IT-Infrastruktur

SS 2015

Hans-Georg Eßer
Dipl.-Math., Dipl.-Inform.

Foliensatz A: v1.1, 2015/03/05

- Einführung
- Seminararbeiten, Wissenschaftliches Arbeiten
- Datenformate und Wandlung

Zur Veranstaltung (1)

Service / Web-Seite: http://fom.hgesser.de

- Folien und Praktikumsaufgaben
- Vorlesungs-Videos („test, test “)
- Probeklausur gegen Semesterende
- Folien auch im Online-Campus

Prüfung und Benotung:

1. Lernfortschrittskontrolle (LFK)
2. Seminarausarbeitung
3. Klausur über 120 Minuten

Fragen: direkt in der Vorlesung oder danach
oder per E-Mail: h.g.esser@gmx.de

Zur Veranstaltung (2)

10 ECTS-Punkte – großes Modul

- Präsenzstudium: 48 Stunden *) (= 64 UE)
- Eigenstudium: 172 Stunden
- Lernfortschr.-Kontr.: 30 Stunden
- Workload: 250 Stunden

Klausur-relevant:

- Vorlesungen
- Übungsaufgaben
- Seminarvorträge

*) Stunde
= Zeitstunde,
= 60 min.

Über den Dozenten

Hans-Georg Eßer

- Dipl.-Math. (RWTH Aachen, 1997)
  Dipl.-Inform. (RWTH Aachen, 2005)
  Fachjournalist (FJS Berlin, 2006)
- Chefredakteur Linux-Zeitschrift (seit 2000)
  und Autor diverser Computerbücher
- seit 2006 Dozent (u. a. FOM, HS München, TH Nürnberg, Univ. Erlangen-Nürnberg): Betriebssysteme, Rechnerarchitektur, IT-Infrastruktur, Informatik-Grundlagen, Systemprogrammierung, Betriebssystem-Entwicklung, Software Engineering, IT-Sicherheit
- Seit 2010 Doktorand (Univ. Erlangen-Nürnberg), Abschluss im Laufe dieses Jahres

Inhaltsübersicht

Inhalte

- **A. Datenformate und Wandlung (von DTaus bis XML)**
  - Grafik, Video
  - Text
  - Applikationsformate (z.B. GIS, CAD usw.)
  - Kommunikationsformate
  - Konverter
  - Kodierungen (ASCII, ISO-Latin-*, Unicode)
- **B. PC als Arbeitsplatz**

Inhalte

- **C. Ergonomie und Arbeitsschutz**
- **D. Rechnerstrukturen**
  - Prozessor-Architekturen, Befehlssätze
- **E. Zentrale und verteilte IT-Infrastrukturen**
- **F. Telekommunikation**
  - Geräte, Protokolle, Dienste
    → Eigenstudium, Seminararbeiten

  } Skript im Campus-System
- **G. Infrastruktur-Technologie**

  } ggf. weitere Literatur

Dieser Foliensatz

Folien A

- Vorlesungsübersicht
- Seminar
- Wiss. Arbeiten
- Datenformate und Wandlung
- PC als Arbeitsplatz
- Ergonomie und Arbeitsschutz
- Rechnerstrukturen
- Zentrale / verteilte IT-Infrastrukturen

Seminararbeiten

Seminararbeiten (1)

- 23 Teilnehmer laut Campus-System
- Seminar-Themen aus den Bereichen „F. Telekommunikation“ und „G. Infrastruktur-Technologie“
- Literatur im Campus-System verfügbar

[1] Firoz Kaderali: Skript „Kommunikationsnetze und Protokolle“

[2] Peter Richert: Skript „Kommunikationssysteme“

[3] H. R. van As: Skript „Datenkommunikation“

Seminararbeiten (2)

- Themenwahl z. B. auf Basis des Skripts „Kommunikationsnetze und Protokolle“ von Prof. Firoz Kaderali,
  http://www.kaderali.de/fileadmin/vorlesungsskripte/Buch KP (A4).pdf
- oder eigene Themenvorschläge, gerne auch aus der eigenen Praxis
- bitte keine Doppel-Themenbelegung
- Vorträge: während der Präsenztermine am 29.05. / 30.05.
- Vortragsfolien bis 27.05. per Mail an mich

Wissenschaftliches Arbeiten

Ausarbeitungen und Vorträge

Inhalte

- Wie lese ich Fachbücher/Skripte/Papers?
- Wie schreibe ich eine Seminararbeit?
- Wie halte ich einen Seminarvortrag?

Quellen lesen

- Was ist das Themengebiet der Quelle?
- Was ist die zentrale Fragestellung?
  - Welches Thema wird im Detail behandelt?
  - Welche Aspekte sind besonders wichtig oder vernachlässigbar?
  - Welche Aspekte bleiben in der Quelle unklar?
- Literaturangaben auswerten
  - Grundlagen
  - Weiterführende Literatur

Seminararbeit schreiben

- Gliederung erstellen
- Typisch:
  - Kap. 1: Einleitung
  - Kap. 2: } (Inhalt)
  - Kap. n–1: } (Inhalt)
  - Kap. n: Zusammenfassung

Einleitung

- Einleitung besteht aus:
  - Motivation / Themenfeld
    - Welches Themengebiet behandelt die Arbeit
    - Warum ist es relevant?
  - Thema der (Seminar-) Arbeit
    - Fragestellung in dieser Ausarbeitung
    - Bezug auf das Paper / die Papers
    - Welche Lösung wird im Paper vorgeschlagen?
  - Struktur der Arbeit
    - Wie ist diese Arbeit aufgebaut? Roter Faden?

Einleitung

- Leser wollen i. d. R. nicht jedes Dokument vollständig lesen
- Darum: In der Einleitung vollständigen Überblick über die wichtigsten Inhalte geben (→ „Executive Summary“)

Inhaltliche Kapitel

- In den inhaltlichen Kapiteln kann sich die Grobstruktur der Ausarbeitung wiederholen, also
  - Kap. i.1: Einleitung (zu Thema i)
    - Worum geht es?
    - Roter Faden
    - Anknüpfen an vorangehendes Kapitel
  - Kap. i.2: …
  - Kap. $i.m$: Zusammenfassung
    - Worum ging es? Wieder: Roter Faden
    - ggf. Ausblick auf Folgekapitel

Redundanz ist OK, hilft bei Orientierung

Zusammenfassung

- Kurze Zusammenfassung der Ausarbeitung (Kenntnis der Arbeit kann hier vorausgesetzt werden)
- Falls sinnvoll: Hinweis auf offene Punkte, unbeantwortete Fragen

Inhaltsauswahl

- Häufiges Problem:
  Quelle viel zu lang / Quelle viel zu kurz
- Auswahl
- Ergänzung (weitere Literatur)
- Seminarausarbeitung und Vortrag müssen nicht deckungsgleich sein
- Ausarbeitung „in sich geschlossen“ (ohne weitere Literatur verständlich)
- Frage beantworten: Warum sollte man meine Ausarbeitung (statt der Originaltexte) lesen?

Quellen / Zitate (1)

- Beim Strukturieren bereits die relevanten Textstellen der Originalliteratur vermerken
  - Welcher Teil der Arbeit bezieht sich auf welchen Teil der Originalliteratur?
- Im Text eine Referenz einbauen falls ...
  - wesentliche Ideen, Zahlen, Bilder, Tabellen usw. übernommen werden
  - ganze Teile wortwörtlich übernommen werden (Zitate)
- Zitate als solche kenntlich machen („...“ [Referenz])
- Referenzen möglichst genau (am besten mit Seitenangabe, vor allem bei Büchern)

Kritischer Umgang

- Quellen kritisch bearbeiten
  - Nur weil etwas in einer Quelle steht, muss es nicht richtig sein → kein blindes Vertrauen
  - Technischen Beschreibungen und Erklärungen kann man auch widersprechen
  - Wenn unklar: Weitere Literatur zum selben Thema suchen, vergleichen
  - Kein direkter Zusammenhang zwischen „Zitierfähigkeit“ und Glaubwürdigkeit einer Quelle

Quellen / Zitate (2)

- Im Text stehen Referenzen (Verweise) auf das Literaturverzeichnis
  - Referenzen sind meist Kürzel in eckigen Klammern
  - Unterstützung durch LaTeX
- Arten des Zitierens:
  - Aktiv: In [1] wurde gezeigt … [1, S. 35]
  - Passiv: Maier und Müller [1] haben gezeigt …
  - Möglichst für eine Art entscheiden und konsistent verwenden

Quellen / Zitate (3)

- Informationen, die (unter Informatikern) allgemein bekannt sind, brauchen keinen Beleg durch Quellenangabe
  - „C ist eine häufig für systemnahe Programmierung verwendete Sprache.“ (ohne Beleg)
  - „Das Betriebssystem ZonkOS wurde nicht in C, sondern in Fortran implementiert [12].“ (mit Beleg)
- Zielgruppe: andere (Wirtsch.-) Informatik-Studenten, konkret: die übrigen Kursteilnehmer

Quellen / Zitate (4)

- Mehrere Referenzen, Seitenangaben
  - [1, 2, 4]
  - [1–3, 5]
  - [4, S. 15, 6, S. 34] → besser zerlegen
  - LaTeX macht das automatisch
- Viele Autoren
  - Müller et al.: ab vier Autoren; in engl. Texten ab drei Autoren, vgl. Wikipedia [3]
  - im Literaturverzeichnis aber alle Autoren nennen

Quellen / Zitate (5)

- Zitierweise
  - Bitte keine Fußnoten für Literatur-Verweise,
  - sondern einfach z. B. „[6]“ im Text als Verweis auf Eintrag [6] im Literaturverzeichnis
  - bei längeren Quellen (wie dem TK-Skript) immer mit Seitenangabe, in der Form „[6, S. 119]“

Literaturverzeichnis

- alle verwendeten (und nur die!) Quellen aufführen
  - sortiert nach Nachname des Erstautors, dann nach Datum
- Eintrag enthält
  - Namen der Autoren, Titel der Publikation/des Beitrags
  - ggf. Name der Zeitschrift/Konferenz, Band, Nummer, Seitenzahl / Ort
  - Erscheinungsjahr
  - möglichst genau
- Quellen im Web: Autoren, Titel, URL und Zugriffsdatum (wenn es eine Originalquelle gibt, diese zitieren!)

Literaturverzeichnis

- Wikipedia: u. U. akzeptable Quelle. Ganz gut für technische Dinge
- Whitepapers von Unternehmen: da fehlen oft wichtige Angaben (z. B. Autoren), → Firma als Hrsg.
- „keinen Schrott zitieren“

Literaturverzeichnis

- Negativ-Beispiel

Bei einem Vergleich forensisch nutzbarer Informationen in Windows-Dateisystemen sieht man u. a., dass FAT [1] nur einen einzigen Zeitstempel pro Datei speichert, während NTFS [2] für jede Datei vier Zeitstempel verwaltet [3]. Ergänzend gibt ...

[1] http://de.wikipedia.org/wiki/File_Allocation_Table
[2] http://de.wikipedia.org/wiki/NTFS
[3] http://articles.forensicfocus.com/2013/04/06/interpretation-of-ntfs-timestamps/
[4] http://books.google.de/books?id=fummOICB9IgC&pg=PA148&lpg=PA148&dq=ntfs+%22delete+time%22+timestamp&source=bl&ots=FOFB7xD3MY&sig=awkTk3V-f1dR3E6ivx46-Gc7xs4&hl=en&sa=X&ei=loFXU6mOC4LNtQbLuwE&ved=0CDwQ6AEwAg#v=onepage&q=ntfs%20%22delete%20time%22%20timestamp&f=false

Literaturverzeichnis

Positiv-Beispiel

Bei einem Vergleich forensisch nutzbarer Informationen in Windows-Dateisystemen sieht man u. a., dass FAT [1] nur einen einzigen Zeitstempel pro Datei speichert, während NTFS [2] für jede Datei vier Zeitstempel (create, modify, access, change) verwaltet [3]. Der vierte Zeitstempel (change) wird für gelöschte Dateien auch als delete-Timestamp betrachtet [4, S. 148].

[1] Microsoft: Microsoft EFI FAT32 File System Specification, 2000, Whitepaper, http://download.microsoft.com/download/1/6/1/161ba512-40e2-4cc9-843a-923143f3456c/fatgen103.doc, Onlineabruf am 23.04.2014
[2] Microsoft: NTFS Technical Reference, 2003, http://technet.microsoft.com/en-us/library/cc758691%28WS.10%29.aspx, Onlineabruf am 23.04.2014
[3] wpathulin: „Interpretation of NTFS Timestamps“, Forensic Focus, 2013, http://articles.forensicfocus.com/2013/04/06/interpretation-of-ntfs-timestamps/, Onlineabruf am 23.04.2014
[4] Greg Gogolin: *Digital Forensics Explained*, Auerbach Publications, 2012, ISBN: 1-4398-7495-6

Text produzieren

- In eigenen Worten formulieren
- Keine Textblöcke aus der Quelle übernehmen, auch keine Wort-für-Wort-Übersetzung
- kein Copy & Paste
  - Plagiat, ist in Prüfungs- und Seminararbeiten ein Grund für Nichtbestehen; an einigen Hochschulen sogar für offizielle Rügen oder Exmatrikulation (Abschlussarbeiten)
  - fällt auf (Stilbruch etc.) und wird geprüft
  - Reines Umformulieren von Satz für Satz ist aber genauso Plagiat!

Text produzieren

- Eigene Beiträge kennzeichnen (wenn Sie z. B. eigene Praxistests etc. machen)
- Stil: Passivkonstruktionen, Substantivierungen meiden

Plagiat-Formen

- Copy & Paste (wortwörtliche Wiedergabe)
- Paraphrasierung (Wiedergabe mit eigenen Worten),
- Übersetzungsplagiat
- Strukturplagiat
- „Shake and Paste“ [1]

[1] http://plagiat.htw-berlin.de/ff/schule/3_2/wie

Aktuelles Plagiat (2013)

1 INTRODUCTION

CONSIDER a set of parties who wish to correctly compute some common function F of their local inputs, while keeping their local data as private as possible, but who do not trust each other, nor the channels by which they communicate. This is the problem of *Secure Multiparty Computation* (SMC) [1]. SMC is a very general security problem, i.e., it can be used to solve various real-life problems such as distributed voting, private bidding and online auctions, sharing of signature or decryption functions and so on. Unfortunately, solving SMC is—without extra assumptions—very expensive in terms of communication (number of messages), resilience (amount of redundancy), and time (number of synchronous rounds).

TrustedPals [2] is a smart card-based security framework for solving SMC which allows much more efficient solutions to the problem. Conceptually, TrustedPals considers a distributed system in which processes are locally equipped with tamper-proof security modules. In practice, processes are implemented as a Java desktop application and security

links: R. Cortiñas, F. C. Freiling, M. Ghajar-Azadanlou, A. Lafuente, M. Larrea, L. Draque Penso, I. Soraluze: "Secure Failure Detection and Consensus in „TrustedPals“, IEEE TDSC (July-Aug. 2012, vol. 9 no. 4, pp. 608-623)

rechts: Khaderbasha, Shakeel, Babu: „Secure Failure Detection and Aggrements In Trusted Pals“, Int. Journal of Innovative Technologies (Vol. 01, Issue 05, Oct 2013)

1. INTRODUCTION

Consider a set of parties who wish to correctly compute some common function F of their local inputs, while keeping their local data as private as possible, but who do not trust each other, nor the channels by which they communicate. This is the problem of Secure Multiparty Computation (SMC) [1]. SMC is a very general security problem, i.e., it can be used to solve various real-life problems such as distributed voting, private bidding and online auctions, sharing of signature or decryption functions and so on. Unfortunately, solving SMC is without extra assumptions very expensive in terms of communication (number of messages), resilience (amount of redundancy), and time (number of synchronous rounds).

TrustedPals [2] is a smart card-based security framework for solving SMC which allows much more efficient solutions to the problem. Conceptually, TrustedPals considers a distributed system in which processes are

Bilder und Tabellen

- Jedes Bild hat eine Bildunterschrift
  - beschreibt das Bild – ohne den restlichen Text vorauszusetzen
  - ist keine Kopie eines Satzes aus dem Text
- Für Tabellen gilt dasselbe analog

Umfang, Layout

- Ziel: 13–15 Seiten,
  - zzgl. Anhang, Verzeichnisse
- Format / Layout:
  - DIN-A4, 12pt Times New Roman, 1,5-zeilig, Blocksatz, autom. Silbentrennung
  - Abstände: oben 3 cm, unten 2 cm, links 4 cm, rechts 2 cm
  - Seitenzahlen: oben (zwischen Textblock und Papierrand)
  - kein Inhaltsverzeichnis

Abschließende Tipps

- Konsistent sein
  - beim Zitieren
  - bei der Verwendung von Fachbegriffen
- Sich an die (deutsche) Sprache halten
  - englische Wörter übersetzen und (wenn nötig) den Originalbegriff beim ersten Mal nennen
  - steht das Wort im Duden? Dann ist es deutsch
  - Fachbegriffe wie IP-Stack, Bridge, Gateway sind ok (1x erklären)
  - teilweise Geschmacksache („I/O“ oder „E/A“?)
- Sparsame Typographie

Häufige Fehler (1)

- Beschwerden, dass der Stoff zu umfangreich ist. Aus jedem Thema lässt sich problemlos ein 10-, 20- oder 60-minütiger Vortrag gestalten. Das ist eben die Vortragskunst.
- Eine Motivation wird vernachlässigt.
- Sich nicht mit dem roten Faden oder der „Message“ auseinanderzusetzen.
- Es werden Dinge vorausgesetzt, die bei Teilen des Publikums nicht bekannt sind.
- Fachbegriffe werden nicht erklärt, Abkürzungen nicht ausgeführt.

Quelle: Weicker & Weicker, Lehrstuhl 4, Univ. Erl.-Nbg. [5]

Häufige Fehler (2)

- Gliederung wird anhand von Stichworten erstellt, die dann in jeweils ein bis zwei Sätzen ausgeführt werden. Meist geht hierbei der rote Faden verloren: die Arbeit wirkt abgehackt und unverständlich
- Gliederung der Folien für den Vortrag oder Gliederung des Vortrags für die Ausarbeitung verwenden
- Zu viel Zeit auf Folien verwenden, aber das Gesprochene improvisieren
- Den Folieninhalt nur vorlesen oder sich an den Folien entlang zu hangeln ohne den Vortrag lebendig werden zu lassen
- Mit Powerpoint-Effekten über inhaltliche Defizite hinwegtäuschen

Quelle: Weicker & Weicker, Lehrstuhl 4, Univ. Erl.-Nbg. [5]

Literatur

[1] Marcus Deininger, Horst Lichter, Jochen Ludewig, Kurt Schneider: Studienarbeiten. Ein Leitfaden zur Vorbereitung, Durchführung und Betreuung von Studien-, Diplom-, Abschluss- und Doktorarbeiten am Beispiel Informatik. vdf, 5. Auflage, 2005.

[2] Albers et al.: Gute wissenschaftliche Praxis für das Verfassen wissenschaftlicher Qualifikationsarbeiten, http://www.hochschulverband.de/cms1/uploads/media/Gute_wiss._Praxis_Fakultaetentage.pdf, Juli 2012.

[3] Wikipedia zu „et al.“: http://de.wikipedia.org/wiki/Et_al.

[4] Peter Rechenberg: Technisches Schreiben. Hanser, 2. Auflage, 2003.

[5] Karsten Weicker, Nicole Weicker: Seminarrichtlinien am Lehrstuhl 4, https://www4.cs.fau.de/Lehre/SS11/PS_KVBK/info/Weicker.pdf

[6] Markus Rath: Leitfaden zur Anfertigung von Seminar-, Studien- und Diplomarbeiten, http://www.wi-inf.uni-duisburg-essen.de/FGFrank/documents/Lehre/Leitfaden_WissArbeit.pdf

Weitere Hinweise zum Seminar

- FOM-Dokument:
  „Leitfaden zur formalen Gestaltung von Seminar- und Abschlussarbeiten“
- über Campus-System verfügbar (von Kursseite aus verlinkt)

Datenformate und Wandlung

Gliederung

Gliederung (1)

- Daten und Informationen
- Zahlensysteme
- ASCII und andere Zeichenkodierungen (ISO-Latin-*, Unicode / UTF)
- Digitalisierung (Bilder, Audio, Video)
- Kompression

Gliederung (2)

- Datenformate
  - Textformate
  - Grafikformate
  - Konverter
- Kommunikationsformate
- Applikationsformate
- Archive und Programmpakete

A. Datenformate und Wandlung

Daten und Informationen (1/7)

Was bedeutet „Information“?

- eine Form von Wissen
- Information hat immer eine Bedeutung
  - Text in einer unbekannten Fremdsprache: bedeutungslos
  - Bedeutung also abhängig vom Betrachter
  - Zusammenhang wichtig (etwa: Text aus einem fremden Fachgebiet)
- Information informiert:
  - Herr Müller informiert Frau Meier
  - Ich informiere mich (selbst) über ...

Daten und Informationen (2/7)

Informationen...

- vielseitig, z. B.
  - Fakten(wissen)
  - Konzepte (die Antwort auf: „Was sind Informationen?“ ist auch eine Information)
  - Anleitungen (z. B. Algorithmen)
- Information an sich hat keine „standardisierte“ Darstellung, etwa in Schriftform

Daten und Informationen (3/7)

Weitergabe von Informationen

- Viele Wege denkbar
  - im direkten Gespräch erzählen
  - eine Vorlesungsstunde darüber halten
  - aufschreiben (Buch? Notizzettel? Tafel?)
  - etwas (ohne Worte) vorführen

Daten und Informationen (4/7)

und „Daten“?

- Repräsentation von Information(en)
- mit oder ohne Struktur

Name	Telefon	Ort
Anton Müller	089/1234567	München
Berta Meier	0241/7343	Aachen
Christian Bauer	0211/64834	Düsseldorf
Dagmar Grün	02131/46734	Neuss

Wegbeschreibung: aus dem Münchener HBf nach Ankunft links raus, nach dem Ausgang links halten bis zur nächsten großen Kreuzung, diagonal die Kreuzung überqueren, Eingang der FOM liegt an Hauptstraße, im Gebäude in den ersten Stock zur Bibliothek

Daten und Informationen (5/7)

Daten laut Wikipedia:

„In der Informatik und Datenverarbeitung versteht man Daten als (Maschinen-) lesbare und bearbeitbare in der Regel **digitale Repräsentation von Information**. Die Information wird dazu meist zunächst in Zeichen (bzw. Zeichenketten) **kodiert**, deren Aufbau strengen Regeln folgt, der so genannten **Syntax**. Um aus Daten Informationen zu gewinnen, müssen sie in einem **Bedeutungskontext** interpretiert werden.“

Quelle: http://de.wikipedia.org/wiki/Daten

Daten und Informationen (6/7)

- **Repräsentation**
  - eine Form der Darstellung, die gewisse Regeln einhält
  - z. B.: 5 vs. „fünf“ vs. IIIII vs. ~~IIII~~ vs. 
  - für den Betrachter: offensichtlich alle gleichwertig
- Digitale Repräsentation: „im Computer“
- Frage: **Was** kann man **wie** im Computer speichern?

Daten und Informationen (7/7)

- **Kodierung durch Zeichen (-ketten)**
  - Was ist ein Zeichen?
  - Vorschlag: A-Z, a-z, 0-9 und Leerzeichen – gut?
  - Wie speichert der Computer Zeichen?
  - Prinzipiell kennt der Rechner nur zwei Werte: 0 und 1
  - Für alles andere: Umwandlung in Kombinationen aus Nullen und Einsen

Bits und Bytes

- **Bit:** 0 / 1 an / aus wahr / falsch (binary digit – Binärziffer)
- **Bit-Folge:** Zeichenkette, die aus Nullen und Einsen besteht, z. B. 00101, 10
- **Byte:** Bit-Folge aus acht Bits (auch: Oktett), z. B. 01101011, 11111111, 00000000
- Führende Nullen kann man weglassen: 00000010 = 10
- **Wie viele (unterschiedliche) Bytes gibt es?**

Dualzahlen (1/3)

- Bitfolgen auch als Zahlenwerte auffassen: $1_b = 1$, $10_b = 2$, $11_b = 3$, $100_b = 4$, $101_b = 5$ ...
- **Dualzahlen:** Zahlensystem, das zur Darstellung von Zahlen nur die Ziffern 0 und 1 verwendet. Auch **Binärzahlen** genannt
- Rechnen mit Dualzahlen funktioniert wie mit normalen Zahlen. Hier:
  - Addieren + Subtrahieren
  - Multiplizieren

Dualzahlen (2/3)

- Addieren:

```
  001001001
+ 010101110
      1        Übertrag
-----------
= 011110111
```

- Subtrahieren:

```
  011010111
- 010101110
    1 1        Übertrag
-----------
= 000101001
```


Dualzahlen (3/3)

- Multiplizieren

```
101001 x 1001
-------------
      101001
     000000
    000000
   101001
     1          Übertrag
-------------
   101110001
```

Probe:

$101001_b = 41$
$1001_b = 9$
41 x 9 = 369
$101110001_b = 369$

Umrechnung dual → dezimal (1/3)

- Grundlage: Wie funktionieren unsere Zahlen?
- 4982 = 4 x 1000 + 9 x 100 + 8 x 10 + 2 x 1
  = 4 x 10^3 + 9 x 10^2 + 8 x 10^1 + 2 x 10^0
  (von rechts nach links: Einser, Zehner, Hunderter, Tausender, ...)
- Bei Dualzahlen geht das genauso:
- 10011_b = 1 x 2^4 + 0 x 2^3 + 0 x 2^2 + 1 x 2^1 + 1 x 2^0
  = 1 x 16 + 0 x 8 + 0 x 4 + 1 x 2 + 1 x 1
  = 19

Umrechnung dual → dezimal (2/3)

umgekehrt: dezimal → dual etwas komplizierter

49 als Dualzahl?

49 : 2 = 24, Rest	1	Einser
24 : 2 = 12, Rest	0	Zweier
12 : 2 = 6, Rest	0	Vierer
6 : 2 = 3, Rest	0	Achter
3 : 2 = 1, Rest	1	
1 : 2 = 0, Rest	1	-> 110001_b (32+16+1)

Warum geht das? Rechnen Sie mal direkt
110001_b : 2... 110001_b = 2 x 11000_b + 1

Umrechnung dual → dezimal (1/3)

- oder durch „Kopfrechnen“:
  - kleinste 2er-Potenz (2, 4, 8, 16, ...), die in die Zahl 49 „passt“: 32 (nächst größere: 64)
  - also 49 = 32 + ? = 32 + 17
  - 17 = 16 + ? = 16 +1
  - Damit: 49 = 32 + 16 + 1
    = 100000 + 010000 + 000001
    = 110001

Bit, Byte, (Doppel-) Wort

Einheit	Erklärung	Werte	Anzahl Werte
Bit	Binary Digit	0, 1	2
Byte	8 Bit	0 – 255	256
Wort	2 Byte, 16 Bit	0 – 65535	65536
Doppelwort	2 Worte (4 Byte)	0 – 4294967295	4294967296

Kodierung (1/3)

- Was der Computer gut kann:
  Bits und Bytes speichern; auch (Doppel-) Worte und längere Bitfolgen (mehrere Bytes verwenden)
- Problem: allgemeine Daten speichern
- Lösung: „beliebige“ Daten auf Bitfolgen abbilden

Kodierung (2/3)

- Beispiel: „A-Z“ als 1-26 speichern, binär:
  A = 00001, B = 00010, ...

A	00001	H	01000	O	01111	V	10110
B	00010	I	01001	P	10000	W	10111
C	00011	J	01010	Q	10001	X	11000
D	00100	K	01011	R	10010	Y	11001
E	00101	L	01100	S	10011	Z	11010
F	00110	M	01101	T	10100		
G	00111	N	01110	U	10101		

unbenutzt
00000
11011
11100
11101
11110
11111

- Also 5 Bit pro Buchstabe
- HALLO → 01000 00001 01100 01100 01111

Kodierung (3/3)

- Praxis: „nur Großbuchstaben“ unbrauchbar
- Kleinbuchstaben, Zahlen, Sonderzeichen
- erster Standard: ASCII, enthält die Zeichen:
  0-9, A-Z, a-z, das Leerzeichen „ “ und:
  `!"#$%&\'()*+,-./:;<=>?@[\]^_`{|}~`

ASCII-Tabelle (1/2)

- **ASCII = A**merican **S**tandard **C**ode for **I**nformation **I**nterchange:

32		48	0	64	@	80	P	96	`	112	p
33	!	49	1	65	A	81	Q	97	a	113	q
34	"	50	2	66	B	82	R	98	b	114	r
35	#	51	3	67	C	83	S	99	c	115	s
36	$	52	4	68	D	84	T	100	d	116	t
37	%	53	5	69	E	85	U	101	e	117	u
38	&	54	6	70	F	86	V	102	f	118	v
39	'	55	7	71	G	87	W	103	g	119	w
40	(	56	8	72	H	88	X	104	h	120	x
41	)	57	9	73	I	89	Y	105	i	121	y
42	*	58	:	74	J	90	Z	106	j	122	z
43	+	59	;	75	K	91	[	107	k	123	{
44	,	60	<	76	L	92	\	108	l	124	|
45	-	61	=	77	M	93	]	109	m	125	}
46	.	62	>	78	N	94	^	110	n	126	~
47	/	63	?	79	O	95	_	111	o	127	

ASCII-Tabelle (2/2)

- ASCII – und was ist mit Umlauten?
  - „einfach drauf verzichten“ – ae, oe, ue, Ae, Oe, Ue und ss stoeren hoechstens die Uebergenauen
  - Zeichen aus der Zeichentabelle werfen und durch Umlaute ersetzen, etwa
    [→ ä,] → ö, \ → ü,
    { → Ä, } → Ö, | → Ü usw.
  - ASCII verwendet nur 7 Bit (0-127); über achtes Bit neuen Zeichensatz mit Sonderzeichen definieren, z. B. ISO-8859-15 (Westeuropa mit €-Zeichen). Dort: 0-127 wie ASCII, 128-255 Zusatzzeichen

ISO-8859-15

NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
SP	!	"	#	$	%	&	'	(	)	*	+	,	-	.	/
0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
@	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	[	\	]	^	_
`	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	{	|	}	~	DEL
PAD	HOP	BPH	NBH	IND	NEL	SSA	ESA	HTS	HTJ	VTS	PLD	PLU	RI	SS2	SS3
DCS	PU1	PU2	STS	CCH	MW	SPA	EPA	SOS	SGCI	SCI	CSI	ST	OSC	PM	APC
NBSP	¡	¢	£	€	¥	Š	§	š	©	ª	«	¬	SHY	®	¯
°	±	²	³	Ž	µ	¶	·	ž	¹	º	»	Œ	œ	Ÿ	¿
À	Á	Â	Ã	Ä	Å	Æ	Ç	È	É	Ê	Ë	Ì	Í	Î	Ï
Ð	Ñ	Ò	Ó	Ô	Õ	Ö	×	Ø	Ù	Ú	Û	Ü	Ý	Þ	ß
à	á	â	ã	ä	å	æ	ç	è	é	ê	ë	ì	í	î	ï
ð	ñ	ò	ó	ô	õ	ö	÷	ø	ù	ú	û	ü	ý	þ	ÿ

Quelle: http://de.wikipedia.org/wiki/ISO_8859-15

Oktal- und Hexadezimalzahlen (1/9)

- Noch zwei weitere Zahlensysteme
- Bisher:
  - Dualzahlen – Basis 2
  - Dezimalzahlen – Basis 10
- Jetzt:
  - Oktalzahlen – Basis 8
  - Hexadezimalzahlen – Basis 16

Oktal- und Hexadezimalzahlen (2/9)

Oktalzahlen

Basis 8, also
8 Ziffern:
0, 1, 2, 3,
4, 5, 6, 7

$7_o + 1_o = 10_o$

oktal	dez.	binär	oktal	dez.	binär
0	0	0	14	12	1100
1	1	1	15	13	1101
2	2	10	16	14	1110
3	3	11	17	15	1111
4	4	100	20	16	10000
5	5	101	...		
6	6	110	77	63	111111
7	7	111	100	64	1000000
10	8	1000	101	65	1000001
11	9	1001	102	66	1000010
12	10	1010	103	67	1000011
13	11	1011	104	68	1000100

Oktal- und Hexadezimalzahlen (3/9)

Hexadezimalzahlen

- Basis 16, also 16 Ziffern:
  0, 1, 2, 3, 4, 5, 6, 7, 8, 9, A, B, C, D, E, F
  10 11 12 13 14 15
- $9_h + 1_h = A_h$,
  $F_h + 1_h = 10_h$ (mit Wert 16)

Oktal- und Hexadezimalzahlen (4/9)

hex.	dez.	binär	hex.	dez.	binär	hex.	dez.	binär
0	0	0	10	16	10000	20	32	100000
1	1	1	11	17	10001	21	33	100001
2	2	10	12	18	10010	22	34	100010
3	3	11	13	19	10011	23	35	100011
4	4	100	14	20	10100	24	36	100100
5	5	101	15	21	10101	25	37	100101
6	6	110	16	22	10110	26	38	100110
7	7	111	17	23	10111	27	39	100111
8	8	1000	18	24	11000	...		
9	9	1001	19	25	11001	FF	255	11111111
A	10	1010	1A	26	11010	100	256	100000000
B	11	1011	1B	27	11011	101	257	100000001
C	12	1100	1C	28	11100	102	258	100000010
D	13	1101	1D	29	11101	...		
E	14	1110	1E	30	11110	FFF	4095	111111111111
F	15	1111	1F	31	11111	1000	4096	1000000000000

Oktal- und Hexadezimalzahlen (5/9)

- Umrechnen Dual ↔ Oktal
  und Dual ↔ Hexadezimal
  ist also leicht:
- Jede Ziffer einer Oktalzahl wird zu drei Bits:
  $307_o = 011\ 000\ 111_b$
- Jede Ziffer einer Hex.-Zahl wird zu vier Bits:
  $3AF_h = 0011\ 1010\ 1111_b$

Oktal- und Hexadezimalzahlen (6/9)

Umrechnen in Dezimalzahlen: Wie bei Dualzahlen, aber mit anderer Basis

- $1101_b = 1 \times \underline{2}^3 + 1 \times \underline{2}^2 + 0 \times \underline{2}^1 + 1 \times \underline{2}^0 = 13$
- $1734_o = 1 \times \underline{8}^3 + 7 \times \underline{8}^2 + 3 \times \underline{8}^1 + 4 \times \underline{8}^0 = 988$
- $1A3F_h = 1 \times \underline{16}^3 + 10 \times \underline{16}^2 + 3 \times \underline{16}^1 + 15 \times \underline{16}^0 = 6719$
- zur Erinnerung im Dezimalsystem:
  $3921 = 3 \times 10^3 + 9 \times \underline{10}^2 + 2 \times \underline{10}^1 + 1 \times \underline{10}^0 = 6719$

Oktal- und Hexadezimalzahlen (7/9)

Umrechnen von Dezimal- in Oktal- oder Hexadezimalzahlen:

- entweder in zwei Schritten – erst in Dualzahlen umrechnen, dann 3er- bzw. 4er-Gruppen zusammenfassen:
  $80 = 001\ 010\ 000_b = 120_o = 0101\ 0000_b = 50_h$
- oder durch schriftliches Dividieren wie bei Umrechnen in Dualzahl, aber diesmal mit Divisor 8 oder 16

Oktal- und Hexadezimalzahlen (8/9)

942 als Hexadezimalzahl?

942	: 16	= 58,	Rest	14 (E)	Einser	(16^0)
58	: 16	= 3,	Rest	10 (A)	16er	(16^1)
3	: 16	= 0,	Rest	3	256er	(16^2)

→ $3AE_h$ (3 x 256 + 10 x 16 + 14 x 1)

Warum geht das? Rechnen Sie mal direkt
$3AE_h$: 16... $3AE_h = 16 \times 3A_h + E_h$

Oktal- und Hexadezimalzahlen (9/9)

942 als Oktalzahl?

942	: 8	= 117,	Rest	6	Einser	(8^0)
117	: 8	= 14,	Rest	5	8er	(8^1)
14	: 8	= 1,	Rest	6	64er	(8^2)
1	: 8	= 0,	Rest	1	512er	(8^3)

→ 1656_o (1 x 512 + 6 x 64 + 5 x 8 + 6 x 1)

Wie bei Hexadez.-Zahlen: Rechnen Sie mal direkt
1656_o : 8... $1656_o = 8 \times 165_o + 6_o$

Warum hexadezimal? (1/3)

- deckt praktische (häufig benutzte) Bereiche ab
- z. B.: Home-Computer mit 64 KByte RAM
  64 KByte = 64 x 1024 Byte = 65 536 Byte
  → hexadezimal: 10000_h Byte
  also Adressen: 0000_h – $FFFF_h$
- z. B.: PC mit 1 GByte RAM
  1 GByte = 1024 x 1024 x 1024 Byte
  = 1 073 741 824 Byte
  → hexadezimal: 40000000_h Byte
  also Adressen: 00000000_h – $3FFFFFFF_h$

Warum hexadezimal? (2/3)

- Kodierung von Bytes (z. B.: ASCII-Zeichen), also 8 Bit, durch zwei Hex-Zahlen:

hex	dez	hex	dez	hex	dez	hex	dez	hex	dez	hex	dez	hex	dez	hex	dez		hex	dez
00	0	10	16	20	32	30	48	40	64	50	80	60	96	70	112		F0	240
01	1	11	17	21	33	31	49	41	65	51	81	61	97	71	113		F1	241
02	2	12	18	22	34	32	50	42	66	52	82	62	98	72	114		F2	242
03	3	13	19	23	35	33	51	43	67	53	83	63	99	73	115		F3	243
04	4	14	20	24	36	34	52	44	68	54	84	64	100	74	116		F4	244
05	5	15	21	25	37	35	53	45	69	55	85	65	101	75	117		F5	245
06	6	16	22	26	38	36	54	46	70	56	86	66	102	76	118	...	F6	246
07	7	17	23	27	39	37	55	47	71	57	87	67	103	77	119		F7	247
08	8	18	24	28	40	38	56	48	72	58	88	68	104	78	120		F8	248
09	9	19	25	29	41	39	57	49	73	59	89	69	105	79	121		F9	249
0A	10	1A	26	2A	42	3A	58	4A	74	5A	90	6A	106	7A	122		FA	250
0B	11	1B	27	2B	43	3B	59	4B	75	5B	91	6B	107	7B	123		FB	251
0C	12	1C	28	2C	44	3C	60	4C	76	5C	92	6C	108	7C	124		FC	252
0D	13	1D	29	2D	45	3D	61	4D	77	5D	93	6D	109	7D	125		FD	253
0E	14	1E	30	2E	46	3E	62	4E	78	5E	94	6E	110	7E	126		FE	254
0F	15	1F	31	2F	47	3F	63	4F	79	5F	95	6F	111	7F	127		FF	255

Warum hexadezimal? (3/3)

- Für viele Aufgaben ist Hex-Darstellung der Standard, z. B. Analyse von Binärdateien:

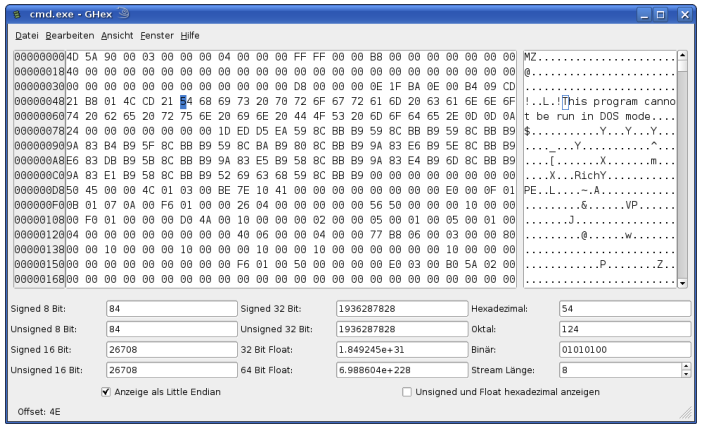

Zahlensysteme

- Sie kennen nun bereits vier Zahlensysteme:

System	Basis	Ziffern
• Dezimalsystem	10	0 – 9
• Dualsystem	2	0, 1
• Oktalsystem	8	0 – 7
• Hexadezimalsystem	16	0 – 9, A – F

- Das Ganze lässt sich auf beliebige Basen verallgemeinern: Basis *n* mit *n* Ziffern; z. B. Basis 32 mit Ziffern 0 – 9, A (10) – V (31)

Kodierung: Übungen (1/2)

1. Stellen Sie den folgenden Text:
   `Infrastruktur`
   - im Dezimalformat (normales 10er-System),
   - im Hexadezimalformat, Oktalformat und Dualformat dar. Wählen Sie dafür eine sinnvolle Reihenfolge!

   Dazu benötigen Sie:
   - ASCII-Tabelle (1. Schritt)
   - Hex/Oktal/Dual-Tabellen (2. Schritt)

Kodierung: Übungen (2/2)

2. a) Wie viele 16-stellige Bitfolgen gibt es?
   b) Wie viele verschiedene Worte („Doppel-Bytes“) gibt es?
3. Rechnen Sie die Hexadezimalzahl **$A01F_h$** in Dual- und Oktaldarstellung um.
4. Wenn Sie wissen, dass **$FF_h = 100_h - 1$** gilt, wie können Sie dann schnell **FFF_h** und **$FFFF_h$** in Dezimalzahlen umrechnen?

Zahlensysteme: Fragen (1/2)

- Aus welchen Zahlensystemen kann die folgende Zahl stammen? Aus welchen nicht? Warum? **41823**
  - Berücksichtigen Sie: Dual-, Oktal-, Dezimal- und Hexadezimalsystem.
- Können Sie **2049** (dezimal) ganz schnell in eine Dualzahl umrechnen?
- Wie sieht das Wort „Übung“ in ASCII-Darstellung aus? (Achtung: Fangfrage)

Zahlensysteme: Fragen (2/2)

- Was ist größer: **74_h** oder **75** ?
- Wie viele Hexadezimalzahlen liegen zwischen $7A7_h$ und $8B8_h$? (Zählen Sie die beiden „begrenzenden“ Zahlen mit.)

