LMU LUDWIG-MAXIMILIANS-UNIVERSITY MUNICH
DEPARTMENT INSTITUTE FOR INFORMATICS
DATABASE SYSTEMS GROUP

Skript zur Vorlesung:

Einführung in die Informatik: Systeme und Anwendungen

Sommersemester 2008

Kapitel 3: Datenbanksysteme

Vorlesung: Prof. Dr. Christian Böhm
Übungen: Annahita Oswald, Bianca Wackersreuther

http://www.dbs.ifi.lmu.de/Lehre/InfoNF

Überblick

3.1 Einleitung
3.2 Das Relationale Modell
3.3 Die Relationale Algebra
3.4 Mehr zu SQL
3.5 Das E/R-Modell
3.6 Normalformen

Überblick

3.1 Einleitung

3.2 Das Relationale Modell
3.3 Die Relationale Algebra
3.4 Mehr zu SQL
3.5 Das E/R-Modell
3.6 Normalformen

Motivation

- Bisher:
  - Eigentlich nur Betrachtung des Hauptspeicher
  - Objekte zur Datenverarbeitung werden im Hauptspeicher erzeugt und nach dem Programmlauf wieder entfernt
  - Swapping / virtueller Speicher: Objekte werden möglicherweise ausgelagert, aber „eigentliche Aktionen“ (Verarbeitung) nur im Hauptspeicher

- Warum ist dies nicht ausreichend?
  - Viele Anwendungen müssen Daten ***permanent*** speichern
  - Arbeitsspeicher ist häufig nicht groß genug, um z.B. alle Kundendaten einer Bank oder Patientendaten einer Klinik zu speichern

Permanente Datenspeicherung

- Daten können auf dem sog. ***Externspeicher*** (auch ***Festplatte*** genannt) permanent gespeichert werden

Arbeitsspeicher:

- rein elektronisch (Transistoren und Kondensatoren)
- flüchtig
- schnell
- wahlfreier Zugriff
- teuer

Externspeicher:

- Speicherung auf magnetisierbaren Platten (rotierend)
- nicht flüchtig
- langsam
- blockweiser Zugriff
- wesentlich billiger

Aufbau einer Festplatte

- Mehrere magnetisierbare ***Platten*** rotieren um eine gemeinsame Achse
- Ein Kamm mit je zwei ***Schreib-/Leseköpfen*** pro Platte (unten/oben) bewegt sich in radialer Richtung.

