Prof. Dr. S. Deßloch
AG Heterogene Informationssysteme
Zi. 36/329, Tel.: 0631-205-3275
E-Mail: dessloch@informatik.uni-kl.de
http://wwwdbis.informatik.uni-kl.de/

Datenbankanwendung

Wintersemester 2002/2003

Universität Kaiserslautern
Fachbereich Informatik
Postfach 3049
67653 Kaiserslautern

Vorlesung:

Ort: 48 - 208

Zeit: Mo., 10.00 - 11.30 Uhr

und

Ort: 48 - 210

Zeit: Mi., 11.45 - 13.15 Uhr

Übung:

Ort: 32 - 439

Zeit: Do., 15.30 - 17.00 Uhr

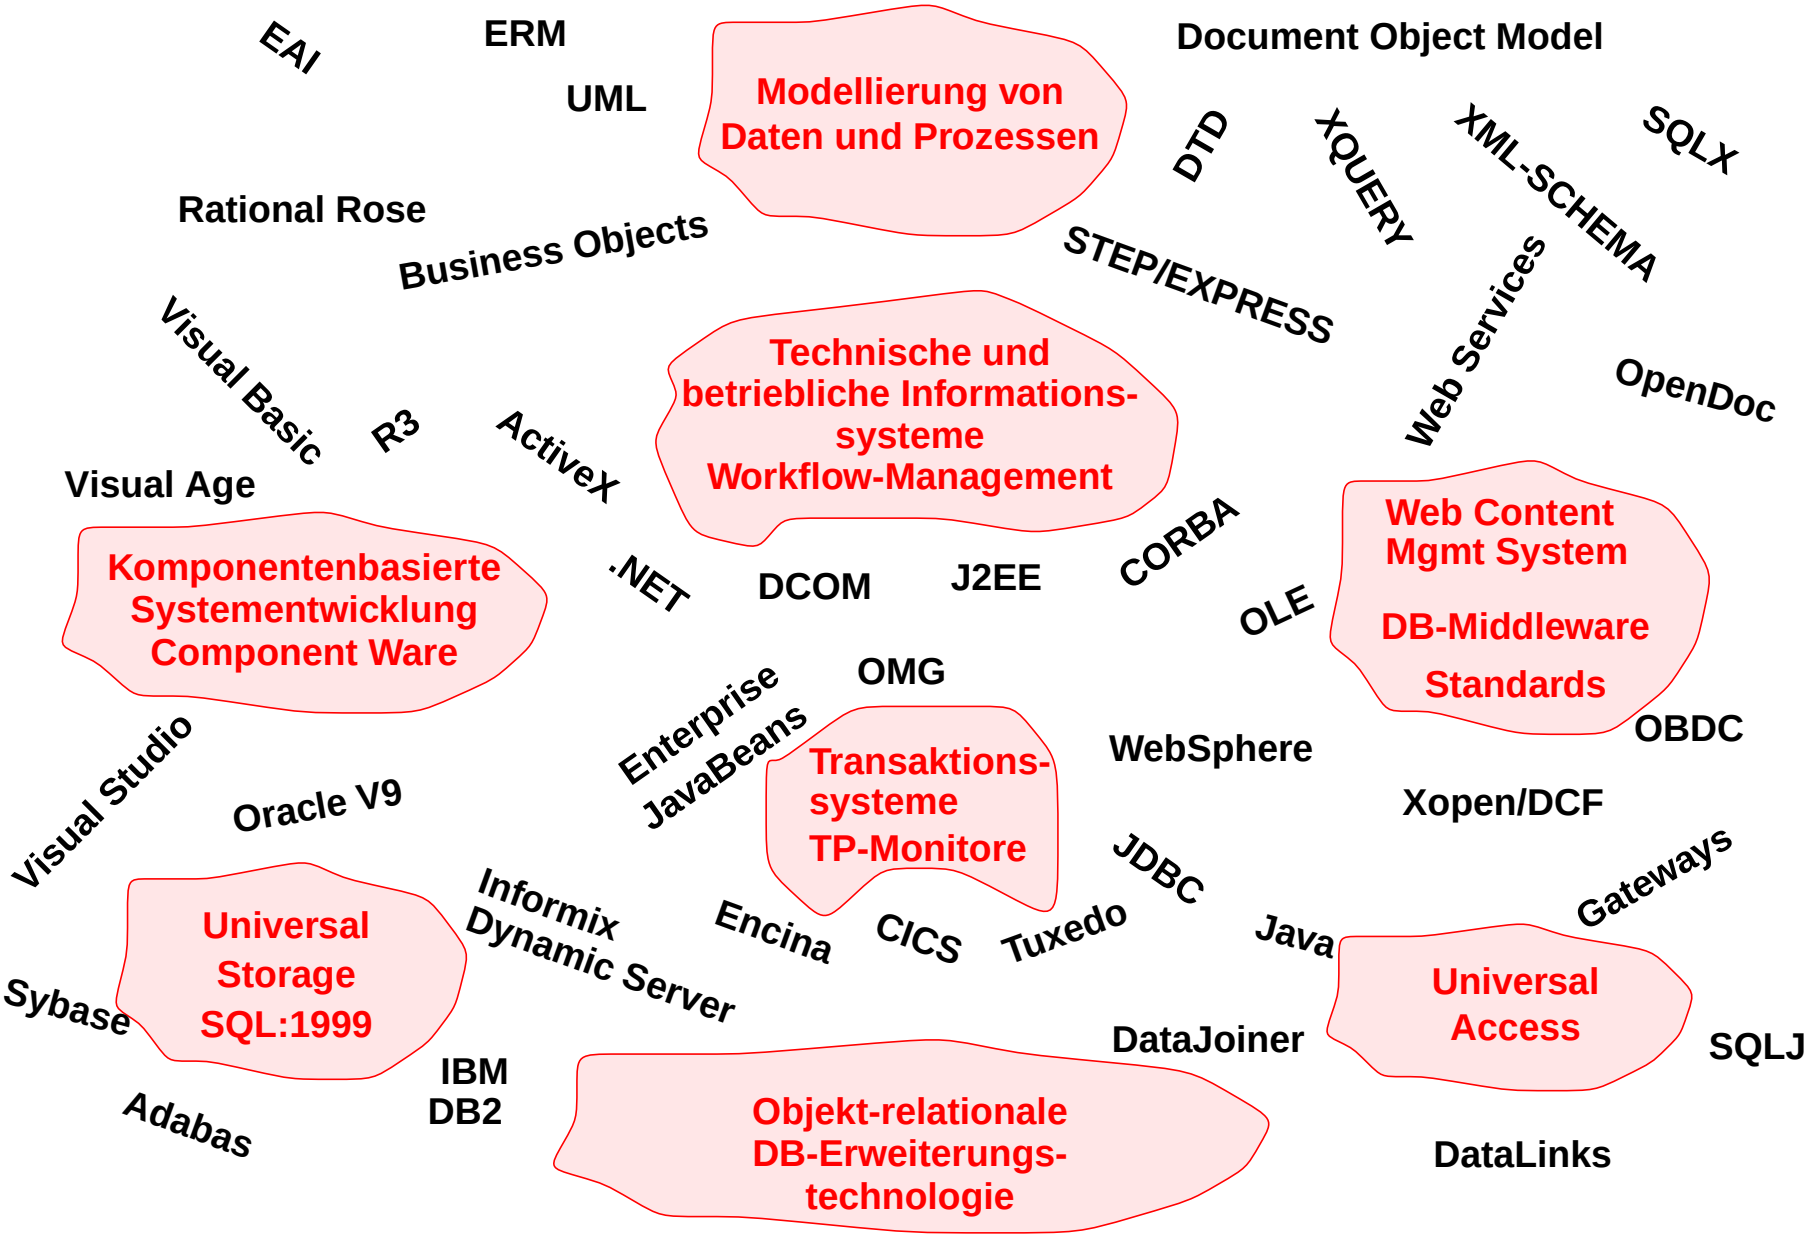
EAI
ERM
UML
Modellierung von Daten und Prozessen
Document Object Model
DTD
XQUERY
XML-SCHEMA
SQLX
Rational Rose
Business Objects
STEP/EXPRESS
Web Services
OpenDoc
Visual Basic
R3
ActiveX
Technische und betriebliche Informations-systeme Workflow-Management
Visual Age
Komponentenbasierte Systementwicklung Component Ware
.NET
DCOM
J2EE
CORBA
OLE
Web Content Mgmt System
DB-Middleware
Standards
OMG
Enterprise JavaBeans
Transaktions-systeme TP-Monitore
WebSphere
OBDC
Visual Studio
Oracle V9
Xopen/DCF
JDBC
Gateways
Informix Dynamic Server
Encina
CICS
Tuxedo
Java
Universal Storage SQL:1999
Sybase
Universal Access
SQLJ
DataJoiner
IBM DB2
Adabas
Objekt-relationale DB-Erweiterungs-technologie
DataLinks