Größenordnungen

Name (Symbol)	SI-konforme Bedeutung[1)]	„klassische“ Bedeutung	Unterschied
Kilobyte (kB)	10^3 Byte = 1.000 Byte	2^{10} Byte = 1.024 Byte	2,4 %
Megabyte (MB)	10^6 Byte = 1.000.000 Byte	2^{20} Byte = 1.048.576 Byte	4,9 %
Gigabyte (GB)	10^9 Byte = 1.000.000.000 Byte	2^{30} Byte = 1.073.741.824 Byte	7,4 %
Terabyte (TB)	10^{12} Byte = 1.000.000.000.000 Byte	2^{40} Byte = 1.099.511.627.776 Byte	10,0 %
Petabyte (PB)	10^{15} Byte = 1.000.000.000.000.000 Byte	2^{50} Byte = 1.125.899.906.842.624 Byte	12,6 %
Exabyte (EB)	10^{18} Byte = 1.000.000.000.000.000.000 Byte	2^{60} Byte = 1.152.921.504.606.846.976 Byte	15,3 %
Zettabyte (ZB)	10^{21} Byte = 1.000.000.000.000.000.000.000 Byte	2^{70} Byte = 1.180.591.620.717.411.303.424 Byte	18,1 %

[1)] SI: Internationales Einheitensystem (Système International d'Unités) Quelle: Wikipedia, „Byte“

Informationen speichern

- Bisher: Einfache Texte (z. B. im ASCII- oder ISO-8859-15-Format) in Bytes gespeichert
- Was tun mit analogen Daten?
  - Wie speichert ein digitaler Fotoapparat Bilder?
  - Wie speichert ein MP3-Player Musik?
  - Was unterscheidet Schallplatte und CD?
- Digitalisierung von analogen Daten

Digitalisierung analoger Daten

- **Rasterung** (**Diskretisierung**): Abtasten (Sampling) an diskreten zeitlichen oder örtlichen Punkten
  - diskret = nur endlich viele Werte
  - Gegenteil: kontinuierlich, z.B. Werte aus ℚ
- **Quantisierung** der abgetasteten Werte (runden auf wenige mögliche Werte)
- **Digitalisierung** (Kodierung): Darstellung des abgetasteten und quantisierten Signals als Digitalcode

Zeitliche Digitalisierung

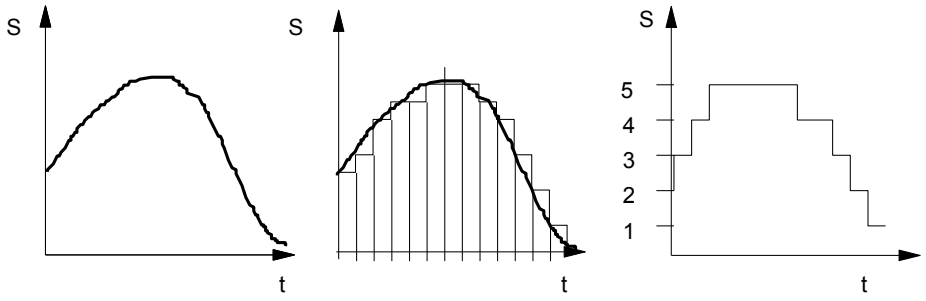

analoges Signal

„gesampelt“: Proben zu festen Zeitpunkten gezogen – noch mit exakten Werten

quantisiert: alle Messwerte auf 1, 2, 3, 4, 5 gerundet

Örtliche Digitalisierung

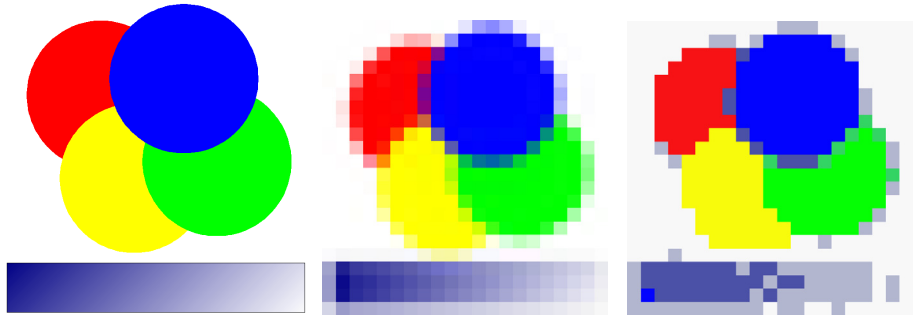

gleichmäßige Färbung über ganze Bereiche

begrenzt viele (diskrete) Farbabstufungen

Kodierung von Farbinformation: Die Farbe eines Bildpunktes ist eine additive Mischung der 3 Grundfarben Rot, Grün und Blau → für Darstellung des Farbbildes wird die Rot-, Grün- und Blau-Intensität für jeden Bildpunkt separat digitalisiert.

Gebräuchliche Datenformate

- Text: ASCII/ANSI/Unicode (.txt), RTF (.rtf), Word (.doc), LibreOffice (.odt)
- Tabellen: Excel (.xls), LibreOffice (.ods)
- Dokumente: .doc, .pdf, HTML (.html / .htm), …
- strukturierte Daten: XML
- Rastergrafik: Bitmap (.bmp), Graphics Interchange Format (.gif), JPEG, TIFF, PNG
- CAD: VDA-FS, IGES, STEP
- Audiodateien: MP3 (.mp3), Ogg Vorbis (.ogg)
- Bildfolgen (Video): MPEG

Alltagsthemen der Kodierung

- Reduktion der Datenmenge durch Kompression
  - verlustfrei
  - verlustbehaftet
- Fehlerhafte Darstellung aufgrund ungleicher Zeichenvorräte bei Sender und Empfänger (z. B. bei Darstellung von nationalen Sonderzeichen)
- Fehlerhafte Übertragung
  → Codes mit Fehlererkennung, Fehlerkorrektur
- Verschlüsselung, Signatur

Kompression (1/3)

- Einfaches Verfahren:
  - „AAAAABBCCCCCCCCDD“ → „5A2B8C2D“ (kürzer)
  - aber: „ABCDAB“ → „1A1B1C1D1A1B“ (länger)
- verlustbehaftet:
  - „IT-Infrastruktur“ → „it infrastruktur“ (kleineres Alphabet: a-z + Leerzeichen = 27 Zeichen, weniger Bits pro Zeichen)
  - „IT-Infrastruktur“ → „TNFRSTRKTR“ (gleiches Prinzip; hier: Verzicht auf Vokale)

Kompression (2/3)

- Besseres Verfahren: Buchstabenhäufigkeiten
  - Welche Buchstaben kommen wie häufig vor? Reihenfolge („top ten“) festlegen, z. B. a, e, i, o, u, n, t, s, r, p, k, l, m, ..., q, y
- Dann Kodierung
  - von „häufigen“ Buchstaben in kurze Bitfolgen
  - und von „seltenen“ Buchstaben in lange Bitfolgen
  - z. B. a → 000, e → 001, i → 010, o → 011,
    u → 1000, n → 1001, t → 1010, s → 1011,
    r → 11000, k → 11001, l → 11010, m → 11011,
    ..., q → 11111001, y → 11111010

Kompression (3/3)

- Beispiele mit obiger Tabelle:
  - „nein“ → 1001 001 010 1001
  - „test“ → 1010 001 1011 1010
  - „mlml“ → 11011 11010 11011 11010
  - „qyqy“ → 11111001 11111010 11111001 11111010
- Je „unwahrscheinlicher“ ein Wort, desto länger seine Kodierung

Fehlererkennung (1/3)

- Übertragung von digitalen Daten (etwa über eine Telefonleitung oder ein Datenkabel zwischen zwei PCs) ist oft fehlerhaft:
  - einzelne Bits „kippen“ bei der Übertragung
  - einzelne Bits gehen bei der Übertragung komplett verloren
- Fehlererkennung: Übertragen von zusätzlichen Informationen, mit denen Fehler erkannt werden

Fehlererkennung (2/3)

- Einfachste Möglichkeit: Alles doppelt senden
  - Empfänger vergleicht die beiden empfangenen Infomationen, die identisch sein sollten – sind sie es nicht, hat es einen Fehler gegeben
  - Wahrscheinlichkeit, dass die Daten zweimal mit exakt demselben Fehler übertragen werden, ist klein
  - Verfahren ist aber sehr aufwendig:
    - Verdopplung der übertragenen Datenmenge
    - d. h. Halbierung der Übertragungsgeschwindigkeit

Fehlererkennung (3/3)

- Idee: Daten mit **Prüfsummen** versehen
  - einfaches Beispiel: 7 Bit (ASCII-Zeichen) um sog. **Paritäts-Bit** ergänzen:
  - Im ASCII-Code ist das höchstwertige (ganz links) stehende Bit immer 0
  - Verwende dieses Bit wie folgt:
    - Wenn die Summe der übrigen Bits ungerade ist, setze es auf 1
    - Wenn die Summe der übrigen Bits gerade ist, setze es auf 0

ASCII + Paritätsbit

	ASCII	ASCII binär (nur 7 Bit)	Anzahl Einsen	ASCII + Paritätsbit
A	65	01000001	gerade	**0**1000001
B	66	01000010	gerade	**0**1000010
C	67	01000011	ungerade	**1**1000011
D	68	01000100	gerade	**0**1000100
E	69	01000101	ungerade	**1**1000101

- In den Bytes **mit** Paritätsbit: Anzahl Einsen immer gerade
- „Kippt“ ein Bit, fällt der Fehler auf
- Kippen zwei Bits, dann nicht...

Übung: ASCII-Fehlerkorrektur

- Sie haben folgende Nachricht (binär) erhalten: 01001000, 11100001, 11101100, 11101110, 01101111
- Prüfen Sie zunächst, welche Zeichen ohne „Bit-Kipper“ übertragen wurden
  - Für alle korrekt empfangenen schlagen Sie in der ASCII-Tabelle den zugehörigen Buchstaben nach,
  - für alle fehlerhaft empfangenen setzen Sie ein Fragezeichen ein.

65	A	97	a
66	B	98	b
67	C	99	c
68	D	100	d
69	E	101	e
70	F	102	f
71	G	103	g
72	H	104	h
73	I	105	i
74	J	106	j
75	K	107	k
76	L	108	l
77	M	109	m
78	N	110	n
79	O	111	o
80	P	112	p
81	Q	113	q
82	R	114	r
83	S	115	s
84	T	116	t
85	U	117	u
86	V	118	v
87	W	119	w
88	X	120	x
89	Y	121	y
90	Z	122	z

Datenformate: Text, *.txt (1/8)

- ASCII bereits vorgestellt
- Problem: Regionale Zeichen (äöüßñš...) nicht in ASCII-Tabelle
- Erweiterungen der ASCII-Tabelle
  - 8-bittig: Zeichen 128-255 verwenden
  - 16-bittig: Platz für „alles“, inkl. Kyrillisch, Chinesisch, Japanisch etc.
  - „Mischform“ 8- und 16-bittig

Datenformate: Text, *.txt (2/8)

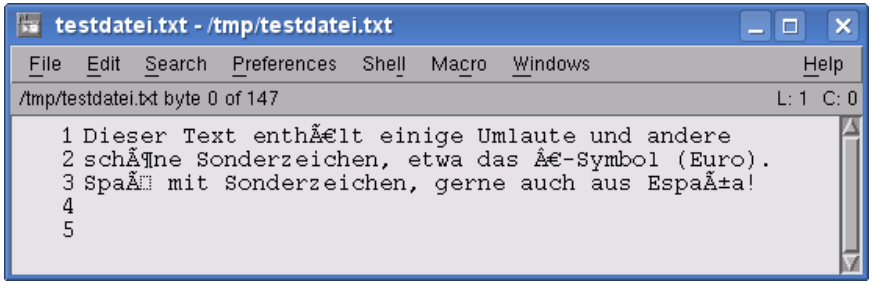

Was ist hier passiert?

Datenformate: Text, *.txt (3/8)

- Es gibt etliche Kodierungen für Textdateien
- Man muss wissen, in welcher Kodierung eine Datei gespeichert wurde
- Alternative: selbst-beschreibende Datei

```
<html>
<head>
<title>Eine Webseite</title>
<meta http-equiv="Content-Type"
      content="text/html; charset=iso-8859-1">
...
```


Datenformate: Text, *.txt (4/8)

Wichtige Kodierungen:

- **Latin-1** (iso-8859-1, ISO/IEC 8859-1, westeuropäisch)

¡¢£¤¥¦§¨©ª«¬ ®¯
°±²³´µ¶·¸¹º»¼½¾¿
ÀÁÂÃÄÅÆÇÈÉÊËÌÍÎÏ
ÐÑÒÓÔÕÖ×ØÙÚÛÜÝÞß
àáâãäåæçèéêëìíîï
ðñòóôõö÷øùúûüýþÿ

- **Latin-9** (iso-8859-15, ISO/IEC 8859-15, westeuropäisch)
  - gegenüber Latin-1 mehr Buchstaben, weniger math. Symbole
  - u.a. € und Š, š, Ž, ž, Œ, œ, Ÿ

Datenformate: Text, *.txt (5/8)

Unicode

- Ziel: Alle Zeichen aus allen Schriftarten der Welt unterstützen
- bis zu 1.114.112 Zeichen in 17 Codebereichen („Planes“) mit je 65.536 (64K) Zeichen
- aktuell (Unicode 5.1): 100.713 Zeichen
- wichtigster Codebereich: **BMP** (Basic Multilingual Plane) mit allen aktuellen Schriftsystemen
- aber: keine 21-bittige Kodierung, sondern ...

Datenformate: Text, *.txt (6/8)

Unicode-Formate / UTF-16, UTF-8

- UTF-8
  - ASCII-Zeichen (0–127) „normal“ (8-bittig) kodiert
  - andere Zeichen 16-, 24- oder 32-bittig (also über zwei, drei oder vier Bytes) kodiert
  - z. B. deutsche Umlaute: je zwei Bytes
- UTF-16
  - Zeichen der **BMP** 16-bittig (mit 2 Bytes) kodiert
  - sonstige Zeichen 32-bittig (mit 4 Bytes) kodiert

Datenformate: Text, *.txt (7/8)

Beispiele: Umlaute ÄÖÜ, äöü, ß. (in Latin-9 erzeugt)
Euro: €. Britisches Pfund: £.
Französische «Anführungen»

Latin-9-Kodierung:

```
00000000  42 65 69 73 70 69 65 6c  65 3a 20 55 6d 6c 61 75  |Beispiele: Umlau|
00000010  74 65 20 c4 d6 dc 2c 20  e4 f6 fc 2c 20 df 2e 0a  |te ÄÖÜ, äöü, ß..|
00000020  45 75 72 6f 3a 20 a4 2e  20 42 72 69 74 69 73 63  |Euro: €. Britisc|
00000030  68 65 73 20 50 66 75 6e  64 3a 20 a3 2e 0a 46 72  |hes Pfund: £..Fr|
00000040  61 6e 7a f6 73 69 73 63  68 65 20 ab 41 6e 66 fc  |anzösische «Anfü|
00000050  68 72 75 6e 67 65 6e bb                           |hrungen»|
```

UTF-8-Kodierung:

```
00000000  42 65 69 73 70 69 65 6c  65 3a 20 55 6d 6c 61 75  |Beispiele: Umlau|
00000010  74 65 20 c3 84 c3 96 c3  9c 2c 20 c3 a4 c3 b6 c3  |te Ã.Ã.Ã., Ã¤Ã¶Ã|
00000020  bc 2c 20 c3 9f 2e 0a 45  75 72 6f 3a 20 c2 a4 2e  |¼, Ã...Euro: Â¤.|
00000030  20 42 72 69 74 69 73 63  68 65 73 20 50 66 75 6e  | Britisches Pfun|
00000040  64 3a 20 c2 a3 2e 0a 46  72 61 6e 7a c3 b6 73 69  |d: Â£..FranzÃ¶si|
00000050  73 63 68 65 20 c2 ab 41  6e 66 c3 bc 68 72 75 6e  |sche Â«AnfÃ¼hrun|
00000060  67 65 6e c2 bb                                    |genÂ»|
```


Datenformate: Text, *.txt (8/8)

UTF-16-Kodierung:

```
00000000  fe ff 00 42 00 65 00 69  00 73 00 70 00 69 00 65  |þÿ.B.e.i.s.p.i.e|
00000010  00 6c 00 65 00 3a 00 20  00 55 00 6d 00 6c 00 61  |.l.e.:. .U.m.l.a|
00000020  00 75 00 74 00 65 00 20  00 c4 00 d6 00 dc 00 2c  |.u.t.e. .Ä.Ö.Ü.,|
00000030  00 20 00 e4 00 f6 00 fc  00 2c 00 20 00 df 00 2e  |. .ä.ö.ü.,. .ß..|
00000040  00 0a 00 45 00 75 00 72  00 6f 00 3a 00 20 00 a4  |...E.u.r.o.:. .€|
00000050  00 2e 00 20 00 42 00 72  00 69 00 74 00 69 00 73  |... .B.r.i.t.i.s|
00000060  00 63 00 68 00 65 00 73  00 20 00 50 00 66 00 75  |.c.h.e.s. .P.f.u|
00000070  00 6e 00 64 00 3a 00 20  00 a3 00 2e 00 0a 00 46  |.n.d.:. .£.....F|
00000080  00 72 00 61 00 6e 00 7a  00 f6 00 73 00 69 00 73  |.r.a.n.z.ö.s.i.s|
00000090  00 63 00 68 00 65 00 20  00 ab 00 41 00 6e 00 66  |.c.h.e. .«.A.n.f|
000000a0  00 fc 00 68 00 72 00 75  00 6e 00 67 00 65 00 6e  |.ü.h.r.u.n.g.e.n|
000000b0  00 bb                                             |.»|
```

Dateigrößen:

```
test-latin9.txt      88 Bytes
test-utf8.txt       101 Bytes
test-utf16.txt      178 Bytes
```


Besondere Textformate

- Neben reinen Textformaten (ASCII, ISO-Latin-*, UTF): Textformate mit Auszeichnungen (Markup)
  - HTML (**H**yper**T**ext **M**arkup **L**anguage) (Webseiten)
  - LaTeX (Textsatz-Auszeichnungssprache)
  - SGML (**S**tandard **G**eneralized **M**arkup **L**anguage)
  - XML (E**x**tensible **M**arkup **L**anguage) (Grundlage für viele Markup-Sprachen)
  - Wikitext (Texte in Wikis)

Markup-Sprachen

- Markup-Sprachen ergänzen den reinen Text mit Markup-Elementen
- Zweierlei Markup möglich:
  - „Grafisches“ Markup (fett, kursiv, Schriftgröße)
  - Struktur-Markup (Kapitelanfang, Zitat)
  - Kombination (mit Stylesheets)
- Markup unabhängig von Kodierung der Textinhalte; oft beliebige Kodierung möglich

HTML, LaTeX und Wikitext

Beispiele: HTML, LaTeX, Wikitext

Beispiel für	HTML	LaTeX	Wikitext
Überschrift	`<h1>Überschrift</h1>`	`\section{Überschrift}`	`= Überschrift =`

Aufzählung	`<ul>`
	`<li>Punkt 1</li>`
	`<li>Punkt 2</li>`
	`<li>Punkt 3</li>`
	`</ul>`
		`\begin{itemize}`
		`\item Punkt 1`
		`\item Punkt 2`
		`\item Punkt 3`
		`\end{itemize}`
			`* Punkt 1`
			`* Punkt 2`
			`* Punkt 3`

fetten Text	`<b>fett</b>`	`\textbf{fett}`	`'''fett'''`
kursiven Text	`<i>kursiv</i>`	`\textit{kursiv}`	`''kursiv''`

Quelle: Wikipedia, http://de.wikipedia.org/wiki/Auszeichnungssprache#Beispiele

Datenformate: HTML / *.html (1/8)

- Grober Aufbau eines HTML-Dokuments:

```
<html>
  <head>
    <title>Titel des Dokuments</title>
  </head>
  <body>
    <h1>Überschrift</h1>
    <p>Ein Absatz Text reicht für das Beispiel</p>
  </body>
</html>
```

- unterteilt in Head und Body
- öffnende und schließende Tags <xyz>, </xyz>

Datenformate: HTML / *.html (2/8)

- < und > sind Kontrollzeichen, die ein Tag einleiten / beenden
- Um „<“ oder „>“ im Text zu verwenden:
  - `<` (less than) „<“
  - `>` (greater than) „>“
  - Beispiel:
    `Das Tag <html>` → Das Tag <html>
- Sonderzeichen: `&auml;` (ä), `&Auml;` (Ä) etc., `&szlig;` (ß, „S-Z-Ligatur“); `&euro;` (€)

Datenformate: HTML / *.html (3/8)

- Cascading Stylesheets (CSS):
  - trennen die inhaltliche von der grafischen Auszeichnung
  - Texte verwenden Tags mit Klassenangabe
  - Stylesheet enthält Layout-Definition für das Tag und die Klasse
- Position des Stylesheets
  - wahlweise direkt in der HTML-Datei
  - oder in separater *css*-Datei

Datenformate: HTML / *.html (4/8)

- Ziel: Drei Absätze in verschiedenen Zeichenformatierungen
  - Arial, 20 pt
  - Courier, 15 pt
  - Times, 10 pt

Das ist ein Stylesheet-Test. (Arial 20pt)

Das ist ein Stylesheet-Test. (Courier 15pt)

Das ist ein Stylesheet-Test. (Times 10pt)

Datenformate: HTML / *.html (5/8)

- Formatierung ohne CSS, direkt mit `style=...`

```
<html>
<head><title>Test ohne CSS-Datei</title></head>
<body>

<p style="font-family: arial;
          font-size: 20pt">
Das ist ein Stylesheet-Test. (Arial 20pt)
</p>

<p style="font-family: courier;
          font-size: 15pt">
Das ist ein Stylesheet-Test. (Courier 15pt)
</p>

<p style="font-family: times;
          font-size: 10pt">
Das ist ein Stylesheet-Test. (Times 10pt)
</p>
```


Datenformate: HTML / *.html (6/8)

- Formatierung mit CSS-Datei

```
<html>
<head><title>Test mit CSS-Datei</title>
<link rel="stylesheet" type="text/css"
      href="/stylesheet.css"> </head>
<body>

<p class="arial20">
Das ist ein Stylesheet-Test. (Arial 20pt)
</p>

<p class="courier15">
Das ist ein Stylesheet-Test. (Courier 15pt)
</p>

<p class="times10">
Das ist ein Stylesheet-Test. (Times 10pt)
</p>
```

Stylesheet-Datei:

```
p.arial20 {
  font-family: arial;
  font-size: 20pt;
}

p.courier15 {
  font-family: courier;
  font-size: 15pt;
}

p.times10 {
  font-family: times;
  font-size: 10pt;
}
```


Datenformate: HTML / *.html (7/8)

- Aufbau der Einträge in der CSS-Datei

Es geht um das <p>-Attribut

in einer Klasse *arial20*

```
p.arial20 {
  font-family: arial;
  font-size:   20pt;
}
```

Das sind die Eigenschaften

Datenformate: HTML / *.html (8/8)

- Hier keine vollständige Einführung in HTML und CSS
- Gute Dokumentation im Web: SelfHTML http://de.selfhtml.org/

Datenformate: LaTeX / *.tex (1/4)

- TeX (sprich: „Tech“) ist eine Dokumenten-beschreibungssprache, LaTeX ein Makropaket für TeX. Man benutzt meist LaTeX
- Auszeichnung von Kapitelüberschriften, Zitaten, … über LaTeX-Befehle, z. B. `\section{Abschnitt}`, `\begin{quotation}` … `\end{quotation}`

Datenformate: LaTeX / *.tex (2/4)

- kleines Beispieldokument

```
\documentclass{article}
\begin{document}

\tableofcontents   % erzeuge Inhaltsverzeichnis

\section{Erster Abschnitt}

Hallo, das ist ein Beispieltext mit einem
\emph{hervorgehobenen} und einem \textbf{fett}
geschriebenen Wort.

\end{document}
```


Datenformate: LaTeX / *.tex (3/4)

- TeX/LaTeX selbst arbeitet wie ein Compiler und erzeugt aus den Eingabedateien (*.tex) PDF-Dateien
- Wie bei Programmiersprachen: Syntax- und komplexere Fehler möglich, die zum Abbruch führen können
- LaTeX kann aber auch unabhängig vom LaTeX-Compiler als eigenständiges Datenformat verstanden werden → Converter *latex2html*

Datenformate: LaTeX / **.tex* (4/4)

LyX
(LaTeX-GUI)

Quelle Bild:
http://www.lyx.org

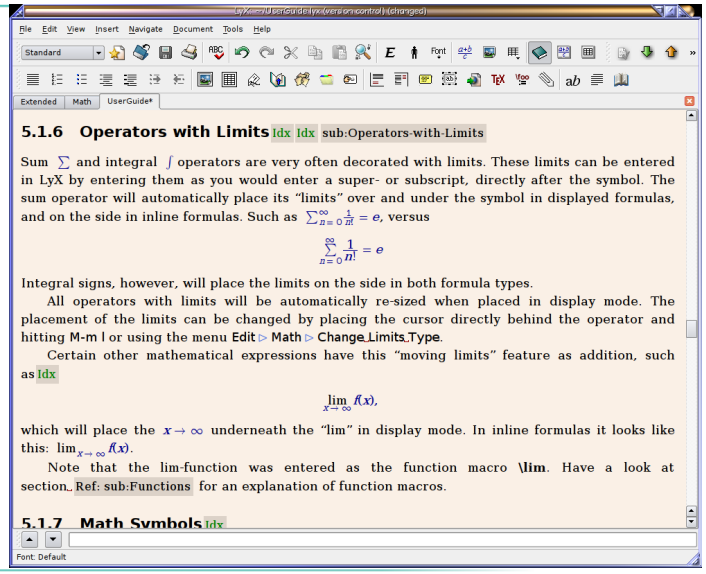

Datenformate: XML / **.xml* (1/6)

- **HTML:** Markup-Sprache mit fest vorgegebenen Tags (z. B. <head>, <font>, <p>, <table> etc.)
- **XML:** E**x**tensible **M**arkup **L**anguage
- **XML** erlaubt es, **eigene** Markup-Sprachen mit HTML-ähnlicher Syntax zu definieren
- unterscheiden zwischen
  - Dokument, das die Regeln für die eigene Sprache definiert (→ **DTD**, Document Type Definition)
  - Dokument, das nach diesen Regeln erstellt (ausgezeichnet) wurde

Datenformate: XML / **.xml* (2/6)

- Eine DTD ist nicht zwingend nötig – wenn es eine gibt, erlaubt sie das **Validieren** von XML-Dokumenten
- Ohne DTD nur allgemeine Syntaxprüfung möglich

Datenformate: XML / **.xml* (3/6)

Syntaxfehler (nicht „wohlgeformt“)

```
<person>
  <name>Müller</name>
  <ort>München</tor>
  <tel v="0123456" />
</person>

<person>
  <name>Meier</name>
  <ort>Augsburg</ort>
  <tel v="0987641">
</person>

<person>
  <name>Huber
  <ort>Erlangen
  </name>
  </ort>
  <tel v="0448"></tel>
</person>
```

DTD-Fehler (nicht „gültig“)

```
<person>
  <wer>Müller</wer>
  <wo>München</wo>
  <tel v="0123456" />
</person>

<leute>
  <name>Meier</name>
  <ort>Augsburg</ort>
  <tel v="0123456" />
</leute>

<person> !
  <ort>Erlangen</ort>
  <tel v="0448" />
</person>
```

(im letzten Eintrag fehlt ein vorgeschriebenes <name> Element)

alles korrekt

```
<person>
  <name>Müller</name>
  <ort>München</ort>
  <tel v="0123456" />
</person>

<person>
  <name>Meier</name>
  <ort>Augsburg</ort>
  <tel v="0987641" />
</person>

<person>
  <name>Huber</name>
  <ort>Erlangen</ort>
  <tel v="0448" />
</person>
```

Datenformate: XML / *.xml (4/6)

- XML erlaubt Transformation von Dokumenten in andere Darstellungen
- **XSLT:** XSL Transformation (**XSL** = E**x**tensible **S**tylesheet **L**anguage)
- Syntax recht komplex; siehe http://de.wikipedia.org/wiki/XSL_Transformation

Datenformate: XML / *.xml (5/6)

- XHTML: Neuformulierung von HTML in XML
- Abweichungen minimal, z. B.:
  - alle Tags müssen geschlossen werden
  - Attribute immer in Anführungen
  - nur Kleinschreibung

```
<!DOCTYPE html ... >
<html>
...
<H1>Test</H1>
<img src="test.jpg">
<td width=10 height=10>
<ul>
  <li>Eintrag 1
  <li>Eintrag 2
</ul>
```

von HTML zu XHTML

```
<?xml version="1.0" encoding="UTF-8" ?>
<!DOCTYPE html  .... >
<html xmlns="http://www.w3.org/1999/xhtml" ...>
...
<h1>Test</h1>
<img src="test.jpg" />
<td width="10" height="10">
<ul>
  <li>Eintrag 1</li>
  <li>Eintrag 2</li>
</ul>
```


Datenformate: XML / *.xml (6/6)

- **DocBook:** XML-basiertes Format für komplexe Dokumente, z. B.
  - Bücher
  - technische Dokumentation

```
<?xml version='1.0' encoding='UTF-8'?>
<!DOCTYPE book PUBLIC "-//OASIS//DTD DocBook XML V4.2//EN" ...>
<book lang="de">
  <bookinfo>
    <title>
      Ein kurzes Buch
    </title>
  </bookinfo>
  <chapter>
    <title>
      Das erste Kapitel
    </title>
    <para>
      Ein einziger Absatz füllt das erste Kapitel.
    </para>
  </chapter>
</book>
```


Datenformate: SGML

- SGML: **S**tandard **G**eneralized **M**arkup **L**anguage
- gleicher Ansatz wie bei XML, erlaubt aber noch komplexere Dinge, z. B. Unterdokumente
- genauer:

„The Extensible Markup Language (XML) is a subset of SGML [...]. Its goal is to enable generic SGML to be served, received, and processed on the Web in the way that is now possible with HTML. XML has been designed for ease of implementation and for interoperability with both SGML and HTML.“

Quelle: http://www.w3.org/TR/2006/REC-xml-20060816/

Word & LibreOffice Writer

- Auch Word- und LibreOffice-Textdateien bestehen aus Inhalt + Formatierung
- Alte Versionen von Word und OpenOffice (LibreOffice-Vorläufer) verwenden Binärformate zum Speichern der Informationen (Dateiendungen: **.doc*, **.sdw*)
- Neue Versionen erzeugen Zip-Archive, die XML-Dateien enthalten (Dateiendungen: **.docx*, **.odt*)

Textverarbeitung: Binärformat

Binäre Textdokumente (Word & Co.) ...

- ... sind (von Anwendern) nicht lesbar
- ... können von Fremdprogrammen nur mit Hilfe von Importfiltern gelesen werden, wenn der Aufbau dokumentiert ist
- ... sind schlimmstenfalls einfache „Memory Dumps“ der Anwendungen

Binärformat: Word

```
$ hexdump -C linux.doc

00000000  d0 cf 11 e0 a1 b1 1a e1  00 00 00 00 00 00 00 00  |ÐÏ.à¡±.á........|
00000010  00 00 00 00 00 00 00 00  3e 00 03 00 fe ff 09 00  |........>...þÿ..|
00000020  06 00 00 00 00 00 00 00  00 00 00 00 04 00 00 00  |................|
00000030  cb 01 00 00 00 00 00 00  00 10 00 00 cd 01 00 00  |Ë...........Í...|
00000040  01 00 00 00 fe ff ff ff  00 00 00 00 c7 01 00 00  |....þÿÿÿ....Ç...|
00000050  c8 01 00 00 c9 01 00 00  ca 01 00 00 ff ff ff ff  |È...É...Ê...ÿÿÿÿ|
[...]
00034110  0b 00 00 00 4e 6f 72 6d  61 6c 2e 64 6f 74 00 20  |....Normal.dot. |
00034120  1e 00 00 00 11 00 00 00  20 48 61 6e 73 2d 47 65  |........ Hans-Ge|
00034130  6f 72 67 20 45 df 65 72  00 00 64 00 1e 00 00 00  |org Eßer..d.....|
00034140  02 00 00 00 31 00 61 6e  1e 00 00 00 13 00 00 00  |....1.an........|
00034150  4d 69 63 72 6f 73 6f 66  74 20 57 6f 72 64 20 39  |Microsoft Word 9|

$ strings -e S linux.doc
                                    Vorwort
Linux                                PAGEREF _Toc13267048 \h
zum Nachschlagen                     HYPERLINK \l "_Toc13267049"
SuSE Linux 8.x
Hans-Georg Eßer                     [...]
Inhalt
 TOC \o "1-3" \h \z                 Normal.dot
 HYPERLINK \l "_Toc13267047"         Hans-Georg Eßer
Inhalt                              Microsoft Word 9.0
 PAGEREF _Toc13267047 \h
 HYPERLINK \l "_Toc13267048"        [...]
```


Textverarbeitung: XML-Format

- Neuere Versionen (Word: **.docx*; OOO: **.odt*) speichern im XML-Format
- Vorteile:
  - einfacheres Einlesen / Bearbeiten durch Fremdprogramme
  - ermöglicht automatisches Generieren durch andere Tools, etwa auf einer Webseite ein Button „Seite als *docx*-Datei speichern“

XML-Format: LibreOffice (1/6)

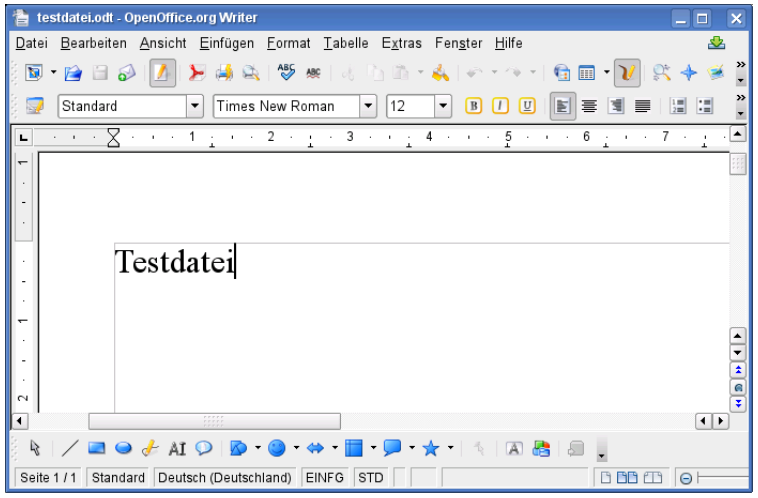

XML-Format: LibreOffice (2/6)

```
$ unzip -l /tmp/testdatei.odt

Archive:  /tmp/testdatei.odt
  Length      Date    Time    Name
 --------     ----    ----    ----
       39  09-09-10 19:01   mimetype
        0  09-09-10 19:01   Configurations2/statusbar/
        0  09-09-10 19:01   Configurations2/accelerator/current.xml
        0  09-09-10 19:01   Configurations2/floater/
        0  09-09-10 19:01   Configurations2/popupmenu/
        0  09-09-10 19:01   Configurations2/progressbar/
        0  09-09-10 19:01   Configurations2/menubar/
        0  09-09-10 19:01   Configurations2/toolbar/
        0  09-09-10 19:01   Configurations2/images/Bitmaps/
     2683  09-09-10 19:01   content.xml
      532  09-09-10 19:01   manifest.rdf
    10302  09-09-10 19:01   styles.xml
     1097  09-09-10 19:01   meta.xml
      725  09-09-10 19:01   Thumbnails/thumbnail.png
     8387  09-09-10 19:01   settings.xml
     1989  09-09-10 19:01   META-INF/manifest.xml
 --------                   -------
    25754                   16 files
```


XML-Format: LibreOffice (3/6)

Inhalt von *content.xml*:

```
<office:document-content xmlns:office="urn:oasis:names:tc:opendocument:xmlns:office:1.0" xmlns:style="urn:oasis:names:tc:opendocument:x
                         xmlns:text="urn:oasis:names:tc:opendocument:xmlns:text:1.0" xmlns:table="urn:oasis:names:tc:opendocument:xmlns
                         xmlns:draw="urn:oasis:names:tc:opendocument:xmlns:drawing:1.0" xmlns:fo="urn:oasis:names:tc:opendocument:xmlns
                         xmlns:xlink="http://www.w3.org/1999/xlink" xmlns:dc="http://purl.org/dc/elements/1.1/"
                         xmlns:meta="urn:oasis:names:tc:opendocument:xmlns:meta:1.0" xmlns:number="urn:oasis:names:tc:opendocument:xmln
                         xmlns:svg="urn:oasis:names:tc:opendocument:xmlns:svg-compatible:1.0" xmlns:chart="urn:oasis:names:tc:opendocum
                         xmlns:dr3d="urn:oasis:names:tc:opendocument:xmlns:dr3d:1.0" xmlns:math="http://www.w3.org/1998/Math/MathML"
                         xmlns:form="urn:oasis:names:tc:opendocument:xmlns:form:1.0" xmlns:script="urn:oasis:names:tc:opendocument:xmln
                         xmlns:ooo="http://openoffice.org/2004/office" xmlns:ooow="http://openoffice.org/2004/writer"
                         xmlns:oooc="http://openoffice.org/2004/calc" xmlns:dom="http://www.w3.org/2001/xml-events"
                         xmlns:xforms="http://www.w3.org/2002/xforms" xmlns:xsd="http://www.w3.org/2001/XMLSchema"
                         xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance" xmlns:rpt="http://openoffice.org/2005/report"
                         xmlns:of="urn:oasis:names:tc:opendocument:xmlns:of:1.2" xmlns:xhtml="http://www.w3.org/1999/xhtml"
                         xmlns:grddl="http://www.w3.org/2003/g/data-view#" xmlns:field="urn:openoffice:names:experimental:ooo-ms-intero
                         office:version="1.2" grddl:transformation="http://docs.oasis-open.org/office/1.2/xslt/odf2rdf.xsl"
  <office:scripts/>
  <office:font-face-decls>
    <style:font-face style:name="Times New Roman" svg:font-family="'Times New Roman'" style:font-family-generic="roman" style:font-pitch
    <style:font-face style:name="Arial" svg:font-family="Arial" style:font-family-generic="swiss" style:font-pitch="variable"/>
    <style:font-face style:name="Arial1" svg:font-family="Arial" style:font-family-generic="system" style:font-pitch="variable"/>
  </office:font-face-decls>
  <office:automatic-styles/>
  <office:body>
    <office:text>
      <text:sequence-decls>
        <text:sequence-decl text:display-outline-level="0" text:name="Illustration"/>
        <text:sequence-decl text:display-outline-level="0" text:name="Table"/>
        <text:sequence-decl text:display-outline-level="0" text:name="Text"/>
        <text:sequence-decl text:display-outline-level="0" text:name="Drawing"/>
      </text:sequence-decls>
      <text:p text:style-name="Standard">
        Testdatei
      </text:p>
    </office:text>
  </office:body>
</office:document-content>
```


XML-Format: LibreOffice (4/6)

Jetzt eine Datei mit Bild:

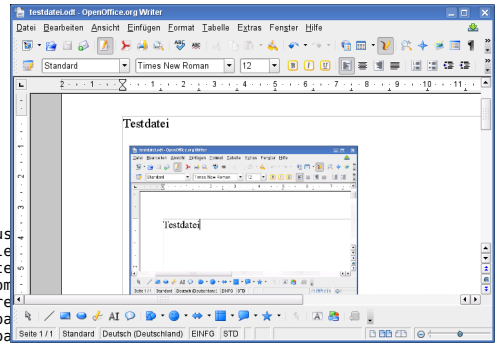


```
$ unzip -l  /tmp/testdatei.odt
Archive:  /tmp/testdatei.odt
  Length      Date    Time    Name
 --------     ----    ----    ----
       39  09-09-10 19:14   mimetype
        0  09-09-10 19:14   Configurations2/status
        0  09-09-10 19:14   Configurations2/accele
        0  09-09-10 19:14   Configurations2/floate
        0  09-09-10 19:14   Configurations2/popupm
        0  09-09-10 19:14   Configurations2/progre
        0  09-09-10 19:14   Configurations2/menuba
        0  09-09-10 19:14   Configurations2/toolba
        0  09-09-10 19:14   Configurations2/images/Bitmaps/
    37829  09-09-10 19:14   Pictures/10000000000002BB000001C9C86EB88C.png
     3599  09-09-10 19:14   content.xml
      532  09-09-10 19:14   manifest.rdf
    10591  09-09-10 19:14   styles.xml
     1097  09-09-10 19:14   meta.xml
     4718  09-09-10 19:14   Thumbnails/thumbnail.png
     8914  09-09-10 19:14   settings.xml
     2190  09-09-10 19:14   META-INF/manifest.xml
 --------                   -------
    69509                   17 files
```

XML-Format: LibreOffice (5/6)

Inhalt von *content.xml* (Auszug):

```
<office:body>
  <office:text>
    <text:sequence-decls>
      <text:sequence-decl text:display-outline-level="0" text:name="Illustration"/>
      <text:sequence-decl text:display-outline-level="0" text:name="Table"/>
      <text:sequence-decl text:display-outline-level="0" text:name="Text"/>
      <text:sequence-decl text:display-outline-level="0" text:name="Drawing"/>
    </text:sequence-decls>
    <text:p text:style-name="Standard">
      Testdatei
    </text:p>
    <text:p text:style-name="Standard"/>
    <text:p text:style-name="Standard">
      <draw:frame draw:style-name="fr1" draw:name="Grafik1"
           text:anchor-type="paragraph" svg:x="0.235cm" svg:y="0cm"
           svg:width="7.491cm" svg:height="4.898cm" draw:z-index="0">
        <draw:image xlink:href="Pictures/10000000000002BB000001C9C86EB88C.png"
             xlink:type="simple" xlink:show="embed" xlink:actuate="onLoad"/>
      </draw:frame>
    </text:p>
  </office:text>
</office:body>
```


XML-Format: LibreOffice (6/6)

Inhalt von *meta.xml* (Metadaten):

```
<office:document-meta office:version="1.2" grddl:transformation=
  "http://docs.oasis-open.org/office/1.2/xslt/odf2rdf.xsl">
  <office:meta>
    <meta:initial-creator>Hans-Georg Eßer</meta:initial-creator>
    <meta:creation-date>2010-09-09T21:01:27</meta:creation-date>
    <dc:date>2010-09-09T21:14:40</dc:date>
    <dc:creator>Hans-Georg Eßer</dc:creator>
    <meta:editing-duration>PT00H13M05S</meta:editing-duration>
    <meta:editing-cycles>2</meta:editing-cycles>
    <meta:generator>
      OpenOffice.org/3.2$Linux OpenOffice.org_project/320m12$Build-9483
    </meta:generator>
    <meta:document-statistic meta:table-count="0" meta:image-count="1"
      meta:object-count="0" meta:page-count="1" meta:paragraph-count="1"
      meta:word-count="1" meta:character-count="9"/>
  </office:meta>
</office:document-meta>
```


Grafikformate

- Zwei Welten bei Grafikformaten:
  - Rastergrafiken (jpg, png, tif, bmp, gif, xpm)
  - Vektorgrafiken (eps, emf, svg, ps)
  - Gigantische Liste: http://de.wikipedia.org/wiki/Grafikformat

Rastergrafiken (1/5)

- pixel-basiert
- Größe einer Grafik abhängig von
  - Breite x Höhe in Pixeln
  - Farbtiefe (8 Bit, 16 Bit pro RGB-Farbkanal etc.)
  - Kompressionsverfahren

Rastergrafiken (2/5)

- Rechenbeispiel
  - Bild: 800 x 600 Punkte
  - RGB, 8 Bit pro Farbkanal
    (also insgesamt 24 Bit, 24 bpp: bits per pixel)
  - 800 x 600 x 24 = 11.520.000 Bit = 1.440.000 Byte

```
$ identify test.bmp
test.bmp BMP 800x600 8-bit DirectClass 1.831mb

$ convert test.bmp test.rgb

$ ls -l test.*
-rw-r--r-- 1 esser users 1920122 10. Sep 10:37 test.bmp
-rw-r--r-- 1 esser users 1440000 10. Sep 10:41 test.rgb
```


Rastergrafiken (3/5)

