1. Grundlegende Konzepte

1.1. Motivation und Historie

Softwareschichten

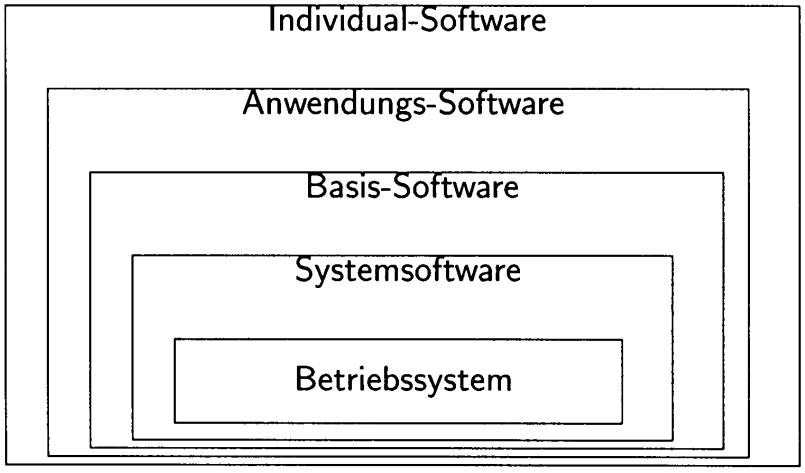

- Jede Schicht baut auf den weiter innen liegenden Schichten auf
- *Bsp.:* Betriebssystem bietet Dateien und Operationen auf Dateien, Möglichkeiten zum Drucken, Anwendungs-Software wie Textverarbeitung nutzt diese Möglichkeiten
- Beispiele für Schichten:
  - Betriebssysteme: MS-DOS, OS/2, UNIX, VMS, . . .
  - Systemsoftware: Datenbanksysteme, Benutzerschnittstellen (MS-Windows)
  - Basissoftware: Graphiksysteme (Draw, Designer,. . .), Textverarbeitungssysteme (MS-Word, Star-Writer, . . .)
  - Anwendungs-Software: CAD-Systeme (AutoCAD, . . .), DTP-Systeme (Ventura, Pagemaker, . . .), Buchhaltungssysteme, Lagerverwaltungssysteme, Umweltdatenbanken

Beispiel für ein "Semantisches Netz"
(aus dem Bereich automatische Bildverarbeitung)