Ziele

- **Vermittlung von Grundlagen- und Methodenwissen[1] zur Anwendung von Datenbanksystemen; Erwerb von Fähigkeiten und Fertigkeiten für DB-Administrator und DB-Anwendungsentwickler**
  - Entwurf, Aufbau und Wartung von Datenbanken, insbesondere auf der Basis von
    - Relationenmodell und SQL
    - objektorientierten und objekt-relationalen Datenmodellen mit Bezug auf die Standards ODMG und SQL:1999
  - Sicherung der Abläufe von DB-Programmen
    - Transaktionsverwaltung, Synchronisation, Fehlerbehandlung
    - Semantische Integrität, aktive DB-Mechanismen
    - Datenschutz und Zugriffskontrolle
  - Beschreibung und Analyse von wichtigen DB-Anwendungen

- **Voraussetzungen für Übernahme von Tätigkeiten:**
  - Entwicklung von datenbankgestützten Anwendungen
  - Nutzung von Datenbanken unter Verwendung von (interaktiven) Datenbanksprachen
  - Systemverantwortlicher für Datenbanksysteme, insbesondere Unternehmens-, Datenbank-, Anwendungs- und Datensicherungsadministrator

1.Grundlagenwissen ist hochgradig allgemeingültig und nicht von bestimmten Methoden abhängig. Die Halbwertzeit ist sehr hoch. Methodenwissen muß ständig an die aktuelle Entwicklung angepaßt werden. In der Informatik haben sich die entscheidenden Methoden alle 8-10 Jahre erheblich geändert. Werkzeugwissen ist methodenabhängig. Werkzeuge haben in der Informatik oft nur eine Lebensdauer von 2-3 Jahren.

ÜBERSICHT (vorl.)