- Primitiv-Format: XPM
  - **X Pixmap**
  - vor allem für Icons
  - „lesbar“
  - nicht komprimiert
- Beispiel (48x20 Pixel):

```
/* XPM */
static char * linux_xpm[] = {
"48 20 7 1",
"       c None",
".      c #D0D0D0",
"+      c #C0C0C0",
"@      c #808080",
"#      c #D0D0C0",
"$      c #000000",
"%      c #C08000",
"......................................+@@+.......",
".........+@.........................#+$$$$@......",
".+$$$+...$$..........................@$$$$$+#....",
"..#$@#...++.........................#$$$$$$@.....",
"..#$@+...++..+++@+..+@..++.+++++++..@@$@@$@+....",
"..+$@...+$$+@$$@$$@+$$.@$@.@$$+$@..+$@%@$$$+....",
"..#$@++..$$.+$$+.$@.@$..$@+.@$@@++.+@%%%$$.+...",
"..+$@+...$$.+$$.+$@+@$++$@...$$++##+@+$%+$$+....",
"..#$@++$.$@++$$..$@+@$++$@+++$$$..#+$+#+#+$$+...",
".++$$++$.$$++$$++$@+@$$@$@++$++$@++$+##+++$$@...",
".+@@@@@@+@@+@@@+@@@++@++@@+@@++@@+@$.+.+#+@$$+..",
".+++++++++++.+.+++++++++++++%+++.$++#+.+#+$$@..",
"..+++++++.++++%++%+%%%%%%%%%%%%%%@$+.+.+.+.$$$+.",
"...++%+%%%%%%%%%%%%%%%%%%%%%%%+%+..$$.+.+.+.+$$$..",
".+%%%%%%%%%%%%%%%%%+%++++#+++##..%%+++++.++$$$#.",
".%%%%%%%%%%%%%%+###+############+++%%$@.+.++%@$%+.",
".+%%%%%%%+###.##################%%%%%$+.+++%%%%%+",
".%%%%%+######.#####.###########+%%%%%%++++$@%%%%+",
"##%%#########...##################+%%%%%$$$$$%%%%##",
"######..##..########################+@@@+##.+@%++#+"};
```


Rastergrafiken (4/5)

- Anderes Beispiel: FOM-Logo (Ausschnitt)

```
/* XPM */
static char *fom_s[] = {
/* columns rows colors chars-per-pixel */
"55 60 256 2",
"   c black",
".  c #010101",
"X  c #020202",
[...]
"PX c #FDFDFD",
"IX c #FEFEFE",
"UX c gray100",
/* pixels */
```

```
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 e f f f e 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 e e e e e e e e e e e e e 3 3 3 3 3 3 3 3 3 3 3 3 e e           & f 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3               3 3 3 3 3 3 3 3 3 3 3 f     UXUXUXUXUXU   e e 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 & 2XUXUXUXUXUXUXUXUXUXUXUXUXf.& 3 3 3 3 3 3 3 3 f   vXUXUXUXUXUXUXUX  & e 3 3 3 3 3 3 3 3 3 3 3 3 e ",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUX3 & e 3 3 3 3 3 3 3 3 3 e   b.",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUXUXUX  3 3 3 3 3 3 3 3 3 e   2X",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUX  e 3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 e   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUX  3 3 3 3 3 3 e UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  e 3 3 3 3 3 3 3 e   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXf 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXS 3 3 3 3 3 3 3 e   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUX2.  3 3 3   w.UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 3 3 3 f   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUX2X  e 3 f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXS & 3 3 3 3 3 f   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  e 3 3 b UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  e 3 3 3 3 f   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  e e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  e 3 3 3 3 f   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXU.  e 3 3 3 f   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f & S UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 3 e   UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f   UXUXUXUXUXUXUXUXUXUX      UXUXUXUXUXUXUXUXUXUX  f 3 3 3 e   UX",
"3 3 3 3 e   UXUXUXUXUXUXUX                3 f   UXUXUXUXUXUXUXUXUX  e f f   2XUXUXUXUXUXUXUXUX3 3 3 3 3 3   UX",
"3 3 3 3 e   UXUXUXUXUXUXUX  U f f f e f e 3 f   UXUXUXUXUXUXUXUX  e e 3 3 b   UXUXUXUXUXUXUXUX&X  e 3 3 3 f UX",
"3 3 3 3 e   UXUXUXUXUXUXUX  e & & 3 3 3 3 3 3   UXUXUXUXUXUXUXUX  f 3 3 3 3 3 e UXUXUXUXUXUXUXUX  e 3 3 &  .UX",
"3 3 3 3 e   UXUXUXUXUXUXUX  2. .&.b 3 3 3 3 & &.UXUXUXUXUXUXUXS 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUX  f 3 e   S.UX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 e   dXUXUXUXUXUXUXUX  f 3 3 3 3 3 e   UXUXUXUXUXUXUXUX  f 3 e   wXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 e   UXUXUXUXUXUXUXUX  f 3 3 3 3 3 3 & S UXUXUXUXUXUXUXUX  f 3 e   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 e   UXUXUXUXUXUXUXUX  e 3 3 3 3 3 3 e   UXUXUXUXUXUXUX  e 3 e   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 f   UXUXUXUXUXUXUX X  e 3 3 3 3 3 3 f   UXUXUXUXUXUXUX  e 3 e   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 f   UXUXUXUXUXUXUX&.& 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUX  3 3 f   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 f   UXUXUXUXUXUXUX .& 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUX& 3 3 f   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 f   UXUXUXUXUXUXUX( & 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUX  3 3 f   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 f   UXUXUXUXUXUXUXS.  e 3 3 3 3 3 3 f   UXUXUXUXUXUXUX  3 3 f   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 e   UXUXUXUXUXUXUXUX  e 3 3 3 3 3 3 e   UXUXUXUXUXUXUX  e 3 f   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 e   UXUXUXUXUXUXUXUX  e 3 3 3 3 3 3 3 e UXUXUXUXUXUXUX  e 3 e   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  f 3 e   UXUXUXUXUXUXUXUX  f 3 3 3 3 3 e   dXUXUXUXUXUXUX  f 3 e   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX  e 3 3   w.UXUXUXUXUXUXUX& 3 3 3 3 3 3 f   UXUXUXUXUXUXUX  f 3 3   UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  e & & & 3 3 3 3 3 3 UXUXUXUXUXUXUXUX  e 3 3 3 3 e   UXUXUXUXUXUXUX  e 3 3 f UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 e   UXUXUXUXUXUXUXUX  f 3 3 3 f   UXUXUXUXUXUXUXSX  e 3 &  .UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUX  b e f   e UXUXUXUXUXUXUXUXS & 3 e   S.UXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 e   UXUXUXUXUXUXUXUXUXUX      b UXUXUXUXUXUXUXUXUX  e 3 e   dXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 & 2.UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 e   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  e 3 e   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  3 3 3 e   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 & 2.UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 f   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXb.  3 3 3 f   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 e   dXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 3 f   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXS.  e 3 3 3 f   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 3 e   b.UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  f 3 3 3 3 f   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXUXUX  3 3 3 3 3 3 e   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 3 3 3 f   UXUXUXUXUXUXUXUXUXUXUXUXUXUXw.  e 3 3 3 3 3 e   UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  f 3 3 3 3 3 3 3 3 3 3 3 3 3 e   UXUXUXUXUXUXUXUXUXUXUXUX/.  e 3 3 3 3 3 3 3 & UXUXUX",
"3 3 3 3 e   UXUXUXUXUXUXUX  e 3 3 3 3 3 3 3 3 3 3 3 3 3 3 e   UXUXUXUXUXUXUXUXUX(   e 3 3 3 3 3 3 3 3 f UXUXUX",
"3 3 3 3 3 3               3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 e   ( UXUXUXUXUXUX  & e 3 3 3 3 3 3 3 3 3 3         ",
"3 3 3 3 3 3 e e e e e e 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 f &             f 3 3 3 3 3 3 3 3 3 3 3 3 3 e e e ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 f e 3 e f e 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 ",
"3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 3 "
};
```


Rastergrafiken (5/5)

- „normale“ Rasterformate sind binär und **komprimieren** die Daten
- „Pixelgrafiken“ sind Rastergrafiken
- zwei Arten von Kompression
  - verlustfrei (z. B. bei png, tif)
    → Originalbild wiederherstellbar
  - verlustbehaftet (z. B. bei jpg)
    → Teile der Bildinformation gehen verloren

JPEG-Format / **.jpg* (1/2)

- **JPEG**-Format (entwickelt von der **J**oint **P**hotographic **E**xperts **G**roup)
- verlustbehaftete Kompression
- Qualitätsstufen

fom.png (Original) 4575	fom-85.jpg (85% Qual.) 1988	fom-70.jpg (70% Qual.) 1540	fom-50.jpg (50% Qual.) 1302	fom-25.jpg (25% Qual.) 985	fom-05.jpg (5% Qual.) 553	fom-00.jpg (0% Qual.) 461

JPEG-Format / **.jpg* (2/2)

- am besten für Fotos geeignet

Original 392.190 Bytes	JPEG, 85 % 107.748 Bytes	JPEG, 30 % 36.383 Bytes	JPEG, 5 % 8.632 Bytes

PNG-Format / **.png*

- **PNG: P**ortable **N**etwork **G**raphics
- als Ersatz für das *gif*-Format vor allem für Grafiken auf Webseiten eingesetzt
- patentfrei
- verlustfreie Komprimierung
  – viel besser als bei *gif*-Dateien

TIFF-Format / **.tif*

- **TIFF: T**agged **I**mage **F**ile **F**ormat
- verlustfreie Kompression
  (außer in einem Spezialformat → JPEG)
- Standardformat im DTP-Bereich: unterstützt
  - RGB-Format (**R**ed, **G**reen, **B**lue)
  - CMYK-Format
    (**C**yan, **M**agenta, **Y**ellow, **K**ey / ~~Black~~)

Welche Kompression?

- Entscheidung über Bildformat (und damit: über Kompression) hängt von Bildtyp ab
  - Fotos:
    große Vielfalt an Farbtönen, weiche Übergänge
    → JPEG
  - Diagramme, Grafiken, ins Rasterformat gewandelte Vektorgrafiken:
    geringe Farbzahl, harte Kanten
    → PNG, TIFF etc.
- Falsches Format zu wählen, bedeutet:
  - zu hoher Platzbedarf oder
  - zu geringe Qualität

Vektorformate

- Idee: Bilder nicht in Pixel zerlegen, sondern „beschreiben“, z. B.
  Bild mit Abmessungen 10 cm x 10 cm, weißer Hintergrund, roter Kreis mit Durchmesser 1 cm und Mittelpunkt bei Koordinaten (3 cm, 4 cm). Rand des Kreises blau, Dicke 1 mm
- allgemein: grafische „Primitive“ (Linie, Kreis, Rechteck etc., Pfad, Polygon, Text)
- Beispielformate, SVG, PS (PostScript), EPS
- Vorteil: Beliebige Skalierbarkeit

Vektorformate

Quelle:
http://de.wikipedia.org/wiki/Vektorgrafik

SVG-Format / **.svg*

SVG: Scalable **V**ector **G**raphics

- Freies Format (patentfrei)
- ein weiteres XML-Format:

```
<circle
  cx="1275"
  cy="1511"
  r="708"
  style="stroke:#000000;
         stroke-width:8;"
/>
```

X- und Y-Koordinaten des Mittelpunkts

Kreisradius

Stilangaben: Farbe, Breite

SVG-Format / **.svg*

```
<?xml version="1.0" standalone="no"?>
<!DOCTYPE svg PUBLIC "-//W3C//DTD SVG 1.1//EN"
"http://www.w3.org/Graphics/SVG/1.1/DTD/svg11.dtd">
<svg xmlns="http://www.w3.org/2000/svg" width="1.2in"
  height="1.2in" viewBox="558 794 1434 1434">
  <g style="stroke-width:.025in; fill:none">
  <!-- Circle -->
  <circle cx="1275" cy="1511" r="708"
    style="stroke:#000000;stroke-width:8;"/>
  </g>
</svg>
```

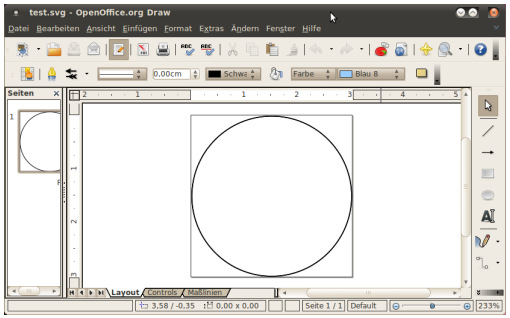

PostScript-Format / **.ps* (1/2)

- altes Format: 1984 (Adobe)
- ursprünglich: Seitenbeschreibungssprache (für Laserdrucker und Druckmaschinen)
- wird heute durch PDF verdrängt
- Linux setzt (noch) in seinem Drucksystem PostScript ein
- Variante: **EPS** (**E**ncapsulated **P**ost**S**cript)
- kann auch Rastergrafik-Elemente enthalten
- PostScript ist eine Programmiersprache

PostScript-Format / **.ps* (2/2)

```
%!
/Courier findfont     % Schrift auswählen
50 scalefont          % auf Schriftgröße 50 skalieren
setfont               % zum aktuellen Zeichensatz machen
50 50 moveto          % (50, 50) als aktuelle Schreibposition setzen
(Hallo Welt!) show    % und dort den Text ausgeben
showpage              % Seite ausgeben
```

(Quelle Listing: http://de.wikipedia.org/wiki/PostScript)

PDF-Format / **.pdf* (1/2)

- PDF: Portable Document Format
- 1993 (Adobe), seit 2008 „offener Standard“
- Seitenbeschreibungssprache
- ähnliches Datenmodell wie PostScript, mit komprimierter Kodierung
- einbetten von Schriftarten
- Hyperlinks (intern & extern)
- Zugriffsschutz (Verschlüsselung/Passwort, Copy & Paste, Drucken)

PDF-Format / *.pdf (2/2)

- interaktiv: Lesezeichen, Formulare, Kommentare (im Reader)
- unsichtbare Textebenen (für gescannte und mit OCR analysierte Dokumente)
- eingeschränkt: Nacharbeiten an PDF-Datei möglich
- einfache Konvertierung PDF ↔ PostScript
- PDF heute ein Standardformat für Dokumentenweitergabe und Druckdaten
- PDF/A: PDF Archive, für Langzeitarchivierung

Vektorisieren (1/3)

Inkscape (www.inkscape.org) kann Bitmap-Grafiken vektorisieren

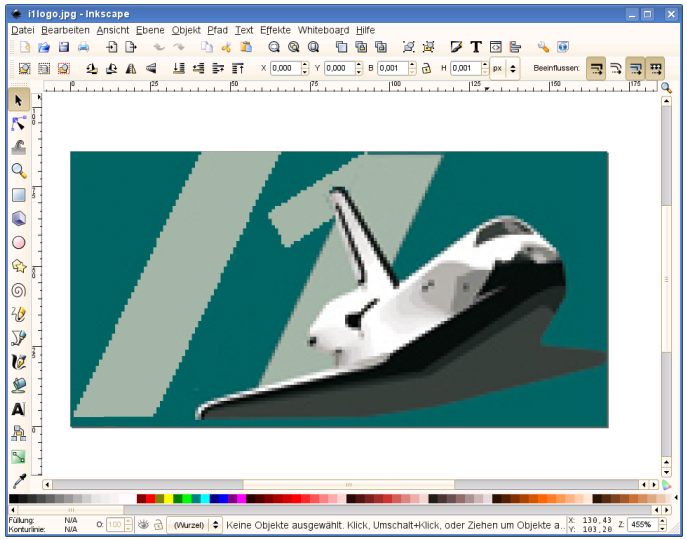

Vektorisieren (2/3)

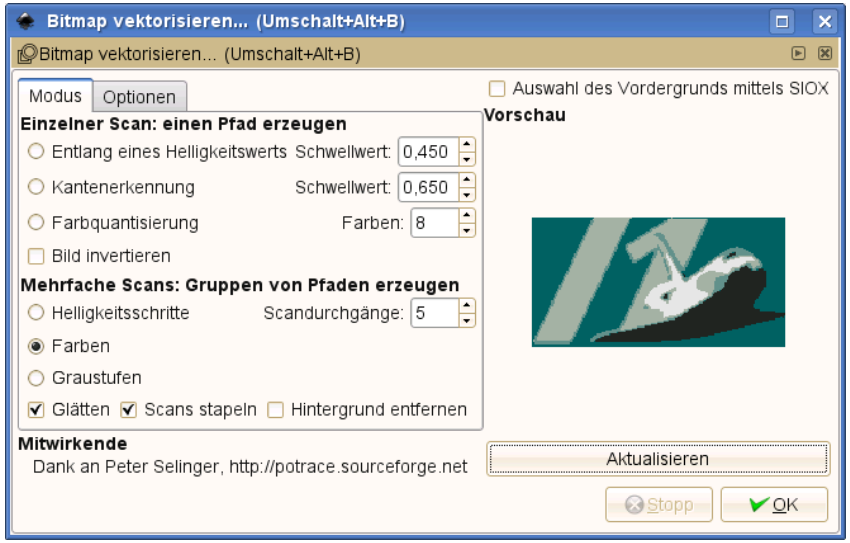

Vektorisieren (3/3)

Ergebnis:

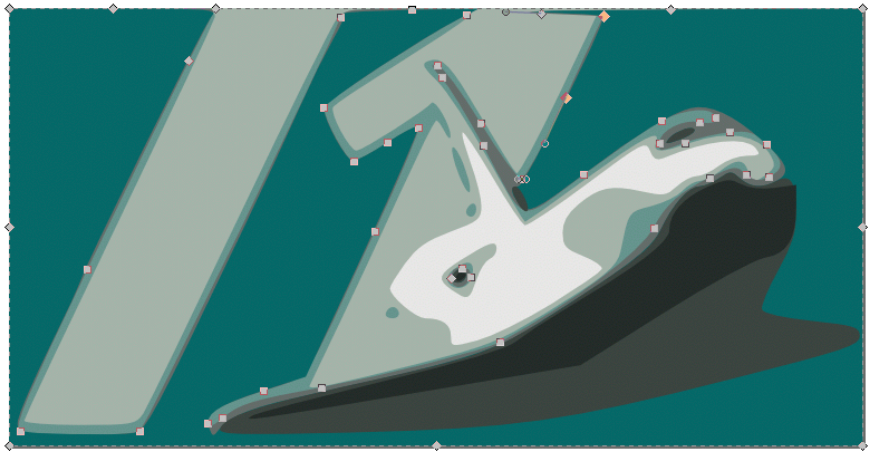

Adobe Acrobat: OCR / ClearType

Aktuelle Acrobat-Version hat interessantes Feature „ClearType“:

- Dokument einscannen und als PDF speichern
- OCR auf PDF-Datei anwenden
- neue Fonts (Schriftartdateien) aus erkannten Buchstaben erzeugen
- Pixel-Buchstaben in PDF-Datei durch Buchstaben in diesen Fonts ersetzen

Videoformate

- „Video“ = Audio + Video
- Bilder (Frames), pro Frame ein „volles Bild“
- simpelste Variante: MJPEG (Motion JPEG)
- separates Speichern von Ton und Bild – oder „gemischt“

MPEG-Formate

- **MPEG: M**oving **P**icture **E**xperts **G**roup
- MPEG-1: erstes Videoformat der MPEG
- verschiedene Frame-Typen:
  - I-Frame: intra coded picture. Standbild (wie MJPEG)
  - P-Frame: predictive coded picture. Bild hängt von vorherigen Bildern ab
  - B-Frame: bidirectional coded picture. Bild hängt von vorherigen und folgenden (!) Bildern ab
  - D-Frame
- Audio: Audio Layer 1–3 (MP1–MP3)

Codec-Vielfalt

- Codec = **Co**der/**Dec**oder
- viele Container-Formate (z. B. AVI), die Video- und Audio-Streams in diversen Kodierungen aufnehmen
- abspielen eines Videos:
  - Analyse des Container-Formats
  - Lesen der Metadaten (welche Codecs?)
  - suchen der Decoder für Audio und Video
  - Streams dekodieren (Wiedergabe)

Konverter (1/3)

- Ziel: Daten aus einem Format in ein anderes umwandeln
- Beispiele
  - UTF-8-Text → ISO-Latin9-Text
  - PNG-Bild → JPEG-Bild
  - MP3-Audiodatei → Ogg-Vorbis-Datei
  - Word-Dokument → LibreOffice-Dokument
  - PostScript → PDF
  - PNG-Bild → UTF-8-Text (sinnvoll?)
  - MP3-Audiodatei → UTF-8-Text (sinnvoll?)

Konverter (2/3)

Probleme

- Quell- oder Zielformat evtl. nicht vollständig bekannt (→ proprietäre Dateiformate)
- Quell- oder Zielformat evtl. nicht gleich „mächtig“
- Verlust durch Kompression
- Verlust von Struktur (z. B. DocBook → PDF)

Konverter (3/3)

Import- und Export-Filter

- Öffnen- und Speichern-Funktion von Anwendungen mit Import-/Export-Feature
- Qualität hängt von Güte der Filter ab

Kommunikation

- Verschiedene Modelle
  - Nachricht: Sender → Empfänger
  - Dialog
  - Gruppenkommunikation
- Klartext vs. „binäre“ Nachrichten

Begriff „Kommunikationsformat“

- Format/Standard für Kommunikation
  - Netzwerkprotokolle
- Dateiformat für den Austausch von Informationen
  - PDF für Dokumente
  - spezialisierte Formate, etwa DTaus im Bankenbereich

Netzwerkprotokolle (1/3)

Eine kleine Auswahl

- HTTP (Webserver)
- FTP (FTP-Fileserver)
- SMTP (Mail-Versand)
- POP3, IMAP (Mail-Empfang)
- IRC (Chatten)
- SSL (Verschlüsselung)
- Time Protocol (Zeitabfrage)

Netzwerkprotokolle (2/3)

Grundlagen / Allgemeines

- meist Kommunikation zwischen zwei Seiten
- typisch: Client-Server-Prinzip
- verbindungslos
  - A schickt Anfrage an B
  - B schickt Antwort an A
  - Ende
- verbindungsorientiert
  - A und B bauen Verbindung auf
  - A und B kommunizieren über die Verbindung, bis sie geschlossen wird

Netzwerkprotokolle (3/3)

- Kommunikation folgt einem festen, vorgegebenen Protokoll
- Client und Server müssen sich exakt an das Protokoll halten, damit Kommunikation gelingt
- wie im „richtigen Leben“
  - A: „Wie möchten Sie bezahlen?“ –
    B: „mit Kreditkarte“ – *erfolgreich*
  - A: „Wie möchten Sie bezahlen?“ –
    B: „Heute ist es sehr warm“ – *nicht erfolgreich*

HTTP (1/8)

- HTTP: **H**yper**t**ext **T**ransfer **P**rotocol
- Client: Webbrowser (Firefox, IE, Opera etc.)
- Server: Webserver (Apache, Microsoft IIS etc.)
- verbindungsorientierte Kommunikation (TCP)
- Anfrage: HTTP-Request
- Antwort: HTTP-Response

HTTP (2/8)

HTTP-Requests

- GET (Daten: Header + Dokument holen)
- POST (Daten an den Server senden, Formulare)
- HEAD (nur Header holen)

HTTP (3/8)

HTTP GET

- Anfrage:

```
GET /ii-ws2010/fom-itis-datenformate-01.pdf HTTP/1.1
Host: fom.hgesser.de
```

- Antwort:

```
HTTP/1.1 200 OK
Date: Fri, 10 Sep 2010 10:33:23 GMT
Server: Apache/2.2.3 (Debian) PHP/4.4.4-8+etch6
Last-Modified: Fri, 03 Sep 2010 13:40:06 GMT
ETag: "3c630f7e-aec13-118b9980"
Accept-Ranges: bytes
Content-Length: 715795
Content-Type: application/pdf

%PDF-1.4
[...]
```


HTTP (4/8)

- Angabe des Hosts

```
Host: fom.hgesser.de
```

war früher (HTTP 1.0) nicht nötig und nicht möglich

- Moderne Webserver hosten mehrere Domains unter derselben IP-Adresse (z. B. fom.hgesser.de, hm.hgesser.de, hgesser.com) – ohne Angabe des Hostnamens keine Unterscheidung möglich

HTTP (5/8)

HTTP HEAD: holt nur den Header

- Anfrage:

```
HEAD /ii-ws2010/fom-itis-datenformate-01.pdf HTTP/1.1
Host: fom.hgesser.de
```

- Antwort:

```
HTTP/1.1 200 OK
Date: Fri, 10 Sep 2010 10:37:00 GMT
Server: Apache/2.2.3 (Debian) PHP/4.4.4-8+etch6
Last-Modified: Fri, 03 Sep 2010 13:40:06 GMT
ETag: "3c630f7e-aec13-118b9980"
Accept-Ranges: bytes
Content-Length: 715795
Content-Type: application/pdf
```


HTTP (6/8)

HTTP POST: überträgt Zusatzdaten

- Anfrage:

```
POST /search.html HTTP/1.1
Host: fom.hgesser.de
Content-Type: application/x-www-form-urlencoded
Content-Length: 20

search=Infrastruktur
```

- Antwort:

```
HTTP/1.1 200 OK
Date: Fri, 10 Sep 2010 10:37:00 GMT
Server: Apache/2.2.3 (Debian) PHP/4.4.4-8+etch6
Last-Modified: Fri, 03 Sep 2010 13:40:06 GMT
[...]
```


HTTP (7/8)

- Verbindung bleibt nach GET/HEAD/POST geöffnet
  - Client kann sofort weitere Anfragen schicken (z. B. für Bilder auf der HTML-Seite)
  - reduziert den Aufwand für Verbindungsauf- und -abbau (TCP-Verbindungen)
- Bei Fehler (z. B. falsche Syntax in Anfrage) wird Verbindung geschlossen. Rückmeldung:

```
HTTP/1.1 400 Bad Request
```


HTTP (8/8)

- HTTP Status Codes
  - immer in der ersten Zeile der Antwort
  - 200 OK
  - 301 Moved Permanently
  - 304 Not Modified
  - 400 Bad Request
  - 401 Unauthorized
  - 403 Forbidden
  - 404 Not Found
  - 500 Internal Server Error
  - 503 Service Unavailable
  - weitere: http://de.wikipedia.org/wiki/HTTP-Statuscode
- Antwort steht nur im Header!

FTP (1/3)

- **FTP: F**ile **T**ransfer **P**rotocol
- Client: FTP-Client (z. B. Webbrowser oder spezielles FTP-Programm)
- Server: FTP-Server
- verbindungsorientierte Kommunikation (TCP) mit zwei Kanälen
  - Kontrollkanal (Port 21)
  - und Datenkanal (Port 20)
- aktives FTP (Direktverbindung) vs. passives FTP (Firewall)

FTP (2/3)

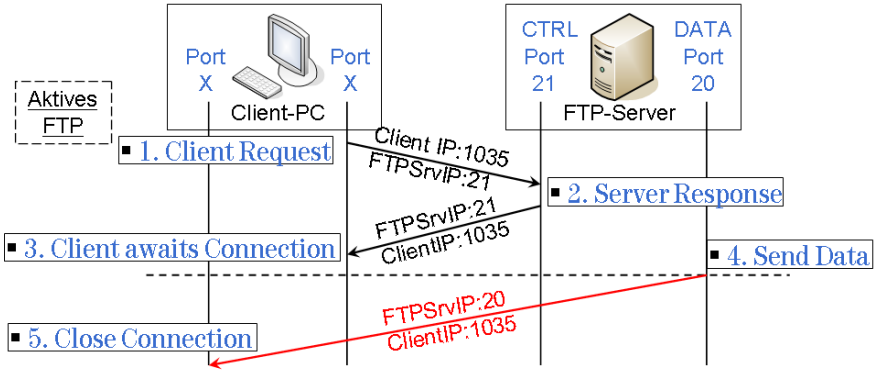

Quelle Bild: http://de.wikipedia.org/wiki/File_Transfer_Protocol

FTP (3/3)

- Authentifizierung (Username, Passwort)
- alternativ: „anonymous FTP“
- verschiedene Übertragungsvarianten
  - ASCII
  - Binary

Mail-Versand mit SMTP (1/2)

- **SMTP: S**imple **M**ail **T**ransfer **P**rotocol
- Kommunikation im Textmodus, SMTP-Port 25
- Kommandos:
  - HELO („Begrüßung“)
  - MAIL FROM: *Adresse*
  - RCPT TO: *Adresse*
  - DATA
  - dann die Nachricht (erst die Mail-Header)

Mail-Versand mit SMTP (2/2)

```
esser@netbook:~$ telnet hgesser.de smtp
Trying 217.160.135.96...
Connected to hgesser.de.
Escape character is '^]'.
220 hgesser.de ESMTP Exim 3.36 #1 Sat, 11 Sep 2010 00:28:31 +0200
helo absender.de
250 hgesser.de Hello mnch-123.pool.mediaways.net [93.133.124.239]
mail from: h.g.esser@gmx.de
250 <h.g.esser@gmx.de> is syntactically correct
rcpt to: esser@hgesser.de
250 <esser@hgesser.de> verified
data
354 Enter message, ending with "." on a line by itself
Hallo, das ist eine Nachricht.
.
250 OK id=1OuC5Z-0005cW-00
quit
221 s15337257.onlinehome-server.info closing connection
Connection closed by foreign host.
```


Daytime Protocol

- veraltetes (aber angenehm einfaches) Protokoll, mit dem man nach der Uhrzeit fragen kann
- Kontakt zu Port 13 (daytime) eines Servers, der einen Daytime-Service anbietet
- Server liefert Zeit als lesbaren Text

```
esser@netbook:~$ netcat hgesser.de daytime
Sat Sep 11 00:23:55 2010
```

- nicht mit NTP verwechseln ...

Austauschformate

Und wieder: Eine kleine Auswahl

- RSS (News-Feeds)
- DTaus (Banküberweisungen)
- PDF/PostScript
- CSV (Tabellendaten)
- EPS (Vektorgrafik-Austauschformat)
- RTF (Textdatei-Austauschformat)

RSS (1/3)

- **RSS: R**eally **S**imple **S**yndication
- RSS-Feed: XML-Format, enthält Titel, Kurzfassungen und Links zu Nachrichten
- typisch bei Blogs, News-Seiten u. ä.
- Idee:
  - News-Feed abonnieren
  - regelmäßig Infos zu neuen Beiträgen erhalten
  - Bei Klick auf Link den vollen Artikel lesen

RSS (2/3)

```
<?xml version="1.0" encoding="utf-8"?>
<rss version="2.0">
  <channel>
    <title>IT-Infrastruktur News</title>
    <link>http://fom.hgesser.de/</link>
    <description>Infos zu IT-Infrastruktur / FOM</description>
    <language>de-de</language>
    <copyright>Hans-Georg Eßer</copyright>
    <pubDate>Sat, 11 Sep 2010 2:43:19</pubDate>

    <item>
      <title>Folien zu RSS fertig</title>
      <description>Kurze Zusammenfassung: RSS ...</description>
      <link>http://fom.hgesser.de/rss-folien/</link>
      <author>Hans-Georg Eßer</author>
      <guid>http://fom.hgesser.de/id00012</guid>
      <pubDate>Sat, 11 Sep 2010 2:43:19</pubDate>
    </item>

    <item> ...  </item>
  </channel>
</rss>
```


RSS (3/3)

Banking: DTaus (1/7)

- Datenträgeraustauschverfahren
  - ursprünglich: mit Disketten („Datenträger-...“)
  - auch: online
  - Kunde ↔ Bank und Bank ↔ Bank
- Datei besteht aus
  - A-Satz: „Datenträgervorsatz“ (Header), 128 Byte
  - C-Sätze: Buchungen („Zahlungsaustausch“), 187 + 29·*n* Byte
  - E-Satz: „Datenträgernachsatz“ (Prüfsumme), 128 Byte

Banking: DTaus (2/7)

A-Satz

1	0	4	Zeichen	Länge des Datensatzes, immer "0128"
2	4	1	Zeichen	Datensatz-Typ, immer 'A'
3	5	2	Zeichen	Art der Transaktionen "LB" für Lastschriften Bankseitig "LK" für Lastschriften Kundenseitig "GB" für Gutschriften Bankseitig "GK" für Gutschriften Kundenseitig
4	7	8	Zeichen	Bankleitzahl des Auftraggebers
5	15	8	Zeichen	CST, "00000000", nur belegt, wenn Diskettenabsender Kreditinstitut
6	23	27	Zeichen	Name des Auftraggebers
7	50	6	Zeichen	aktuelles Datum im Format DDMMJJ
8	56	4	Zeichen	CST, " " (Blanks)
9	60	10	Zeichen	Kontonummer des Auftraggebers
10	70	10	Zeichen	Optionale Referenznummer
11a	80	15	Zeichen	Reserviert, 15 Blanks
11b	95	8	Zeichen	Optionales Ausführungsdatum, DDMMJJJJ.
11c	103	24	Zeichen	Reserviert, 24 Blanks
12	127	1	Zeichen	Währungskennzeichen: " " = DM, "1" = Euro
	-- 128	Zeichen		

Quelle: Dokumentation zum Programm *dtaus* (http://www.infodrom.org/projects/dtaus/)

Banking: DTaus (3/7)

C-Satz (1/3)

```
1    0   4 Zeichen Länge des Datensatzes, 187 + x * 29 (x..Anzahl
                   Erweiterungsteile)
2    4   1 Zeichen Datensatz-Typ, immer 'C'
3    5   8 Zeichen Bankleitzahl des Auftraggebers (optional)
4   13   8 Zeichen Bankleitzahl des Kunden
5   21  10 Zeichen Kontonummer des Kunden
6   31  13 Zeichen 1. Zeichen        "0"
                   2. - 12. Zeichen  interne Kundennummer oder Nullen
                   13. Zeichen       "0"
                   Die interne Nummer wird vom erstbeauftragten
                   Institut zum endbegünstigten Institut
                   weitergeleitet.  Die Weitergabe der internenen
                   Nummer an den Überweisungsempfänger ist der
                   Zahlstelle freigestellt.
```

Quelle dieser und der folgenden zwei Seiten:
Dokumentation zum Programm *dtaus* (http://www.infodrom.org/projects/dtaus/)

Banking: DTaus (4/7)

C-Satz (2/3)

```
7a  44   2 Zeichen Art der Transaktion
7b  46   3 Zeichen ------- "----------
                   "04000" Lastschrift des Abbuchungsauftragsverfahren
                   "05000" Lastschrift des Einzugsermächtigungsverfahren
                   "05005" Lastschrift aus Verfügung im elec. Cash-System
                   "05006" Wie 05005 mit ausländischen Karten
                   "05015" Lastschrift aus Verfügung im elec. Cash-
                           System - POZ
                   "51000" Überweisungs-Gutschrift
                   "53000" Überweisung Lohn/Gehalt/Rente
                   "54XXJ" VL mit Sparzulage
                           XX = 00 oder %-Satz der Sparzulage
                           J = Endziffer des Jahres für diese Leistung
                   "56000" Überweisung öffentlicher Kassen
 8   49   1 Zeichen Reserviert, " " (Blank)
 9   50  11 Zeichen Betrag
10   61   8 Zeichen Bankleitzahl des Auftraggebers
11   69  10 Zeichen Kontonummer des Auftraggebers
```


Banking: DTaus (5/7)

C-Satz (3/3)

```
12   79  11 Zeichen Betrag in Euro einschließlich
                    Nachkommastellen, nur belegt, wenn Euro als
                    Währung angegeben wurde (A12, C17a), sonst Nullen
13   90   3 Zeichen Reserviert, 3 Blanks
14a  93  27 Zeichen Name des Kunden
14b 120   8 Zeichen Reserviert, 8 Blanks
     -- 128 Zeichen
15  128  27 Zeichen Name des Auftraggebers
16  155  27 Zeichen Verwendungszweck
17a 182   1 Zeichen Währungskennzeichen: " " = DM, "1" = Euro
17b 183   2 Zeichen Reserviert, 2 Blanks
18  185   2 Zeichen Anzahl der Erweiterungsdatensätze, "00" bis "15"
19  187   2 Zeichen Typ (1. Erweiterungsdatensatz)
                      "01" Name des Kunden
                      "02" Verwendungszweck
                      "03" Name des Auftraggebers
20  189  27 Zeichen Beschreibung gemäß Typ
21  216   2 Zeichen wie C19, oder Blanks,  (2. Erweiterungsdatensatz)
22  218  27 Zeichen wie C20, oder Blanks
23  245  11 Zeichen 11 Blanks
     -- Ende des ersten Erweiterungsdatensatzes
     -- 256 Zeichen
```


Banking: DTaus (6/7)

- Daten erzeugen mit Tool *dtaus* (http://www.infodrom.org/projects/dtaus/)
- Umwandeln mit

  `dtaus -dtaus -c control.txt`
- Ergebnis in Datei *dtaus0.txt*

control.txt:

```
BEGIN {
  Art    GK
  Name   Martin Schulze
  Konto 123545
  BLZ    2004002
  Ausfuehrung 23.12.2001
  Euro
}

{
  Transaktion Gutschrift
  Name    Martha Schulze
  Konto   98832
  BLZ     2004003
  Betrag 20.00
  Zweck   Gebuehr Wohnheimnetz
  Text    Anschluss u. 11+12.97
}
```

Banking: DTaus (7/7)

```
00000000  30 31 32 38 41 47 4b 30  32 30 30 34 30 30 32 30  |0128AGK020040020|
00000010  30 30 30 30 30 30 30 4d  41 52 54 49 4e 20 53 43  |0000000MARTIN SC|
00000020  48 55 4c 5a 45 20 20 20  20 20 20 20 20 20 20 20  |HULZE           |
00000030  20 20 31 30 30 39 31 30  20 20 20 20 30 30 30 30  |  100910    0000|
00000040  31 32 33 35 34 35 30 30  30 30 30 30 30 30 30 30  |1235450000000000|
00000050  20 20 20 20 20 20 20 20  20 20 20 20 20 20 20 32  |               2|
00000060  33 31 32 32 30 30 31 20  20 20 20 20 20 20 20 20  |3122001          |
00000070  20 20 20 20 20 20 20 20  20 20 20 20 20 20 20 31  |               1|
00000080  30 32 31 36 43 30 32 30  30 34 30 30 32 30 32 30  |0216C02004002020|
00000090  30 34 30 30 33 30 30 30  30 30 39 38 38 33 32 30  |0400300000988320|
000000a0  30 30 30 30 30 30 30 30  30 30 30 30 35 31 30 30  |0000000000005100|
000000b0  30 20 30 30 30 30 30 30  30 30 30 30 30 30 30 20  |0 00000000000020|
000000c0  30 34 30 30 32 30 30 30  30 31 32 33 35 34 35 30  |0400200001235450|
000000d0  30 30 30 30 30 30 32 30  30 30 20 20 20 4d 41 52  |0000002000   MAR|
000000e0  54 48 41 20 53 43 48 55  4c 5a 45 20 20 20 20 20  |THA SCHULZE     |
000000f0  20 20 20 20 20 20 20 20  20 20 20 20 20 20 20 20  |                |
00000100  4d 41 52 54 49 4e 20 53  43 48 55 4c 5a 45 20 20  |MARTIN SCHULZE  |
00000110  20 20 20 20 20 20 20 20  20 20 20 47 45 42 55 45  |           GEBUE|
00000120  48 52 20 57 4f 48 4e 48  45 49 4d 4e 45 54 5a 20  |HR WOHNHEIMNETZ |
00000130  20 20 20 20 20 20 31 20  20 30 31 30 32 41 4e 53  |      1  0102ANS|
00000140  43 48 4c 55 53 53 20 55  2e 20 31 31 2b 31 32 2e  |CHLUSS U. 11+12.|
00000150  39 37 20 20 20 20 20 20  20 20 20 20 20 20 20 20  |97              |
00000160  20 20 20 20 20 20 20 20  20 20 20 20 20 20 20 20  |                |
```


CSV (1/2)

- **CSV: C**omma-**S**eparated **V**alues
- einfache Textdatei, die Tabellen in folgendem Aufbau speichert:
  - jede Zeile der Datei entspricht einer Tabellenzeile
  - Felder (Spalten) sind durch ein Trennsymbol (oft: ein Komma, alternativ: Semikolon, Tabulator, Leerzeichen) getrennt
  - Felder zusätzlich in Anführungszeichen (um Kommata im Feld zu erlauben)

CSV (2/2)

	A	B
1	Eins	Vier
2	Zwei	Fünf
3	Drei	Sechs
4		

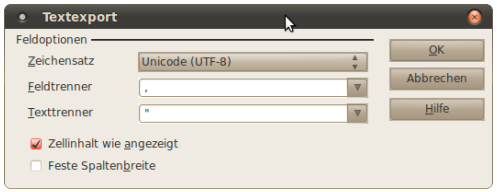

Ergebnis des Exports ins CSV-Format:

```
"Eins","Vier"
"Zwei","Fünf"
"Drei","Sechs"
```


EPS

- **EPS: E**ncapsulated **P**ost**S**cript
- im Prinzip eine normale (einseitige) PostScript-Datei, aber mit einer zusätzlichen „Bounding Box“
- EPS-Dateien kann man in andere Dokumente integrieren (wie Bilddateien)

```
%!PS-Adobe-3.0 EPSF-3.0
%%Title: rob-aktiv.eps
%%Creator: (ImageMagick)
%%CreationDate: Thu May 13 09:43:18 2004
%%BoundingBox: 0 0 168 86
%LanguageLevel: 1
%%Pages: 1
```

unten links: (0, 0)
oben rechts: (168, 86)
(Einheit: 1/72 Zoll)

Applikationsformate

- **CAD**, **C**omputer **A**ided **D**esign
- **GIS**, **G**eo**i**nformations**s**ystem
- **DTP**, **D**eskt**o**p **P**ublishing

CAD (1/4)

Computer Aided Design

- Mechanische Konstruktion
  - Bauwesen
    - Architektur (CAAD)
    - Holzbau
    - Ingenieurbau
    - Historische Rekonstruktion
    - Städtebau
    - Wasserbau
    - Verkehrswegebau
  - Vermessungswesen
  - Produktdesign
- Maschinenbau
  - Anlagenbau
  - Fahrzeugbau
  - Formen- und Werkzeugbau
  - Antriebstechnik
  - Mechanische Simulation
- Schaltpläne in der Elektrotechnik
- Zahnmedizin
- Schmuck- und Textilindustrie
- Elektronische Schaltungen

Quelle: http://de.wikipedia.org/wiki/CAD

CAD (2/4)

- Dateiformate: vektorbasiert
- Verwaltung in objektorientierter Datenbank (nicht in einfachen Vektorgrafikdateien)
- Jedes Objekt besteht aus kleineren Teilobjekten
- Objekte haben Eigenschaften
  - Maschinenteile: Anschlüsse, Befestigungen etc.