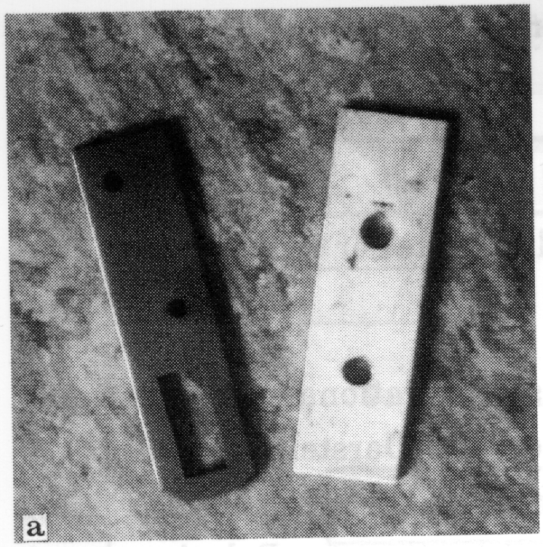

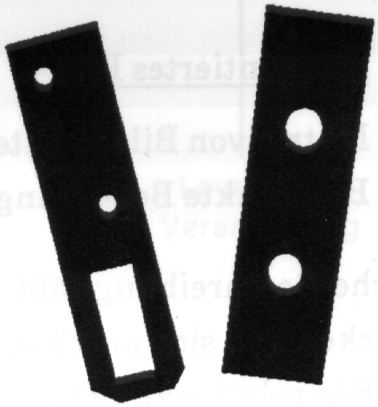

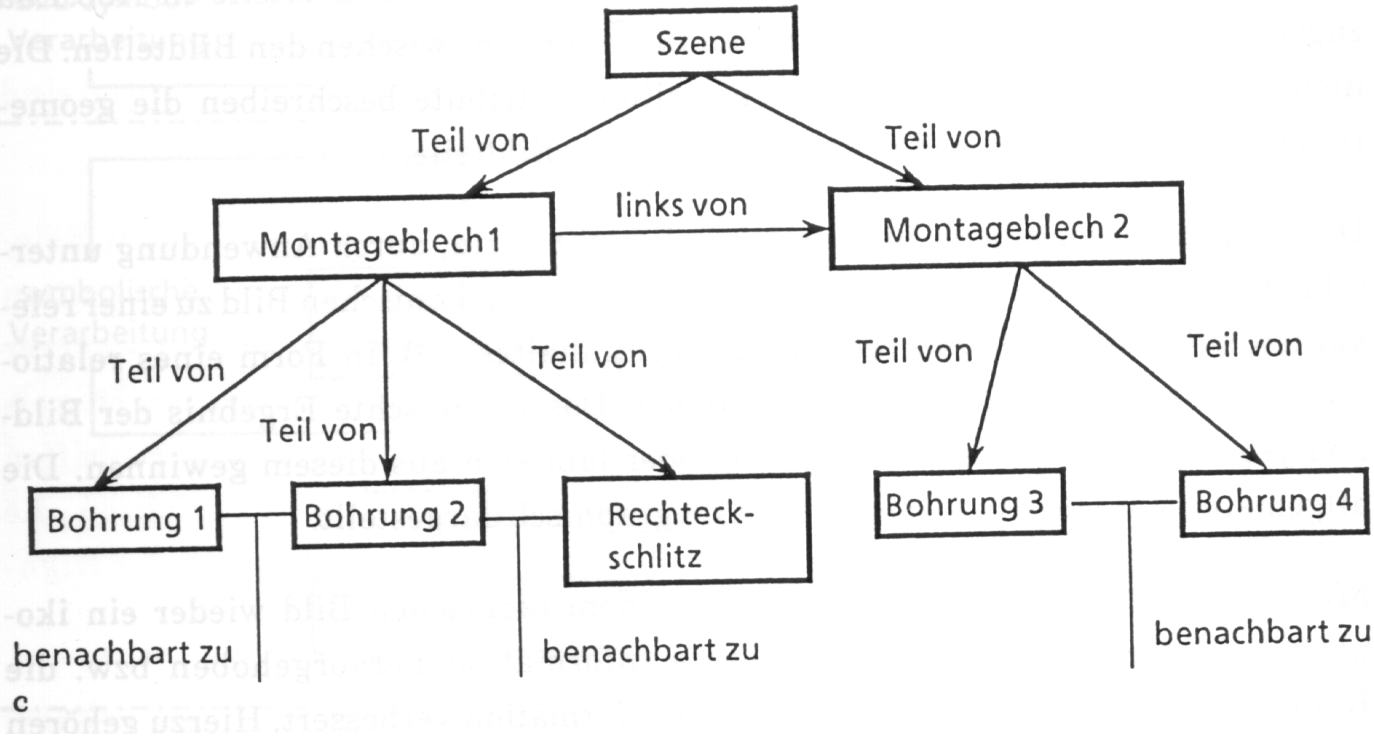

a.) Zu bearbeitendes Bild (Pixel-Matrix)
b.) Segmentiertes Bild
c.) Symbolische Beschreibung durch ein Semantisches Netz
(attributierter relationaler Graph)