0. Übersicht und Motivation

- Datenstrukturen und Datenbanken
- Voraussetzungen für die Vorlesung

1. Anforderungen und Beschreibungsmodelle

- Anforderungen an DBS
- Aufbau von DBS
- Beschreibungsmodelle
  (Fünf-Schichten-Modell, Drei-Ebenen-Beschreibungsarchitektur)

2. Logischer DB-Entwurf

- Konzeptioneller DB-Entwurf
- Normalformenlehre (1NF, 2NF, 3NF, 4NF)
- Synthese von Relationen

3. Tabellen und Sichten

- Datendefinition von SQL-Objekten
- Schemaevolution
- Indexstrukturen
- Sichtenkonzept

4. Anwendungsprogrammier-Schnittstelle

- Kopplung mit einer Wirtssprache
- Übersetzung von DB-Anweisungen
- Eingebettetes / Dynamisches SQL, PSM
- CLI, JDBC und SQLJ

ÜBERSICHT (2)

5. Transaktionsverwaltung

- Transaktionskonzept
- Ablauf von Transaktionen
- Commit-Protokolle

6. Serialisierbarkeit

- Anomalien beim Mehrbenutzerbetrieb
- Theorie der Serialisierbarkeit
- Klassen von Historien

7. Synchronisation

- Sperrverfahren
  (hierarchische Verfahren, Deadlocks)
- Konsistenzebenen
- Optimierungen
  (Optimistische Verfahren, Prädikatssperren, Mehrversions- und Zeitstempelverfahren, spezielle Protokolle)
- Leistungsbewertung und Lastkontrolle

8. Logging und Recovery

- Fehlermodell und Recovery-Arten
- Logging-Strategien
- Recovery-Konzepte - Abhängigkeiten
- Sicherungspunkte
- Transaktions-, Crash- und Medien-Recovery

ÜBERSICHT (3)

9. Integritätskontrolle und aktives Verhalten

- Semantische Integritätskontrolle
- Regelverarbeitung in DBS
- Trigger-Konzept von SQL
- Definition und Ausführung von ECA-Regeln

10. Datenschutz und Zugriffskontrolle

- Technische Probleme des Datenschutzes
- Konzepte der Zugriffskontrolle
- Zugriffskontrolle in SQL
- Sicherheitsprobleme in statistischen DBs

11. Objektorientierung und Datenbanken

- Beschränkungen klassischer Datenmodelle
- Grundkonzepte der Objektorientierung

12. SQL:1999 - Neue Funktionalität

- Einführung in ein OR-Datenmodell (SQL:1999)
- ORDBS: Anforderungen, Architekturvorschläge
- Erhöhung der Anfragemächtigkeit, Rekursion

ÜBERSICHT (4)

13. Große Objekte

- Anforderungen und Verarbeitung mit SQL
- Lokator-Konzept
- Speicherungsstrukturen, . . .

14. Erweiterbares Typsystem

- Umbenannte Typen
- Benutzerdefinierte Datentypen/Funktionen
- Typ- und Tabellenhierarchien, . . .
- Konstruierte Typen

15. Anwendungsklassen

- Transaktionssysteme
- Data Warehouse
- Data Mining
- WWW-Anbindung von Datenbanken

LITERATURLISTE

Chamberlin, D.: DB2 Universal Database, Addison-Wesley Publ. Comp., 1999

Date, C. J.: An Introduction to Database Systems, Addison-Wesley Publ. Comp., Reading, Mass., 7th Edition, 2000

Härder, T., Rahm, E.: Datenbanksysteme – Konzepte und Techniken der Implementierung, Springer-Verlag, Berlin, 2001 (Es sind Hörerscheine erhältlich)

Heuer, A., Saake, G.: Datenbanken – Konzepte und Sprachen, 2. Auflage, Int. Thompson Publ. Comp., 2000

Kemper, A., Eickler, A.: Datenbanksysteme – Eine Einführung, 4. Auflage, Oldenbourg-Verlag, 2001

Melton, J., Simon, A. R.: SQL:1999 - Understanding Relational Language Components, Morgan Kaufmann Publishers, San Francisco, CA, 2002

Ramakrishnan, R.: Database Management Systems, McGraw-Hill, Boston, 1998

Weikum, G., Vossen, G.: Transactional Information Systems, Morgan Kaufmann Publishers, San Francisco, CA, 2002

ZEITSCHRIFTEN:

TODS Transactions on Database Systems, ACM Publikation (vierteljährlich)

Information Systems Pergamon Press (6-mal jährlich)

The VLDB Journal (vierteljährlich)

Informatik - Forschung und Entwicklung (vierteljährlich)

TAGUNGSBÄNDE:

SIGMOD Tagungsband, jährliche Konferenz der ACM Special Interest Group on Management of Data

VLDB Tagungsband, jährliche Konferenz „Very Large Data Bases“

IEEE Tagungsband, jährliche Konferenz „Int. Conf. on Data Engineering“

GI Tagungsbände der Tagungen der Gesellschaft für Informatik, Tagungen innerhalb des Fachbereichs “Datenbanken und Informationssysteme”

und viele weitere Konferenzreihen

Datenstrukturen ?

- **Bisher bekannte Datenstrukturen**
  - Felder (Reihungen, Arrays, ...)
  - Verbunde (Tupel, Sätze, Records, ...)
  - Listen
  - Graphen
  - Bäume

  → bisher im **Hauptspeicher**,
  d. h. Bestand nur für die Dauer einer Programmausführung
  („transiente“ Daten)

- **hier nun neue Aspekte:**
  Nutzung von Hintergrundspeicher und neuen Operationen
  - **Persistenz:**
    Werte bleiben über Programmende, Sitzungsende,
    Betriebssystem-Uptime, Rechnereinschaltung, ...
    hinaus erhalten
  - andere Arten des Zugriffs: Lese- und Schreiboperationen,
    in vorgegebenen Einheiten von Blöcken und Sätzen

    → Strukturen und zugehörige Algorithmen (Suchen, Sortieren),
    die im Hauptspeicher optimal sind, sind es auf Sekundärspeicher
    nicht unbedingt!
  - gezielter, wertabhängiger Zugriff auch auf sehr große Datenmengen
  - umfangreiche Attributwerte (z. B. Bilder, Texte)

Datenmodelle ?