CAD (3/4)

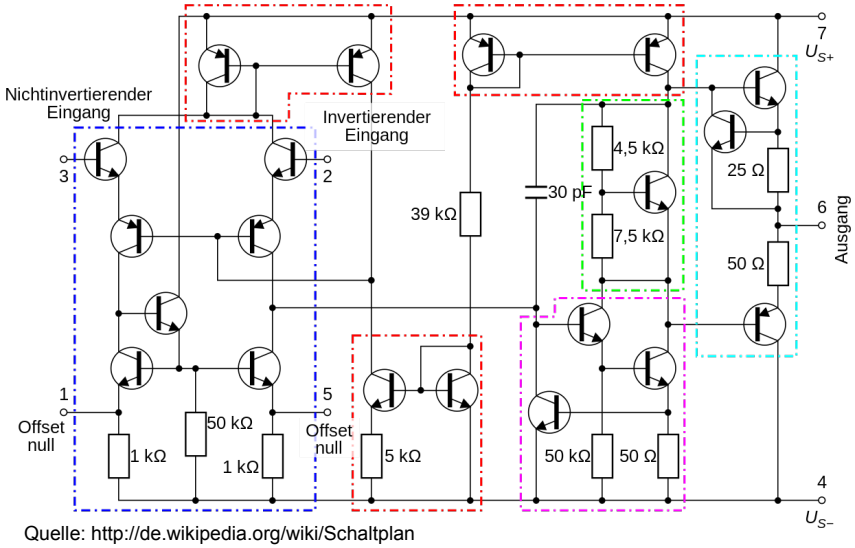

Quelle: http://de.wikipedia.org/wiki/Schaltplan

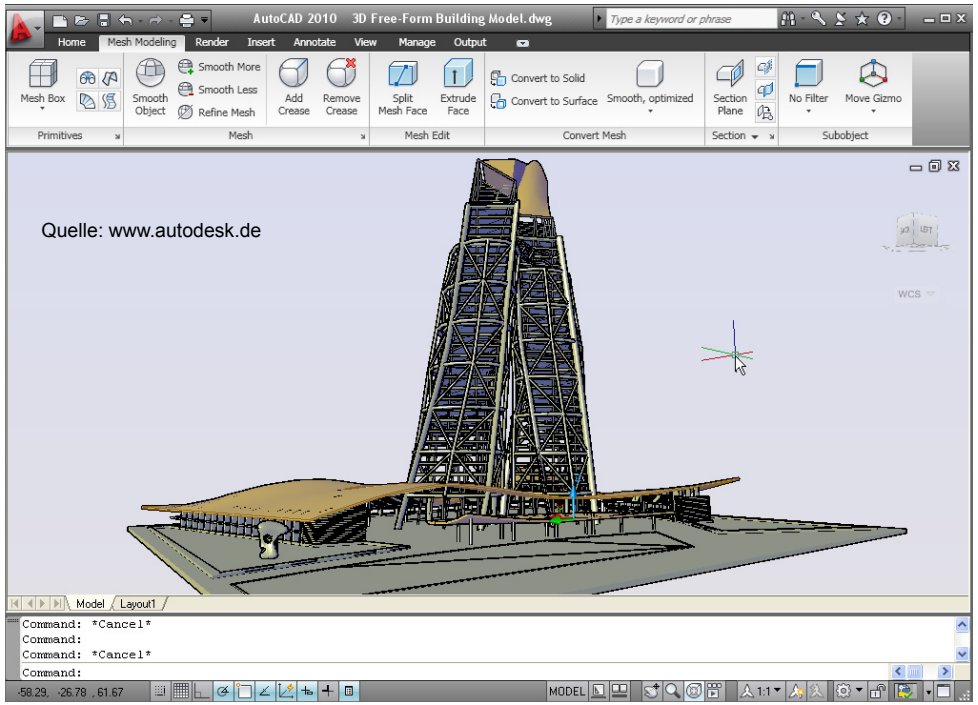

GIS (1/3)

- GIS: **Geo**informations**s**ystem
- Geometriedaten + Sachdaten
- gibt es vektor- und rastergrafikbasiert
- Beispiel: **GPX**, **G**PS E**x**change **F**ormat
  - XML-basiert, speichert
    - GPS-Informationen (Breiten- und Längengrad, Höhe)
    - Zusatzdaten (Zeitpunkt, Ortsbeschreibung etc.)

GIS (2/3)

```
<?xml version="1.0" encoding="UTF-8" standalone="no" ?>
<gpx xmlns="http://www.topografix.com/GPX/1/1"
    creator="byHand" version="1.1"
    xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
    xsi:schemaLocation="http://www.topografix.com/GPX/1/1
    http://www.topografix.com/GPX/1/1/gpx.xsd">

  <wpt lat="39.921055008" lon="3.054223107">
    <ele>12.863281</ele>
    <time>2005-05-16T11:49:06Z</time>
    <name>Cala Sant Vicenç - Mallorca</name>
    <sym>City</sym>
  </wpt>
</gpx>
```

lat = latitude = Breite,
lon = longitude = Länge,
ele = elevation = Höhe
wpt = waypoint = Wegpunkt

GIS (3/3)

Quelle: http://www.gpsvisualizer.com/examples/

Zeitschriftenlayout (1/2)

- Layout-/Satzprogramme (Desktop Publishing)
- ähnlich wie Textverarbeitung, aber rahmenbasiert
- Text fließt von Rahmen zu Rahmen (auch zur nächsten Seite)
- Beispiele: Adobe InDesign, QuarkXPress, Scribus
- Dateiformate proprietär (bei kommerziellen Anwendungen)

Zeitschriftenlayout (2/2)

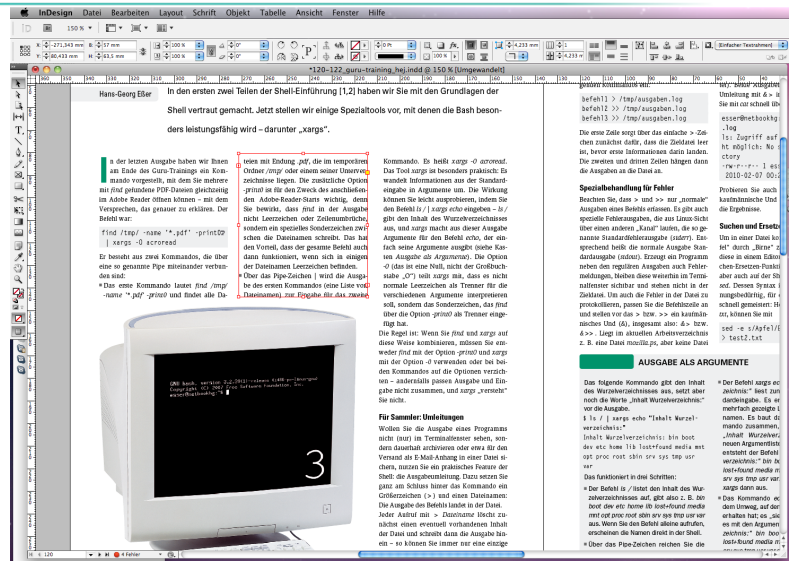

Archive und Software-Pakete

Archive und Software-Pakete

- Kompressions- und Archivformate
  - Kompatibilität / Plattformen
- (Software-) Paketformate

  Installierbare Pakete für …
  - Windows: MSI
  - Linux: RPM, DEB
  - Mac OS: DMG

Kompression einzelner Dateien

- In der Linux-/Unix-Welt: diverse Komprimierer mit eigenen Dateiformaten
  - datei.txt → datei.txt.gz (gzip)
  - datei.txt → datei.txt.bz2 (bzip2)
  - datei.txt → datei.txt.Z (compress)

  etc.
- In der Windows-Welt: meist Archivformate
  - datei.txt → archiv.zip
    (auch wenn nur eine Datei komprimiert wird)

Kompression einzelner Dateien

```
esser@netbook:~/tmp$ ls -l
-rw-r--r-- 1 esser esser 14226 2010-07-12 21:07 index.html
-rw-r--r-- 1 esser esser 14226 2011-01-14 10:03 kopie1.html
-rw-r--r-- 1 esser esser 14226 2011-01-14 10:03 kopie2.html
-rw-r--r-- 1 esser esser 14226 2011-01-14 10:03 kopie3.html
esser@netbook:~/tmp$ gzip kopie1.html ; bzip2 kopie2.html
esser@netbook:~/tmp$ compress kopie3.html ; ls -l
-rw-r--r-- 1 esser esser 14226 2010-07-12 21:07 index.html
-rw-r--r-- 1 esser esser  3806 2011-01-14 10:03 kopie1.html.gz
-rw-r--r-- 1 esser esser  3893 2011-01-14 10:03 kopie2.html.bz2
-rw-r--r-- 1 esser esser  6850 2011-01-14 10:03 kopie3.html.Z
esser@netbook:~/tmp$ file kopie*
kopie1.html.gz:  gzip compressed data, was "kopie1.html", from
                 Unix, last modified: Fri Jan 14 10:03:25 2011
kopie2.html.bz2: bzip2 compressed data, block size = 900k
kopie3.html.Z:   compress'd data 16 bits
```


Kompression einzelner Dateien

- komprimierte Datei enthält (meist) keine Metadaten
  - Dateiname des Originals:
    entsteht durch Weglassen der neuen Dateiendung (.gz, .bz2, .Z)
  - Besitzer, Gruppe, Zugriffsrechte des Originals:
    sind identisch in komprimierte Datei übernommen

```
esser@netbook:~/tmp$ ls -l programm
-rwxr-x--- 1 esser users 211 2011-01-14 10:32 programm
esser@netbook:~/tmp$ gzip programm
esser@netbook:~/tmp$ ls -l programm.gz
-rwxr-x--- 1 esser users  40 2011-01-14 10:32 programm.gz
```


Kompression einzelner Dateien

- komprimierte Datei enthält **meist** keine Metadaten, bei gzip aber Dateiname/Datum:

```
By default, gzip keeps the original file name and  time-stamp
in the compressed file. These are used when decompressing the
file with the -N option. This is useful when the compressed
file  name  was  truncated  or  when  the  time  stamp  was  not
preserved after a file transfer.

-N --name
When compressing, always save the original file name and time
stamp;  this  is the default. When decompressing, restore the
original file name and time stamp if present. This option  is
useful  on  systems which have a limit on file name length or
when the time stamp has been lost after a file transfer.
```

Kompression einzelner Dateien

```
esser@netbook:~$ ls -l
-rw-r--r-- 1 esser esser 14226 2011-01-14 10:50 test1.html
-rw-r--r-- 1 esser esser 14226 2011-01-14 10:50 test2.html
esser@netbook:~$ gzip test1.html
esser@netbook:~$ gzip -n test2.html   # (ohne Namen)
esser@netbook:~$ strings test1.html.gz | grep test
test1.html
esser@netbook:~$ strings test2.html.gz | grep test
esser@netbook:~$ mv test1.html.gz FALSCH1.gz
esser@netbook:~$ mv test2.html.gz FALSCH2.gz
esser@netbook:~$ gunzip -N FALSCH1.gz
esser@netbook:~$ gunzip -N FALSCH2.gz
esser@netbook:~$ ls -l
-rw-r--r-- 1 esser esser 14226 2011-01-14 10:50 FALSCH2
-rw-r--r-- 1 esser esser 14226 2011-01-14 10:50 test1.html
```


Kompression einzelner Dateien

```
esser@netbook:~/tmp$ zip archiv.zip index.html
  adding: index.html (deflated 73%)

esser@netbook:~/tmp$ ls -l index.html archiv.zip
-rw-r--r-- 1 esser esser  3946 2011-01-14 10:08 archiv.zip
-rw-r--r-- 1 esser esser 14226 2010-07-12 21:07 index.html

esser@netbook:~/tmp$ unzip -l archiv.zip
Archive:  archiv.zip
  Length      Date    Time    Name
---------  ---------- -----   ----
    14226  2010-07-12 21:07   index.html
---------                     -------
    14226                     1 file
```


Archivformate

- speichern (meist komprimiert)
  - mehrere Dateien
  - ganze Verzeichnishierarchien
- besonders populär:
  - ZIP (Windows, Mac OS)
  - tar.gz, tar.bz2 (Linux, Unix)
  - DMG (Mac OS)
- eingeschränkt plattformübergreifend

Archivformate

- Probleme beim Transfer zwischen Betriebssystemen (Windows, Linux, Mac OS)
- Was soll man im Archiv (neben den Dateien selbst) speichern?
  - Timestamps – Erstellung, letzte Änderung, letzter Zugriff (nicht jedes Dateisystem hat alle drei Typen)
  - Zugriffsrechte – bei jedem OS anders geregelt: Besitzer, Gruppe, ACLs, klassische Unix-Dateirechte
  - speziell bei Mac OS: Resource Forks
  - speziell bei Windows: Streams („datei.txt:stream“)

Archivformate

- Unterschiedliche Dateiattribute (der versch. Betriebs- bzw. Dateisysteme) kann ein Archivformat durchaus handhaben
- Aber was tun beim Entpacken einer Datei, die auf einem fremden System gepackt wurde?
  - Im Idealfall: So viele Eigenschaften „mitnehmen“ wie möglich, z. B. Datum der letzten Änderung gibt es auf jedem System
  - Oft: Wegwerfen aller Attribute
- Weiteres Problem: Dateinamenskonventionen

Archivformat: ZIP

- ZIP-Format
  - populärer Klassiker, schon seit DOS-Zeiten benutzt
  - speichert ganze Unterordner, Archiv kann ergänzt werden
  - mittelmäßige Kompressionsrate, dafür schnell beim Packen und Entpacken
  - für alle Betriebssysteme verfügbar
  - kann mit speziellen Attributen der diversen BS umgehen (darunter auch Linux-Attribute und Mac OS Resource Forks)
  - Packprogramme mit GUI und für die Shell

Archivformat: ZIP

- Auch Dateien ohne Endung „.zip“ können ZIP-Archive sein, z. B. aktuelle Office-Dateien:
  - .docx, .xlsx, pptx – alle XML-basierten Office-Dateien von Microsoft Office
  - .odt, .ods, .odp – alle XML-basierten Office-Dateien von OpenOffice / LibreOffice
- Solche Dateien kann man untersuchen, indem man sie in *.zip umbenennt (siehe Folien A-130 bis A-139 zu Office-Formaten)

Archivformat: tar

- tar (tape archive)
  - Historie: Unix-Tool, das ganze Verzeichnisse unkomprimiert auf ein Streamer-Band (ein tape) sichert. Nur unter Linux/Unix verbreitet
  - heute: Anlegen von tar-Dateien
  - tar-Kommando bietet Optionen, mit denen sich beliebige Kompressionsprogramme nutzen lassen (-z: gzip, -j: bzip2, -I tool: tool)
  - Nutzung ohne Kompression manchmal nützlich, etwa, beim Packen eines Ordners, der nur bereits komprimierte Dateien enthält

Archive ohne Kompression

- nur in der Linux-/Unix-Welt üblich
- Archivformate
  - tar (tape archive)
  - ar (archive)
  - cpio (copy in, copy out)
  - pax (portable archive exchange)
- Vorteil:
  - Keine Standardkompression integriert; nach Archivbildung Nutzung eines beliebigen Komprimierers

Beispiel: tar-Archiv (1)

```
esser@netbook:~/tmp$ echo "Hallo Welt" > datei1.txt

esser@netbook:~/tmp$ echo "Kleiner Test" > datei2.txt

esser@netbook:~/tmp$ tar cf archiv.tar datei*.txt

esser@netbook:~/tmp$ cat archiv.tar
datei1.txt0000644000175000017500000000000013115140124270120010
0ustar  esseresserHallo Welt
datei2.txt0000644000175000017500000000000015115140124360120040
0ustar  esseresserKleiner Test
```

(cat zeigt nur darstellbare Zeichen an)

Beispiel: tar-Archiv (2)

```
esser@netbook:~/tmp$ hexdump -C archiv.tar
00000000  64 61 74 65 69 31 2e 74  78 74 00 00 00 00 00 00  |datei1.txt......|
00000010  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00000060  00 00 00 00 30 30 30 30  36 34 34 00 30 30 30 31  |....0000644.0001|
00000070  37 35 30 00 30 30 30 31  37 35 30 00 30 30 30 30  |750.0001750.0000|
00000080  30 30 30 30 30 31 33 00  31 31 35 31 34 30 31 32  |0000013.11514012|
00000090  34 32 37 00 30 31 32 30  30 31 00 20 30 00 00 00  |427.012001. 0...|
000000a0  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00000100  00 75 73 74 61 72 20 20  00 65 73 73 65 72 00 00  |.ustar  .esser..|
00000110  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
00000120  00 00 00 00 00 00 00 00  00 65 73 73 65 72 00 00  |.........esser..|
00000130  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00000200  48 61 6c 6c 6f 20 57 65  6c 74 0a 00 00 00 00 00  |Hallo Welt......|
00000210  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00000400  64 61 74 65 69 32 2e 74  78 74 00 00 00 00 00 00  |datei2.txt......|
[...]
```


Beispiel: tar-Archiv (3)

```
[...]
00000400  64 61 74 65 69 32 2e 74  78 74 00 00 00 00 00 00  |datei2.txt......|
00000410  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00000460  00 00 00 00 30 30 30 30  36 34 34 00 30 30 30 31  |....0000644.0001|
00000470  37 35 30 00 30 30 30 31  37 35 30 00 30 30 30 30  |750.0001750.0000|
00000480  30 30 30 30 30 31 35 00  31 31 35 31 34 30 31 32  |0000015.11514012|
00000490  34 33 36 00 30 31 32 30  30 34 00 20 30 00 00 00  |436.012004. 0...|
000004a0  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00000500  00 75 73 74 61 72 20 20  00 65 73 73 65 72 00 00  |.ustar  .esser..|
00000510  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
00000520  00 00 00 00 00 00 00 00  00 65 73 73 65 72 00 00  |.........esser..|
00000530  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00000600  4b 6c 65 69 6e 65 72 20  54 65 73 74 0a 00 00 00  |Kleiner Test....|
00000610  00 00 00 00 00 00 00 00  00 00 00 00 00 00 00 00  |................|
*
00002800
```

Syntax des tar-Kommandos

- Drei Haupt-„Betriebsarten“:
  - **c**reate: `tar -cf Archivname.tar Dateien`
  - lis**t**: `tar -tf Archivname.tar`
  - e**x**tract: `tar -xf Archivname.tar [Dateien]`
  - Option -v (verbose): gibt immer Namen der bearbeiteten Dateien aus

Archivformat: tar.gz, tar.bz2

- tar.gz (auch: tgz) / tar.bz2:
  - eigentlich kein eigenständiges Format:

    Dateien entstehen (eigentlich) in zwei Schritten
    - tar-Archiv erstellen (archiv.tar)
    - dieses Archiv komprimieren; gzip: archiv.tar.gz
    - dank tar-Optionen aus Anwendersicht nur ein Schritt
  - Standardformat für Archive unter Linux/Unix
    - z. B. Quellcode von Software fast immer als tar.gz- oder tar.bz2-Paket erhältlich
    - bzip2: bessere Kompression als gzip, dafür etwas langsamer beim Packen

Archivformat: DMG

- DMG (Apple Disk Image, Mac OS)
  - Standardformat unter Mac OS für Software-Downloads
  - Kompression und Passwortschutz möglich
  - DMG-Images werden von Mac OS automatisch „gemountet“ und erlauben dann die Installation der enthaltenen Programme (meist einfaches Kopieren in den Anwendungen-Ordner)
  - technisch: in DMG-Datei steckt ein Disk Image, vergleichbar mit der Raw-Kopie einer Plattenpartition

Linux-Paketformate

- Die meisten Linux-Distributionen setzen eine Paketverwaltung ein:
  - Installation von Paketen aus sog. **Repositories** (Repos, Paketquellen)
  - Bequemes Entfernen, Aktualisieren von Paketen
  - Paketverwaltung löst automatisch **Abhängigkeiten** und **Konflikte** auf
- Es gibt viele Paketsysteme. Zwei sind populär:
  - RPM (Red Hat Package Manager)
  - DEB (Debian Package Manager) & APT (Advanced Package Tool)

Linux-Paketformate

- Vorteile der Paketverwaltung gegenüber „install.exe“ aus Windows-Welt:
  - automatische „Masseninstallation“ von vielen Anwendungen möglich
  - automatische Aktualisierung aller Programme, für die es ein Update gibt
  - automatische Aktualisierung des ganzen Betriebssystems auf eine neuere Version

Linux-Paketformate: RPM

- Ein **RPM-Paket** besteht aus …
  - einem **Archiv** mit den zu installierenden Dateien
  - **Metadaten** (Paketname, Version, Datum der Erstellung, für welche Linux-Version, Kontakt zum Paketbauer, Abhängigkeiten, Konflikte)
  - Skripte, die vor/nach Installation/Deinstallation ausgeführt werden
- Ein **RPM-Repository** listet eine Sammlung von RPM-Paketen und deren Download-Adressen auf (etwas vereinfacht...)

Linux-Paketformate: RPM

- Manche Programme sind in mehrere RPM-Pakete unterteilt, von denen evtl. nur eine Auswahl benötigt wird. Beispiel:
  - prog-1.2.3.i586.rpm
  - prog-1.2.3.x86_64.rpm
  - prog-lib-1.2.3.i586.rpm
  - prog-lib-1.2.3.x86_64.rpm
  - prog-debug-1.2.3.i586.rpm
  - prog-debug-1.2.3.x86_64.rpm
  - prog-data-1.2.3.noarch.rpm

Linux-Paketformate: RPM

- RPM-Pakete mit Kommando rpm installieren:
  rpm -i paketname.rpm
- Update eines schon installierten Pakets:
  rpm -U paketname.rpm
- Entfernen eines Pakets:
  rpm -e paketname (ohne „.rpm“)
- Überprüfen eines installierten Pakets:
  rpm -V paketname (ohne „.rpm“)

Linux-Paketformate: RPM

- Problem:
  - Es gibt viele verschiedene Linux-Distributionen (OpenSuse, Fedora, Red Hat, Mandriva, ...), die alle RPM-Pakete verwenden.
  - Pakete verschiedener Distributionen sind meist inkompatibel; in der Regel auch Pakete verschiedener Versionen (z. B. OpenSuse 11.2 / 11.3)
- Lösung: Repositories
  - Jeder Distributor verwaltet eines oder mehrere Repositories für jede Version seiner Distribution; mehr dazu später

Linux-Paketformate: RPM

- Problem: Abhängigkeiten
  - Ein Programm X benötigt eine Bibliothek Y (shared library, wie DLL-Datei bei Windows)
  - Das Paket, das X enthält, enthält kein Y
  - Der Paketmanager (RPM) weiß nicht, in welchem Paket sich die Bibliothek Y befindet – wenn es überhaupt eines für diese Linux-Version gibt
  - Installation des X-Pakets schlägt fehl (immerhin), weil RPM erkennt, dass die Bibliothek fehlt
- Lösung: auch Repositories (→ später)

Linux-Paketformate: RPM

- (Kein) Problem: Konflikte
  - Im RPM-Paket X findet sich der Hinweis, dass es nicht parallel zu Paket Y installiert sein darf
  - Y ist installiert, Anwender will X installieren
  - RPM verweigert Installation
  - Problem oder Feature?
- Lösung:
  - Es gibt die Option --force, die das Ignorieren der Konflikte erzwingt (fast immer eine schlechte Idee)

RPM: Repositories

- Installation am besten nur über Repositories
- Je nach Distribution verschiedene Tools für Zugriff auf die Repos:
  - OpenSuse: Zypper (zypper install paketname)
  - Fedora/Red Hat: YUM (yum install paketname)
  - Mandriva: URPMI (urpmi paketname)

  usw.
- Zugriff auf verschiedene Medien möglich

RPM: Repositories

- Repositories auf verschiedenen Medien:
  - HTTP
  - FTP
  - lokales Verzeichnis
  - CD/DVD

  u. a.
- Repositories nach Inhalten aufgeteilt:
  - Pakete
  - Updates
  - Quellpakete

RPM: Repositories

- Neben den offiziellen Repos vom Distributor gibt es oft viele Zusatz-Repos von Drittanbietern, z. B.
  - für spezielle Multimedia-Player und -Codecs
  - für proprietäre Hardware-Treiber (etwa Grafikkarten von Nvidia oder ATI/AMD)
  - von Software-Entwicklern, die ihre Programme nicht in den „regulären“ Repos unterbringen konnten
- Wie schützt man sich vor „falschen“ Repos?

RPM: Repositories

- Signierte Pakete / Repo-Keys:
  - Public-Key-Kryptographie (GPG, PGP etc.)
  - Jedes Repo bietet ein Paket mit öffentlichen Schlüsseln dieses Repos an.
    Wollen Sie das Repo nutzen? → Keys installieren
  - Jedes Paket ist mit dem privaten Key des Repos signiert (diesen Key kennt nur der Repo-Betreiber)
  - Bei Installation eines Pakets aus dem Repo wird die Signatur mit dem vorhandenen public key geprüft. Gibt es keinen Key oder einen Fehler, erscheint eine Warnung

Linux-Paketformate: DEB

- Gleicher Ansatz wie bei RPM:
  - Pakete über Tool dpkg installieren, updaten, löschen, Status prüfen etc.
  - Pakete enthalten Archive, Metadaten (inkl. Abhängigkeiten und Konflikten), Installations- und Deinstallationsskripte
  - Admin-Tool dpkg bietet ähnliche Funktionen wie RPM-Tool rpm
- Andere Liste von Distributionen:
  Debian, Ubuntu, Knoppix, ...

Linux-Paketformate: DEB

- DEB-Pakete nicht auf RPM-Systemen installierbar, und
- RPM-Pakete nicht auf DEB-Systemen installierbar („zwei Welten)
- aber: Programm alien konvertiert zwischen DEB- und RPM-Formaten
- Wie in der RPM-Welt: Ein DEB-Paket zu haben, heißt nicht, es installieren zu können
- Lösung aller Probleme auch hier: Repos

APT: Repositories

- Anders als in der RPM-Welt gibt es ein einheitliches Tool für die Verwaltung von Repos: APT (Advanced Package Manager)
- Zwar müssen auch APT-Anwender für jede Distribution (und jede Version davon) separate Repos nutzen, aber die APT-Kommandos sind immer gleich
  - apt-get install paketname
  - apt-cache search paketname
  - apt-get remove paketname

APT: Repositories

Verwaltung der Repos in /etc/apt/resources.list

```
deb cdrom:[Ubuntu-Netbook 10.04 _Lucid Lynx_ - Release i386
  (20100429.4)]/ lucid main restricted
deb http://de.archive.ubuntu.com/ubuntu/ lucid main restricted
deb-src http://de.archive.ubuntu.com/ubuntu/ lucid main restricted

## Bug Fixes, Updates
deb http://de.archive.ubuntu.com/ubuntu/ lucid-updates main restricted

## Universe Repos
deb http://de.archive.ubuntu.com/ubuntu/ lucid universe
deb http://de.archive.ubuntu.com/ubuntu/ lucid-updates universe
deb http://de.archive.ubuntu.com/ubuntu/ lucid multiverse
deb http://de.archive.ubuntu.com/ubuntu/ lucid-updates multiverse

## Fremdanbieter
deb http://download.virtualbox.org/virtualbox/debian lucid non-free
deb http://ppa.launchpad.net/d.filoni/dillo/ubuntu lucid main
```


Repos und Pakete aus Anbietersicht

- Aus Sicht eines Software-Anbieters:
  - Chaos – Debian, RPM, weitere Paketformate, diverse inkompatible Distributionen und deren Versionen
  - Wer eigene Repos anbieten will, muss diese für alle zu unterstützenden Distributionen separat pflegen
  - Beim RPM-Format heißt das auch: Nutzung verschiedener Tools, mit denen man Repos erstellt, denn Suse != Fedora != Mandriva...
  - Beim DEB-Format: immerhin einheitliche Tool-Welt (APT)

Beispiel: RPM-Paket „bauen“

- Um ein RPM-Paket zu bauen, ist ein sog. Specfile nötig (specification file)
- Beispiel für ein Specfile
  - Programm „Bomberclone“
  - Quelle: T. Schürmann, LinuxUser 07/2006, S. 52 ff., http://www.linux-user.de/ausgabe/2006/07/052-rpm/

RPM-Specfile (1/3)

- Specfile bomberclone.spec:

```
# Specfile fuer BomberClone
Summary: Bomberman-Klon
Name: bomberclone
Version: 0.11.6.2
Release: 1
Copyright: GPL
Group: Games/Action
Source: bomberclone-0.11.6.2.tar.gz
URL: http://www.bomberclone.de
Distribution: Suse Linux 10.0
Packager: Tim Schuermann <tschuermann@linux-user.de>
```


RPM-Specfile (2/3)

```
%description
Ein Bomberman-Klon, bei dem sich mehrere Spieler mit
kleinen Bomben heftig unter Druck setzen.
Mehrspielerpartien in einem Netzwerk sind ebenfalls
möglich.

%prep
%setup
./configure

%build
make

%install
make install
```


RPM-Specfile (3/3)

```
%files
/usr/local/bin/bomberclone
/usr/local/share/games/bomberclone
%doc /usr/local/doc/bomberclone/README
%doc AUTHORS TODO INSTALL NEWS COPYING ChangeLog

%post
ldconfig
```

- Paket bauen mit
  `rpmbuild -bb bomberclone.spec`

Windows-Installer

- MSI-Dateien
  - historisch: „Microsoft Installer“; für Windows-Installer
  - enthalten keine eigene Installationsroutine, sondern das Software-Paket und eine „Anleitung“ für den Windows-Installer
  - komplexe Struktur, MSI-Dateien enthalten Datenbanktabellen
  - MS bietet Tool, das aus XML-Dateien eine MSI-Datei erstellt (Vorgang deutlich komplexer als beim Bauen von RPM- / DEB-Paketen

Windows-Installer

- MSI-Dateien / Windows-Installer erlauben
  - Roll-Back bei Installationsfehlern: Alle schon vorgenommenen Änderungen rückgängig machen (z.B. auch Registry-Edits)
  - Einrichten der Deinstallationsroutine (Kontrollzentrum, Softwareverwaltung)
  - Aufteilung der Software in Komponenten, Anwender kann bei Installation auswählen, welche Teile installiert werden
  - ...

Windows-Installer

- MSI-Dateien / Windows-Installer erlauben
  - On-Demand-Installation und „Advertise“-Feature:
    - Programm enthält Menüpunkte für *nicht* installierte Komponenten
    - bei Aufruf dynamische Nachinstallation der benötigten Komponenten über den Windows-Installer – dafür keine neue Eingabe des Administrator-Passworts nötig

Mac-OS-Paketformate??

- kein spezielles Paketformat für Mac OS
- Software meist in DMG-Image
- Anwendung besteht häufig aus Verzeichnis
  - z. B.: Eintrag „Safari“ im Mac-OS-Programmordner ist in Wirklichkeit ein Verzeichnis „Safari.app“ (→ nächste Folie)
- Einige Programme bringen Installer mit (vgl. setup.exe/Windows)
- Neu: Mac OS AppStore (wie für iPhone & Co.)

Mac OS: Beispiel Safari

```
imac27:Applications esser$ ls -l Safari.app/
drwxr-xr-x  12 root  wheel  408 Nov 18 21:25 Contents

imac27:Applications esser$ ls -l Safari.app/Contents/
lrwxr-xr-x    1 root  wheel      28 Nov 18 21:23 CodeResources ->
_CodeSignature/CodeResources
-rw-r--r--    1 root  wheel   14809 Oct 15 02:40 Info.plist
drwxr-xr-x    3 root  wheel     102 Nov 18 21:25 MacOS
-rw-r--r--    1 root  wheel       8 Oct 15 02:40 PkgInfo
drwxr-xr-x  475 root  wheel   16150 Nov 18 21:25 Resources
-rwxr-xr-x    1 root  wheel  214752 Oct 15 02:40 Safari Webpage Preview
Fetcher
drwxr-xr-x    3 root  wheel     102 Nov 18 21:27 SafariSyncClient.app
drwxr-xr-x    3 root  wheel     102 Apr 20  2010 WebApplicationCore.bundle
drwxr-xr-x    3 root  wheel     102 Nov 18 21:25 _CodeSignature
-rw-r--r--    1 root  wheel     458 Oct 15 02:42 version.plist

imac27:Applications esser$ ls -l Safari.app/Contents/MacOS/
-rwxr-xr-x  1 root  wheel  13518992 Oct 15 02:42 Safari
```

IT-Infrastruktur

SS 2015

Hans-Georg Eßer
Dipl.-Math., Dipl.-Inform.

Foliensatz B: v1.1, 2015/03/05
- PC als Arbeitsplatz

Dieser Foliensatz

PC als Arbeitsplatz

- Office-Anwendungen
  - Textverarbeitung, Serienbrief-Funktion
  - Tabellenkalkulation
  - Präsentationssoftware
  - Textsatz mit LaTeX
- Internet
  - Browser, SaaS (Software as a Service)
  - Mail, Usenet-News, FTP
  - Remote Access: RDP, VNC, SSH

PC als Arbeitsplatz

- Standardapplikationen, z. B.
  - Statistik
  - Numerik
  - Computeralgebra
  - Geoinformationssysteme
- Diagramme und Schemaskizzen
- einfache Bildbearbeitung (Retusche, Veränderung der Auflösung)
- Versionierung

Standardapplikationen: Statistik

- Auswertung von erhobenen Daten (Messungen, Umfrage-Ergebnisse, Verkaufszahlen etc.)
- Data Mining (Wissensextraktion aus Daten)
- Mehrere Anbieter
  - SPSS Statistics (IBM)
  - PSPP (freier SPSS-Klon)
  - Programmiersprache S (Implementationen: R, S-plus)
  - SAS (Business Intelligence Software)

Exkurs: LaTeX

Exkurs: LaTeX (1)

- Seminararbeit evtl. mit LaTeX erstellen
- auch gute Vorbereitung für Bachelorarbeit
- hier eine Einführung in die grundlegenden Konzepte
  - LaTeX basiert auf TeX und ist ein Makropaket, das TeX leichter benutzbar macht
  - zentrale Idee: Trennung zwischen Layout und Inhalt
  - Autor konzentriert sich auf Inhalt, LaTeX übernimmt das Layout

Exkurs: LaTeX (2)

- LaTeX ist ein Dokumenten-*Compiler*.
- Text in einem Editor Ihrer Wahl erstellen
- Als Kodierung UTF8 einstellen
- speichern als `*.tex`-Datei
- übersetzen mit `pdflatex`, erzeugt `*.pdf`-Datei

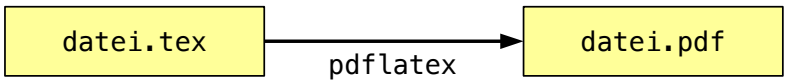

Exkurs: LaTeX (3)

- Wenn LaTeX beim Setzen auf einen Fehler trifft, stoppt es den Vorgang und fragt den Benutzer
  - Wenn die Fehlermeldung unklar ist, einfach [Eingabe] drücken → LaTeX versucht, den Fehler selbst zu beheben
  - Aussehen der PDF-Datei deutet dann meist auf den Fehler hin
  - Wenn viele Fehler auftreten: „S“ eingeben (scrollmode)
  - Wie dauerhaftes Drücken von [Eingabe]

Exkurs: LaTeX (4)

- Sonderzeichen: \ $ # ^ _ muss man „escapen“, um sie benutzen zu können
  - `\$` erzeugt $
  - `\#` erzeugt #
  - `\textbackslash{}` erzeugt \
  - `\textasciitilde{}` erzeugt ~ (oder: `\verb#~#`)
  - `\^{}` erzeugt ^ (oder: `\verb#^#`)
  - `\_` erzeugt _
- Befehle i. d. R. mit `{}` abschließen: `\today{}`

Exkurs: LaTeX (5)

Beispiel für Weglassen der Klammern `{}`:

Heute ist der 35. Mai 2012. Oder: Heute ist der 35. Mai 2012. Falsch ist: Am 35. Mai 2012regnet es. Richtig: Am 35. Mai 2012 scheint die Sonne. Oder: Am 35. Mai 2012 schneit es.

```
Heute ist der \today.
Oder: Heute ist der \today .
Falsch ist:
 Am \today regnet es.
Richtig:
 Am \today{} scheint die Sonne.
 Oder: Am \today\ schneit es.
```

(Quelle: LaTeX2e-Kurzbeschreibung, Version 3.0 von Marco Daniel, Patrick Gundlach, Walter Schmidt, Jörg Knappen, Hubert Partl und Irene Hyna)

Exkurs: LaTeX (6)

- Leerzeichen / Leerzeilen (1)
  - Leerzeichen, Tabulatoren und Zeilenumbrüche werden alle als (ein) Leerzeichen interpretiert
  - auch mehrere davon (außer Umbrüche) werden zu einem Leerzeichen
  - Absatzumbruch durch Einfügen einer (oder mehrerer) Leerzeilen
  - keine Befehle wie `\newline` oder `\\` zum Erzwingen des Umbruchs verwenden
  - neue Seite: `\pagebreak`

Exkurs: LaTeX (7)

- Leerzeichen / Leerzeilen (2)
  - Folgende Texte erzeugen das gleiche Dokument:

```
Abc abc abc
Abc Abc Bcad

Abcda abc afb
```

```
Abc   abc     abc
Abc   Abc     Bcad


Abcda  abc  afb
```


Exkurs: LaTeX (8)

- Befehle und Gruppen
  - LaTeX-Kommandos sind entweder einzelne **Befehle** wie `\today{}` oder
  - Gruppen, die mit `\begin{gruppe}` begonnen und mit `\end{gruppe}` beendet werden

```
\begin{center}
Abgesetzter zentrierter Text
\end{center}
```


Exkurs: LaTeX (9)

- Dokumentstruktur
  - einheitlicher Aufbau:

```
\documentclass{article}    % oder andere Klasse
% Präambel
% Befehle wie \usepackage{...} für LaTeX-Pakete
\begin{document}
% Dokument-Inhalt
Mein erstes Beispiel-Dokument.
\end{document}
```

  - **Klasse:** definiert globale Dokumenten-Eigenschaften (Layout)
  - **Pakete:** ergänzen Zusatzfunktionen

Exkurs: LaTeX (10)

- Aufzählungen (auch geschachtelt)
  - Bullet-Listen:

```
\begin{itemize}
\item Absatz 1
\item Absatz 2
\end{itemize}
```

→

- Absatz 1
- Absatz 2

  - Nummeriert:

```
\begin{enumerate}
\item Absatz 1
\item Absatz 2
\end{enumerate}
```

→

1. Absatz 1
2. Absatz 2

Exkurs: LaTeX (11)

- Einfache Auszeichnungen
  - `\textbf{Text}`: **fett**
  - `\emph{Text}`: hervorgehoben (*kursiv*)
  - `\underline{Text}`: unterstrichen
- Bilder und Tabellen: über `figure`-, `table`- und `tabular`-Umgebungen sowie den Befehl `\includegraphics{bilddatei}` (ohne Endung)
- Bild-/Tabellen-Unterschrift mit `\caption{Text.}`
- Labels: `\label{label}`, Verweise: `\ref{label}`, `\pageref{label}` (Seitenzahl)

Exkurs: BibTeX / Biber (1)

- Literaturverwaltung über separates Tool (`bibtex` oder `biber`)
- Quellen in `*.bib`-Dateien mit eigener Syntax verwalten
- Typische Sequenz, um Dokument `dokument.tex` zu bauen:

```
pdflatex dokument
bibtex dokument
pdflatex dokument
pdflatex dokument
```


Exkurs: BibTeX / Biber (2)

- Syntax in den `*.bib`-Dateien

```
@article{CS03,
 author = "Carrier, Brian and Spafford, Eugene H.",
 title = "Getting physical with the digital
          investigation process",
 journal = "International Journal of Digital Evidence",
 volume = 2,
 year = 2003
}
```

- `CS03` ist ein BibTeX-Label → `\cite{CS03}`
- Beispiele in `literatur/literatur.bib`

Exkurs: BibTeX / Biber (3)

- BibTeX-Tipps
  - für Bücher: Google-Suche nach „ISBN to Bibtex“ → http://manas.tungare.name/software/isbn-to-bibtex/ (oder andere Konverter-Seiten)
  - für Artikel: z. B. auf der ACM-DL-Seite (http://dl.acm.org), Beitrag suchen, Detailseite aufrufen, BibTeX-Export

LaTeX-Tipps (1)

- Ausprobieren
- Mit funktionierenden Beispielen starten (z. B. mit der Vorlage; siehe auch folgende Folien)
- auf den Inhalt konzentrieren / nicht durch Layout-Fragen ablenken lassen
- ggf. nach speziellen Paketen suchen; LaTeX bringt umfangreiche Dokumentation mit:

  `texdoc paketname` (Mac, Linux)

LaTeX-Tipps (2)

- für mehr Komfort: LaTeX-IDE einsetzen
  - TeXShop (Mac), http://pages.uoregon.edu/koch/texshop/
  - TeXstudio (Windows, Mac, Linux u. a.), http://texstudio.sourceforge.net/
  - Features:
    - Aufrufe von pdflatex, bibtex/biber und anderen Tools über Tastenkombination
    - parallele Ansicht von Editor und Vorschau
    - SyncTeX
    - ggf. Debugging-Hilfe

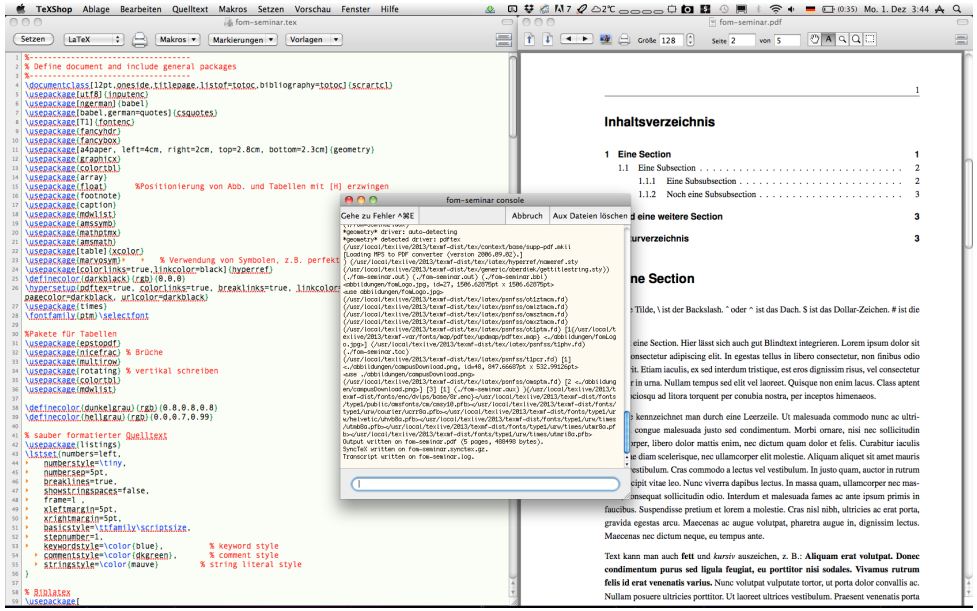

(TeXShop, OS X)

LaTeX: Arbeiten mit der FOM-Vorlage (1)

- Datei `fom-seminar.zip` (im Campus-System) herunterladen und entpacken; erzeugt Ordner `fom-seminar/`.
- Darin liegt eine Datei `fom-seminar.tex` – das ist das Hauptdokument
- Literaturverzeichnis: `literatur/literatur.bib`
- Übersetzen mit `./compile.sh` (Linux, OS X) bzw. `compile.bat` (Windows)

LaTeX: Arbeiten mit der FOM-Vorlage (2)

- Anpassungen:

```
% Autor
\newcommand{\myAutor}{Max Mustermann}
% Titel der Arbeit
\newcommand{\myTitel}{Meine \LaTeX{}-Seminararbeit}
% Betreuer
\newcommand{\myBetreuer}{Dipl.-Math. Dipl.-Inform. Hans-Georg Eßer}
% Matrikelnummer
\newcommand{\myMatrikelNr}{123456}
% Ort
\newcommand{\myOrt}{Nürnberg}
% Datum der Abgabe
\newcommand{\myAbgabeDatum}{15. Januar 2015}
% Semesterzahl
\newcommand{\mySemesterZahl}{4}
% Name der Hochschule
\newcommand{\myHochschulName}{FOM Hochschule}
% Studiengang
\newcommand{\myStudiengang}{Wirtschaftsinformatik}
% Art der Arbeit
\newcommand{\myThesisArt}{Seminararbeit}
```


LaTeX: Arbeiten mit der FOM-Vorlage (3)

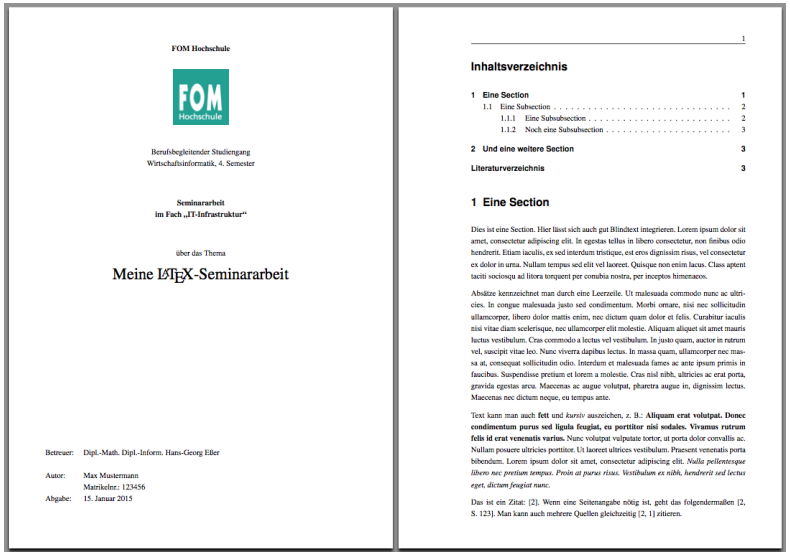

FOM Hochschule

Berufsbegleitender Studiengang
Wirtschaftsinformatik, 4. Semester

Seminararbeit
im Fach „IT-Infrastruktur"

über das Thema

Meine LaTeX-Seminararbeit

Betreuer: Dipl.-Math. Dipl.-Inform. Hans-Georg Eßer

Autor: Max Mustermann
Matrikelnr.: 123456
Abgabe: 15. Januar 2015

1

Inhaltsverzeichnis

1 Eine Section

Dies ist eine Section. Hier lässt sich auch gut Blindtext integrieren. Lorem ipsum dolor sit amet, consectetur adipiscing elit. In egestas tellus in libero consectetur, non finibus odio hendrerit. Etiam iaculis, ex sed interdum tristique, est eros dignissim risus, vel consectetur ex dolor in urna. Nullam tempus sed elit vel laoreet. Quisque non enim lacus. Class aptent taciti sociosqu ad litora torquent per conubia nostra, per inceptos himenaeos.