Ohne Datenbanken: Datenredundanz

- Basis- oder Anwendungssoftware verwaltet ihre eigenen Daten in ihren eigenen (Datei-)Formaten; *Bsp.:*
  - Textverarbeitung: Texte, Artikel und Adressen
  - Buchhaltung: Artikel, Adressen
  - Lagerverwaltung: Artikel, Aufträge
  - Auftragsverwaltung: Aufträge, Artikel, Kundenadressen
  - CAD-System: Artikel, Technische Daten, Technische Bausteine
  - Produktion:. . . , Bestelleingang:. . . , Kalkulation:. . .
- Daten sind redundant: mehrfach gespeichert; Probleme: Verschwendung von Speicherplatz, "Vergessen" von Änderungen; keine zentrale, "genormte" Datenhaltung
- Andere Software-Systeme (auch Programmiersprachen, Tabellenkalkulation, Dateiverwaltungssysteme, . . .) können große Mengen von Daten nicht effizient verarbeiten
- Mehrere Benutzer oder Anwendungen können nicht parallel auf den gleichen Daten arbeiten, ohne sich zu stören
- Anwendungsprogrammierer / Benutzer können Anwendungen nicht programmieren / benutzen, ohne
  - interne Darstellung der Daten
  - Speichermedien oder Rechner (bei verteilten Systemen)

  zu kennen (**Datenunabhängigkeit** nicht gewährleistet)
- Datenschutz und Datensicherheit sind nicht gewährleistet

Mit Datenbanken: Datenintegration

- Die gesamte Basis- und Anwendungssoftware arbeitet auf denselben Daten (Datenbankentwurf, Datendefinition)
- *Bsp.:* Adressen und Artikel werden nur einmal gespeichert
- Auch andere Probleme (Effizienz, Parallelität, Datenschutz, Datensicherheit) werden gelöst
  - Datenbanksysteme können große Datenmengen effizient verwalten (Anfragesprachen, Optimierung, Interne Ebene)
  - Benutzer können parallel auf Datenbanken arbeiten (Transaktionskonzept)
  - Datenunabhängigkeit durch 3-Ebenen-Konzept
  - Datenschutz (kein unbefugter Zugriff) und Datensicherheit (kein ungewollter Datenverlust) werden vom System gewährleistet

Historie

- Anfang 60er Jahre: elementare Dateien, anwendungsspezifische Datenorganisation (geräteabhängig, redundant, inkonsistent)
- Ende 60er Jahre: Dateiverwaltungssysteme (SAM, ISAM) mit Dienstprogrammen (Sortieren) (gerateunabhängig, aber redundant und inkonsistent)
- 70er Jahre: Datenbanksysteme (Geräte- und Datenunabhängigkeit, redundanzfrei, konsistent)