- **Mengen von Konstruktoren**

  zur (abstrakten) Erzeugung von Datenstrukturen
  mit darauf definierten Operatoren

  z. B. Tabellen (Relationen): Mengen von gleichartig strukturierten Tupeln

```
CREATE TABLE STUDENT
       (MATRIKELNUMMER      INTEGER,
       NACHNAME             VARCHAR(40),
       FBNUMMER             INTEGER,
       GEBURTSDATUM         CHAR(8),
       .... )

CREATE TABLE FACHBEREICH
       (FBNUMMER            INTEGER,
       FBNAME               VARCHAR(20),
       DEKAN                PROF,
       .... )
```

  nicht nur ein einzelner Satz, sondern Menge

- **Wichtige Rolle von Beziehungen**

  in einigen Datenmodellen auch sehr spezielle Arten von **Beziehungen** zwischen Sätzen und/oder Tupeln: Hierarchien, Zusammensetzungen, funktionale Zuordnungen u.v.a.m.

- **Modellbegriff**

  vorgegebene Menge von (sprachlichen) Ausdrucksmitteln, mit denen Diskursbereich beschrieben (erfaßt) werden muß

  → auch Programmiersprachen und Betriebssysteme haben ein „Datenmodell“

Datenbanken ?

- **Große Datenmengen**
  - auch, aber **nicht immer** entscheidend

- **Übereinstimmung von Modell und Miniwelt**[1]
  - Genauigkeit der Abbildung und Erhaltung ihrer Integrität (Bedeutungstreue)
  - zeitgerechter und durch Integritätsbedingungen abgesicherter Änderungsdienst

- **Datenunabhängigkeit (der Anwendungen)**
  - Benutzung der Daten, ohne Details der systemtechnischen Realisierung zu kennen (abstraktes „Datenmodell“, z. B. Tabellen)
  - einfache Handhabung der Daten, mächtige Auswertungsoperationen

- **Offenheit der Daten für neue Anwendungen (Anwendungsneutralität der Speicherung)**
  - symmetrische Organisationsformen (keine Bevorzugung einer Verarbeitungs- und Auswertungsrichtung)
  - explizite Darstellung der Annahmen/Zusicherungen (nicht in den Anwendungsprogrammen verstecken)
  - Redundanzfreiheit aus der Sicht der Anwendung: keine wiederholte Speicherung in unterschiedlicher Form für verschiedene Anwendungen
  - Konsistenzüberwachung durch das Datenbanksystem

---

1. Ein Datenbanksystem verwaltet Daten einer realen oder gedanklichen Anwendungswelt. Diese Daten gehen aus Informationen hervor, die stets aus den Sachverhalten und Vorgängen dieser Anwendungswelt durch gedankliche Abstraktionen (Abbilder, Modelle) gewonnen werden. Sie beziehen sich nur auf solche Aspekte des betrachteten Weltausschnitts, die für den Zweck der Anwendung relevant sind. Ein solcher Weltausschnitt wird auch als *Miniwelt* (Diskurswelt) bezeichnet.

Datenbanken ? (2)

- **Transaktionskonzept mit Garantie von ACID-Eigenschaften**
  - Atomizität (*atomicity*)
  - Konsistenz (*consistency*)
  - Isolation (*isolated execution*)
  - Dauerhaftigkeit (*durability*)

- **Ausfallsicherheit**
  - Aufzeichnung redundanter Daten im Normalbetrieb
  - Replikation von Datenstrukturen
  - Vorkehrungen für den Katastrophenfall
  - automatische Reparatur der Datenbestände nach Programm-, System- und Gerätefehlern
    - Rückgängigmachen unvollständiger Transaktionen, so daß sie wiederholt werden können
    - Wiederherstellen der Ergebnisse vollständiger Transaktionen, so daß sie nicht wiederholt werden müssen

- **Mehrbenutzerbetrieb**
  - gleichzeitiger (zeitlich eng verzahnter) Zugriff verschiedener Anwendungen und Benutzer auf gemeinsame Daten
  - Synchronisation, d. h. Vermeidung von Fehlern in der wechselseitigen Beeinflussung
  - Kooperation über gemeinsame Daten mit hohem Aktualitätsgrad

Verteilung von DBS und Dateien

- **Es gibt verschiedenartige Datenmodelle und die sie realisierenden DBS**
  - relational und objekt-relational (RDBS/ORDBS)
  - hierarchisch (DBS nach dem Hierarchiemodell)
  - netzwerkartig (DBS nach dem Codasyl-Standard)
  - objektorientiert (OODBS)

	1990	1995	2000
OODBS	1 %	2 %	3 %
RDBS/ORDBS	9 %	25 %	50 %
Cod. DBS	30 %	22 %	12 %
Hier. DBS	25 %	20 %	15 %
Flache Dateien	35 %	31 %	20 %
Gesamt	100 %	100 %	100 %