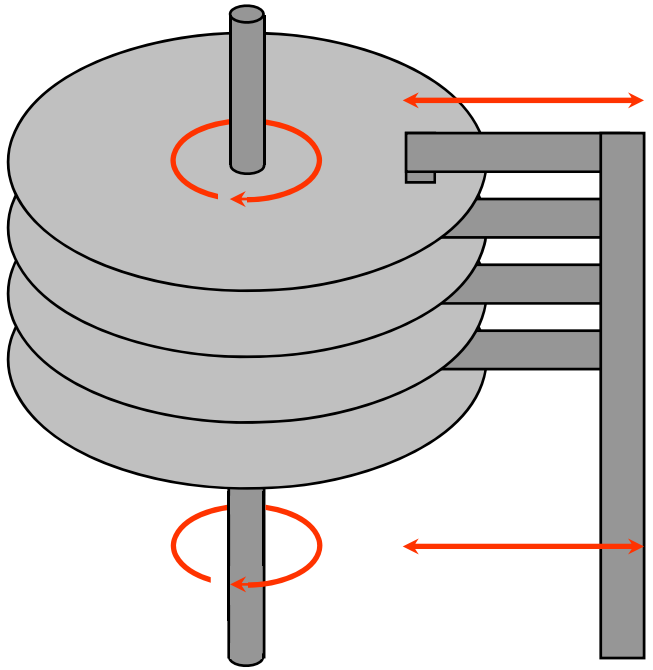

Einteilung der Plattenoberfläche

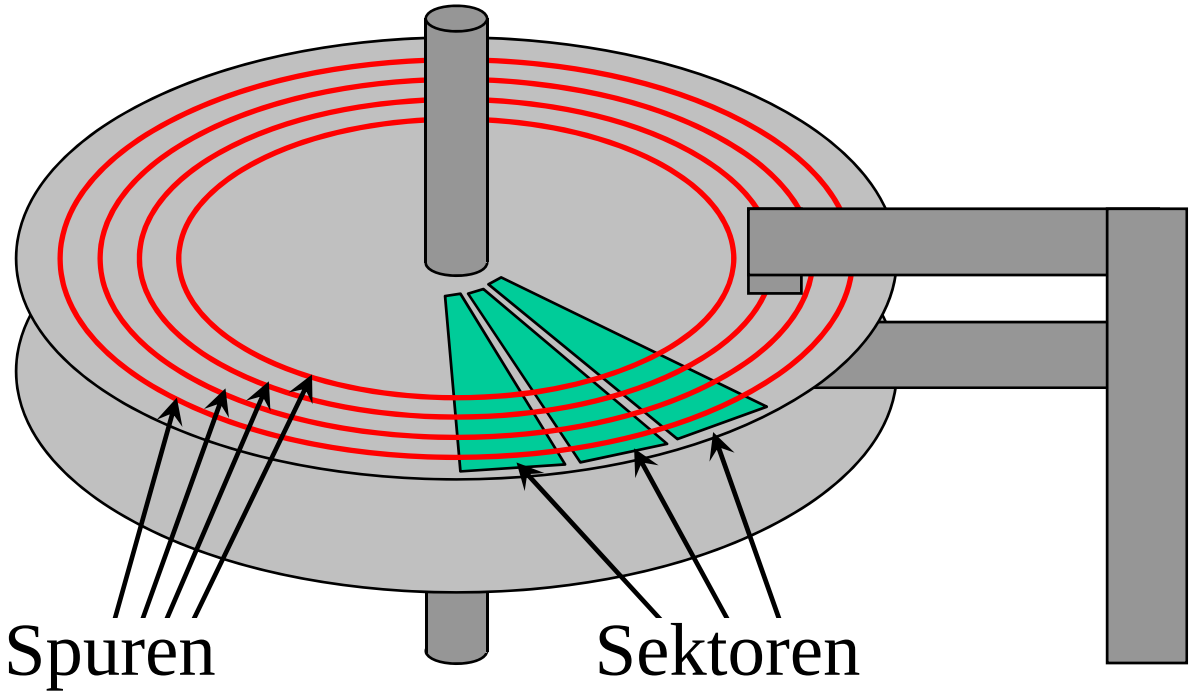

- (interne) Adressierung einer Information:
  [Platten-Nr | Oberfl.-Nr | Spur-Nr | Sektor-Nr | Byte-Nr]
- Berechnung der Kapazität:

  # Platten * 2 * # Spuren * # Sektoren * Bytes pro Sektor

Lesen/Schreiben eines Sektors

- Positionieren des Kamms mit den Schreib-/Leseköpfen auf der Spur
- Warten bis die Platte so weit rotiert ist, dass der Beginn des richtigen Sektors unter dem Schreib-/Lesekopf liegt
- Übertragung der Information von der Platte in den Arbeitsspeicher (bzw. umgekehrt)

Achtung:

Es ist aus technischen Gründen nicht möglich, einzelne Bytes zu lesen bzw. zu schreiben, sondern mindestens einen ganzen Sektor

Speicherung in Dateien

- Adressierung mit Platten-Nr., Oberfl.-Nr. usw. für den Benutzer nicht sichtbar

- Arbeit mit Dateien:
  - Dateinamen
  - Verzeichnishierarchien
  - Die Speicherzellen einer Datei sind byteweise von 0 aufsteigend durchnummeriert.
  - Die Ein-/Ausgabe in Dateien wird gepuffert, damit nicht der Programmierer verantwortlich ist, immer ganze Sektoren zu schreiben/lesen.

Beispiel: Dateizugriff in Java

- Werden die Objekte einer Applikation in eine Datei geschrieben, ist das Dateiformat vom Programmierer festzulegen:

- Wo findet man dieses Datei-Schema im Quelltext z.B. des Java-Programms ?

Das Dateischema wird nicht explizit durch den Quelltext beschrieben, sondern implizit in den Ein-/Auslese-Prozeduren der Datei

Logische Datenabhängigkeit

- Konsequenz:
  - Wenn eine Änderung des Dateiformates nötig ist (z.B. zusätzliche Objektattribute in neuer Programmversion):
    - Alte Datendateien können nicht mehr verwendet werden oder müssen z.B. durch extra Programme konvertiert werden
    - Die Änderung muss in allen Programmen nachgeführt werden, die mit den Daten arbeiten, auch in solchen, die logisch von Änderung gar nicht betroffen sind