1.2. Komponenten und Funktionen

Architektur eines Datenbanksystems

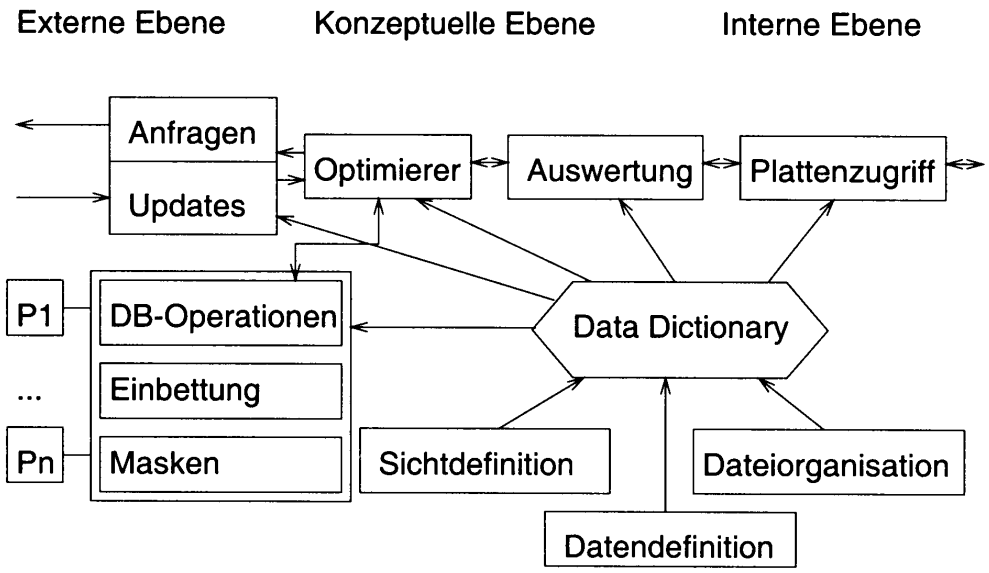

- Dateiorganisation: Definition der (internen) Dateiorganisation und Zugriffspfade
- Datendefinition: Konzeptuelle Datendefinition (konzeptuelles Schema)
- Sichtdefinition: Definition von Benutzersichten (externe Schemata)
- Masken: Entwurf von Menüs und Masken
- DB-Operationen: Anfrage- und Update-Operationen
- Einbettung: Einbettung dieser Operationen in Anwendungsprogramme
- P1, . . . , Pn: Verschiedene Anwendungsprogramme
- Optimierer und Auswertung: Effiziente Umsetzung dieser Operationen
- Plattenzugriff: Plattenzugriffssteuerung (genauer: Fünf-Schichten-Architektur)

Modell für die konzeptuelle Ebene: Relationenmodell

Konzeptuell ist die Datenbank eine Menge von Tabellen

AUSLEIH

INV.NR	NAME
4711	Meyer
1201	Schulz
0007	Müller
4712	Meyer

BUCH

INV.NR	TITEL	ISBN	AUTOR
0007	Dr. No	3-125	James Bond
1201	Objektbanken	3-111	Heuer
4711	Datenbanken	3-765	Vossen
4712	Datenbanken	3-891	Ullman
4717	PASCAL	3-999	Wirth

- **Fett** geschriebene Zeilen: *Relationenschema*
- Weitere Einträge in der Tabelle: *Relation*
- Eine Zeile der Tabelle: *Tupel*
- Eine Spaltenüberschrift: *Attribut*

Relationenmodell: Integritätsbedingungen

AUSLEIH

INV.NR	NAME
4711	Meyer
1201	Schulz
0007	Müller
4712	Meyer

BUCH

INV.NR	TITEL	ISBN	AUTOR
0007	Dr. No	3-125	James Bond
1201	Objektbanken	3-111	Heuer
4711	Datenbanken	3-765	Vossen
4712	Datenbanken	3-891	Ullman
4717	PASCAL	3-999	Wirth

- Relationenschema + lokale Integritätsbedingungen
  - INVENTARNR ist *Schlüssel* für BUCH
  - d.h.: eine INVENTARNR darf nicht doppelt vergeben werden
  - d.h.: in Spalte INVENTARNR dürfen keine zwei gleichen Werte auftauchen
- Datenbankschema ist Menge von Relationenschemata + globale Integritätsbedingungen
  - INVENTARNR in AUSLEIH ist *Fremdschlüssel* bezüglich BUCH
  - d.h.: INVENTARNR taucht in einem anderen Relationenschema als Schlüssel auf
  - d.h.: die Inventarnummern in AUSLEIH müssen auch in BUCH auftreten

Anfrageoperationen

- SELEKTION: Zeilen (Tupel) auswählen
  SEL [NAME = 'Meyer'] (AUSLEIH) ergibt:

INVENTARNR	NAME
4711	Meyer
4712	Meyer

- PROJEKTION: Spalten (Attribute) auswählen
  PROJ [INVENTARNR, TITEL] (BUCH) ergibt:

INVENTARNR	TITEL
0007	Dr. No
1201	Objektbanken
4711	Datenbanken
4712	Datenbanken
4717	PASCAL

