Prof. Dr.-Ing. Dr. h. c. Theo Härder
AG Datenbanken und Informationssysteme
Zi. 36/330, Tel.: 0631-205-4030
E-Mail: haerder@informatik.uni-kl.de
http://wwwdvs.informatik.uni-kl.de/

# Datenbankanwendung

Wintersemester 2003/2004

TU 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: 13–222**

**Zeit: Do., 15.30–17.00 Uhr**



## Weltbild des Lehrgebietes Datenverwaltungssysteme

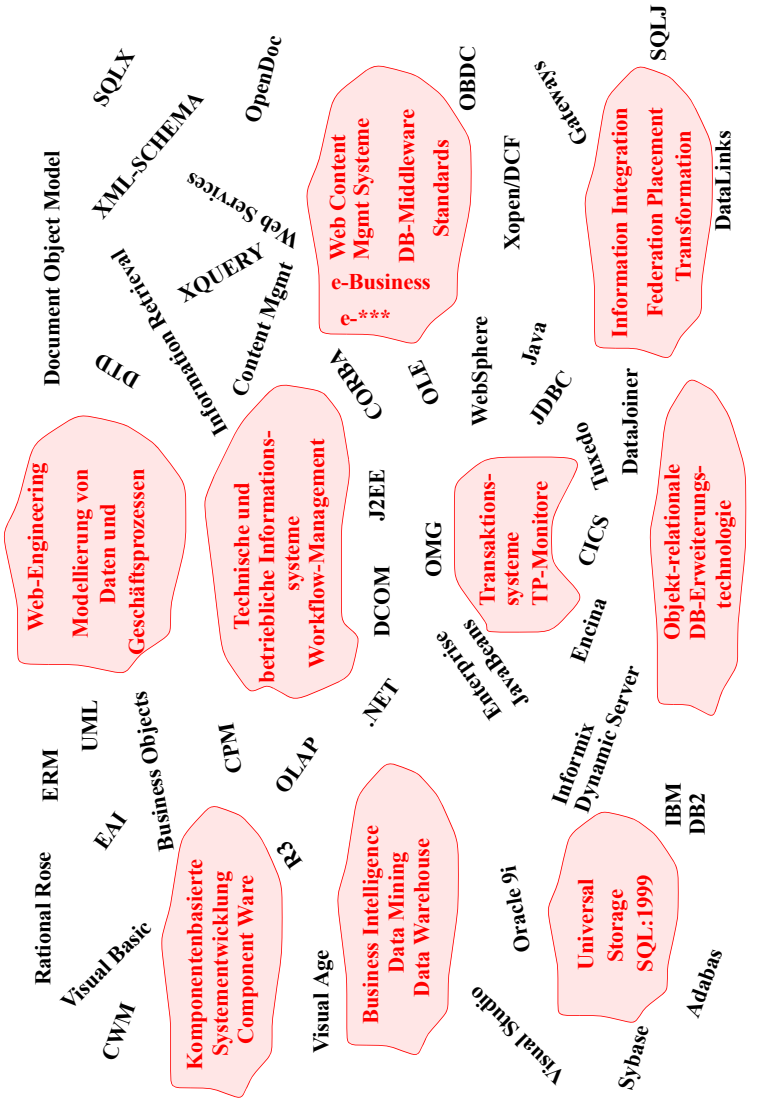

# Ziele

- **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 sowie Programmierung und Übersetzung von DB-Programmen, 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 Klassen wichtiger DB-Anwendungen wie Transaktionssysteme, Data-Warehouse- und Data-Mining-Systeme

- **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.)

# ÜBERSICHT (2)

## 5. Transaktionsverwaltung

- Transaktionskonzept
- Ablauf von Transaktionen
- Commit-Protokolle

## 6. Serialisierbarkeit

- Anomalien beim Mehrbenutzerbetrieb
- Theorie der Serialisierbarkeit
  - Final-State-Serialisierbarkeit, Sichtenserialisierbarkeit
  - Konfliktserialisierbarkeit
- Klassen von Historien

## 7. Synchronisation

- Sperrverfahren
  (hierarchische Verfahren, Deadlocks)
- Konsistenzebenen
- Optimierungen
  (Optimistische Verfahren, Prädikatssperren, Mehrversions- und Zeitstempelverfahren, Objektsperren, 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 Datenbanken

## 11. Objektorientierung und Datenbanken

- Beschränkungen klassischer Datenmodelle
- Grundkonzepte der Objektorientierung
- SQL:1999 – Neue Funktionalität
  - ORDBS: Anforderungen, Architekturvorschläge
  - Erhöhung der Anfragemächtigkeit, Rekursion

## 12. Große Objekte

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

## 13. Anwendungsklassen

- Transaktionssysteme
- Data Warehouse
- Data Mining
- . . .