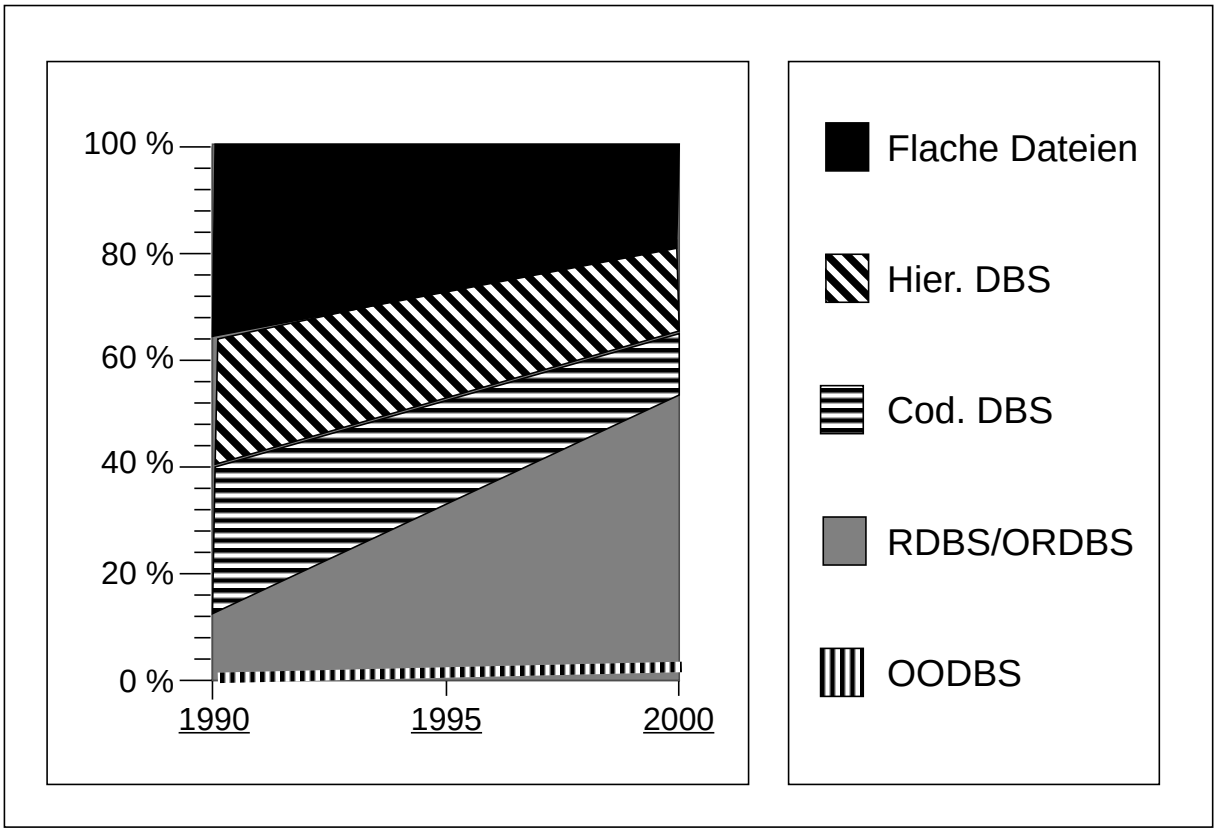

Voraussetzungen

- **Beherrschung von**
  - Informationsmodellen (erweitertes ER-Modell)
  - Relationenmodell und Relationenalgebra
  - SQL-92 als Standardsprache

- **Beispiel eines ER-Schemas**

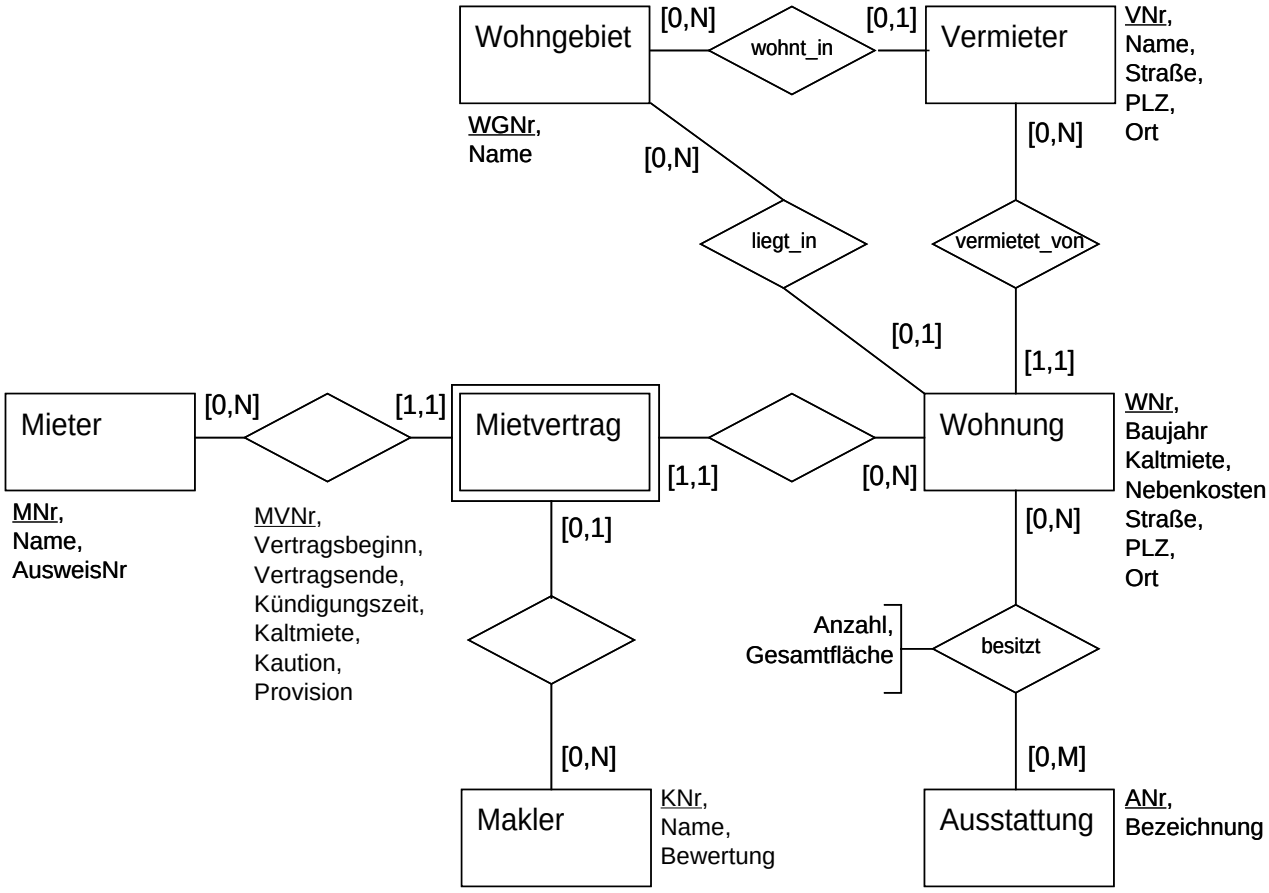

Voraussetzungen (2)

