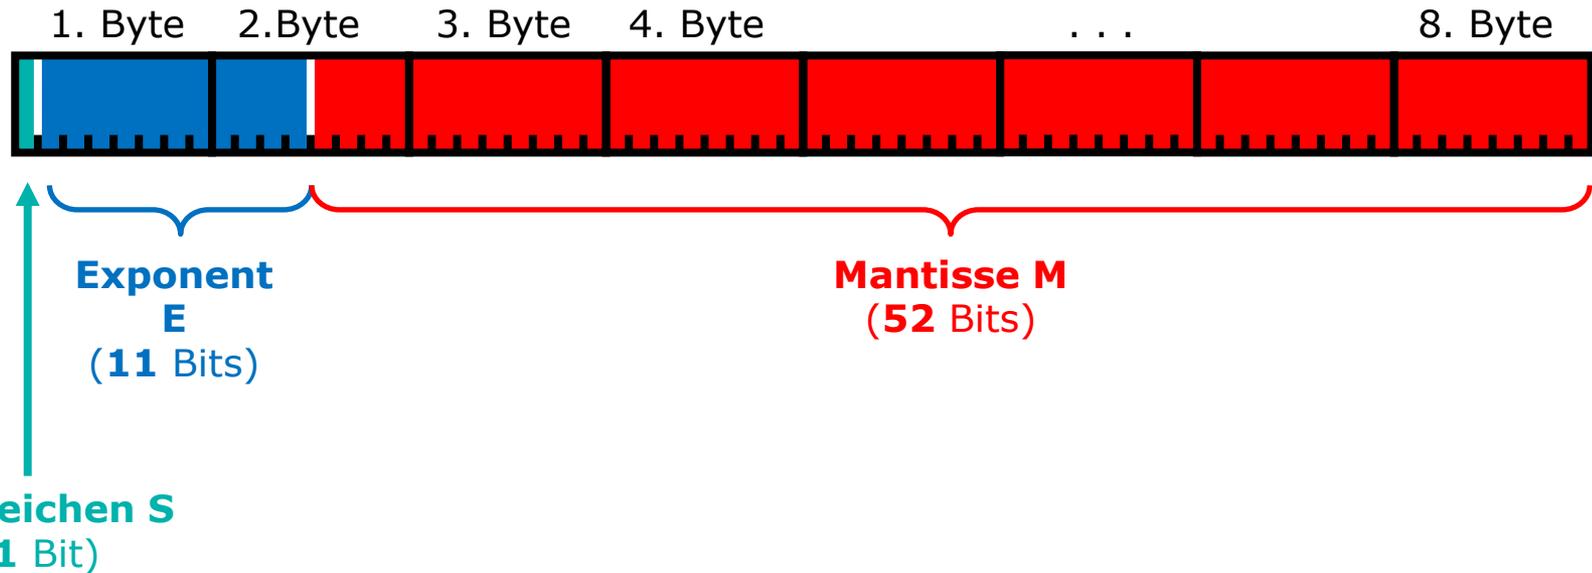
Einfache Genauigkeit



- Der Exponent kann Werte von -126 bis $+127$ annehmen
 - > Die Werte -127 und $+128$ sind für Spezialfälle reserviert
- Der Biaswert b ist 127

Gleitkommazahlen

Doppelte Genauigkeit



- Der Exponent kann Werte von -1022 bis + 1023 annehmen
 - > Die Werte -1023 und + 1024 sind für Spezialfälle reserviert
- Der Biaswert b ist 1023

Gleitkommazahlen

Normalisierung

Normalisierung bringt die Mantisse einer Gleitkommazahl in ein bestimmtes Format

- Vorüberlegungen
 - > Die Mantisse selbst ist eigentlich auch eine Gleitkommazahl
 - > Ein Format zur Speicherung von Gleitkommazahlen zu definieren, welches selbst eine Gleitkommazahl speichern muss, ist unsinnig
- Idee
 - > Das Komma der Mantisse kann beliebig verschoben werden, sofern der Exponent der Gleitkommazahl entsprechend angepasst wird
- Beispiel aus dem Dezimalsystem
 - > $579_{10} * (10_{10})^0 = 57,9_{10} * (10_{10})^1 = 5,79_{10} * (10_{10})^2$ usw.

Gleitkommazahlen

Normalisierung

Das Komma der Mantisse wird so verschoben, dass nur noch eine einzelne 1 direkt vor dem Komma steht

$$m = 1, M$$

- Da dies (zunächst) für alle Gleitkommazahlen nach der IEEE 754 Norm gilt, muss die 1 vor dem Komma der Mantisse nicht mehr explizit gespeichert werden
- Es werden in den entsprechenden Bits der Mantisse also nur die Nachkommastellen *M* der Mantisse gespeichert
- Der Exponent muss bei der Normalisierung der Mantisse entsprechend angepasst werden

Gleitkommazahlen

Umwandlung

Prinzipiell wird bei der Umwandlung einer Dezimalzahl in das IEEE 754 Format wie folgt vorgegangen

1. Umwandlung der Dezimalzahl in eine binäre Festkommazahl ohne Vorzeichen
2. Normalisieren und Bestimmen des Exponenten
3. Vorzeichen-Bit bestimmen
4. Gleitkommazahl zusammensetzen

Gleitkommazahlen

Umwandlung – Beispiel

Die Zahl 73.5_{10} soll in eine Gleitkommazahl nach IEEE 754 Norm in einfacher Genauigkeit umgewandelt werden

1. Umwandlung der Dezimalzahl in eine binäre Festkommazahl ohne Vorzeichen

- $73.5_{10} = 1001001.1_2$

2. Normalisieren und Bestimmen des Exponenten

- $1001001.1_2 * 2^0 = 1.0010011_2 * 2^6$
- $M = 00100110000000000000000_2$
- $E = 6_{10} + 127_{10} = 110_2 + 1111111_2 = 10000101_2$

3. Vorzeichen-Bit bestimmen

- $S = 0$

4. Gleitkommazahl zusammensetzen

- $01000010\ 10010011\ 00000000\ 00000000$

Gleitkommazahlen

Spezialfälle

Anmerkung

- r ist die Anzahl der Exponenten-Bits

Exponent E	Mantisse M	Bedeutung
$E = 0$	$M = 0$	$+/- 0$
$E = 0$	$M \neq 0$	$+/- 0.M * 2^{1-b}$
$0 < E < 2^r - 1$	$M \neq 0$	$+/- 1.M * 2^{E-b}$
$E = 2^r - 1$	$M = 0$	$+/- \infty$
$E = 2^r - 1$	$M \neq 0$	NaN

Gleitkommazahlen

Addition und Subtraktion

Addition und Subtraktion zweier Gleitkommazahlen im IEEE 754 Format

- Beide Zahlen müssen denselben Exponenten haben, ansonsten muss zunächst eine Zahl umgerechnet werden
 - > Die betragsmäßig kleinere Zahl wird umgerechnet
- Haben beide Zahlen denselben Exponenten kann die Mantisse einfach addiert oder subtrahiert werden
- Die resultierende Zahl muss – wenn möglich und nötig – wieder normalisiert werden

Gleitkommazahlen

Ein beispielhaftes Beispiel – Addition

Es seien zwei Gleitkommazahlen a und b gegeben

- $a = |0|10000001|(1)100100000000000000000000$
- $b = |0|01111111|(1)1011000100010000000000$

Die Zahl b ist kleiner und muss daher umgerechnet werden

- $b = |0|10000001|(0)011011000100010000000000$

Addition

- $a + b = |0|10000001|(1)111111000100010000000000$

Gleitkommazahlen

Bezug zur Programmiersprache

Datentyp	Größe	Wrapper-Klasse	Wertebereich	Beschreibung
byte	8 Bit	java.lang.Byte	-128 ... +127	2-Komplement
short	16 Bit	java.lang.Short	-32.768 ... +32.767	2-Komplement
int	32 Bit	java.lang.Integer	-2.147.483.648 ... +2.147.483.647	2-Komplement
long	64 Bit	java.lang.Long	-9.223.372.036.854.775.808 ... +9.223.372.036.854.775.807	2-Komplement
float	32 Bit	java.lang.Float	$\pm 1,4E-45 \dots \pm 3,4E+38$	Gleitkommazahl (IEEE 754)
double	64 Bit	java.lang.Double	$\pm 4,9E-324 \dots \pm 1,7E+308$	Gleitkommazahl (IEEE 754)

Gleitkommazahlen

Übung



Festkommazahl	Gleitkommazahl
01011001.010	
	1 10000110 101100100100000000000000

Gleitkommazahlen

Übung



Festkommazahl	Gleitkommazahl
01011001.010	0 10000101 011001010000000000000000
-11011001.001	1 10000110 101100100100000000000000

3 – Codierung

Einfache Codes, Spezialisierte Codes

Lessons Learned

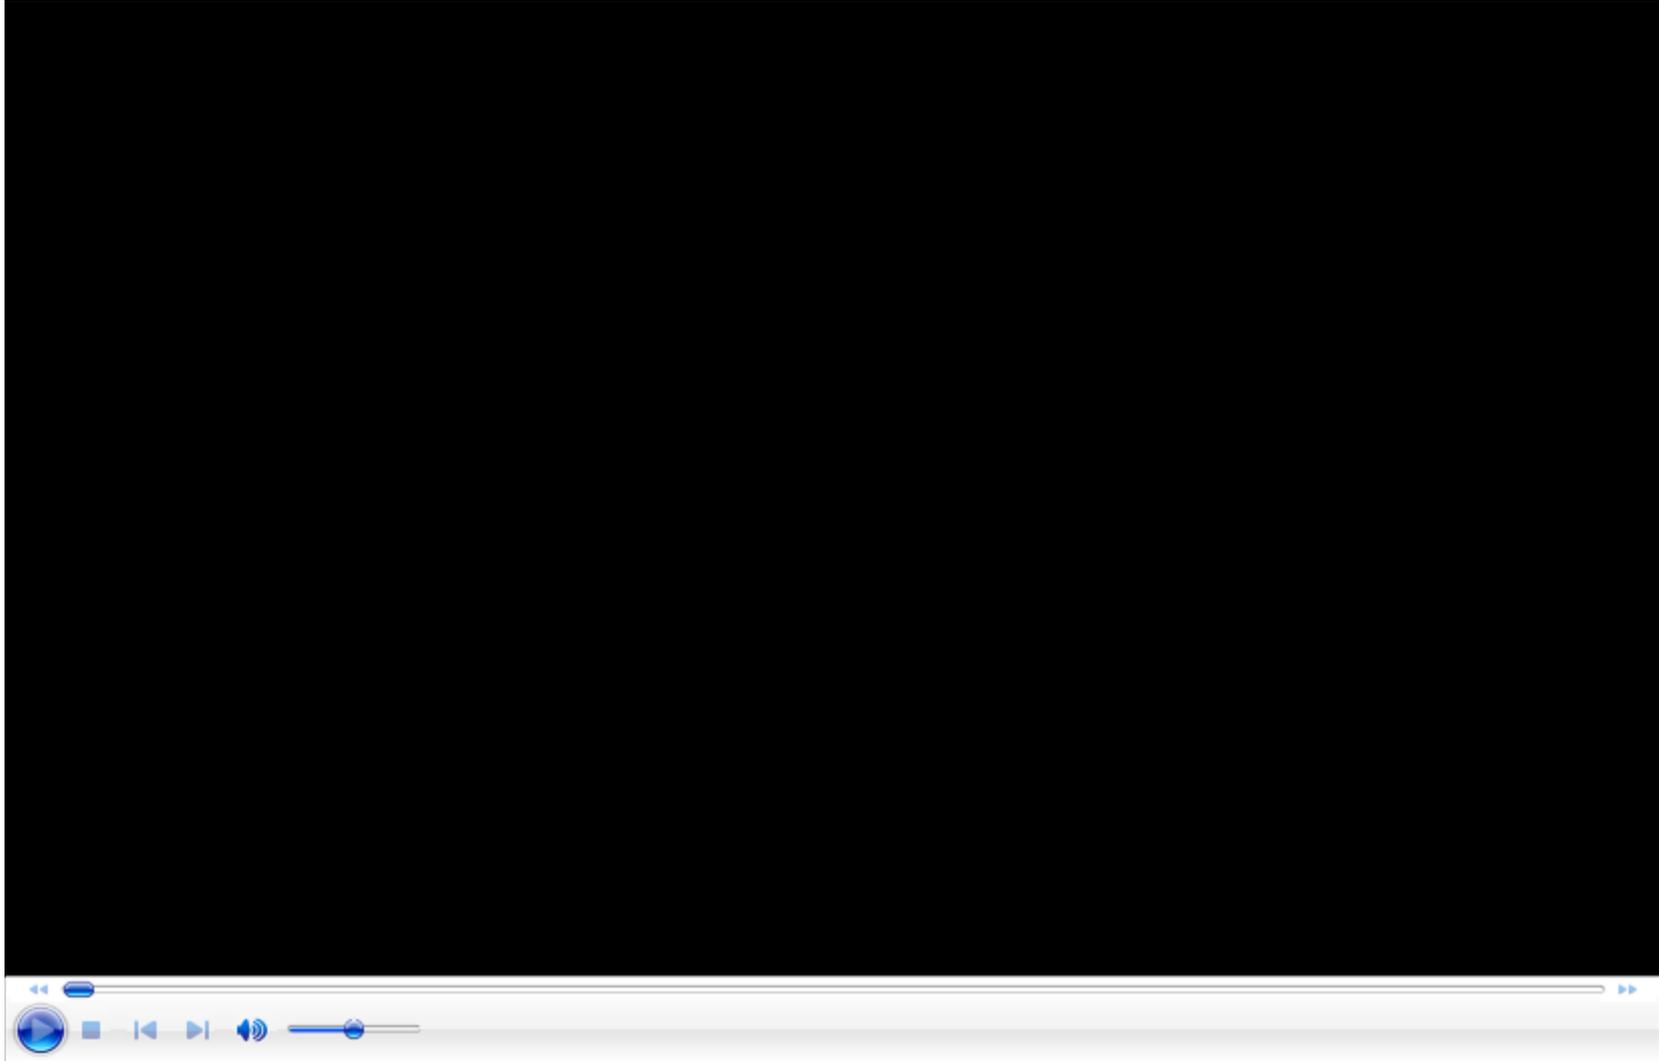
Muss ich mir das alles merken?

In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können

- Einfache Codes
 - > Darstellung von Ziffern und Zeichen im Rechner
 - > Gängige Standards
- Spezialisierte Codes
 - > Motivation für spezielle Codierungen
 - > Optimale Codes
 - > Robuste Codes

Codes

Ein anschauliches Beispiel



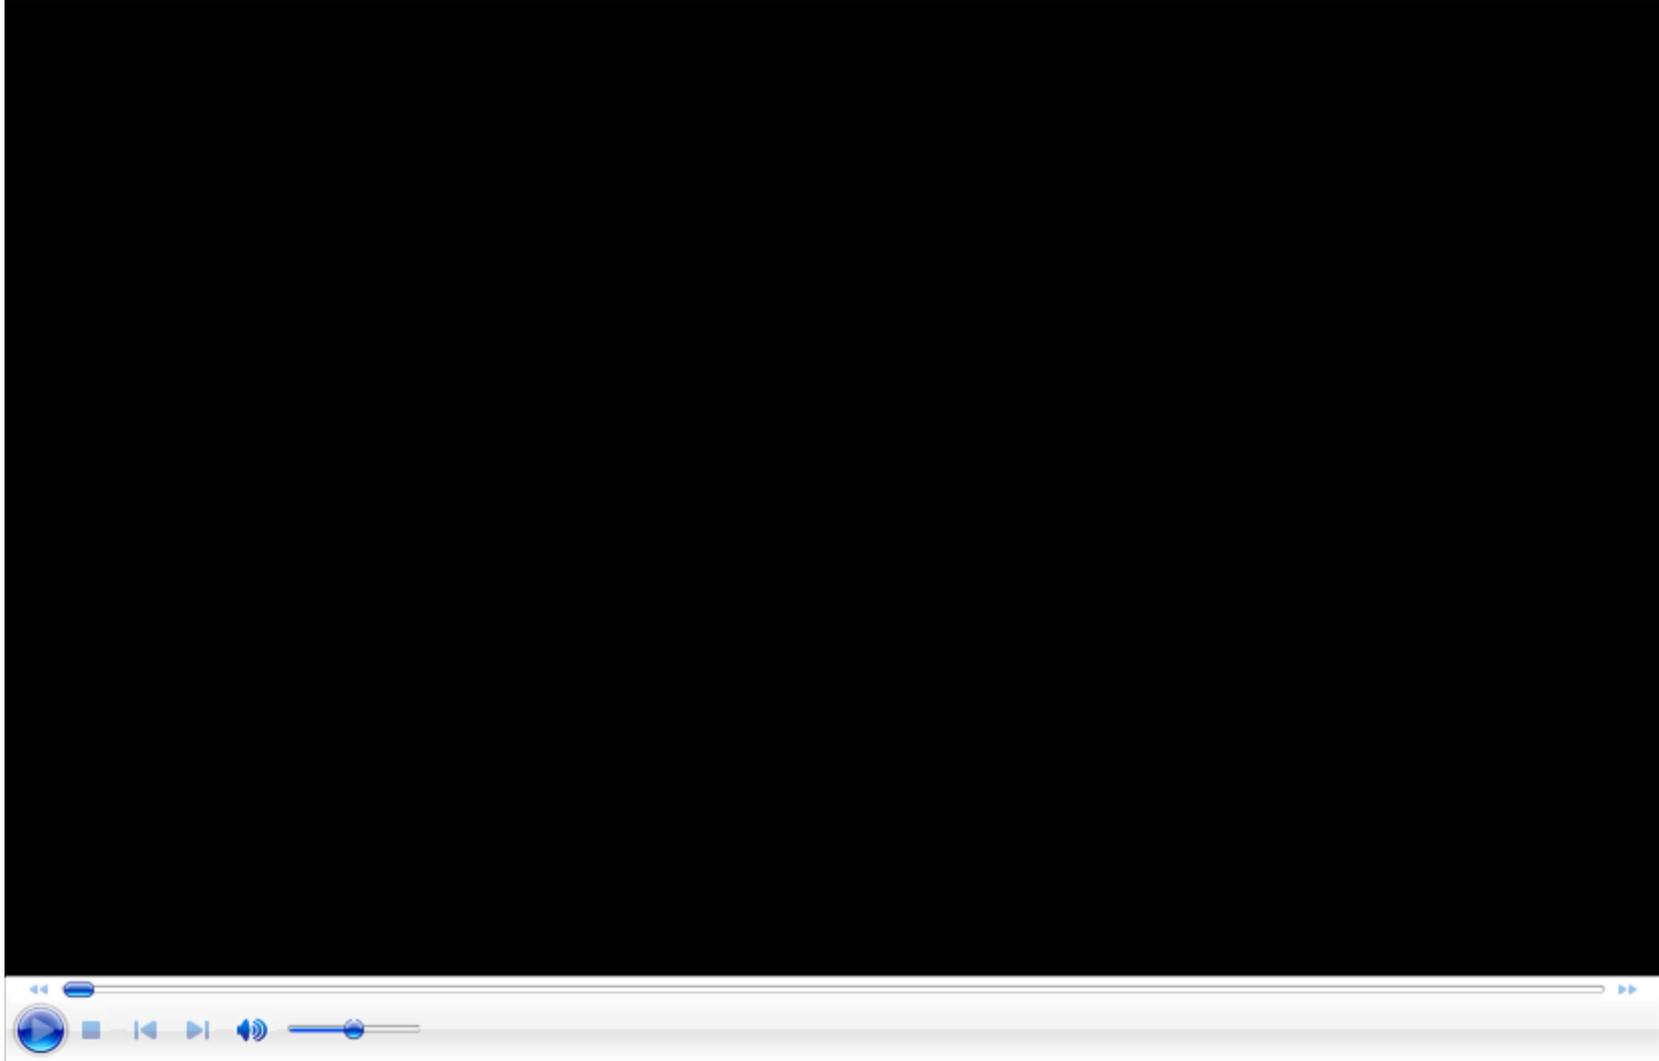
Was ist ein Code?

Und was hat dieser Da Vinci damit zu tun?

Morsecode
The Da Vinci Code
Zugangscodes
Barcode
ASCII-Code
sourcecode
Genetischer Code
Geheimcode
QR-Code

Codes

Ein anschauliches Beispiel



Was ist ein Code?

Eigenschaften

Ein Code ist ...

- ... eine Formulierung von **Information**
- ... eine Vereinbarung über einen **Satz von Symbolen**
- ... eine **Abbildung**, die Symbolen eines *Alphabets* eindeutige Symbole eines eventuell anderen *Alphabets* zuordnet
 - > Ist die Abbildung **eineindeutig**, so ist der Code **entzifferbar**

Was ist ein Code?

Sinntragende Zeichen / Symbole

Code dient dazu Informationen zu transportieren

- Es gibt sinntragende Zeichen, aus denen die Information vom Empfänger des Codes gewonnen werden kann
 - > Werden auch Symbole genannt
- Ein Code bildet zwischen zwei sogenannten Alphabeten aus sinntragenden Zeichen (eindeutig) ab
- Beispiele
 - > Ziffern, Großbuchstaben, Kleinbuchstaben, Sonderzeichen, Hieroglyphen, Kanjis, ...



ASCII

Ein einfacher Code

Der ASCII-Code stellt Buchstaben, Ziffern und Sonderzeichen anhand einer binären Zahl mit 7 Bits dar

- Vorteile
 - > Einfach zu Codieren und Decodieren
 - > Kurze Darstellung
 - > Wenig Speicherplatz
- Nachteile
 - > Menge der darstellbaren Zeichen (zu) klein

ASCII

Codierungstabelle

Anmerkung

- 128 Zeichen darstellbar: 00 – 7F

	...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

ASCII

Ein beispielhaftes Beispiel

Es soll der Ausdruck „**MILKY GREEN**“ codiert werden:

- Es muss zu jedem Buchstaben und jedem Sonderzeichen (= Leerzeichen) die entsprechende Zahl aus der Codierungstabelle gelesen werden
- In diesem Fall sollen die Zahlen zur Basis 10 angegeben werden

M	I	L	K	Y	␣	G	R	E	E	N
77	73	76	75	89	32	71	82	69	69	78



String	ASCII Binär	ASCII Hexadezimal
MATSE		
	1000101 1000100 1010110	
		43 2B 2B

ASCII Übung



String	ASCII Binär	ASCII Hexadezimal
MATSE	1001101 1000001 1010100 1010011 1000101	4D 41 54 53 45
EDV	1000101 1000100 1010110	45 44 56
C++	1000011 0101011 0101011	43 2B 2B

Mit den 7 Bits von ASCII kann man nur sehr wenige Zeichen darstellen.

Was ist z.B. mit Umlauten?

Unicode

Ein erweiterter Code

Unicode ist ein Zeichensatz mit 32 Bits, der als weltweiter Standard geplant ist

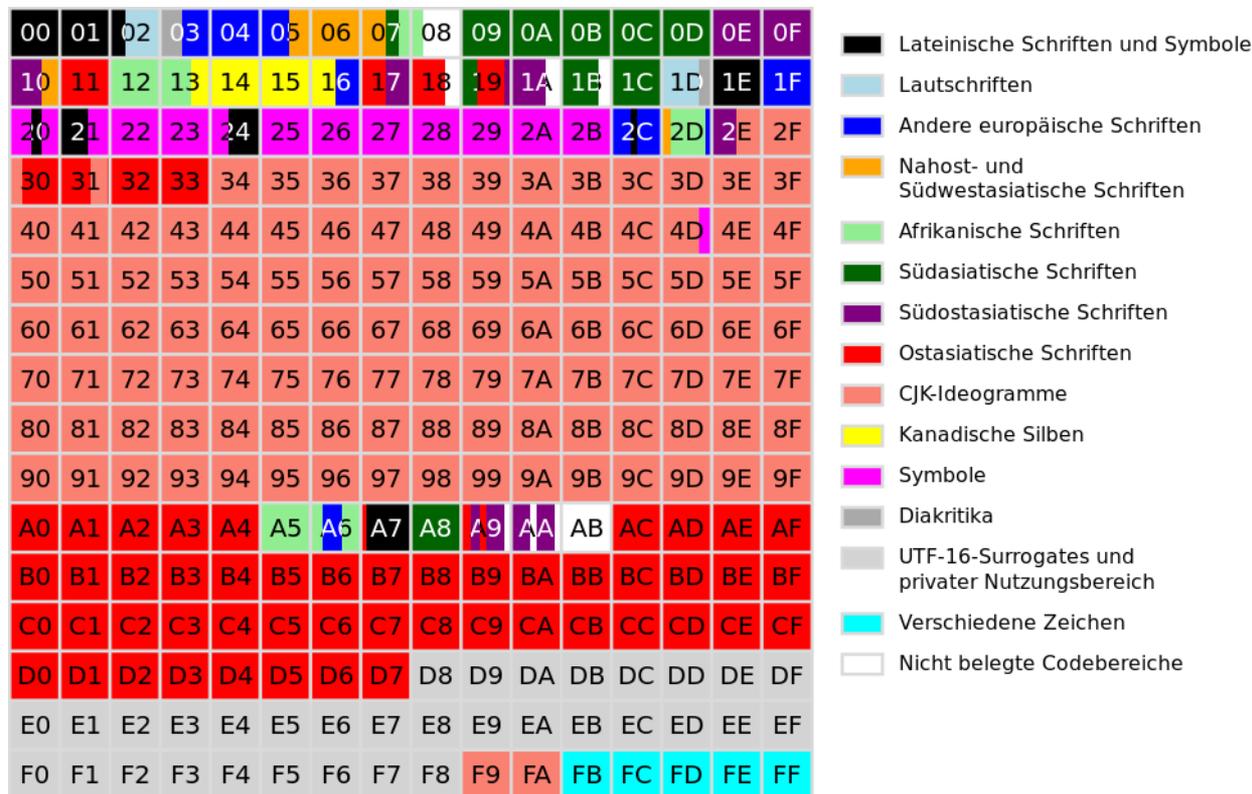
- Ziel ist ein eindeutiger, digitaler Code für jedes sinntragende Zeichen weltweit
 - > Globaler Informationsaustausch wird möglich
- Die digitalen Codes für die Zeichen des ASCII-Codes sind weiterhin dieselben
 - > Führenden Nullen werden hinzugefügt
- Aufbau des Codes
 - > Zunächst 16-Bit Codierung mit fester Länge, später 32 Bit
 - > Maximal **65.536** bzw. **4.294.967.296** Zeichen darstellbar
 - > Notation im Hexadezimalsystem **U+(XX)XXXXXX**
 - > Dabei geben die **letzten 2 Byte** eine Position in **einer Plane (Ebene)** an
 - > Die Angabe der Plane ist dabei optional (Standard = **00**)

Unicode

Basic Multilingual Plane

Anmerkung

- Das erste Byte adressiert den Block innerhalb der Plane, das zweite Byte ein Zeichen innerhalb des Blocks



Unicode

Anmerkungen

- Zeichen, die in unterschiedlichen Kontexten mehrfach vorkommen werden im Unicode auch mehrfach codiert
 - > z.B. gibt es das „A“ im lateinischen und im griechischen Alphabet
- Es gibt nur 17 Planes
 - > Die 32 Bit werden also (noch) nicht vollständig zur Zeichencodierung benutzt
- Näheres zu ASCII, Unicode und UTF-8
 - > <http://www.youtube.com/watch?v=MijmeoH9LT4>

Unicode Transformation Format

Ein Code mit variabler Länge

Um die Unicode-Zeichen im Rechner zur Weiterverarbeitung darstellen zu können gibt es die UTF-Codierung

Es gibt mehrere UTF-Standards

- **UTF-32** je Zeichen 4 Bytes (32 Bit)
 - > feste Länge, einfache Codierung, hoher Speicherbedarf
- **UTF-16** je Zeichen 2 oder 4 Bytes (16 – 32 Bit)
 - > Variable Länge, hoher Speicherbedarf
- **UTF-8** je Zeichen 1 bis 4 Byte (8 – 32 Bit)
 - > Variable Länge, niedriger Speicherbedarf

UTF-8

Ein Code mit variabler Länge

UTF-8 ist dazu geeignet, den Speicherplatz eines Zeichens den Anforderungen anzupassen

- Handelt es sich bei einem Zeichen um ein ASCII-Zeichen wird ein Byte zur Codierung benötigt
 - > (0 – 127) → 0xxx xxx
- Handelt es sich um ein anderes Zeichen werden 2 bis 4 Bytes zur Codierung benötigt
 - > Das erste Byte beginnt mit einer Anzahl von Einsen, die der Anzahl von zu verwendenden Bytes entspricht, gefolgt von einer 0
 - > Jedes folgende Byte beginnt mit **10**
 - > Beispiel
 - > Ein 3 Byte-Code sieht wie folgt aus: **1110 xxxx | 10xx xxxx | 10xx xxxx**
 - > Damit verbleiben 16 Bits zur Darstellung eines Unicode Zeichens

UTF-8

Übung



Zeichen / Dezimalwert	Unicode	UTF-8
A / 65		
ä / 257		
Ÿ / 1038		

UTF-8

Übung



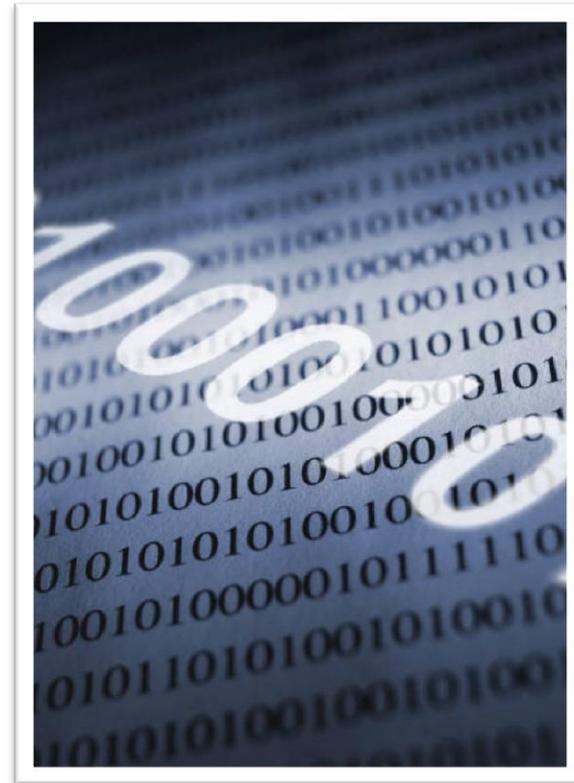
Zeichen / Dezimalwert	Unicode	UTF-8
A / 65	U+0041	41
ä / 257	U+0101	C4 81
ÿ / 1038	U+040E	D0 8E

Spezielle Codes

Wozu überhaupt?

Es gibt verschiedene Gründe für spezielle Codierungen

- Technische Randbedingungen
- Speicheroptimierung
- Robuste Codierung
 - > Fehler erkennen & korrigieren



Spezielle Codes

Technische Randbedingungen

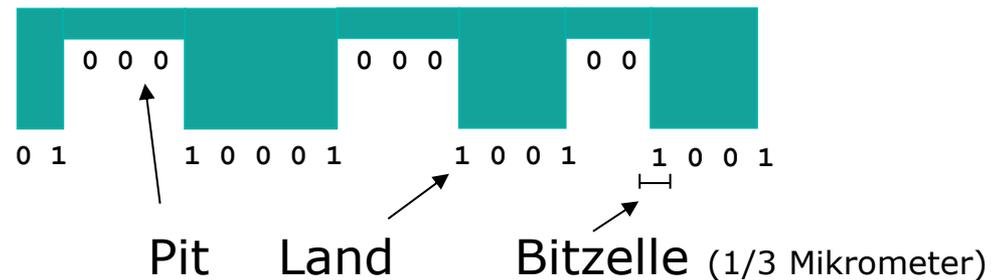
Es kann technische Randbedingungen geben, die die Verwendung spezieller Codes nötig machen

- Möglichkeiten zur Optimierung
 - > z.B. Binärcode auf dem Computer
- Ungenauigkeiten
 - > z.B. Daten auf einer CD / DVD / Blu-ray
- Bestimmte Formate
 - > z.B. QR-Code zur Erkennung mit Smartphones



Technische Realisierung einer CD

- Eine CD hat eine reflektierende Oberfläche
 - > Pits = (eingebrannte) Vertiefungen
 - > Lands = Erhebungen
- Codierung
 - > Pits & Lands = 0
 - > Übergänge = 1



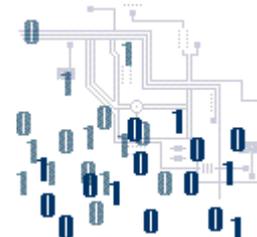
Technische Randbedingungen

- Es müssen mindestens 2 Nullen und höchstens 11 Nullen zwischen zwei Einsen folgen
 - > 8-Bit-Codes sind nicht verwendbar
 - > Stattdessen wird ein 14-Bit-Code benutzt
 - > EFM = Eight-To-Fourteen-Modulation
 - > Jedem 8-Bit-Code wird anhand einer Tabelle ein 14-Bit-Code zugewiesen

Dezimal	Binar	EFM
0	0	1001000100000
1	1	10000100000000
2	10	10010000100000
3	11	10001000100000
4	100	10001000000000
5	101	100010000
6	110	100001000000
7	111	100100000000
8	1000	1001001000000
9	1001	10000001000000
10	1010	10010001000000
11	1011	10001001000000
12	1100	1000001000000
13	1101	1000000
14	1110	100010000000
15	1111	100001000000
16	10000	10000000100000

Codes zur Speicheroptimierung komprimieren Daten

- Ziele der Kompression
 - > Möglichst Kompakte Darstellung
 - > Verlustfreie Codierung (nicht immer)
- Motivation
 - > Codes mit fester Länge (z.B. ASCII) ineffizient
- Lösungsansatz
 - > Kurzer Code für häufig vorkommende Zeichen
 - > Langer Code für seltene Zeichen

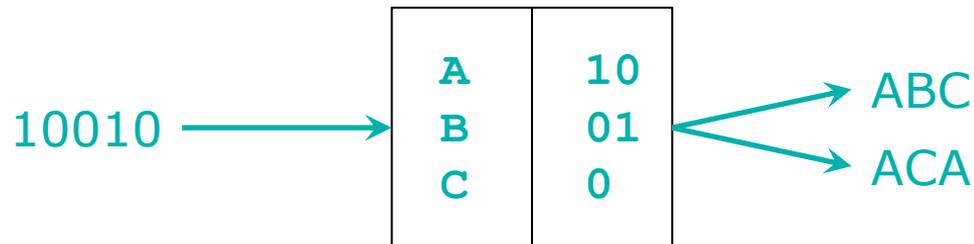


Spezielle Codes

Speicheroptimierung – Präfixfreiheit

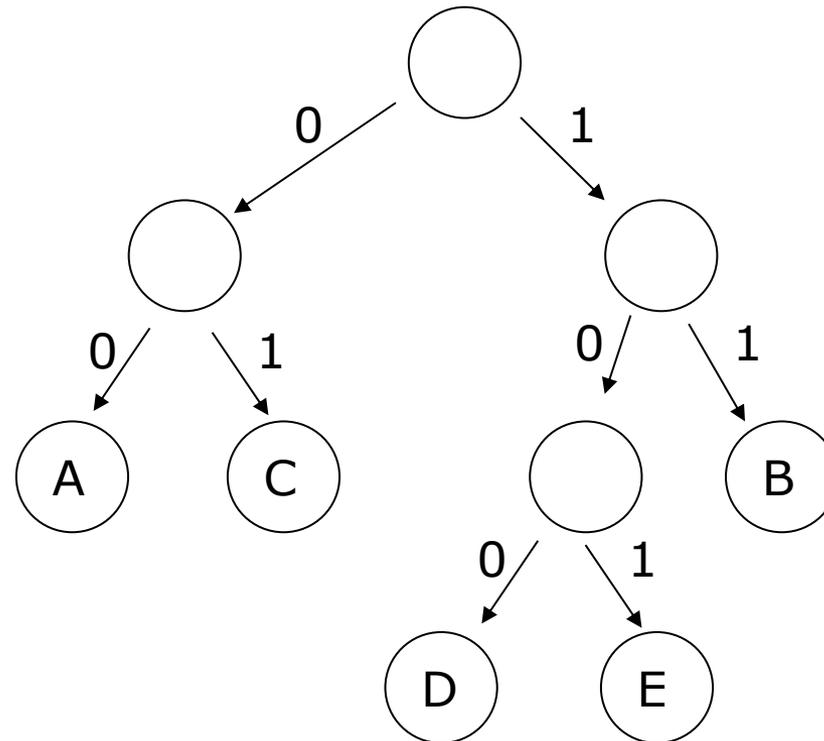
Wenn Codes unterschiedliche Länge haben, müssen diese präfixfrei sein

- Kein Codewort ist der Anfang eines anderen Codewortes
- Beispiel für nicht-präfixfreie Codierung



Spezielle Codes

Speicheroptimierung – Präfixfreiheit



A	B	C	D	E
00	11	01	100	101

Spezielle Codes

Speicheroptimierung – Huffman-Code

Der Huffman-Code ist eine Variante eines präfixfreien Codes

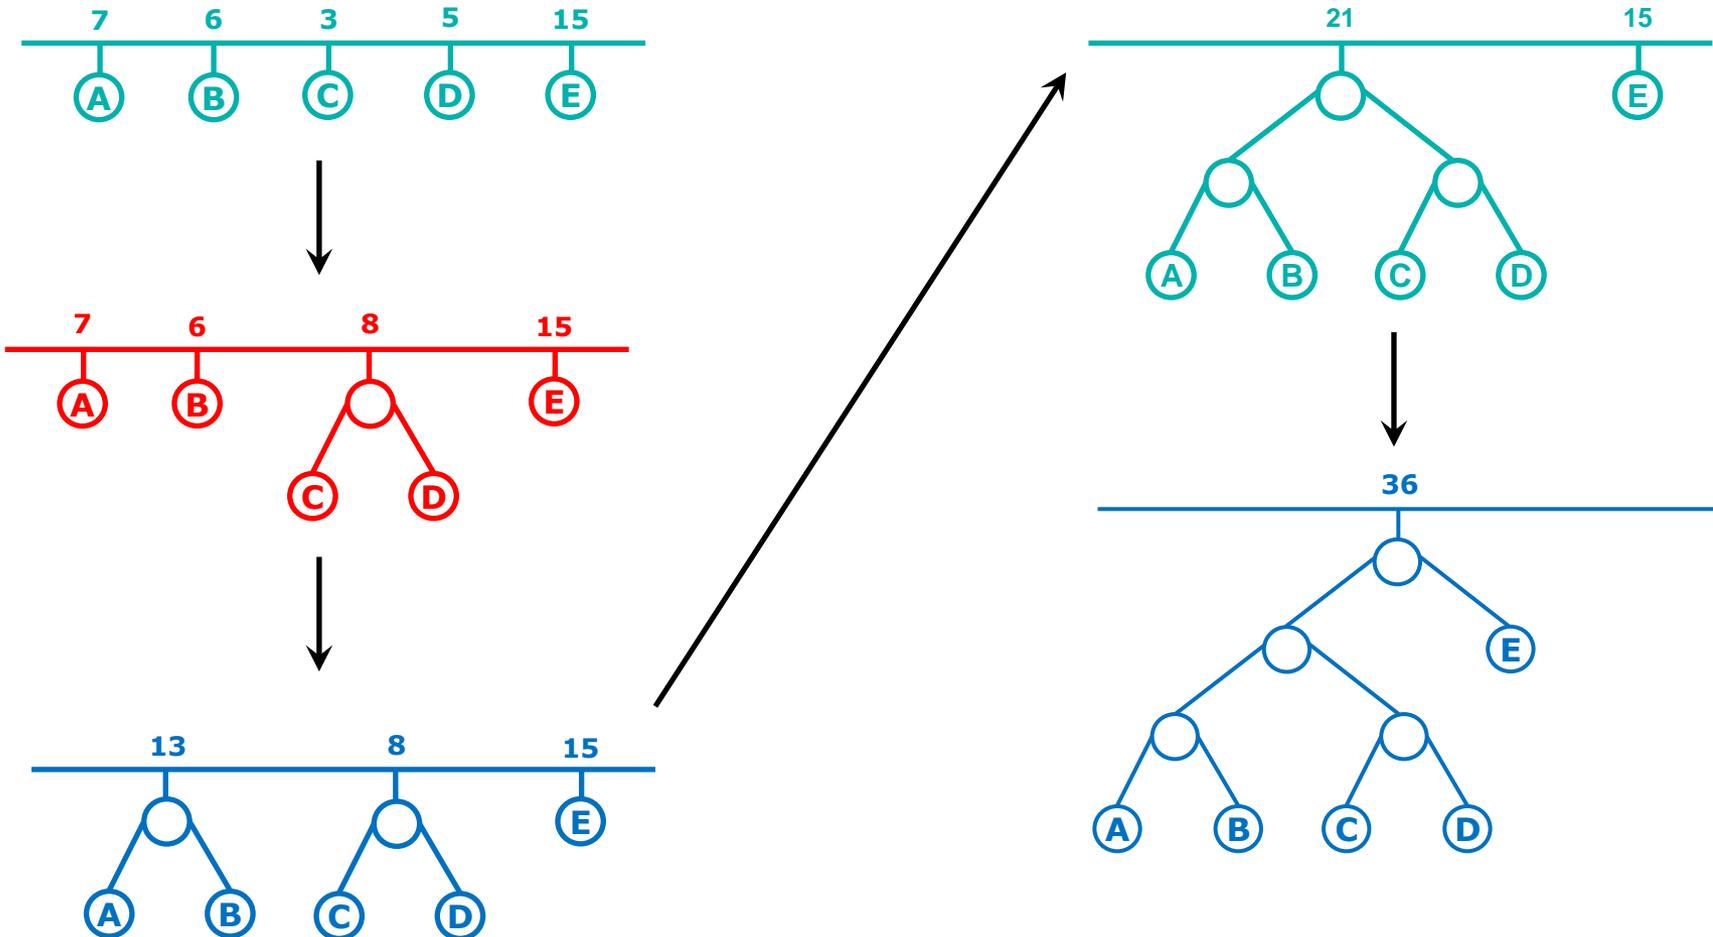
- Eigenschaften
 - > Code möglicherweise für jeden Anwendungsfall anders
 - > Basiert auf den Auftrittswahrscheinlichkeiten eines Zeichens
 - > Die mittlere Codelänge wird minimiert