=> ***Logische Datenabhängigkeit***

Physische Datenabhängigkeit

- Meist werden die Datensätze anhand ihrer Position adressiert/separiert:
  - z.B. jeder Satz hat 22 Zeichen:
  - 1. Satz: Adresse 0; 2. Satz: Adresse 22 usw.
- Suche gemäß bestimmten Attributwerten (z.B. Namen des Kunden) muss im Programm codiert werden
- Soll die Datei z.B. mit einem Suchbaum unterstützt werden, dann gleiche Konsequenzen wie bei logischer Änderung

=> ***Physische Datenabhängigkeit***

Informationssysteme

- Große Software-Systeme
- Viele einzelne Programme
- Programme arbeiten teils mit gemeinsamen Daten, teils mit unterschiedlichen
- Beispiele für die Programme:
  - Buchhaltung: Artikel- und Adressinformation
  - Lagerverwaltung: Artikel und Aufträge
  - Auftragsverwaltung.: Aufträge, Artikel, Adressen
  - CAD-System: Artikel, techn. Daten, Bausteine
  - Produktion, Bestelleingang, Kalkulation: ...

Redundanz

- Daten werden meist mehrfach gespeichert

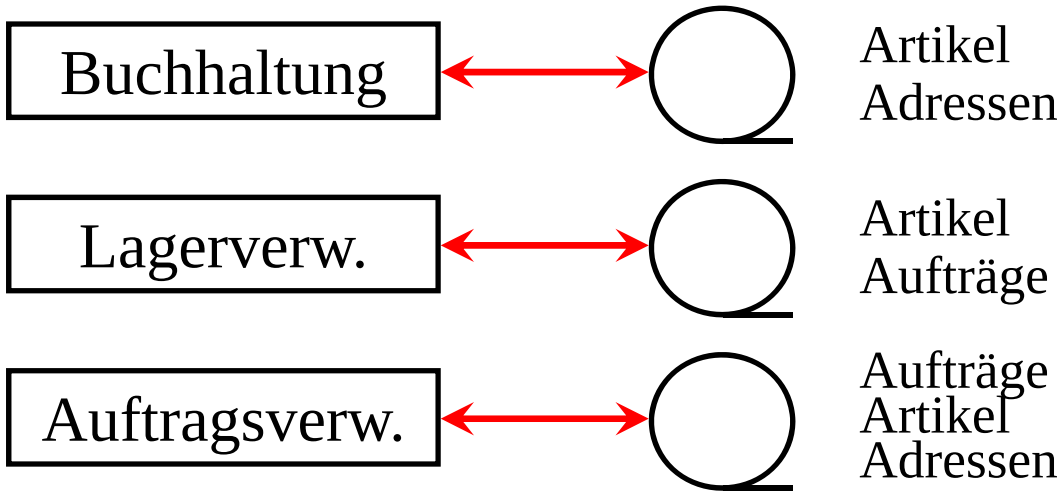

- Konsequenz: u.a. ***Änderungs-Anomalien***
  Bei Änderung einer Adresse müssen viele Dateien nach den Einträgen durchsucht werden
  (hierzu später mehr)

Schnittstellenproblematik

- Alternative Implementierung

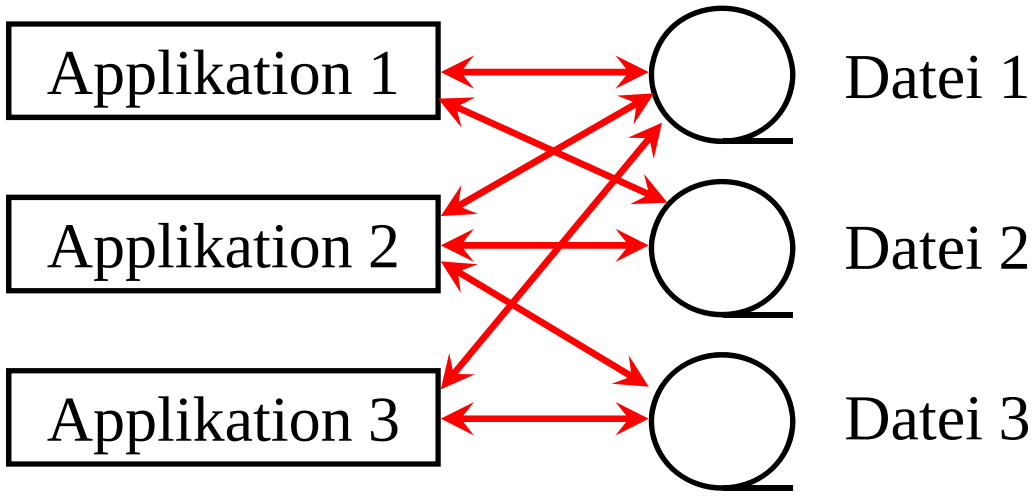

- Nachteile:
  - unübersichtlich
  - bei logischen oder physischen Änderungen des Dateischemas müssen viele Programme angepasst werden