Absätze kennzeichnet man durch eine Leerzeile. Ut malesuada commodo nunc ac ultricies. In congue malesuada justo sed condimentum. Morbi ornare, nisi nec sollicitudin ullamcorper, libero dolor mattis enim, nec dictum quam dolor et felis. Curabitur iaculis nisi vitae diam scelerisque, nec ullamcorper elit molestie. Aliquam aliquet sit amet mauris luctus vestibulum. Cras commodo a lectus vel vestibulum. In justo quam, auctor in rutrum vel, suscipit vitae leo. Nunc viverra dapibus lectus. In massa quam, ullamcorper nec massa at, consequat sollicitudin odio. Interdum et malesuada fames ac ante ipsum primis in faucibus. Suspendisse pretium et lorem a molestie. Cras nisl nibh, ultricies ac erat porta, gravida egestas arcu. Maecenas ac augue volutpat, pharetra augue in, dignissim lectus. Maecenas nec dictum neque, eu tempus ante.

Text kann man auch **fett** und *kursiv* auszeichen, z. B.: **Aliquam erat volutpat. Donec condimentum purus sed ligula feugiat, eu porttitor nisi sodales. Vivamus rutrum felis id erat venenatis varius.** Nunc volutpat vulputate tortor, ut porta dolor convallis ac. Nullam posuere ultricies porttitor. Ut laoreet ultrices vestibulum. Praesent venenatis porta bibendum. Lorem ipsum dolor sit amet, consectetur adipiscing elit. *Nulla pellentesque libero nec pretium tempus. Proin at purus risus. Vestibulum ex nibh, hendrerit sed lectus eget, dictum feugiat nunc.*

Das ist ein Zitat: [2]. Wenn eine Seitenangabe nötig ist, geht das folgendermaßen [2, S. 123]. Man kann auch mehrere Quellen gleichzeitig [2, 1] zitieren.

Statistik: Programmiersprache R

R: Einführung

- R ist Programmiersprache
- interaktiver Modus oder R-Skripte ausführen
- IDE: R Studio
- nur mit Statistik-Grundkenntnissen sinnvoll nutzbar
- R ist über Zusatzpakete erweiterbar

R: Interessante Sprach-Features

```
> x = 1:20
> x
 [1]  1  2  3  4  5  6  7  8  9 10 11 12 13 14 15 16 17 18 19 20
> y = x+0.5
> y
 [1]  1.5  2.5  3.5  4.5  5.5  6.5  7.5  8.5  9.5 10.5 11.5 12.5
[13] 13.5 14.5 15.5 16.5 17.5 18.5 19.5 20.5
> index = c(1,2,3,11,12,13)
> x[index]
[1]  1  2  3 11 12 13
> y[index]
[1]  1.5  2.5  3.5 11.5 12.5 13.5
> val = 1:100; plot(val,sin(val/15))
```

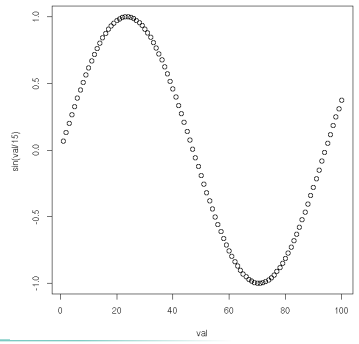

R: Beispiele (1)

```
> temp = read.table("normtemp.txt")
> names(temp)
[1] "V1" "V2" "V3"
> degreesF = temp$V1
> qqnorm(degreesF)
> qqline(degreesF)
> plot(density(degreesF))
> qqnorm(degreesF)
> qqline(degreesF)
```

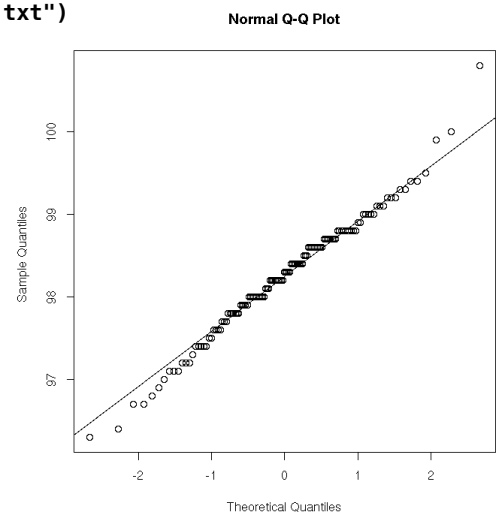

normtemp.txt:

```
96.3    1    70
96.7    1    71
96.9    1    74
97.0    1    80
97.1    1    73
...
```


R: Beispiele (2)

```
> plot(density(degreesF))
> shapiro.test(degreesF)

    Shapiro-Wilk normality test

data:  degreesF
W = 0.9866, p-value = 0.2332

> t.test(degreesF, mu=98.6,
    alternative="two.sided")

    One Sample t-test

data:  degreesF
t = -5.4548, df = 129, p-value = 2.411e-07
alternative hypothesis: true mean is not equal to 98.6
95 percent confidence interval:
 98.12200 98.37646
sample estimates:
mean of x
 98.24923
```

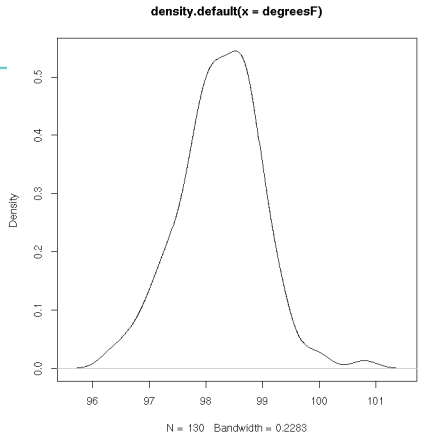

R: Beispiele (3)

```
> x <- c(8,11,3,6,6,7, 9,11,12,9,8,8,6,13)   # Test vorher
> y <- c(2,12,4,4,2,9,10, 7, 5,5,8,8,9, 9)   # Test nachher
> qqnorm(x); qqline(x, col = 2);             # linker  Plot (x)
> qqnorm(y); qqline(y, col = 2);             # rechter Plot (y)
```

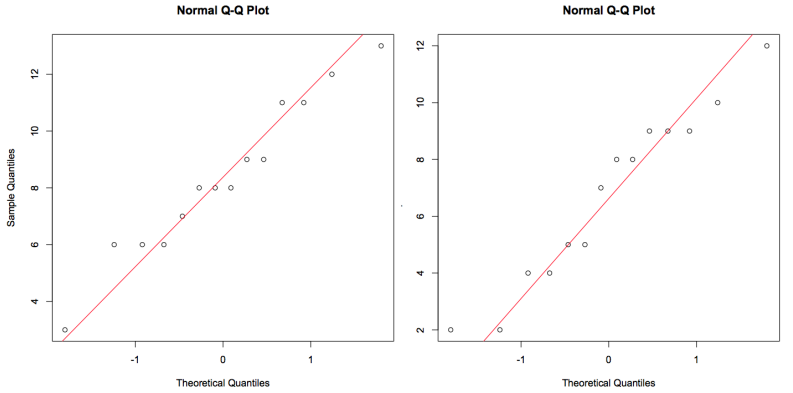

Daten sind nicht normalverteilt

R: Beispiele (4)

```
> x <- c(8,11,3,6,6,7, 9,11,12,9,8,8,6,13)    # Test vorher
> y <- c(2,12,4,4,2,9,10, 7, 5,5,8,8,9, 9)    # Test nachher
> wilcox.test (x, y, alternative = "greater", paired = TRUE,
  correct = TRUE)

    Wilcoxon signed rank test with continuity correction

data: x and y
V = 61.5, p-value = 0.04129
alternative hypothesis: true location shift is greater than 0
```

p-value ist kleiner als 0,05 → Null-Hypothese („keine signifikante Verbesserung“) ablehnen

R Studio

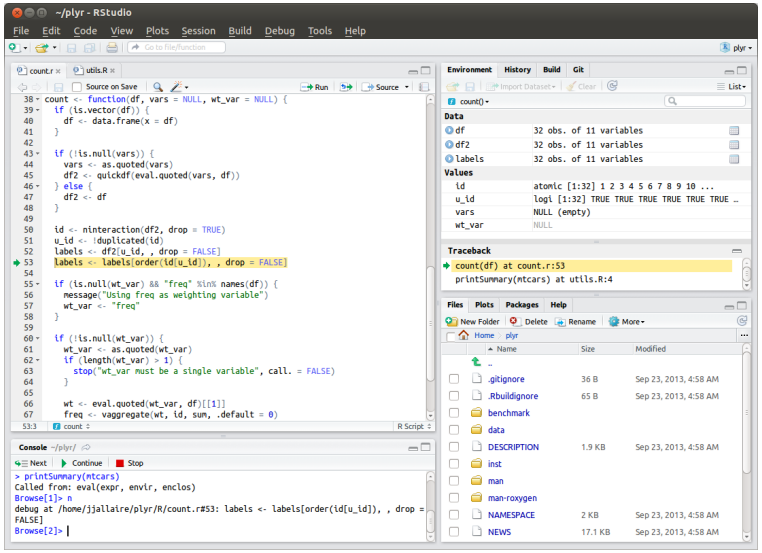

Quelle: http://rstudioblog.files.wordpress.com/2013/09/rstudiodebugger.png

Numerik: MatLab, GNU Octave

MatLab / Octave: Numerische Methoden

Datenanalyse, Algorithmen-Entwicklung und Modellerstellung

- Interpolation und Regression
- Differenzierung und Integration
- Lineare Gleichungssysteme
- Fourier-Analyse
- Eigenwerte und Singulärwerte
- Gewöhnliche Differenzialgleichungen
- Dünnbesetzte Matrizen

Octave, Beispiel: Numerische Integration

```
octave:1> function y = f(x)
>   y = x .* sin (1./x) .* sqrt (abs (1-x));
> endfunction
octave:2> x = 0:0.005:3;
octave:3> plot (x, f(x));
octave:4> quad ("f", 0, 3)
 ABNORMAL RETURN FROM DQAGP
ans =  1.9819
```

$$f(x) = x \sin\left(\frac{1}{x}\right)\sqrt{|1-x|}$$

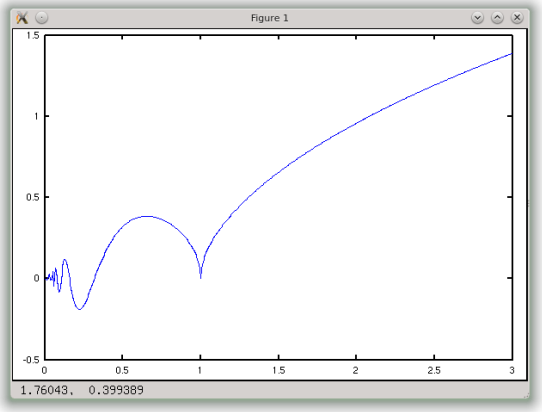

Octave, Beispiel: Histogramm

```
octave:1> hist(randn(100000, 1), 100)
```

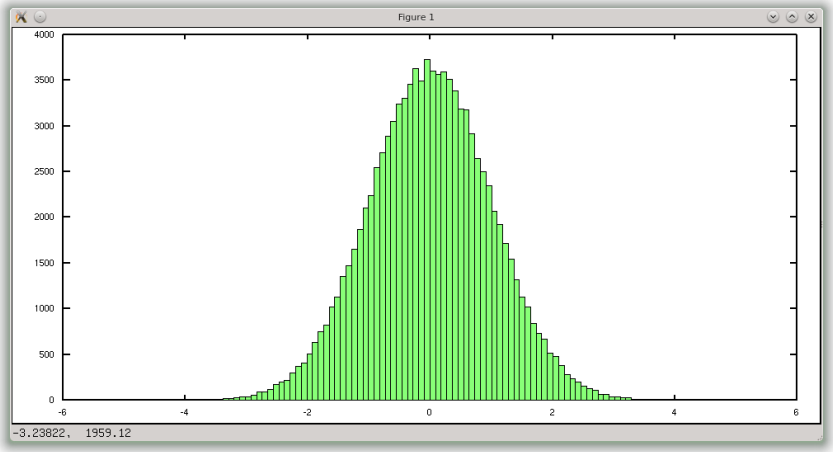

Octave, Beispiel: Inverse Matrix

```
octave:48> A = [ 1 1 1; 0 1 1; 0 0 1]
A =

   1   1   1
   0   1   1
   0   0   1

octave:49> inv (A)
ans =

   1  -1  -0
   0   1  -1
   0   0   1

octave:50> A * inv(A)
ans =

   1   0   0
   0   1   0
   0   0   1
```


Computer-Algebra-Systeme

Computer-Algebra-Systeme (CAS)

- anders als numerische Software führen CAS *symbolische* Berechnungen durch
- mathematische Ausdrücke, Matrizen etc. können Variablen enthalten, z. B.
  - Matrix mit Variable invertieren
  - symbolisches Differenzieren und Integrieren
- Software
  - Maple (kommerziell), Axiom (freie Software)
  - Wolfram Alpha (Webseite)

Matrix-Invertierung mit Wolfram Alpha

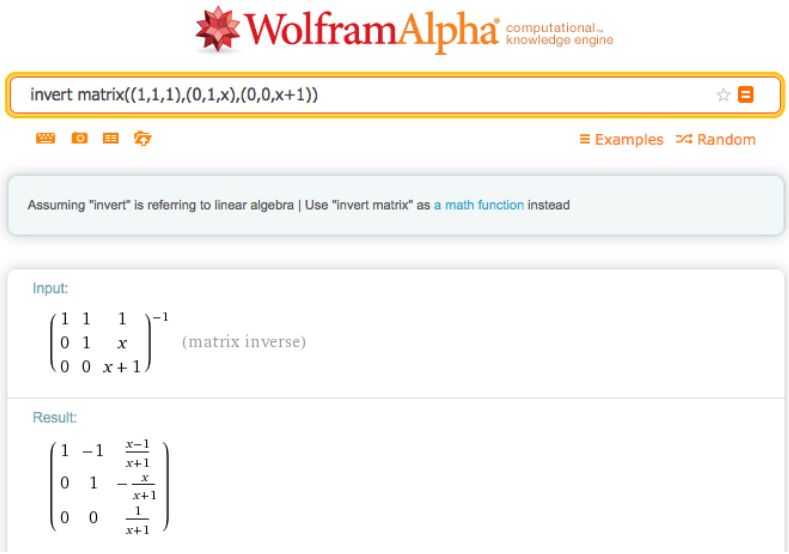

Symbol. Integration mit Wolfram Alpha

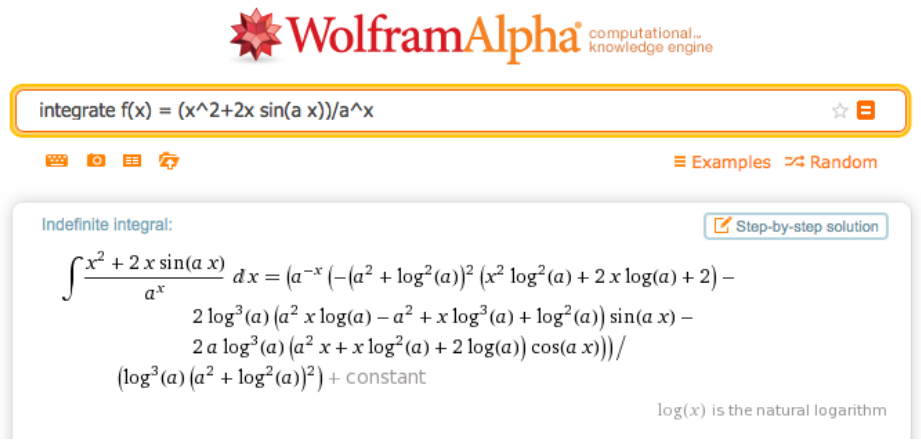

Geo-Informationssysteme (GIS)

Geo-Informationssysteme

- Erfassung, Bearbeitung, Organisation, Analyse und Präsentation räumlicher Daten
- verwenden eigene Auszeichnungssprachen, um Daten zu speichern; z. B.
- KML (Keyhole Markup Language), verwendet von Google Earth
- GPS Exchange Format (GPX)

(Quelle: Wikipedia)

```
<?xml version="1.0" encoding="UTF-8"?>
<kml xmlns="http://www.opengis.net/kml/2.2">
<Document>
  <Placemark>
    <name>Zürich</name>
    <description>Zürich</description>
    <Point>
      <coordinates>8.55,47.3666667,0
        </coordinates>
    </Point>
  </Placemark>
</Document>
</kml>
```


Standardapplikationen: GIS

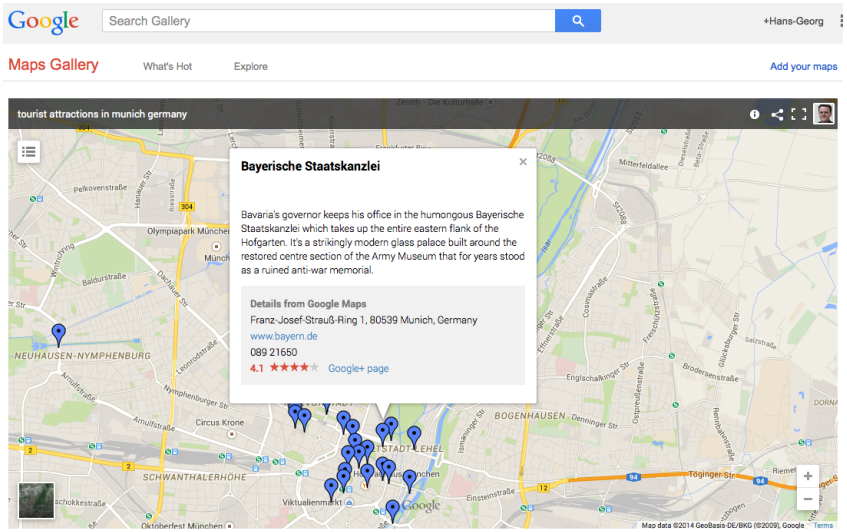

Standardapplikationen: GIS

- Nielsen-Gebiete

Gebiet 1:	Hamburg Bremen Schleswig-Holstein Niedersachsen
Gebiet 2:	Nordrhein-Westfalen
Gebiet 3a:	Hessen Rheinland-Pfalz Saarland
Gebiet 3b:	Baden-Württemberg
Gebiet 4:	Bayern
Gebiet 5+6:	Berlin Mecklenburg-Vorpommern Brandenburg Sachsen-Anhalt
Gebiet 7:	Thüringen Sachsen

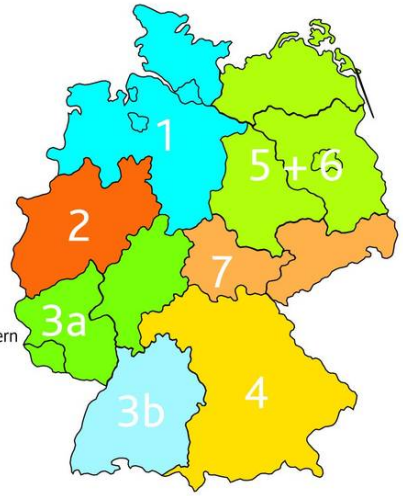

Bild: http://www.makz.de/nielsengebiete.html

Standardapplikationen: GIS

- Kaufkraft 2014

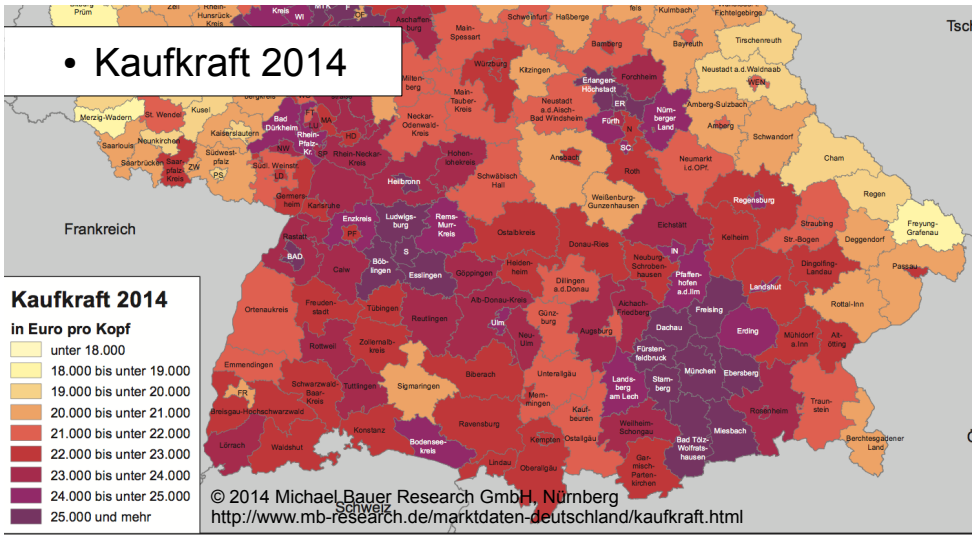

Standardapplikationen: GIS

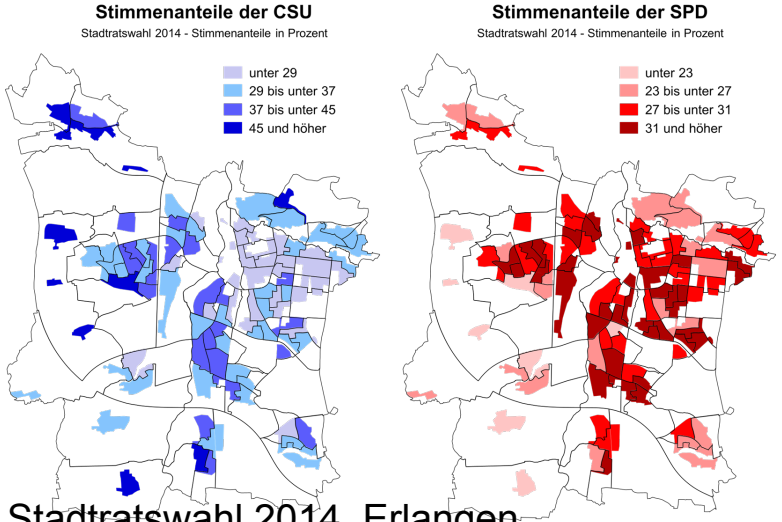

Bilder: http://www.erlangen.de/tabid-1785/

- Stadtratswahl 2014, Erlangen

Versionierung

Versionsverwaltung

- Aufgabe: Änderungen an Dokumenten (oft: an Quellcode-Dokumenten) verwalten
- Eine Auswahl von Tools
  - 1972: Source Code Control System (SCCS)
  - 1982: Revision Control System (rcs)
  - 1990: Concurrent Versions System (cvs)
  - 2000: Subversion (svn)
  - 2005: Git
  - 2005: Mercurial (hg)

Versionsverwaltung: Naiver Ansatz (1)

- Naiver Ansatz: Versionen in separaten Ordnern speichern
- Vergleich der Versionen mit `diff`

```
$ find . -name '*.tex' -exec ls -l {} \;
-rw-r--r--@ 1 ...   823127 31 Okt  2013 ./2013-10-31/diss-hgesser-ulix.tex
-rw-r--r--@ 1 ...   896574  7 Jan  2014 ./2014-01-07/diss-hgesser-ulix.tex
-rw-r--r--@ 1 ...  1005074  2 Mai  2014 ./2014-05-02/diss-hgesser-ulix.tex
-rw-r--r--@ 1 ...  1005063  3 Mai  2014 ./2014-05-03/diss-hgesser-ulix.tex
-rw-r--r--@ 1 ...  1594695 25 Aug 22:26 ./2014-08-25/diss-hgesser-ulix.tex
$ diff 2014-05-02/diss-hgesser-ulix.tex 2014-05-03/diss-hgesser-ulix.tex
12312d12311
< char *buf;
$ _
```

Versionsverwaltung: Naiver Ansatz (2)

- Nachteile des naiven Ansatzes
  - alle Dateien mehrfach vollständig gespeichert
  - keine Zusammenfassung der Änderungen von einer Version zur nächsten
  - keine automatische Zuteilung von Versions- bzw. Revisionsnummern
- Alternative: spezialisierte Versionsverwaltungen
  - speichern jeweils nur die Änderungen (Delta)
  - legen Versionsnummern und Kommentare an
  - multi-user-tauglich

Versionsverwaltungssoftware

- Alle Versionsverwaltungen unterstützen (mindestens) diese drei Operationen:
  - **ADD:** Eine Datei (oder einen ganzen Ordner) hinzufügen (= unter die Verwaltung stellen)
  - **CHECK-IN / COMMIT:** Die aktuelle Arbeitsfassung „einchecken“ (sichert die Datei unter einer neuen Revisionsnummer ins Archiv)
  - **CHECK-OUT:** Die letzte oder eine ältere Revision „aus-checken“, also aus dem Archiv wiederherstellen

Beispiel: Mercurial (1)

- hier nur lokaler Einsatz (kein Repository im Netzwerk)
- Verzeichnis für die Nutzung von Mercurial vorbereiten:

  ```
  hg init
  ```

- Datei hinzufügen:

  ```
  hg add Dateiname
  ```


Beispiel: Mercurial (2)

- alle aktualisierten Dateien einchecken:

  ```
  hg commit
  ```

  öffnet Editor-Fenster, Eingabe einer Zusammenfassung

```
Erste Revision; nur Datei test.tex

HG: Bitte gib eine Versions-Meldung ein. Zeilen beginnend mit
  'HG:' werden
HG: entfernt. Leere Versionsmeldung wird das Übernehmen
  abbrechen.
HG: --
HG: Benutzer: Hans-Georg Esser <h.g.esser@gmx.de>
HG: Zweig 'default'
HG: Hinzugefügt test.tex
```

Beispiel: Mercurial (3)

- Neue Dateien im Ordner entdecken:

```
$ hg status
? literatur.bib
```

- Andere Revision aus-checken:

```
$ hg co 0
1 Dateien aktualisiert, 0 Dateien
zusammengeführt, 0 Dateien entfernt,
0 Dateien ungelöst
```

(hat im Arbeitsverzeichnis Version 1 durch die ältere Version 0 ersetzt)

Beispiel: Mercurial (4)

- Verlauf der Änderungen anzeigen:

```
$ hg annotate -r0 test.tex
0: \documentclass{article}
0: \begin{document}
0: Hello World
0: \end{document}
$ hg annotate -r1 test.tex
0: \documentclass{article}
0: \begin{document}
0: Hello World
1: One more line
0: \end{document}
$ hg annotate -r2 test.tex
0: \documentclass{article}
0: \begin{document}
2: Old two lines deleted, one new line
0: \end{document}
```


Beispiel: Mercurial (5)

- Vergleich zweier Versionen:

```
$ hg diff -r0:2 test.tex
diff -r 34972b9741f6 -r 3e988791a22a test.tex
--- a/test.tex Mon Dec 01 11:37:11 2014 +0100
+++ b/test.tex Mon Dec 01 11:54:00 2014 +0100
@@ -1,5 +1,5 @@
 \documentclass{article}
 \begin{document}
-Hello World
+Old two lines deleted, one new line
 \end{document}
```


Beispiel: Mercurial (6)

- Protokoll:

```
$ hg log
Änderung:        2:3e988791a22a
Marke:           tip
Nutzer:          Hans-Georg Esser <h.g.esser@gmx.de>
Datum:           Mon Dec 01 11:54:00 2014 +0100
Zusammenfassung: Zwei Zeilen geloescht, eine neu

Änderung:        1:8f2ae3855183
Nutzer:          Hans-Georg Esser <h.g.esser@gmx.de>
Datum:           Mon Dec 01 11:49:28 2014 +0100
Zusammenfassung: Aenderung, eine neue Zeile in test.tex

Änderung:        0:34972b9741f6
Nutzer:          Hans-Georg Esser <h.g.esser@gmx.de>
Datum:           Mon Dec 01 11:37:11 2014 +0100
Zusammenfassung: Erste Revision; nur Datei test.tex
```

Mercurial: Revisions-Bäume

- Durch Ändern einer älteren Version und Wieder-Ein-Checken entsteht ein paralleler Zweig – und damit ein Baum

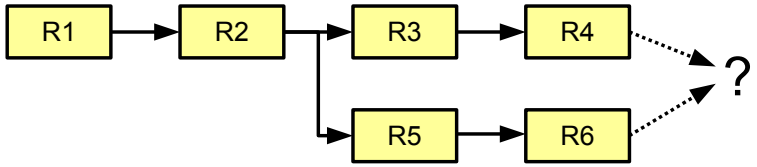

- Entwicklung kann nun parallel weiter laufen
- Zweige können auch wieder vereinigt werden

Mercurial: Merge

- Weiterentwicklung von Code in mehreren Zweigen
- Zweige sollen zusammengeführt werden

  → **Merge**-Operation

  → Änderungen eines Zweigs in anderen Zweig übernehmen

Mercurial: Merge

Rev. 0:

```
int main () {
  // Block 1
  int i = 0;
  for (; i < 10; i++) {
    printf (i);
  }

  // Block 2
  char c = 'a';
  for (; c <= 'z'; c++) {
    printf (c);
  }
}
```

Rev. 1:

```
int main () {
  // Block 1
  int i = 0;
  for (; i < 10; i++) {
    printf ("%d\n", i);
  }

  // Block 2
  char c = 'a';
  for (; c <= 'z'; c++) {
    printf (c);
  }
}
```

Rev. 2:

```
int main () {
  // Block 1
  int i = 0;
  for (; i < 10; i++) {
    printf (i);
  }

  // Block 2
  char c = 'a';
  for (; c <= 'z'; c++) {
    printf ("%c \n", c);  // %c!
  }
}
```


Mercurial: Merge

```
$ hg merge -r1          # arbeite gerade mit rev. 2
Führe code.c zusammen
0 Dateien aktualisiert, 1 Dateien zusammengeführt, 0
Dateien entfernt, 0 Dateien ungelöst
(Zusammenführen von Zweigen, vergiss nicht 'hg commit'
auszuführen)
$ hg commit
```

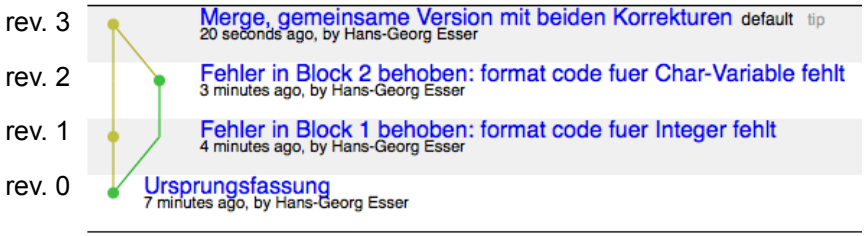

Mercurial: Merge

- Ergebnis:

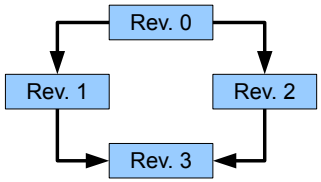

Rev. 3:

```
int main () {
  // Block 1
  int i = 0;
  for (; i < 10; i++) {
    printf ("%d\n", i);   // format code fehlt!
  }

  // Block 2
  char c = 'a';
  for (; c <= 'z'; c++) {
    printf ("%c \n", c);  // %c!
  }
}
```

Änderung aus Rev. 1

Änderung aus Rev. 2

Mercurial: Merge-Probleme

- Merge-Operation erfolgreich, wenn Änderungen in Zweigen verschiedene Bereiche der Datei (oder versch. Dateien) betreffen
- Bei Änderungen derselben Bereiche Konflikt
  → kein automatischer Merge möglich
- Lösen der Konflikte über Tools wie KDiff3

  → KDiff3-Demo

Mercurial: geklonte Repositorys

- Klonen (hg clone) erzeugt unabhängige Kopie eines Repositorys
- Bsp.:

```
$ hg clone \
  my-hello \
  my-new-hello
```

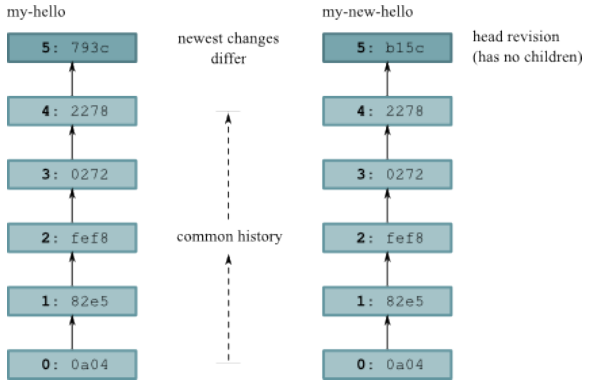

Quelle für Beispiel und Bilder: http://hgbook.red-bean.com/read/a-tour-of-mercurial-merging-work.html

Mercurial: geklonte Repositorys

- Pull-Operation (hg pull) zieht aktuelle Fassung aus anderem Repository
- Bsp.:

```
$ hg pull \
  ../my-hello
```

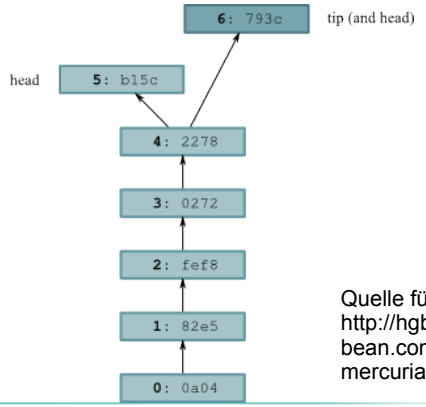

Quelle für Beispiel und Bilder: http://hgbook.red-bean.com/read/a-tour-of-mercurial-merging-work.html

Mercurial: geklonte Repositorys

- Zwei Heads (Revisionen ohne Kinder)

```
$ hg heads
changeset:   6:b6fed4f21233
tag:         tip
parent:      4:2278160e78d4
user:        Bryan O'Sullivan <bos@serpentine.com>
date:        Tue May 05 06:55:53 2009 +0000
summary:     Added an extra line of output
changeset:   5:5218ee8aecf3
user:        Bryan O'Sullivan <bos@serpentine.com>
date:        Tue May 05 06:55:55 2009 +0000
summary:     A new hello for a new day.
```

- `hg merge` vereinigt die beiden heads

Mercurial: geklonte Repositorys

- `hg merge` und `hg commit`

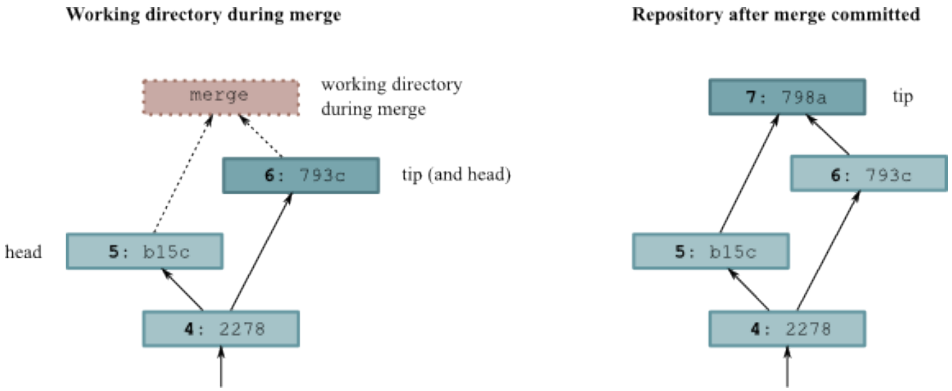

IT-Infrastruktur

SS 2015

Hans-Georg Eßer
Dipl.-Math., Dipl.-Inform.

Foliensatz D: v1.1, 2015/03/05

Rechnerstrukturen
- Pipelining
- Multi-Core-, Multi-Prozessor-Systeme

Dieser Foliensatz

Inhalte

- Prinzipien und Methoden für Analyse, Implementierung, Bewertung und Klassifikation von Rechnerarchitekturen
- Architekturprinzipien und Merkmale moderner RISC- und CISC- (Mikro-) Prozessoren wie
  - Befehlssätze
  - Superskalarität
  - Pipelining
  - Cache-Organisation
- Organisationsprinzipien von Multiprozessor-Systemen und wichtige Architekturmodelle

Grobe Gliederung

1. Grundlagen
- Begriffsbestimmung, Abgrenzung
- Historische Entwicklung

2. Instruction Set Architecture (ISA)
- Registerstruktur, Adressierungsarten
- Maschinenbefehlssätze, Spezialbefehle
- Stack-Maschinen

3. Leistungsbewertung und Leistungsmessung

Grobe Gliederung

4. Pipelining
- Klassische Fünf-Stufen-Pipeline
- Pipeline-Hemmnisse
- Superskalarität, *out of order execution*
- Spekulative Befehlsausführung, Sprungvorhersage

5. Speichersysteme
- Speichertypen, Caches

6. Sprungvorhersage

7. Mehrprozessorsysteme

Literatur (1/2)

Rechneraufbau und Rechnerarchitektur
Axel Böttcher (Hochschule München)
ISBN: 3540209794 (2007)

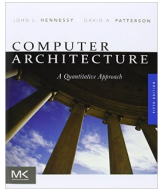

Computer Architecture: A Quantitative Approach
5th ed.
John L. Hennessy, David A. Patterson
ISBN: 012383872X (2011)

Literatur (2/2)

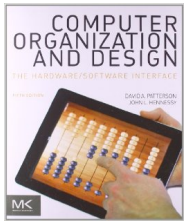

Computer Organization and Design, The Hardware/Software Interface
5th ed.
David A. Patterson, John L. Hennessy
ISBN: 0124077269 (2013)

Rechnerarchitektur: Von der digitalen Logik zum Parallelrechner
Andrew S. Tanenbaum
ISBN: 3868942386 (2014)

Hinweis

- Einen Großteil der Folien habe ich von

  Prof. Dr. Axel Böttcher

  (FH München) übernommen, der diese Vorlesung 2009 gehalten hat und mir sein Material freundlicherweise zur Verfügung gestellt hat.

1. Grundlagen

Begriffsbestimmung (1/2)

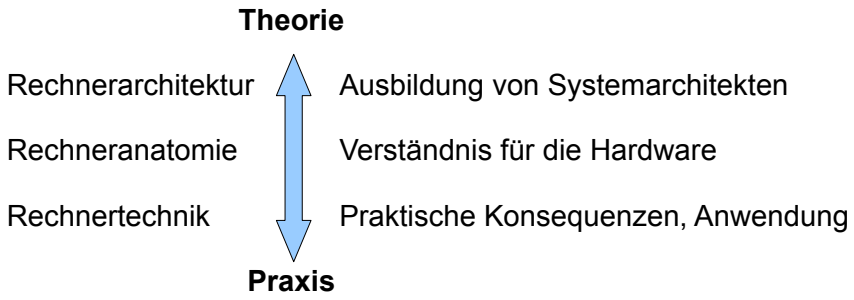

Rechnerarchitektur umfasst
- die Analyse
- den Entwurf
- die Bewertung
- die Synthese

von Rechnern und Rechnerkomponenten.

Begriffsbestimmung (2/2)

Dazu:
- strukturelle
- organisatorische
- implementierungstechnische

Aspekte berücksichtigen und auf der
- globalen Systemebene
- Maschinenbefehlssatzebene
- Mikroarchitekturebene

untersuchen

Zwischen den beteiligten Ebenen und den verschiedenen Teilaspekten der Rechnerarchitektur sind Rückkopplungen möglich.

Auf allen Ebenen umfangreiche Wechselwirkungen mit anderen Disziplinen der
- Informatik,
- Ingenieur- und Naturwissenschaften
- Mathematik

Betrachtungsebenen (1/3)

Verschiedene Betrachtungsebenen

Globale Systemebene (Prozessoren, Busse, Speicher)
- *Für:* System-Architekt für Chip/Motherboard, Vertrieb
- *Sicht auf:* ganzes System
- *Elemente:* Welche Hauptelemente besitzt das System, und wie sind diese miteinander verbunden.

Maschinenbefehlssatzebene
- *Für:* Compilerbauer, Assembler-Programmierer, Vertrieb
- *Sicht auf:* Prozessor-Funktionen
- *Elemente:* Satz von Befehlen (Maschineninstruktionen), den der Prozessor beherrscht.