- Algorithmus
 1. Schreibe Symbole mit Wahrscheinlichkeiten als Wald
 2. Fasse die beiden Bäume mit der geringsten Wahrscheinlichkeit in einem neuen Baum zusammen
 - > Die Wahrscheinlichkeit für den neuen Zweig ergibt sich durch Addition
 3. Wiederhole bis nur noch ein Baum existiert

Spezielle Codes

Speicheroptimierung – Huffman-Code

Beispiel



Spezielle Codes

Übung

Codieren Sie das folgende Wort nach dem Huffman-Code:

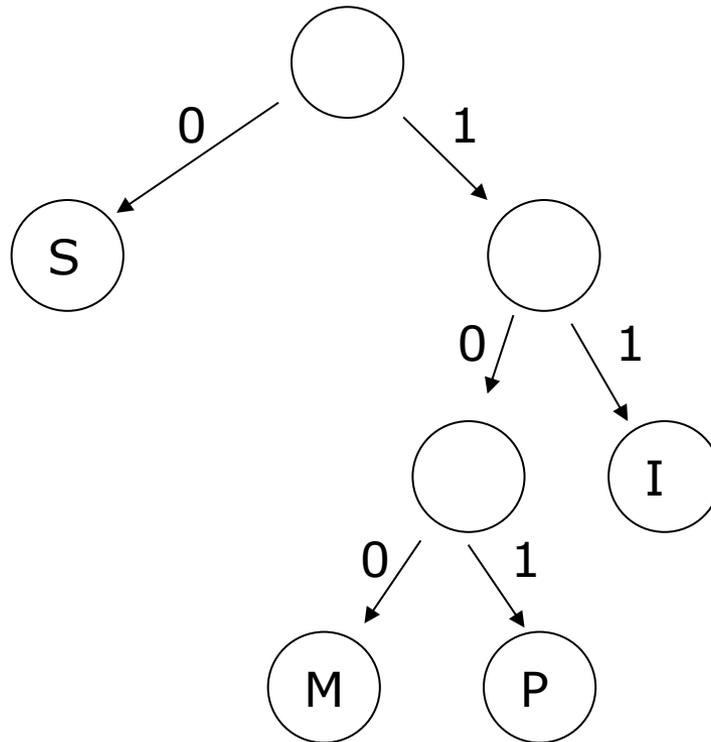
MISSISSIPPI

Spezielle Codes

Übung

Codieren Sie das folgende Wort nach dem Huffman-Code:

MISSISSIPPI



Manche Übertragungsmedien sind fehleranfällig

- Fehler müssen erkannt und im Optimalfall korrigiert werden können
- Lösungsvarianten
 - > Mehrfache Übertragung der Daten
 - > Sehr einfach zu realisieren
 - > Es werden sehr viele Daten übertragen
 - > Prüfsummenverfahren
 - > Es werden zusätzliche Informationen übertragen, die von den zu übertragenden Daten abhängig sind

Spezielle Codes

Robuste Codierung – Prüfsummen

Ein einfaches Prüfsummenverfahren

- Ein einfaches Prüfsummenverfahren ist die sogenannte **Parität**
 - > Die zusätzliche Information bezieht sich auf die Anzahl der zu übertragenden Einsen im Binärcode
 - > Es wird nur ein Bit zusätzlich benötigt: Das **Paritätsbit**
 - > Ist die Anzahl der Einsen ungerade ist das Paritätsbit 1, sonst 0
 - > Es kann allerdings nur **ein** Fehler gefunden und **nicht** korrigiert werden
 - > Beispiel
 - > Binärdaten: 1111 0000
 - > Prüfsumme: 0 (da vier Einsen)

Spezielle Codes

Robuste Codierung – Hamming-Code

Um Fehler besser erkennen und vor allem korrigieren zu können kann der Hamming-Code verwendet werden

- Ein Codewort im Hamming-Code ist immer $N = 2^k - 1$ Bits groß
 - > Davon sind k Bits für die Parität und werden immer an Positionen, deren Nummer eine 2er-Potenzen ist, gesetzt
 - > Die restlichen $n = N - k$ Bits können Informationen enthalten
 - > Beispiel

Bitposition	1	2	3	4	5	6	7
	Parität	Parität	Daten	Parität	Daten	Daten	Daten

Spezielle Codes

Robuste Codierung – Hamming Code

Berechnung der Paritätsbits

- Ein Paritätsbit verknüpft $2^{k-1} - 1$ der Datenbits mit einer XOR-Verknüpfung („die Hälfte der Bits“ = Verknüpfte Datenbits + Paritätsbit)
 - > Das bedeutet, dass die Anzahl der Einsen in der „Hälfte der Bits“ gerade ist
- Welche Datenbits werden in einem Paritätsbit verknüpft?
 - > Alle Bits die eine „1“ im entsprechenden Polynomialcode haben
- Was bedeutet das?
 - > Der Polynomialcode des Paritätsbits an Stelle 2^l besteht aus einer Abfolge von 2^l Einsen, danach folgen 2^l Nullen, danach wieder 2^l Einsen usw.
 - > Der Polynomialcode beginnt erst am zugehörigen Bit, vorher stehen Nullen

Spezielle Codes

Robuste Codierung – Hamming Code

Beispiel für $N = 7$

- 3 Paritätsbits p_n an Stellen 1, 2, 4
- 4 Datenbits d_n an Stellen 3, 5, 6, 7

Bitposition	1	2	3	4	5	6	7
Aufteilung	Parität	Parität	Daten	Parität	Daten	Daten	Daten
Daten	p_1	p_2	0	p_3	1	1	0
Polynomialcode $l=0$	1	0	1	0	1	0	1
Polynomialcode $l=1$	0	1	1	0	0	1	1
Polynomialcode $l=2$	0	0	0	1	1	1	1

- Berechnung der Paritätsbits

- > $p_1 = 0 \oplus 1 \oplus 0 = 1$

- > $p_2 = 0 \oplus 1 \oplus 0 = 1$

- > $p_3 = 1 \oplus 1 \oplus 0 = 0$

Spezielle Codes

Robuste Codierung – Hamming Code

Erkennung von Fehlern

- Zum Erkennen von Fehlern muss der Empfänger einer codierten Nachricht selbst noch einmal die Paritätsbits berechnen
- Anschließend werden die übertragenen Paritätsbits mit den berechneten verglichen
 - > Alle Bits sind gleich
 - > Die Information ist korrekt übertragen worden
 - > Es ist ein Bit unterschiedlich
 - > Das Paritätsbit ist falsch übertragen worden
 - > Es sind zwei oder mehr Bits unterschiedlich
 - > Anhand der Kombinationen aus Datenbits und Paritätsbits kann das defekte Datenbit erkannt werden

Spezielle Codes

Robuste Codierung – Hamming Code

Beispiel für Fehlerkorrektur – 1

Bitposition	1	2	3	4	5	6	7
Aufteilung	Parität	Parität	Daten	Parität	Daten	Daten	Daten
Übertragene Daten	1	1	0	0	1	1	0
Empfangene Daten	1	1	0	0	1	1	1
Berechnete Bits	0	0	-	1	-	-	-
Polynomialcode $l=0$	1	0	1	0	1	0	1
Polynomialcode $l=1$	0	1	1	0	0	1	1
Polynomialcode $l=2$	0	0	0	1	1	1	1

- Berechnung der Paritätsbits

> $p_1 = 0 \oplus 1 \oplus 1 = 0$

> $p_2 = 0 \oplus 1 \oplus 1 = 0$

> $p_3 = 1 \oplus 1 \oplus 1 = 1$

ungleich

ungleich

ungleich

Bit 7 ist fehlerhaft

Spezielle Codes

Robuste Codierung – Hamming Code

Beispiel für Fehlerkorrektur – 2

Bitposition	1	2	3	4	5	6	7
Aufteilung	Parität	Parität	Daten	Parität	Daten	Daten	Daten
Übertragene Daten	1	1	0	0	1	1	0
Empfangene Daten	1	1	0	0	0	1	0
Berechnete Bits	0	1	-	1	-	-	-
Polynomialcode $l=0$	1	0	1	0	1	0	1
Polynomialcode $l=1$	0	1	1	0	0	1	1
Polynomialcode $l=2$	0	0	0	1	1	1	1

- Berechnung der Paritätsbits

> $p_1 = 0 \oplus 0 \oplus 0 = 0$

> $p_2 = 0 \oplus 1 \oplus 0 = 1$

> $p_3 = 0 \oplus 1 \oplus 0 = 1$

ungleich

gleich

ungleich

Bit 5 ist fehlerhaft

Spezielle Codes

Übung

Wie lautet der Hamming-Code zu den 4 Datenbits 1001?

Wo ist der Fehler im Code 1010000?

Wo ist der Fehler im Code 0011000?

Spezielle Codes

Übung

Wie lautet der Hamming-Code zu den 4 Datenbits 1001?

- 0011001

Wo ist der Fehler im Code 1010000?

- Das zweite Paritätsbit ist falsch

Wo ist der Fehler im Code 0011000?

- Das letzte Datenbit ist falsch

4.1 – Formale Sprachen

Syntax, Semantik, Grammatik

Lessons Learned

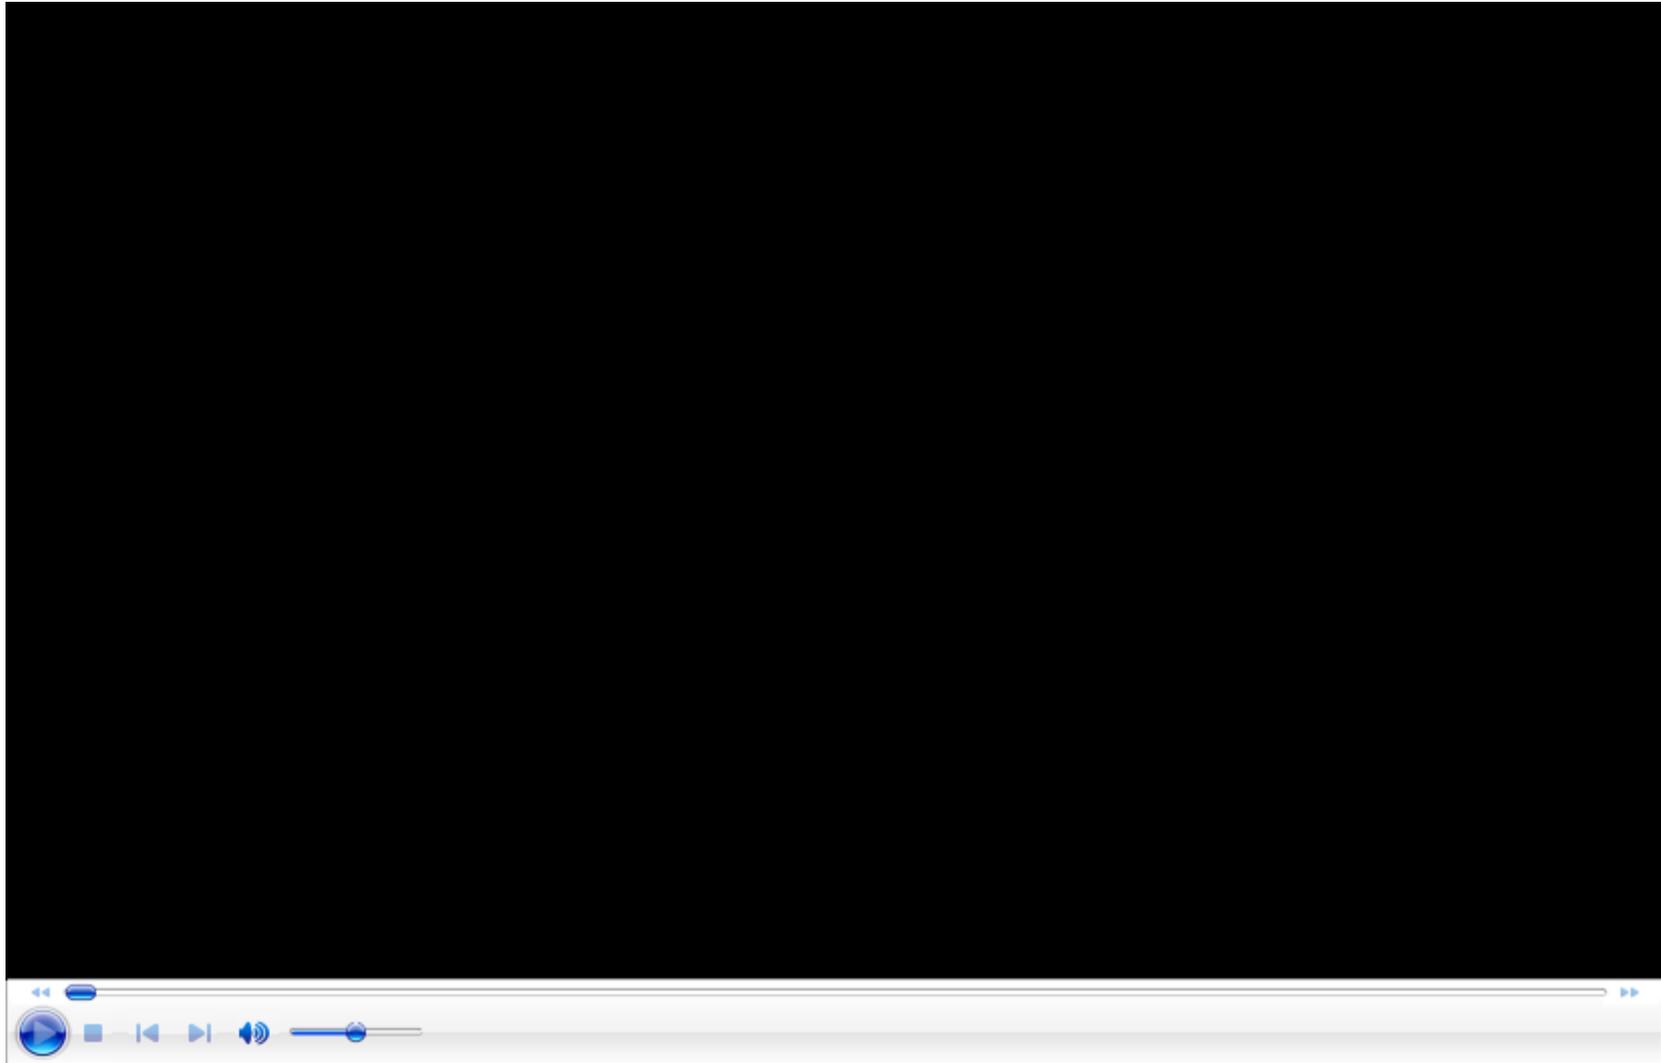
Muss ich mir das alles merken?

In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können

- Aufbau und Anwendung von formalen Grammatiken
- Bezug zu Programmiersprachen

Sprachen

Ein anschauliches Beispiel



Was ist eine Sprache?

Und was hat dieser Da Vinci damit zu tun?

Muttersprache

Fremdsprache
Umgangssprache
Formale Sprache
Bildersprache
Gebärdensprache
Körpersprache
Programmiersprache
Konstruierte Sprache
Lautsprache
Geheimsprache
Weltsprache

Formale Sprachen

Grundlegende Grundlagen

Eine formale Sprache ...

- ... dient nicht zur Kommunikation, sondern zur eindeutigen Darstellung von Informationen
 - > z.B. Programmiersprachen
- ... hat eine **Grammatik**, die den Aufbau der Sprache regelt und deren **Syntax** festlegt
- ... hat ein **Alphabet** erlaubter Zeichen
- ... besteht aus **Worten**, die aus den Zeichen des Alphabets aufgebaut sind

Formale Sprachen

Beispiel einer Grammatik

1. Satz := Subjekt " " Verb " " Präposition
" " Nomen Ende
2. Subjekt := Nomen
3. Nomen := Artikel Substantiv
4. Artikel := "der" | "die" | "das"
5. Substantiv := "mann" | "frau" | "haus"
6. Verb := "geht"
7. Präposition := "in"
8. Ende := "."

Eine Grammatik beschreibt bzw. regelt die Syntax einer formalen Sprache

- **Terminale Symbole**
 - > Elemente aus Zeichen des Alphabets der Sprache
- **Nicht-terminale Symbole**
 - > Symbole, die nach den Syntaxregeln aus anderen Symbolen zusammengesetzt sind
- **Grundidee**
 - > Angabe der terminalen Symbole
 - > Rekursive Definition der nicht-terminalen Symbole

Formale Sprachen

Grammatik –BNF

- Symbole werden durch eine **Zuweisung** [:=] definiert
 - > **Non-terminale Symbole** beziehen sich auf mindestens ein anderes Symbole
 - > **Terminale Symbole** beziehen sich auf kein anderes Symbol
- Verknüpfungen bei einer Zuweisung
 - > Ein Zwischenraum bedeutet „**und**“ und legt die Reihenfolge der Symbole fest
 - > Ein senkrechter Strich [|] bedeutet „**oder**“
- Wiederholungen
 - > Mit { } geklammerte Ausdrücke können beliebig oft wiederholt werden
 - > Mit [] geklammerte Ausdrücke können 0 oder 1 mal auftreten
- Klammerung mit () dient zur logischen Gliederung

Eine Produktion ist eine syntaktisch mögliche Kombination von terminalen Symbolen

- In einer Produktion kommen keine nicht-terminalen Symbole vor
 - > Die Regeln der Grammatik müssen „bis zum Schluss“ angewendet werden
- Beispiel einer Produktion
 - > `der mann geht in das haus.`
 - > `der mann geht in der haus.`
 - > `die frau geht in das mann.`

Die Semantik beschreibt die Bedeutung der Zeichen

- Syntaktisch mögliche Produktionen sind unter Umständen „sinnlos“
 - > Der Grammatik müssen weitere Regeln hinzugefügt werden, damit alle syntaktisch möglichen Produktionen auch einen Sinn ergeben
- Beispiel
 - > In der bekannten Grammatik ist es sinnvoll, dass eine Produktion von **Nomen** nur aus Artikel und Substantiv des gleichen „Geschlechtes“ bestehen darf

```
Nomen           :=      ( wArtikel wSubstantiv ) |  
                   ( mArtikel mSubstantiv )  
  
wArtikel         :=      "die"  
mArtikel         :=      "der"  
wSubstantiv     :=      "frau"  
mSubstantiv     :=      "mann"
```

Formale Sprachen

Beispiel einer Grammatik in BNF

```
Programm := 'PROGRAM' Bezeichner
           'BEGIN'
           { Zuweisung [";"] }
           'END' "." ;
```

```
Bezeichner := Buchstabe { ( Buchstabe | Ziffer ) } ;
```

```
Zahl := [ "-" ] Ziffer { Ziffer } ;
```

```
String := '"' { AlleZeichen } '"' ;
```

```
Zuweisung := Bezeichner "=" ( Zahl |
                                Bezeichner |
                                String ) ;
```

```
Buchstabe := "A" | "B" | "C" | "D" | "E" | "F" | "G"
            | "H" | "I" | "J" | "K" | "L" | "M" | "N"
            | "O" | "P" | "Q" | "R" | "S" | "T" | "U"
            | "V" | "W" | "X" | "Y" | "Z" ;
```

```
Ziffer := "0" | "1" | "2" | "3" | "4" | "5" | "6"
         | "7" | "8" | "9" ;
```

```
AlleZeichen := ? alle sichtbaren Zeichen ? ;
```

Formale Sprachen

Beispiel einer Produktion

```
PROGRAM DEMO1
BEGIN
  A0=3;
  B=45;
  H=-100023;
  C=A;
  D123=B34A;
  ESEL=GIRAFFE;
  TEXTZEILE="Hallo, Welt!";
END.
```

Formale Sprachen

Formale Definition einer Grammatik

Die Grammatik einer Sprache $L(G)$ ist ein 4-Tupel mit:

$$G = \{ N, T, \Sigma, P \}$$

- N = Menge der nicht-terminalen Symbole
- T = Menge der terminalen Symbole
- Σ = Startsymbol
- P = Menge der Produktionen
(die sich aus den Regeln der Syntax und der Semantik ergeben)

Formale Sprachen

Formale Definition einer Grammatik

Anmerkungen

- Die Menge der terminalen und nicht-terminalen Symbole ist disjunkt
- Es gibt nur endlich viele Produktionsregeln
- Das Startsymbol verhindert die Bildung nicht gewollter „Teil-Produktionen“
 - > $\Sigma = \{\text{Satz}\}$ garantiert z.B. vollständige Sätze in der Produktion
- Man sagt eine Grammatik „erzeugt“ die zugehörige Sprache
 - > Das bedeutet, dass alle Produktionen der Sprache der Grammatik gehorchen

Welche Sprache L erzeugt folgende Grammatik ?

$$G = \{ N, T, \Sigma, P \}$$

- $N = \{ X \}$
- $T = \{ a, b \}$
- $\Sigma = \{ X \}$
- $P = \{ X \rightarrow ab, X \rightarrow aXb \}$

L =

Welche Sprache L erzeugt folgende Grammatik ?

$$G = \{ N, T, \Sigma, P \}$$

- $N = \{ X \}$
- $T = \{ a, b \}$
- $\Sigma = \{ X \}$
- $P = \{ X \rightarrow ab, X \rightarrow aXb \}$

$$L = \{ a^n b^n \mid n \in \mathbb{N} \}$$

4.2 – Programmiersprachen

Compiler, Linker & the Rest

Lessons Learned

Muss ich mir das alles merken?

In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können

- Bezug zu formalen Sprachen
- Ablauf der Erstellung von Programmen

Compiler

Wozu das Ganze?

Als Compiler wird ein Programm bezeichnet, das Quellcode in ein lauffähiges Programm überführt

- Ein Compiler übersetzt nach **Bytecode** oder **Maschinsprache**
- Es gibt verschiedene Arten von Compilern
 - > **Ahead-Of-Time** Compiler
 - > „normaler Compiler“
 - > **Just-in-Time** Compiler
 - > wird erst aktiv, wenn ein bestimmter Teil des Programm gebraucht wird
 - > [**Interpreter**]
 - > Führt Quellcode direkt und Schritt für Schritt aus
 - > Kein Compiler im eigentlichen Sinne

Compiler

Ablauf der Kompilierung

Die Kompilierung besteht aus zwei Phasen

- **Analysephase** – Der Code wird analysiert und auf Fehler überprüft
 - > Lexikalische Analyse
 - > Syntaktische Analyse
 - > Semantische Analyse
- **Synthesephase** – Der Programmcode wird erzeugt
 - > Zwischencode-Erzeugung
 - > Programmoptimierung
 - > Codegenerierung

Compiler

Analysephase – Lexikalische Analyse

Die lexikalische Analyse wird vom **lexikalischen Scanner** (kurz: **Lexer**) ausgeführt

- Der Quellcode wird in einzelne Teile, sog. **Tokens**, zerlegt
- Die Tokens werden klassifiziert (Schlüsselwort, Bezeichner, ...)
- Kommentare und überflüssige Whitespaces werden entfernt

Compiler

Analysephase – Syntaktische Analyse

Die syntaktische Analyse wird vom **Parser** ausgeführt

- Die einzelnen Tokens, die der Lexer erzeugt hat, werden in einen Syntaxbaum umgesetzt
- Der Sourcecode wird auf syntaktische Fehler überprüft

Compiler

Analysephase – Semantische Analyse

Bei der semantischen Analyse werden die einzelnen Anweisungen überprüft

- Sind alle Variablen vor dem ersten Zugriff deklariert worden?
- Stimmen Quell- und Zieltyp einer Zuweisung überein?
- Sind alle aufgerufenen Funktionen deklariert?
- ...

Compiler

Analysephase – Beispiel

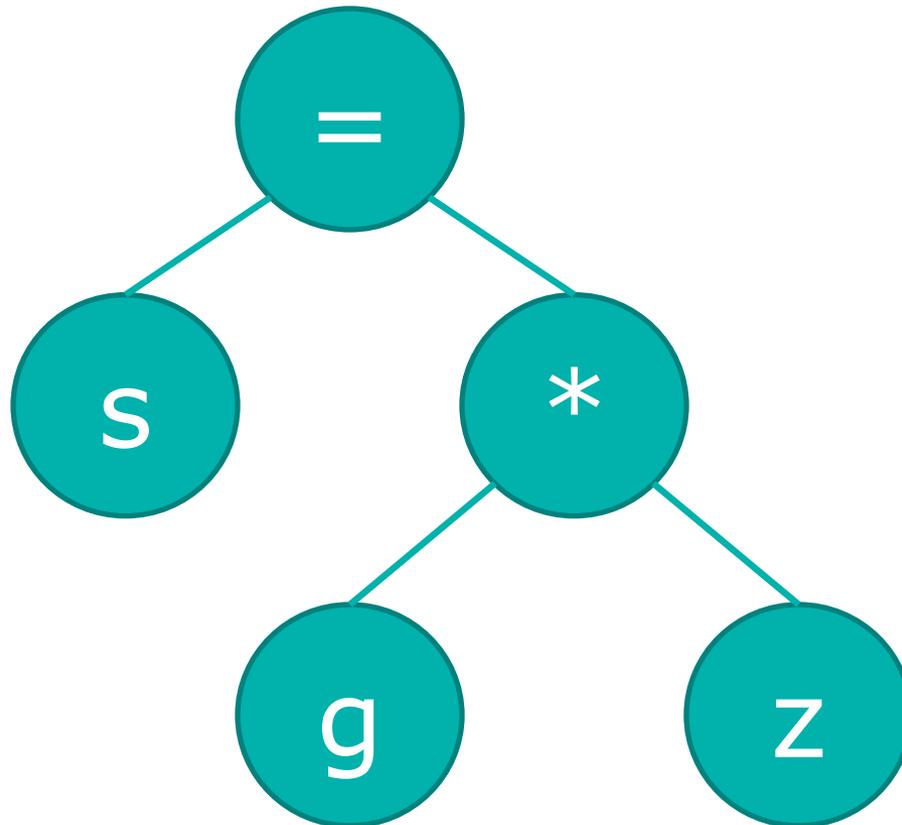
strecke = geschwindigkeit * zeit;

- **Bezeichner** „strecke“
- **Operator** (Zuweisung) „=“
- **Bezeichner** „geschwindigkeit“
- **Operator** (Multiplikation) „*“
- **Bezeichner** „zeit“
- **Trennzeichen** (Befehlsende) „;“

Compiler

Analysephase – Beispiel

`strecke = geschwindigkeit * zeit;`



Die Synthesephase besteht aus ...

- ... **Zwischencode-Erzeugung**
 - > Generiert einen (plattformunabhängigen) Zwischencode
 - > Portabilität, Optimierung einfacher, ...
- ... **Programmoptimierung**
 - > Anpassung an Zielplattform und -hardware
 - > Optimierung der Befehlsstruktur
- ... **Codegenerierung**
 - > Aus dem (optimierten) Zwischencode wird der Programmcode erzeugt
 - > Entweder lauffähiges Programm ...
 - > ... oder Objektdatei (→ Linker)

Compiler

Synthesephase – Programoptimierung

Viele verschiedene Optimierungen möglich

- Einsparung von Maschinenbefehlen
- Umsetzung statischer Formeln
- Elimination von „Dead Code“
- Entfernung unbenutzter Variablen
- Integration von Funktionsaufrufen
- ...

Compiler

Einsparung von Maschinenbefehlen

Dreieckstausch von Variablen

Programmiersprache	Maschinencode	
	Ohne Optimierung	Mit Optimierung
temp = a	a → Register 1 Register 1 → temp	a → Register 1
a = b	b → Register 1 Register 1 → a	b → Register 2 Register 2 → a
b = temp	temp → Register 1 Register 1 → b	Register 1 → b

Compiler

Umsetzung statischer Formeln

Als statische Formeln werden Formeln bezeichnet, welche (mehrere) Konstanten enthalten

- Alle zur Kompilierungszeit bekannten Konstanten werden zusammengefasst, um Operationen zur Laufzeit einzusparen
- „constant folding“

Beispiel

- Vorher

```
> pi = 3.141592653; u = 2 * pi * r;
```
- Nachher

```
> pi = 3.141592653; u = 6.28318531 * r;
```

Compiler

Elimination von „Dead Code“ ...

... und unbenutzten Variablen

- Nicht verwendeter Code kann beim Kompilieren entfernt werden

- Beispiel

- > Vorher

- >

```
int addiere(int a, int b) {  
    int c;  
    return (a + b);  
    c = a + b;  
    return c;  
}
```

- > Nachher

- >

```
int addiere(int a, int b) {  
    return (a + b);  
}
```

Compiler

Integration von Funktionsaufrufen

Bei kleinen Funktionen ist der Aufwand der Adressumsetzung und des Sprungbefehls oft größer, als der Nutzen des strukturierten Codes

- Beispiel

- > Vorher

- ```
> int addiere(int a, int b)
 {
 return a + b;
 }
```

- ```
int c = addiere(3, 4);
```

- > Nachher

- ```
> int c = 3 + 4;
```

# Compiler

## Expertenmeinung

---

### Donald Knuth:

- "We should forget about small efficiencies, say about 97% of the time: premature optimization is the root of all evil"

### Michael A. Jackson

- *"The First Rule of Program Optimization: Don't do it."*
- *"The Second Rule of Program Optimization (for experts only!): Don't do it yet."*

# Linker

## Generelle Informationen

---

### Ein Linker erstellt aus verschiedenen Programmmodulen (Objektdateien) ein lauffähiges Programm

- Die Dateien werden „zusammengebunden“ (gelinkt)
  - > Eigene Objektdateien
  - > Programmbibliotheken
- Umsetzung symbolischer Adressen (Funktionen, Variablen) der verschiedenen Module in Speicheradressen
- Unterscheidung zwischen ...
  - > Statischem Linken
  - > Dynamischem Linken

# Linker

## Statisches Linken

---

### Alle verfügbaren Objektdateien werden zu **einer einzigen**, ausführbaren Programmdatei gelinkt

- Einfacher Austausch von Programmteilen nicht möglich
  - > Bei Änderungen am Programm muss der Linkvorgang jeweils wiederholt werden
- Wird heute nur noch in Mischform mit dynamischem Linken betrieben

# Linker

## Dynamisches Linken

---

### **Funktions- und Variablenadressen werden erst zur Laufzeit des Programms aufgelöst**

- Einfacher Austausch von Programmteilen möglich
- **DLL** (Dynamically Linked Library), Shared Library
- Vorteile
  - > Von mehreren Programmen verwendete DLLs müssen nur einmal im System verfügbar sein
  - > Die fertigen Programm werden kleiner
- Nachteile
  - > Es muss sichergestellt sein, dass die richtige DLL in der richtigen Version vorliegt

# Linker Programmbibliotheken

---

## Als Programmbibliothek wird eine Sammlung von Funktionen bezeichnet

- Oft thematisch zusammenhängend
  - > z.B. Grafikbibliotheken, Mathematikbibliotheken, ...
- Programmbibliotheken sind keine eigenständigen Programme, sondern nur Hilfsmodule
- Unterscheidung zwischen ...
  - > Statischen Bibliotheken (statisches Linken)
  - > Dynamischen Bibliotheken (dynamisches Linken)

## Quellcode wird nicht kompiliert, sondern bei der Programmausführung eingelesen und Schritt für Schritt ausgeführt

- z.B. in Webabwendungen verwendet (PHP, JavaScript, ...)
- Nachteile gegenüber Compilersprachen
  - > Geringere Ausführungsgeschwindigkeit
- Vorteile gegenüber Compilersprachen
  - > Quellcode ist einfach portabel, sofern für die Zielplattform eine Interpreter-Implementierung vorhanden ist
  - > Bei Änderungen des Quellcodes muss nicht das ganze Programm aufwändig neukompiliert werden

# 5 - Rechnerorganisation

---

## Von Neumann Architektur

# Lessons Learned

## Muss ich mir das alles merken?

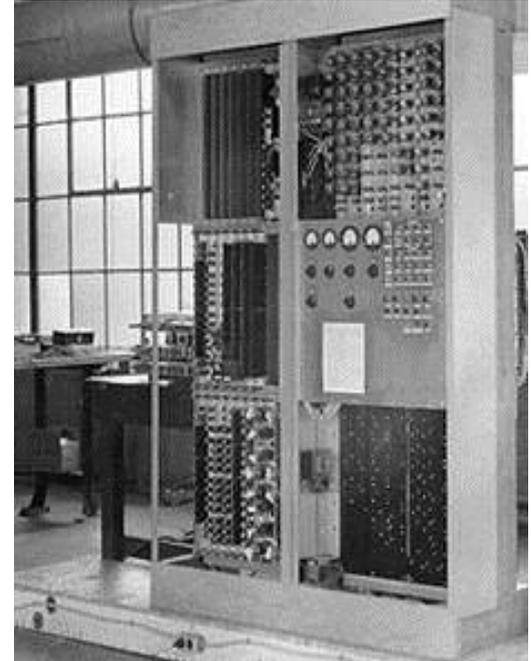
---

**In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können**

- Von Neumann'sches Rechnerkonzept
- Speicherhierarchie zur Befehlsverarbeitung
- Typische Prozessorarchitekturen

# Der von Neumann-Rechner

## EDVAC



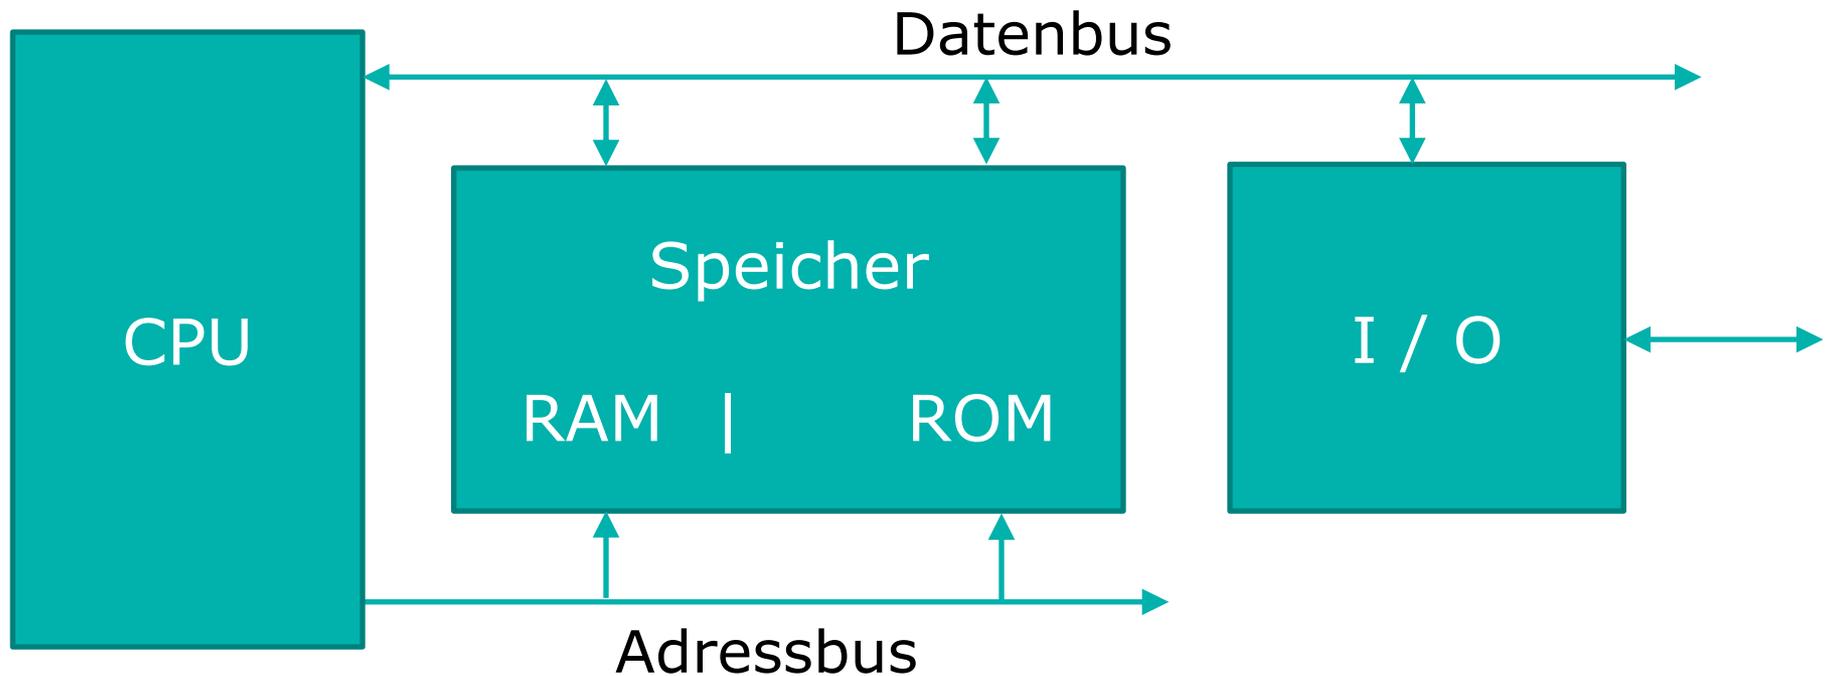
John von Neumann:  
First Draft of a Report on the EDVAC  
(**E**lectronic **D**iscrete **V**ariable **A**utomatic **C**omputer) <sup>1</sup>  
30. 6. 1945

<sup>1</sup> <http://qss.stanford.edu/~godfrey/vonNeumann/vnedvac.pdf>

# Der von Neumann-Rechner

## Komponenten

### Übersicht

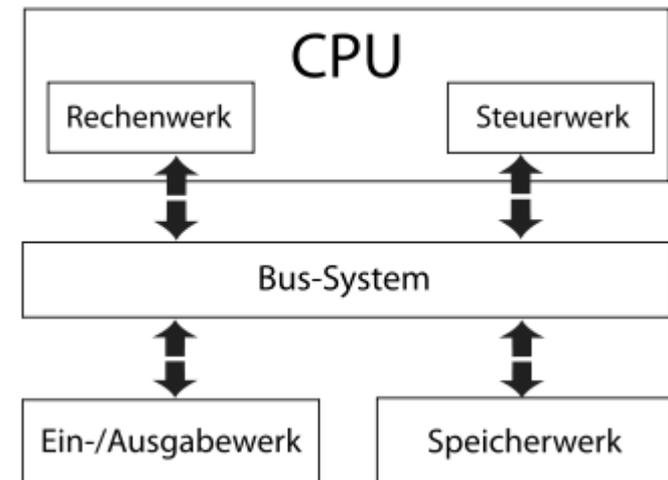


# Der von Neumann-Rechner Komponenten

## Übersicht

- ALU (Arithmetic Logic Unit) – **Rechenwerk**
  - > Führt Rechenoperationen und logische Verknüpfungen durch.
- Control Unit – **Steuerwerk** oder **Leitwerk**
  - > Interpretiert Anweisungen eines Programms
  - > Verschaltet Daten und notwendige ALU-Komponenten
- Memory – **Speicherwerk**
  - > Speichert Programme und Daten, RAM (Rnd. Access Mem.), ROM (Read-Only Mem.)
- Bus – **Datenleitung**
  - > Datenbus und Adressbus
- I/O Unit – **Eingabe-/Ausgabewerk**
  - > Steuert Ein- und Ausgabe von Daten