# LITERATURLISTE


*Elmasri, R., Navathe, S. B.:* Grundlagen von Datenbanksystemen, 3. Auflage, Pearson Studium, 2002

*Garcia-Molina, H., Ullman, J.D., Widom, J.:* Database Systems – The Complete Book, Prentice Hall, Upper Saddle River, NJ, 2002

*Härder, T., Rahm, E.:* Datenbanksysteme – Konzepte und Techniken der Implementierung, Springer-Verlag, Berlin, 2001

*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

*Lewis, P. M., Bernstein, A., Kifer, M.:* Databases and Transaction Processing – An Application-Oriented Approach, Addison-Wesley, 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:

*ACM TODS* Transactions on Database Systems, ACM Publikation (vierteljährlich)

*Information Systems* Pergamon Press (6-mal jährlich)

*The VLDB Journal* VLDB Foundation (vierteljährlich)

*Informatik – Forschung und Entwicklung* Springer Verlag (vierteljährlich)

*ACM Computing Surveys* ACM-Publikation (vierteljährlich)

## TAGUNGSBÄNDE:

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

*VLDB* Tagungsbände, jährliche Konferenz „Very Large Data Bases“

*ICDE* Tagungsbände, jährliche Konferenz „Int. Conf. on Data Engineering“

*BTW* Tagungsbände der alle 2 Jahre stattfindenden Tagungen „Datenbanksysteme für Business, Technologie und Web“ der GI, und weitere Tagungen innerhalb des GI-FB „DBIS“

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, 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[2]
  - umfangreiche Attributwerte (z. B. Bilder, Texte)
  - Homogenisierung und Verarbeitung der im Web verfügbaren Daten[3]

---

2. 1 Gigabyte (GByte) = 1,000 Megabytes = $10^9$ Bytes
   1 Terabyte (TByte) = 1,000 Gigabytes
   1 Petabyte (PByte) = 1,000 Terabytes
   1 Exabyte (EByte) = 1,000 Petabytes
   1 Zettabyte (ZByte) = 1,000 Exabytes
   1 Yottabyte (YByte) = 1,000 Zettabytes

3. Schätzungen:
   How much data is out there?
   300 PByte online, 8 EByte offline, 200 EByte analog data (audio, video, etc.)

## 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**[4]
  - 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

4. 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**
  - Atomarität (*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)

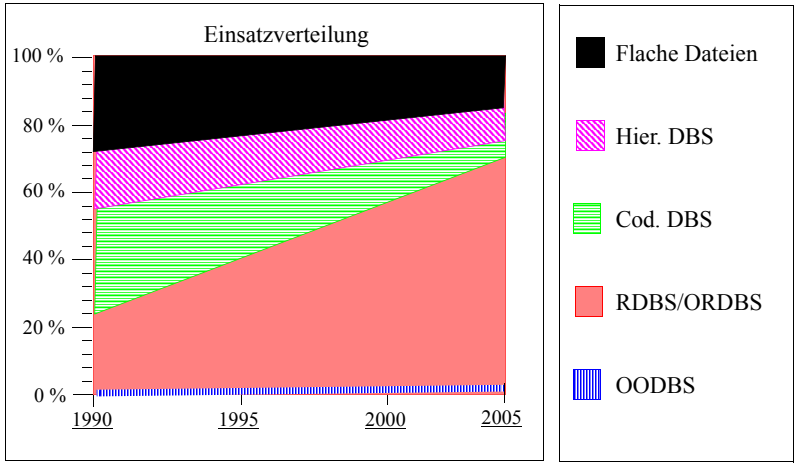


- **Künftige DBS**
  - Aufstellung berücksichtigt nur strukturierte Daten. 85% der weltweit verfügbaren Daten aber sind semi- oder unstrukturiert (Internet, wiss. Aufzeichnungen und Experimente usw.)
  - SQL-XML-DBS, XML-SQL-DBS native XML-DBS