Betrachtungsebenen (2/3)

Verschiedene Betrachtungsebenen

Register-Transfer-Ebene (Mikroprogramm-Ebene)

- *Für:* CPU-Entwickler, Programmierer, Mikroprogrammierer (Informatik-Grundwissen)
- *Sicht auf:* Infrastruktur auf dem Chip
- *Elemente:* Register; wie diese mit ihrer Umgebung verbunden sind und welche Verknüpfungen vorgesehen sind, um den Befehlssatz zu realisieren.

Betrachtungsebenen (3/3)

Teile der Mikroarchitekturebene

- Logikebene
  - *Für:* Chip-Designer
  - *Sicht auf:* Schaltung
  - *Elemente:* Gatter und Flipflops und wie diese verbunden sind.
- Hardware-Realisierungs-Ebene
  - *Für:* Designer
  - *Sicht auf:* Chiplayout
  - *Elemente:* Bauteile (z.B. Transistoren, Kondensatoren etc.) und wie diese verbunden sind, um Gatter oder Flipflops zu realisieren.

Universalrechner (1/4)

- Bestandteile eines Universalrechners (Computer) nach John v. Neumann

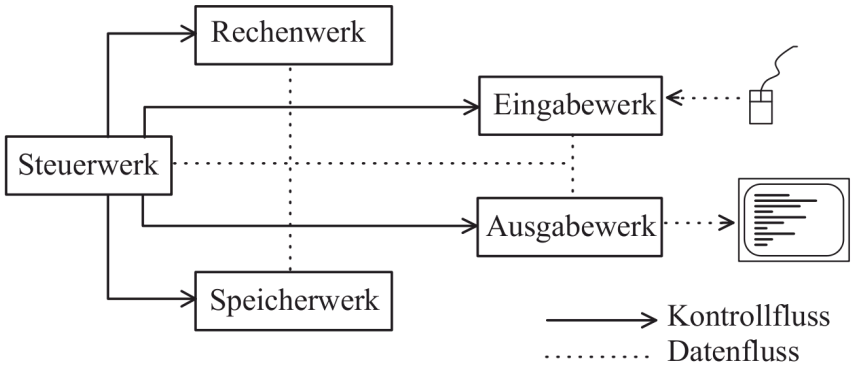

Universalrechner (2/4)

- 5 Funktionseinheiten: Steuerwerk, Rechenwerk, Speicherwerk, Eingabewerk und Ausgabewerk
- Aufbau unabhängig vom zu bearbeitenden Problem
- Programme und Daten, Zwischenergebnisse und Endergebnisse im gleichen Speicher
- Eingabewerk liest Daten und Programm-Code ein und legt sie im Speicherwerk ab.
- Speicher in gleich große Zellen aufgeteilt (fortlaufend nummeriert)
- Aufeinander folgende Befehle befinden sich in aufeinander folgenden Speicherzellen.
- Im Steuerwerk gibt es einen **Befehlszähler**, der immer auf den nächsten auszuführenden Befehl zeigt.

Universalrechner (3/4)

Befehlsausführung

- Der aktuelle Befehl wird aus dem Speicher ausgelesen und im **Befehlsregister** des Steuerwerks zwischengespeichert.
- Der Befehl wird dann dekodiert, und die Ausführung des Befehls durch Steuersignale veranlasst.

Universalrechner (4/4)

- Es gibt folgende Befehlsarten:
  - Arithmetische und logische Befehle zur Verknüpfung von Daten
  - Transportbefehle zum Verschieben von Daten zwischen diesen Komponenten
  - Bedingte und unbedingte Sprungbefehle, Unterprogrammaufrufe
  - Ein-/Ausgabebefehle zur Kommunikation mit der Peripherie
  - Sonstige Befehle wie Unterbrechen, Warten, Stop etc.

Beispiel: Aufbau eines PCs

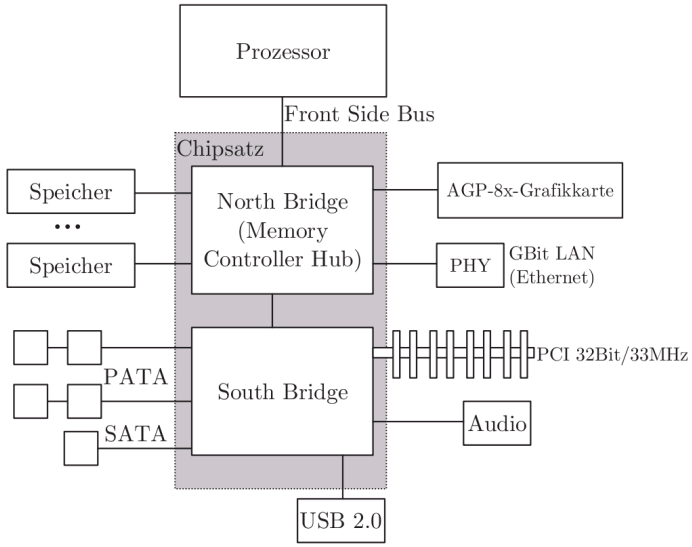

Beispiel: Aufbau der PSP

Höhere Integrationsdichte (→ embedded systems)

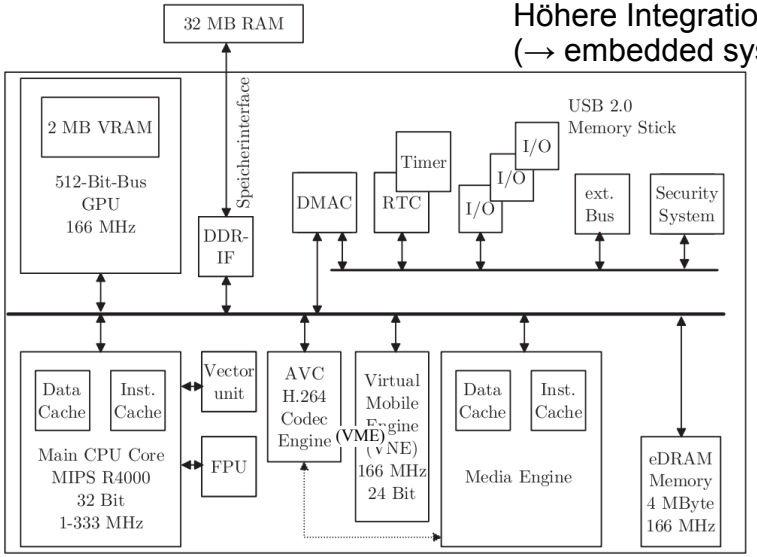

Komplexität von Schaltungen

Chip		Anzahl Transistoren
Flipflop	Speichert ein Bit	6
Gatter (und/oder)	Verknüpft zwei binäre Werte	4
Addierer	Addiert 64-Bit-breite Worte	> 400
Datenpfad	Komplettes Rechenwerk mit Puffern	> 200.000
Pentium II	Ganzer Prozessor	4,5 Millionen
Pentium 4	Ganzer Prozessor	42 Millionen
Xeon-Dunnington	6-Kern-Prozessor	1,9 Milliarden

Landschaft der Prozessoren (Wichtige Begriffe)

- **Hardwarebeschreibungssprachen:**
  Programmiersprachen zur Beschreibung von Hardware. Können verwendet werden, um Hardware zu generieren. Wichtigste Vertreter: VHDL (Very High Speed Integrated Circuit Hardware Description Language) und Verilog. (siehe HP-Forschungsprogramm PICO: „Program In – Chip Out“)
- **Synthetisierbarer Kern:**
  Prozessorkern, der in einer Hardwarebeschreibungs-sprache vorliegt (**Softcore**) und von Lizenznehmern in eigene Entwürfe eingebunden werden kann; z. B.: MIPS32 24K, ARM1136J, Intel XScale 80200T.

Landschaft der Prozessoren (Wichtige Begriffe)

- **System on a Chip (SoC):**
  enthält auf einem einzigen Chip neben dem Prozessorkern auch Speicher, Schnittstellen, Timer und ggf. auch Grafik-, DMA- und Interrupt-Controller sowie PCMCIA, Touch-Panel-Interface etc. (z.B. PowerPC 405LP). Daher kein Chipsatz erforderlich
- **Embedded Systeme** (auch: Prozessrechnersysteme): kleine Computer, die in bestimmten Produkten eingesetzt werden (also **eingebettet** sind). Sie übernehmen dort Steuerungs-, Kontroll- oder Bedienaufgaben. Einsatzgebiete: Haushaltsgeräte, Unterhaltungselektronik, Fahrzeuge, ...

von Neumann vs. Harvard

- Von-Neumann-Architektur

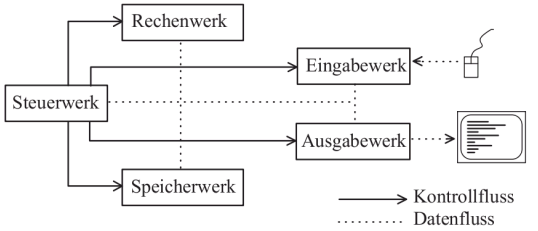

- Harvard-Architektur

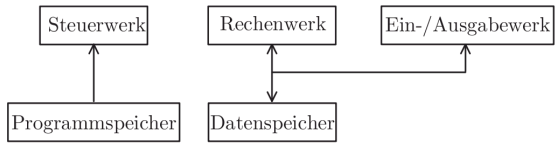

Getrennte Speicher fur Programm und Daten. Anzutreffen bei manchen Signalprozessoren. Als modifizierte Harvard-Architektur in praktisch allen modernen Prozessoren mit getrennten Level-1-Caches fur Code und Daten verwendet

Klassifikation nach Flynn: SISD, SIMD

- Flynn (1966). Heute nicht mehr ganz tragfähig, aber die Begriffe werden noch verwendet.
- Single Instruction, Single Data (**SISD**):

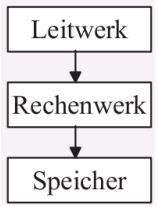

- Single Instruction, Multiple Data (**SIMD**):

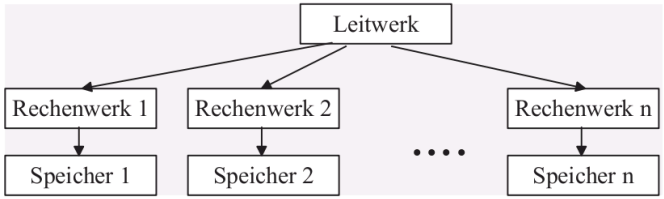

Klassifikation nach Flynn: MIMD, MISD

- Multiple Instruction, Multiple Data (**MIMD**):

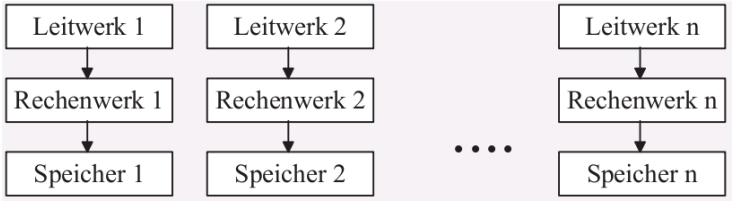

- Multiple Instruction, Single Data (**MISD**):

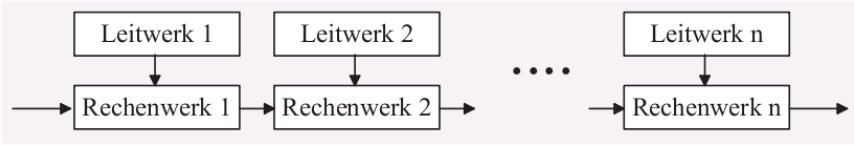

2. ISA: Instruction Set Architecture (Befehlssatzarchitektur)

Befehlssatzarchitektur (Instruction Set Architecture, ISA)

Beschreibung umfasst:

- Maschinenbefehlssatz
- Registerstruktur
- Adressierungsarten
- Interruptbehandlung

Klassisch: Unterscheidung in Ein-, Zwei- und Drei-Adress*maschinen*

Heute üblicher: unterscheiden nach Ein-, Zwei- und Drei-Adress*befehlen*

Register und Registersätze (1/2)

- Register: die schnellsten speichernden Elemente eines Prozessors
- meist allgemein verwendbare Register (General Purpose Registers, GPR) und Spezialregister.
- Gesamtheit aus Befehlssatz und verfügbaren Registern heißt **Programmiermodell**

Register und Registersätze (2/2)

Typische Spezialregister

- Befehlszähler
- Stackpointer
- Statusregister (kann z. B. anzeigen, ob bei der letzten Operation ein Überlauf aufgetreten ist, oder ob das Ergebnis negativ war etc.)
- Indexregister (für Adressrechnungen)

Operanden und Ergebnis (1/6)

- ISAs unterscheiden nach Zugriff auf Register und Speicherinhalte
- Aufgabe: Werte aus zwei Speicherzellen addieren und in dritter Zelle speichern

  C := A + B;

Operanden und Ergebnis (2/6)

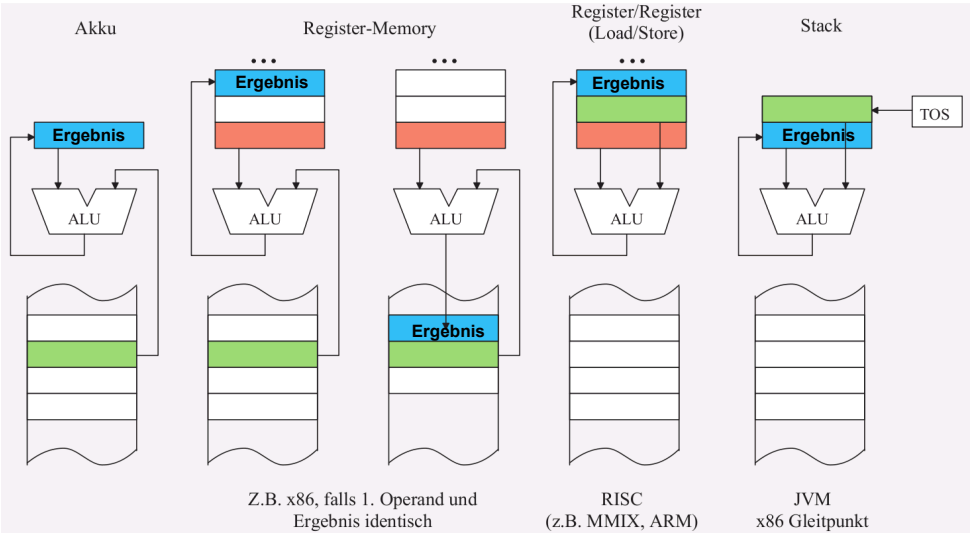

Operanden und Ergebnis (3/6)

C := A + B

mit **Akku**:

```
LOAD  A
ADD   B
STORE C
```

nutzt implizit den Akku:
- LOAD A = lade A in Akku
- ADD B = addiere B zum Wert in Akku (Ergebnis im Akku)
- STORE C = schreibe Akku-Inhalt nach C

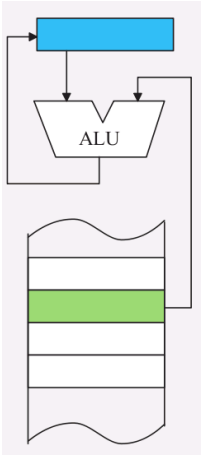

Operanden und Ergebnis (4/6)

C := A + B

mit **Register-Memory**:

```
LOAD  R1,A
ADD   R3,R1,B
STORE R3,C
```

nennt alle Register explizit (R1, R3)
Argumente können Register oder Speicherstellen sein (z. B. R1, B)

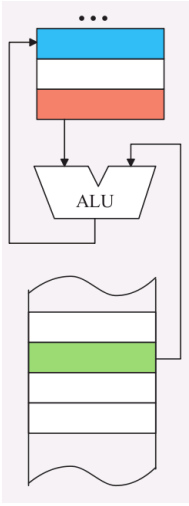

Operanden und Ergebnis (5/6)

C := A + B

mit **Register-Register (Load/Store)**:

```
LOAD  R1,A
LOAD  R2,B
ADD   R3,R1,R2
STORE R3,C
```

- nennt alle Register explizit (R1, R3)
- Argumente für Operationen können nur Register sein (R1, R2)
- Zugriff auf Speicher nur durch LOAD, STORE

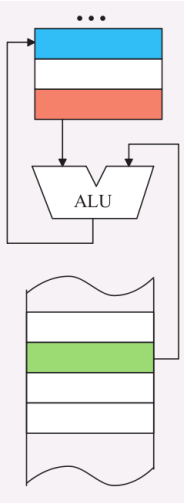

Operanden und Ergebnis (6/6)

C := A + B

mit **Stack**:

```
PUSH A
PUSH B
ADD
POP  C
```

- keine Register
- Argumente auf Stack, dann Operation
- Operation implizit (oberste Werte auf Stack)
- Zugriff auf Speicher nur durch PUSH, POP

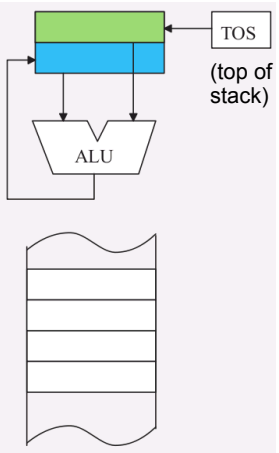

Ein-Adress-Maschinen (1/4)

- Maschinen, deren Befehle nur einen Operanden haben, heißen **Ein-Adress-Maschinen**.
- Akku: spezielles Register, impliziter linker Operand und Zielregister für das Ergebnis („Akkumulatormaschinen“)
- rechter Operand aus Speicher

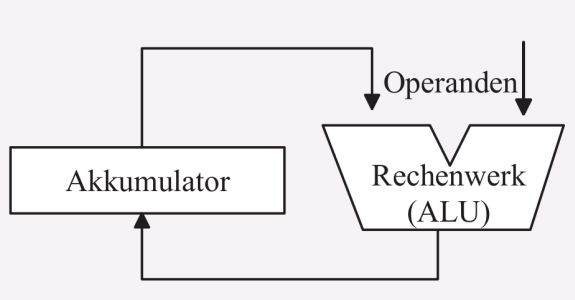

Ein-Adress-Maschinen (2/4)

- **Vorteile**
  - Ausführung der einzelnen Befehle wegen der einfachen Hardware sehr schnell
  - geringer Speicherbedarf für einen Befehl
  - Fast jeder Befehl hat einen Operanden (außer z. B. NOP, INC, DEC) → einheitliche Befehlslänge, einfaches Aktualisieren des Program Counters
- **Nachteile**
  - Programmierung in diesem Format erfordert Übung – vor allem das Auswerten von mathematischen Formeln
  - Programme wegen des häufig erforderlichen Zwischenspeicherns von Hilfsgrößen etwas „länglich“

Ein-Adress-Maschinen (3/4)

- Berechnung der Formel $y = \frac{x_1 + x_2 x_3}{x_1 - x_2}$

mit MMIX (als Ein-Adress-Maschine; $1=Akku)

```
01  x1     OCTA  3
02  x2     OCTA  7
03  x3     OCTA  11
04  Accu   IS    $1
05  Main   LDO   Accu,x2
06         LDO   $2,x3
07         MUL   Accu,Accu,$2
08         LDO   $2,x1
09         ADD   Accu,Accu,$2
10         STO   Accu,x3
11         LDO   Accu,x1
12         LDO   $2,x2
13         SUB   Accu,Accu,$2
14         STO   Accu,x1
15         LDO   Accu,x3
16         LDO   $2,x1
17         DIV   Accu,Accu,$2
18         TRAP  0,Halt,0
```


Ein-Adress-Maschinen (4/4)

- Gleiches Programm in „echter“ Akku-Syntax:

```
01  x1     OCTA  3
02  x2     OCTA  7
03  x3     OCTA  11
04         LOAD  x2      Akku enthält x2
05         MUL   x3      Akku enthält x2*x3
06         ADD   x1      Akku enthält x2*x3+x1
07         STOR  x3      x3 ← x2*x3+x1
08         LOAD  x1      Akku enthält x1
09         SUB   x2      Akku enthält x1-x2
10         STOR  x1      x1 ← x1-x2
11         LOAD  x3      Akku enthält orig. x2*x3+x1
12         DIV   x1      Akku enthält Ergebnis
13         TRAP  Halt...
```

Zwei-Adress-Befehle (1/3)

- Befehle mit zwei Operanden (Register oder Speicheradressen)
- linker Operand ist implizit Ziel:

  `CMD x1,x2` bedeutet $x1 \leftarrow x1 \otimes x2$
- z. B. Addition

  `ADD $1,$2` bedeutet $\$1 \leftarrow \$1 + \$2$
- in MMIX-Syntax:

```
ADD $1,$1,$2
```


Zwei-Adress-Befehle (2/3)

- Wieder mit MMIX-Befehlen

```
01  x1    OCTA  3
02  x2    OCTA  7
03  x3    OCTA  11
04  Main  LDO   $1,x1        Startwerte in $1,
05        LDO   $2,x2        $2,
06        LDO   $3,x3        $3.
07        MUL   $3,$3,$2     Produkt x2*x3 in $3
08        ADD   $3,$3,$1     x1 + x2*x3 in $3
09        SUB   $1,$1,$2     x1-x2 in $1
10        DIV   $3,$3,$1     Bruch in $3, fertig
```


Zwei-Adress-Befehle (3/3)

- und mit „echter“ Zwei-Adress-Syntax

```
01  x1    OCTA  3
02  x2    OCTA  7
03  x3    OCTA  11
04  Main  LDO   $1,x1
05        LDO   $2,x2
06        LDO   $3,x3
07        MUL   $3,$2
08        ADD   $3,$1
09        SUB   $1,$2
10        DIV   $3,$1
```

```
01  x1    OCTA  3
02  x2    OCTA  7
03  x3    OCTA  11
04  Main  LDO   $1,x1
05        LDO   $2,x2
06        LDO   $3,x3
07        MUL   $3,$3,$2
08        ADD   $3,$3,$1
09        SUB   $1,$1,$2
10        DIV   $3,$3,$1
```


Drei-Adress-Befehle (1/2)

- Format von MMIX-Befehlen
- ein Ziel (erster Operand)
- zwei Quellen (2. und 3. Operand)

Beispiel

```
01  x1    OCTA  3
02  x2    OCTA  7
03  x3    OCTA  11
04  Main  LDO   $1,x1
05        LDO   $2,x2
06        LDO   $3,x3
07        SUB   $6,$1,$2
08        MUL   $7,$2,$3
09        ADD   $7,$7,$1
10        DIV   $7,$7,$6
```

Drei-Adress-Befehle (2/2)

- Vorteile
  - bequeme Programmierung
  - kurze Programme (Anzahl der Befehle)
- Nachteil
  - Eine Speicheradresse ist 64 Bit lang
  - drei Operanden (zunächst Register oder Speicheradresse): enorm große Befehlsbreite
    → darum keine Speicheradressen als Operanden

Null-Adress- (Stack-) Maschine

- Operanden der ALU immer oben auf Stack
- keine normalen Register
- Anwendung: Java Byte Code
- Beispiel: Berechne (a-b)*c

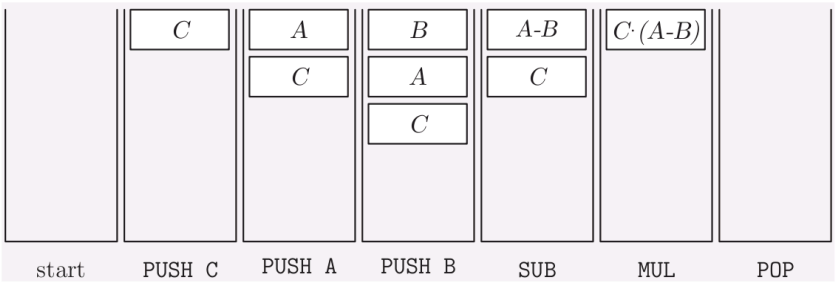

Länge von Befehlen

- flexibel
  - Befehlslänge hängt vom Befehl ab
  - Auslesen komplizierter (erstes Byte entscheidet über Länge), keine Ausrichtung an Wortgrenzen
  - CISC
- fest
  - Alle Befehle gleich lang
  - Leichtes Auslesen
  - Einschränkung: Operanden nur in Registern (nicht genug Platz für Adressangaben)
  - RISC

Platzbedarf

c := a+b; d := a–b; e := c*d – gesucht: nur e = (a+b)(a-b)

Zwei Varianten

- Register-Memory

```
ADD c,a,b       SUB d,a,b       MUL e,c,d
1   4 4 4       1   4 4 4       1   4 4 4
```

S=39

- Register-Register (Load/Store)

```
LD R1,a    LD R2,b    ADD R3,R1,R2    SUB R4,R1,R2
1     4    1     4    2               2

MUL R5,R3,R4    STO R5,e
2               1      4
```

S=21

Pipelining

Pipelining – Ziele

- Wesentliche Begriffe und Fakten über Pipelining kennen
- Vorteile des Pipelining kennen
- Bearbeitung von Sprungbefehlen – Arbeitsschritte für alle Befehle
  - Pipelining Hemmnisse verstehen: Sprünge, Speicherzugriff, Langläufer, Datenabhängigkeiten
- Zusammenhang Arbeitsschritte – Taktrate:
  - Implementierung analysieren können
  - MMIX-Programmstück analysieren und die Ausführung auf einer 5-stufigen Pipeline nachvollziehen können

Einleitung – einfache Pipeline

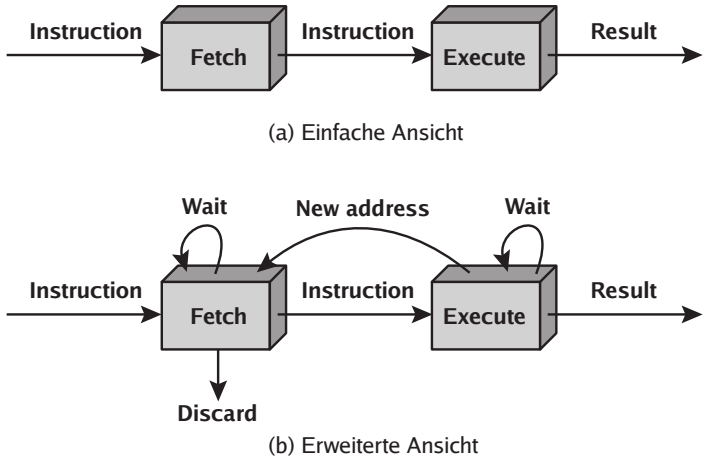

Quelle: Stallings, Computer Organization and Architecture, 8th ed., 2010, S. 463

Instruction Cycle State Diagram

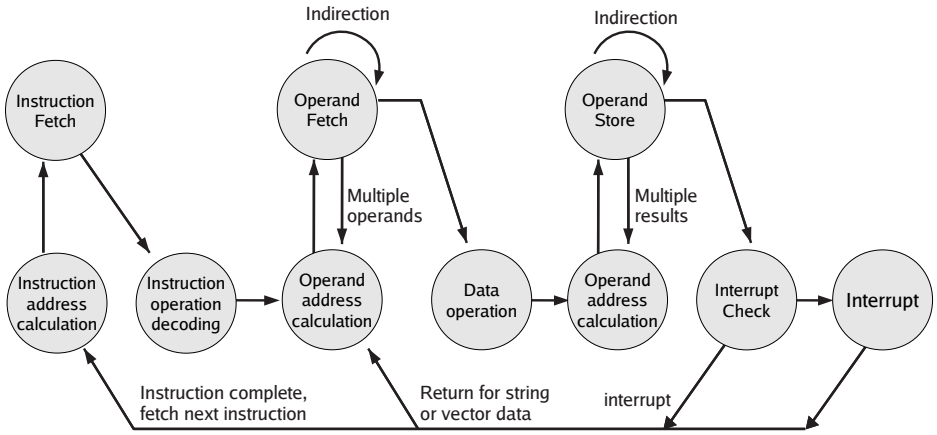

Quelle: Stallings, Computer Organization and Architecture, 8th ed., 2010, S. 460

Pipeline-Designs

- 5-stufige RISC-Pipeline
  - Fetch – Decode – Execute – Memory Access – Write Back
  - siehe auch http://en.wikipedia.org/wiki/Classic_RISC_pipeline
- 6-stufige CISC-Pipeline
  - Fetch Instruction – Decode – Calculate Operands – Fetch Operands – Execute – Write Back
  - siehe Stallings, S. 464

Klassische 5-Stufen-RISC-Pipeline (1/3)

- Holen des Befehls – Fetch (**F**)
  Befehlszähler liefert Adresse für Speicherzugriff und wird (um vier) erhöht.
- Dekodieren des Befehls – Decode (**D**)
  Bei RISC üblicherweise „fixed field decoding“
  - 2 Register-Operanden (OP $X,**$Y,$Z**):
    Bereitstellen der beiden Operanden aus Registern
  - 1 Register-Operand, 1 Direktoperand (OP $X,**$Y,Z**):
    Register $Y auslesen; Z aus Befehlswort
  - Speicherzugriff: Adresse aus Register- und/oder Direktoperand auslesen.
    Bei schreibendem Zugriff: Wert aus $X lesen
  - Sprung: Für Bedingung $X auslesen; Direktoperand aus Befehlswort (für Sprungzielberechnung)

Klassische 5-Stufen-RISC-Pipeline (2/3)

- Ausführen des Befehls – Execute (**X**)
  - Im Befehl spezifizierte ALU-Operation ausführen
  - Bei Speicherzugriff: (ggf.) Adresse berechnen
  - Bei Verzweigungen: Bedingungen prüfen, Adresse des Folgebefehls festlegen
- Speicherzugriff – Memory Access (**M**)
  Lesender oder schreibender Speicherzugriff, falls erforderlich
- Ergebnis zurückschreiben – Result Write-back (**W**)
  Ergebnis einer Operation in ein Register schreiben, falls erforderlich (ALU-Output oder Speicherwort)

Klassische 5-Stufen-RISC-Pipeline (3/3)

MMIX:

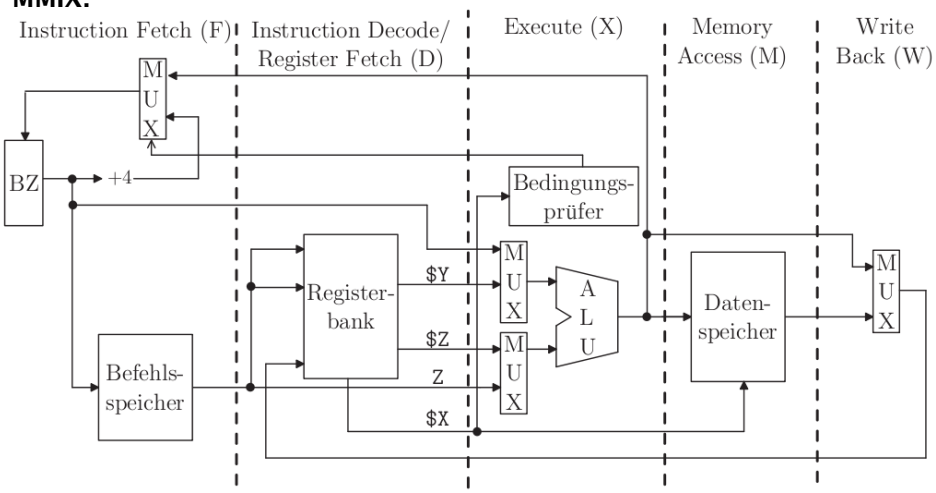

MUX: Multiplexer

6-Stufen-CISC-Pipeline

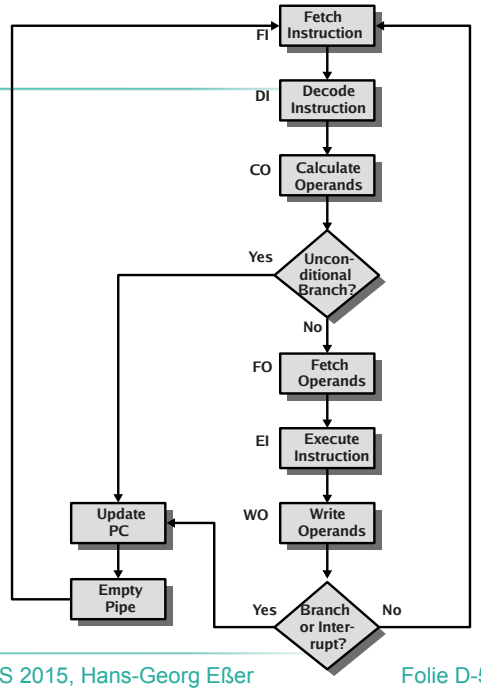

Quelle: Stallings, Computer Organization and Architecture

Takt

- Übergang zwischen Pipeline-Stufen muss getaktet sein
- Bei Übergang Werte-Weitergabe (CPU-interne Pipeline-Register)
- Annahmen:
  - Fetch, Execute, Memory Access: je 2 *t*
  - Decode, Write Back: je *t*
  - Dauer einer Takteinheit hängt von längster Stufe ab, hier also 2 *t*

Ausführung mit und ohne Pipelining

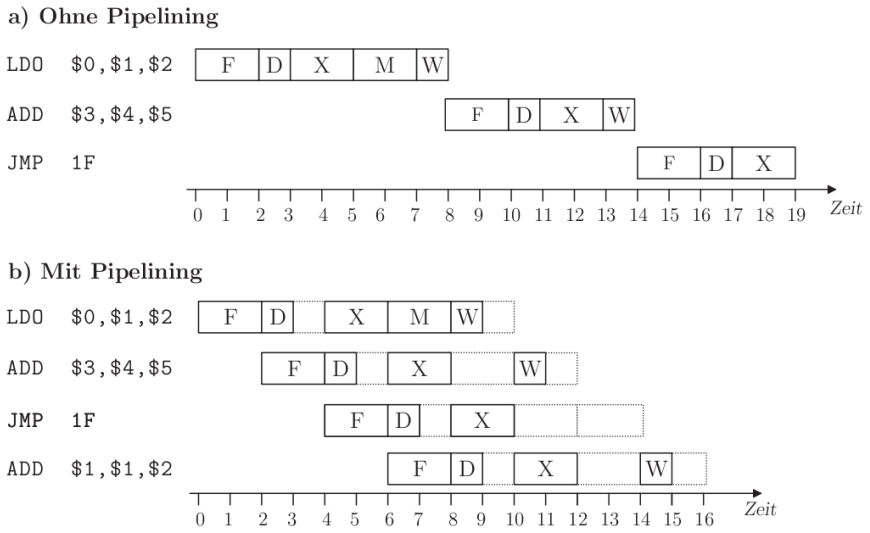

Pipeline-Diagramme („Reservation Tables“)

a) aus Sicht der Stufen

	Takt 1	Takt 2	Takt 3	Takt 4	Takt 5	Takt 6	Takt 7
Fetch	Befehl 1	Befehl 2	Befehl 3	Befehl 4	Befehl 5	Befehl 6	Befehl 7
Decode		Befehl 1	Befehl 2	Befehl 3	Befehl 4	Befehl 5	Befehl 6
Execute			Befehl 1	Befehl 2	Befehl 3	Befehl 4	Befehl 5
Memory				Befehl 1	Befehl 2	Befehl 3	Befehl 4
Write Back					Befehl 1	Befehl 2	Befehl 3

b) aus Sicht der Befehle

	Takt 1	Takt 2	Takt 3	Takt 4	Takt 5	Takt 6	Takt 7
Befehl 1	F	D	X	M	W		
Befehl 2		F	D	X	M	W	
Befehl 3			F	D	X	M	W
Befehl 4				F	D	X	M
Befehl 5					F	D	X

Pipeline-Hemmnisse

- Theoretisch: In jedem Takt ein Befehl fertig
- Praktisch: „Hemmnisse“ („Hazards“) verhindern das:
  - Strukturelle Hemmnisse
  - Datenabhängigkeiten (data hazard)
  - Ablaufbedingte Hemmnisse

Pipeline-Hemmnisse: strukturell (1)

- Nur ein Speicherzugriff pro Takt möglich

	Takt 1	Takt 2	Takt 3	Takt 4	Takt 5	Takt 6	Takt 7
Befehl 1	F	D	X	M	W		
Befehl 2		F	D	X	M	W	
Befehl 3			F	D	X	M	W
Befehl 4				---	---	---	F
Befehl 5					---	---	---

- komplexe Befehle (z. B. Gleitkomma)

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
SETH $3,#4000	F	D	X	M	W									
FMUL $4,$4,$3		F	D	X	X	X	X	M	W					
FADD $4,$4,$2			F	D	--	--	--	X	X	X	X	M	W	
SET $3, $10				F	--	--	--	D	--	--	--	X	M	W

Pipeline-Hemmnisse: strukturell (2)

- Beispiele für Länge der Execute-Phase komplexer Befehle (bei MMIX):
  - Integer-Multiplikation: 10 Takte
  - Integer-Division: 60 Takte
  - Gleitkommabefehle: 4 Takte (i.d.R.)
- Taktrate auf Dauer des längsten Befehls anheben?