- **Zugehöriges SQL-Schema**

```
CREATE TABLE WOHNGEBIET (
       WGNR            WOHNGEBIETSNUMMER   PRIMARY KEY,
       NAME            CHAR(30)            NOT NULL);


CREATE TABLE VERMIETER (
       VNR             VERMIETERNUMMER     PRIMARY KEY,
       NAME            CHAR(30)            NOT NULL,
       STRASSE         CHAR(30),
       PLZ             POSTLEITZAHL,
       ORT             CHAR(30),
       WOHNT_IN        WOHNGEBIETSNUMMER,
       FOREIGN KEY (WOHNT_IN) REFERENCES WOHNGEBIET (WGNR));


CREATE TABLE WOHNUNG (
       WNR             WOHNUNGSNUMMER      PRIMARY KEY,
       BAUJAHR         INT                 DEFAULT 1800 NOT NULL
                                           CHECK (BAUJAHR >= 1800),
       KALTMIETE       INT                 NOT NULL,
       NEBENKOSTEN     INT                 NOT NULL,
       STRASSE         CHAR(30),
       PLZ             POSTLEITZAHL,
       ORT             CHAR(30),
       LIEGT_IN        WOHNGEBIETSNUMMER,
       VERMIETET_VON   VERMIETERNUMMER     NOT NULL,
       FOREIGN KEY (LIEGT_IN) REFERENCES WOHNGEBIET (WGNR),
       FOREIGN KEY (VERMIETET_VON) REFERENCES VERMIETER (VNR));


CREATE TABLE AUSSTATTUNG (
       ANR             AUSSTATTUNGSNUMMER  PRIMARY KEY,
       BEZEICHNUNG     CHAR(30)            NOT NULL);
/* Zur Ausstattung gehören z. B. Schlafzimmer, Bad, Balkon, usw. */
```

Voraussetzungen (3)

```
CREATE TABLE BESITZT (
       WNR            WOHNUNGSNUMMER,
       ANR            AUSSTATTUNGSNUMMER,
       ANZAHL         INT                DEFAULT 1 NOT NULL,
       GESAMTFLAECHE  INT                NOT NULL, /* In m^2 */
       PRIMARY KEY (WNR, ANR),
       FOREIGN KEY (WNR) REFERENCES WOHNUNG (WNR),
       FOREIGN KEY (ANR) REFERENCES AUSSTATTUNG (ANR));

CREATE TABLE MAKLER (
       KNR            MAKLERNUMMER       PRIMARY KEY,
       NAME           CHAR(30)           NOT NULL,
       BEWERTUNG      BEWERTUNGSSKALA);

CREATE TABLE MIETER (
       MNR            MIETERNUMMER       PRIMARY KEY,
       NAME           CHAR(30)           NOT NULL,
       AUSWEISNR      CHAR(30)           NOT NULL);

CREATE TABLE MIETVERTRAG (
       MVNR           MIETVERTRAGSNUMMER PRIMARY KEY,
       VERTRAGSBEGINN DATE               NOT NULL,
       VERTRAGSENDE   DATE               NOT NULL,
       KUENDIGUNGSZEIT INT               DEFAULT 90, /* In Tagen */
       KALTMIETE      INT                NOT NULL,
       KAUTION        INT                DEFAULT 3 NOT NULL,
       PROVISION      INT                DEFAULT 2 NOT NULL,
       /* Werte fuer Kaution und Provision seien n-Mal Kaltmiete */
       MNR            MIETERNUMMER       NOT NULL,
       WNR            WOHNUNGSNUMMER     NOT NULL,
       KNR            MAKLERNUMMER       DEFAULT NULL,
       FOREIGN KEY (MNR) REFERENCES MIETER (MNR) ON DELETE CASCADE,
       FOREIGN KEY (WNR) REFERENCES WOHNUNG (WNR) ON DELETE CASCADE,
       FOREIGN KEY (KNR) REFERENCES MAKLER (KNR)
                                          ON DELETE SET NULL);
```

Voraussetzungen (4)