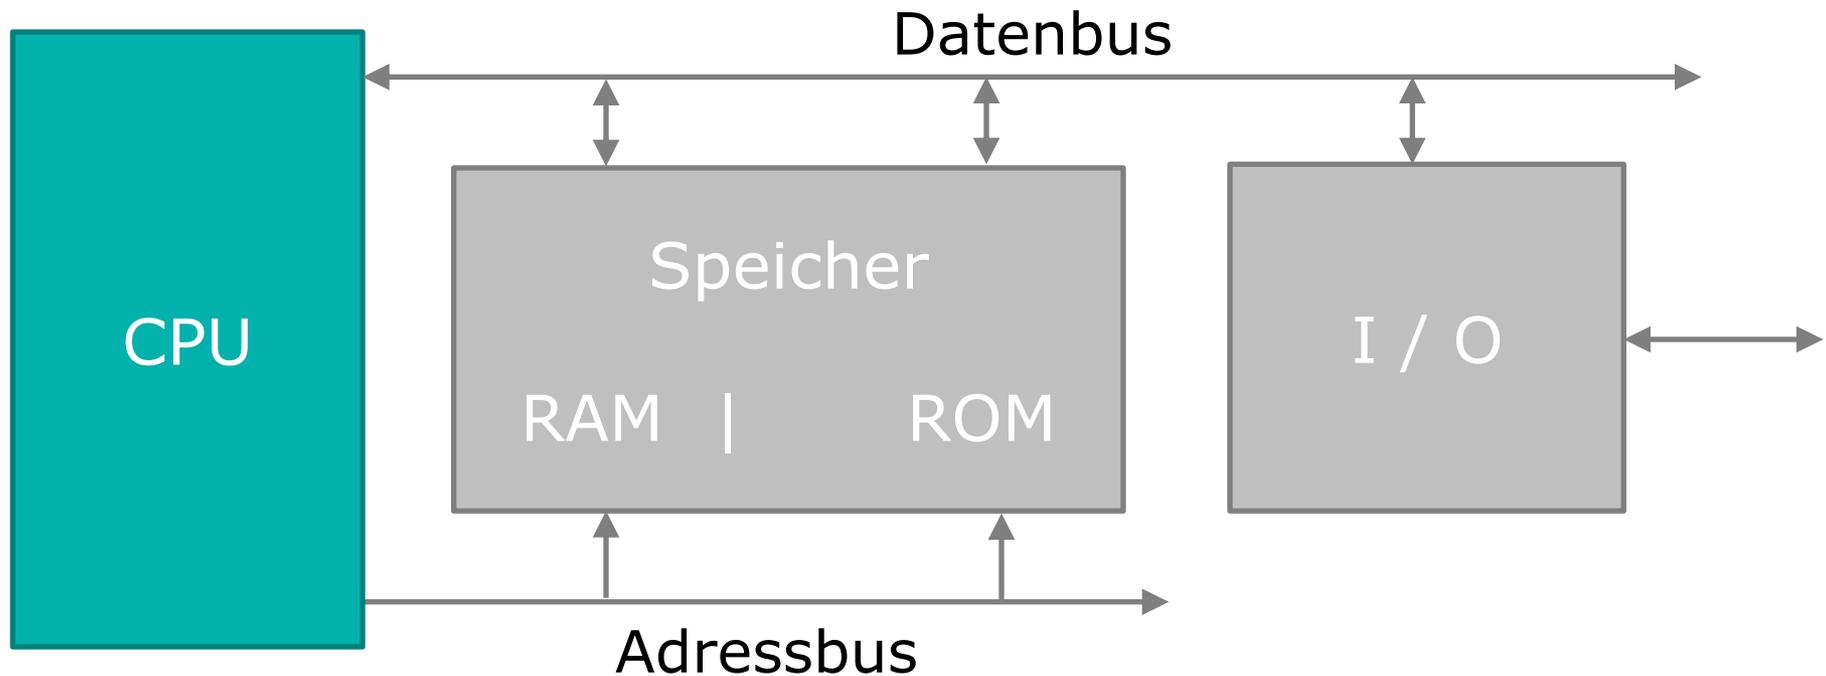
CPU



# Der von Neumann-Rechner

## Komponenten – CPU

### Übersicht

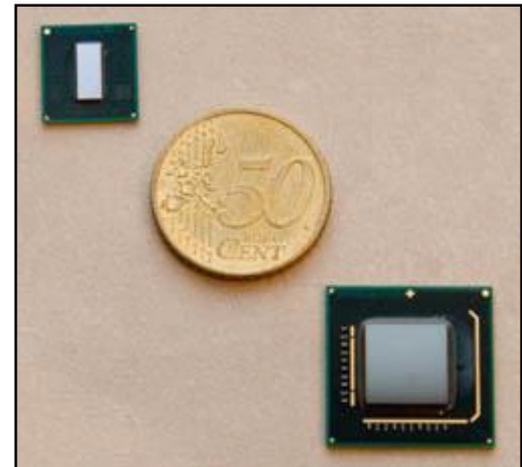
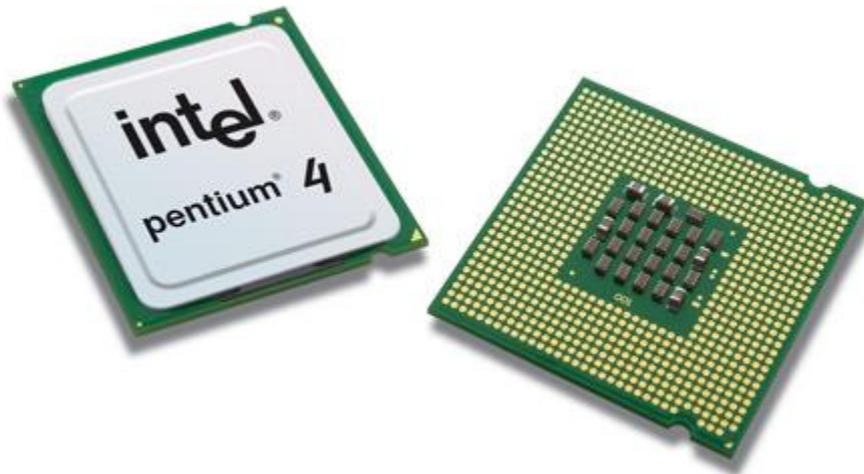


# Der von Neumann-Rechner

## CPU

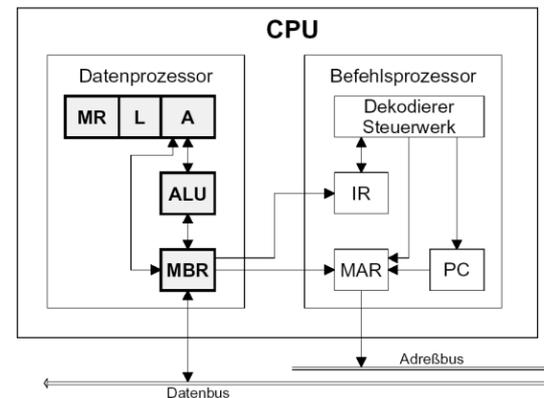
## Die CPU (Central Processing Unit)

- Auch **Prozessor** genannt
- Besteht aus Leitwerk und Rechenwerk
- Beispiel: Intel Pentium 4, Intel Atom, AMD Phenom, ...



## Rechenwerk (Datenprozessor)

- Ausführung von arithmetischen und logischen Operationen **(ALU)**
- Zwischenspeicherung mittels Registern:
  - Akkumulator-Register **(A)**
  - Operanden-Register **(MBR)**
  - Übertrags-Register **(L)**



**ALU** (Arithmetic Logic Unit): führt die Rechenoperationen durch

**A** (Akkumulator): dient zur Aufnahme von Operanden

**L** (Link Register): z.B. zur Aufnahme eines Additionsübertrags

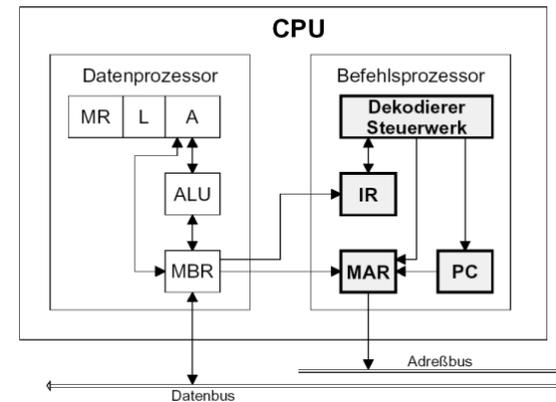
**MR** (Multiplikator Register): z.B. zur Aufnahme von Multiplikationsergebnissen

**MBR** (Memory Buffer Register): dient zur Kommunikation mit dem Speicher

# Der von Neumann-Rechner CPU

## Leitwerk (Befehlsprozessor)

- Überwachung der Programm durchführung, also der im gespeicherten Programm festgelegten Arbeitsanweisungen
- Adresse des ersten Befehls in den Befehls- Zähler laden (**PC**)
  - Leitwerk holt den Befehl in das Befehls-Register (**IR**)
  - Befehls- Zähler (PC) um 1 erhöht.
  - Ausführung des Befehls
  - Weiter bei 2.



**IR** (Instruction Register): enthält den jeweils aktuell bearbeiteten Befehl

**MAR** (Memory Address Register): enthält die Adresse des als nächsten anzusprechenden Speicherplatzes

**PC** (Program Counter): beinhaltet die Adresse des nächsten auszuführenden Befehls

**Dekodierer/Steuerwerk**: Dekodierung von Befehlen und Steuerung der Ausführung

# Der von Neumann-Rechner CPU

## Leitwerk

- Befehlsarten
  - > Arithmetische Befehle (Grundrechenarten)
  - > Logische Befehle (Vergleichsoperationen, ...)
  - > Transferbefehle (Speicherung, ...)
  - > Steuerbefehle (Sprungbefehle, ...)
  - > ...
- Befehlsaufbau
  - > Jeder Befehle besteht aus zwei Abschnitten:
    - > Operationsteil (Welcher Befehl?)
    - > Argumente (Womit, Wohin, ...?)

## Befehlsabarbeitung im Leitwerk

- Jeder Befehl durchläuft drei Komponenten des Leitwerks
  - > **Befehlsregister** (*fetch cycle*)
    - > Der Befehl wird in das Befehlsregister des Steuerwerks geladen
  - > **Dekodierer** (*decode cycle*)
    - > Der Befehl wird dekodiert und der Befehlszähler neu gesetzt
  - > **Steuerwerk** (*execute cycle*)
    - > Der Befehl wird ausgeführt

# Der von Neumann-Rechner

## CPU-Typen

## Es gibt zwei grundsätzliche Typen von CPUs

- **CISC** (Complex Instruction Set Computer)
  - > Komplexe Befehle, Bsp. Division
  - > Befehlssatz meist in Form von Microcode
  - > Wenig Register, Bsp. x86 (9 Register)
  
- **RISC** (Reduced Instruction Set Computer)
  - > Verzichtet auf komplexe Befehle
  - > Einzelnen Befehle sind fest verdrahtet
  - > Viele Register, Bsp. PowerPC (32 GPR Register, Playstation, Lockheed Martin F-22)

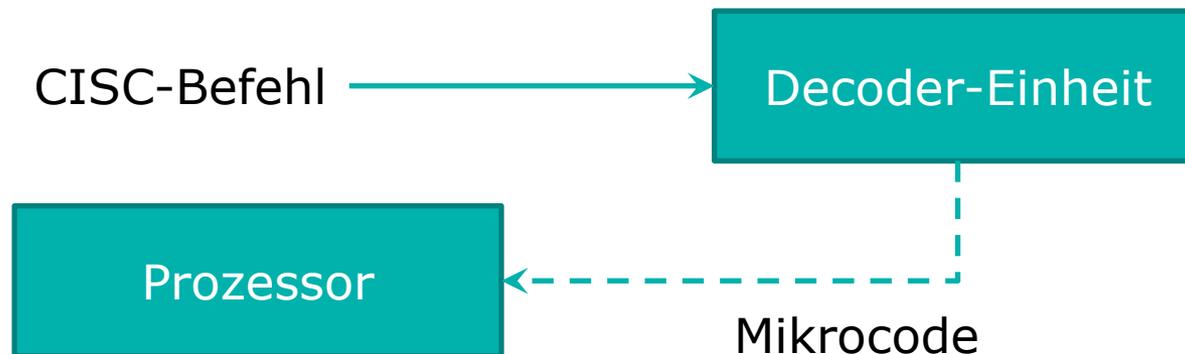


# Der von Neumann-Rechner

## CISC CPUs

### Eine CISC CPU hat folgende Eigenschaften

- Die CPU stellt eine große Anzahl zum Teil sehr komplexer Befehle zur Verfügung
- Die Abarbeitungszeit verschiedener Befehle ist unterschiedlich lang
- Die Befehle haben unterschiedliche „Größen“ (Speicherplatz)
- CISC-CPU's sind mikroprogrammiert



# Der von Neumann-Rechner

## CISC CPUs

---

### Argumente...

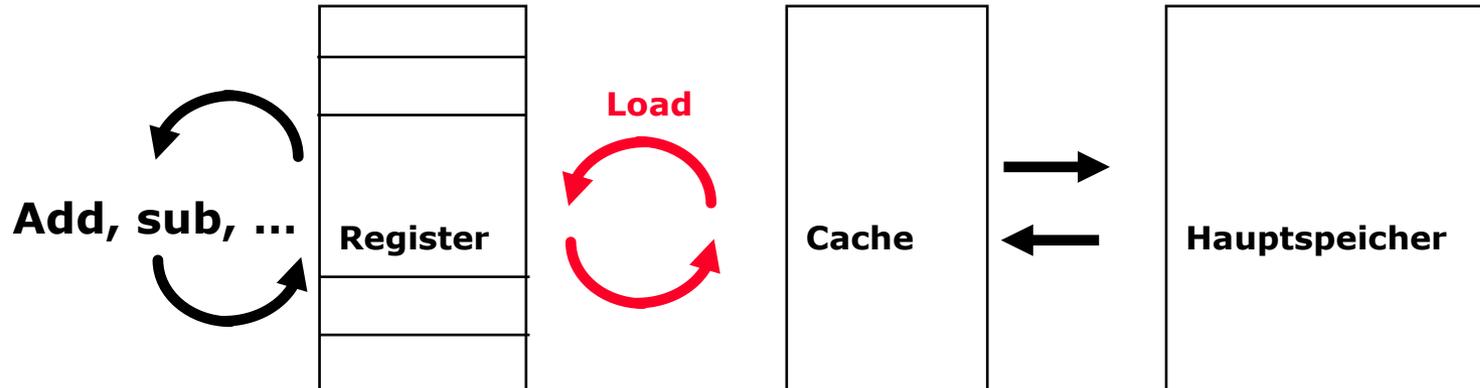
- ... für CISC
  - > Komplexe Befehle verringern den Hauptspeicherbedarf für Programmcode
  - > Komplexe Befehle vereinfachen den Compiler
- ... gegen CISC
  - > Die komplexen Befehle, die eigentlich die Compiler vereinfachen sollen, werden kaum von den Compilern benutzt
  - > Caching verringert die Anzahl der Hauptspeicherzugriffe ebenfalls effizient

# Der von Neumann-Rechner

## RISC CPUs

### Eine RISC CPU hat folgende Eigenschaften

- Die CPU stellt wenige, elementare Funktionen zur Verfügung
- Alle Befehle haben die gleiche „Größe“
- Dekodieraufwand kleiner
- Befehle sind „fest verdrahtet“



# Der von Neumann-Rechner

## RISC CPUs

**Nach D. Tabak ("RISC Architecture", 1995) müssen mindestens 5 der folgenden Kriterien erfüllt sein, damit eine RISC-Architektur vorliegt**

- Kriterien für RISC CPUs:
  - > Mindestens 80% der Befehle werden in einem Taktzyklus ausgeführt
  - > Alle Befehle werden mit einem Maschinenwort codiert
  - > weniger als 128 Maschinenbefehle
  - > weniger als 4 Adressierungsarten
  - > weniger als 4 Befehlsformate
  - > Speicherzugriffe nur über Load/Store-Befehle
  - > Register-Register Architektur (ALU)
  - > mehr als 32 Prozessorregister
  - > festverdrahtete Maschinenbefehle (keine Mikroprogrammierung)
  - > höhere Programmiersprachen werden durch optimierende Compiler unterstützt

# Der von Neumann-Rechner

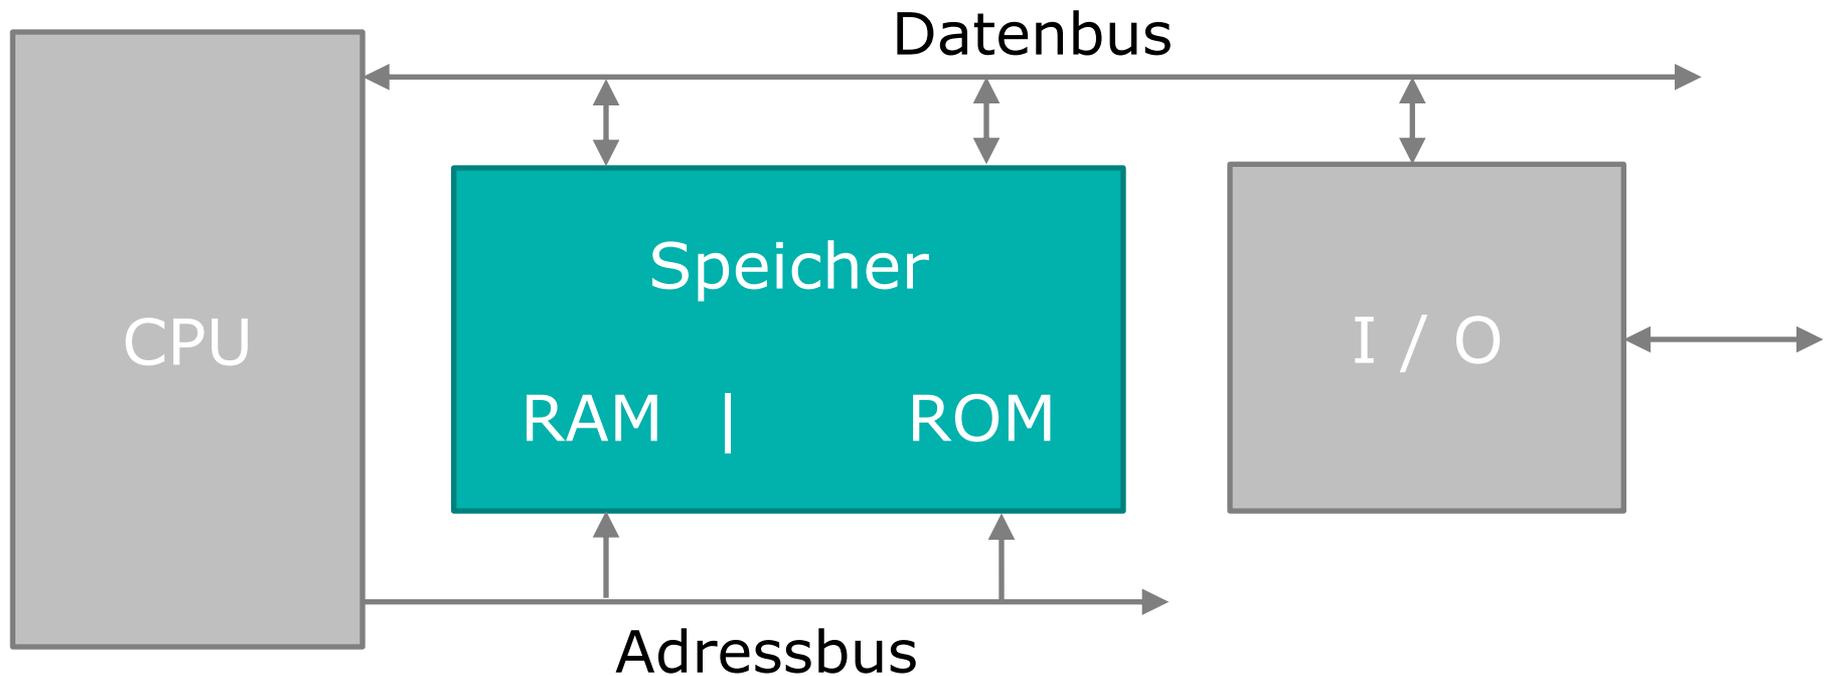
## RISC vs. CISC

|                                        | RISC                                          | CISC                     |
|----------------------------------------|-----------------------------------------------|--------------------------|
| <b>Ausführungszeit</b>                 | 1 Datenpfadzyklus<br>(fetch, decode, execute) | ≥ 1 Datenpfadzyklus      |
| <b>Instruktionsanzahl</b>              | Klein                                         | Groß                     |
| <b>Instruktionsformat</b>              | Einfach / einheitlich                         | Variabel                 |
| <b>Steuerung über...</b>               | Hardware                                      | Mikroprogramm            |
| <b>Hauptspeicherzugriffe</b>           | LOAD/STORE-Architektur                        | Keine<br>Einschränkungen |
| <b>Pipelining</b>                      | Möglich                                       | Nicht möglich            |
| <b>Verlagerung der<br/>Komplexität</b> | Compiler                                      | Hardware                 |

# Der von Neumann-Rechner

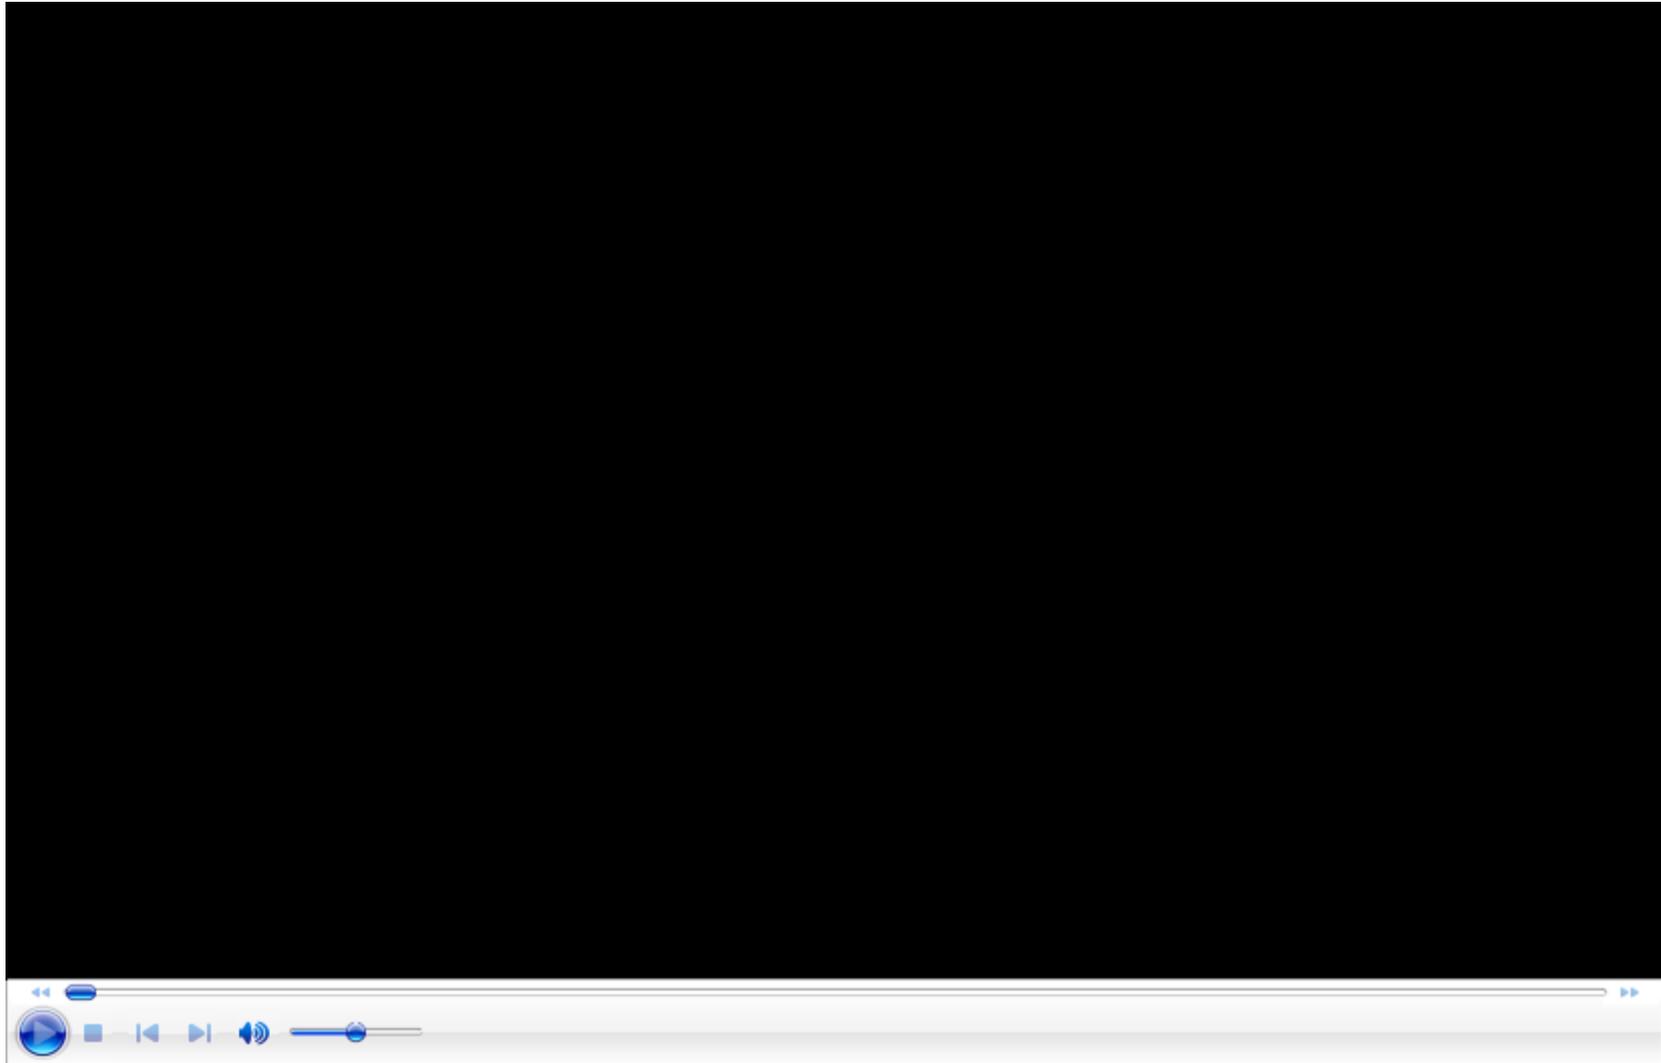
## Komponenten – Speicher

### Übersicht



# Speicher

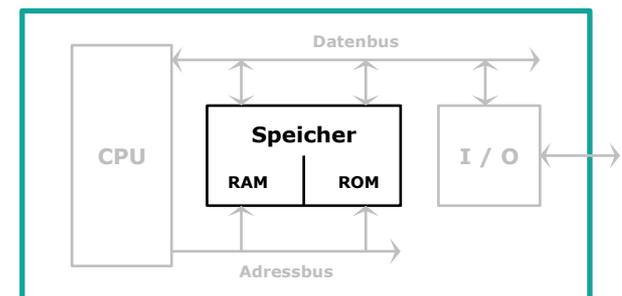
## Ein anschauliches Beispiel



# Der von Neumann-Rechner Speicher

## Es gibt im Wesentlichen zwei Arten von Speicher

- ROM (Read Only Memory)
  - > Festwertspeicher
    - > Daten fest eingebrannt, nicht mehr veränderbar
  - > Es gibt mehrere Arten
    - > ROM, PROM, EPROM, EEPROM
- RAM (Random Access Memory)
  - > Speicher mit wahlfreiem Zugriff
    - > Speichert Befehle **und** Daten
  - > Es gibt zwei verschiedene Arten
    - > SRAM (Static RAM)
    - > DRAM (Dynamic RAM)

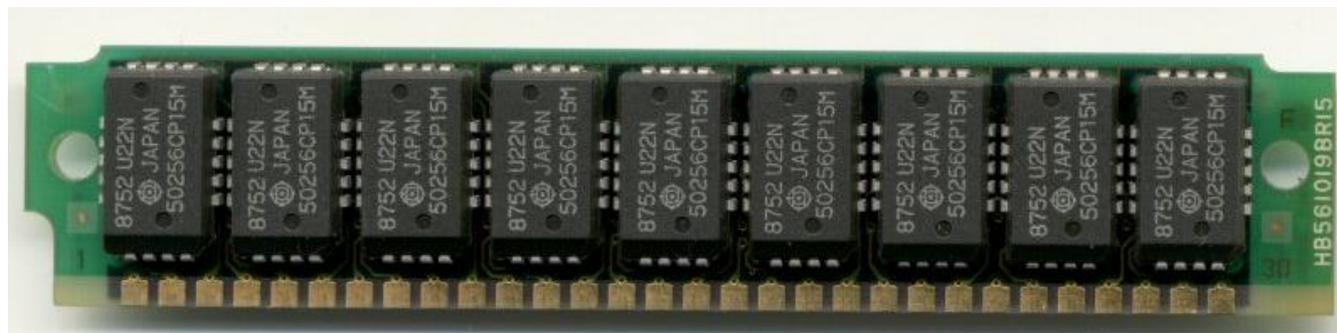


# Der von Neumann-Rechner

## Speicher – RAM

RAM ist ein **flüchtiger** Speicher, der bei der Abschaltung der Betriebsspannung verloren geht

- Im RAM liegen Informationen, die ein Programm **während der Laufzeit** braucht
  - > Soll eine Information über das Ende des Programms hinaus gespeichert werden, muss sie auf der Festplatte (o.Ä.) gespeichert werden
- Der RAM besteht aus gleichartigen Speicherplätzen, die jeweils eine **Adresse** haben



Single Inline Memory Modul (SIMM)

# Der von Neumann-Rechner

## Speicher – DRAM vs. SRAM

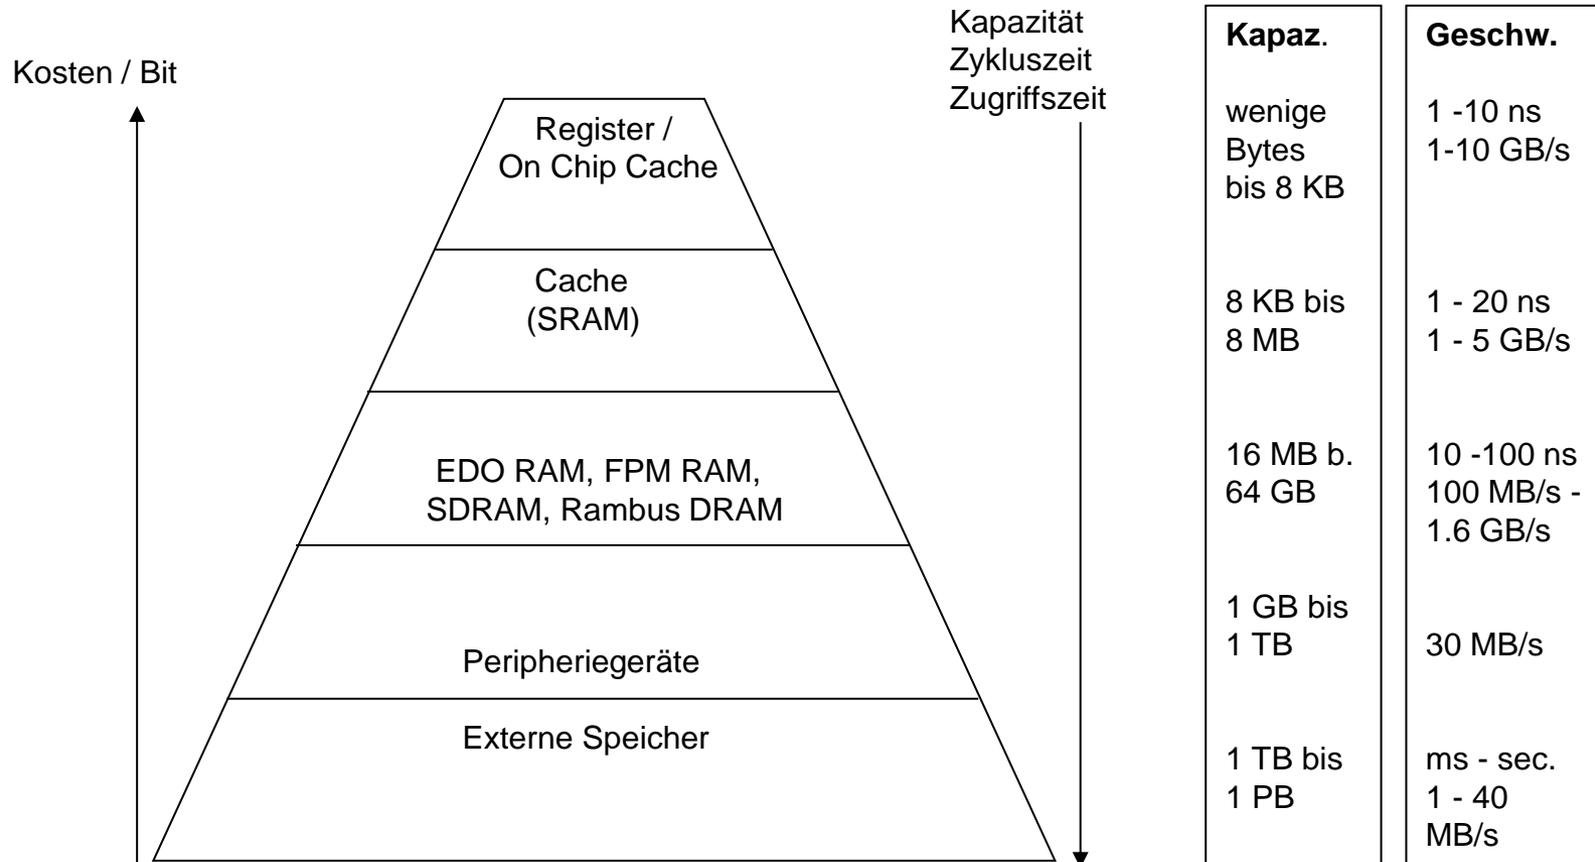
### Es gibt zwei verschiedene Arten von RAM in einem Computer

- Der Hauptspeicher eines Computers ist aus **DRAM** aufgebaut
  - > Der Inhalt von DRAM-Modulen ist **flüchtig** (volatil)
    - > Die Information muss ständig aufgefrischt werden
      - > Auch nach dem Auslesen der Information
- Der Cache eines Computers ist aus SRAM aufgebaut
  - > Der Inhalt von SRAM-Modulen ist **nicht flüchtig**

**SRAM** ist **schneller** aber **teurer** und **größer**  
**DRAM** ist **langsamer** aber **billiger** und **kleiner**

# Der von Neumann-Rechner

## Speicher – Hierarchie



# Der von Neumann-Rechner

## Expertenmeinung

---

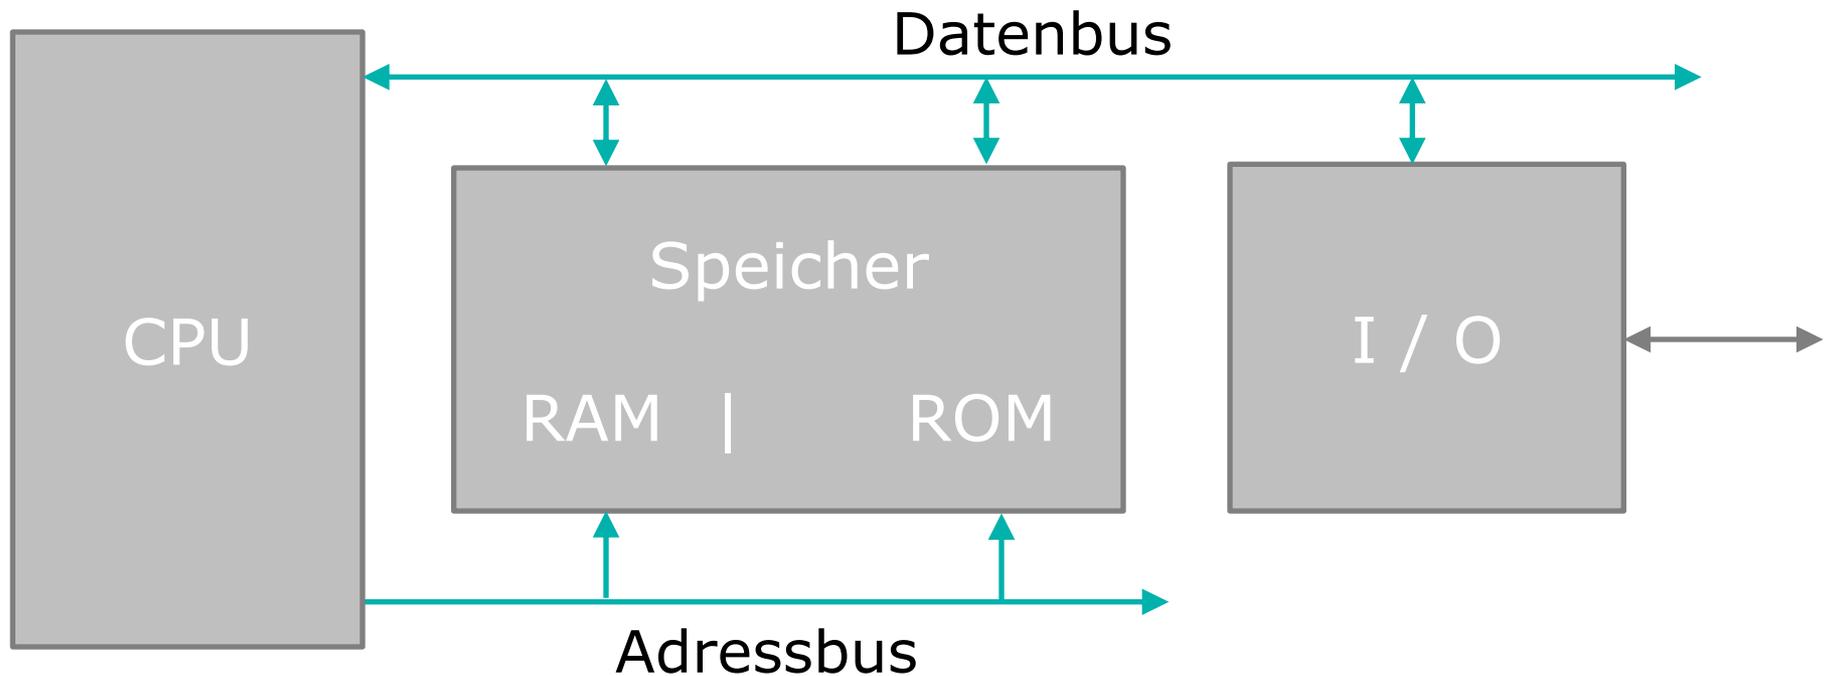
**„640 KBytes [Arbeitsspeicher]  
sollten für jeden genug sein...“**