Weitere Probleme von Dateien

- In großen Informationssystemen arbeiten viele Benutzer gleichzeitig mit den Daten
  - Dateisysteme bieten zu wenige Möglichkeiten, um diese Zugriffe zu synchronisieren
- Dateisysteme schützen nicht in ausreichendem Maß vor Datenverlust im Fall von Systemabstürzen und Defekten
- Dateisysteme bieten nur unflexible Zugriffskontrolle (Datenschutz)

Zusammenfassung

- Probleme von Dateien:
  - Logische Datenabhängigkeit
  - Physische Datenabhängigkeit
  - Redundanz
  - Keine Synchronisation für Mehrbenutzerbetrieb
  - Kein ausreichender Schutz vor Datenverlust
  - Kein ausreichender Datenschutz
  - ...

Von Dateien zu Datenbanken

- Um diese Probleme mit einheitlichem Konzept zu behandeln, setzt man ***Datenbanken*** ein:

Mit Dateisystem:

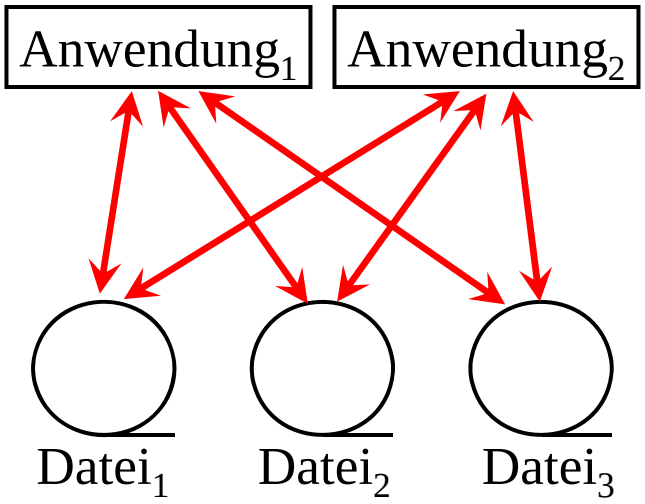

Mit Datenbanksystem:

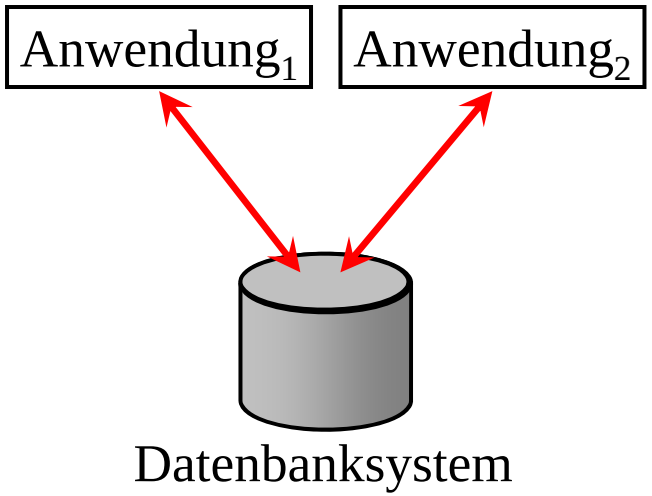

Komponenten eines DBS

Man unterscheidet zwischen...

DB-Anwendungen
(kommunizieren mit DBMS)

DBS: Datenbanksystem
(DB + DBMS)

DBMS: Datenbank-Management-System
(Software zur Verwaltung)

DB: Datenbank
(eigentliche Datensammlung)