  Achtung: doppelte Tupel werden entfernt!
- VERBUND (JOIN): Tabellen verknüpfen über gleichbenannte Spalten und gleiche Werte

PROJ [INVENTARNR, TITEL](BUCH)

JOIN

SEL [NAME = 'Meyer'](AUSLEIH).

ergibt:

INVENTARNR	TITEL	NAME
4711	Datenbanken	Meyer
4712	Datenbanken	Meyer

- Weitere Operationen: Vereinigung, Differenz, Durchschnitt, Umbenennung
- Alle Operationen beliebig kombinierbar ("Algebra")

Sprachen und Sichten

Abfragesprache

- Interaktive Möglichkeit, Datenbankabfragen zu formulieren und zu starten
- Relationenalgebra + Funktionen (SUM, MAX, MIN, COUNT, . . .) + arithmetische Operationen
- eventuell graphisch "verpackt"

Update-Komponente

- Interaktive Möglichkeit
  - Tupel einzugeben
  - Tupel zu löschen
  - Tupel zu ändern
- Lokale und globale Integritätsbedingungen werden geprüft!

Definition von Benutzersichten

- Häufig vorkommende Datenbankabfragen können unter einem "Sichtnamen" als "virtuelle" Tabelle gespeichert werden.
- Bsp.:

$$\begin{aligned} \text{MEYERS} := \quad & \text{PROJ}\,[\text{INVENTARNR}, \text{TITEL}](\text{BUCH}) \\ & \text{JOIN} \\ & \text{SEL}\,[\text{NAME} = \text{'Meyer'}](\text{AUSLEIH}), \end{aligned}$$

ergibt Tabelle von vorhin; ansprechbar wie BUCH oder AUSLEIH über Sichtnamen MEYERS.

Optimierer

Problem: Finde einen Relationenalgebra-Ausdruck, der äquivalent ist ("das gleiche Ergebnis liefert") wie der gegebene, aber effizienter auszuwerten ist

Eine Möglichkeit: algebraische Optimierung

- allgemeine Regel:
  1. *SEL [A = Konst] (REL1 JOIN REL2)* und A aus REL1
  2. *SEL [A = Konst] (REL1) JOIN REL2*

  sind äquivalent
- allgemeine Strategie: Selektionen möglichst früh, da sie Tupelanzahlen in Relationen verkleinern
- Beispiel: REL1 100 Tupel, REL2 50 Tupel
  intern: Tupel sequentiell abgelegt
  1. 5000 (JOIN) + 5000 (SEL) = 10000 Operationen
  2. 100 (SEL) + $10 \cdot 50$ (JOIN) = 600 Operationen
     falls 10 Tupel in REL1 die Bedingung A = Konst erfüllen

Interne Strukturen

Dateiorganisationsformen

Relation kann intern als Datei wie folgt abgespeichert werden:

- Heap, ungeordnet
- Sequentiell, geordnet nach bestimmter Spalte oder Spaltenkombination
- Hash-organisiert, gestreut gespeichert, Adreßberechnung durch Formel
- Baumartig, Tupel in einem Suchbaum angeordnet
- . . .

Zusätzliche Zugriffspfade:

- statischer Index, einstufig oder mehrstufig
- dynamischer Index

Zwischen Dateiorganisationen/Zugriffspfaden kann beliebig gewechselt werden, ohne Auswirkungen auf konzeptuelle/externe Ebene

ACHTUNG: je schneller die Abfrage, desto langsamer der Update

Zugriffe auf Plattenseiten

Jede Operation (SEL, PROJ, JOIN, . . .) wird nun in optimale Folge von Seitenzugriffen umgesetzt

Dabei werden:

- Zugriffspfade und Dateiorganisation ausgenutzt, wenn es dem System sinnvoll erscheint
- Reihenfolge der Zugriffe nach vorliegenden Zugriffspfaden bestimmt.