*(Bill Gates, 1981)*

# Der von Neumann-Rechner

## Komponenten – Busse

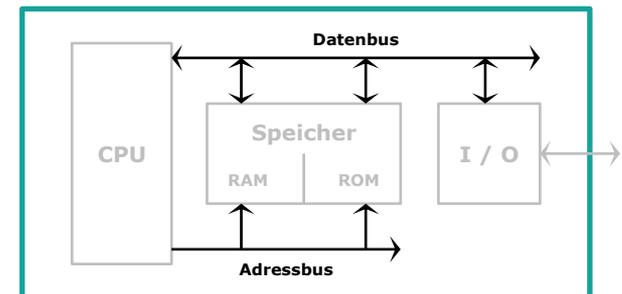
### Übersicht



# Der von Neumann-Rechner Busse

## Busse ermöglichen die Kommunikation zwischen Speicher, CPU und I/O-Einheit

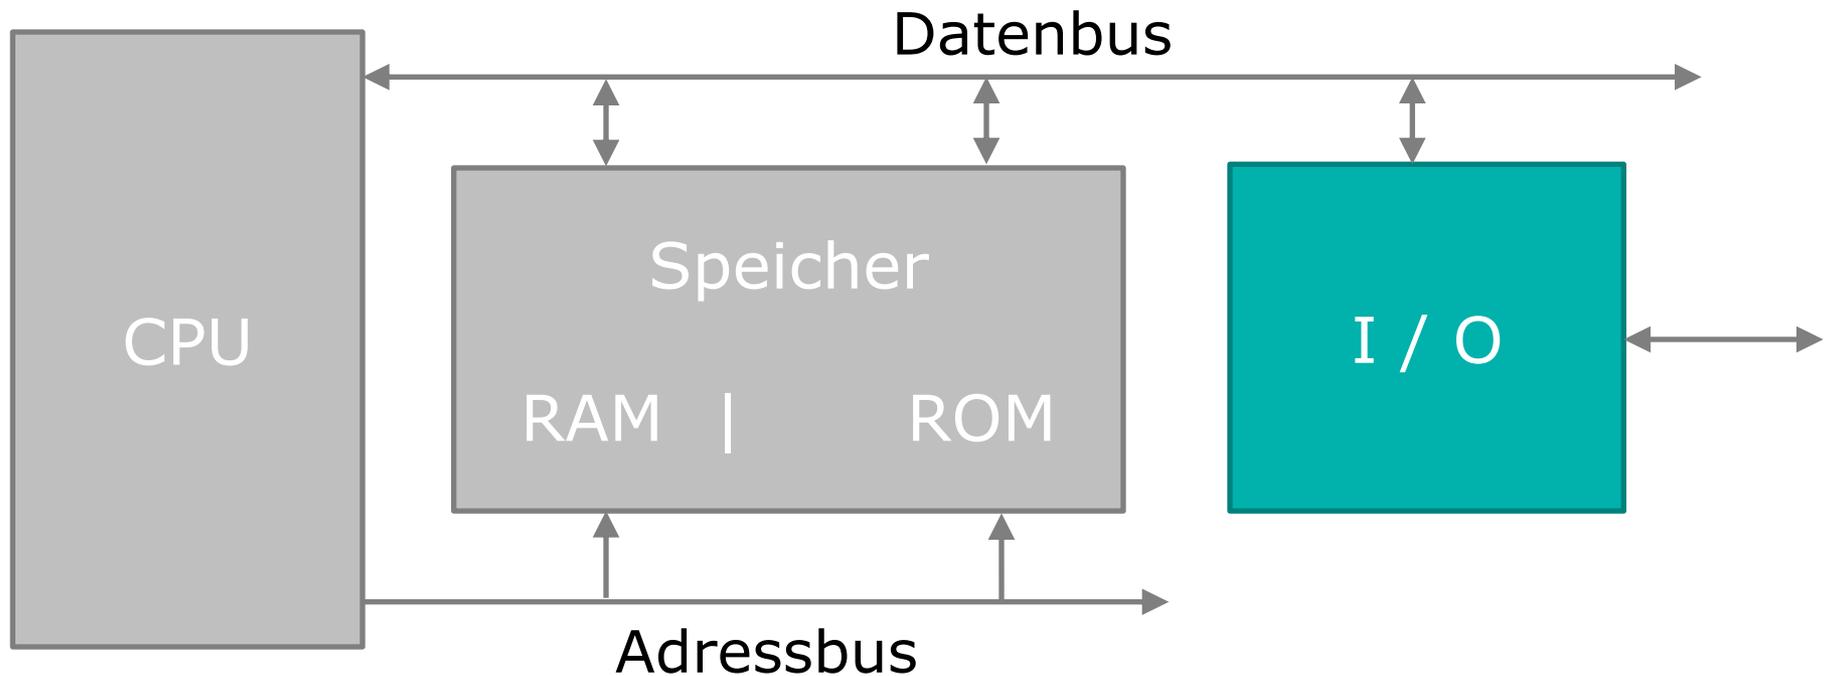
- Man unterscheidet zwischen **Daten-** und **Adressbus**
  - > Der Datenbus ist **bidirektional**
  - > Der Adressbus ist **unidirektional**



# Der von Neumann-Rechner

## Komponenten – I / O

### Übersicht



# Der von Neumann-Rechner

## Eigenschaften

---

## Der Von-Neumann-Flaschenhals

- Vorüberlegungen
  - > Die Ausführungszeit eines Befehls ist meistens sehr kurz
  - > Die Zugriffszeit auf den Speicher ist im Vergleich sehr lang
- Die CPU wartet, während Dinge aus dem Speicher geladen oder in den Speicher geschrieben werden
  - > Die Ausführungszeit eines Programms hängt (auch) von der Anzahl der Speicherzugriffe ab
  - > Es gibt viele Ideen und Strategien, um Teilbereich zu parallelisieren bzw. zu beschleunigen

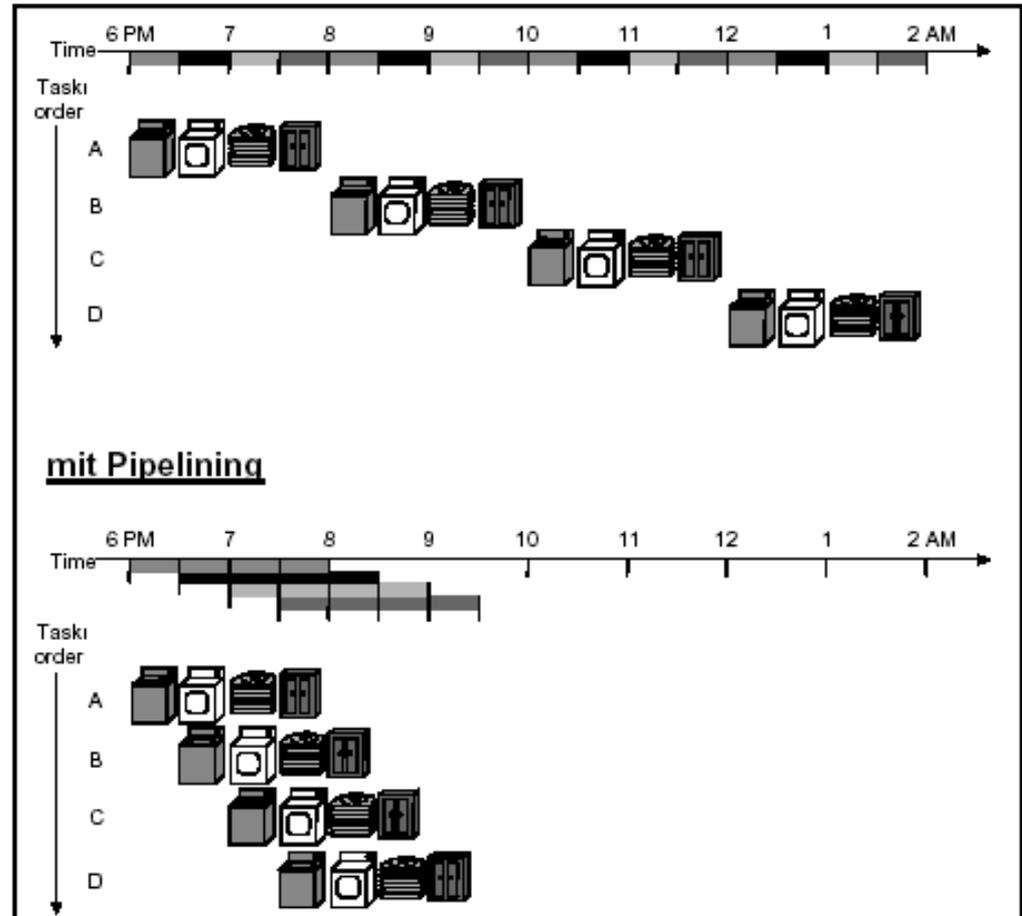
# Der von Neumann-Rechner Pipelining

## Idee: „Never waste time“

- Sie kommen aus dem Urlaub und es ist viel schmutzige Wäsche zu waschen!
- Zur Verfügung stehen:
  - > Eine Waschmaschine (0.5 Std. Laufzeit)
  - > Ein Trockner (0.5 Std. Laufzeit)
  - > Eine Bügelmaschine (0.5 Std. Arbeit zum Bügeln)
  - > Ein Wäscheschrank (0.5 Std. Arbeit zum Einräumen)
- Jede Person (A, B, C, D) wäscht seine Wäsche selbst.

# Der von Neumann-Rechner Pipelining

**Dauer: 8 Stunden**



**Dauer: 3,5 Stunden**

# Der von Neumann-Rechner

## Pipelining

### Pipelining ist nur auf RISC-Architekturen möglich

- Die Befehlsausführung funktioniert immer nach demselben Prinzip
- Es gibt unabhängige Teile einer Befehlsausführung
  - > Diese können parallelisiert werden
  - > Diese benutzen im Allgemeinen unabhängige Hardwarekomponenten

### • Beispiel

#### > 5 Stage Pipeline

- > Instruction Fetch (**IF**): Befehl lesen
- > Instruction Decode (**ID**): Befehl decodieren
- > Execute (**EX**): Ausführen
- > Memory Access (**MEM**): Speicherzugriff
- > Writeback (**WB**): Ergebnis schreiben

| Instr. No.         | Pipeline Stage |          |          |          |          |          |
|--------------------|----------------|----------|----------|----------|----------|----------|
|                    | IF             | ID       | EX       | MEM      | WB       |          |
| 1                  | IF             | ID       | EX       | MEM      | WB       |          |
| 2                  |                | IF       | ID       | EX       | MEM      | WB       |
| 3                  |                |          | IF       | ID       | EX       | MEM      |
| 4                  |                |          |          | IF       | ID       | EX       |
| 5                  |                |          |          |          | IF       | ID       |
| <b>Clock Cycle</b> | <b>1</b>       | <b>2</b> | <b>3</b> | <b>4</b> | <b>5</b> | <b>6</b> |

# Der von Neumann-Rechner

## Pipelining – Hazards

---

### **Hazards sind Situationen, in denen die Abarbeitung einer Pipeline unterbrochen werden muss**

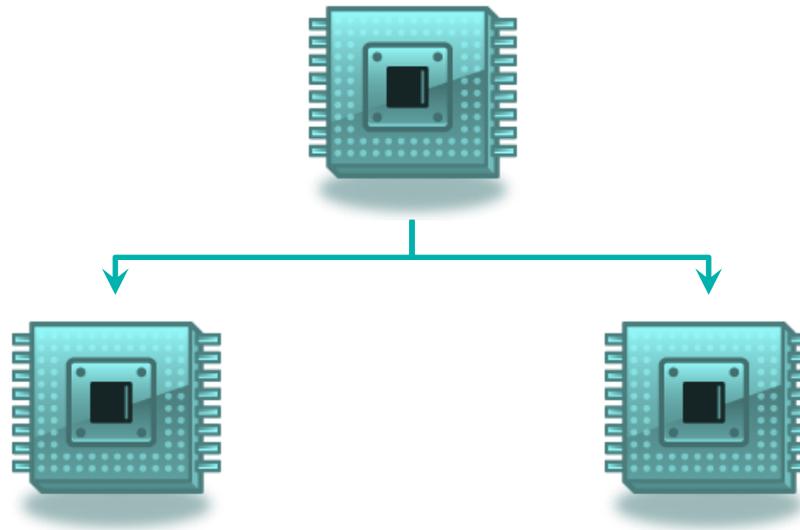
- Structural-Hazards
  - > Instruktionen benötigen dieselbe Hardware und können nicht überlappend ausgeführt werden
- Data-Hazards
  - > Datenabhängigkeiten zwischen aufeinander folgenden Instruktionen
- Control-Hazards
  - > Änderungen der sequentiellen Abarbeitung von Befehlsfolgen durch bedingte Sprünge

# Der von Neumann-Rechner

## Pipelining – Hazards

### Structural-Hazards

- Problem
  - > Instruktionen benötigen dieselbe Hardware
- Lösung
  - > Vermeidung typischerweise durch Replizieren der Hardware



# Der von Neumann-Rechner

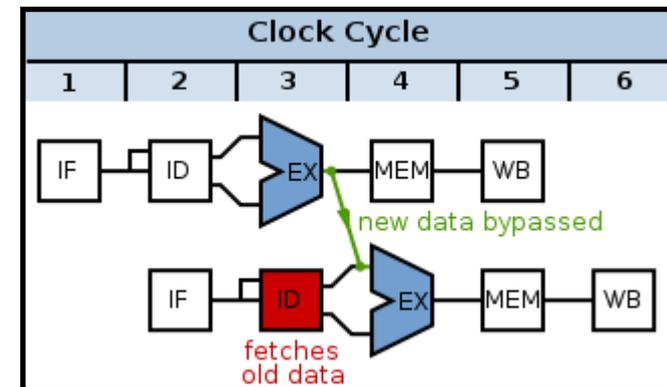
## Pipelining – Hazards

### Data-Hazards

- Problem
  - > Datenabhängigkeiten

| Pipeline Stage | Clock Cycle |     |     |     |     |     |
|----------------|-------------|-----|-----|-----|-----|-----|
|                | 1           | 2   | 3   | 4   | 5   | 6   |
| Fetch          | SUB         | AND |     |     |     |     |
| Decode         |             | SUB | AND |     |     |     |
| Execute        |             |     | SUB | AND |     |     |
| Access         |             |     |     | SUB | AND |     |
| Write-Back     |             |     |     |     | SUB | AND |

- Lösung
  - > Data Bypassing
    - > Eingangsdaten für Befehle stammen aus Registern oder „Zwischenergebnissen“

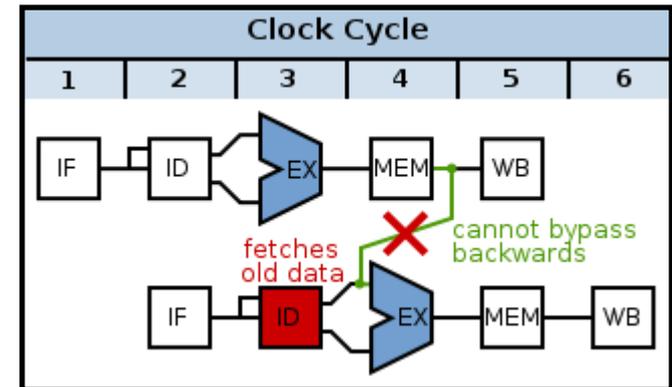


# Der von Neumann-Rechner

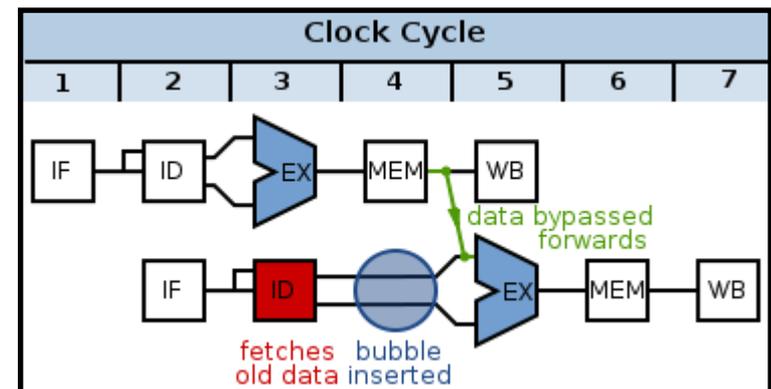
## Pipelining – Hazards

### Data-Hazards – Data Bypassing

- Problem
  - > Es kann trotzdem sein, dass Informationen nicht rechtzeitig zur Verfügung stehen



- Lösung
  - > NOP
  - > NOP-Befehl (No Operation) einfügen



# Der von Neumann-Rechner

## Pipelining – Hazards

---

### Control-Hazards

- Bedingte Sprungbefehle ändern den als nächstes auszuführenden Befehl
  - > Nächster Befehl steht erst am Ende des vorherigen Befehls fest
  - > Die Pipeline hat bereits begonnen unnötige Befehle abzuarbeiten
- Lösung:
  - > Stall / Freeze
  - > Predict Taken
  - > Predict Not Taken
  - > Branch Delay Slot

# 6 - Speicher

---

## Arbeitsspeicher und Cache

# Lessons Learned

## Muss ich mir das alles merken?

---

### **In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können**

- Technische Realisierungen von Speicher
  - > Arbeitsspeicher
  - > Massenspeicher
- Funktionweise und Aufbau eines Caches
- Funktionsweise eines RAID-Systems

# Speicher

## Fotografischer Speicher

### Speicherung der Information als Bild

- Speichern der Information durch chemischen Vorgang
- Lesen der Informationen durch simples Betrachten des Bildes
  - > Formatunabhängig
  - > Kein spezielles Lesegerät notwendig
- Informationen können bewegt oder unbewegt abgelegt werden
- Beispiele
  - > Filme
  - > Fotos



# Speicher

## Mechanischer Speicher

### Daten werden durch mechanische Einwirkung auf das Speichermedium geschrieben

- Daten können analog oder digital gespeichert werden
- Daten können mechanisch oder optisch ausgelesen werden

### Beispiele

- Mechanischer Lesevorgang
  - > LP (analog)
  - > Lochkarte (digital)
- Optischer Lesevorgang
  - > Laserdisc (analog)
  - > CD, DVD, Blu-ray, ... (digital)



# Speicher

## Halbleiterspeicher

**Die Daten werden auf Siliziumbasis mittels integrierter Schaltkreise gespeichert**

**Verschiedene Arten der Speicherung werden unterschieden**

- Flüchtige Speicherung
  - > DRAM, SRAM
- Permanente Speicherung
  - > ROM, PROM
- Semi-permanente Speicherung
  - > EPROM, EEPROM, Flash-Speicher, ...



# Speicher

## Magnetischer Speicher

### Die Informationen werden durch gezielte, partielle Magnetisierung des Speichermediums abgelegt

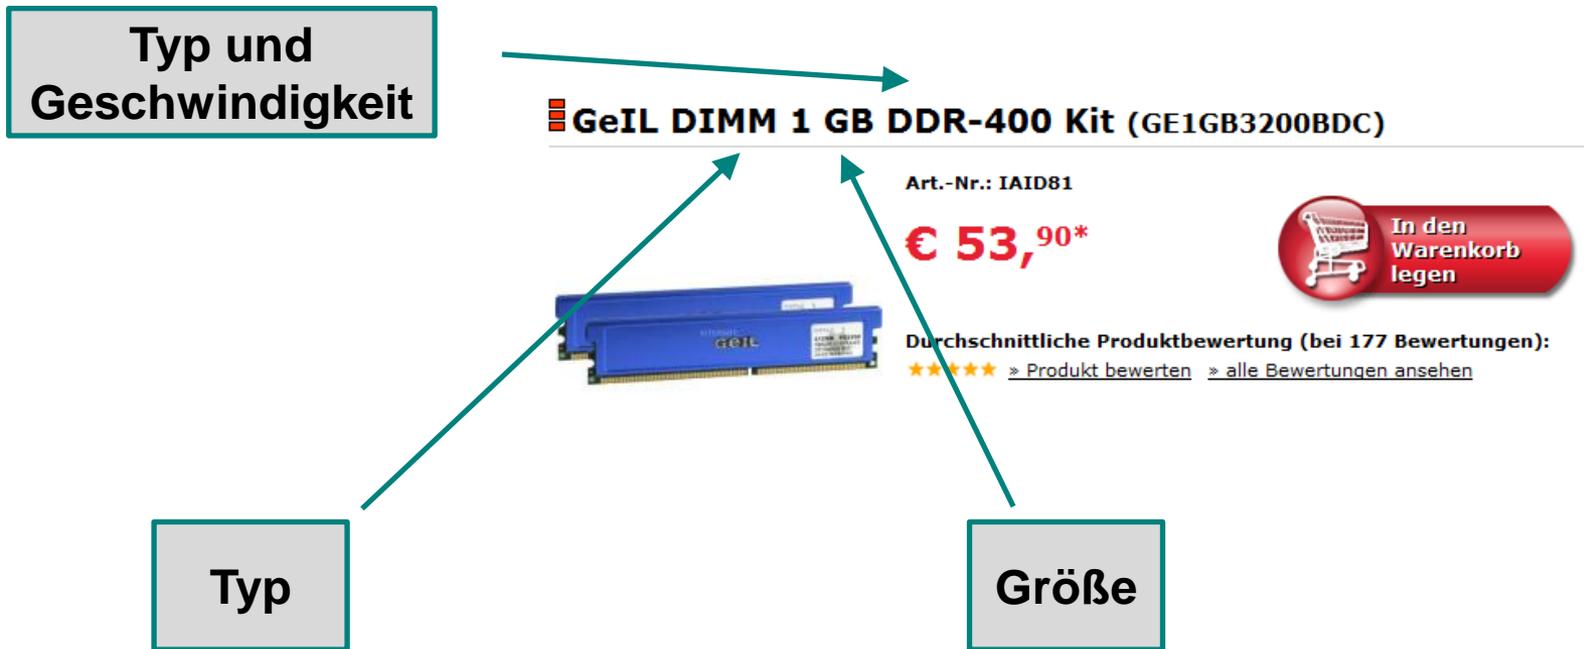
- Zugriff auf die Informationen mittels eines Schreib-/Lesekopfes
- Magnetisches Material als ...
  - > ... Plattenstapel (z.B. bei Festplatte)
  - > Beweglicher Lesekopf
  - > ... Band (z.B. bei MCs)
  - > Feststehender Lesekopf
- Speicherung der Informationen analog oder digital



### Beispiele

- Festplatte, Diskette, ... (digital, beweglicher Lesekopf)
- Magnetstreifen, Magnetkarte, ... (digital, feststehender Lesekopf)
- MC, VHS, ... (analog, feststehender Lesekopf)

# Speicher Kenngrößen

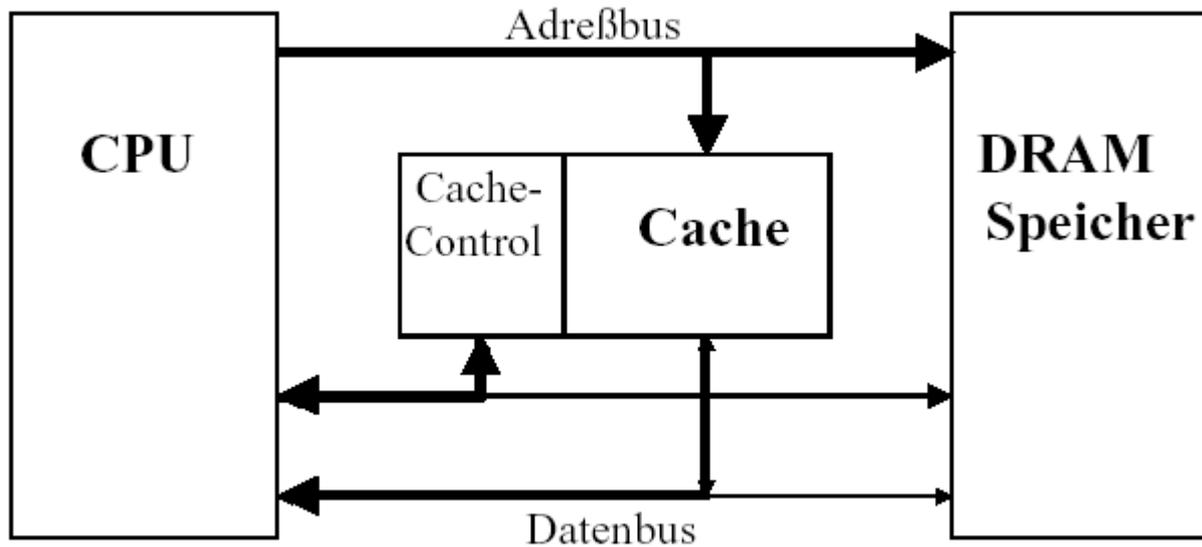


### Problem

- Schnelle SRAM-Bausteine sind teuer
- Schnelle SRAM-Bausteine nehmen viel Platz in Anspruch
  - In Größenordnung von mehreren GB Speicher schwer zu realisieren

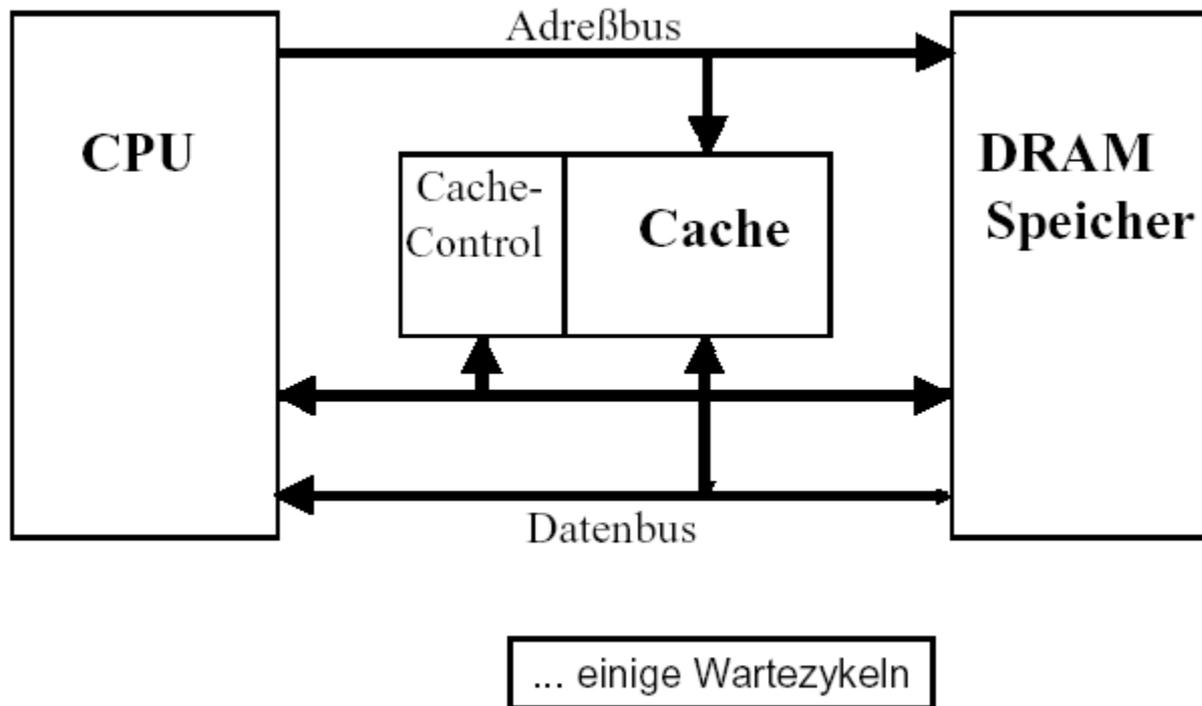
# Caches

## Idee: Cache-Hit



# Caches

## Idee: Cache-Miss



## Grundlegendes zu Caches

- Cache ist aus SRAM-Bausteinen aufgebaut
  - > Wenig Speicher, im Vergleich zum Hauptspeicher
  - > Schneller Speicher, im Vergleich zum Hauptspeicher
- Ein Cache enthält nur kleine Datenmengen (*Cacheblocks*) aus dem Hauptspeicher
  - > Problem: Welche Daten sollen aus dem Hauptspeicher geladen werden?
- Ist im Cache keinen Platz mehr für einen neuen Block, muss zuerst ein Block verdrängt werden – **Wie?**

# Caches

## Lokalitätsprinzip

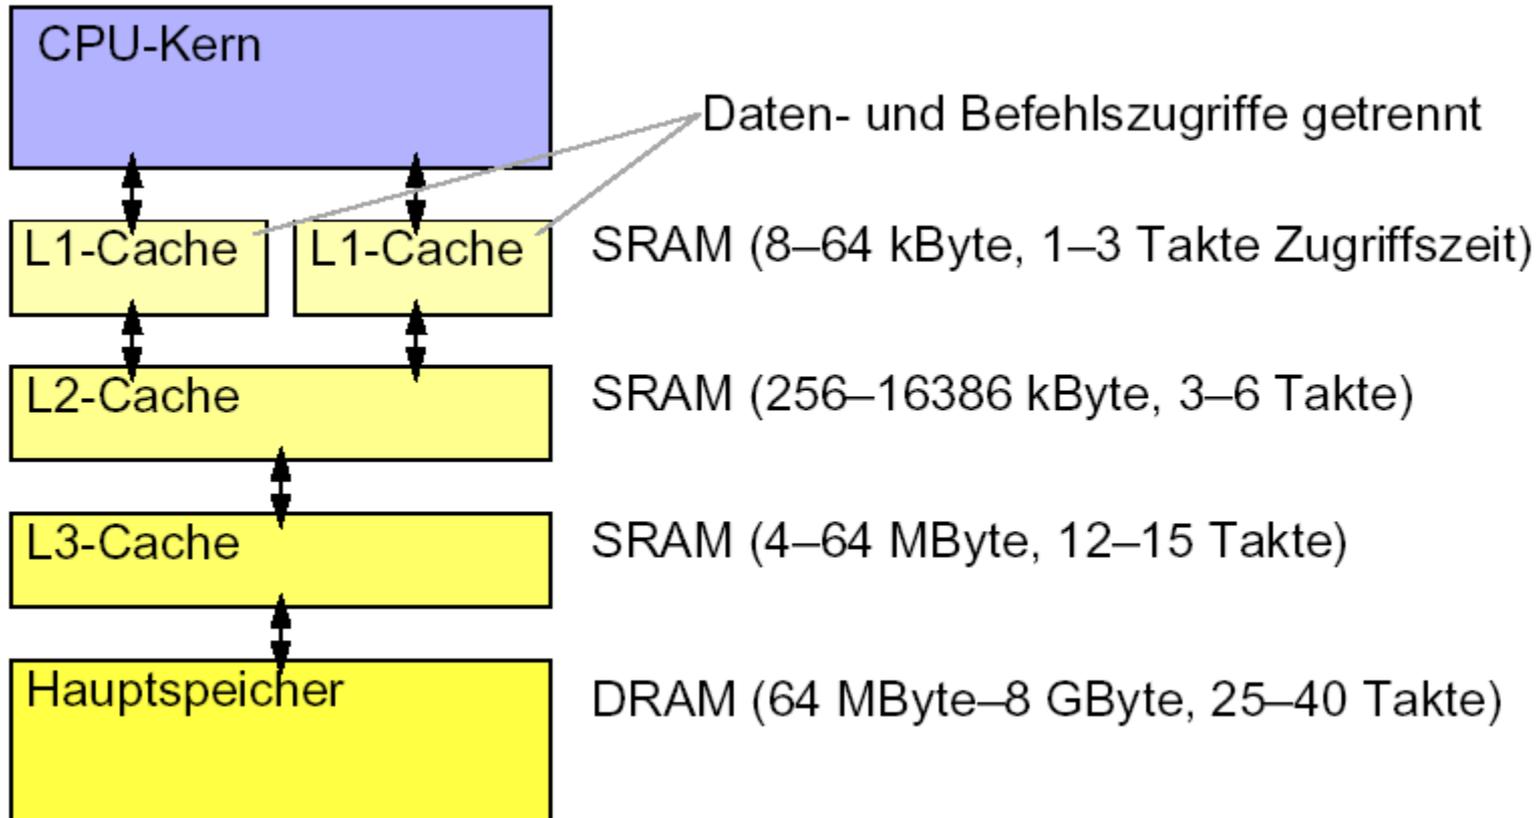
---

### Es gibt zwei Arten von sogenannter **Lokalität**

- **Zeitliche** Lokalität
  - > Es ist, bei entsprechender Programmierung, sehr wahrscheinlich, dass auf eine Speicherzelle nicht nur einmal, sondern zeitlich „nah“ mehrmals zugegriffen wird
- **Örtliche** Lokalität
  - > Es ist, bei entsprechender Programmierung, sehr wahrscheinlich, dass nach dem Zugriff auf eine bestimmte Speicherzelle auch ein Zugriff in deren unmittelbarer „Nachbarschaft“ stattfindet

# Caches

## Hierarchie auf einem modernen System



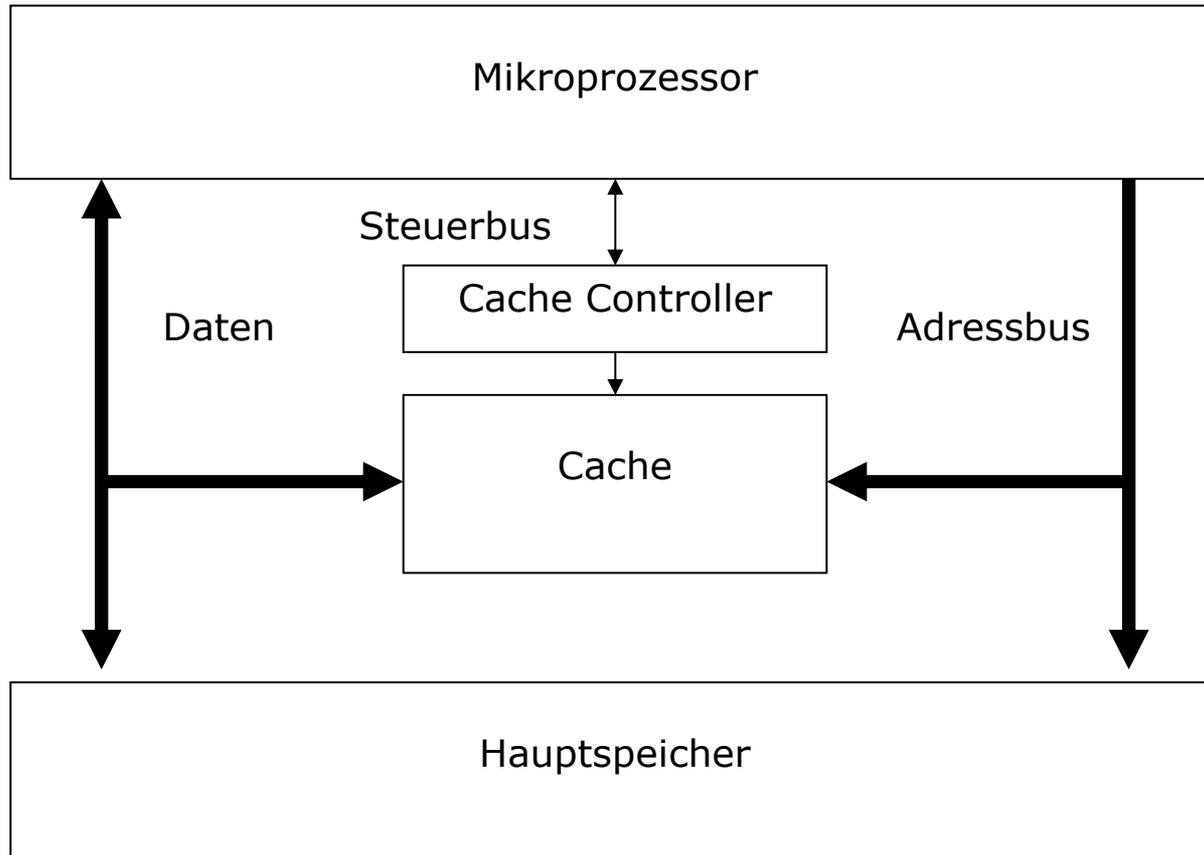
### Die wichtigsten Cache-Level haben folgende Eigenschaften

- L1-Cache
  - > Im Prozessor integriert
  - > Trennung in Befehls- und Datencache
  - > Cache-Blöcke häufig nicht länger als 32 Bytes
- L2-Cache
  - > Heute auch schon im Prozessor integriert
  - > Gemeinsame Speicherung von Befehlen und Daten
  - > Cache-Blöcke bis zu 128 Bytes

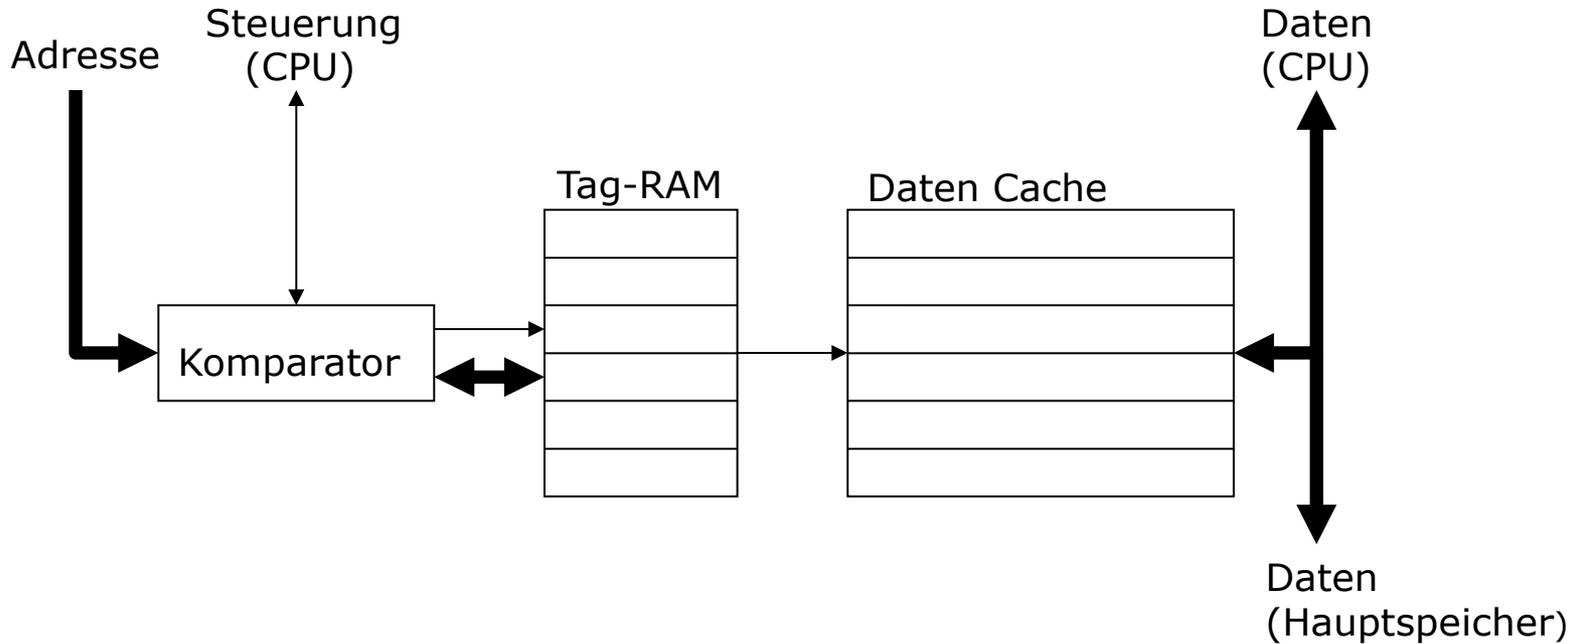
## Ein Cache funktioniert wie folgt

- Cache ist ein Assoziativspeicher für Blöcke des Hauptspeichers
  - > Tag (*Key/Schlüssel*) entspricht der Speicheradresse
- Ungültige Einträge werden nicht aus dem Cache gelöscht
  - > Markierung ungültiger Blocks durch Löschen des Valid-Flags (*V-Flag*)
- Aufbau eines Cacheeintrags
  - > Die Daten selbst
  - > Tag (Teil der Adresse)
  - > Statusbits, u.a.
    - > Valid-Flag (gültige Daten)
    - > Modified bzw. Dirty (wurde geändert, wichtig für Write-Back)

# Caches Platzierung



# Caches Aufbau



# Caches

## Arten von Caches

---

### Es gibt drei Arten von Caches

- Direct Mapped Cache
  - > Direkte Abbildung auf den Hauptspeicher
  - > Jeder Block kann nur an genau einem Platz im Cache eingefügt werden, der sich aus der Hauptspeicheradresse ergibt
- Fully associative Cache
  - > Ein Block kann an jeder Stelle des Caches eingefügt werden
  - > Identifizierung über Tag
- Set associative Cache
  - > Mehrere fully associative Caches arbeiten parallel
  - > Identifizierung des „richtigen“ Caches über Tag

# Caches

## Direct Mapped Cache

---

**Die Stelle, an der ein Block im Cache eingefügt wird, berechnet sich direkt aus der Adresse im Hauptspeicher durch eine **Modulo-Operation****

- Beispiel
  - > Cache besteht aus 8 Blöcken
  - > Speicherblock 13 soll in den Cache aufgenommen werden
  - > Cacheblock =  $13 \bmod 8 = 5$

# Caches

## Fully Associative Cache

---

### **Ein Block kann in jeder Stelle in den Cache eingefügt werden**

- Beim Einfügen in den Cache wird die Adresse des Blocks in das Tag-RAM geschrieben
- Bei der Überprüfung, ob ein Block im Cache liegt, wird das Tag-RAM durchsucht, ob es die entsprechende Speicheradresse enthält

# Caches

## Set-Associative Cache

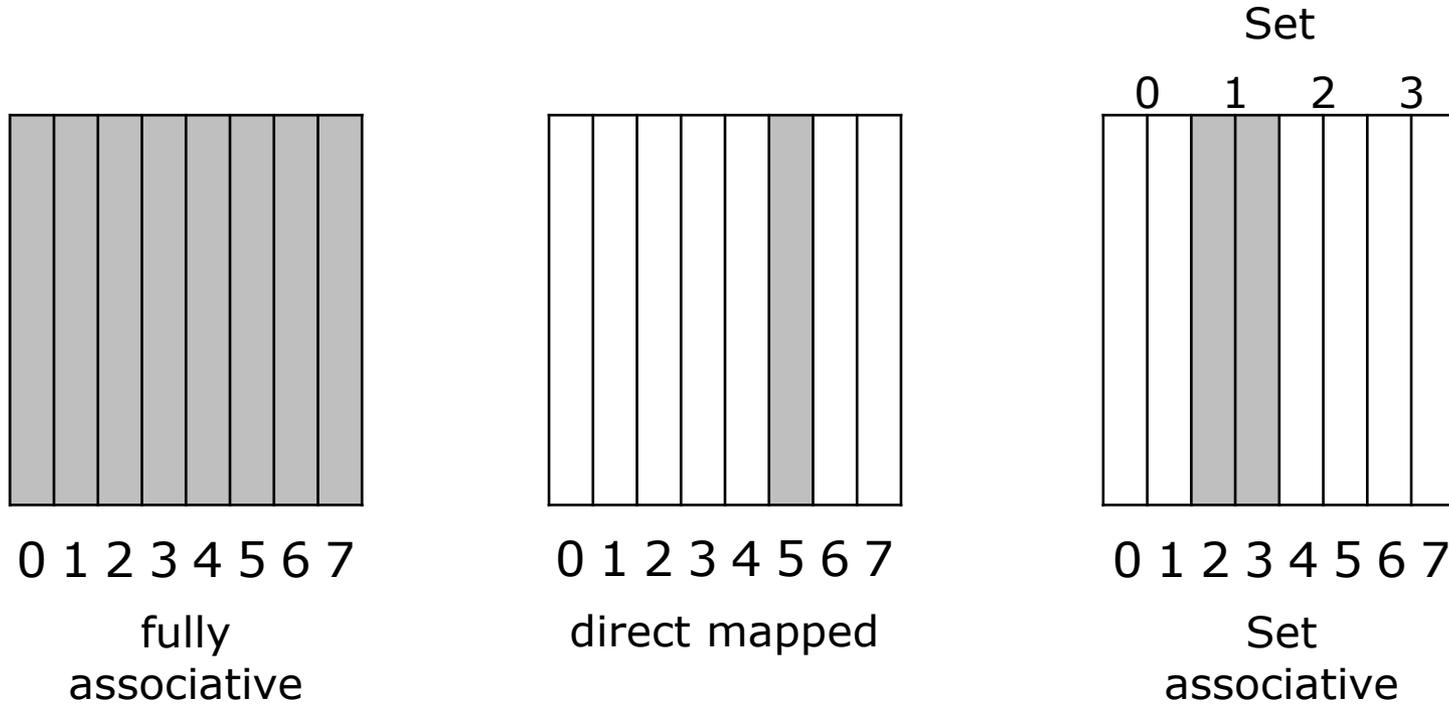
---

### Mehrere fully associative Caches arbeiten parallel

- Der fully associative Cache, in den ein Block eingefügt wird, wird anhand der Speicheradressen und Modulo-Operationen bestimmt
- Beispiel
  - > Es gibt 8 fully associative Caches zu je 10 Blöcken
  - > Speicherblock 13 soll in den Cache aufgenommen werden
  - > Bestimmung des fully associative Caches:  $13 \bmod 8 = 5$ 
    - > Der fünfte Cache wird verwendet
  - > Einfügen des Blocks in diesen Cache wie bei fully associative Caches üblich

# Caches

## Blockplatzierung



**Es soll der Block mit der Speicheradresse 13 eingefügt werden.**

- $13 \bmod 8 = 5$
- $13 \bmod 4 = 1$

### Findet ein Lesezugriff auf Speicherzelle $A$ statt ...

- ... wird zunächst geprüft, ob Speicherzelle  $A$  bereits im Cache liegt.
  1.  $A$  liegt im Cache (**cache hit**)
    - > Der Datensatz kann direkt aus dem Cache gelesen werden.
  2.  $A$  liegt nicht im Cache (**cache miss**)
    - > Der Datensatz muss aus dem Hauptspeicher in den Cache geladen werden.
    - > Aus dem Cache wird das Datum in die CPU geladen.