- **Voraussetzung für die Vorlesung: Beherrschung von**
  - Informationsmodellen (erweitertes ER-Modell)
  - Relationenmodell und Relationenalgebra
  - SQL-92 als Standardsprache

# Überblick über die wichtigsten Datenmodelle

- **Entity/Relationship-Diagramm der Beispiel-Miniwelt**

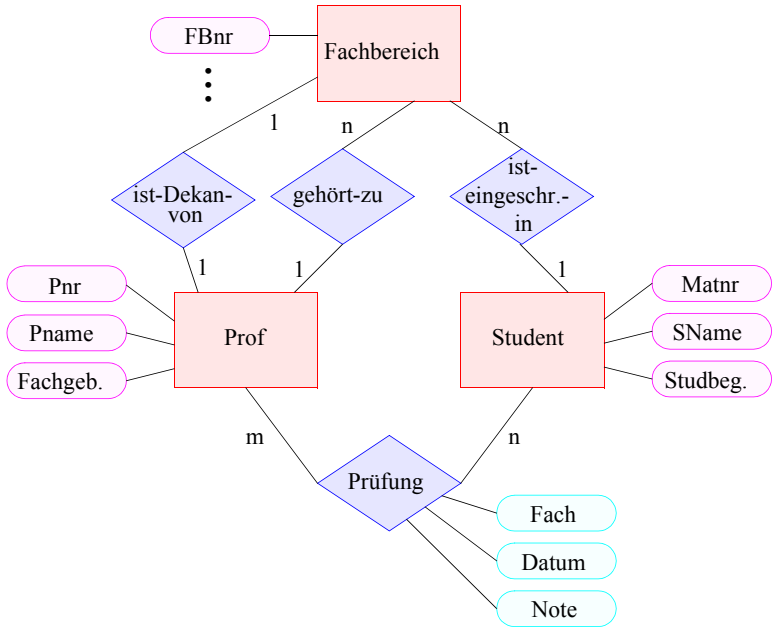


- Spezifikation benutzerdefinierter Beziehungen (rein struktureller Natur)
- Klassifikation der Beziehungstypen (1:1, 1:n, n:m)

➥ **relativ semantikarme Darstellung von Weltausschnitten**

- deshalb Verfeinerungen/Erweiterungen durch
  - **Kardinalitätsrestriktionen** ([1,1]:[1,10], [0:1]:[0:*])
  - **Abstraktionskonzepte**
    (Klassifikation/Instantiierung, Generalisierung/Spezialisierung,
    Element-/Mengen-Assoziation, Element-/Komponenten-Aggregation)



# Relationenmodell – Beispiel

**DB-Schema**

FB

| FBNR | FBNAME | DEKAN |
|---|---|---|

PROF

| PNR | PNAME | FBNR | FACHGEB |
|---|---|---|---|

STUDENT

| MATNR | SNAME | FBNR | STUDBEG |
|---|---|---|---|

PRÜFUNG

| PNR | MATNR | FACH | DATUM | NOTE |
|---|---|---|---|---|

**Ausprägungen**

| FB | FBNR | FBNAME | DEKAN |
|---|---|---|---|
| | FB 9 | WIRTSCHAFTSWISS | 4711 |
| | FB 5 | INFORMATIK | 2223 |

| PROF | PNR | PNAME | FBNR | FACHGEB |
|---|---|---|---|---|
| | 1234 | HÄRDER | FB 5 | DATENBANKSYSTEME |
| | 5678 | WEDEKIND | FB 9 | INFORMATIONSSYSTEME |
| | 4711 | MÜLLER | FB 9 | OPERATIONS RESEARCH |
| | 6780 | NEHMER | FB 5 | BETRIEBSSYSTEME |

| STUDENT | MATNR | SNAME | FBNR | STUDBEG |
|---|---|---|---|---|
| | 123 766 | COY | FB 9 | 1.10.00 |
| | 225 332 | MÜLLER | FB 5 | 15.04.97 |
| | 654 711 | ABEL | FB 5 | 15.10.99 |
| | 226 302 | SCHULZE | FB 9 | 1.10.00 |
| | 196 481 | MAIER | FB 5 | 23.10.00 |
| | 130 680 | SCHMID | FB 9 | 1.04.02 |

| PRÜFUNG | PNR | MATNR | FACH | PDATUM | NOTE |
|---|---|---|---|---|---|
| | 5678 | 123 766 | BWL | 22.10.03 | 4 |
| | 4711 | 123 766 | OR | 16.01.02 | 3 |
| | 1234 | 654 711 | DV | 17.04.03 | 2 |
| | 1234 | 123 766 | DV | 17.04.03 | 4 |
| | 6780 | 654 711 | SP | 19.09.03 | 2 |
| | 1234 | 196 481 | DV | 15.10.03 | 1 |
| | 6780 | 196 481 | BS | 23.10.03 | 3 |