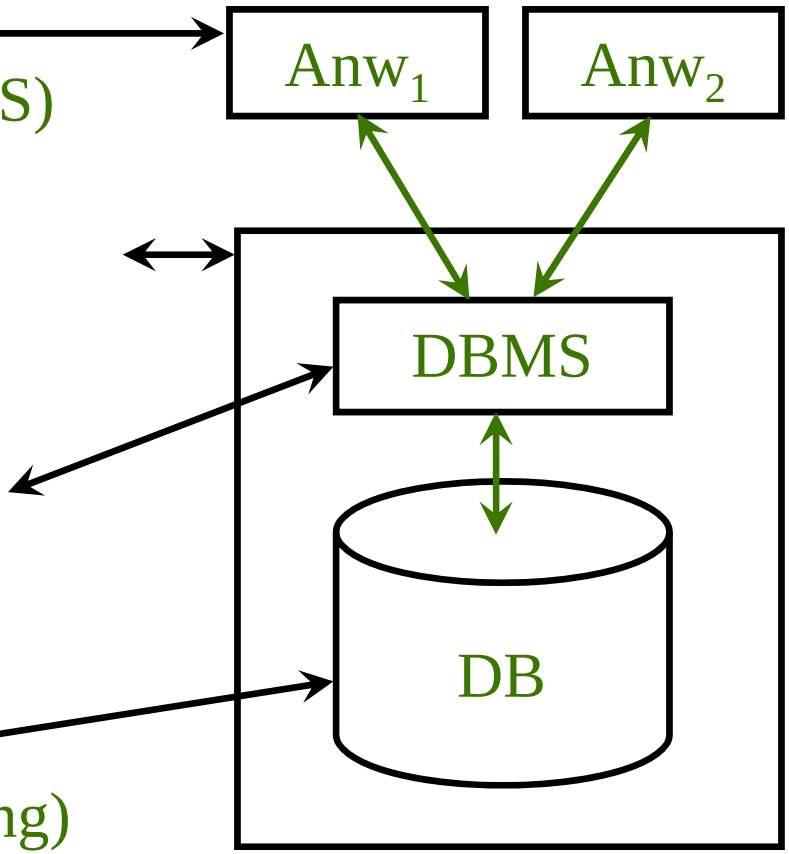

Typische Einsatzbereiche

- Im betriebswirtschaftlichen Bereich:
  - Banken (Kontoführung)
  - Buchhaltung und Rechnungswesen
  - Flugbuchungssysteme
  - Telefongesellschaften (Abrechnung)
  - Lagerverwaltung
- Im technisch-wissenschaftlichen Bereich:
  - CAD/CAM/CIM
  - Medizin
  - Molekularbiologie (Gendatenbanken)

Aufgaben eines DBS

Primäre Aufgabe eines DBS ist die ...

- Beschreibung
- Speicherung und Pflege
- und Wiedergewinnung

umfangreicher Datenmengen, die von verschiedenen Anwendungsprogammen dauerhaft (persistent) genutzt werden

Anforderungen an ein DBS

Liste von 9 Anforderungen (Edgar F. Codd, 1982)

- Integration
  Einheitliche Verwaltung aller von Anwendungen benötigten Daten.
  Redundanzfreie Datenhaltung des gesamten Datenbestandes
- Operationen
  Operationen zur Speicherung, zur Recherche und zur Manipulation der Daten müssen vorhanden sein
- Data Dictionary
  Ein Katalog erlaubt Zugriffe auf die Beschreibung der Daten
- Benutzersichten
  Für unterschiedliche Anwendungen unterschiedliche Sicht auf den Bestand
- Konsistenzüberwachung
  Das DBMS überwacht die Korrektheit der Daten bei Änderungen

Anforderungen an ein DBS

- Zugriffskontrolle
  Ausschluss unautorisierter Zugriffe
- Transaktionen
  Zusammenfassung einer Folge von Änderungsoperationen zu einer Einheit, deren Effekt bei Erfolg permanent in DB gespeichert wird
- Synchronisation
  Arbeiten mehrere Benutzer gleichzeitig mit der Datenbank dann vermeidet das DBMS unbeabsichtigte gegenseitige Beeinflussungen
- Datensicherung
  Nach Systemfehlern (d.h. Absturz) oder Medienfehlern (defekte Festplatte) wird die Wiederherstellung ermöglicht (im Ggs. zu Datei-Backup Rekonstruktion des Zustands der letzten erfolgreichen TA)

Inhalte von Datenbanken

Man unterscheidet zwei Ebenen:

- Intensionale Ebene: ***Datenbankschema***
  - beschreibt ***möglichen*** Inhalt der DB
  - Struktur- und Typinformation der Daten (Metadaten)
  - Art der Beschreibung vorgegeben durch Datenmodell
  - Änderungen möglich, aber selten (Schema-Evolution)
- Extensionale Ebene: ***Ausprägung der Datenbank***
  - ***tatsächlicher*** Inhalt der DB (DB-Zustand)
  - Objektinformation, Attributwerte
  - Struktur vorgegeben durch Datenbankschema
  - Änderungen häufig (Flugbuchung: 10000 TA/min)

Inhalte von Datenbanken

Einfaches Beispiel:

- Schema:

- DB-Zustand:

Franklin	Aretha	1942
Ritchie	Lionel	1949

- Nicht nur DB-Zustand, sondern auch DB-Schema wird in DB gespeichert.
- Vorteil: Sicherstellung der Korrektheit der DB

Vergleich bzgl. des Schemas

- Schema in Datenbanken
  - Explizit modelliert (Textdokument oder grafisch)
  - In Datenbank abgespeichert
  - Benutzer kann Schema-Informationen auch aus der Datenbank ermitteln: ***Data Dictionary***, ***Metadaten***
  - DBMS überwacht Übereinstimmung zwischen DB-Schema und DB-Zustand
  - Änderung des Schemas wird durch DBMS unterstützt (Schema-Evolution, Migration)

Vergleich bzgl. des Schemas

- Schema in Dateien
  - Kein Zwang, das Schema explizit zu modellieren
  - Schema implizit in den Prozeduren zum Ein-/Auslesen
  - Schema gehört zur Programm-Dokumentation
  - oder es muss aus Programmcode herausgelesen werden.
    Hacker-Jargon: RTFC (read that f***ing code)
  - Fehler in den Ein-/Auslese-Prozeduren können dazu führen, dass gesamter Datenbestand unbrauchbar wird:

F	r	a	n	k	l	i	n			A	r	e	t	h	a		1	9	4	2	R
i	t	c	h	i	e				L	i	o	n	e	l			1	9	4	9	

  - Bei Schema-Änderung müssen Migrations-Prozeduren programmiert werden, um bestehende Dateien auf das neue Format umzustellen

Datenmodelle

- Formalismen zur Beschreibung des DB-Schemas
  - Objekte der Datenbank
  - Beziehungen zwischen verschiedenen Objekten
  - Integritätsbedingungen
- Verschiedene Datenmodelle unterscheiden sich in der Art und Weise, wie Objekte und Beziehungen dargestellt werden
- Die wichtigsten Datenmodelle sind:
  - Hierarchisches Datenmodell
  - Netzwerk-Datenmodell
  - Relationales Datenmodell
  - Objektorientiertes Datenmodell
  - Objekt-relationales Datenmodell

Produkte

- (Objekt-) Relationale Datenbanken:
  - Oracle (Marktführer)
  - Informix
  - IBM DB2
  - Microsoft SQL Server
  - MySQL (Open Source)
  - PostgreSQL (Open Source)
  - keine vollwertigen Datenbanksysteme: dBase, FoxPro
- Nicht-Relationale Datenbanken
  - IMS: Hierarchisches Datenbanksystem (IBM)
  - UDS: Netzwerk-Datenbanksystem (Siemens)
  - Verschiedene objektorientierte DB-Produkte