## Findet ein Schreibzugriff auf Speicherzelle $A$ statt ...

- ... wird zunächst geprüft, ob Speicherzelle  $A$  bereits im Cache liegt.
  1.  $A$  liegt im Cache (**cache hit**)
    - > Der Datensatz wird im Cache aktualisiert
    - > (Der Datensatz wird im Hauptspeicher aktualisiert)
  2.  $A$  liegt nicht im Cache (**cache miss**)
    - > Der Datensatz wird direkt in den Hauptspeicher geschrieben.
    - > Der Inhalt des Caches wird nicht verändert.

## Es gibt zwei Verfahren zum Aktualisieren von Datensätzen im Cache

- Write-Through
  - > Der Datensatz wird im Cache und direkt anschließend auch im Hauptspeicher aktualisiert
  - > Keine Probleme mit der Datenkonsistenz im Hauptspeicher
- Write-Back
  - > Der Datensatz wird im Cache aktualisiert und erst in den Hauptspeicher zurückgeschrieben, wenn der entsprechende Cacheblock aus dem Cache verdrängt wird
  - > Niedrige Belastung der Systembusse und keine Wartezyklen

## Es gibt drei Arten von Cache Misses

- *Compulsory (zwangsweise, zwangsläufig)*
  - > erstmaliger Zugriff auf eine Adresse, dazugehörigen Daten noch nicht im Cache ⇒ Mgl. Lsg.: Prefetch Einheiten laden selbständig Cache
- *Capacity*
  - > Cache ist zu klein, Daten waren im Cache vorrätig, wurden aber wieder aus dem Cache entfernt ⇒ Mgl. Lsg.: größerer Cache
- *Conflict*
  - > in einem Satz ist nicht mehr genug Platz und Block wird entfernt, obwohl Platz in anderen Sätzen wäre; erneuter Zugriff auf entfernten Block ist ein „Conflict Miss“ ⇒ Mgl. Lsg.: Erhöhung der Cacheblocks pro Satz – also eine Erhöhung der Assoziativität.

# Caches

## Verdrängungsstrategien

---

### Wenn der Cache voll ist muss Platz geschaffen werden

- FIFO (First In, First Out)
  - > Der Block, welcher chronologisch gesehen zuerst in den Cache geladen wurde, wird aus dem Cache verdrängt
- LRU (Least Recently Used)
  - > Der Block, auf den am längste nicht mehr zugegriffen wurde, wird aus dem Cache verdrängt
- Optimale Ersetzungsstrategie
  - > Der Block, der chronologisch gesehen am spätesten wieder gebraucht wird, wird aus dem Cache verdrängt
  - > Nachteil: Diese Information steht meistens nicht zur Verfügung
- Varianten der genannten Strategien

## RAID steht für "Redundant Array of Independent Disks"

- Ehemals „Redundant Array of Inexpensive Disks“
- Dient zur Organisation mehrerer physikalischer Festplatten in einem Verbund
- Kann hardware- oder softwareseitig verwaltet werden
- Es werden gezielt redundante Daten erzeugt, um beim Ausfall einer Festplatte die Integrität und Funktionalität des Gesamtsystems trotzdem gewährleisten zu können
  - > RAID0 Sonderfall

# Massenspeicher

## Aufbau eines RAID

---

### Es werden mindestens 2 Festplatten benötigt

- Alle in das RAID eingebundenen Festplatten werden gemeinsam betrieben und zielen auf die Verbesserung einer Eigenschaft ab
  - > Erhöhung der Ausfallsicherheit
  - > Steigerung der Datentransferrate
  - > Erweiterung der Speicherkapazität
  - > Möglichkeit des Austauschs von Festplatten im laufenden Betrieb
  - > Kostenreduktion durch Einsatz mehrerer kostengünstiger Festplatten
- Die genau Art des Betriebs wird durch das sog. *RAID-Level* angegeben

# Massenspeicher

## Hardware-RAID vs. Software-RAID

### Es gibt zwei verschiedenen Arten ein RAID zu verwalten

- In einem Hardware-RAID werden alle beteiligten Festplatten durch den sogenannten RAID-Controller angesprochen und verwaltet
- In einem Software-RAID wird die Verwaltung der Festplatten im RAID komplett von einer Software gesteuert
- Pro und Contra beim Software-RAID
  - > Pro
    - > Es wird kein zusätzliches Hardwarebauteil benötigt
    - > Der RAID-Controller selbst kann keinen Schaden nehmen (wie beim Hardware-RAID möglich)
  - > Contra
    - > CPU und Systembusse werden stärker belastet
    - > Nur der RAM kann als Cache benutzt werden

# Massenspeicher

## Probleme mit RAID 1 / 2

---

### Es können mehrere Problem beim Betrieb eines RAID auftreten

- Größenänderungen
  - > Es ist nicht ohne Weiteres möglich die Kapazität eines RAID im Nachhinein durch einfaches Zuschalten einer weiteren Festplatte zu erhöhen
- Austausch von Datenträgern
  - > Muss eine Festplatte im RAID ausgetauscht werden, so muss sie durch eine Platte gleicher oder größerer Kapazität ausgetauscht werden
- Defekte Controller
  - > Defekte RAID-Controller können Datenverluste erzeugen
  - > Defekte RAID-Controller können i.A. nur durch identische Controller ersetzt werden

# Massenspeicher

## Probleme mit RAID 2 / 2

---

### Es können mehrere Problem beim Betrieb eines RAID auftreten

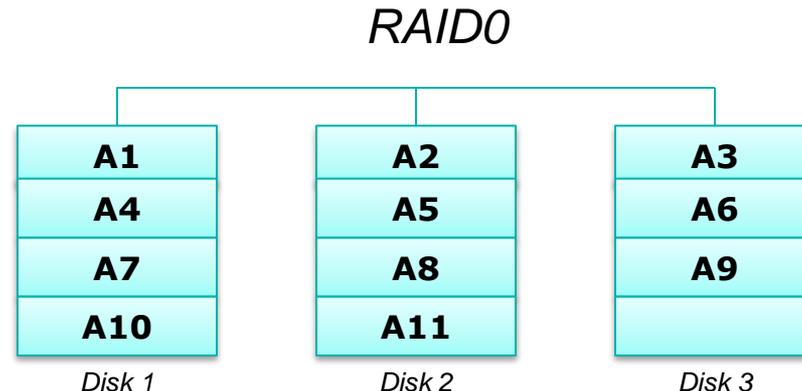
- Fehlerhaft produzierte Datenträgerserien
  - > Kommen mehrere Festplatten einer fehlerhaften Charge im selben RAID zum Einsatz können sich deren Fehler multiplizieren
- Statistische Fehlerrate bei großen Festplatten
  - > Die vom Hersteller angegebenen Fehlerraten können sich beim Betrieb der Platte in einem RAID akkumulieren

# Massenspeicher

## RAID 0

### RAID 0 ist kein RAID im herkömmlichen Sinne, da keine redundanten Daten erzeugt werden

- Bietet höhere Transferraten durch *Striping*
  - > Alle beteiligten Festplatten werden in gleich große Blöcke unterteilt
    - > Häufig 64 kB pro Block
  - > Diese Blöcke werden im Reißverschlussverfahren zu einer großen Festplatte angeordnet
  - > Zugriff auf Blöcke kann in gewissem Maße parallel geschehen



### Es gibt mehrere Nachteile bei RAID 0

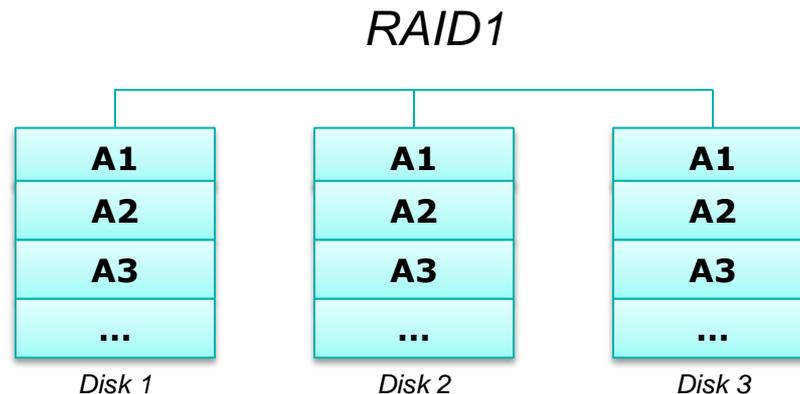
- Ist eine Festplatte im RAID 0 defekt, so können die Nutzdaten nicht mehr vollständig rekonstruiert werden
  - > Kleine Dateien können möglicherweise gerettet werden, wenn keine Datenblöcke auf der kaputten Festplatte lagen
- Der laufende Betrieb muss bei Ausfall einer Festplatte zwangsläufig unterbrochen werden
- Die Ausfallwahrscheinlichkeit eines RAID 0 mit n Festplatten beträgt
$$1 - (1 - p)^n$$
  - > Die Ausfallwahrscheinlichkeiten p einer einzelnen Festplatte müssen statistisch unabhängig voneinander sein

# Massenspeicher

## RAID 1

### RAID 1 bietet hohe Datenredundanz durch *Mirroring*

- Alle Daten werden identisch auf alle verfügbaren Festplatten geschrieben
  - > Lesezugriffe können, ähnlich wie bei RAID0, parallel ablaufen



### Auch RAID 1 hat einige Nachteile

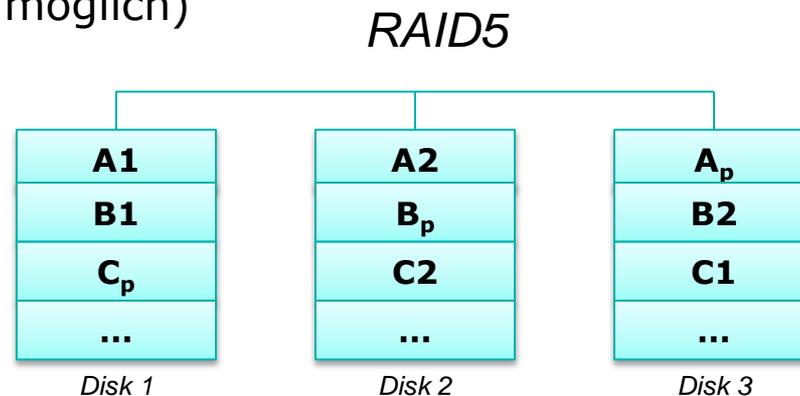
- Das RAID kann maximal so groß sein, wie die kleinste beteiligte Festplatte
- RAID1 ist KEIN Ersatz für Datensicherung, da alle Schreiboperationen auch auf allen Festplatten vorgenommen werden
  - > Versehentlich gelöschte oder geänderte Daten sind trotzdem verloren

# Massenspeicher

## RAID 5

### RAID 5 bietet höhere Transferraten und hohe Datenredundanz

- Daten werden, wie bei RAID0, in gleich großen Blöcken auf die beteiligten Platten gelegt
- Jeweils eine Platte enthält statt eines Datenblocks einen Paritätsblock
  - > Die Berechnung des Paritätsblocks erfolgt durch XOR-Verknüpfung aller zugehöriger Datenblöcke
  - > Datenintegrität ist bei Ausfall von maximal einer Platte gewährleistet (Rekonstruktion möglich)



# Massenspeicher

## RAID 5

### Redundanz bei RAID 5 wird mit XOR-Operationen erreicht

- Original bei drei Platten

| D1 | D2 | D3 | par |
|----|----|----|-----|
| 1  | 1  | 0  | 0   |
| 0  | 1  | 1  | 0   |
| 0  | 1  | 0  | 1   |

- Wiederherstellung bei Ausfall durch Auswertung der Parität

| D1 | D2 | D3 | par |
|----|----|----|-----|
| 1  | ?  | 0  | 0   |
| ?  | 1  | 1  | 0   |
| 0  | 1  | ?  | 1   |

# Massenspeicher

## RAID 5

---

### Die Speicherkapazität eines RAID 5 mit n Festplatten errechnet sich wie folgt

- $(n - 1) * (\text{Kapazität der kleinsten Festplatte})$
- Zweiphasiges Schreibverfahren
  - > Schreiben der Daten
  - > Schreiben / Aktualisieren des Paritätsblocks

# Massenspeicher

## RAID Kombinationen

---

### **Kombinationen von RAID-Systemen sind möglich**

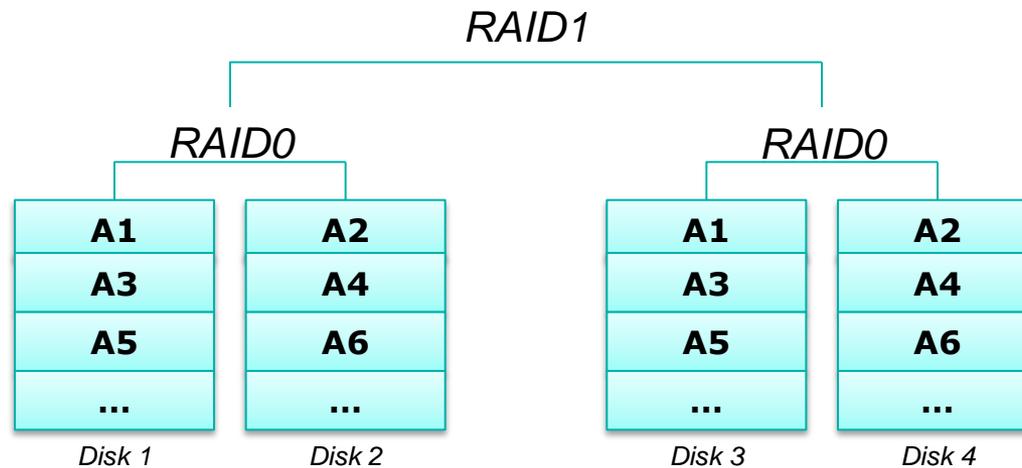
- Mehrere RAID-Systeme eines bestimmten Typs werden zu einem RAID-System zusammengefasst
  - > z.B. RAID 10, RAID 01, ...
- RAID-Kombinationen sind theoretisch n-stufig möglich
  - > z.B. RAID 100

# Massenspeicher

## Beispiele für RAID Kombinationen

### RAID 01

- Mehrere RAID0 werden zu einem RAID1 zusammengefasst

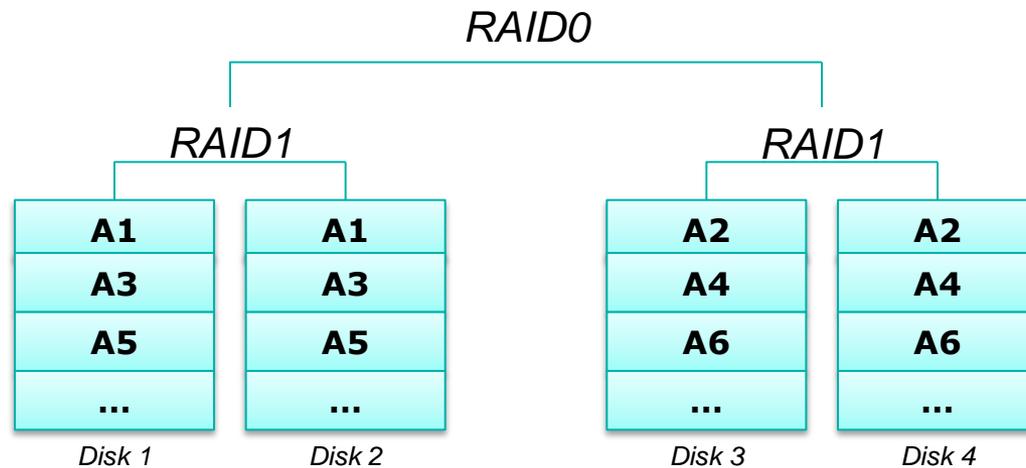


# Massenspeicher

## Beispiele für RAID Kombinationen

### RAID 10

- Mehrere RAID1 werden zu einem RAID0 zusammengefasst



## Festplatte, Hard Disk, HD, Hard Disk Drive, HDD, ...

- Information wird durch Magnetisierung abgelegt
  - > Gehäuse der Festplatte beinhaltet mehrere, auf einer Achse übereinander montierten, runden Platten, welche mit einer magnetisierbaren Schicht überzogen sind
  - > Enthaltene Platten haben alle denselben Durchmesser (3,5", 2,5", 1,8" Formfaktor)
- Heutzutage etwa 1-3 TB Speicherkapazität üblich

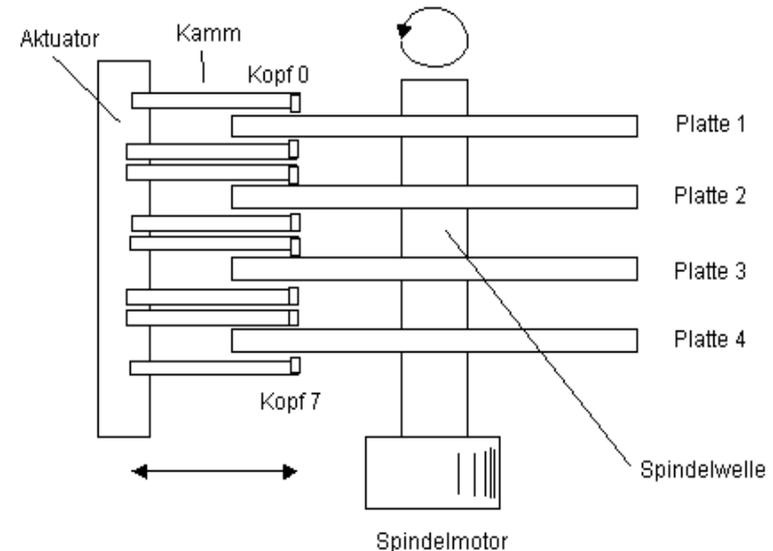


# Massenspeicher

## Aufbau einer Festplatte

### Eine Festplatte funktioniert wie folgt:

- Schreib-/Leseköpfe werden durch einen zentralen Kamm über die Platten bewegt
  - > Etwa 1  $\mu\text{m}$  Abstand zwischen Platte und Kopf
- „Landing Zone“ zum Parken der Köpfe
  - > Kommen die Köpfe mit einem Plattenbereich in Berührung, welcher Daten enthält, werden diese zerstört
- Platten rotieren mit konstanter Umdrehungszahl (5400 – 15000 rpm)



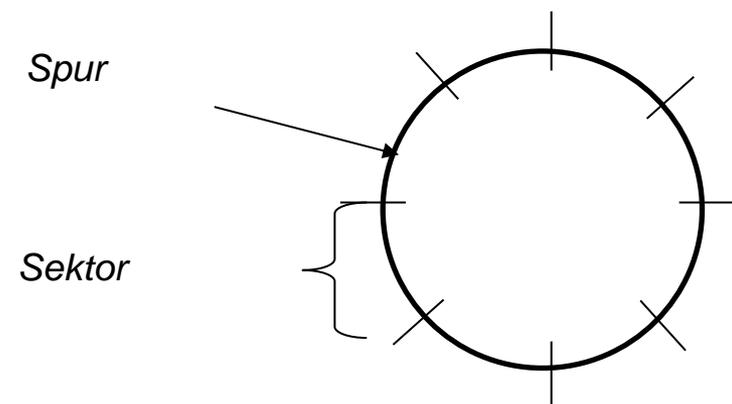
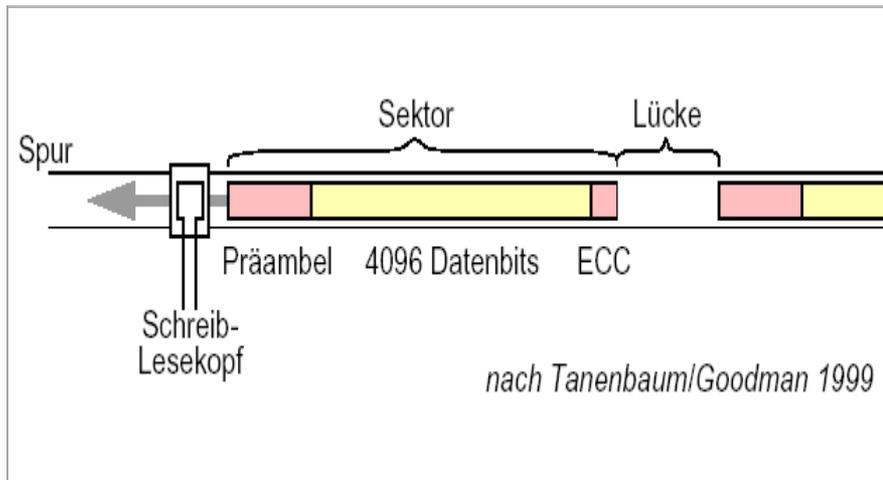
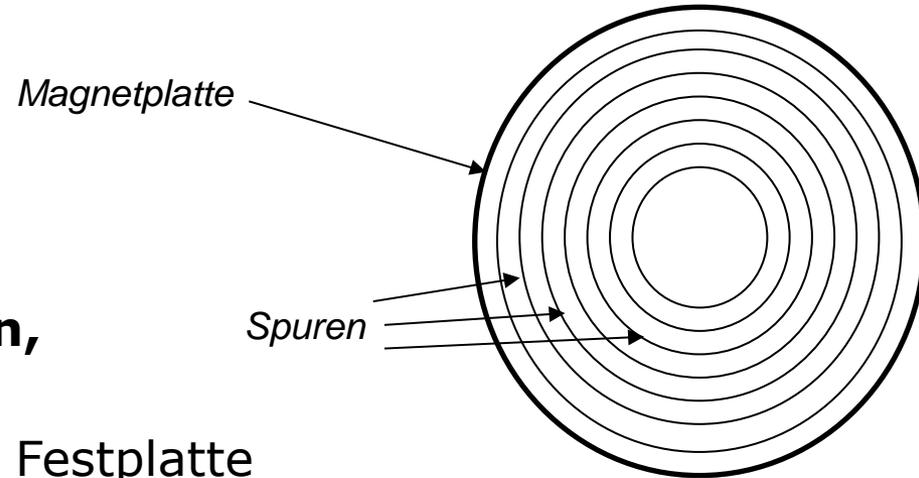
# Massenspeicher

## Spuren und Sektoren

**Die Oberfläche der Platten ist in konzentrische Kreise, die Spuren, eingeteilt**

**Die Spuren sind in Abschnitte fester Speichergröße, die Sektoren, unterteilt**

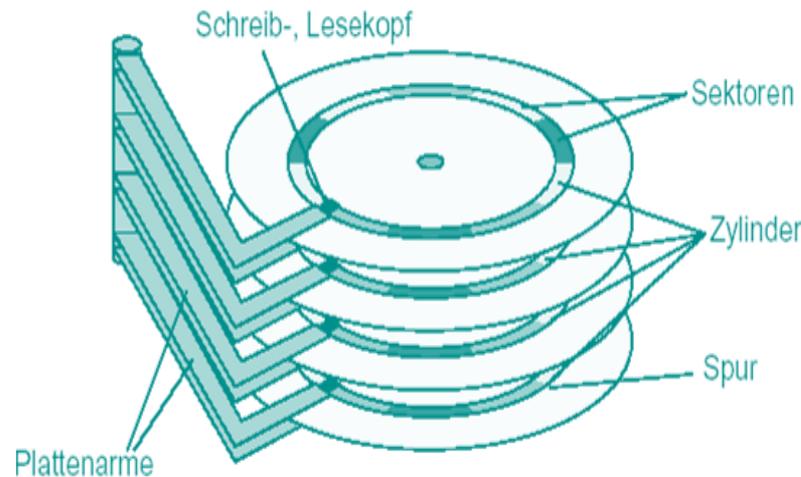
- Kleinste adressierbare Einheit einer Festplatte



# Massenspeicher Zylinder

## Als Zylinder werden die übereinander liegenden Spuren der Platten bezeichnet

- Alle Zylinder können von den entsprechenden Schreib-/Leseköpfen gleichzeitig zugegriffen werden



## Charakteristische Größen

- **kontinuierliche Übertragungsrate** (*sustained data rate*)
  - > Datenmenge, die die Festplatte beim Lesen aufeinander folgender Sektoren im Mittel pro Sekunde überträgt (Schreiben ähnlich)
- **mittlere Zugriffszeit ([data] access time)**
  - > der Spurwechselzeit (*seek time*, Mittelwert beim Wechsel von einer zufälligen zu einer anderen zufälligen Spur)
  - > der Latenzzeit (*latency*, im Mittel dauert es eine halbe Umdrehung, bis ein bestimmter Sektor unter dem Kopf vorbeikommt)
  - > die Kommando-Latenz (*controller overhead*, Zeit, die der Festplattencontroller damit verbringt, das Kommando zu interpretieren)

# Massenspeicher

## Kenngrößen

## Charakteristische Größen

Exemplarische Entwicklung der Plattengeschwindigkeit über der Zeit

| Kategorie | Jahr | Modell                      | Größe       | Drehzahl                 | Datenrate     | Spurwechsel | Latenz | mittlere Zugriffszeit |
|-----------|------|-----------------------------|-------------|--------------------------|---------------|-------------|--------|-----------------------|
| Server    | 1993 | IBM 0662                    | 1 GB        | 5.400 min <sup>-1</sup>  | ca. 5 MB/s    | 8,5 ms      | 5,6 ms | 15,4 ms               |
| Server    | 2002 | Seagate Cheetah X15 36LP    | 18–36 GB    | 15.000 min <sup>-1</sup> | 52–68 MB/s    | 3,6 ms      | 2,0 ms | 5,8 ms                |
| Server    | 2007 | Seagate Cheetah 15k.6       | 146–450 GB  | 15.000 min <sup>-1</sup> | 112–171 MB/s  | 3,4 ms      | 2,0 ms | 5,6 ms                |
| Desktop   | 1989 | Seagate ST296N              | 80 MB       | 3.600 min <sup>-1</sup>  | 0,5 MB/s      | 28 ms       | 8,3 ms | 40 ms                 |
| Desktop   | 1993 | Seagate Marathon 235        | 64–210 MB   | 3.450 min <sup>-1</sup>  | ?             | 16 ms       | 8,7 ms | 24 ms                 |
| Desktop   | 1998 | Seagate Medalist 2510–10240 | 2,5–10 GB   | 5.400 min <sup>-1</sup>  | ?             | 10,5 ms     | 5,6 ms | 16,3 ms               |
| Desktop   | 2000 | IBM Deskstar 75GXP          | 20–40 GB    | 5.400 min <sup>-1</sup>  | 32 MB/s       | 9,5 ms      | 5,6 ms | 15,3 ms               |
| Desktop   | 2009 | Seagate Barracuda 7200.12   | 160–1000 GB | 7.200 min <sup>-1</sup>  | 125 MB/s      | 8,5 ms      | 4,2 ms | 12,9 ms               |
| Notebook  | 1998 | Hitachi DK238A              | 3,2–4,3 GB  | 4.200 min <sup>-1</sup>  | 8,7–13,5 MB/s | 12 ms       | 7,1 ms | 19,3 ms               |
| Notebook  | 2008 | Seagate Momentus 5400.6     | 120–500 GB  | 5.400 min <sup>-1</sup>  | 39–83 MB/s    | 14 ms       | 5,6 ms | 18 ms                 |

# Massenspeicher

## Kenngrößen

### Festplatten - SATA - 2,5 Zoll (26)

| Produkt                                                                                                                                                                         | Kapazität | ms/Cache/U | Preis pro GB | Bewertungen                    | Preis    |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------|------------|--------------|--------------------------------|----------|
|  <p><b>Hitachi</b><br/><b>HTS547564A9E384 640 GB</b><br/>SATA 300, Travelstar 5K750</p>        | 640 GB    | 12/8/5400  | € 0,09*      | ★★★★★<br><u>1 Bewertung</u>    | € 59,90* |
|  <p><b>Hitachi</b><br/><b>HTS543232A7A384 320 GB</b><br/>SATA 300, Travelstar Z5K320, 7 mm</p> | 320 GB    | 5,5/8/5400 | € 0,13*      | » <u>jetzt bewerten</u>        | € 41,49* |
|  <p><b>Hitachi</b><br/><b>HTS545025B9A300 250 GB</b><br/>SATA 300, Travelstar 5K500.B</p>      | 250 GB    | 12/8/5400  | € 0,15*      | ★★★★★<br><u>2 Bewertungen</u>  | € 36,49* |
|  <p><b>Hitachi</b><br/><b>HTS545032B9A300 320 GB</b><br/>SATA 300, Travelstar 5K500.B</p>      | 320 GB    | 12/8/5400  | € 0,12*      | » <u>jetzt bewerten</u>        | € 39,99* |
|  <p><b>Hitachi</b><br/><b>HTS545050B9A300 500 GB</b><br/>SATA 300, Travelstar 5K500.B</p>    | 500 GB    | 12/8/5400  | € 0,10*      | ★★★★☆<br><u>22 Bewertungen</u> | € 51,90* |
|  <p><b>Hitachi</b><br/><b>HTS547575A9E384 750 GB</b><br/>SATA 300, Travelstar 5K750</p>      | 750 GB    | 12/8/5400  | € 0,11*      | ★★★★★<br><u>2 Bewertungen</u>  | € 84,90* |

# Massenspeicher

## Solid State Drives (SSD)

---

### SSDs sind die neueste Entwicklung im Festplattensektor

- Vorteile
  - > SSDs haben im Vergleich zu herkömmlichen Festplatte keine mechanischen Bauteile mehr
    - > Keine Stoßanfälligkeit
    - > Wesentlich kürzere Zugriffszeit, da keine mechanischen Teile in Position gebracht werden müssen
    - > Keine Geräusentwicklung
  - > SSDs verbrauchen weniger Energie als herkömmliche Festplatten
  - > SSDs bieten besseren Datendurchsatz
- Nachteil
  - > SSDs haben einen wesentlich höheren Preis pro Speichereinheit

# Massenspeicher

## Solid State Drives (SSD)

## SSDs

### Kingston

#### Solid State Drive - SATA - 1,8 Zoll (3)

| Produkt                                                                                                                                                            | ↑↓ | Kapazität | ↑↓ | lesen / schr.  | ↑↓ | Preis pro GB | ↑↓ | Bewertungen                      | ↑↓ | Preis     | ↑↓                                                                                  |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|-----------|----|----------------|----|--------------|----|----------------------------------|----|-----------|-------------------------------------------------------------------------------------|
|  <b>Kingston SSDNow V+<br/>Series 1,8\" SSD 128 GB</b><br>SATA 300, SVP180S2/128G |    | 128 GB    |    | 230 / 180 MB/s |    | € 1,64*      |    | » <a href="#">jetzt bewerten</a> |    | € 209,90* |  |
|  <b>Kingston SSDNow V+<br/>Series 1,8\" SSD 64 GB</b><br>SATA 300, SVP180S2/64G   |    | 64 GB     |    | 230 / 180 MB/s |    | € 2,-*       |    | » <a href="#">jetzt bewerten</a> |    | € 127,90* |  |
|  <b>Kingston SSDNow V+<br/>Series 1,8\" SSD 256 GB</b><br>SATA 300, SVP180S2/256G |    | 256 GB    |    | 230 / 180 MB/s |    | € 1,77*      |    | » <a href="#">jetzt bewerten</a> |    | € 454,-*  |  |

» nach oben

# Massenspeicher

## CDs / DVDs / Blu-rays

**Der Datenträger besteht aus einer Kunststoffscheibe mit 12 cm Durchmesser, welche mit einer reflektierenden Aluminiumschicht bedampft wurde**

- Kapazitäten

- > CD: 540 MB – 900 MB (SL)
- > DVD: 4,7 GB (SL), 8,5 GB (DL)
- > Blu-ray: 25 GB (SL), 50 GB (DL)



- Datenraten

- > CD: 1,228 MBit/s
- > DVD: 11,08 MBit/s
- > Blu-ray: 36,00 MBit/s

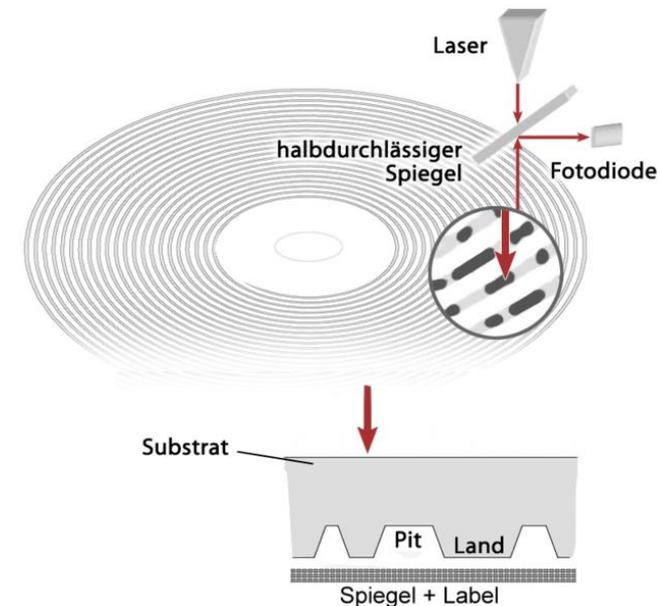
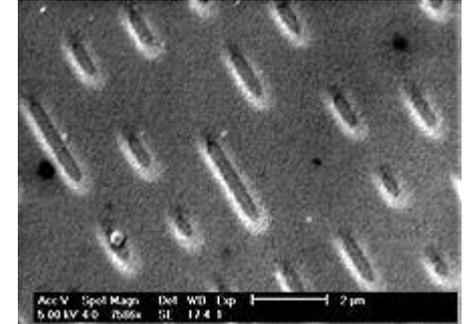
- Optische Speicherung der Daten durch sog. *Pits* und *Lands*

# Massenspeicher

## Prinzipielle Arbeitsweise

**Ein fein gebündelter Laserstrahl wird von einer Laserdiode über Optik mit kippbarem Spiegel auf die Oberfläche der optischen Platte fokussiert**

- Die Intensität des reflektierten Strahls wird von einem Sensor erfasst und liefert das Bitsignal
  - > Helligkeitsschwankungen aufgrund destruktiver Interferenz
  - > Teilwellen mit leicht unterschiedlichem Laufweg
  - > Pits erzeugen reduzierte Helligkeit
- Wellenlängen der Laserstrahlen
  - > CD: 780 nm (Infrarot)
  - > DVD: 650 nm (Rot)
  - > Blu-ray: 405 nm (Violett)
- Abtasten von unten, Pressung von oben (Pits sind Vertiefungen)



# Massenspeicher

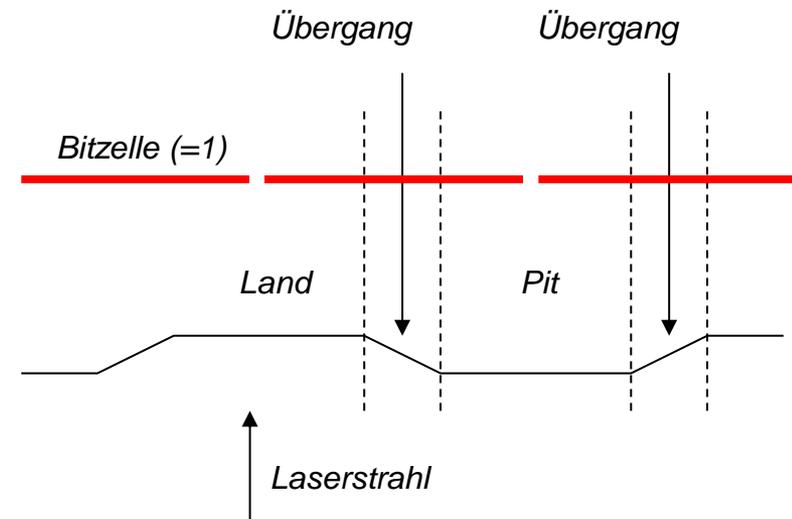
## Pits und Lands

### Pits und Lands sind kleine Vertiefungen und Erhebungen auf der Oberfläche des Datenträgers

- Ein Abschnitt einer Spur von ca.  $0.3 \mu\text{m}$  Länge ist eine Bitzelle
- NRZ-M-Codierung (non-return-to-zero-mark – 1 sind Zustandsänderungen)
  - > Bitzelle mit Übergang stellt eine „1“ dar
  - > Bitzelle ohne Übergang stellt ein „0“ dar