## Relationenmodell – Beispiel (2)

- **Deskriptive DB-Sprachen**
  - hohes Auswahlvermögen und Mengenorientierung
  - leichte Erlernbarkeit auch für den DV-Laien
  - RM ist symmetrisches Datenmodell, d.h., es gibt keine bevorzugte Zugriffs- oder Auswertungsrichtung

- **Anfragebeispiele**

Q1: Finde alle Studenten aus Fachbereich 5, die ihr Studium vor 2000 begonnen haben.

```
SELECT    *
FROM      STUDENT
WHERE     FBNR = 'FB5' AND STUDBEG < '1.1.00'
```

Q2: Finde alle Studenten des Fachbereichs 5, die im Fach Datenverwaltung eine Note 2 oder besser erhalten haben.

```
SELECT    *
FROM      STUDENT
WHERE     FBNR = 'FB5' AND MATNR IN
          (SELECT   MATNR
          FROM      PRÜFUNG
          WHERE     FACH = 'DV' AND NOTE ≤ '2')
```

Q3: Finde die Durchschnittsnoten der DV-Prüfungen für alle Fachbereiche mit mehr als 1000 Studenten.

```
SELECT    S.FBNR, AVG (P.NOTE)
FROM      PRÜFUNG P, STUDENT S
WHERE     P.FACH = 'DV' AND P.MATNR = S.MATNR
GROUP BY  S.FBNR
HAVING    (SELECT   COUNT(*)
           FROM     STUDENT T
           WHERE    T.FBNR = S.FBNR) > 1000
```