Verwendung eines DBS

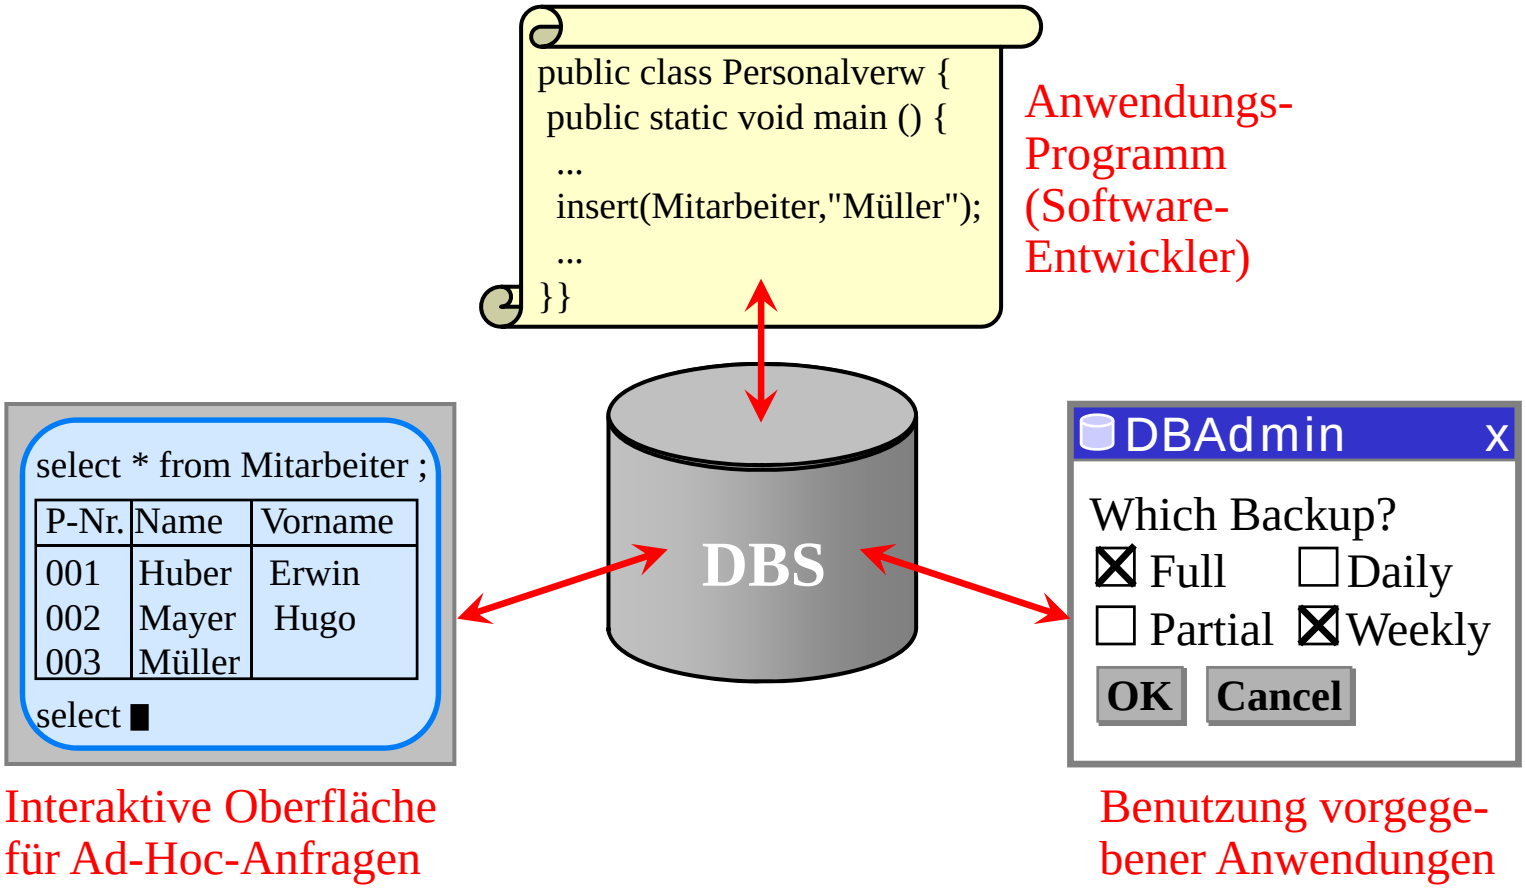

Aus technischer Sicht ist die interaktive Oberfläche ebenfalls ein Anwendungsprogramm, das auf dem DBS aufsetzt

Datenbank-Sprachen

- Data Definition Language (DDL)
  - Deklarationen zur Beschreibung des Schemas
  - Bei relationalen Datenbanken:
    Anlegen und Löschen von Tabellen, Integritätsbedingungen usw.

- Data Manipulation Language (DML)
  - Anweisungen zum Arbeiten mit den Daten in der Datenbank (Datenbank-Zustand)
  - lässt sich weiter unterteilen in Konstrukte
    - zum reinen Lesen der DB (Anfragesprache)
    - zum Manipulieren (Einfügen, Ändern, Löschen) des Datenbankzustands

Datenbank-Sprachen

- SQL (Structured Query Language)
  - ***DIE*** Anfragesprache für relationale Datenbanksysteme
  - Enthält DDL und DML Konstrukte
  - Typischerweise interaktiv (über DB-Oberfläche) als auch aus einem Programm heraus aufrufbar (z.B. aus Java mittels JDBC)
  - Entwickelt seit 1974 bei IBM, erster Standard 1986
  - Beispiel:
    - Anlegen einer Datenbank

      CREATE DATABASE <DBName>;

    - Löschen einer Datenbank

      DROP DATABASE <DBName>;

  - Details später …

Architektur eines DBS

Drei-Ebenen-Architektur zur Realisierung von

- **physischer**
- **und logischer**

Datenunabhängigkeit (nach ANSI/SPARC)