### Auslesen der Information schwierig

- Modulation (EFM=Eight-to-Fourteen Mod.)
  - > CD: EFM-Modulation
  - > DVD: EFMplus-Modulation
  - > Blu-ray: 17PP-Modulation



# 7 – Eingabe und Ausgabegeräte

---

Tastatur, Maus, Touchscreen, Bildschirm

# Lessons Learned

## Muss ich mir das alles merken?

---

### **In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können**

- Wichtige Ein- und Ausgabegeräte kennen
- Technische Realisierungen grundlegend verstehen
- Kriterien zur Bewertung und Auswahl kennen

# Eingabe- und Ausgabegeräte

## Eingabegeräte

## HID – human interface device

### Eingabe von Hand

- **Tastaturen**
- **Zeigeeinrichtungen**  
für Bildschirme  
(Joystick, Maus)
- **Schreibstifteingabe**  
Touchpanels,  
Smartboards

### Lesegeräte

- **Kartenleser**
- **Belegleser**
- **Scanner**  
(Bildabtaster)

### A/V-Eingabegeräte

- **Mikrofon**
- **Telefon**
- **Abspielgeräte**
- **Kameras**

# Eingabe- und Ausgabegeräte

## Ausgabegeräte

### Bildschirme

- **Kathodenstrahl-Monitore**
- **Flachbildschirme**
  - LCD
  - Plasma
- **Projektoren**

### Schreib- und Druckgeräte

- **Zeichendrucker**
- **Zeilendrucker**
- **Seitendrucker**
- **Plotter**

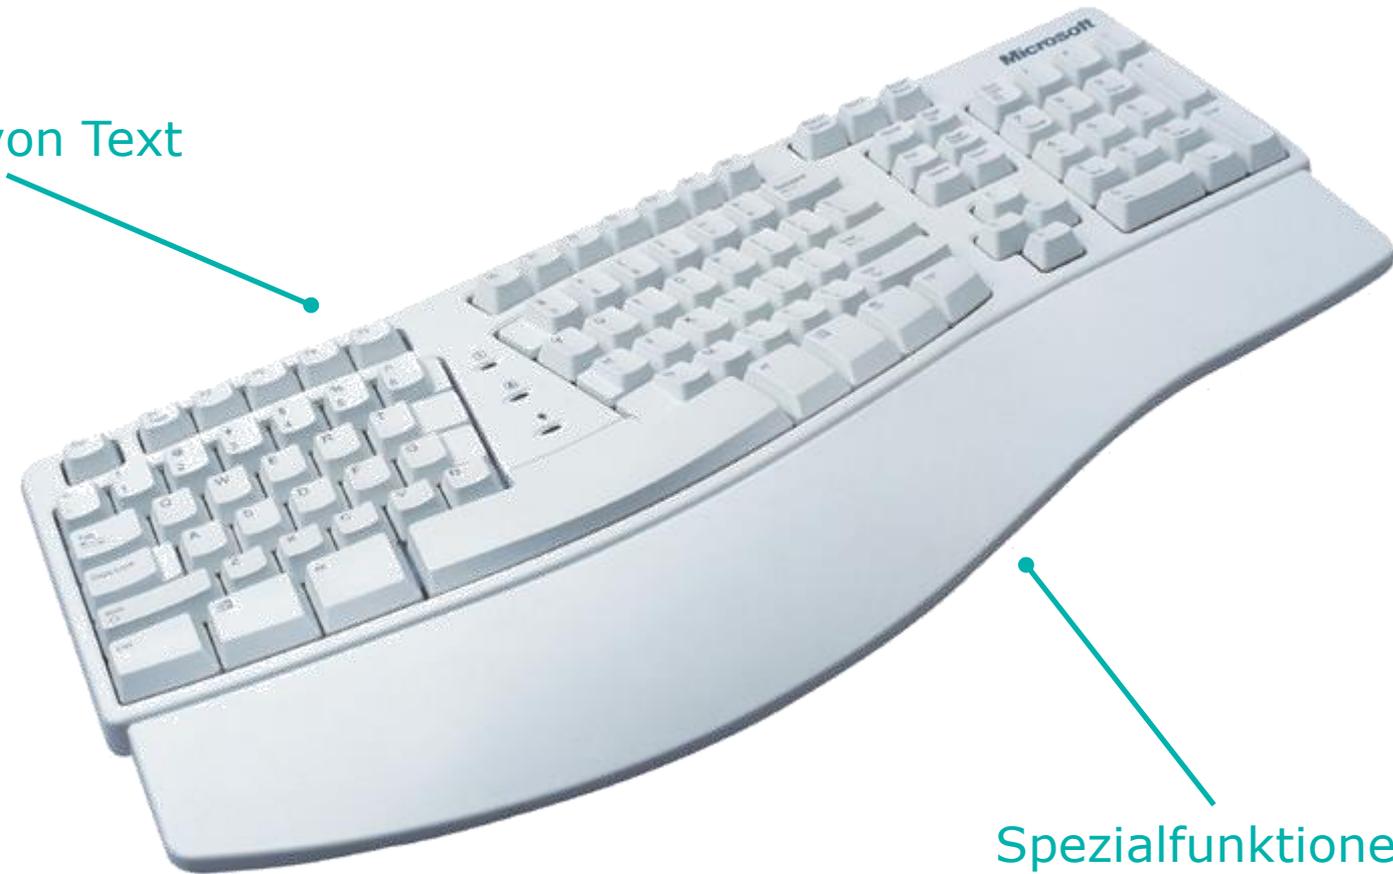
### Audioausgabegeräte

- **Lautsprecher**
- **Kopfhörer**

# Eingabe- und Ausgabegeräte

## Tastaturen

Eingabe von Text



Spezialfunktionen

# Eingabe- und Ausgabegeräte

## Tastaturen

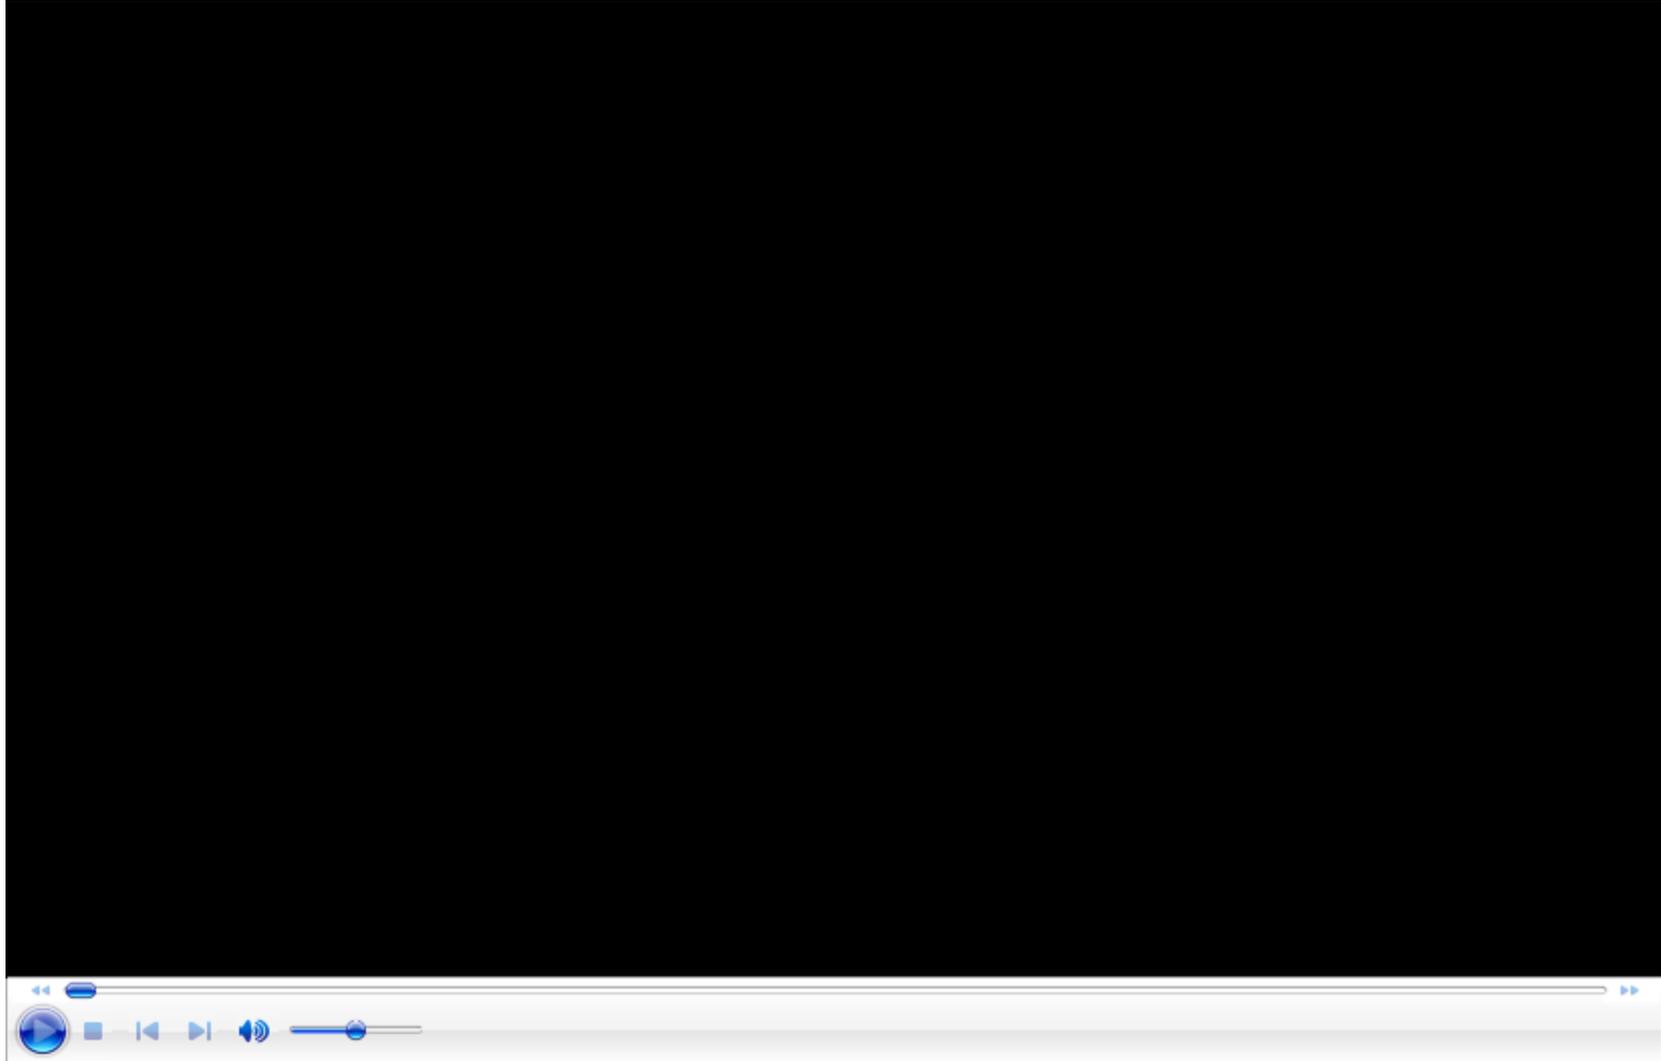
---

### Nachteile von Tastaturen

- Zeitaufwendige Dateneingabe
  - > Tippen einzelner Zeichen
  - > Cursorpositionierung in einem Text
- Nur für Sprachen mit wenigen Zeichen geeignet
- Unterschiedliche Zeichens'tye & Tastenbelegungen
- Relativ lange "Übungszeit"
- Kein Eingabe bildlicher Daten möglich

# Eingabe- und Ausgabegeräte

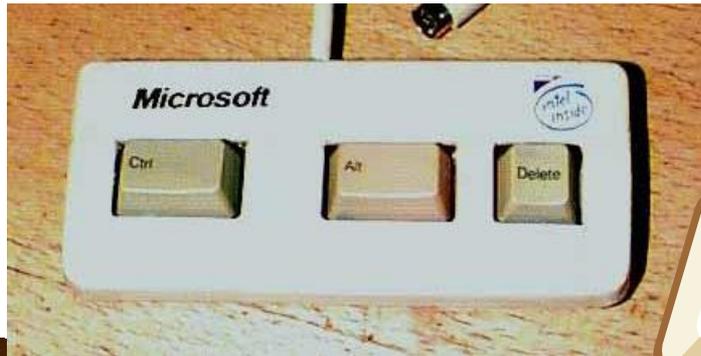
## Tastaturen



# Eingabe- und Ausgabegeräte

## Tastaturen

Für einige Anwendungsfälle gibt es spezielle Tastaturen, die die Arbeit erleichtern



# Eingabe- und Ausgabegeräte

## Mäuse

Zeigen & Klicken



Markieren

Scrollen

# Eingabe- und Ausgabegeräte

## Mäuse

---



## Die Bewegung einer Maus

- Die Bewegungen werden optisch oder mechanisch erfasst
- Die Steuerimpulse werden über Kabel, Funk oder Infrarotlicht übertragen
- Beispiel: Optische Maus
  - > Leuchtdiode oder Laser, Kamera, Rechneinheit
  - > Ablauf
    - > Die Lichtquelle beleuchtet den Untergrund
    - > Die Kamera macht Bilder vom Untergrund
    - > Die Rechneinheit vergleicht aufeinanderfolgende Bilder und gibt den entsprechenden Steuerimpuls aus

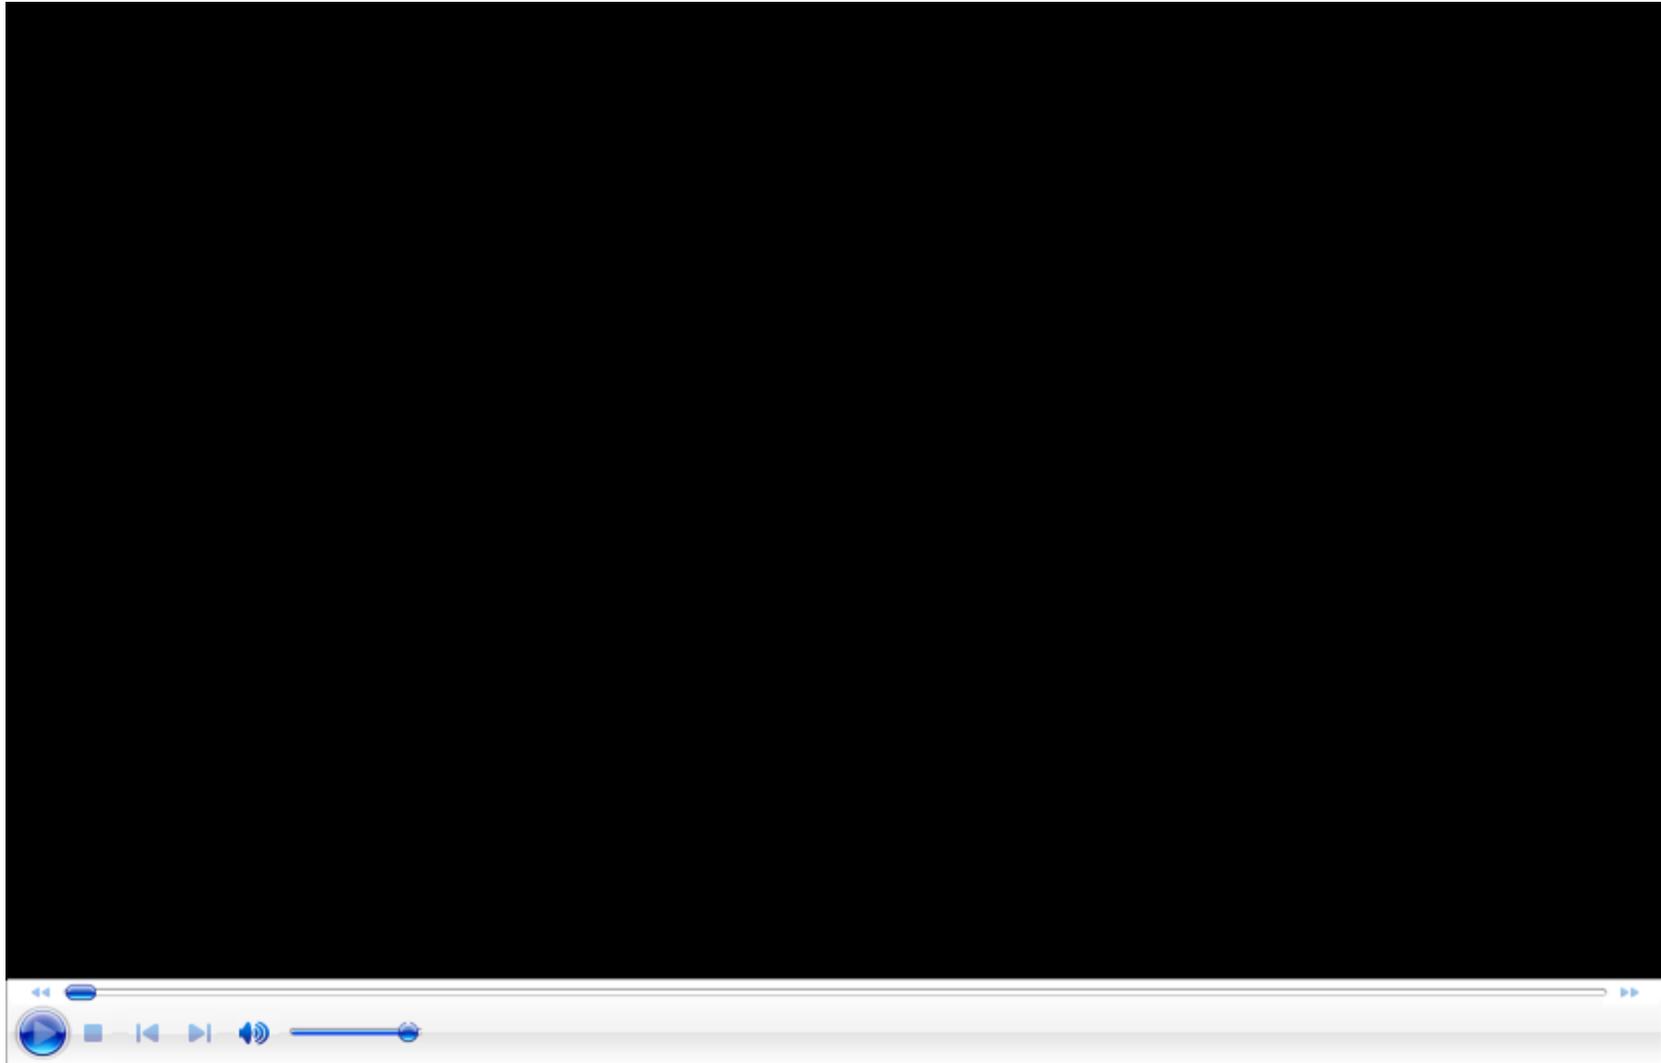


## Touchscreens sind berührungsempfindliche Bildschirme

- Interaktion geschieht direkt mit dem Touchscreen
- Es gibt verschiedene technische Ansätze, die wichtigsten sind ...
  - > Resistive Touchscreens
    - > Der Touchscreen reagiert auf mechanischen Druck
    - > Als Eingabemedium kann alles möglich verwendet werden (Finger, Stift, ...)
  - > Kapazitive Touchscreens
    - > Der Touchscreen reagiert auf elektrische Spannung
    - > Als Eingabemedium können nur elektrisch leitende Dinge verwendet werden (Finger, spezielle Stifte, ...)

# Eingabe- und Ausgabegeräte

## Touchscreens

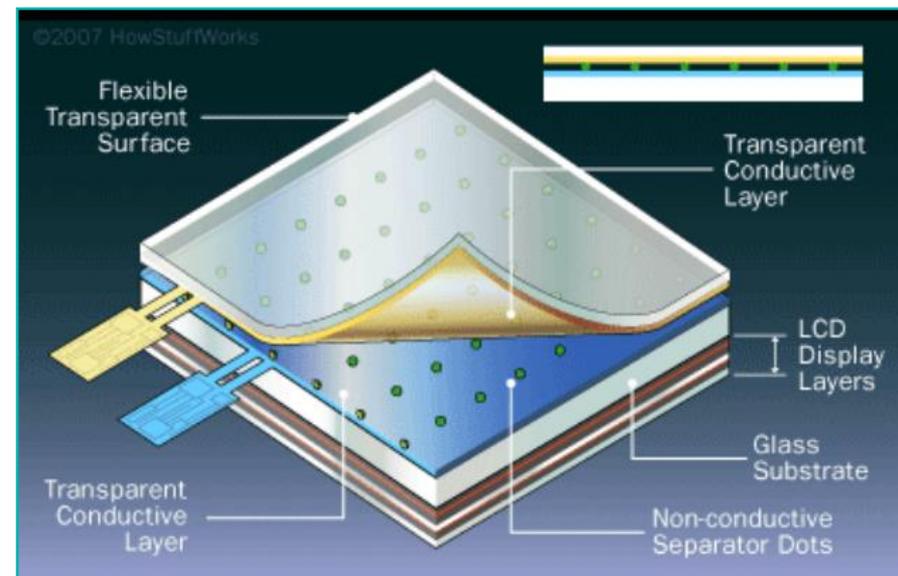


# Eingabe- und Ausgabegeräte

## Touchscreens

### Beispiel: Kapazitiver Touchscreen

- Der Touchscreen besteht aus zwei Glasplatten
  - > Jeweils beschichtet mit transparentem (leitendem) Metalloxyd
  - > Beschichtung in parallelen Leiterbahnen pro Glasplatte
  - > Ausrichtung der Leiterbahnen auf den beiden Glasplatten ist senkrecht zueinander
- Elektrisches Feld im Normalzustand exakt definiert und messbar
- Berührung des Touchscreens mit einem leitenden Gegenstand verändert das elektrische Feld
  - > Punkt der Veränderung kann bestimmt werden



# Eingabe- und Ausgabegeräte

## Bildschirme



## Grundlegendes zu Bildschirmen ...

- Die **Größe** eines Bildschirmes wird in **Zoll** angegeben
  - > Typische Größen
    - > Smartphones: 3" – 6"
    - > Tablets: 7", 8.9", 10.1"
    - > Netbooks 10" – 13"
    - > Laptops: 13" – 17"
    - > Desktop: ab 19"
- Die **Auflösung** eines Bildschirmes wird in **Pixeln** angegeben
  - > Pixel sind Bildpunkte, welche die „Schärfe“ des Bildschirms bestimmen
  - > Ein Pixel besteht in der Regel aus **roten**, **grünen** und **blauen** Subpixeln
  - > Typische Formate
    - > 1024x768 (4:3), 1280x1024 (5:4), 1366x768 (16:9), 1920x1080 (16:9)

# Eingabe- und Ausgabegeräte

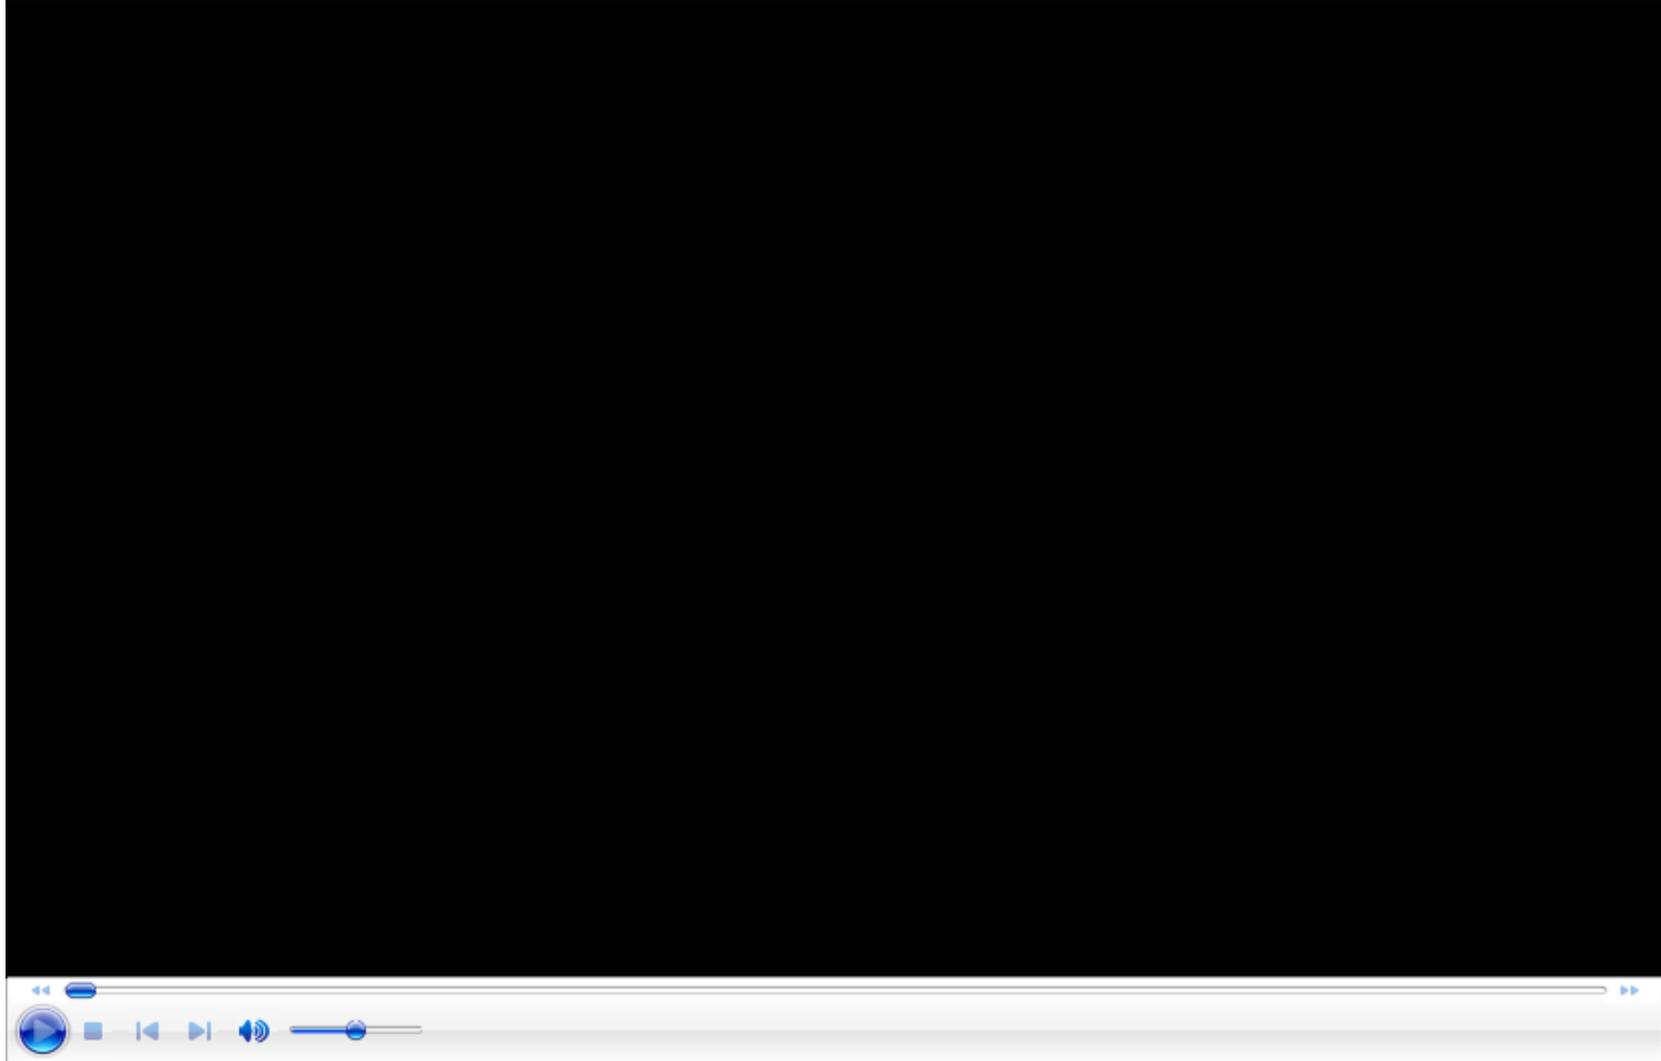
## Bildschirme

### Es gibt verschiedene Arten von Bildschirmen, die wichtigsten sind...

- CRT-Bildschirme (*CRT = Cathode Ray Tube* → *Kathodenstrahlröhre*)
  - > Ein **Elektronenstrahl** bringt Phosphor-Pixel zum Leuchten
    - > Helligkeit des Pixels ist abhängig von der Intensität des Elektronenstrahls
- Plasma-Bildschirme
  - > „Anzünden“ eines **Plasma** in winzigen Zellen bringt entsprechende Pixel zum Leuchten
  - > Helligkeit des Pixels ist abhängig von der Leuchtdauer des Plasmas
- LCD-Bildschirme (*LCD = Liquid Cristal Display* → *Flüssigkristalle*)
  - > Gleichmäßige Hintergrundbeleuchtung wird durch Flüssigkristalle **polarisiert**
    - > Helligkeit des Pixels ist abhängig von der Polarisation

# Eingabe- und Ausgabegeräte

## Alles zusammen



# 8 - Betriebssysteme

---

Allgemeines, Speicherverwaltung

# Lessons Learned

## Muss ich mir das alles merken?

---

### **In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können**

- Aufgaben eines Betriebssystems
  - > Scheduling
  - > Speicherverwaltung
- Bekannte Betriebssysteme benennen

# Betriebssysteme

## Windows, oder was?

---

### Was ist ein Betriebssystem?

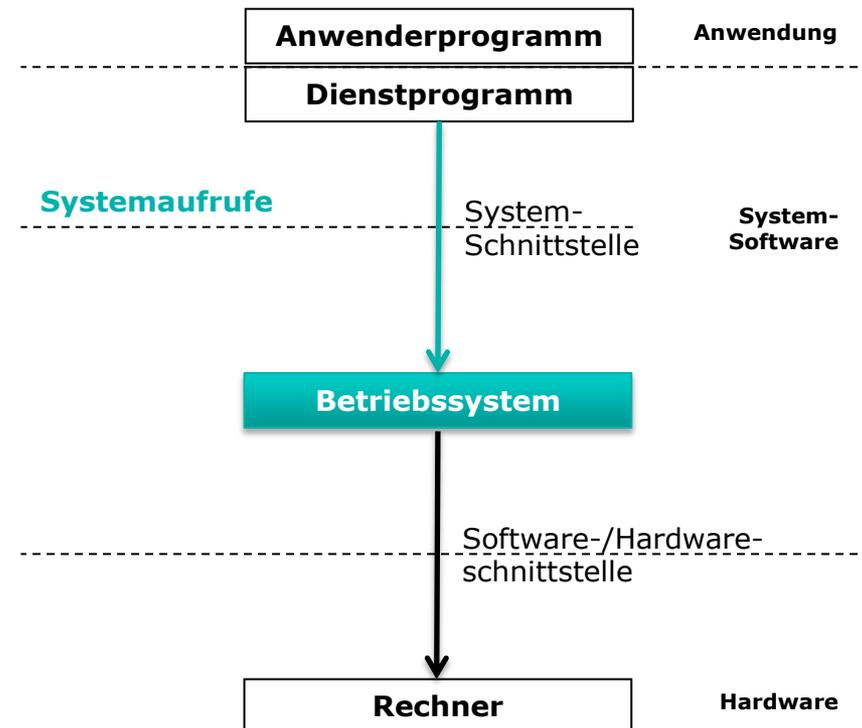
- Versuch einer Definition
  - > „Als Betriebssystem bezeichnet man die Software, die den Ablauf von Programmen auf der Hardware steuert und die vorhandenen Betriebsmittel verwaltet.“
- Zu einem Betriebssystem gehört ggf. auch die Bereitstellung von Dienstprogrammen
  - > Einfacher Editor, Übersetzer, Datenfernverarbeitung, Netzverwaltung, ...
- Betriebssysteme stellen für den Anwender die Schnittstelle zur Maschine dar

# Betriebssysteme

## Eigenschaften eines Betriebssystems

### Das Betriebssystem ist ein grundlegendes Systemprogramm

- Das Betriebssystem liegt als **Softwareschicht** zwischen **Hardware** und **Anwendungen**
- Die Komplexität der Hardware wird durch das Betriebssystem vor dem Anwender verborgen
  - > Hardware Abstraction Layer (HAL)



### Hohe Zuverlässigkeit

- Korrektheit
- Sicherheit
- Verfügbarkeit
- Robustheit
- Schutz von Benutzerdaten

### Hohe Leistung

- Gute Auslastung der Systemressourcen
- Kleiner Verwaltungsaufwand
- Hoher Durchsatz
- Kurze Reaktionszeit

### Hohe Benutzerfreundlichkeit

- Angepasste Funktionalität
- Einfache Benutzerschnittstelle
- Hilfestellung

### Einfache Wartbarkeit

- Einfache Upgrades
- Einfacher Erweiterbarkeit
- Portierbarkeit

**... und geringe Kosten!**

# Betriebssysteme

## Stapelverarbeitungssysteme

---

### **Das Betriebssystem arbeitet nicht interaktiv, sondern nimmt nur Jobs von Benutzern an**

- Jobs werden in eine Job-Queue gelegt und nacheinander abgearbeitet
- Jobs erfordern keinerlei Benutzerinteraktion, d.h. laufen vollständig autonom ab
- Ausgabe der Ergebnisse eines Jobs erfolgt über Dateien oder sonstige Ausgabegeräte (Drucker, ...)
  - > Ausgabe über den Monitor ist nicht sinnvoll...

# Betriebssysteme

## Interaktive Systeme / Dialogsysteme

---

### Das Betriebssystem arbeitet interaktiv

- Programme werden durch Benutzereingaben gesteuert
  - > Tastatureingaben
  - > Mauseingaben
  - > ...
- Ausgabe der Ergebnisse eines Programms kann über jedes beliebige Ausgabegerät erfolgen
  - > Im Gegensatz zu Stapelverarbeitungssystemen, sind auch Ausgaben auf dem Monitor sinnvoll

## Echtzeitsysteme sind reaktive Systeme, welche über Sensoren und Aktoren mit der Umwelt interagieren

- Aktionen erfolgen als Reaktion auf eine Änderung von Sensorwerten
- Es gibt zeitliche Anforderungen an das System
  - > Harte Zeitanforderungen
    - > Reaktionen **müssen** innerhalb eines definierten Zeitfensters erfolgen
    - > Das Überschreiten des Zeitfensters macht das Ausführen / Beenden der Reaktion überflüssig
  - > Weiche Zeitanforderungen
    - > Überschreitungen des Zeitfensters werden toleriert, **können** aber zur Abnahme der Ergebnisqualität führen

# Betriebssysteme

## Betriebsmittel

---

### Ein Betriebssystem hat viele Aufgaben ...

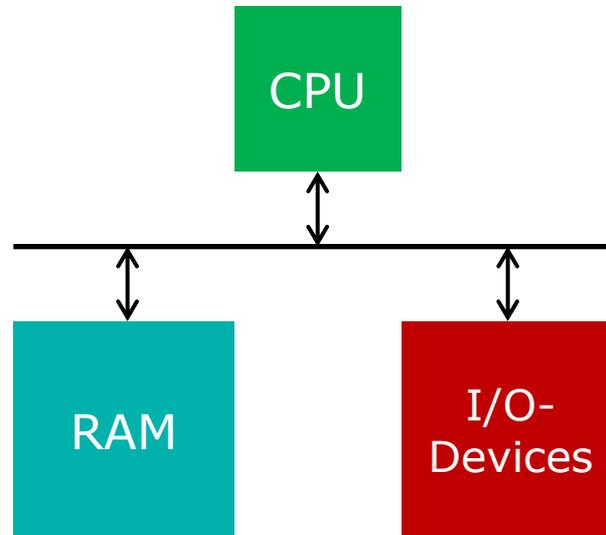
- Betriebsmittelverwaltung
- Prozessverwaltung
- Speicherverwaltung
- Dateiverwaltung
- Rechteverwaltung
- ...

# Betriebssysteme

## Betriebsmittel

### Betriebsmittel sind ...

- Aktive, zeitlich aufteilbare
- Passive, nur exklusiv nutzbare
- Passive, räumlich aufteilbare



# Betriebssysteme

## Betriebsmittelverwaltung

### Die Betriebsmittelverwaltung besteht im wesentlichen aus der ...

- ... Zuteilung von Ein- und Ausgabegeräten
  - > Regelung des Zugriffs einzelner Programme auf nur exklusiv nutzbare Betriebsmittel
  - > Konfliktvermeidung
- ... Verwaltung des Dateisystems
  - > Bearbeitung von Dateizugriffen aus Programmen heraus
    - > Existiert die angeforderte Datei?
    - > Darf der ausführende User diese Datei öffnen?
    - > ...

} Rechteverwaltung

# Betriebssysteme

## Prozesse / Prozessverwaltung

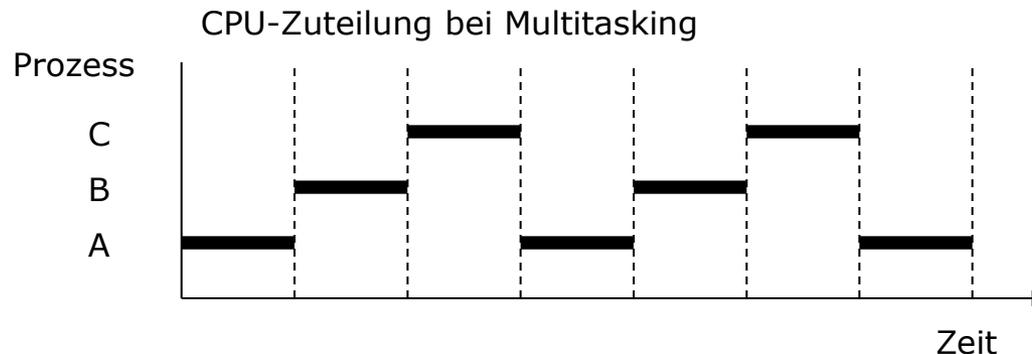
---

### Ein Prozess ...

- ... ist die Abstraktion eines sich in Ausführung befindlichen Programms
  - > Ein Prozess besteht aus den **Programmbefehlen** und dem **Prozesskontext**
  - > Der Prozesskontext besteht aus dem privaten Adressraum des Programms, geöffnete Streams (Dateien, Sockets, ...) und abhängigen Prozessen
- ... wird über die **Prozessverwaltung** gesteuert
  - > Die Prozessverwaltung steuert die Zuteilung von Betriebsmitteln an den Prozess
    - > CPU
    - > Speicher
    - > Ein- und Ausgabegeräte
    - > ...