Pipeline-Hemmnisse: strukturell (3)

- Lösung für Speicherzugriff: Prefetching
  - In jeder Fetch-Phase mehrere Befehle aus dem RAM lesen und puffern („Fetch Buffer“)
  - z. B. MMIX: Befehlslänge 4 Bytes, eine Leseoperation liefert aber 8 Bytes
  - Ungenutzte Memory-Phasen (Befehle ohne Speicherzugriff) für weitere Fetch-Operationen verwenden
- getrennte Prozessor-Caches für Befehle und Daten (→ Pseudo-Harvard-Architektur)

Pipeline-Hemmnisse: Datenabhängigkeiten (1)

- Data hazards: Befehl benötigt ein Ergebnis, das noch nicht fertig berechnet wurde
- Beispiel: Tausch von zwei Werten (aus Quicksort)

	1	2	3	4	5	6	7
`XOR l,l,r`	F	D	X	M	W		
`XOR r,l,r`		F	D	--	--	X	M
`XOR l,l,r`			F	--	--	D	--
`CMP tmp,l,pivot`				--	--	F	--

(l nicht bekannt)
(r nicht bekannt)

Read-after-Write- (**RAW**-) Konflikt (zweiter Befehl braucht das im ersten berechnete l)

- Lösung: Result Forwarding / Bypassing

Pipeline-Hemmnisse: Datenabhängigkeiten (2)

Result Forwarding / Bypassing

- Ergebnisse von X- und M-Phasen immer als ALU-Input zurückreichen („feed back“)
- Spezielle Steuerlogik: Falls erforderlich, die zurückgereichten Ergebnisse (anstelle der Registerinhalte) verwenden

Pipeline-Hemmnisse: Datenabhängigkeiten (3)

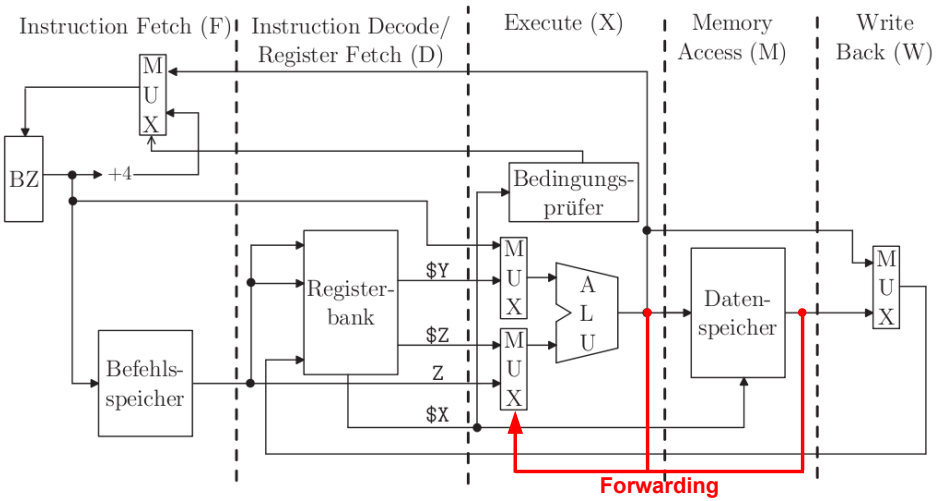

Pipeline-Hemmnisse: Datenabhängigkeiten (4)

- ohne Forwarding

	1	2	3	4	5	6	7
`XOR l,l,r`	F	D	X	M	W		
`XOR r,l,r`		F	D	--	--	X	M
`XOR l,l,r`			F	--	--	D	--
`CMP tmp,l,pivot`				--	--	F	--

(l nicht bekannt)
(r nicht bekannt)

- mit Forwarding

	1	2	3	4	5	6	7
`XOR l,l,r`	F	D	X	M	W		
`XOR r,l,r`		F	D	X	M	W	
`XOR l,l,r`			F	D	X	M	W
`CMP tmp,l,pivot`				F	D	X	M

Pipeline-Hemmnisse: Datenabhängigkeiten (5)

- Result Forwarding hilft nicht immer
  - Lade-Befehle: Erst nach M-Phase steht Ergebnis zur Verfügung

```
                    1  2  3  4  5  6  7
LDO $1,base,off     F  D  X  M  W
ADD $1,$1,$2           F  D  -- X  M  W
SUB $3,$4,$5              F  -- D  X  M
```


Pipeline-Hemmnisse: ablaufbedingt (1)

- bei bedingtem Sprungbefehl: unklar, an welcher Stelle es weiter geht
- Sprungziel steht erst nach Execution-Phase des Sprungbefehls fest
- Frage: Was in die Pipeline schreiben?
  - einfach: Immer davon ausgehen, dass *nicht* gesprungen wird
  - MMIX: „probable branch“ vs. „branch“
  - komplizierter: Sprungvorhersage (eigenes Thema)

Pipeline-Hemmnisse: ablaufbedingt (2)

Beispiel: Berechne $\sum_{i=1}^{9} i$ und $2\sum_{i=1}^{9} i$

```
i       IS $1
sum     IS $2
        SET i,10
        SET sum,0
loop    SUB i,i,1
        ADD sum,sum,i
        BNZ i,loop
cont    STB sum,erg
        ADD $3,sum,sum
        STB $3,erg2
```

```
                1  2  3  4  5  6  7  8  9  10 11 12
SET i,10        F  D  X  M  W
SET sum,0          F  D  X  M  W
SUB i,i,1             F  D  X  M  W
ADD sum,sum,i            F  D  X  M  W
BNZ i,loop               F  D  X  M  W
STB sum,erg                 F  D
ADD $3,sum,sum              F
```

Erst nach Schritt 7 ist klar, dass gesprungen wird

Zwei Stufen der Pipeline löschen

Interrupts (1)

- Auf externe (asynchrone) Interrupts muss die CPU schnell reagieren und in den Interrupt-Handler verzweigen
- Es dürfen keine Befehle unterbrochen werden, die bereits einen Teil der Zustandsänderungen bewirkt haben
- Beispiel: `STB $1, label`
  - nicht zwischen M- und W-Phase unterbrechen!
  - M-Phase: Wert aus $1 in Speicher schreiben
  - W-Phase: Falls Überlauf, Register `rA` (*arithmetic status register*) anpassen

Interrupts (2)

- Darum Befehle in „später“ Pipeline-Phase (X oder M), noch – vor Interrupt-Behandlung – fertig bearbeiten
- Befehle, die gerade erst dekodiert werden, können aber wieder verworfen werden

Superskalare Architekturen

Superskalare Architekturen (1)

- Idee: Parallelisierung durch mehrere (potenziell) parallel arbeitende Ausführungseinheiten (Funktionseinheiten)
- Die Funktionseinheiten können für sich wiederum mehrere Pipelinestufen enthalten
- Der Prozessor „entdeckt“ Möglichkeiten zur Parallelverarbeitung (*impliziter* Parallelismus)

  (*expliziter* Parallelismus: vom Programmierer festgelegt; Intel EPIC: **E**xplicit **P**arallel **I**nstruction **C**omputing; VLIW-Befehle – **V**ery **L**arge **I**nstruction **W**ord)

Superskalare Architekturen (2)

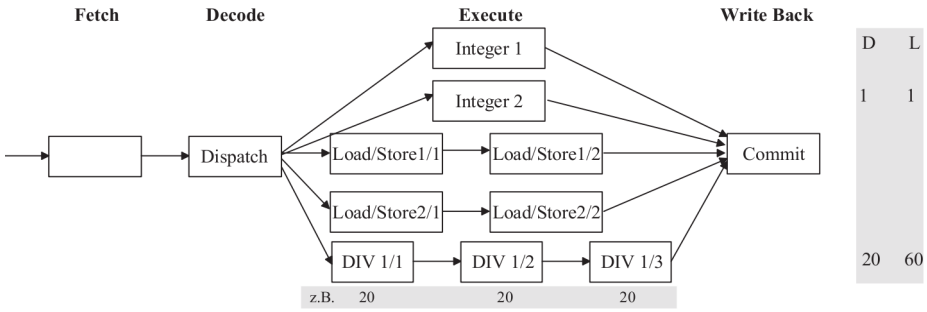

- **Durchsatzzeit** (**D**): Minimaler Abstand zwischen zwei Befehlen, die eine Ausführungseinheit verlassen
- **Latenzzeit** (**L**): Minimale Laufzeit eines Befehls durch eine Ausführungseinheit

Einführendes Beispiel: Parallele Pipelines (1/3)

- abhängige Pipelines
- unabhängige Pipelines

Beispiel: Rechnung aus Mandelbrot-Programm

```
23          FADD   p,p,plow
24          FADD   q,q,qlow
25          SET    xk,0
26          SET    yk,0
27          SET    k,0
28      * Nächste Iteration: x_{k+1} = x_k²–y_k²+p
29      1H  INCL   k,1
```


Einführendes Beispiel: Parallele Pipelines (2/3)

- abhängige Pipelines (z. B. Pentium)
  - Instruktionen müssen synchron durch die Pipelines laufen: gleichzeitiger Wechsel in nächste Stufe
  - Befehle müssen also ggf. „aufeinander warten“
  - Pipelines heißen **U** und **V** (wie bei Pentium)

	1	2	3	4	5	6	7	8	9	Pipeline
FADD q,q,qlow	F	D	X	X	X	X	M	W		**U**
SET xk,0	F	D	X	**	**	**	M	W		**V**
SET yk,0		F	D	**	**	**	X	M	W	**U**
SET k,0		F	D	**	**	**	X	M	W	**V**
INCL k,1			F	**	**	**	D	X	M	**U**

Einführendes Beispiel: Parallele Pipelines (3/3)

- unabhängige Pipelines
  - nicht synchron durch die Stufen; kein Warten
  - mehr „Logistik“ für Steuerung der Stufen nötig

	1	2	3	4	5	6	7	8	Pipeline
FADD q,q,qlow	F	D	X	X	X	X	M	W	**U**
SET xk,0	F	D	X	M	W				**V**
SET yk,0		F	D	**	**	**	X	M	**U**
SET k,0		F	D	X	M	W			**V**
INCL k,1			F	**	**	**	D	X	**U**

- ◯: „**out-of-order completion**“ (Fertigstellung in falscher Reihenfolge)

Out-of-order completion

- Problem: Ergebnis eines späten Befehls vor Fertigstellung eines vorangehenden Befehls verfügbar
- Befehle sind aber voneinander abhängig
- Pipeline muss Befehl evtl. anhalten, bis Ergebnisse aus logisch vorangehenden Befehlen vorliegen
  - kann wieder Result Forwarding verwenden

Parallele Ausführung

- Zwei Pipelines (U, V); abhängig
- Zwei Pipelines; unabhängig
  ⇒ out of order completion
- Superskalare Pipelines allgemein: unabhängig und evtl. mehr als zwei

  ⇒ Es kann (wie bei zwei unabhäng. Pipelines) verschiedene Datenabhängigkeiten geben
- Ziel ist immer: Ergebnis muss identisch mit dem bei sequentieller Ausführung sein

Datenabhängigkeiten (1)

- Keine Abhängigkeit:

```
30    FMUL  temp1,xk,xk      x_k^2
31    FMUL  temp2,yk,yk      y_k^2
```

  (kann man einfach vertauschen)

- **Read-after-Write**-Abhängigkeit (**RAW**):

```
50    ADD   temp2,temp2,bildx
51    STBU  k,    temp1,temp2
```

  tauschen verboten (sonst wird in #51 der Wert an der falschen Adresse `temp1+temp2` gespeichert)

Datenabhängigkeiten (2)

- **Write-after-Read**-Abhängigkeit (**WAR**):

```
35    FMUL  yk,   xk,yk
36    SETH  xk,   #4000       2,0 (Gleitkommawert!)
37    FMUL  yk,   yk,xk       2 * y_k
```

  - #36 muss zwischen #35 und #37 bleiben
  - #35/#36 tauschbar, falls anderes Register verwendet wird
  - auch: **Antidependence**, „falsche“ Abhängigkeit
  - außerdem: **Name Dependence**

Datenabhängigkeiten (3)

- **Write-after-Write**-Abhängigkeit (**WAW**):

```
37    FMUL  yk,   yk,xk     2 * y_k
38    FADD  yk,   yk,q
```

  - Beide Befehle schreiben yk. Würde #38 vor #37 fertiggestellt (Write-Back-Phase), wäre das Ergebnis falsch
  - auch: **Output Dependence**
  - außerdem: **Name Dependence**

Datenabhängigkeiten, Übersicht

RAW	**Read-After-Write** true dependence	Befehl *B* verwendet das Ergebnis von Befehl *A* (Vorgänger). Konflikt, falls Ergebnis noch nicht da
WAR	**Write-After-Read** antidependence (name dependence)	*B* überschreibt Wert, den der Vorgänger *A* benötigt. Konflikt, falls *B* schreibt, bevor *A* liest
WAW	**Write-After-Write** output dependence (name dependence)	*A* und *B* schreiben in dasselbe Register (oder dieselbe Speicherzelle) Konflikt, wenn *B* vor *A* schreibt
RAR	***Read-After-Read***	*A und B lesen denselben Wert; kein Konflikt*

Abhängigkeitsgraph (1)

- Abhängigkeiten grafisch darstellen
  - 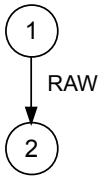

bedeutet eine RAW-Abhängigkeit zwischen Instruktionen 1 und 2, also: (2) liest Wert, den (1) schreibt
- mehrere Abhängigkeiten gleichzeitig: alle angeben (z. B. „RAW, WAW“)
- keine transitiven Abhängigkeiten einzeichnen

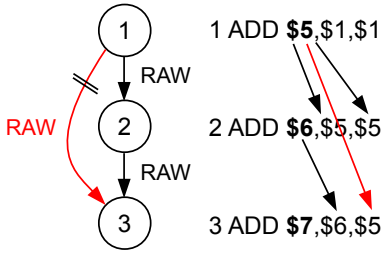

Abhängigkeitsgraph (2)

Auszug aus einem Beispiel-Programm

```
30      FMUL   temp1,xk,xk        x_k^2
31      FMUL   temp2,yk,yk        y_k^2
32      FSUB   temp1,temp1,temp2
33      FADD   temp1,temp1,p       x_k+1
34  * y_k+1=2x_k y_k+q
35      FMUL   yk,    xk,yk
36      SETH   xk,    #4000        2,0 (Gleit-
                                   kommawert!)
37      FMUL   yk,    yk,xk        2 * y_k
38      FADD   yk,    yk,q
39      SET    xk,    temp1        x_k kann über-
                                   schrieben werden
40  * r=x_k+1^2+y_k+1^2
41      FMUL   temp1,xk,xk
42      FMUL   temp2,yk,yk
43      FADD   r,     temp1,temp2
44      FCMP   test,  r,:M
45      BNP           test, 2F
```

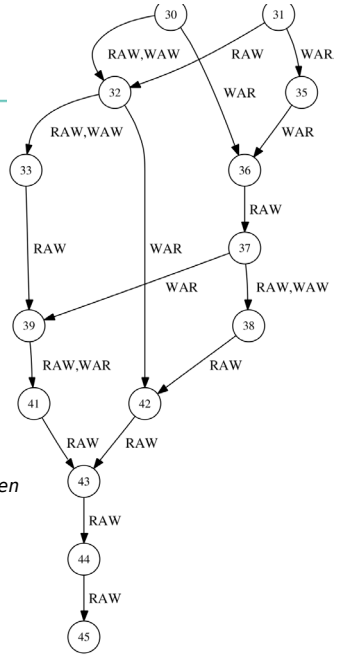

Phasen superskalarer Pipelines

- **Instruction Fetch:** Es steht ein Puffer zur Verfügung (Fetch buffer), in dem mehrere Instruktionen bereit stehen können.
- **Instruction Issue:** Instruktionen werden der Reihe nach (in order) auf freie Ausführungseinheiten (functional units, FUs) verteilt („issued“).

  Dieser Prozess stoppt, falls keine freien FUs vorhanden sind.
- **Read Operands:** Instruktionen warten ggf. auf ihre Operanden (RAW); ab hier ist Überholen möglich.
- **Execute:** out of order (OOO). Instruktionen warten, bis alle WAR-Vorgänger fertig sind.
- **Write Back:** Endgültiges Zurückschreiben in order: Write-after-Write (WAW) beachten. Ergebnisse stehen allerdings schon vorher zur Verfügung (Forwarding).

Reorder Buffer

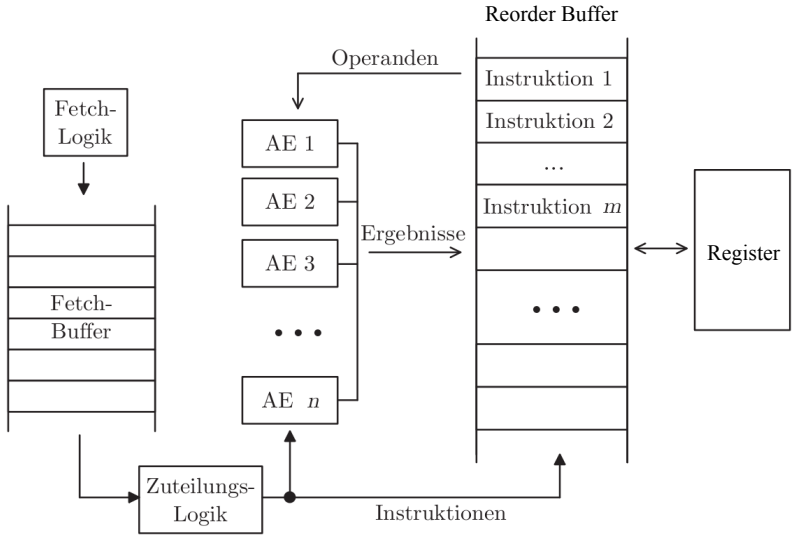

Reorder Buffer

1. Freie Ausführungseinheit suchen.
   Falls verfügbar, durch den Befehl belegen und einen Eintrag im **Reo**rder **B**uffer (**ROB**) anlegen
2. Operanden bereitstellen. Für jeden Operanden den ROB von unten nach oben durchsuchen:
   - Wert aus Register (kein Ergebnis eines Bef. im ROB) *oder*
   - Ergebnis eines vorangehenden (fertigen) Befehls *oder*
   - vorangehenden Befehl beobachten, falls er noch nicht fertig ausgeführt ist (Pause!)
3. Befehl ausführen. Ergebnis im Eintrag des Befehls im ROB vermerken
4. Befehl bestätigen (commit): Ergebnisse in die Register übernehmen

Aufbau des Reorder Buffer

t_0			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
`FMUL yk,yk,xk`	MUL	▶	`$4`	`$3`	—	—	`$4` (ungültig)
`FADD yk,yk,q`	FPU	⏸	—	`$2`	`FMUL`	—	`$4` (ungültig)

```
q  = $2
xk = $3
yk = $4
```

- Befehl
- Unit (welche Ausführungseinheit?)
- Status: ▶ = läuft, ⏸ = Pause, ✔ = fertig
- Operanden: Q_Y, Q_Z: Werte der zwei Operanden, evtl. noch nicht verfügbar
- V_Y, V_Z: ggf. Zeiger auf ROB-Eintrag ⇒ dann Q_Y bzw. Q_Z bereits (im ROB) verfügbar
- Ziel

Beispiel: Reorder Buffer (1)

- wieder unser Beispiel-Programm; diesmal Zeilen 34-41

```
34  * y_{k+1} = 2 x_k y_k + q
35  FMUL yk,xy,yk
36  SETH xk,#4000
37  FMUL yk,yk,xk
38  FADD yk,yk,q
39  SET  xk,temp1
40  * r = x_{k+1}^2 + y_{k+1}^2
41  FMUL temp1,xk,xk
```

das schauen wir uns an ...

Legende

```
q     = $2
xk    = $3
yk    = $4
temp1 = $10
```

Beispiel: Reorder Buffer (2)

- Abhängigkeitsgraph:

```
37  FMUL yk,   yk,xk
38  FADD yk,   yk,q
39  SET  xk,   temp1
40
41  FMUL temp1,xk,xk
```

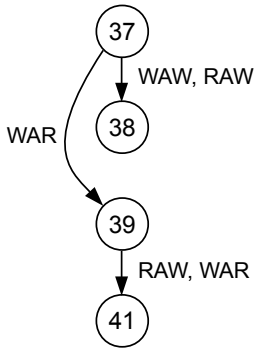

Beispiel: Reorder Buffer (3)

Annahmen:

- 1 FPU (alle Floating-Point-Ops außer FMUL)
- 2 Integer-Einheiten (INT1, INT2), alles außer Multiplikation
- 1 MUL (FP- und Integer-Multiplikation)
- FPU und MUL: je 4 Takte, INT: je 1 Takt
- Reorder Buffer hat Platz für 4 Einträge
- Je Takt max. 2 Befehle zuteilen (issue) und max. 2 Befehle bestätigen (commit)

`q = $2,  xk = $3,  yk = $4,  temp1 = $10` **(4)**

t_0			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
`FMUL yk,yk,xk`	MUL	▶	$4	$3	—	—	$4 (ungültig)
`FADD yk,yk,q`	FPU	❚❚	—	$2	FMUL	—	$4 (ungültig)
—							
—							

t_1			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
`FMUL yk,yk,xk`	MUL	▶	$4	$3	—	—	$4 (ungültig)
`FADD yk,yk,q`	FPU	❚❚	—	$2	FMUL	—	$4 (ungültig)
`SET xk,temp1`	INT1	▶	$10	×	—	—	$3 (ungültig)
—							

t_2 und t_3			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
`FMUL yk,yk,xk`	MUL	▶	$4	$3	—	—	$4 (ungültig)
`FADD yk,yk,q`	FPU	❚❚	—	$2	FMUL	—	$4 (ungültig)
`SET xk,temp1`	—	✔	$10	×	—	—	$3
—							

zu den Taktzeitpunkten t_2 und t_3: **(5)**

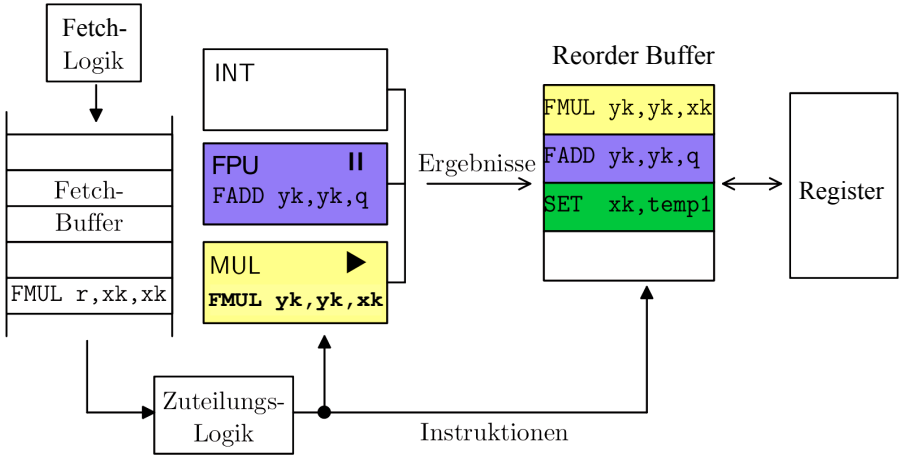

`q = $2,  xk = $3,  yk = $4,  temp1 = $10`

q = $2, xk = $3, yk = $4, temp1 = $10 **(6)**

t_4			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
FMUL yk,yk,xk	—	✔	$4	$3	—	—	$4
FADD yk,yk,q	FPU	▶	$4*	$2	—	—	$4 (ung.)
SET xk,temp1	INT1	✔	$10	×	—	—	$3
FMUL temp1,xk,xk	MUL	▶	$3*	$3*	—	—	—

t_5			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
FADD yk,yk,q	FPU	▶	$4*	$2	—	—	$4 (ung.)
SET xk,temp1	—	✔	$10	×	—	—	$3
FMUL temp1,xk,xk	MUL	▶	$3*	$3*	—	—	$10 (ung.)
—							

*) Wert aus ROB übernommen (Forwarding)

Beispiel: Reorder Buffer (7)

Klassisch:

			0	1	2	3	4	5	6	7	8	
FMUL **yk**, yk,xk	F	D	Xm	Xm	Xm	Xm	W					(Xm: 0-3)
FADD **yk**, yk,q	F	D	-	-	-	-	Xf	Xf	Xf	Xf	W	(Xf: 4-7)
SET **xk**, temp1		F	D	Xi	W							(Xi: 1)
FMUL **temp1**,xk,xk		F	D	-	-	-	Xm	Xm	Xm	Xm	W	(Xm: 4-7)

Leicht geändertes Programm:

			0	1	2	3	4	5	6	7	8		
FMUL **yk**, yk,xk	F	D	Xm	Xm	Xm	Xm	W						(Xm: 0-3)
FADD **yk**, yk,q	F	D	-	-	-	-	Xf	Xf	Xf	Xf	W		(Xf: 4-7)
SET **yk**, temp1		F	D	-	-	-	-	-	-	-	Xi	W	(Xi: 8)
FMUL **temp1**,yk,yk		F	D	-	-	-	-	-	-	-	-	Xm	(Xm: 9-)

Register Renaming (1)

- Jeder Eintrag im Reorder Buffer benötigt Register zum Speichern von Operanden und spekulativen (= noch nicht bestätigten) Ergebnissen.
- Diese heißen **Schattenregister** oder **Rename Registers** (im Unterschied zu den **Befehlssatz-Registern**; **Architectural Registers**)
- *Was* wird denn hier gespeichert?

Register Renaming (2)

- Was im Reorder Buffer steht...

Befehlssatz-Register 0..n

t_0			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
FMUL yk,yk,xk	MUL	▶	$4	$3	—	—	$4 (ungültig)
FADD yk,yk,q	FPU	❚❚	—	$2	FMUL	—	$4 (ungültig)
—							
—							

Register-Nummer (0..n) dito dito (nur Hinweis, wo Ergebnis später hin gehört; sowie Status)

Verweis auf Ergebnis im ROB Reg.-Nr. (0..n) für Ziel, Status **und(!)** Ergebniswert

t_4			Operanden				
Befehl	unit	Status	Q_Y	Q_Z	V_Y	V_Z	Ergebnis
FMUL yk,yk,xk	—	✔	$4	$3	—	—	$4
FADD yk,yk,q	FPU	▶	$4*	$2	—	—	$4 (ung.)
SET xk,temp1	INT1	✔	$10	×	—	—	$3
FMUL temp1,xk,xk	MUL	▶	$3*	$3*	—	—	—

Register Renaming (3)

- Pro „Zeile“ im ROB muss die Ziel-Spalte also Platz bieten für
  - eine Register-Nummer (Zielregister)
  - Status
  - einen berechneten Wert (in „Registergröße“, diese Teile des ROB heißen „Rename-Register“)
- Es ist ökonomisch sinnvoll, lediglich Pointer auf Rename Register in einem Register-Pool (für Zwischenergebnisse) zu speichern.

Register Renaming (4)

Register-Pool:

Wert	frei	gültig
	+	–
	–	+
	–	+
	–	–
	+	–
	–	+
	–	–
	–	+
	+	–
	–	+

Pointer aus ROB-Ziel-Spalte

frei: Eintrag nicht benutzt

gültig: enthält fertig berechneten Wert, kann für weitere Berechnungen genutzt werden

Register Renaming (5)

Implizite Umbenennung

- Zwei getrennte Sätze physischer Register für Befehlssatz-Register und Rename Register
- Es ist nirgends explizit vermerkt, wo sich der jüngste spekulative Wert eines Registers befindet. Finden des Wertes: ROB durchsuchen
  - Neuer Befehl `ADD $1,$3,$3` kommt in den ROB. „Welches“ $3 nehmen? Reg.-Inhalt? ROB-Inhalt? Warten auf Berechnung von $3?
- Das Verwerfen spekulativer Werte (bei Interrupts oder falsch vorhergesagten Sprüngen) ist einfach.

Register Renaming (6)

Implizite Umbenennung

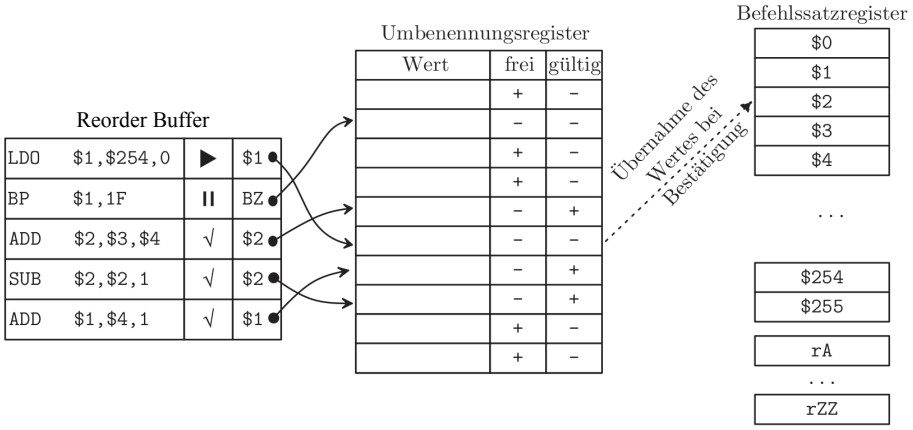

Register Renaming (7)

Explizite Umbenennung

- Es gibt nur einen Register-Pool (gemeinsam für Befehlssatz- und Rename-Register)
- Eine Tabelle gibt an, wo die jüngsten (spekulativsten) Werte der Register stehen
- Kein Umkopieren der Register nach Bestätigen eines Befehls;
  Pointer auf die physischen Register beschreiben Registerzustand

Register Renaming (8)

Explizite Umbenennung

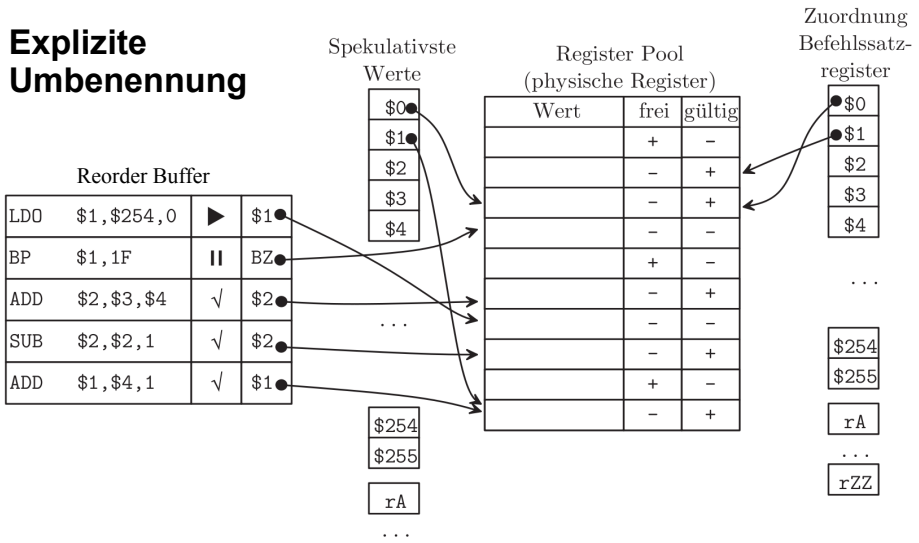

Register Renaming (9)

Datenabhängigkeiten

- **Read-after-Write** (**RAW**):
  führt stets zum Stillstand, bis das Ergebnis zur Verfügung steht.
- **Write-after-Read** (**WAR**) und
  Write-after-Write (**WAW**):
  Schattenregister können Stillstand verhindern (wenn es genügend freie gibt)

Register Renaming (10)

- „Register Renaming“ auch direkt aus dem Wort verständlich:

```
1. R1=M[1024]
2. R1=R1+2
3. M[1032]=R1
4. R1=M[2048]
5. R1=R1+4
6. M[2056]=R1
```

Nach Umbenennen von R1 in R2:

```
1. R1=M[1024]     4. R2=M[2048]
2. R1=R1+2        5. R2=R2+4
3. M[1032]=R1     6. M[2056]=R2
```

WAR-Konflikt zwischen (3) und (4); Befehl (4) darf erst schreiben, wenn (3) fertig ist

„echte“ Pipelines

- echte Beispiel-Architekturen:
  - Pentium Pro: bis zu 16 Stufen
  - PowerPC 970: 16–24 Stufen

Anhang: Mandelbrot-Programm (1/2)

```
01              PREFIX  :Mandel:
02              LOC     #100
03      plow    GREG    #c002000000000000       -0,025
04      pdelta  GREG    #3f83333333333333       0,009375=(0,75- (-2,25))/320
05      qlow    GREG    #bff8000000000000       -1,5
06      qdelta  GREG    #3f8999999999999a       0,0125=(1,5 - (-1,5))/240
07      p       IS      $1
08      q       IS      $2
09      xk      IS      $3                      x_k
10      yk      IS      $4                      y_k
11      k       IS      $5                      Iteration k
12      r       IS      $6
13      bildx   IS      $7                      Gerätekoordinaten (integer)
14      bildy   IS      $8
15      test    IS      $9
16      temp1   IS      $10                     Zwischenergebnisse
17      temp2   IS      $11
18
19      :Mandel FLOT    p,bildx
20              FLOT    q,bildy
21              FMUL    p,p,pdelta
22              FMUL    q,q,qdelta
23              FADD    p,p,plow
24              FADD    q,q,qlow
25              SET     xk,0
26              SET     yk,0
27              SET     k,0
28      * Nächste Iteration: x_{k+1}=x_k^2-y_k^2+p
29      1H      INCL    k,1
30              FMUL    temp1,xk,xk             x_k^2
31              FMUL    temp2,yk,yk             y_k^2
32              FSUB    temp1,temp1,temp2
33              FADD    temp1,temp1,p           x_{k+1}
```

Quelle: Böttcher, „Rechneraufbau und Rechnerarchitektur“

Mehrprozessor- und Multi-Core-Systeme

Ausgangssituation

- Uni-Prozessoren, ohne Pipeline
- Beschleunigen:
  - Prozessortakt (hat Grenzen)
  - Pipelining, skalar und superskalar (hat auch Grenzen)
  - mehr Leistung nur noch durch echte Parallelität erreichbar, also:

    mehr als eine CPU
    → **Multiprozessor- und Multi-Core-Systeme**

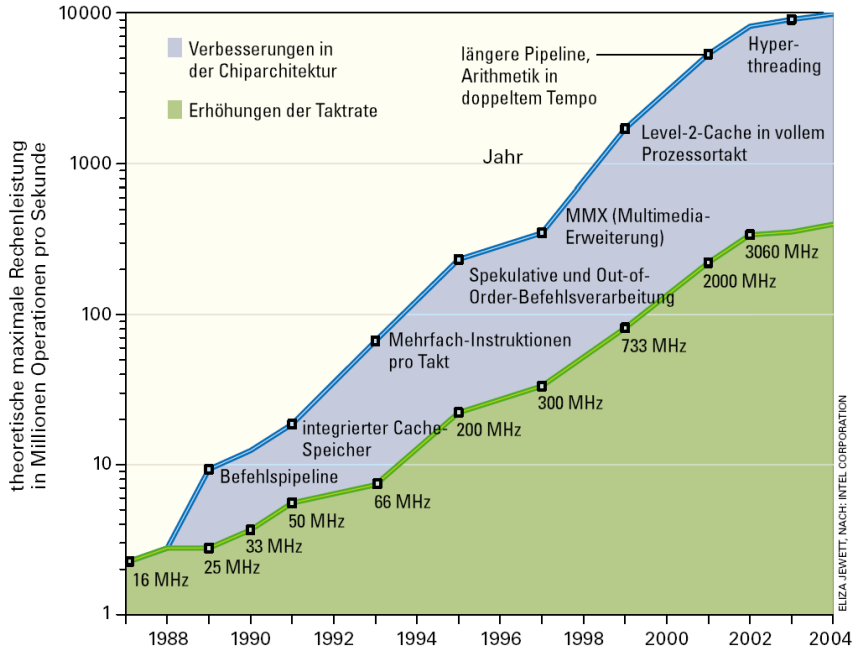

Parallelisierung

- Einfaches Problem: zehn unabhängige Aufgaben parallel bearbeiten
  - z. B.: zehn separate Rechner einsetzen, perfekt parallelisierbar
- Schwierigeres Problem: eine komplexe Aufgabe parallel bearbeiten
  - wie aufteilen? Automatismus?

Parallele Architekturen

- Cluster: mehrere unabhängige Rechner, nur durch Netzwerk verbunden
- Multi-Prozessor: mehrere CPUs auf Hauptplatine
- Multi-Core: mehrere vollwertige CPUs-Kerne in einem CPU-Chip
- Hyper-Threading: mehrere logische CPUs in einem CPU-Chip (auch kombinierbar mit Multi-Core)

Hyper-Threading (HT)

- hardwareseitiges Multithreading (Intel)
- mehrere vollständige Registersätze und ein komplexes Steuerwerk
- parallel arbeitende Pipeline-Stufen (aber genauso viele Ausführungseinheiten wie in „normaler“ CPU)
- aus BS-Sicht: mehrere (virtuelle) CPUs
- mehrere parallele Befehls- und Datenströme (Threads) werden auf diese parallelen Stufen verteilt
- (erhöht die Anzahl *unabhängiger* Instruktionen in der Pipeline)

Multi-Core-System

- mehrere CPUs auf einem Chip
- alles mehrfach vorhanden (außer L2 Cache und höher sowie Bus)
- aus BS-Sicht: mehrere (echte) CPUs
- aktuell üblich: 2-/4-/6-/8-/12-/16-Core
- Beispiele:
  - AMD Opteron 16-Core
  - Intel Tera-Scale, Teraflops Research Chip (Polaris, 80 Cores)

Mehrprozessorsystem

- mehrere CPUs auf einem Mainboard
- weniger effiziente (ältere) Variante von Multi-Core-Systemen
- auch hier aus BS-Sicht: mehrere echte CPUs

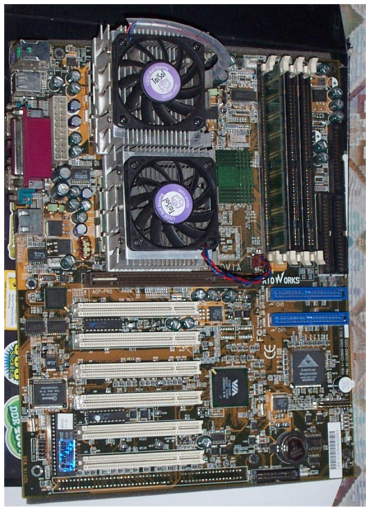

Bild: Wikipedia, http://de.wikipedia.org/wiki/Mehrprozessorsystem

Cluster

- mehrere Rechner mit je einer oder mehreren CPUs
- lokaler Speicher in jedem Rechner
- „lose gekoppeltes System“
- verteilte Anwendungen, die gleichzeitig auf mehreren Rechnern arbeiten
- Austausch zwischen Rechnern über Netzwerk

Cluster: MOSIX

- MOSIX2: http://www.mosix.org/
- Linux-basierter Cluster mit
  - automatischem Load-Balancing
  - Prozess-Migration
  - migrierbare Sockets
  - technisch: Virtualisierungsschicht
- am besten für Anwendungen mit wenig I/O geeignet

Speicher & HT, Multi-Core/-CPU

- Zugriff auf (gemeinsamen!) Hauptspeicher
  - Anbindung an RAM über gemeinsam genutzten Bus
  - Was tun bei parallelen Zugriffen auf den Hauptspeicher?
  - Parallel Write: Wer setzt sich durch?
- Cache
  - interner Cache: was tun, wenn mehrere (echte oder virtuelle) Kerne die gleiche Speicheradresse cachen?
  - Stichworte: Cache-Kohärenz, Cache-Konsistenz

Cache-Hierarchie bei Multi-Core

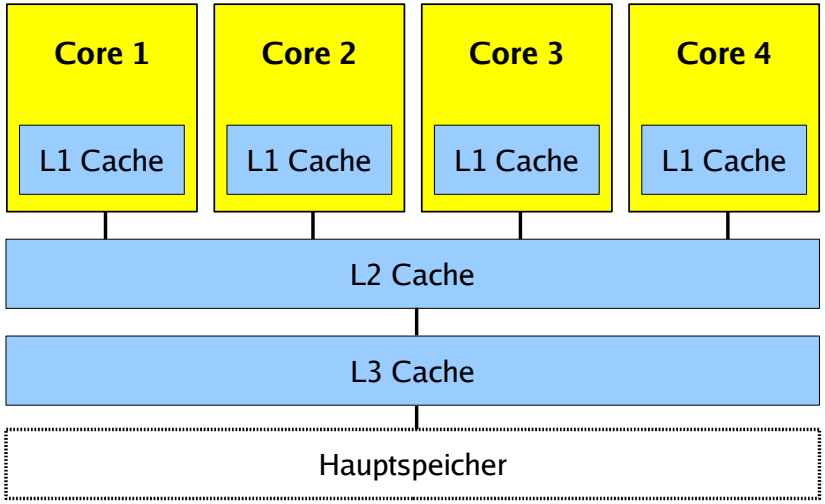

Cache-Kohärenz (1)

- konsistente Daten in allen Caches
- Beispiel:
  - CPU 1 liest Mem[x] und speichert Cache-Line im lokalen CPU-Cache
  - CPU 2 liest auch Mem[x] und speichert Cache-Line im lokalen CPU-Cache
  - CPU 1 schreibt Mem[x] und aktualisiert dabei auch den lokalen Cache
  - CPU 2 liest Mem[x] – was steht im lokalen Cache?

Cache-Kohärenz (2)

- Idee: Zu jedem Zeitpunkt ist ein bestimmter Wert Z für eine Speicherzelle Mem[x] gültig (der zuletzt geschriebene)
- Jeder Prozessor, der Mem[x] liest, sollte Z erhalten
- Unmittelbar nach Schreiben von Mem[x] muss man eine kurze Verzögerung akzeptieren, in der es „unterschiedliche Meinungen“ über Mem[x] gibt

Cache-Kohärenz (3): Protokolle

- Cache-Kohärenz-Protokolle garantieren Kohärenz
- zwei Ansätze
  - Verzeichnis: zentrale Liste mit dem Status aller Cache-Lines (in allen Caches)
    - Liste der CPUs mit Read-only-Kopie (Status *Shared*)
    - CPU mit exklusivem Schreibzugriff (Status *Exclusive*)
  - **Snooping:** Alle Cache Controller lauschen auf Speicherbus und erkennen Schreib- und Lesezugriffe auf Cache-Line, die sie auch speichern

MESI Cache Coherence Protocol (1)

- Ziel: Verwalten, wo der aktuell(st)e Inhalt Mem[x] einer Speicherzelle x zu finden ist
- Für jede Cache-Line vier mögliche Zustände **M**, **E**, **S**, **I**:
  - **Modified:** Cache-Line nur im lokalen Cache, „*dirty*“: wurde verändert → Cache muss Daten ins RAM zurück schreiben, bevor weitere Lesezugriffe auf diese Adresse im RAM erlaubt sind. Nach dem Zurückschreiben Zustandsänderung in **Exclusive.**
  - **Exclusive:** Cache-Line nur im lokalen Cache, „*clean*“: identisch mit RAM. Kann jederzeit in Status **Shared** wechseln, wenn andere CPU den Wert lesen will. Auch Wechsel zu **Modified** möglich, wenn Wert überschrieben wird.

MESI Cache Coherence Protocol (2)

- (vier Zustände...)
  - **Shared:** Diese Cache-Line wird evtl. auch in anderen Caches vorrätig gehalten, „*clean*“: identisch mit RAM. Bei Schreibzugriff müssen alle Kopien (in anderen Caches) auf **Invalid** gesetzt werden.
  - **Invalid:** Diese Cache-Line ist veraltet (der Wert im Hauptspeicher hat sich geändert); nicht benutzen.

Zustandskombinationen (zwei Caches):

(Quelle: http://en.wikipedia.org/wiki/MESI_protocol)

	M	E	S	I
M	✗	✗	✗	✓
E	✗	✗	✗	✓
S	✗	✗	✓	✓
I	✓	✓	✓	✓

MESI Cache Coherence Protocol (3)

- **Lesezugriff:** In allen Zuständen außer **invalid** erlaubt
- **Schreibzugriff:** nur im (lokalen!) Zustand **modified** oder **exclusive** erlaubt –
  Im Zustand **shared** müssen zuerst alle Kopien der Cache-Line auf **invalid** gesetzt werden.

	M	E	S	I
M	✗	✗	✗	✓
E	✗	✗	✗	✓
S	✗	✗	✓	✓
I	✓	✓	✓	✓

Nutzen?

- „Wer“ profitiert von mehreren Kernen/CPUs?
  - Takterhöhung beschleunigt jede Anwendung
  - Pipelining beschleunigt (automatisch) die meisten Anwendungen
  - Einsatz mehrerer Kerne / CPUs / HT:
    - zunächst gar keine Beschleunigung einer einzelnen Applikation
    - schlimmstes Szenario: Ein Kern durch Anwendung belegt, restliche Kerne untätig
    - Betriebssystem und Anwendungen müssen mehrere Kerne unterstützen

Multi-Thread-Support

- BS-Support: Scheduler muss das Verteilen von mehreren Prozessen/Threads auf mehrere Kerne unterstützen
- Anwendungs-Support: Anwendung muss „parallelisiert“ sein, also aus mehreren (relativ) unabhängigen Anwendungssträngen (Threads) bestehen

Typische Anwendungs-Designs (1)

- Master/Worker
  - Ein Master-Thread erhält oder erstellt Aufträge und verteilt diese an ...
  - ... mehrere Worker-Threads: Die rechnen / erledigen je einen konkreten Auftrag, geben das Ergebnis an den Master zurück und beenden sich
  - Beispiel: Apache Webserver

Bild: HP

```
[esser@vserver:~]$ pstree -p|grep apache
init(1)-+-apache2(19459)-+-apache2(1798)
        |                |-apache2(3400)
        |                |-apache2(3976)
        |                |-apache2(3977)
        |                |-apache2(3978)
        |                |-apache2(23603)
        |                |-apache2(26067)
        |                |-apache2(26238)
        |                |-apache2(5995)
        |                `-apache2(16194)
```


Typische Anwendungs-Designs (2)

- Örtliche Parallelisierung
- z. B. Bildverarbeitung:

  - einzelne Teilbereiche separat bearbeiten
  - regelmäßig „Randinformationen“ austauschen

Parallel programmieren (1)

- Threads in Standardsprache (C, C++, ...) von Hand erstellen
- Standardsprache mit Bibliothek um spezielle Parallelisierungsfunktionen erweitern (z. B. OpenMP, siehe https://computing.llnl.gov/tutorials/openMP/)
- spezielle parallele Programmiersprache nutzen
  - Occam, Erlang, Scala, Clojure, Fortress, ...
  - kurze Beschreibungen: z. B. unter http://pvs.uni-muenster.de/pvs/lehre/SS10/seminar/

Parallel programmieren (2)

- Beispiel in der Sprache Fortress:

```
for k<-1:5 do
  print k " "
  print k " "
end
```

erzeugt z. B. 4 1 4 1 5 2 5 2 3 3
und nicht 1 1 2 2 3 3 4 4 5 5

  - For-Schleife **implizit parallel**
  - Während Laufzeit des Programms werden neue Threads erzeugt, die Teile der Schleife berechnen
  - alternativ: neue Threads von Hand starten (für klassisches Modell, manuelle Parallelisierung)

Parallel programmieren (3)

- Klassisch / manuell

```
while (true) {
  req = read_request();          // Warten auf Arbeit
  T = new WorkerThread(req);     // neuen Thread ...
  T.start()                      // ... starten
}

Class WorkerThread extends Thread {
  ...
}
```


Parallel programmieren (4)

- Alternative „gute“ Nutzung eines Mehrkernsystems: Multi-User-Betrieb
- viele Anwender starten eigene Prozesse
- Nichts zu tun: Szenario ist schon parallelisiert

Ergänzende Literatur

- Parallelprogrammierung, in verschiedenen Hardware-Modellen: https://computing.llnl.gov/tutorials/parallel_comp/
- Kapitel 5 (Mehrprozessorsysteme) der Vorlesung Rechnerarchitektur, Univ. Dortmund, SS 2009, http://ls12-www.cs.tu-dortmund.de/de/patrec/teaching/SS09/rechnerarchitektur/

IT-Infrastruktur

SS 2015

Hans-Georg Eßer
Dipl.-Math., Dipl.-Inform.