## Netzwerkmodell – Beispiel

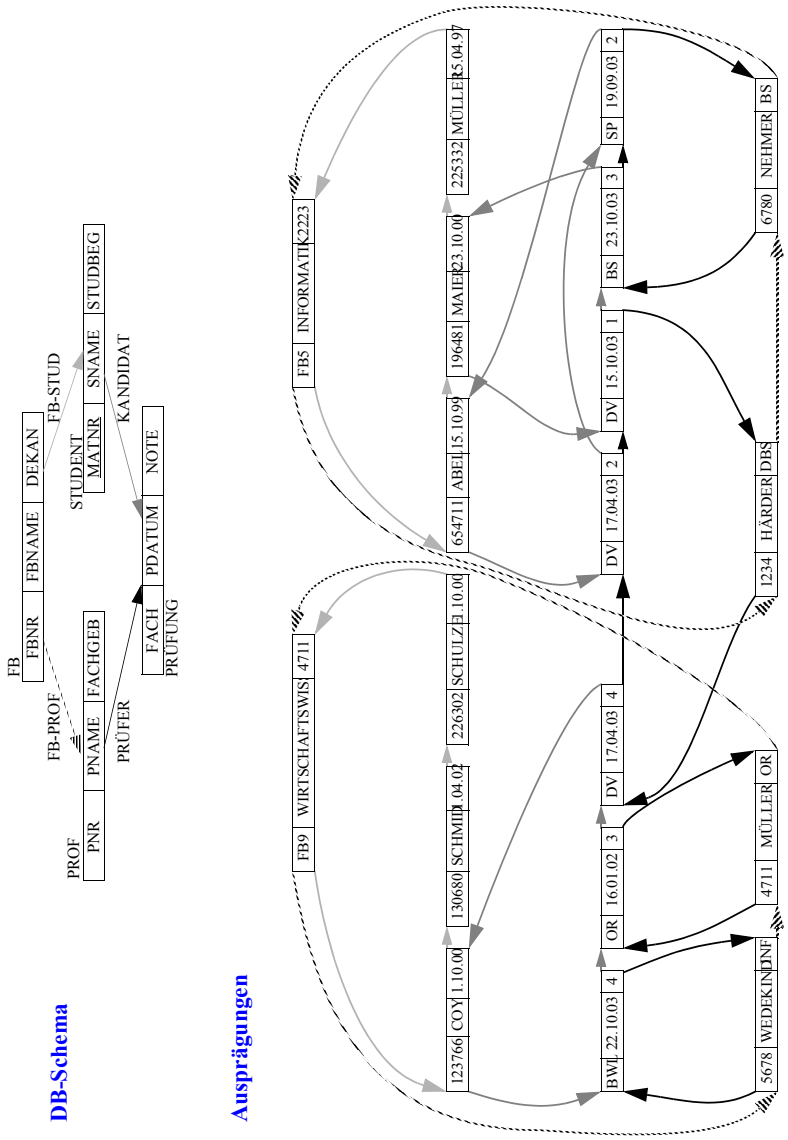

## Netzwerkmodell – Beispiel (2)

- **Prozedurale DB-Sprachen**
  - Programmierer als Navigator
  - satzweiser Zugriff über vorhandene Zugriffspfade

- **Anfragebeispiele**

Q4: Finde alle Studenten aus Fachbereich 5, die ihr Studium vor 2000 begonnen haben.

```
                MOVE 'FB5' TO FBNR OF FB;
                FIND FB USING FBNR;
NEXT_STUDENT:   FETCH NEXT STUDENT WITHIN FB-STUD SET;
                IF   END_OF_SET THEN EXIT;
                IF   STUDBEG < '1.1.00' THEN
                     PRINT STUDENT RECORD;
                GOTO NEXT_STUDENT;
```

Q5: Finde alle Studenten des Fachbereichs 5, die im Fach Datenverwaltung eine Note 2 oder besser erhalten haben.

```
                MOVE 'FB5' TO FBNR OF FB;
                FIND FB USING FBNR;
NEXT_STUDENT:   FETCH NEXT STUDENT WITHIN FB-STUD SET;
                IF   END_OF_SET THEN EXIT;
NEXT_PRÜFUNG:   FETCH NEXT PRÜFUNG WITHIN KANDIDAT SET;
                IF   END_OF_SET THEN GOTO NEXT_STUDENT;
                IF   FACH = 'DV' AND NOTE ≤ '2'
                DO;
                     PRINT STUDENT RECORD;
                     GOTO NEXT_STUDENT;
                END;
                GOTO NEXT_PRÜFUNG;
```