## Der Prozessor kann zwischen mehreren Prozessen hin und her geschaltet werden

- Im Allgemeinen wird sogenanntes **preemptives Multitasking** verwendet
  - > Das Betriebssystem entscheidet, wann welcher Prozess zur Ausführung kommt
  - > Jeder Prozess wird für einige Millisekunden (Zeitscheibe, timeslice) ausgeführt
  - > Der Benutzer erhält dadurch den Eindruck von Parallelität



# Betriebssysteme

## Kooperatives Multitasking

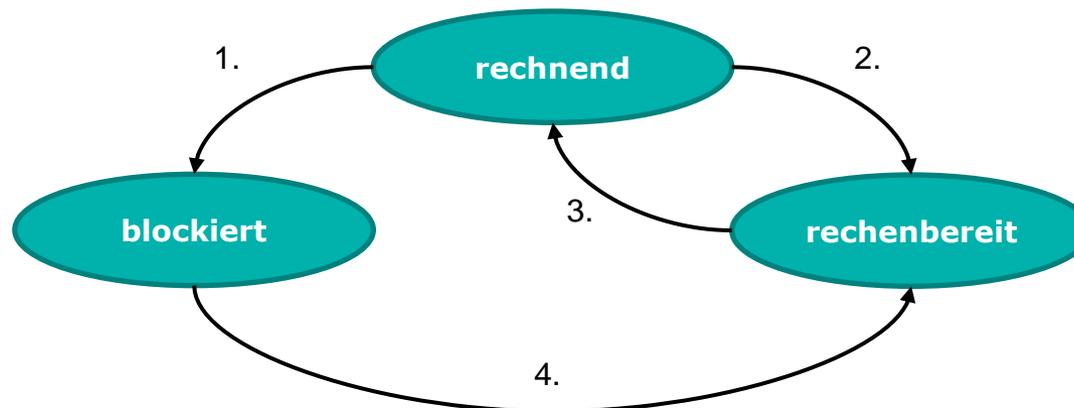
---

**Im Gegensatz zum preemptiven Multitasking bestimmt ein Prozess selbst, wann er den Prozessor an andere Prozesse abgibt**

- Nachteile
  - > Ein einzelner Prozess kann bei bestimmten Fehlern, z.B. Endlosschleifen, das gesamte System zum Absturz bringen
  - > Selbst das Betriebssystem kann nicht mehr rechnen, wenn ein Prozess den Prozessor nicht wieder freigibt

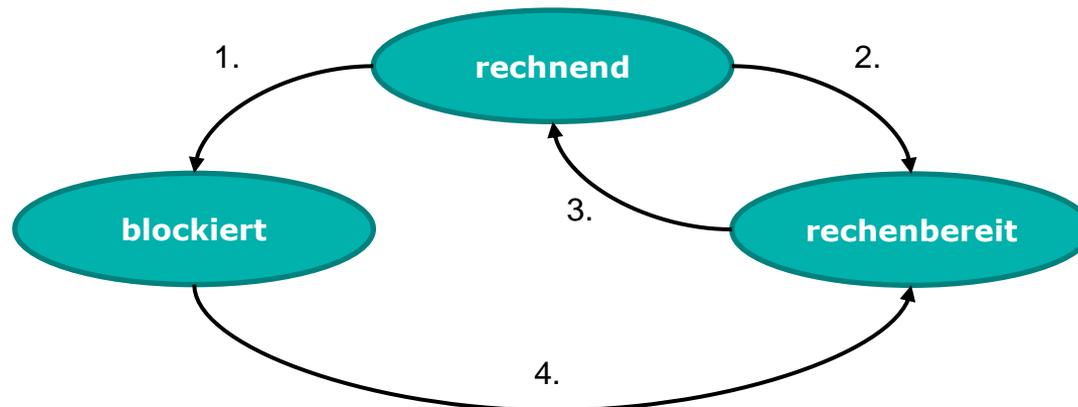
### Ein Prozess kann sich in folgenden Zuständen befinden

- **Rechnen:** Der Prozessor ist dem Prozess zugeteilt
- **Blockiert:** Der Prozess kann nicht ausgeführt werden, bis ein externes Ereignis auftritt
- **Rechenbereit:** Der Prozess ist ausführbar, aber der Prozessor ist einem anderen Prozess zugeteilt



## Der **Prozessscheduler** organisiert die **Übergänge** der Prozesse **zwischen den einzelnen Zuständen**

1. Der Prozess wartet, z.B. auf Eingabe des Benutzers
2. Die Zeitscheibe des Prozesses ist abgelaufen oder ein höher priorisierter Prozess muss ausgeführt werden
3. Der Prozess bekommt eine neue Zeitscheibe zugeteilt
4. Das Ereignis, auf welches ein Prozess nach 1. gewartet hat, ist eingetreten



### Ein guter Scheduling-Algorithmus muss einige Anforderungen erfüllen

- Fairness: Jeder Prozess erhält einen gerechten Anteil der CPU-Zeit
- Effizienz: Die CPU und andere Ressourcen sind möglichst ausgelastet
- Einhaltung der Systemregeln
- Weitere Anforderungen hängen vom Einsatzgebiet ab
  - > Stapelverarbeitungssysteme
  - > Dialogsysteme
  - > Echtzeitsysteme

# Betriebssysteme

## Scheduling auf Stapelverarbeitungssystemen

---

### Zusätzlich Anforderungen an den Scheduler auf einem Stapelverarbeitungssystem

- Möglichst hohe CPU-Auslastung
  - > Es sollte nicht vorkommen, dass die CPU Leertakte hat
- Job-Durchsatz
  - > Die Anzahl der bearbeiteten Aufgaben pro Zeiteinheit sollte maximal sein
- Minimale Durchlaufzeit
  - > Die Zeit, welche ein Job von Ankunft in der Job-Queue bis zur Fertigstellung des Jobs benötigt, sollte minimal sein

# Betriebssysteme

## Scheduling auf Dialogsystemen

---

### Zusätzlich Anforderungen an den Scheduler auf einem Dialogsystem

- Kurze Antwortzeiten
  - > Der Benutzer sollte nicht das Gefühl haben, auf Reaktionen des Systems, z.B. auf Mausklicks oder Tastatureingaben, warten zu müssen
  - > Prozesse, die Interaktion mit dem Benutzer erfordern, sollten vor anderen Prozessen bevorzugt werden
- Proportionalität
  - > Die Antwortzeit verschiedener Prozesse sollte mit der Benutzererwartung übereinstimmen
  - > Aus Benutzersicht „einfache“ Aufgaben sollten schneller erledigt werden, als aus Benutzersicht „schwierige“ Aufgaben

# Betriebssysteme

## Scheduling auf Echtzeitsystemen

---

### Zusätzlich Anforderungen an den Scheduler auf einem Echtzeitsystem

- Einhaltung von Zeitfenstern
  - > Der Scheduler muss einen Überblick über die Zeitfenster verschiedener Prozesse haben und diesen entsprechend Rechenzeit zuweisen
- Vorhersagbarkeit
  - > Das System muss deterministisch agieren / reagieren

### Einige bekannte Scheduling-Strategien sind...

- First-Come, First Serve (Stapelverarbeitungssysteme)
- Shortest Job First (Stapelverarbeitungssysteme)
- Prioritätsscheduling (alle Systeme)
- Round Robin (alle Systeme)
  - > Alle laufenden Prozesse bekommen der Reihe nach eine (gleichgroße) Zeitscheibe auf der CPU zugeteilt

# Betriebssysteme

## First Come, First Serve

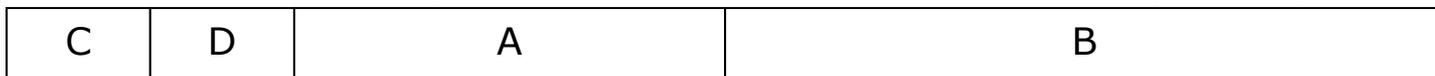
### Die Prozesse werden nach der Reihenfolge ihres Einfügens in die Job-Queue eines Stapelverarbeitungssystems bearbeitet

- Die Zuteilung des Prozessors an andere Prozesse findet nur statt, wenn ein laufender Prozess zu warten beginnt oder sich beendet
- Jeder Prozess kommt garantiert an die Reihe
- Kurze Prozesse müssen unter Umständen sehr lange warten, bis sie ausgeführt werden
  - > Unverhältnismäßig langes Warten auf das Ergebnis



### Die Prozesse werden aufsteigend nach ihrer geschätzten Ausführungszeit bearbeitet

- Große Prozesse kommen möglicherweise nie an die Reihe, wenn immer wieder kleinere Prozesse in die Job-Queue eingefügt werden
- Die Wartezeit auf das Ergebnis eines Prozesses verhält sich in etwa proportional zur Ausführungszeit des Prozesses



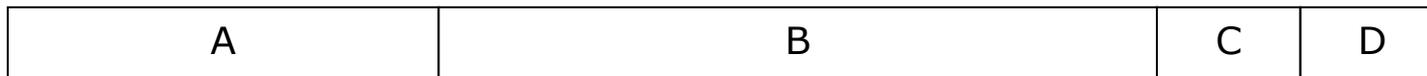
# Betriebssysteme

## Beispiel: FCFS vs. SJF

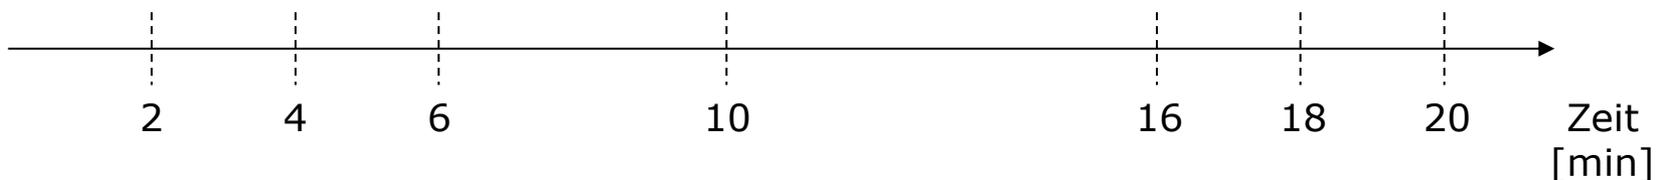
**Gegeben sind 4 Prozesse mit den folgenden Ausführungszeiten**

- Prozess A: 6 Minuten
- Prozess B: 10 Minuten
- Prozess C: 2 Minuten
- Prozess D: 2 Minuten

First-Come, First-Serve



Shortest Job First



# Betriebssysteme

## Beispiel: FCFS vs. SJF

### Die **mittlere Verweilzeit** berechnet sich dann wie folgt

- First Come, First Serve

- > Prozess A: 6 Minuten
- > Prozess B: 16 Minuten
- > Prozess C: 18 Minuten
- > Prozess D: 20 Minuten
- > Mittlere Verweilzeit:  $\frac{6+16+18+20}{4} = 15$  Minuten

- Shortest Job First

- > Prozess A: 10 Minuten
- > Prozess B: 20 Minuten
- > Prozess C: 2 Minuten
- > Prozess D: 4 Minuten
- > Mittlere Verweilzeit:  $\frac{10+20+2+4}{4} = 9$  Minuten

### **Jedem laufenden Prozess wird eine Priorität zugewiesen**

- Zuweisung der Priorität wird vom Betriebssystem gesteuert
  - > Es gibt dynamische und statische Zuweisung
- Es wird immer dem Prozess mit der höchsten Priorität eine Zeitscheibe zugeteilt
- Neu hinzukommende Prozesse hoher Priorität verdrängen rechnende Prozesse niedriger Priorität
  - > Auch der Übergang nach Rechenbereit eines hoch priorisierten Prozesses verdrängt niedrig priorisierte Prozesse

### Es gibt zwei Arten von Prioritätszuweisung

- Statische Priorität
  - > Jeder Prozess erhält bei seinem Start eine feste Priorität
  - > Der Prozess mit der höchsten Priorität bekommt als nächstes eine Zeitscheibe zugeteilt
    - > Gibt es mehrere Prozesse mit der gleichen Priorität werden diese im Round-Robin-Verfahren bearbeitet
  - > Wird oft in Echtzeitsystemen verwendet
- Dynamische Priorität
  - > Jedem Prozess wird eine Anfangspriorität zugeordnet
  - > Der Prozess mit der höchsten Priorität bekommt als nächstes eine Zeitscheibe zugeteilt
    - > Die Prioritäten der Prozesse werden dynamisch geändert
    - > Es gibt verschiedene Verfahren der Realisierung

# Betriebssysteme

## Multilevel-Feedback-Queue

---

### Die MFQ ist ein Beispiel für dynamische Prioritätszuweisung

- Die Prozesse werden anhand ihres bisherigen Ressourcenverbrauchs priorisiert
- Es werden mehrere FIFO-Queues benutzt
  - > Neue Prozesse werden in der höchst priorisierten Queue eingefügt
- Prioritäten werden abhängig vom Verhalten des Prozesses geändert
  - > Der Prozess gibt den Prozessor freiwillig ab
    - > Der Prozess wird in dieselbe Queue wieder eingefügt
  - > Der Prozess verbraucht seine gesamte Zeitscheibe
    - > Der Prozess wird in der nächst niedriger priorisierten Queue wieder eingefügt

## Die Speicherverwaltung eines Betriebssystems ermöglicht den Prozessen den Zugriff auf den Arbeitsspeicher des Computers

- Der Zugriff soll effizient, komfortabel und sicher sein
  - > Der Zugriff auf den Speicherbereich eines anderen Prozesses muss durch das Betriebssystem explizit unterbunden werden
- Es wird zwischen realer und virtueller Speicherverwaltung unterschieden
  - > Welche der beiden Varianten verwendet wird hängt vom Einsatzgebiet des Systems ab

# Betriebssysteme

## Reale Speicherverwaltung

---

### Der Arbeitsspeicher wird aus den Prozessen heraus direkt adressiert

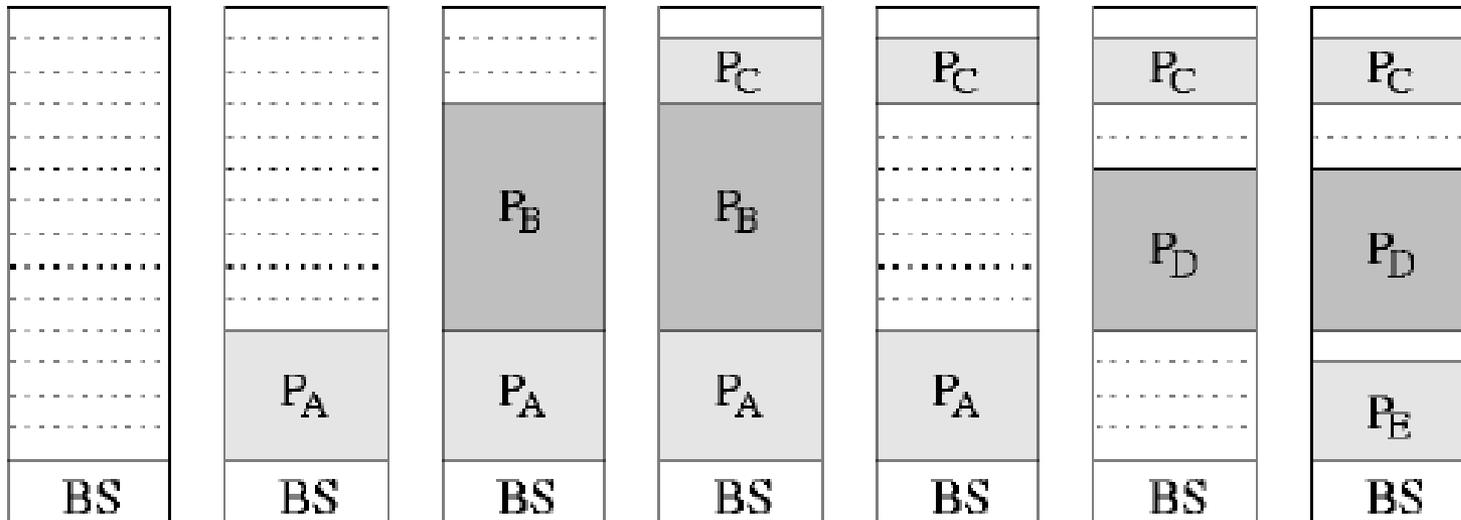
- Die Größe des physikalischen Speichers begrenzt die Anzahl der gleichzeitig ausführbaren Prozessen
  - > Nutzung von **Swapping**, um mehr Prozesse „parallel“ betreiben zu können
- Probleme realer Speicherverwaltung
  - > **Fragmentierung** des Speichers
  - > Suche nach freien Speicherblöcken mittels Belegungstabelle sehr aufwändig

# Betriebssysteme

## Fragmentierung des Speichers

### Beim Ersetzen von Speicherblöcken können viele kleine, freie Bereiche im Speicher entstehen

- Neue Prozesse finden keine ausreichend großen, zusammenhängenden Bereiche mehr



# Betriebssysteme

## Reale Speicherverwaltung

---

### Beim Starten eines Prozesses wird dieser in einen freien Speicherblock geladen

- First Fit
  - > Wählt den ersten, freien Speicherbereich, welcher groß genug ist
  - > Diese Variante ist schnell, verschwendet aber möglicherweise große Blöcke an kleine Prozesse
- Next Fit
  - > Funktioniert wie First Fit, startet aber nicht am Anfang des Speichers, sondern an der Stelle, wo der letzte Prozesse eingefügt wurde
- Best Fit
  - > Wählt den kleinstmöglichen, freien Speicherbereich
  - > Verteilt Speicher gut, aber die Suche nach freien Speicherblöcken ist sehr aufwändig

### Nachteile reale Speicherverwaltung

- Nutzung des Speicherplatzes
  - > Es muss Platz für das gesamte Programm und die Daten gefunden werden, obwohl diese wahrscheinlich nicht alle gleichzeitig benötigt werden
- Beschränkung des Speicherplatzes
  - > Es kann insgesamt nicht mehr Speicher genutzt werden, als physikalisch vorhanden ist
- Belegung des Speichers
  - > Die Anforderung zusammenhängende Speicherblöcke für Prozesse zu finden, verschärft das Problem der Fragmentierung

# Betriebssysteme

## Virtuelle Speicherverwaltung

---

### Virtuelle Speicherverwaltung behebt die Nachteile realer Speicherverwaltung

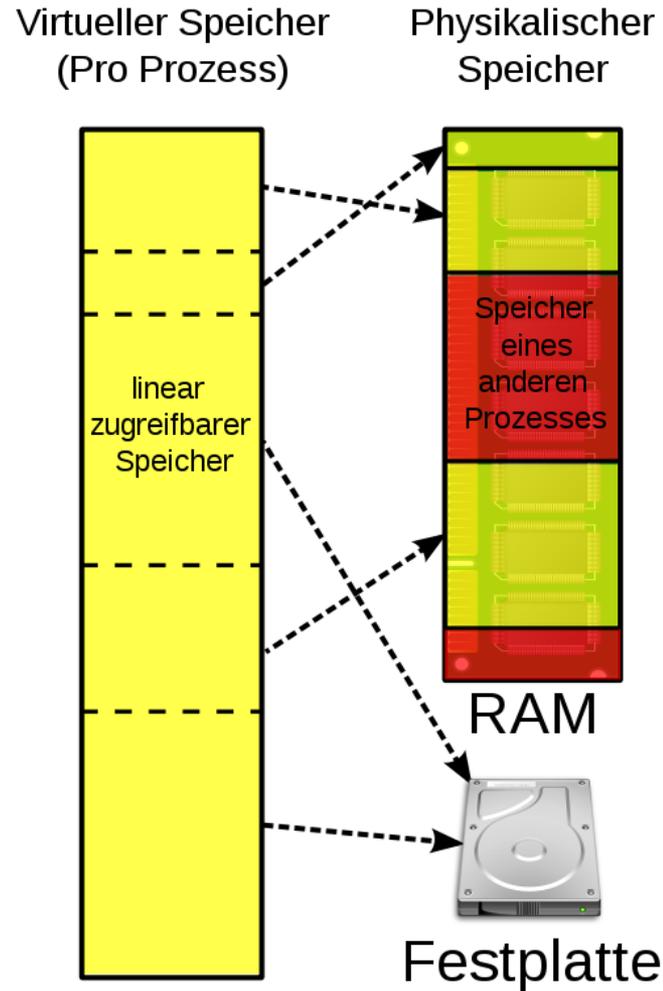
- Jedem Prozess wird ein scheinbar zusammenhängender Speicherbereich der Größe  $n$  zur Verfügung gestellt
  - > Tatsächlich besteht der Speicher des Prozesses aus nicht zwangsläufig zusammenhängenden **virtuellen Pages**
  - > Der Prozess kann seinen Speicher mit den **virtuellen Adressen 0** bis  $(n - 1)$  adressieren
- Die Gesamtheit aller virtuellen Adressen wird als **virtueller Adressraum** bezeichnet

### **Virtuelle Pages werden rechnerintern auf physikalisch vorhandene Pages gleicher Größe abgebildet**

- Die physikalischen Pages können irgendwo im Arbeitsspeicher oder in einer Auslagerungsdatei auf der Festplatte liegen
- Beim Zugriff eines Prozesses auf eine **virtuelle Speicheradresse**...
  - > ... wird zunächst die zu dieser Adresse gehörige **virtuelle Page** ermittelt
  - > Anschließend wird die zu dieser virtuellen Page gehörige **physikalische Page** ermittelt
    - > Die Zuordnung von virtuellen und physikalischen Pages und deren Ablageort werden in der sogenannten **Pagetable** gespeichert
  - > Die **relative Speicheradresse** innerhalb einer Page ist in virtuellen und physikalischen Pages dieselbe

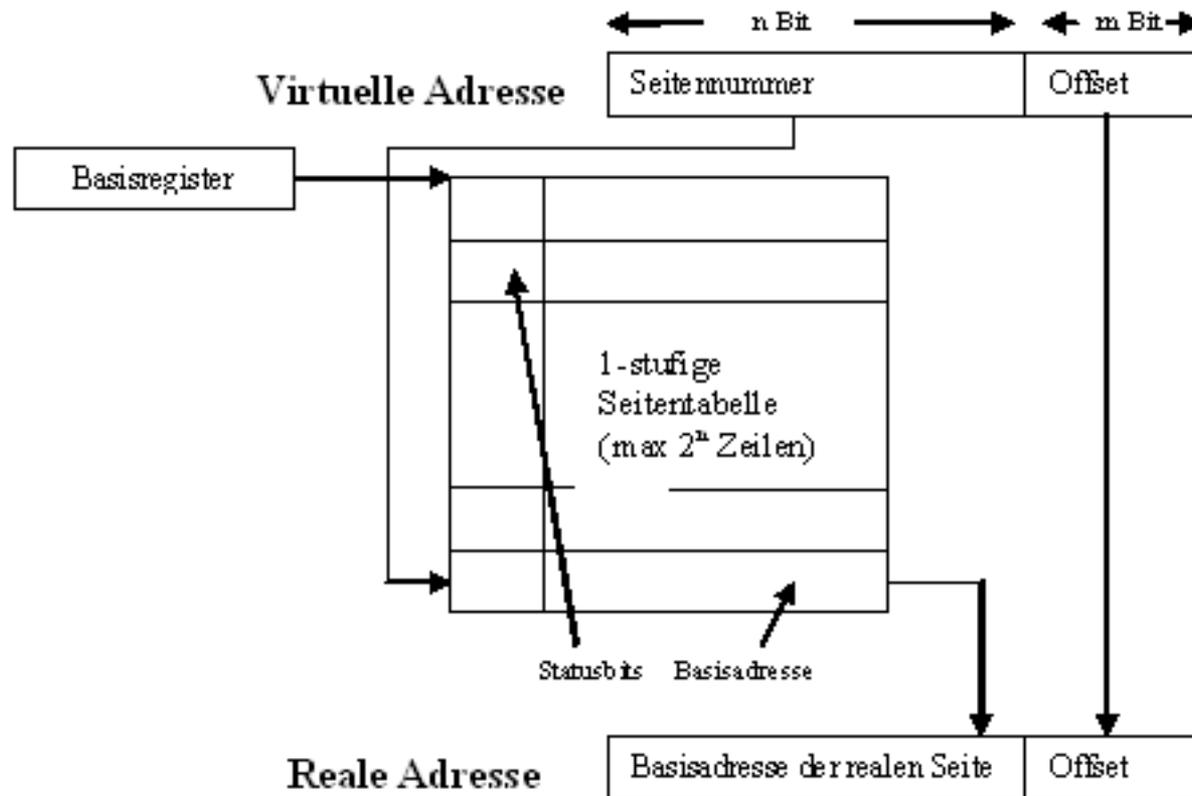
# Betriebssysteme

## Virtuelle Pages



Quelle: [http://de.wikipedia.org/wiki/Virtuelle\\_Speicherverwaltung](http://de.wikipedia.org/wiki/Virtuelle_Speicherverwaltung)

### Berechnung der physikalischen Speicheradresse



Quelle: <http://de.wikipedia.org/wiki/Paging>

### Berechnung der physikalischen Speicheradresse:

- Beispiel Adresslänge 16 Bit, 8 Bit Offset (low) und 8 Bit Seitennummer (high)

> Seitentabelle:

| Eintrag | Gültig | Seitenrahmen |
|---------|--------|--------------|
| 00      | Nein   | -            |
| 01      | Ja     | 0x17         |
| 02      | Ja     | 0x20         |
| 03      | Ja     | 0x08         |
| 04      | Nein   | -            |
| 05      | Ja     | 0x10         |

> Zu übersetzen:

| virtuelle Adresse | physikalische Adresse         |
|-------------------|-------------------------------|
| 0x083A            | ungültig (Seite 8 ex. nicht)  |
| 0x01FF            | 0x17FF (Seite 1, Rahmen 0x17) |
| 0x0505            | 0x1005 (Seite 5, Rahmen 0x10) |
| 0x043A            | ungültig (Seite 4 ungültig)   |

# Betriebssysteme

## Paging on Demand

---

**Zu einem Prozess gehörige, jedoch aktuell nicht genutzte Pages werden auf den Hintergrundspeicher, z.B. Festplatte, ausgelagert**

- Es wird Arbeitsspeicher für andere Prozesse freigegeben
- Braucht der Prozess zu einem späteren Zeitpunkt wieder, muss sie erneut in den Arbeitsspeicher geladen werden
  - > Es muss eventuell eine andere Page aus dem Arbeitsspeicher verdrängt werden
  - > Es gibt mehrere Möglichkeiten zu bestimmen, welche Page aus dem Arbeitsspeicher verdrängt wird

# Betriebssysteme

## Verdrängungsstrategien

---

### Ähnlich wie beim Caching gibt es auch hier verschiedene Verdrängungsstrategien

- FIFO (First-In, First-Out)
  - > Die Page, welche bereits am längsten im Speicher liegt, wird verdrängt
- Least recently / frequently used (LRU / LFU)
  - > Die Page welche am längst nicht mehr bzw. am seltensten zugegriffen wurde, wird verdrängt
- Unversehrtheit der Speicherseite
  - > Es werden Pages ausgelagert, die sich im Arbeitsspeicher nicht geändert haben, sodass Schreiboperationen auf die Festplatte entfallen

# Betriebssysteme

## Verdrängungsstrategien

---

### Ähnlich wie beim Caching gibt es auch hier verschiedene Verdrängungsstrategien

- FIFO (First-In, First-Out)
  - > Die Page, welche bereits am längsten im Speicher liegt, wird verdrängt
- Least recently / frequently used (LRU / LFU)
  - > Die Page welche am längst nicht mehr bzw. am seltensten zugegriffen wurde, wird verdrängt
- Unversehrtheit der Speicherseite
  - > Es werden Pages ausgelagert, die sich im Arbeitsspeicher nicht geändert haben, sodass Schreiboperationen auf die Festplatte entfallen

# Betriebssysteme

## Verdrängungsstrategien

### FIFO-Strategie

- Seitenanforderungen: 1, 2, 3, 4, 1, 2, 5, 1, 2, 3, 4, 5

| Referenzfolge                                              |        | 1 | 2 | 3 | 4 | 1 | 2 | 5 | 1 | 2 | 3 | 4 | 5 |
|------------------------------------------------------------|--------|---|---|---|---|---|---|---|---|---|---|---|---|
| Arbeitsspeicher                                            | Page 1 | 1 | 1 | 1 | 4 | 4 | 4 | 5 | 5 | 5 | 5 | 5 | 5 |
|                                                            | Page 2 |   | 2 | 2 | 2 | 1 | 1 | 1 | 1 | 1 | 3 | 3 | 3 |
|                                                            | Page 3 |   |   | 3 | 3 | 3 | 2 | 2 | 2 | 2 | 2 | 4 | 4 |
| Kontrollzustand<br>(wie lange im<br>Speicher in<br>Zyklen) | Page 1 | 0 | 1 | 2 | 0 | 1 | 2 | 0 | 1 | 2 | 3 | 4 | 5 |
|                                                            | Page 2 | - | 0 | 1 | 2 | 0 | 1 | 2 | 3 | 4 | 0 | 1 | 2 |
|                                                            | Page 3 | - | - | 0 | 1 | 2 | 0 | 1 | 2 | 3 | 4 | 0 | 1 |

**Anzahl Einlagerungen: 9**

# Betriebssysteme

## Verdrängungsstrategien

### LRU-Strategie

- Seitenanforderungen: 1, 2, 3, 4, 1, 2, 5, 1, 2, 3, 4, 5

| Referenzfolge                                                |        | 1 | 2 | 3 | 4 | 1 | 2 | 5 | 1 | 2 | 3 | 4 | 5 |
|--------------------------------------------------------------|--------|---|---|---|---|---|---|---|---|---|---|---|---|
| Arbeitsspeicher                                              | Page 1 | 1 | 1 | 1 | 4 | 4 | 4 | 5 | 5 | 5 | 3 | 3 | 3 |
|                                                              | Page 2 |   | 2 | 2 | 2 | 1 | 1 | 1 | 1 | 1 | 1 | 4 | 4 |
|                                                              | Page 3 |   |   | 3 | 3 | 3 | 2 | 2 | 2 | 2 | 2 | 2 | 5 |
| Kontrollzustand<br>(wie lange nicht<br>drauf<br>zugegriffen) | Page 1 | 0 | 1 | 2 | 0 | 1 | 2 | 0 | 1 | 2 | 0 | 1 | 2 |
|                                                              | Page 2 | - | 0 | 1 | 2 | 0 | 1 | 2 | 0 | 1 | 2 | 0 | 1 |
|                                                              | Page 3 | - | - | 0 | 1 | 2 | 0 | 1 | 2 | 0 | 1 | 2 | 0 |

**Anzahl Einlagerungen: 10**

# Betriebssysteme

## Verdrängungsstrategien

### „Future“-Strategie

- Seitenanforderungen: 1, 2, 3, 4, 1, 2, 5, 1, 2, 3, 4, 5

| Referenzfolge                                                  |        | 1 | 2 | 3 | 4 | 1 | 2 | 5 | 1 | 2 | 3 | 4 | 5 |
|----------------------------------------------------------------|--------|---|---|---|---|---|---|---|---|---|---|---|---|
| Arbeitsspeicher                                                | Page 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 1 | 3 | 4 | 4 |
|                                                                | Page 2 |   | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 | 2 |
|                                                                | Page 3 |   |   | 3 | 4 | 4 | 4 | 5 | 5 | 5 | 5 | 5 | 5 |
| Kontrollzustand<br>(in wie viel<br>Zyklen wird<br>zugegriffen) | Page 1 | 4 | 3 | 2 | 1 | 3 | 2 | 1 | - | - | - | - | - |
|                                                                | Page 2 | - | 4 | 3 | 2 | 1 | 3 | 2 | 1 | - | - | - | - |
|                                                                | Page 3 | - | - | 7 | 7 | 6 | 5 | 5 | 4 | 3 | 2 | 1 | - |

**Anzahl Einlagerungen: 7**

# Betriebssysteme

## Verdrängungsstrategien

### Übung - Strategie: FIFO

- Seitenanforderungen: 1, 4, 2, 5, 3, 2, 1, 4, 2, 5

| Referenzfolge                                                |        | 1 | 4 | 2 | 5 | 3 | 2 | 1 | 4 | 2 | 5 |
|--------------------------------------------------------------|--------|---|---|---|---|---|---|---|---|---|---|
| <b>Arbeitsspeicher</b>                                       | Page 1 |   |   |   |   |   |   |   |   |   |   |
|                                                              | Page 2 |   |   |   |   |   |   |   |   |   |   |
|                                                              | Page 3 |   |   |   |   |   |   |   |   |   |   |
| <b>Kontrollzustand<br/>(Wie lange schon<br/>im Speicher)</b> | Page 1 |   |   |   |   |   |   |   |   |   |   |
|                                                              | Page 2 |   |   |   |   |   |   |   |   |   |   |
|                                                              | Page 3 |   |   |   |   |   |   |   |   |   |   |

### Anzahl Einlagerungen:

# Betriebssysteme

## Verdrängungsstrategien

### Übung - Strategie: FIFO

- Seitenanforderungen: 1, 4, 2, 5, 3, 2, 1, 4, 2, 5

| Referenzfolge                                       |        | 1 | 4 | 2 | 5 | 3 | 2 | 1 | 4 | 2 | 5 |
|-----------------------------------------------------|--------|---|---|---|---|---|---|---|---|---|---|
| Arbeitsspeicher                                     | Page 1 | 1 | 1 | 1 | 5 | 5 | 5 | 5 | 4 | 4 | 4 |
|                                                     | Page 2 | - | 4 | 4 | 4 | 3 | 3 | 3 | 3 | 2 | 2 |
|                                                     | Page 3 | - | - | 2 | 2 | 2 | 2 | 1 | 1 | 1 | 5 |
| Kontrollzustand<br>(Wie lange schon<br>im Speicher) | Page 1 | 0 | 1 | 2 | 0 | 1 | 2 | 3 | 0 | 1 | 2 |
|                                                     | Page 2 | - | 0 | 1 | 2 | 0 | 1 | 2 | 3 | 0 | 1 |
|                                                     | Page 3 | - | - | 0 | 1 | 2 | 3 | 0 | 1 | 2 | 0 |

**Anzahl Einlagerungen: 9**

**Wenn einem Prozess nicht genügend Pages zur Verfügung stehen, kann es passieren, dass sehr oft Pages nachgeladen / ersetzt werden müssen**

- Der Prozess verbringt mehr Zeit mit dem Warten auf den Speicher, als mit der eigentlichen Ausführung
- Ursachen
  - > Prozesse ohne Lokalität: Random Access auf große Speicherbereiche
  - > Zu viele Prozesse
  - > Schlechter Ersetzungsstrategie
- Lösung
  - > Zuteilung einer genügend großen Anzahl von Pages
  - > Begrenzung der Prozessanzahl
  - > Codeoptimierung, sodass der Prozess lokaler arbeitet

# Betriebssysteme

## Lokale vs. Globale Ersetzung

---

### Es gibt zwei mögliche Varianten Pages zu ersetzen

- Lokale Ersetzung
  - > Ein Prozess ersetzt immer nur seine eigenen Pages
    - > Statische Zuteilung von Pages an Prozesse
  - > Nachladen / Ersetzen von Pages liegt in der Verantwortung der Prozesse
- Globale Ersetzung
  - > Ein Prozess ersetzt auch Pages anderer Prozesse
    - > Dynamisches Verhalten der Prozesse kann berücksichtigt werden
  - > Im Schnitt bessere Effizienz, da ungenutzte Pages von anderen Prozessen verwendet werden können

### **Virtuelle Speicherverwaltung sorgt implizit dafür, dass mehrere Prozesse nicht gegenseitig auf ihre Speicherbereiche zugreifen können**

- Versucht ein Prozess auf eine Adresse zuzugreifen, für welche er selbst keinen Speicher allokiert hat, wird die dazugehörige Page nicht gefunden
  - > Es tritt ein **Segmentation Fault** auf
- Gezielt auf den Speicher anderer Prozesse kann nicht zugegriffen werden, da erst bei der Umsetzung der virtuellen Adresse der physikalische Speicher referenziert wird

# Betriebssysteme

## Speicherbereinigung

---

**Wird in einem Prozess Speicher dynamisch zur Laufzeit allokiert, muss dieser auch irgendwann wieder freigegeben werden**

- Wird der Speicher nicht freigegeben, steht dem Prozess irgendwann kein Speicher mehr zur Verfügung
- Der Prozess kann dies selbst tun
  - > z.B. in C/C++ mit `free()` oder `delete()`
  - > Volle Kontrolle über belegten Speicher, aber kompliziert
- Es kann eine automatische Speicherbereinigung (engl. **Garbage Collection**) verwendet werden
  - > z.B. in JAVA
  - > Ist bequem, entzieht dem Programmierer aber die Kontrolle über den Speicher

### Vorteile der Speicherbereinigung

- Einige Programmierfehler im Umgang mit Speicher (De-)Allokation können vermieden werden
  - > Doppelte Freigabe von Speicher
  - > Zugriff auf bereits freigegebene Objekte
- Das Programm läuft möglicherweise schneller, da Speicher gezielt und gesammelt freigegeben werden kann

### Nachteile der Speicherbereinigung

- Der Zeitpunkt der Garbage Collection ist nicht deterministisch und hängt von diversen Faktoren ab
  - > z.B. Belegung des Speichers
  - > Der Algorithmus zur Berechnung des Startzeitpunkts variiert von Plattform zu Plattform (z.B. von C# von JAVA)
- Aufgrund des non-Determinismus ist eine Garbage Collection nicht ohne Weiteres für Echtzeitsysteme geeignet

## DOS = Disk Operating System

- Reale Speicherverwaltung
- Kooperatives Scheduling
- Kein Multitasking
- Kommandozeilen-basiertes Dialogsystem

```
Starten von MS-DOS...
```

```
HIMEM testet den erweiterten Speicher...beendet.
```

```
This driver is provided by Oak Technology, Inc..
OTI-91X ATAPI CD-ROM device driver, Rev D91XV352
(C)Copyright Oak Technology Inc. 1987-1997
```

```
Device Name : CDROM
Transfer Mode : Programmed I/O
Number of drives : 1
```

```
C:\>C:\DOS\SMARTDRU.EXE /X
```

```
MSCDEX Version 2.23
```

```
Copyright (C) Microsoft Corp. 1986-1993. Alle Rechte vorbehalten.
```

```
Laufwerk D: = Treiber CDROM Gerät 0
```

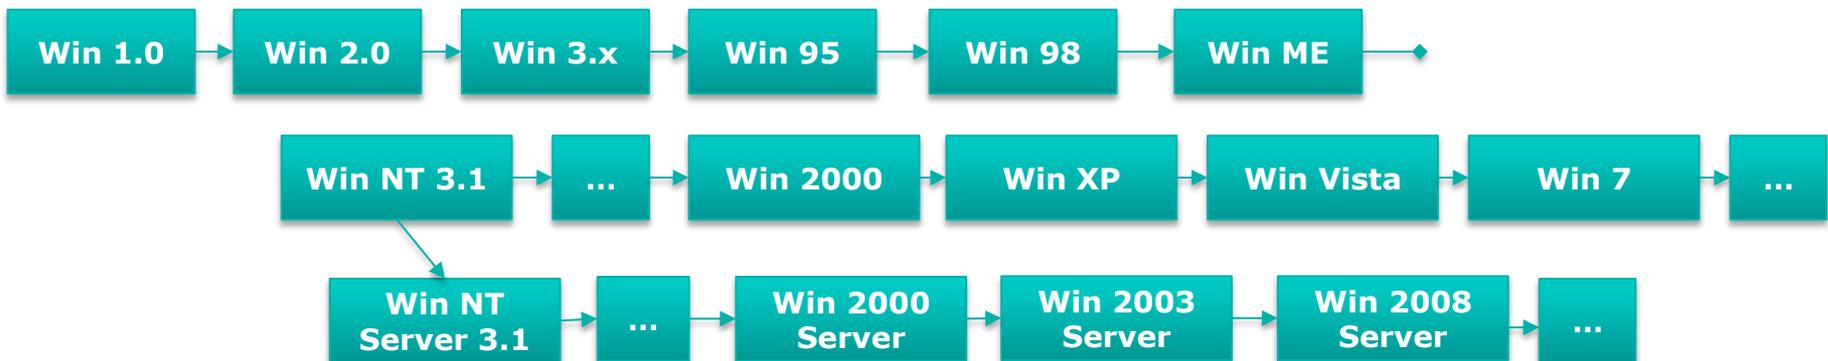
```
C:\>_
```

# Betriebssysteme

## Windows

### Es gibt nicht DAS Windows, sondern ...

- Windows 1.x, 2.x, 3.x 16 Bit
- Windows 9x 32 Bit
- Windows {NT 3.x, NT 4.x, 2000, ab XP} 32 / 64 Bit