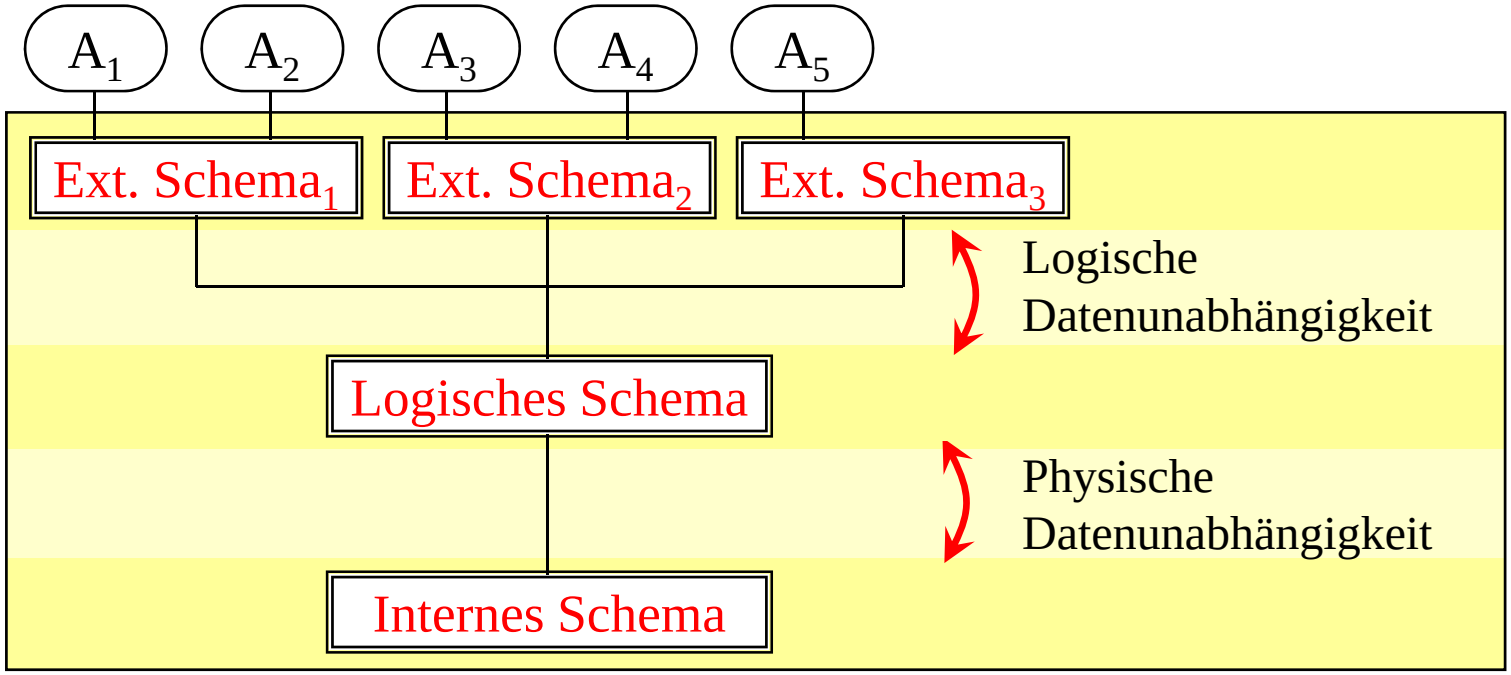

Konzeptionelle Ebene

- Logische Gesamtsicht *aller* Daten der DB
  unabhängig von den einzelnen Applikationen
- Niedergelegt in konzeptionellem (logischem) Schema
- Ergebnis des (logischen) Datenbank-Entwurfs
  (siehe Kapitel 6)
- Beschreibung aller Objekttypen und Beziehungen
- Keine Details der Speicherung
- Formuliert im Datenmodell des Datenbanksystems
- Spezifiziert mit Hilfe einer Daten-Definitionssprache (Data Definition Language, DDL)

Externe Ebene

- Sammlung der individuellen Sichten aller Benutzer- bzw. Anwendungsgruppen in mehreren externen Schemata
- Ein Benutzer soll keine Daten sehen, die er nicht sehen will (Übersichtlichkeit) oder nicht sehen soll (Datenschutz)
  - Beispiel: Das Klinik-Pflegepersonal benötigt andere Aufbereitung der Daten als die Buchhaltung
- Datenbank wird damit von Änderungen und Erweiterungen der Anwenderschnittstellen abgekoppelt (logische Datenunabhängigkeit)

Interne Ebene

- Das interne Schema beschreibt die systemspezifische Realisierung der DB-Objekte (physische Speicherung), z.B.
  - Aufbau der gespeicherten Datensätze
  - Indexstrukturen wie z.B. Suchbäume
- Das interne Schema bestimmt maßgeblich das Leistungsverhalten des gesamten DBS
- Die Anwendungen sind von Änderungen des internen Schemas nicht betroffen (physische Datenunabhängigkeit)