Foliensatz E: v1.1, 2015/03/05

- Zentrale und verteilte IT-Infrastrukturen
- Zusammenfassung der Vorlesung

Dieser Foliensatz

Vorlesungsübersicht
Seminar
Wiss. Arbeiten
Datenformate und Wandlung
PC als Arbeitsplatz
Ergonomie und Arbeitsschutz
Rechnerstrukturen
Folien E → Zentrale / verteilte IT-Infrastrukturen

Zentrale und verteilte IT-Infrastrukturen

- Parallelität
- Verteilte Systeme
- Client / Server
- Grid
- Cloud
- Virtualisierung

Parallelität (1)

- Cloud-Computing basiert auf Grundlagen in den Bereichen
  - parallele und verteilte Systeme
  - Client/Server, Thin Clients
  - Kommunikationsprotokolle

Parallelität (2)

- Parallele Systeme
  - Probleme lösen, für welche die Ressourcen einer einzelnen Maschine nicht ausreichen
  - Benötigte Zeit für die Problemlösung reduzieren („Speed-up“)
  - Erfolg abhängig vom Anteil α des nicht-parallelisierbaren Codes
  - Amdahls Gesetz (1967):
    Speed-up $S(n) \rightarrow 1 / \alpha$ (für $n \rightarrow \infty$)

    z. B. α = 5 % = 0,05: 1/0,05 = 20 ist max. Speed-up

Parallelität (3)

- Parallele Systeme
  - Beispiel zu Amdahl:

    α = 5 %; Code braucht insgesamt 1000 Zeiteinheiten (ZE), 950 parallelisierbar, 50 sequentiell

n	Par.	Seq.	Summe	Speed-up
1	950	50	1000	1
2	475	50	525	1,90
10	95	50	145	6,90
50	19	50	69	14,49
950	1	50	51	19,6
∞	0	50	50	20,0

Parallelität (4)

- Was verhindert Parallelisierbarkeit?
  - Zwei Ereignisse sind nebenläufig, wenn keines die Ursache des anderen ist.
  - Datenabhängigkeit: z. B. RAW-Konflikt (vgl. Pipelines)
- Was verlangsamt parallele Threads?
  - Synchronisation (Mutex, Semaphore, Barrieren, Inter-Thread-Kommunikation)

Parallelität (5)

- Arten der Parallelität
  - **Bit-Level-Parallelität:** Zahl der Bits, die eine CPU-Instruktion bearbeitet (entspricht i.d.R. der Breite der Register)
  - **Instruction-Level-Parallelität:** Pipelining
  - **Daten-/Schleifen-Parallelität:** Schleifen können parallel bearbeitet werden
  - **Task-Parallelität:** Programm in unabhängige Threads aufteilen

Verteilte Systeme (1)

- Verteiltes System:
  - Zusammenschluss mehrerer Computer, auch mit unterschiedlicher Architektur
  - präsentiert sich gegenüber Nutzer als ein System
  - Komponenten arbeiten autonom, auch bzgl. Scheduling und Ressourcen-Verwaltung
  - ist durch Hinzufügen weiterer Rechner skalierbar
  - kein gemeinsamer Speicher, darum Synchronisation nur durch Nachrichtenversand möglich

Verteilte Systeme (2)

- Beispiele:
  - P2P-Netze (z. B. für Filesharing)
  - Verteiltes Dateisystem (z. B. IBM GPFS, Google Filesystem)
  - HPC, inkl. Cluster- und Grid-Computing, auch Seti@Home u. ä.

Client / Server (1)

- Server und Client sind Prozesse, die auf derselben Maschine oder auf verschiedenen, übers Netz verbundenen Rechnern laufen
- Server bietet eine Dienstleistung
- Clients können diese nutzen, indem sie eine Anfrage an den Server schicken
- wahlweise verbindungsbasiert (z. B. TCP) oder verbindungslos (z. B. UDP)
- Thin Client: nutzt überwiegend Dienste eines oder mehrerer Server

Client / Server (2)

- Client / Server-Beispiele:
  - WWW (HTTP, HTTPS)
  - FTP
  - Datenbank
  - Authentifikation

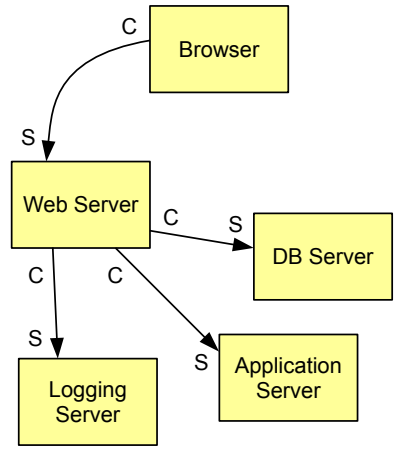

Client / Server (3)

- Remote Procedure Call (RPC)
  - Server erlaubt den Aufruf von Programm-Prozeduren (Funktionen) durch Clients
  - Aufruf (und Ergebnisrückgabe) durch Message Passing
  - Problem: Client und Server können verschiedene Architektur haben → andere Art der Datenablage (z. B. Little-Endian/Big-Endian, verschiedene Kodierungen für Strings)
  - **Marshalling** / **Serialisieren**: Packen der Prozedur-Argumente in ein universelles Format (Unmarshalling: auspacken)

Client / Server (4)

- RPC-Beispiele
  - Sun RPC (heute: Open Network Computing RPC)
    - Dienste über einen Portmapper registrieren, der auf Port 111 Anfragen annimmt
    - unterstützt Authentifikation
    - serialisiert Daten mit XDR (External Data Representation) → nächste Folie
    - z. B. NFS (Network File System) nutzt Sun RPC
  - XML-RPC
  - Web Services Description Language (WSDL), SOAP (Nachfolger von XML-RPC)

XDR-Beispiel: Datei-Versand

```
const MAXUSERNAME = 32;    /* Länge username  */
const MAXFILELEN = 65535; /* max. Dateigröße */
const MAXNAMELEN = 255;    /* Länge Dateiname */

/* Dateitypen: */
enum filekind {
   TEXT = 0,       /* ASCII-Text        */
   DATA = 1,       /* Binäre Daten      */
   EXEC = 2        /* ausführbare Datei */
};

/* Datei-Informationen: */
union filetype switch (filekind kind) {
case TEXT:
   void;
case DATA:
   /* Ersteller */
   string creator<MAXNAMELEN>;
case EXEC:
   /* Interpreter */
   string interpretor<MAXNAMELEN>;
};

/* komplette Datei: */
struct file {
   string filename<MAXNAMELEN>; /* Name     */
   filetype type;               /* Infos    */
   string owner<MAXUSERNAME>;   /* Besitzer */
   opaque data<MAXFILELEN>;     /* Inhalt   */
};
```

Beispiel:

Versand einer Lisp-Datei „sillyprog“ mit Inhalt „(quit)“

Pos.	Hex	ASCII	Kommentare
0	00 00 00 09	....	Länge Dateiname = 9
4	73 69 6c 6c	sill	Dateiname
8	79 70 72 6f	ypro	...
12	67 00 00 00	g...	... (und 3 Füller-Bytes)
16	00 00 00 02	....	Dateityp 2 (EXEC)
20	00 00 00 04	....	Interpreter-Länge 4
24	6c 69 73 70	lisp	Interpreter-Name
28	00 00 00 04	....	Besitzer-Länge 4
32	6a 6f 68 6e	john	Besitzer
36	00 00 00 06	....	Dateigröße = 6
40	28 71 75 69	(qui	Dateiinhalt
44	74 29 00 00	t)..	... (und 2 Füller-Bytes)

Quelle: http://tools.ietf.org/html/rfc1014

Vorteile Client/Server / RPC

- klare Trennung der Aufgaben
- Kommunikation über definiertes Protokoll
- leichter Austausch des Servers (oder des Clients)
- wenn komplexe (aufwendige) Aufgaben von Servern erledigt werden, kann Client klein sein (→ Thin Client)
- Server kann auch ein **Reverse Proxy** sein und Anfragen an einen Server weiterleiten

Reverse Proxy

- Lastverteilung
- Puffern / Cachen der Antworten auf wiederholte Anfragen

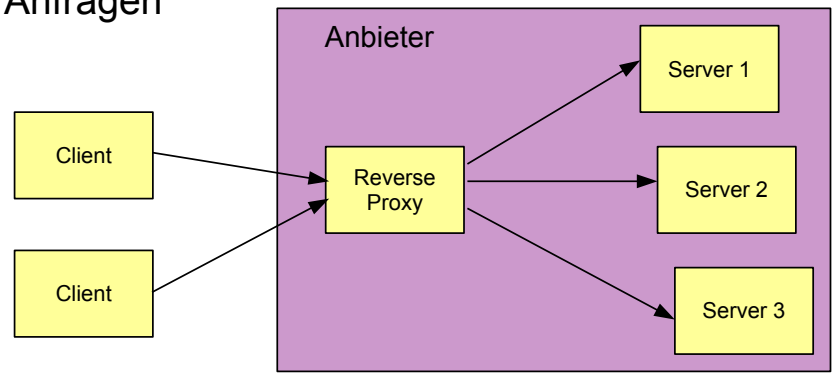

RPC-Anwendung

- Aufruf von RPC-Prozeduren kann wie Aufruf lokaler Funktionen arbeiten
- normales Verhalten: blockierend (wie Funktionsaufruf)
- Alternative: Asynchronous RPC
  - Zugriff auf langsame / überlastete Server → nicht warten, bis Ergebnis da ist
  - Transfer großer Datenmengen
  - Rückgabewert muss dann (später) separat abgefragt werden → Callback

Asynchronous RPC

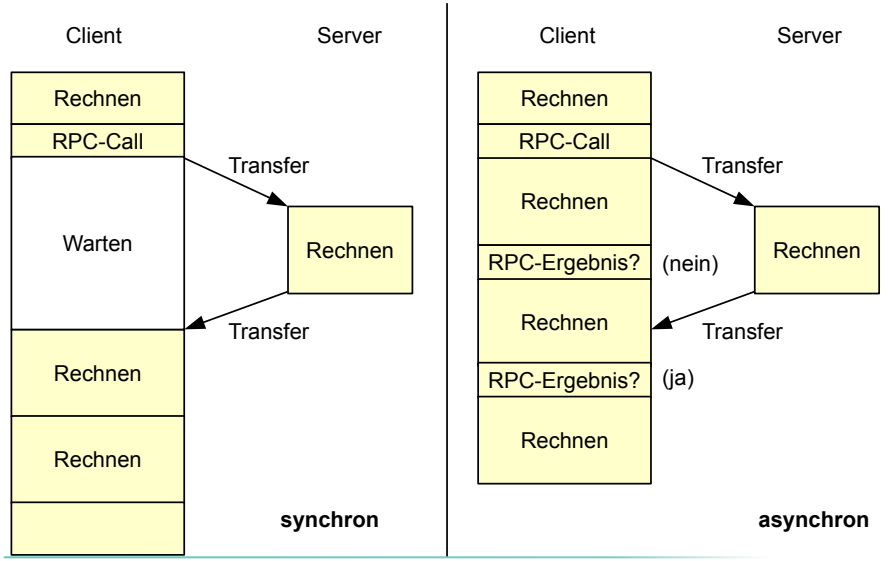

Cluster / Super-Computer (1)

- Super-Computer
  - zahlreiche (tausende) CPUs
  - gemeinsamer Speicher oder separater Speicher je CPU (→ Message Passing)
  - Plattform für High Performance Computing (HPC)
- Cluster
  - zahlreiche separate Rechner, typischerweise mit identischer Hardware
  - verbunden durch spezielles schnelles Netzwerk
  - Kooperation via Message Passing

Cluster / Super-Computer (2)

- Message Passing mit MPI
  - MPI-Standard (Message Passing Interface)
  - wird in parallelen Programmen zur Aufteilung der Arbeit verwendet
  - typische Operationen:
    - **Send** (an einzelnen) und **Recv** (von einzelnen)
    - **Broadcast** (Nachricht an alle)
    - **Gather** (Daten von allen Prozessen erhalten; entspricht *n* mal Recv) und **Reduce** (z. B. Summe der Werte von allen *n* Prozessen erhalten)
    - **Barrier** (Schranke, die alle Prozesse erreichen müssen)

MPI-Beispiel

```
int main(int argc, char *argv[]) {
  char idstr[32]; char buff[BUFSIZE];
  int numprocs; int myid; int i;
  MPI_Status stat;
  MPI_Init(&argc,&argv);
  MPI_Comm_size(MPI_COMM_WORLD,&numprocs);  // wie viele?
  MPI_Comm_rank(MPI_COMM_WORLD,&myid);      // wer bin ich?
  if(myid == 0) {  // Master (Rank 0)
    printf("%d: We have %d processors\n", myid, numprocs);
    for (i=1; i<numprocs; i++) {
      sprintf(buff, "Hello %d! ", i);
      MPI_Send(buff, BUFSIZE, MPI_CHAR, i, TAG, MPI_COMM_WORLD);
    }
    for (i=1; i<numprocs; i++) {
      MPI_Recv(buff, BUFSIZE, MPI_CHAR, i, TAG, MPI_COMM_WORLD, &stat);
      printf("%d: %s\n", myid, buff);
    }
  } else {         // Slave (Rank != 0)
    // Nachricht von Prozess 0 empfangen
    MPI_Recv(buff, BUFSIZE, MPI_CHAR, 0, TAG, MPI_COMM_WORLD, &stat);
    sprintf(idstr, "Processor %d ", myid);
    strncat(buff, idstr, BUFSIZE-1);
    strncat(buff, "active", BUFSIZE-1);
    // Nachricht an Prozess 0 senden
    MPI_Send(buff, BUFSIZE, MPI_CHAR, 0, TAG, MPI_COMM_WORLD);
  }
  MPI_Finalize(); return 0;
}
```

```
$ gcc -lmpi mpitest.c
$ mpirun -n 8 ./a.out
0: We have 8 processors
0: Hello 1! Processor 1 active
0: Hello 2! Processor 2 active
0: Hello 3! Processor 3 active
0: Hello 4! Processor 4 active
0: Hello 5! Processor 5 active
0: Hello 6! Processor 6 active
0: Hello 7! Processor 7 active
```

Quelle: http://en.wikipedia.org/wiki/Message_Passing_Interface#Example_program, leicht verändert

Grid Computing (1)

- Idee auch beim Grid: Lösung einer Aufgabe auf mehrere Maschinen verteilen
- Funktion: ähnlich wie Cluster, aber
  - zum Grid gehörende Rechner sind räumlich weit entfernt (keine schnelle Verbindung)
  - Rechner haben verschiedene Architektur und Hardware-Ausstattung
  - schlecht für Aufgaben, die viel Kommunikation der beteiligten Prozesse benötigen
  - schlecht, wenn parallele Anwendung voraussetzt, dass alle Nodes in etwa gleich schnell arbeiten
  - Normalfall: völlig unabhängige Prozesse

Grid Computing (2)

- „Shared Computing“: Idle-Zeiten (ungenutzte Ressourcen) nutzen
  - SETI@Home
  - kryptographische Verfahren brechen (→ z. B. RSA Secret-Key Challenge)
  - BOINC (Berkeley Open Infrastructure for Network Computing), Projekte: siehe http://boincstats.com/en/stats/projectStatsInfo
  - Auswertung riesiger Datenmengen, die nicht realistisch von Einzelnpersonen oder Unternehmen verarbeitbar sind

Grid Computing (3)

- Beteiligung an Shared-Computing-Projekten
  - Account anlegen
  - Client installieren und laufen lassen
  - bei Interesse Statistik über eigenen Beitrag abrufen
- Grid Computing (und auch Cluster / Super-computer) eher im wissenschaftlichen Umfeld relevant
- Kommerzielle Bedeutung von parallelen Systemen erst durch Cloud Computing

Cloud Computing (Überblick, 1)

- erste Umsetzung verteilter Systeme mit starker kommerzieller Bedeutung
- Anbieter u. a. Amazon, Google, Oracle, SAP, Microsoft, Dropbox … (Liste der Top-100-Cloud-Provider: http://talkincloud.com/tc100)
- drei sehr unterschiedliche Angebotsvarianten:
  - Software as a Service (SaaS)
  - Platform as a Service (PaaS)
  - Infrastructure as a Service (IaaS)

Cloud Computing (Überblick, 2)

- Clouds bieten *skalierbare* und *elastische* Services
  - *skalierbar*: tatsächlich genutzte Ressourcen vom Anwender konfigurierbar
  - *elastisch*: Überwachung der Nutzung; je nach Bedarf wird Rechenleistung, Plattenplatz, Netzwerk-Bandbreite automatisch angepasst
- Messbarer Ressourcenverbrauch → individuelle Gebühren entsprechen der Nutzung
- Cloud-Provider übernehmen Verwaltung und Sicherheit
- zentralisierte Cloud-Rechnerfarmen

Cloud Computing (Überblick, 3)

- Cloud-Anbieter setzen **Virtualisierung** ein und profitieren dadurch von der Lastverteilung (nicht alle Instanzen arbeiten ständig mit Höchstlast)
- geringere Kosten für RZ-Betrieb können an Cloud-Anwender weitergegeben werden
- Daten werden in der Nähe der Rechner vorgehalten, die sie verwenden

Cloud Computing (Überblick, 4)

- Cloud-Arten
  - **Public Cloud:** Infrastruktur gehört einem Cloud-Anbieter, Anwender greifen über das Internet darauf zu. Keine Einschränkung der Benutzergruppe
  - **Private Cloud:** Infrastruktur wird von/für ein einzelnes Unternehmen betrieben
  - **Community Cloud:** ähnlich Public Cloud, aber mit eingeschränkter Benutzergruppe, z. B. nur Krankenhäuser, öffentliche Verwaltungen etc.
  - **Hybrid Cloud:** Kooperation mehrerer Clouds (public, private, community) mit Schnittstellen

Cloud Computing (Überblick, 5)

- Vorteile beim Cloud-Einsatz (für Anwender):
  - keine Anfangsinvestition für eigenes RZ
  - „pay as you go“
  - Elastizität: Leistungen können mit wachsender Benutzergruppe dynamisch mitwachsen; in Zeiten der Nicht-Nutzung keine Kosten
  - Virtualisierung lässt Benutzer (bei IaaS) mit gewohnten Umgebungen arbeiten

Cloud Computing (Überblick, 6)

- Clouds erfolgreicher als Grid, Cluster etc.:
  - Fokus auf Enterprise Computing, nicht wissenschaftliches Rechnen (HPC)
  - Homogene Hardware (anders als beim Grid)
  - Standard-Hardware (anders als beim Supercomputer)
  - Alle Hardware unter einheitlicher Kontrolle des Cloud-Anbieters → Sicherheit, Fehlertoleranz, Quality of Service: leichter umsetzbar

Cloud Computing (Überblick, 7)

- Software as a Service
  - Service Provider stellt Anwendungen zur Verfügung
  - Benutzer verwaltet *nicht* die zugrundeliegende Cloud-Infrastruktur oder Anwendungseinstellungen
  - Services:
    - Enterprise services: workflow management, groupware and collaborative, supply chain, communications, digital signature, customer relationship management (CRM), desktop software, financial management, geo-spatial, search.
    - Web 2.0 applications: metadata management, social networking, blogs, wiki services, portal services.

Cloud Computing (Überblick, 8)

- Software as a Service
  - ungeeignet, wenn Daten nicht extern gehostet werden dürfen
  - Beispiele: GMail, Google-Suchmaschine

Cloud Computing (Überblick, 9)

- Platform as a Service
  - Service Provider stellt Plattform zur Verfügung, auf der vom Anwender entwickelte Anwendungen laufen
  - Programmiersprachen und Tools vom Provider vorgegeben
  - Benutzer verwaltet *nicht* die zugrundeliegende Cloud-Infrastruktur (wie etwa Betriebssystem, Netzwerk-Konfiguration etc.)

Cloud Computing (Überblick, 10)

- Platform as a Service
  - ungeeignet, wenn Optimierung der „Hardware“ und Software nötig ist oder spezielle (proprietäre) Programmiersprachen verwendet werden
  - Beispiele: Microsoft's Windows Azure (PaaS und IaaS), Google App Engine

Cloud Computing (Überblick, 11)

- Infrastructure as a Service
  - Benutzer können beliebige Software ausführen, darunter auch (weitgehend) beliebige Betriebssysteme
  - Benutzer kontrolliert *nicht* die Cloud-Infrastruktur, *aber* die in seinen VMs laufenden Betriebssysteme, Netzwerk- und Firewall-Einstellungen, Software und deren Konfiguration

Cloud Computing (Überblick, 12)

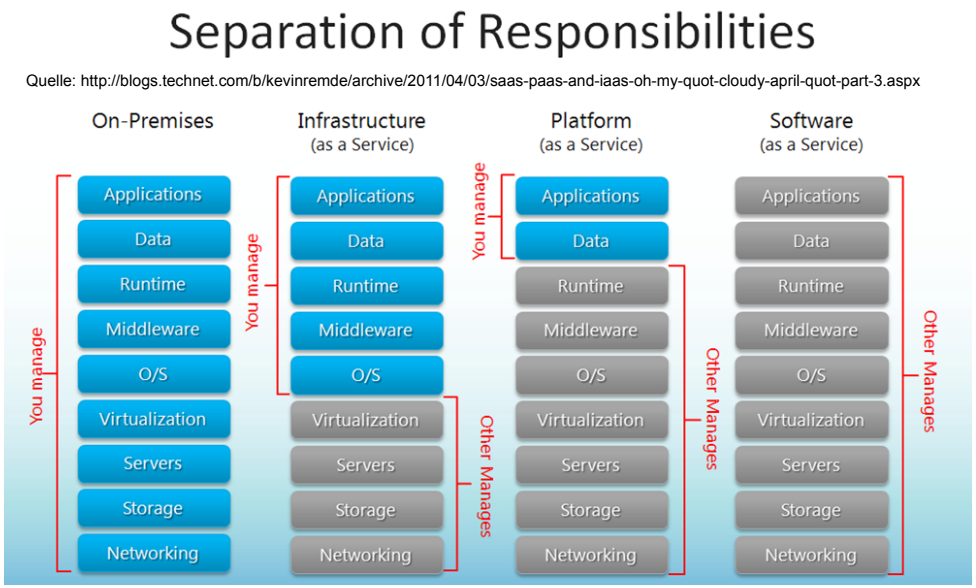

Cloud Computing (Überblick, 13)

- Gründe für den Einsatz von Public Clouds:

Reason	Percentage who agree
Improved system reliability and availability	50%
Pay only for what you use	50%
Hardware savings	47%
Software license saving	46%
Lower labor costs	44%
Lower maintenance costs	42%
Reduced IT support needs	40%
Ability to take advantage of the latest functionality	40%
Less pressure on internal resources	39%
Solve problems related to updating/upgrading	39%
Rapid deployment	39%
Ability to scale up resources to meet the needs	39%
Ability to focus on core competencies	38%
Take advantage of the improved economics of scale	37%
Reduced infrastructure management needs	37%
Lower energy costs	29%
Reduced space requirements	26%
Create new revenue streams	23%

Ausblick

- Nächster Termin:
  - technische Grundlagen der Clouds
  - ausgewählte Beispiele
  - Sicherheit in der Cloud
  - Entwickeln von Cloud-Anwendungen (nur ein grober Überblick)

Cloud: Technische Details

- Verteilte Konfiguration mit ZooKeeper
- Software-Entwicklung mit MapReduce
- Verteilte Dateisysteme

22.01.2015: ab hier neue Folien

ZooKeeper (1)

- Verteiltes Repository von Konfigurationsdaten
- Beispiel: elastische HTTP/DB-Umgebung

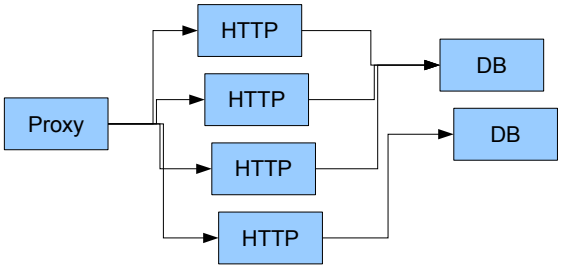

ZooKeeper (2)

- Elastisch: neue VM mit HTTP/DB starten

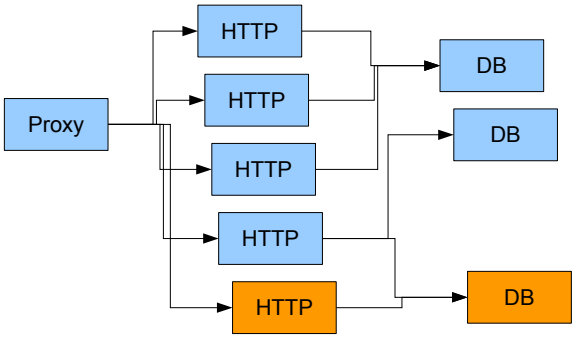

- Proxy/HTTPs müssen neue Server kennen

ZooKeeper (3)

- ZooKeeper verwaltet eine Art Verzeichnisbaum

```
/
/config
/config/http-servers
/config/http-servers/http1
/config/http-servers/http2
/config/http-servers/http3
/config/http-servers/http4
/config/db-servers
/config/db-servers/db1
/config/db-servers/db2
```

speichern u.a.
– IP-Adresse
– Versionsinformation

dito

- neue Server tragen sich hier ein
- Proxy und HTTPs fragen Informationen ab

ZooKeeper (4)

- Load-Verwaltung bemerkt wachsende Last
  - neue VM mit HTTP und DB starten
  - VM im ZooKeeper registrieren
  - Wegen *WATCH* werden Proxy und HTTPs benachrichtigt

→

```
/
/config
/config/http-servers
/config/http-servers/http1
/config/http-servers/http2
/config/http-servers/http3
/config/http-servers/http4
/config/http-servers/http5
/config/db-servers
/config/db-servers/db1
/config/db-servers/db2
/config/db-servers/db3
```

ZooKeeper (5)

- Zwei DB-Server wollen gleichzeitig einen Datensatz ändern → Locking!
  - ZooKeeper bietet systemübergreifende Locks
  - Nur eine der Maschinen kann das Lock erhalten, die übrigen müssen warten
  - Bei Freigabe des Locks werden die wartenden Maschinen benachrichtigt (WATCH)

```
/
/locks
/locks/db
/locks/db/table_customers
```


ZooKeeper (6)

- *Persistant* vs. *Ephemeral* Nodes
  - *persistant*: Node bleibt permanent erhalten
  - *ephemeral*: Node verschwindet, wenn sich die erzeugende Maschine abmeldet (oder ausfällt)

Funktionale Programmierung (1)

Basics

- Listen
  - `[]` ist leere Liste
  - `a::list` – a wird vorne an Liste `list` angehängt (Ergebnis ist neue Liste)
  - `::` heißt **Prepend**-Operator (vgl. Append)

Funktionale Programmierung (2)

- Map-Operation
  - `map(f,[])` = `[]`
  - `map(f,a::list)` = `f(a)::map(f,list)`
  - z. B.: `f=(x->3*x)`, `map(f,[1,2,3])=[3,6,9]`

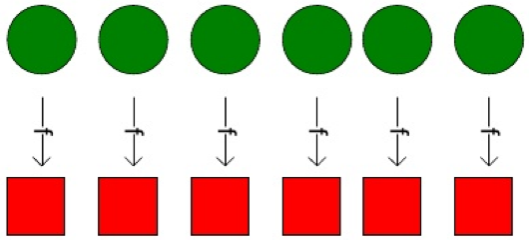

Bild: http://de.slideshare.net/tugrulh/presentations (Google-Präsentation)

Funktionale Programmierung (3)

- Fold-Operation
  - wendet eine Funktion `f(x,y)` mit zwei Argumenten der Reihe nach auf alle Elemente der Liste an

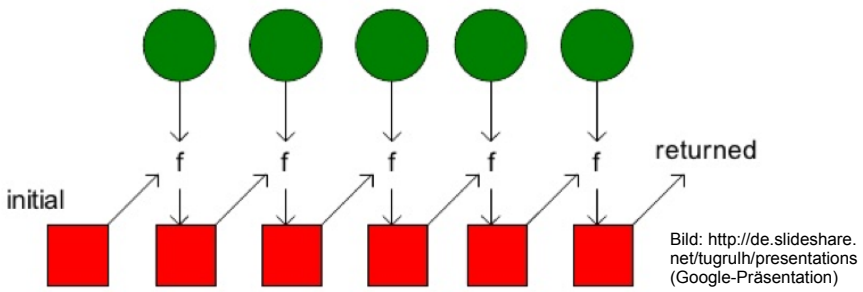

Bild: http://de.slideshare.net/tugrulh/presentations (Google-Präsentation)

Funktionale Programmierung (4)

- Fold-Operation (Forts.)
  - braucht Startwert
  - `foldl(add,0,[1,2,3]) = 3+(2+(1+0)) = 6` (Summe aller Listenelemente)
  - `foldl(mult,1,[3,4,5]) = 5*(4*(3*1)) = 60` (Produkt aller Listenelemente)
  - `foldr`: arbeitet sich von rechts nach links durch

Funktionale Programmierung (5)

- Implementierung von `foldl` und `foldr`
  - `foldl(f, a, []) = a`
  - `foldl(f, a, x::rest) = foldl(f, f(x,a), rest)`
  - `foldr(f, a, []) = a`
  - `foldr(f, a, x::rest) = f(x, foldr(f, a, rest))`
  - a heißt „Akkumulator“

Funktionale Programmierung (6)

- Dabei muss `foldl` nicht zwingend ein einzelnes Element als Ergebnis erzeugen

  → kann auch Liste erzeugen
- Verwende „Prepend“-Operator `::` als Funktion

Funktionale Programmierung (7)

- Beispiel: Reverse-Funktion für Listen
  - `f(x,a) = x :: a` (a ist Liste)
  - `reverse (list) = foldl (f, [], list)`
  - ```
    reverse ([1,2,3])
    = foldl (f, [], [1,2,3])
    = foldl (f, f(1,[]), [2,3])
    = foldl (f, [1], [2,3])
    = foldl (f, f(2,[1]), [3])
    = foldl (f, [2,1], [3])
    = foldl (f, f(3,[2,1]), [])
    = foldl (f, [3,2,1], [])        = [3,2,1]
    ```


Funktionale Programmierung (8)

- Beobachtung: `map` verarbeitet alle Listenelement unabhängig (während `foldl` und `foldr` sequentiell arbeiten)
- Darum lässt sich `map` gut parallelisieren.

MapReduce (1)

- Verarbeitung großer Datenmengen, z. B. Terabytes
- parallelisieren: auf hunderte oder tausende CPUs verteilen
- MapReduce erlaubt
  - automatische Parallelisierung und Verteilung
  - Fehler-Toleranz
  - Statusanzeige, Monitoring

MapReduce (2)

- übernimmt Konzepte der funktionalen Programmierung
  - zu verarbeitende Daten auf mehrere Maschinen aufteilen
  - jede Maschine führt auf den (ihr zugeteilten) Daten eine **Map**-Funktion aus
  - nach Abschluss aller Berechnungen werden die Ergebnisse gesammelt
  - Dann kombiniert eine **Reduce**-Funktion (wie etwa fold) alle Ergebnisse
    ```

MapReduce (3) – Beispiel

- Beispiel: gemeinsame Freunde (Facebook o. ä.)
  - Ausgangssituation: Für jeden Teilnehmer X eine Liste seiner Freunde (`key -> value`)

```
A -> B C D          D -> A B C E
B -> A C D E        E -> B C D
C -> A B D E
```

  - Jede Zeile an eine Maschine schicken und dort eine **Map**-Funktion starten

```
A -> B C D   ──────►   (A B) -> B C D
                       (A C) -> B C D
                       (A D) -> B C D
```

Quelle für Beispiel: http://stevekrenzel.com/finding-friends-with-mapreduce

MapReduce (4) – Beispiel

- Nach Abschluss der Berechnungen alle Ergebnisse zusammenfassen, nach *key* gruppiert

```
(A B) -> (A C D E) (B C D)          (B E) -> (A C D E) (B C D)
(A C) -> (A B D E) (B C D)          (C D) -> (A B C E) (A B D E)
(A D) -> (A B C E) (B C D)          (C E) -> (A B D E) (B C D)
(B C) -> (A B D E) (A C D E)        (D E) -> (A B C E) (B C D)
(B D) -> (A B C E) (A C D E)
```

- Abschluss: für jeden Key die **Reduce**-Funktion aufrufen (hier: Schnittmenge berechnen)

```
(A B) -> (C D)                      (B E) -> (C D)
(A C) -> (B D)                      (C D) -> (A B E)
(A D) -> (B C)                      (C E) -> (B D)
(B C) -> (A D E)                    (D E) -> (B C)
(B D) -> (A C E)
```


MapReduce (5)

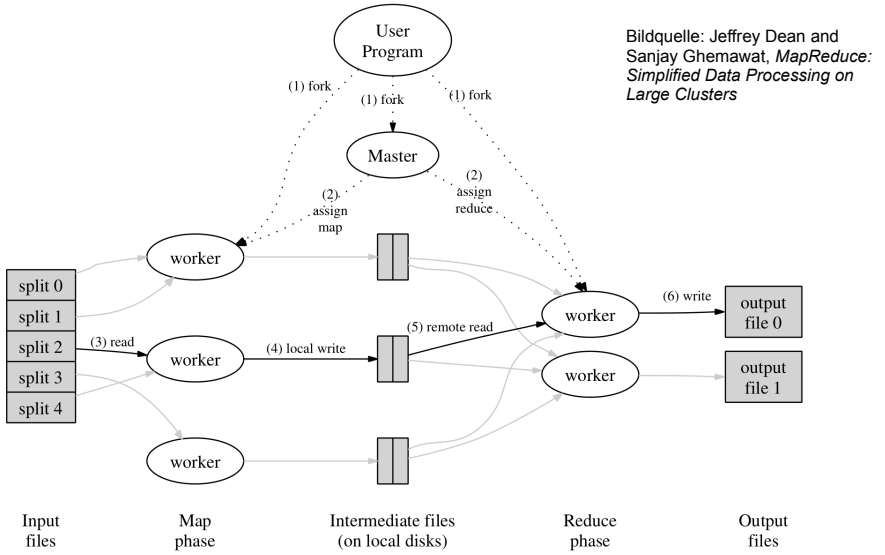

Bildquelle: Jeffrey Dean and Sanjay Ghemawat, *MapReduce: Simplified Data Processing on Large Clusters*

Verteilte Dateisysteme (1)

- Gemeinsames (globales) Dateisystem für alle Mitglieder der Cloud
- Einfacher NFS-Server, dessen Shares an alle Clients exportiert werden?
  - Daten sind immer remote
  - langsame Übertragung aller Daten
  - NFS-Server ist ein Bottleneck, weil etliche Rechner in der Cloud gleichzeitig darauf zugreifen
  - skaliert nicht

Verteilte Dateisysteme (2)

- Statt zentralem Fileserver: verteilten Server nutzen
- mehrere Server im Netz bilden gemeinsam einen Fileserver
  - Ausfallsicherheit durch Duplikation (Redundanz)
  - Datenlokalität: Daten dort speichern, wo sie benötigt werden

IBM Global Parallel Filesystem (GPFS)

- Verteiltes Dateisystem
- ab 2000; zunächst für HPC-Cluster entworfen
- parallele Zugriffe mehrerer Rechner
- Locking schützt Schreibvorgänge
  - Locking verwendet Tokens mit Ablaufzeit
    → keine explizite Rückgabe des Locks nötig
    → reduzierter Traffic
- File Placement Optimizer (FPO)
  - Daten liegen auf Platten in der Nähe des Servers
  - für MapReduce-Berechnungen vorbereitet

Google-Filesystem (1)

- Ausgangssituation bei Google
  - einige Millionen Dateien mit jeweils > 100 MByte
  - Dateien vom Typ „write-once“, mit Append
  - Lese-Zugriff auf diese Dateien über Streaming
  - bei Zugriff: hoher Durchsatz wichtiger als niedrige Latenz

Google-Filesystem (2)

- Design-Entscheidungen für GFS
  - Dateien in 64-MByte-Chunks aufteilen
    → Performance-Optimierung für große Dateien
  - Atomare Append-Operation; mehrere Prozesse können an gleiche Datei Daten anhängen
  - Replikation: jeder Chunk auf ≥3 Chunk-Servern
  - ein Master speichert Metadaten, koordiniert Zugriffe
    → soll Konsistenz garantieren (aber: Bottleneck)

Google-Filesystem (3)

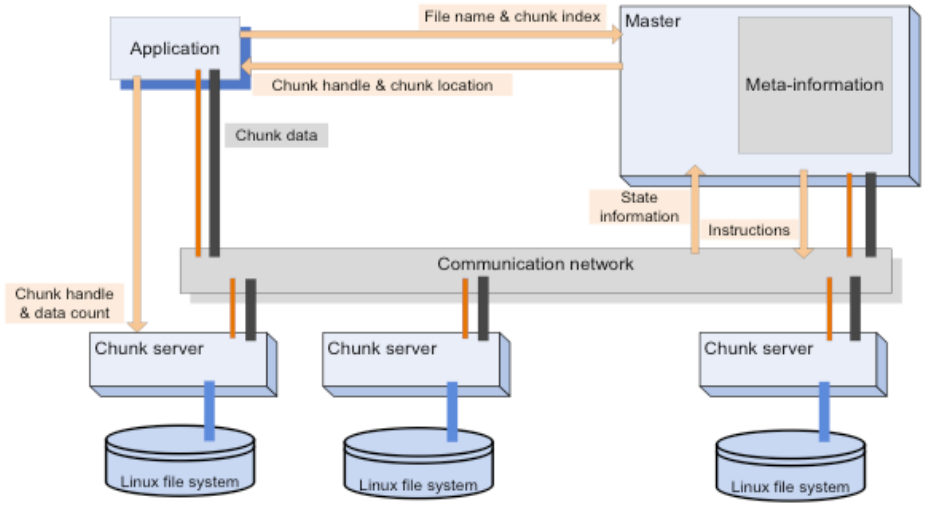

Bildquelle: Marinescu, *Cloud Computing, Theory and Practice*

Google-Filesystem (4)

- GFS Chunks
  - **Chunk**-Größe 64 MByte, aber zerlegt in **Blöcke** der Größe 64 KByte
  - Jeder 64-KByte-Block hat 32-Bit-Prüfsumme
- Locking erfolgt auch Chunk-Ebene

Google-Filesystem (5)

- Schreiben eines Chunks
  - Master wählt einen der Chunk-Server als **Primary** aus, der schreib-berechtigt ist
  - Client (der schreiben will) bittet Master um Schreibberechtigung
  - Master schickt Client Information über Primary und alle Secondary Chunk Servers
  - Client schickt Daten an alle (!) Chunk-Server
  - Alle Chunk-Server schicken ACK an Client
  - Client schickt Write-Request an Primary
  - Primary schickt Write-Request an alle Seconarys

Literatur

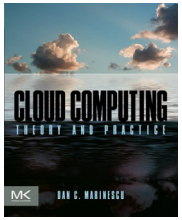

- Dan C. Marinescu: *Cloud Computing – Theory and Practice*, Morgan Kaufmann 2013
- Jimmy Lin and Chris Dyer: Data Intensive Text Processing with MapReduce, 2010, http://lintool.github.io/MapReduceAlgorithms/MapReduce-book-final.pdf

ZUSAMMENFASSUNG und letzte Fragen

A: Datenformate und Wandlung (1)

- Information vs. Daten
- Bits, Bytes, dual/oktal/hex
- ASCII, Unicode (UTF-8, UTF-16)
- Digitalisierung:
  - rastern (diskretisieren, samplen) und
  - quantisieren (Wertebereich einschränken)
- Kompression (verlustfrei/verlustbehaftet)
- Prüfsummen, Fehlerkorrektur
- Mark-up: HTML/CSS, LaTeX, Wiki, XML

A: Datenformate und Wandlung (2)

- Mark-up: HTML/CSS, LaTeX, Wiki,
- XML, XSLT, DTD, XHTML, DocBook, Open Document Format (XML)
- Rastergrafiken (JPG vs. PNG), Vektorgrafiken
- PostScript, PDF
- MPEG, Frames
- Kommunikation
  - Client / Server; HTTP, FTP, SMTP

A: Datenformate und Wandlung (3)

- Datenträgeraustauschformat (DTaus)
- Applikationsformate (CAD, GIS, DTP)
- Archive und Software-Pakete
  - zip, tar, gz, tar.gz (plattform-übergreifend?)
  - Linux: RPM, Debian;
    - Pakete mit Metadaten
    - Abhängigkeiten, Konflikte
    - Repositories: Abh. auflösen, Upgrade
  - Windows: MSI, OS X: DMG mit *.app-Ordnern

B: PC als Arbeitsplatz

- Exkurs: LaTeX, BibTeX
- Statistik: Programmiersprache R
- Numerik: GNU Octave
- Computer-Algebra-Systeme, Wolfram Alpha
- GIS: Mark-up-Sprachen, Nielsen-Gebiete
- Versionsverwaltung, Mercurial (hg), Klonen, Merge-Operation

C: Ergonomie und Arbeitsschutz (1)

- „Gebrauchstauglichkeit“
- Nutzungskontext(e), Zielgruppe(n)
- effektiv, effizient, zufrieden stellend
- Kriterien
  - Aufgabenangemessenheit
  - Selbstbeschreibungsfähigkeit
  - Steuerbarkeit
  - Erwartungskonformität
  - Fehlertoleranz
  - Individualisierbarkeit
  - Lernförderlichkeit

C: Ergonomie und Arbeitsschutz (2)

- Beispiele:
  - Microsoft Ribbons
  - Seriennummern-Eingabe
  - Secure Shell (ssh, scp; Optionen -p, -P)
- Kriterien auch auf Webdesign anwendbar
- Arbeitsschutz

D: Rechnerstrukturen (1)

- Universalrechner, von-Neumann vs. Harvard
- ISA (Instruction Set Architecture)
  - Maschinenbefehle, Register
  - Adressierungsarten, Interruptbehandlung
  - 1-/2-/3-Adress-*Maschinen* bzw. -*Befehle*
  - Spezialregister (IP, SP, Status)
- Load, Store, Push, Pop, arithm. Operationen
  → RISC, CISC

D: Rechnerstrukturen (2)

- Pipelining
  - 5-stufige RISC-Pipeline (Fetch, Decode, Execute, Memory Access, Write-back)
  - 6-stufige CISC-Pipeline (Fetch, Decode, Calculate Operands, Fetch Operands, Execute, Write-back)
  - Pipeline-Hemmnisse
    - strukturell (Speicherzugriff bei **M**, **F**)
    - Datenabhängigkeiten (RAW-Konflikt)
    - ablauf-bedingt (bedingter Sprung; Sprungvorhersage)

D: Rechnerstrukturen (3)

- Superskalare Architekturen
  - mehrere Execute-Einheiten, nach Aufgaben getrennt (z. B. FPU, Int, MUL)
  - abhängige vs. unabhängige Pipelines
  - Datenabhängigkeiten (RAW, WAR, WAW; RAR)
  - Abhängigkeitsgraph (keine RARs, keine transitiven Abhängigkeiten)
  - Reorder-Buffer
    - Platz im Buffer, Anzahl der Ausführ-Einheiten (pro Kategorie), Anzahl der pro Takt zuteilbaren (issue) und bestätigten (commit) Befehle

E: Zentrale/verteilte IT-Infrastrukturen (1)

- Parallele Systeme
- Programm parallelisieren, Speed-up → Amdahls Gesetz: S(n) → 1 / α
- Arten der Parallelität (Bit-Level, Instruction-Level, Daten/Schleifen-Parall., Task-Parall.)
- Verteilte Systeme
- Client / Server, RPC, Reverse Proxy, Asynchronous RPC
- Cluster, Super Computer (HPC, MPI), Grid

E: Zentrale/verteilte IT-Infrastrukturen (2)

- Cloud Computing
  - skalierbar, elastisch, abrechenbar, zentralisiert
  - Virtualisierung
  - public / private / community / hybrid cloud
  - Cloud-Vorteile: pay as you go, keine Investitionen
  - Varianten:
    - Software as a Service (SaaS),
    - Platform as a Service (PaaS),
    - Infrastructure as a Service (IaaS)

E: Zentrale/verteilte IT-Infrastrukturen (3)

- Technische Umsetzung
  - Verteilte Konfiguration mit ZooKeeper
  - Map und Fold (funktionale Programmierung)
  - Software-Entwicklung mit MapReduce
  - Verteilte Dateisysteme (GPFS, GoogleFS statt NFS)