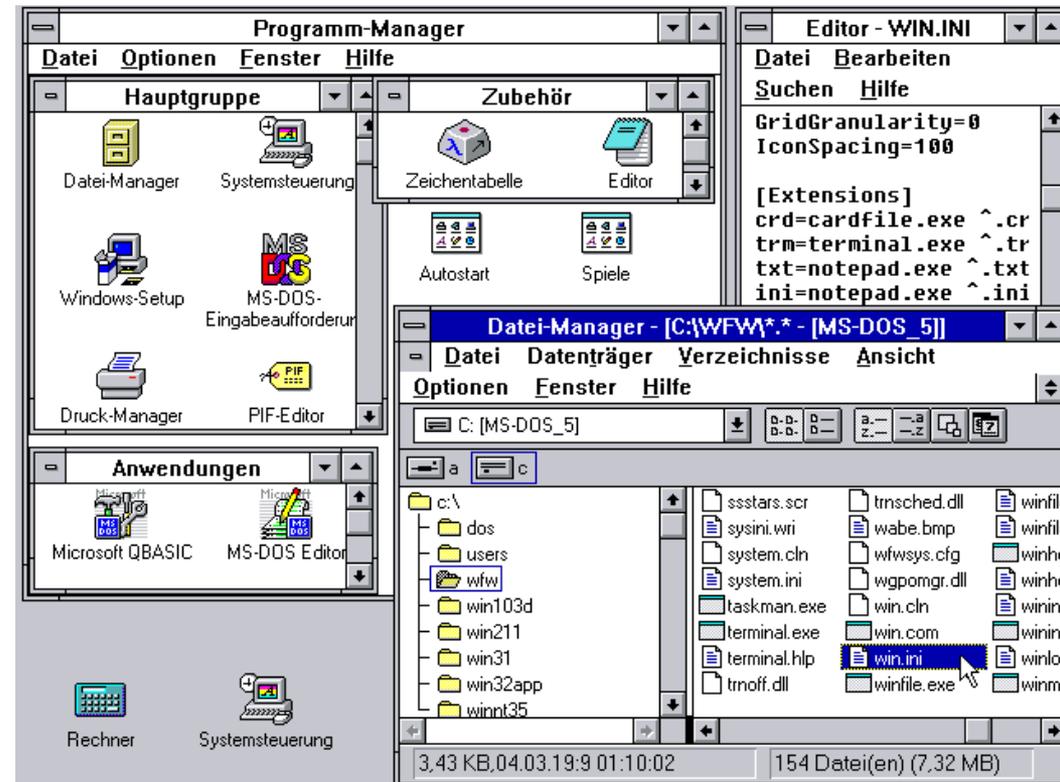


# Betriebssysteme

## Windows

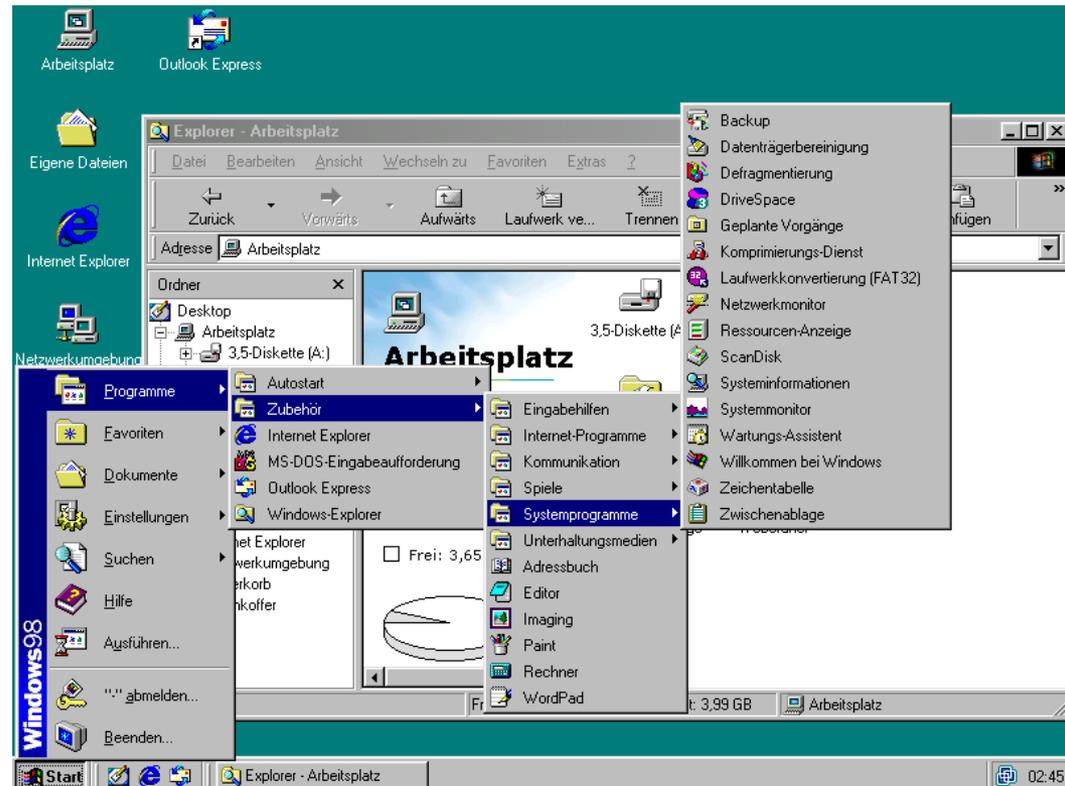
### DOS-Linie 16 Bit

- Reale Speicherverwaltung
- Kooperatives Scheduling
- Multitasking möglich
- Graphisches Dialogsystem



### DOS-Linie 32 Bit

- Virtuelle Speicherverwaltung
- Preemptives Scheduling für 32 Bit-Programme, kooperatives Scheduling für 16-Bit Programme
- Multitasking möglich
- Graphisches Dialogsystem

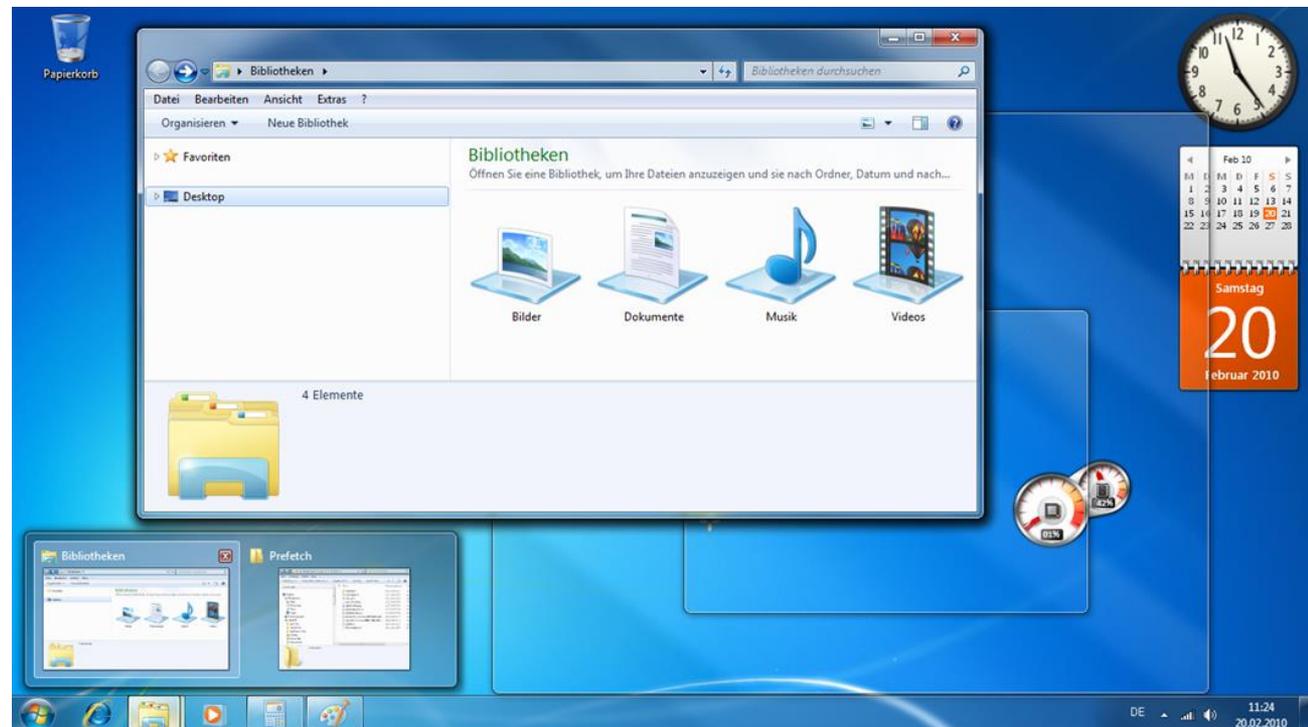


# Betriebssysteme

## Windows

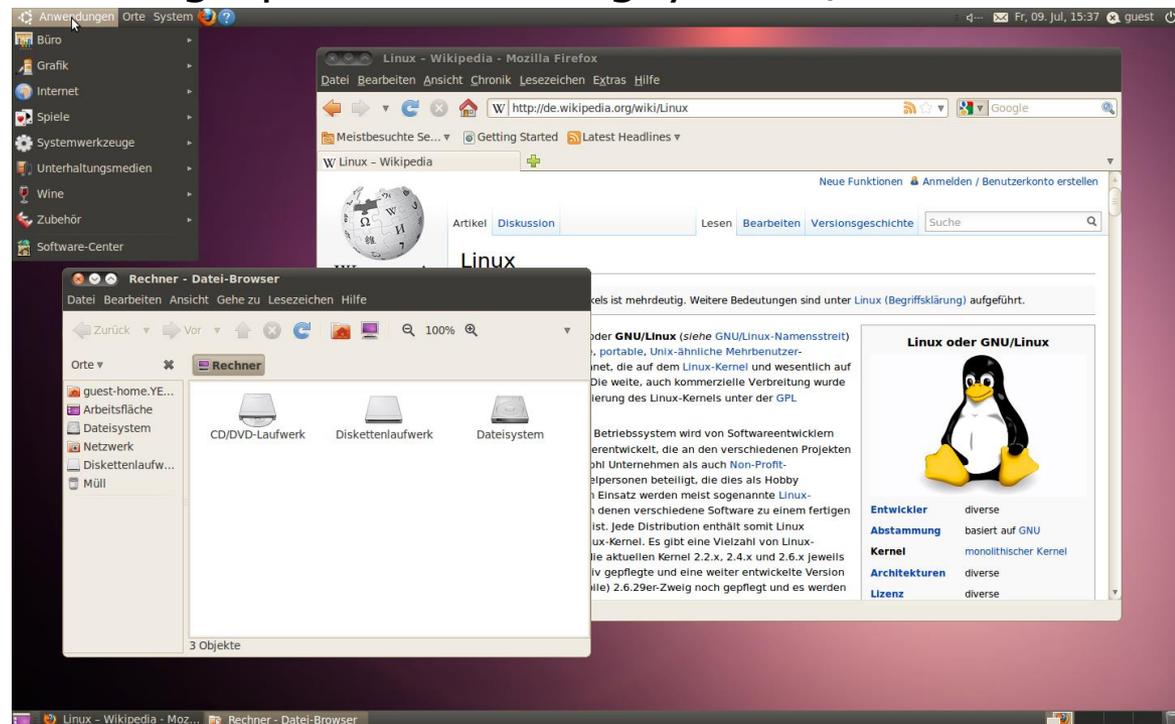
### NT-Linie 32/64 Bit

- Virtuelle Speicherverwaltung
- Preemptives Scheduling
- Multitasking möglich
- Graphisches Dialogsystem / Batchsystem (in der Server-Variante)



## Linux

- Virtuelle Speicherverwaltung
- Preemptives Scheduling
- Multitasking möglich
- Kommandozeilen-basiertes bzw. graphisches Dialogsystem / Batchsystem



# Betriebssysteme

## Mac OS X

### Mac OS X

- Virtuelle Speicherverwaltung
- Preemptives Scheduling
- Multitasking möglich
- Kommandozeilen-basiertes bzw. graphisches Dialogsystem



# 9 - Datensicherheit

---

Kryptographie, Kryptoanalyse, Datenschutz

# Lessons Learned

## Muss ich mir das alles merken?

---

### **In diesem Kapitel geht es darum folgende Dinge zu verstehen und zu können**

- Die Begriffe Kryptographie und Kryptoanalyse kennen und voneinander abgrenzen können
- Algorithmen, Klassische und moderne Verfahren kennen
- Digitale Signatur kennen

## Kryptologie setzt sich zusammen aus ...

- Kryptographie
  - > Beschäftigt sich mit der **Verschlüsselung** von Informationen
- Kryptoanalyse
  - > Beschäftigt sich mit dem **Entschlüsseln** von Informationen, **ohne** den passenden Schlüssel zu kennen

### Oft verwendete Begriffe in diesem Themenfeld sind ...

- Klartext  $M$ 
  - > Der Klartext ist die **unverschlüsselte Nachricht**
- Geheimtext / Chiffretext  $C$ 
  - > Der Geheimtext ist die **verschlüsselte Nachricht**
- Chiffrierung / Dechiffrierung
  - > Das **Ver-** bzw. **Entschlüsseln** wird Chiffrierung bzw. Dechiffrierung genannt
- Schlüssel
  - > Die **Geheime Information** zum Entschlüsseln ist der Schlüssel

# Kryptologie

## Kryptographie – Aber wozu?

---

### Kryptographie hat vier Hauptziele

- **Sichere Kommunikation** über ein unsicheres Medium
  - > Netzwerke (speziell Internet), Briefe, ...
- **Integrität** von Nachrichten
  - > Ist die vorliegende Nachricht verändert worden?
- **Authentifizierung** von Kommunikationspartnern
  - > Rede ich wirklich mit der richtigen Person?
- **Verbindlichkeit**
  - > Hat der Absender die Nachricht wirklich selbst verschickt?

# Kryptologie

## Kryptographie – Rahmenbedingungen

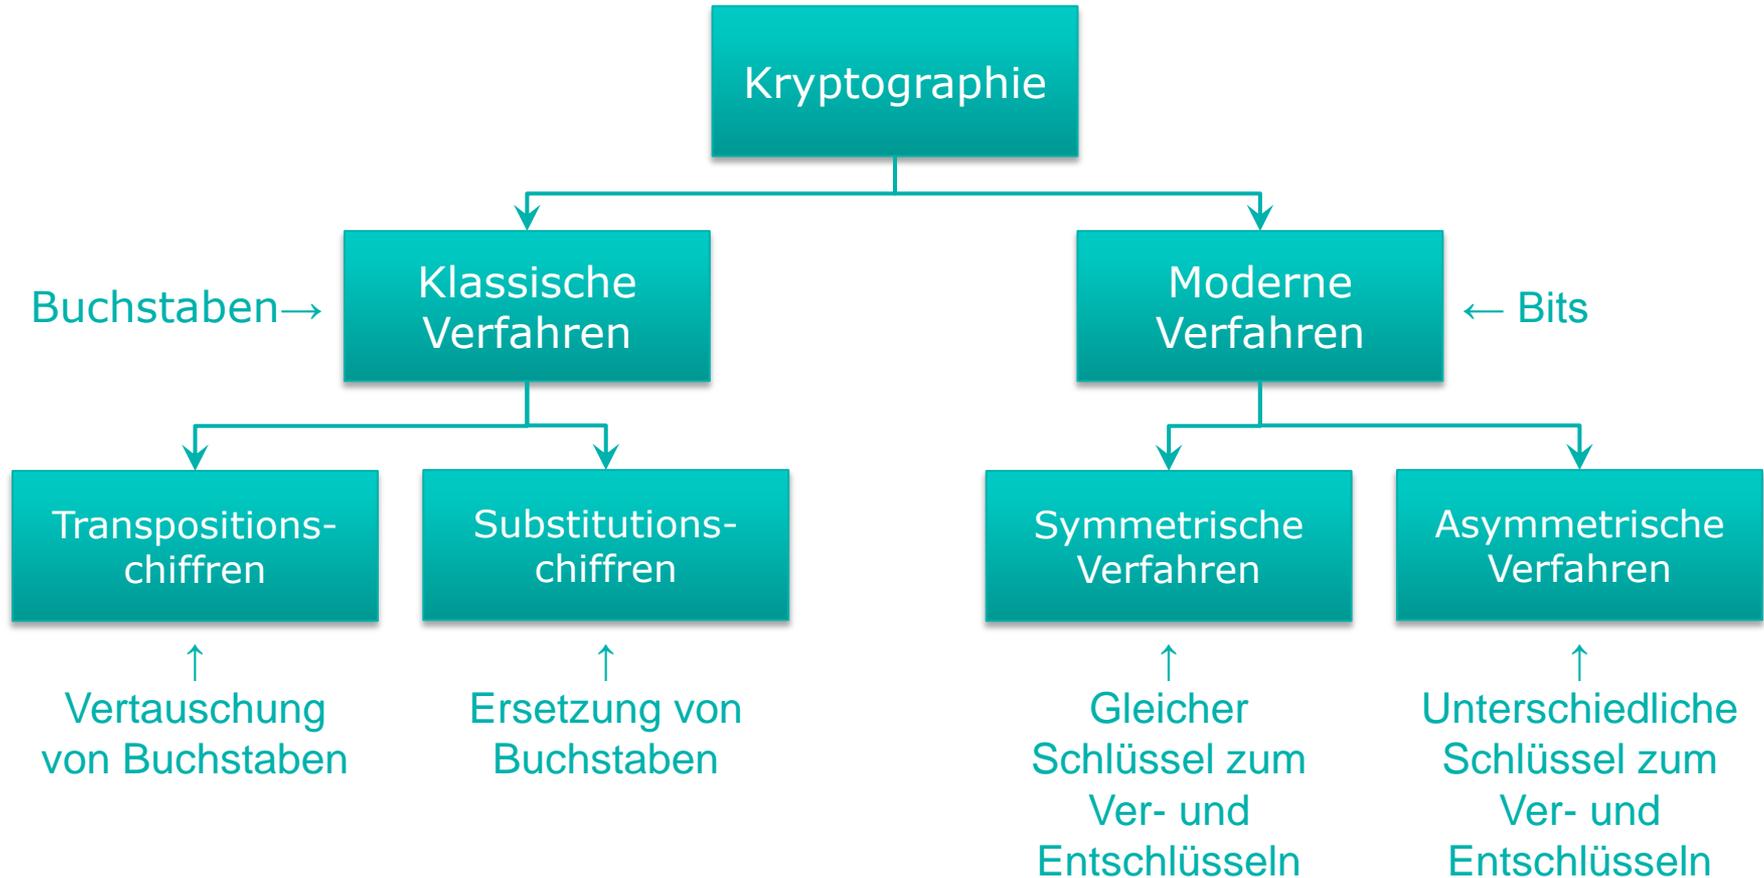
### Welche Anforderungen muss Kryptographie erfüllen?

- Kerckhoffs Prinzip (1883)
  - > Das System muss unentzifferbar sein
  - > Das System selbst darf keine Geheimhaltung erfordern
  - > Der Algorithmus muss leicht zu übermitteln sein und ein Mensch muss sich den Schlüssel ohne schriftliche Aufzeichnung merken können
  - > Das System sollte (muss) mit telegraphischer Kommunikation kompatibel sein (Telefon, eMail, etc.)
  - > Das System muss transportabel sein und die Bedienung darf nicht mehr als eine Person erfordern
  - > Das System muss einfach anwendbar sein



# Kryptologie

## Kryptographie – Algorithmen



# Kryptologie

## Transpositionschiffren – Skytale

### Zur Verschlüsselung wird ein Pergamentstreifen um einen Holzstab gewickelt und beschriftet

- Klartext: Um den Holzstab gewickelter Pergamentstreifen
- Geheimtext: Pergamentstreifen ohne Holzstab
- Schlüssel: Holzstab mit bestimmtem Durchmesser



Quelle: <http://de.wikipedia.org/wiki/Skytale>

# Kryptologie

## Substitutionschiffren

### Es wird zwischen zwei Arten von Substitutionschiffren unterschieden

- Monoalphabetische Substitutionschiffren
  - > Einem Klartextalphabet wird ein Geheimentalphabet zugeordnet

|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| a | b | c | d | e | f | g | h | i | j | k | l | m | n | o | p | q | r | s | t | u | v | w | x | y | z |
| U | F | L | P | W | D | R | A | S | J | M | C | O | N | Q | Y | B | V | T | E | X | H | Z | K | G | I |

- Polyalphabetische Substitutionschiffren
  - > Einem Klartextalphabet werden mehreren Geheimentalphabete zugeordnet

|   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|---|
| a | b | c | d | e | f | g | h | i | j | k | l | m | n | o | p | q | r | s | t | u | v | w | x | y | z |
| U | F | L | P | W | D | R | A | S | J | M | C | O | N | Q | Y | B | V | T | E | X | H | Z | K | G | I |
| N | K | J | S | Z | W | H | M | L | A | V | Y | F | C | P | T | B | Q | R | U | O | G | I | D | X | E |

### Ein Beispiel für eine **monoalphabetische Substitutionschiffre** ist die **Cäsar-Chiffre**

- Klar- und Geheimtextalphabet sind das lateinische Alphabet
  - > Verschiebung der Alphabete zueinander um eine Bestimmte Anzahl von Buchstaben
  - > Die Anzahl der Buchstaben, um die verschoben wird, ist der **Schlüssel** der Cäsar-Chiffre
- Beispiel
  - > A B C D E F G H I J K L M N O P Q R S T U V W X Y Z
  - > J K L M N O P Q R S T U V W X Y Z A B C D E F G H I
  - > HALLO wird zu QJUUX

### Ein Beispiel für eine **polyalphabetische Substitutionschiffre** ist die **Vigenère-Verschlüsselung**

- Ein Schlüsselwort bestimmt, wie viele und welche Geheimtextalphabete benutzt werden
  - > Die einzelnen Geheimtextalphabete leiten sich aus der Cäsar-Chiffre ab
- Beispiel
  - > Schlüsselwort: **EDV**
  - > A B C D E F G H I J K L M N O P Q R S T U V W X Y Z
  - > **E F G H I J K L M N O P Q R S T U V W X Y Z A B C D**
  - > **D E F G H I J K L M N O P Q R S T U V W X Y Z A B C**
  - > **V W X Y Z A B C D E F G H I J K L M N O P Q R S T U**
  - > **MATSE** wird zu **QDOWH**

## Moderne Verfahren unterscheiden zwischen verschiedenen Varianten

- Symmetrische Chiffren
  - > Blockchiffren
  - > Stromchiffren
- Asymmetrische Chiffren
- Hybride Chiffren

# Kryptologie

## Symmetrische Chiffren

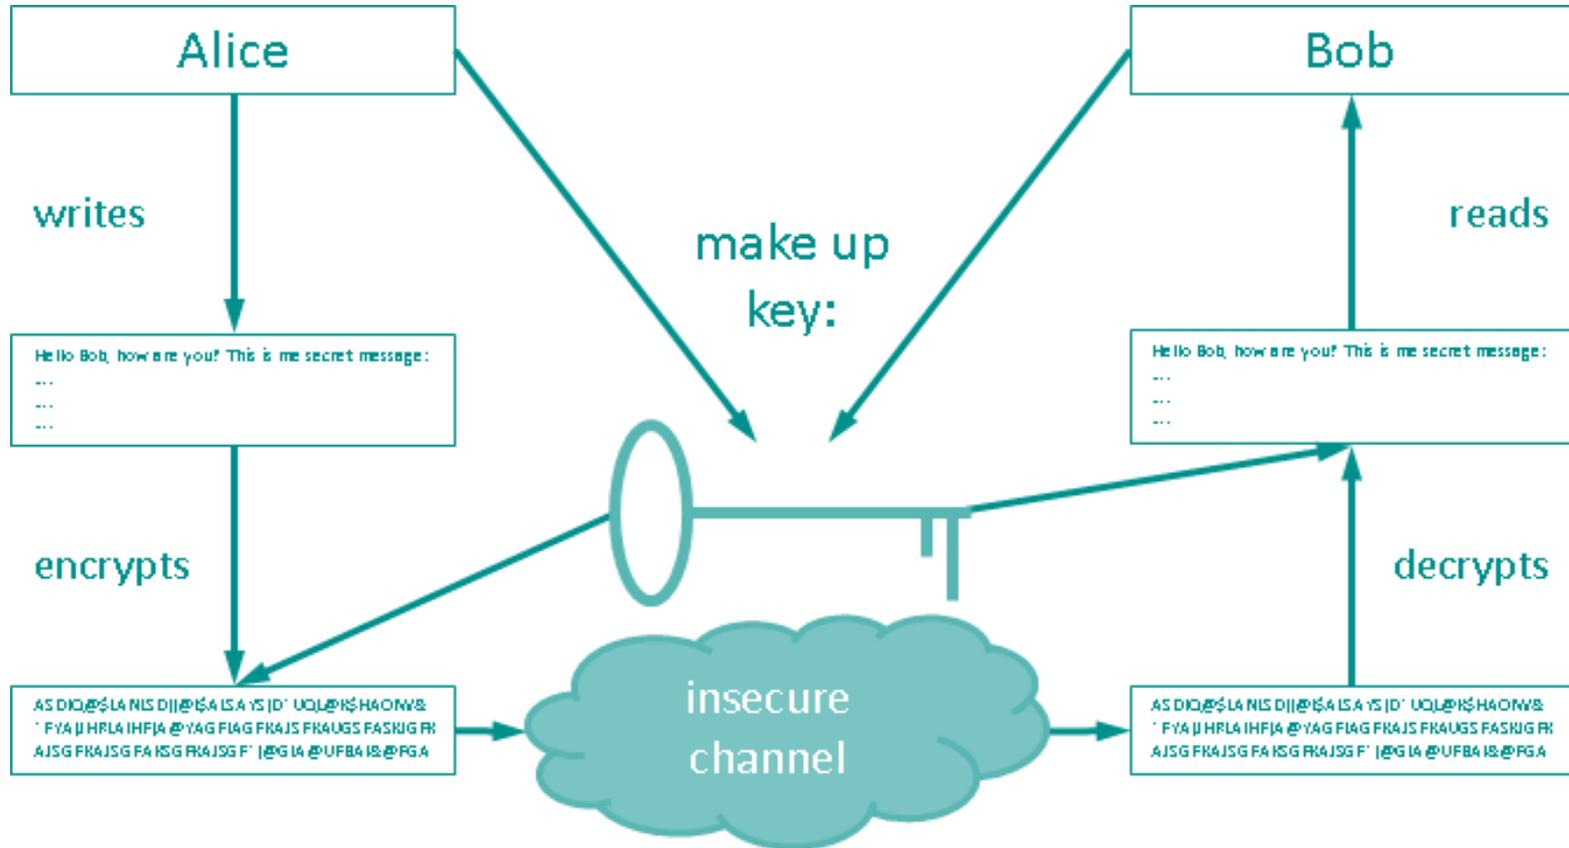
---

### Bei symmetrischen Chiffren wird zum Ver- und Entschlüsseln derselbe Schlüssel benutzt

- Symmetrische Chiffren unterscheiden zwischen **Block-** und **Stromchiffren**
- Vorteile
  - > Geringer Rechenaufwand
- Nachteile
  - > Geheimer Schlüssel muss über ein unsicheres Medium transportiert werden
- Klassische Verfahren sind prinzipiell auch symmetrische Chiffren
- Bekannte Verfahren sind z.B. DES, 3DES, AES, Blowfish, ...

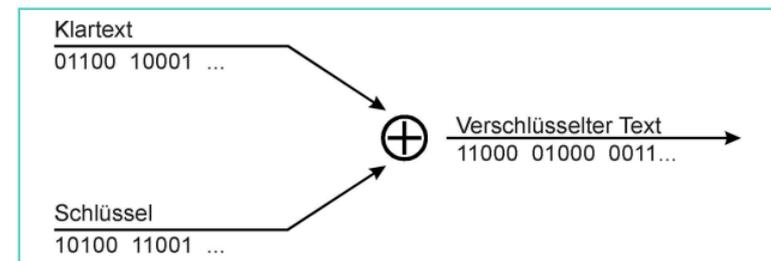
# Kryptologie

## Symmetrische Chiffren



### Symmetrische Chiffren unterscheiden zwischen ...

- ...Blockchiffren
  - > Der Klartext wird in **Blöcke gleicher Länge** eingeteilt und blockweise verschlüsselt
  - > Es wird **derselbe Schlüssel** für alle Klartextblöcke verwendet
  - > Der letzte Klartextblock wird mit Nullen aufgefüllt
- ... Stromchiffren
  - > Der Klartext wird bitweise anhand eines **Schlüsselstroms** verschlüsselt
  - > Der Schlüsselstrom und der Geheimtext haben **dieselbe Länge** wie der Klartext



# Kryptologie

## Asymmetrische Chiffren

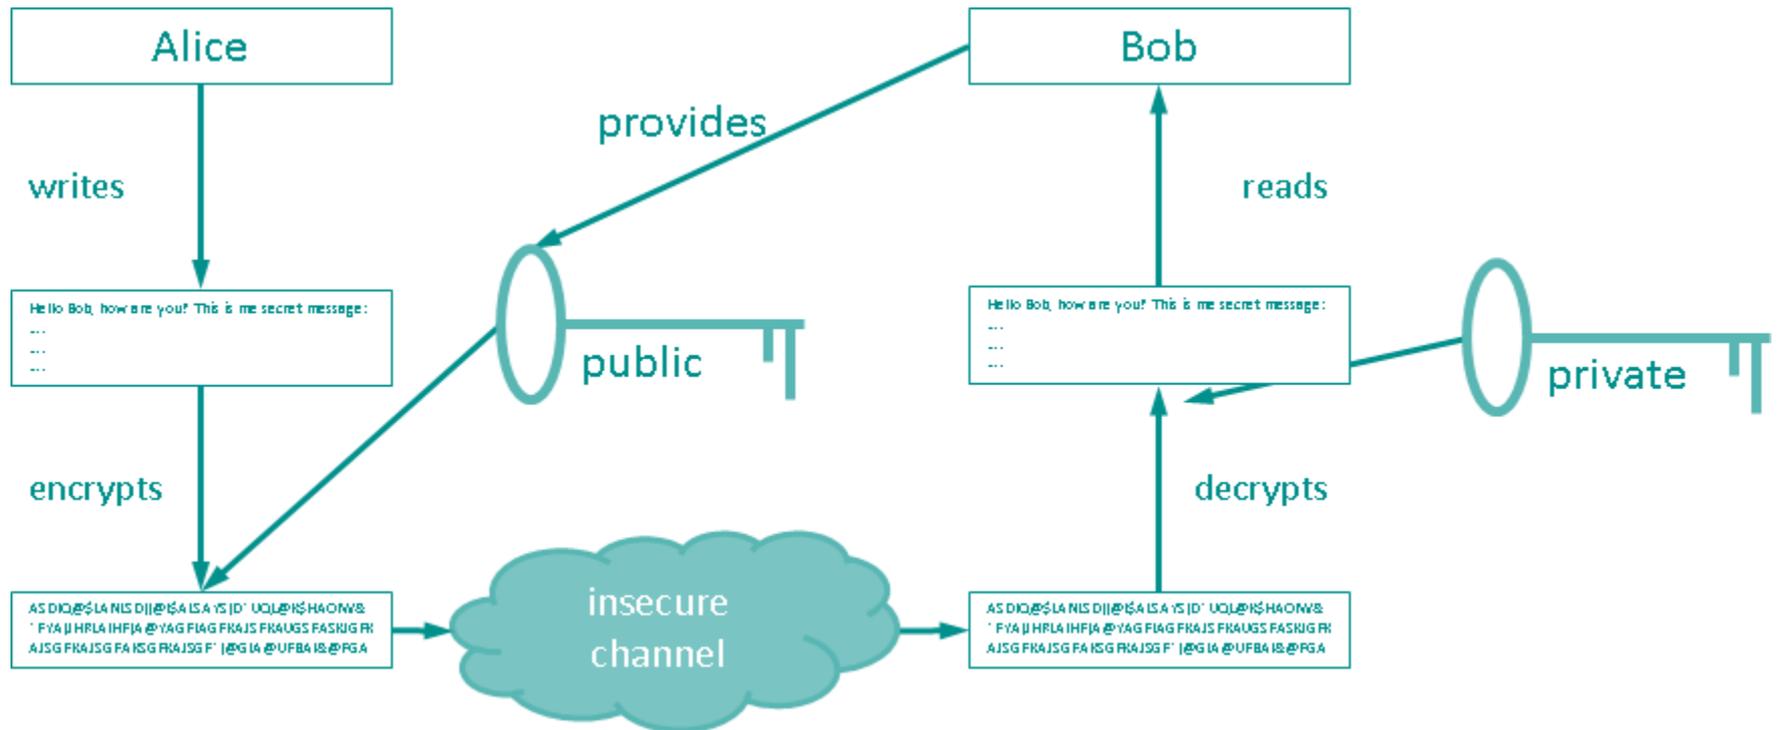
---

### Bei asymmetrischen Chiffren werden **unterschiedliche Schlüssel** zum Ver- und Entschlüsseln benutzt

- Zwei Schlüssel bilden ein **Schlüsselpaar**, bestehend aus...
  - > **Privater Schlüssel** („private key“) zum Entschlüsseln
  - > **Öffentlicher Schlüssel** („public key“) zum Verschlüsseln
- Vorteile
  - > Privater Schlüssel muss nicht übertragen werden
- Nachteile
  - > Rechenaufwand deutlich höher als bei symmetrischen Chiffren (~ Faktor 1000)

# Kryptologie

## Asymmetrische Chiffren



## Das meist genutzte asymmetrische Verfahren ist RSA

- RSA ...
  - > ... wurde 1977 am MIT von R. Rivest, A. Shamir und L. Adleman entwickelt
  - > ... basiert auf Primfaktorzerlegung
- Der RSA-Algorithmus funktioniert wie folgt
  - > Verschlüsselung:  $C = M^e \bmod N$
  - > Entschlüsselung:  $M = C^d \bmod N$
- Die entsprechenden Schlüsselpaare haben folgende Gestalt
  - > Privater Schlüssel:  $(d, N)$
  - > Öffentlicher Schlüssel:  $(e, N)$

# Kryptologie

## Asymmetrische Chiffren

### Ein Beispiel zu RSA

- Gegeben

- > Algorithmen:  $C = M^e \bmod N, M = C^d \bmod N$
- > Privater Schlüssel:  $(d, N) = (47, 143)$
- > Öffentlicher Schlüssel:  $(e, N) = (23, 143)$
- > Klartext:  $M = 97$  (a)

- Berechnen des Geheimtextes

- >  $C = M^e \bmod N = 97^{23} \bmod 143 = 102$

- Berechnen des Klartextes

- >  $M = C^d \bmod N = 102^{47} \bmod 143 = 97$

### Eine digitale Signatur dient zur Sicherung der ...

- ... **Identität des Autors** einer Nachricht
- ... **Integrität der Nachricht** selbst
- Anforderungen an eine digitale Signatur
  - > Es darf nur dem echten Sender einer Nachricht möglich sein, eine digitale Signatur zu erzeugen
  - > Die Signatur muss vom Empfänger überprüft werden können
  - > Eine Signatur muss fest zu einer Nachricht gehören und darf nur in Verbindung mit dieser Nachricht gültig sein

# Kryptologie

## Exkurs: Hashfunktion

---

### Eine Hashfunktion $f(x)$ hat folgende Eigenschaften

- $f(x)$  bildet eine beliebige, aber wohldefinierte, Eingabe auf einen Wert fester Länge (= Hashwert) ab
- $f(x)$  sollte injektiv sein, ist es aber meist nicht
- $f(x)$  ist nicht umkehrbar (speziell für kryptologische Hashfunktionen)
- Beispiel: MD5 (md5() in PHP)
  - > **MATSE** → *0241739d4c2596e4f12a2fd531de6163*

## Wie funktioniert eine digitale Signatur?

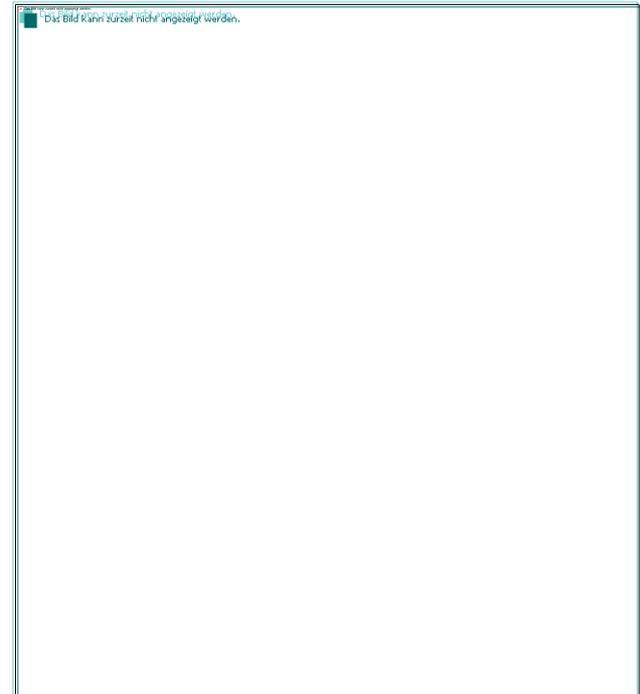
- Signieren
  1. Berechnung einer **Prüfsumme** der Nachricht mittels einer Hashfunktion
  2. Verschlüsselung der Prüfsumme mit dem **privaten Schlüssel**
- Prüfen der Signatur
  1. Entschlüsselung der Nachricht mit dem **öffentlichen Schlüssel** des Senders (= **Identität des Autors**)
  2. Eigene **Berechnung einer Prüfsumme** über die Nachricht
  3. **Vergleich** der selbst berechneten Prüfsumme mit der entschlüsselten Prüfsumme (= **Integrität der Nachricht**)

### Die Kombination von symmetrischen und asymmetrischen Chiffren nennt man **hybride Chiffren**

- Der verhältnismäßig kurze Schlüssel einer Blockchiffre wird asymmetrisch verschlüsselt und zum Empfänger einer Nachricht transportiert
- Die Kommunikation selbst läuft symmetrisch verschlüsselt ab
- Durch Kombination der beiden Verfahren wird ein guter Kompromiss zwischen Sicherheit und Rechenaufwand erzielt
- Anwendungsgebiete
  - > HTTPS (SSL im Browser)
  - > E-Mailverschlüsselung
  - > ...

## Wozu Kryptoanalyse?

- Oft krimineller Hintergrund
  - > z.B. Auslesen von Kreditkartennummern bei Online-Einkäufen
- Bekannte Beispiele für Kryptoanalyse
  - > Die Enigma im 2. Weltkrieg
  - > Der „NSA-Skandal“



## Es gibt mehrere Arten eine Kryptoanalyse durchzuführen

- Brute-Force
  - > Ausprobieren aller möglichen Schlüssel
  - > Ergebnis pro Schlüssel muss jeweils inhaltlich überprüft werden
- Wörterbuchangriff
  - > Geht davon aus, dass der Schlüssel ein existierendes Wort ist
  - > Schneller als Brute-Force, jedoch wirkungslos wenn ein zufälliger Schlüssel verwendet wird
- Häufigkeitsanalyse
  - > Nur bei klassischen Chiffren
  - > Die Verteilung der Buchstaben in einer Sprache wird ausgenutzt
- „Fortgeschrittene“ Methoden

# Datenschutz

## Sicherheitsrisiken

## Daten können nicht nur in falsche Hände gelangen, sondern auch verloren gehen

- Daten können...
  - > ... gestohlen werden
  - > ... verbrennen
  - > ... gelöscht werden
  - > ... durch Hardwaredefekte verloren gehen
  - > ... durch Malware / Viren unbrauchbar gemacht werden
  - > ...



## Daher hat Datenschutz nicht nur etwas mit Kryptographie zu tun, sondern auch mit anderen Aspekten

- Gebäude
  - > Bauliche und organisatorische Maßnahmen gegen höhere Gewalt und Sabotage
- Geräte
  - > Geräte redundant betreiben
- Programme und Daten
  - > Backup der Daten erstellen
- Dienste
  - > Maßnahmen gegen Missbrauch und Attacken

# Datenschutz

## Personenbezogene Daten

---

### **Mit zunehmender Digitalisierung wird der korrekte Umgang mit personenbezogenen Daten immer wichtiger**

- Jeder hat das Recht auf „informationelle Selbstbestimmung“
  - > Soll heißen: Jeder darf selbst entscheiden, welche Informationen über sie / ihn öffentlich zugänglich sind
- Es werden jedoch zunehmend Daten erfasst und gesammelt
  - > Im öffentlichen Raum
    - > Verbrechensaufklärung, Verbrechensprävention, ...
  - > Im privaten Raum
    - > Kontrolle von Mitarbeitern, Erfassung von Kundenprofilen, ...

# Datenschutz

## Personenbezogene Daten

---

### **Gesetzlicher Rahmen stellt sicher, dass...**

- ... nur relevante Daten verwendet werden
- ... ein Betroffener Auskunft über verwendete Daten erhalten kann
- ... ein Betroffener Anspruch auf Korrektur von falschen Daten hat
- ... eine Weitergabe der Daten nur unter bestimmten Bedingungen möglich ist

# Datenschutz

## Personenbezogene Daten

---

**Stellen, die mit sensiblen Daten umgehen (Ämter, Firmen, ...) müssen sicherstellen, dass verarbeitete Daten „sicher“ sind, durch ...**

- ... bauliche Maßnahmen (z.B. Zutrittsbeschränkung)
- ... Benutzer- und Rechteverwaltung in der IT
- ... Kryptographie