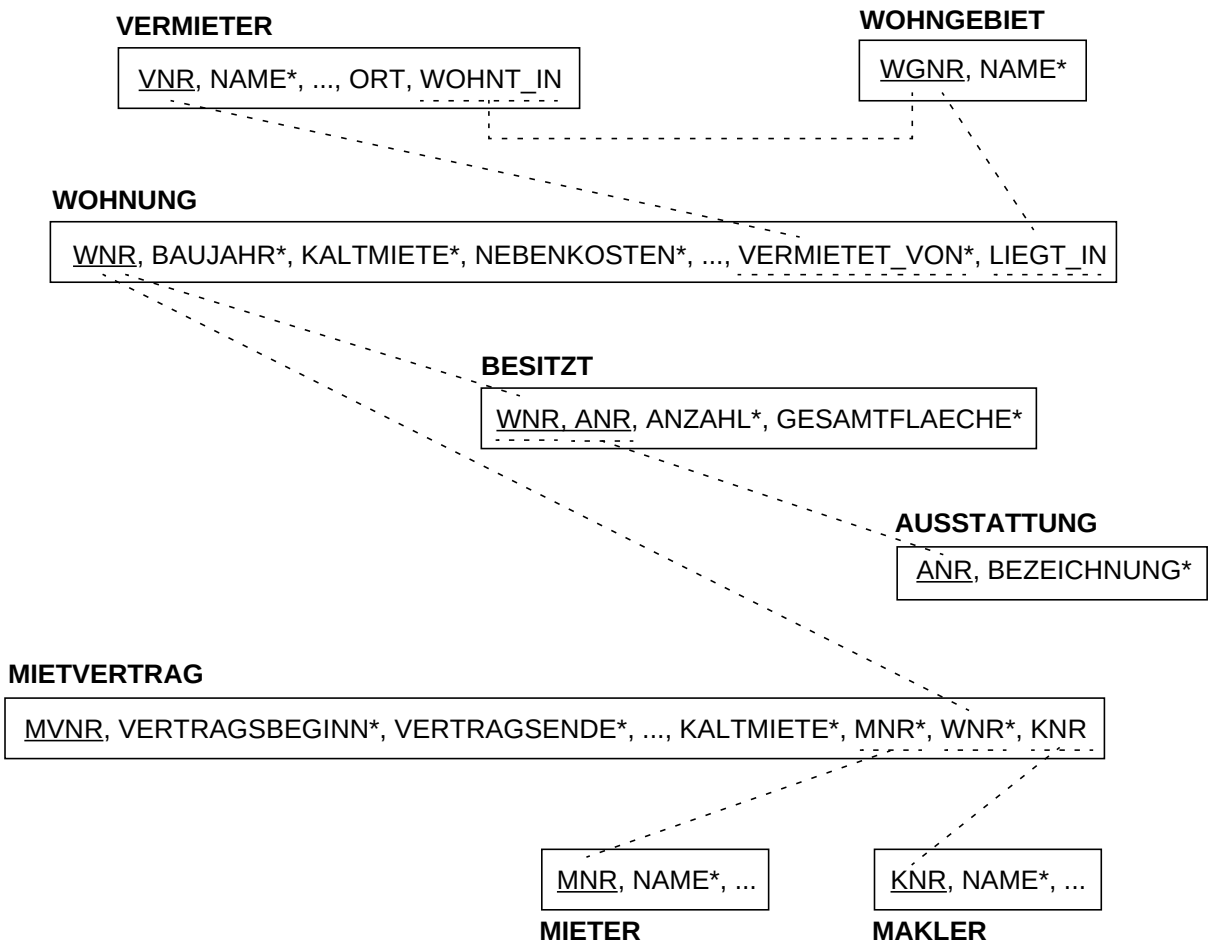

* = NOT NULL

Voraussetzungen (5)

- **Anfragen in SQL**

1. Lösche alle Vermieter, die keine einzige Wohnung vermieten und deren Wohngebiet unbekannt ist.

```
DELETE   FROM VERMIETER V
WHERE    NOT EXISTS
         (SELECT  *
          FROM    WOHNUNG W
          WHERE   W.VERMIETET_VON = V.VNR
         )
         AND     V.WOHNT_IN IS NULL
```

2. Erhöhe die Kaltmiete von Wohnungen, die später als 1990 gebaut wurden und im Uni-Wohngebiet in KL liegen, jeweils um 20% der zugehörigen Nebenkosten.

```
UPDATE   WOHNUNG W
SET      W.KALTMIETE = W.KALTMIETE + W.NEBENKOSTEN * 0.2
WHERE    W.BAUJAHR > 1990
AND      W.ORT = 'KL'
AND      EXISTS
         (SELECT  *
          FROM    WOHNGEBIET WG
          WHERE   WG.WGNR = W.LIEGT_IN
          AND     WG.NAME = 'Uni-Wohngebiet'
         )
```

3. Reduziere die Nebenkosten aller Wohnungen jeweils um 10%, die mindestens 2 Schlafzimmer oder eine Schlafzimmergesamtfläche von < 50 m^2 besitzen und deren Kaltmiete niedriger als ihre zugehörigen Nebenkosten ist.

```
UPDATE   WOHNUNG W
SET      W.NEBENKOSTEN = W.NEBENKOSTEN * 0.9
WHERE    W.KALTMIETE < W.NEBENKOSTEN
AND      EXISTS
         (SELECT  *
          FROM    BESITZT B, AUSSTATTUNG A
          WHERE   B.WNR = W.WNR
          AND     B.ANR = A.ANR
          AND     A.BEZEICHNUNG = 'Schlafzimmer'
          AND     (B.ANZAHL >= 2 OR B.GESAMTFLAECHE < 50)
         )
```

Voraussetzungen (6)

- **Anfragen in SQL**

4. Finde alle zur Zeit vermieteten Wohnungen, deren Kaltmiete größer ist als die Gesamtsumme der vom (einzelnen) Mieter zu zahlenden Kaltmieten.
   (Eine Wohnung kann mehrere gleichzeitig gültige Mietverträge haben (z. B. WG))

```
SELECT   W.*
FROM     WOHNUNG W
WHERE    W.KALTMIETE >
         (SELECT  SUM(MV.KALTMIETE)
          FROM    MIETVERTRAG MV
          WHERE   MV.WNR = W.WNR
          AND     MV.VERTRAGSBEGINN <= TODAY
          AND     MV.VERTRAGSENDE >= TODAY
         )
```

5. Finde alle Wohnungen mit ihrer Gesamtfläche, die ein Bad und wenigstens ein Ausstattungsmerkmal mit der Gesamtfläche von 30 m^2 oder größer besitzen.

```
SELECT   B.WNR, SUM(B.GESAMTFLAECHE)
FROM     BESITZT B
WHERE    EXISTS
         (SELECT  *
          FROM    AUSSTATTUNG A
          WHERE   B.ANR = A.ANR
          AND     A.BEZEICHNUNG = 'Bad'
         )
GROUP BY B.WNR
HAVING   MAX(B.GESAMTFLAECHE) >= 30
```