## Hierarchisches Datenmodell – Beispiel

**DB-Schema**

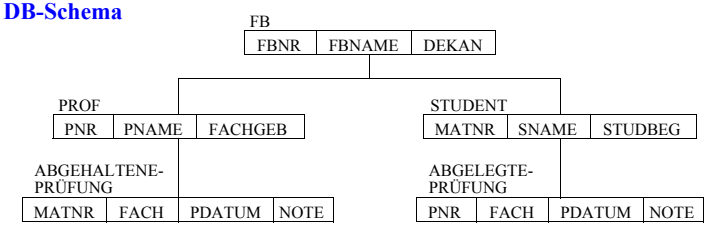


**Ausprägungen**

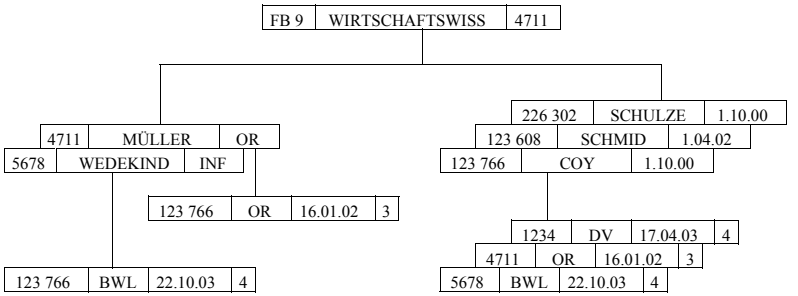


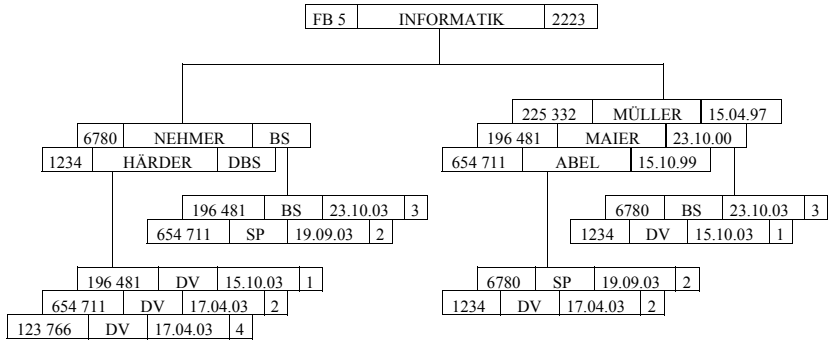

## Hierarchisches Datenmodell – Beispiel (2)

- **Prozedurale DB-Sprachen**
  - navigierende Verarbeitung
  - satzweiser Zugriff in Baumstrukturen
  - durch den Zwang zu Hierarchien
    - unnatürliche Organisation bei komplexen Beziehungen (n:m)
    - Auswertungsrichtung ist vorgegeben

- **Anfragebeispiele**

Q6: Finde alle Studenten aus Fachbereich 5, die ihr Studium vor 2000 begonnen haben.

```
                    GU FB (FBNR = 'FB5');
NEXT_STUDENT:       GNP STUDENT (STUDBEG < '1.1.00');
                    IF END_OF_PARENT THEN EXIT;
                    PRINT STUDENT RECORD;
                    GOTO NEXT_STUDENT;
```

Q7: Finde alle Studenten des Fachbereichs 5, die im Fach Datenverwaltung eine Note 2 oder besser erhalten haben.

```
                    GU FB (FBNR = 'FB5');
NEXT_STUDENT:       GNP STUDENT;
                    IF END_OF_PARENT THEN EXIT;
                    GNP ABGELEGTE_PRÜFUNG    (FACH = 'DV') AND
                                             (NOTE ≤ '2');
                    IF END_OF_PARENT THEN GOTO NEXT_STUDENT;
                    PRINT STUDENT RECORD;
                    GOTO NEXT_STUDENT;
```



## Objektorientierte Datenmodelle

**Schema**

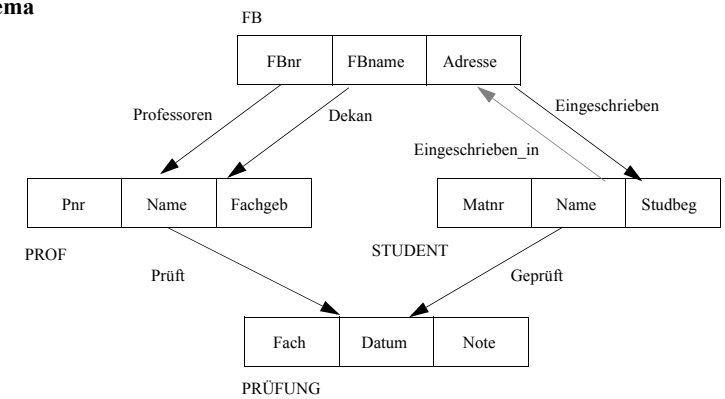


- **Typdefinitionen (fiktives Modell)**

```
CREATE TYPE ADRESSEN_T
        (Strasse            char(30),
        Hausnummer          integer,
        PLZ                 integer,
        Ort                 char(30));

CREATE TYPE DATE_T
        (Jahr               integer,
        Monat               integer,
        Tag                 integer);

CREATE TYPE PERSON_T
        (Name               char(30)
         Adresse            ADRESSEN_T
        ...   (* weitere allg. Personendaten  *)
        ... );

CREATE FUNCTION  . . . ;   (* Definition von zugehörigen Methoden *)
```

## Objektorientierte Datenmodelle (2)

- **Typdefinitionen**

```
CREATE TYPE PRÜFUNG_T
        (Fach           char(30),
         Pdatum         DATE_T,
         Note           integer)
  CREATE FUNCTION Prüfungsbericht (Prüfung REF(PRÜFUNG_T))
      RETURNS integer ... ;

CREATE TYPE FB_T
        (FBnr           char(30),
         FBname         char(30),
         Adresse        ADRESSEN_T,
         Dekan          REF(PROF_T),
         Eingeschrieben SET(REF(STUDENT_T))
         Professoren    SET(REF(PROF_T)));
  CREATE FUNCTION Durchschnittsnote.pro.Student (FB_T) ...;
  CREATE FUNCTION Durchschnittsnote.pro.Fach (FB_T) ...;

CREATE TYPE PROF_T UNDER PERSON_T
        (Pnr            integer,
         Fachgeb        char(30),
         Prüft          SET(REF(PRÜFUNG_T)));
  CREATE FUNCTION
      Prüfungsergebnis (PROF_T, STUDENT_T, PRÜFUNG_T), ... ;

CREATE TYPE STUDENT_T UNDER PERSON_T
        (Matnr          integer,
         Studbeg        DATE_T,
         Eingeschrieben_in  REF(FB_T)
         Geprüft        SET(REF(PRÜFUNG_T)));
  CREATE FUNCTION
      Prüfungsanmeldung (PROF_T, STUDENT_T, PRÜFUNG_T) ...;
      Prüfungsverlegung (PROF_T, STUDENT_T, PRÜFUNG_T) ...;
```