Beispiel: *SEL [NAME = 'Meyer'] (SEL [INVENTARNUMMER > 4500] (AUSLEIH))*

- Annahme: auf NAME ist ein Zugriffspfad definiert, auf INVENTARNUMMER nicht
- System ändert die Reihenfolge der Selektionen!!

Einsatzgebiete und Grenzen

Klassische Einsatzgebiete:

- viele Objekte (15000 Bücher, 300 Benutzer, 100 Ausleihvorgänge pro Woche, . . .)
- wenige Objekttypen (BUCH, BENUTZER, AUSLEIHUNG)
- etwa Buchhaltungssysteme, Auftragserfassungssysteme, Bibliothekssysteme, . . .

Normalerweise sind herkömmliche Datenbanksysteme überfordert mit:

- CAD- oder andere technische Anwendungen (viele Objekte, viele Objekttypen, sehr strukturierte Objekte)
  - ABER: Objektorientierte Datenbanksysteme
- Expertensysteme (wenige Objekte, viele Objekttypen, kompliziertere Operationen)
  - ABER: Deduktive Datenbanksysteme

1.3. Prinzipien

- DBMS: Datenbank-Management-System
- DBS: Datenbanksystem (DBMS + Datenbank)
- Grundmerkmale
  - verwalten persistente (langfristig zu haltende) Daten
  - verwalten große Datenmengen effizient
  - Datenbankmodell, mit dessen Konzepten alle Daten einheitlich beschrieben werden (Integration)
  - Operationen und Sprachen (DDL, IQL, DML, . . .) deskriptiv, getrennt von einer Programmiersprache
  - Transaktionskonzept, Concurrency Control: logisch zusammenhängende Operationen atomar (unteilbar), Auswirkungen langlebig, können parallel durchgeführt werden
  - Datenschutz, Datenintegrität (Konsistenz), Datensicherheit
- Grundprinzip moderner Datenbanksysteme
  - 3-Ebenen-Architektur (physische Datenunabhängigkeit, logische Datenunabhängigkeit)
  - Trennung zwischen Schema (etwa Tabellenstruktur) und Instanz (etwa Tabelleninhalt)

angelehnt an 9 Codd'sche Regeln:

Die neun Codd'schen Regeln

1. Integration
   - einheitliche, nichtredundante Datenverwaltung
2. Operationen
   - Speichern, Suchen, Ändern
3. Katalog
   - Zugriffe auf Datenbankbeschreibungen im Data Dictionary
4. Benutzersichten
5. Konsistenzüberwachung
   - auch: Integritätssicherung (Korrektheit des Datenbankinhalts)
6. Datenschutz
   - Ausschluß unauthorisierter Zugriffe
7. Transaktionen
   - Mehrere DB-Operationen als Funktionseinheit
8. Synchronisation
   - Parallele Transaktionen koordinieren
9. Datensicherung
   - Wiederherstellung von Daten nach Systemfehlern

Entwicklungslinien

60er Jahre

- DBS basierend auf hierarchischem Modell, Netzwerkmodell
  - Zeigerstrukturen zwischen Daten
  - Schwache Trennung interne / konzeptuelle Ebene
  - Navigierende DML
  - Trennung DML / Programmiersprache

70er und 80er Jahre

- Relationale Datenbanksysteme
  - Daten in Tabellenstrukturen
  - 3-Ebenen-Konzept
  - Deklarative DML
  - Trennung DML / Programmiersprache

(80er und) 90er Jahre

- Wissensbanksysteme
  - Daten in Tabellenstrukturen
  - Stark deklarative DML
  - Integrierte Datenbankprogrammiersprache
- Objektorientierte Datenbanksysteme
  - Daten in komplexeren Objektstrukturen (Trennung Objekt und seine Daten)
  - Deklarative oder navigiernde DML
  - Oft integrierte Datenbankprogrammiersprache
  - Oft keine vollständige Ebenentrennung