6. Finde alle Mieter, die zur Zeit mehr als eine Wohnung im Uni-Wohngebiet mieten.

```
SELECT   M.*
FROM     MIETER M
WHERE    1 <
         (SELECT  COUNT(*)
          FROM    MIETVERTRAG MV, WOHNUNG W, WOHNGEBIET WG
          WHERE   MV.MNR = M.MNR
          AND     MV.WNR = W.WNR
          AND     W.LIEGT_IN = WG.WGNR
          AND     WG.NAME = 'Uni-Wohngebiet'
          AND     MV.VERTRAGSBEGINN <= TODAY
          AND     MV.VERTRAGSENDE >= TODAY
         )
```

Voraussetzungen (7)

- **Anfragen in SQL**

7. Finde alle Wohnungen, die 3 Schlafzimmer und 2 Bäder besitzen.

In SQL:

```
SELECT   W.*
FROM     WOHNUNG W
WHERE    EXISTS
         (SELECT  *
          FROM    BESITZT B, AUSSTATTUNG A
          WHERE   B.WNR = W.WNR
          AND     B.ANR = A.ANR
          AND     A.BEZEICHNUNG = 'Schlafzimmer'
          AND     B.ANZAHL = 3
         )
AND      EXISTS
         (SELECT  *
          FROM    BESITZT B, AUSSTATTUNG A
          WHERE   B.WNR = W.WNR
          AND     B.ANR = A.ANR
          AND     A.BEZEICHNUNG = 'Bad'
          AND     B.ANZAHL = 2
         )
```

Wie läßt sich diese Anfrage ohne EXISTS-Prädikate ausdrücken?

8. Finde alle Wohnungen, die alle Ausstattungsmerkmale haben.

In SQL:

```
SELECT   W.*
FROM     WOHNUNG W
WHERE    NOT EXISTS
         (SELECT  *
          FROM    AUSSTATTUNG A
          WHERE   NOT EXISTS
                  (SELECT  *
                   FROM    BESITZT B,
                   WHERE   B.WNR = W.WNR
                   AND     B.ANR = A.ANR
                  )
         )
```

Alternative Formulierung: Finde alle Wohnungen, so daß es kein Ausstattungsmerkmal gibt, das die Wohnung nicht besitzt.

The Big Picture

WWW-basiertes Verarbeitungsmodell ... **Transaktions-verarbeitung** **Client/Server-Verarbeitungsmodell** ... **Objektorientiertes Verarbeitungsmodell**

Middleware und Componentware

Next-Generation DBMS

```
SELECT Unfall.Fahrer, Unfall.Vers-Nummer
FROM   Unfall, Autobahn
WHERE CONTAINS(Unfall.Bericht, "Schaden"
                    IN SAME SENTENCE AS
                    ("schwer" AND "vordere" AND "Stoßstange"))
      AND FARBE(Unfall.Foto, 'rot') > 0.6
      AND ABSTAND(Unfall.Ort, Autobahn.Ausfahrt) < miles (0.5)
      AND Autobahn.Nummer = A8;
```

Parallele und Verteilte DBS

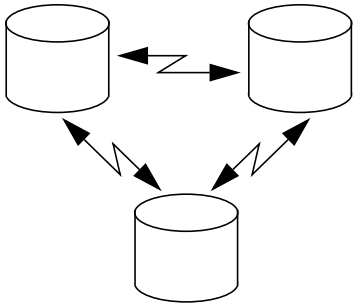

Aktive DBS

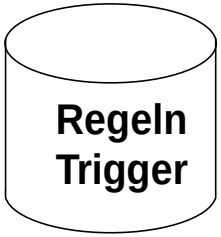

Multimedia-DBS

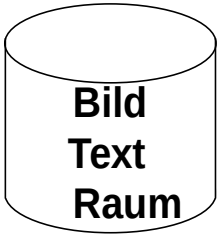

A Dozen Long-Term Systems Research Problems (J. Gray)[1]

1. **Scalability:**

   Devise a software and hardware architecture that scales up by a factor for 10^6. That is, an application's storage and processing capacity can automatically grow by a factor of a million, doing jobs faster (10^6 x speedup) or doing 10^6 larger jobs in the same time (10^6 x scaleup), just by adding more resources.

2. **The Turing Test:**

   Build a computer system that wins the imitation game at least 30% of the time.

3. **Speech to text:**

   Hear as well as a native speaker.

4. **Text to speech:**

   Speak as well as a native speaker.

5. **See as well as a person:**

   Recognize objects and motion.

6. **Personal Memex:**

   Record everything a person and hears, and quickly retrieve any item on request.

7. **World Memex:**

   Build a system that given a text corpus, can answer questions about the text and summarize the text as precisely and quickly as a human expert in that field. Do the same for music, art and cinema.

---

1. J. Gray is the recipient of th 1998 A. M. Turing Award. These problems, many related to database systems, are extracted from the text of the talk J. Gray gave in receipt of that award.

A Dozen Long-Term Systems Research Problems (J. Gray) (2)

8. **TelePresence:**

   Simulate being some other place retrospectively as an observer (TeleOberserver): hear and see as well as actually being there, and as well as a participant, and simulate being some other place as a participant (TelePresent): interacting with others and with the environment as though you are actually there.

9. **Trouble-Free Systems:**

   Build a system used by millions of people each day and yet administered and managed by a single part-time person.

10. **Secure System:**

    Assure that the system of problem 9 only services authorized users, service cannot be denied by unauthorized users, and information cannot be stolen (and prove it).

11. **AlwaysUp:**

    Assure that the system is unavailable for less than one second per hundred years -- 8 9's of availability (and prove it).

12. **Automatic Programmer:**

    Devise a specification language or user interface that:

    (a) makes it easy for people to express designs (1,000x easier),

    (b) computers can compile, and

    (c) can describe all applications (is complete).

    The system should reason about application, asking questions about exception cases and incomplete specification. But it should not be onerous to use.