## Objektorientierte Datenmodelle (3)

- **Tabellendefinitionen**

```
CREATE TABLE FB OF FB_T
  (PRIMARY KEY FBnr
   Dekan WITH OPTIONS SCOPE Prof,
   Professoren WITH OPTIONS SCOPE Prof,
   Eingeschrieben WITH OPTIONS SCOPE Student);

CREATE TABLE Prof OF PROF_T
  (PRIMARY KEY Pnr
   Prüft WITH OPTIONS SCOPE Prüfung);

CREATE TABLE Student OF STUDENT_T
  (PRIMARY KEY Matnr
   Eingeschrieben_in WITH OPTIONS SCOPE FB,
   Geprüft WITH OPTIONS SCOPE Prüfung);

CREATE TABLE Prüfung OF PRÜFUNG_T
  (PRIMARY KEY Fach, Pdatum, Note);
```

# Objektorientierte Datenmodelle – Ausprägungen

| FB | FBnr | FBname | Dekan | Adresse | Professoren | Eingeschrieben |
|---|---|---|---|---|---|---|
| @1 | FB 9 | WIRTS.-WISS | @5 | @201 | @4, @5, ... | @7, @10, ... |
| @2 | FB 5 | INFORMATIK | @111 | @202 | @3, @6, ... | @8, @9, ... |

| PROF | Pnr | Name | Fachgeb | Prüft |
|---|---|---|---|---|
| @3 | 1234 | HÄRDER | DATENBANKSYSTEME | @15, @16, ... |
| @4 | 5678 | WEDEKIND | INFORMATIONSSYSTEME | @13, ... |
| @5 | 4711 | MÜLLER | OPERATIONS RESEARCH | @14 |
| @6 | 6780 | NEHMER | BETRIEBSSYSTEME | @17, @19 |

| STUDENT | Matnr | Sname | Studbeg | Eingeschr._in | Geprüft |
|---|---|---|---|---|---|
| @7 | 123 766 | COY | 1.10.00 | @1 | @13, @16, ... |
| @8 | 225 332 | MÜLLER | 15.4.97 | @2 | - |
| @9 | 654 711 | ABEL | 15.10.99 | @2 | @15, @17 |
| @10 | 226 302 | SCHULZE | 1.10.00 | @1 | - |
| @11 | 194 481 | MAIER | 23.10.00 | @2 | @18, @19 |
| @12 | 130 680 | SCHMID | 1.4.02 | @1 | - |

| PRUEFUNG | Fach | Pdatum | Note |
|---|---|---|---|
| @13 | BWL | 22.10.03 | 4 |
| @14 | OR | 16.1.02 | 3 |
| @15 | DV | 17.4.03 | 2 |
| @16 | DV | 17.4.03 | 4 |
| @17 | SP | 19.9.03 | 2 |
| @18 | DV | 15.10.03 | 1 |
| @19 | BS | 23.10.03 | 3 |



# Objektorientierte Datenmodelle – Anfragebeispiele

- **Prozedurale und deskriptive DB-Sprachen**
  - Zugriff über OIDs und Referenzen
  - Einsatz von Zugriffsroutinen (Methoden, Funktionen, Prozeduren)
  - Hinzufügen von deklarativen und mengenorientierten Zugriffsmöglichkeiten
- **Anfragebeispiele**

Q8: Finde alle Studenten aus Fachbereich 5, die ihr Studium vor 2000 begonnen haben.

```
SELECT *
FROM     STUDENT S
WHERE S.Eingeschrieben_in->FBnr = 'FB5'
          AND S.Studbeg < '1.1.00';
```

Q9: Finde alle Studenten des Fachbereichs 5, die im Fach Datenverwaltung eine Note 2 oder besser erhalten haben.

```
SELECT *
FROM     STUDENT S
WHERE S.Eingeschrieben_in->FBnr = 'FB5' AND EXISTS
          (SELECT *
          FROM TABLE (S.Geprüft) P
          WHERE P.Fach = 'DV' AND P.Note <= 2);
```

Q12: Finde die Durchschnittsnoten der DV-Prüfungen für alle Fachbereiche mit mehr als 1000 Studenten.

```
SELECT F.FBnr, Durchschnittsnote.pro.Fach (F, 'DV')
FROM  FB  F,
WHERE 1000 < (SELECT COUNT(*)
                    FROM TABLE (F.Eingeschrieben));
```

## Bewertung – Relationenmodell

- **Informationen des Benutzers**
  - ausschließlich durch den Inhalt der Daten
  - keine physischen Verbindungen
  - keine bedeutungsvolle Ordnung
- **Deskriptive Sprachen**
  - hohes Auswahlvermögen und Mengenorientierung
  - leichte Erlernbarkeit auch für den DV-Laien
- **Vorteile**
  - strenge theoretische Grundlage
  - einfache Informationsdarstellung durch Tabellen
  - keine Bindung an Zugriffspfade oder Speichertechnologie
  - keine Aussage über die Realisierung
  - hoher Grad an Datenunabhängigkeit
  - symmetrisches Datenmodell; d.h. es gibt keine bevorzugte Zugriffs- oder Auswertungsrichtung
  - Parallelisierung der Auswertung möglich
  - Verteilung der Daten über Prädikate
- **Nachteile**
  - zu starke Beschränkung der Modellierungsmöglichkeiten
  - Schwerfällige und unnatürliche Modellierung bei komplexeren Objekten
  - Einsatz von nicht-prozeduralen Sprachen „soll“ Ineffizienz implizieren!?
  - aber: Optimierung der Anforderungen liegt in der Systemverantwortung



## Bewertung – Hierarchische Datenmodelle und Netzwerkmodelle

- **Informationen des Benutzers**
  - Darstellung durch „Verbindungen“ von Datensätzen
  - Berücksichtigung ihrer Anordnung in Speicherungsstrukturen
- **Prozedurale Sprachen**
  - Programmierer als Navigator
  - satzweiser Zugriff über vorhandene Zugriffspfade
- **Vorteile**
  - Entwurf effizienter Programme durch den Anwendungsprogrammierer
  - höheres Leistungsvermögen bei zugeschnittenen Zugriffspfadstrukturen
- **Nachteile**
  - starke Bindung an Zugriffspfade
  - geringerer Grad an Datenunabhängigkeit
  - beschränkt auf die Benutzerklassen „Anwendungsprogrammierer und “Systempersonal“
  - bei hierarchischen Datenmodellen
    - unnatürliche Organisation bei komplexen Beziehungen (n:m)
    - Auswertungsrichtung ist vorgegeben

## Bewertung – Objektorientierte Modelle

- **Informationen des Benutzers**
  - Darstellung durch „Verbindungen“ von Datensätzen
  - sowie durch den Inhalt der Daten
- **Prozedurale und deskriptive Sprachen**
  - Programmierer als Navigator
  - hohes Auswahlvermögen
  - satzweiser Zugriff (über vorhandene Zugriffspfade)
- **Vorteile (auch bei objekt-relationalen Datenmodellen)**
  - reichhaltiger Vorrat an Modellierungskonzepten
  - Generalisierung/Spezialisierung: Typ- und Tabellenhierarchien – Vererbung
  - Einsatz benutzerdefinierter Datentypen und Funktionen
  - Aktive Mechanismen: Trigger, ECA-Regeln
  - Entwurf effizienter Programme durch den Anwendungsprogrammierer
  - Leistungsvermögen aufgrund der Nutzung zugeschnittener Zugriffspfadstrukturen
- **Nachteile**
  - kein einheitliches Datenmodell
  - keine theoretische Grundlage
  - Informationsdarstellung durch ‘Tabellen’ und ‘Verbindungen’
  - Bindung an Zugriffspfade – Symmetrie des Datenmodells?
  - Grad an Datenunabhängigkeit?

➥ **Objekt-relationale Datenmodelle wollen die Vorteile beider zugrundeliegender Modelle vereinigen**



## The Big Picture

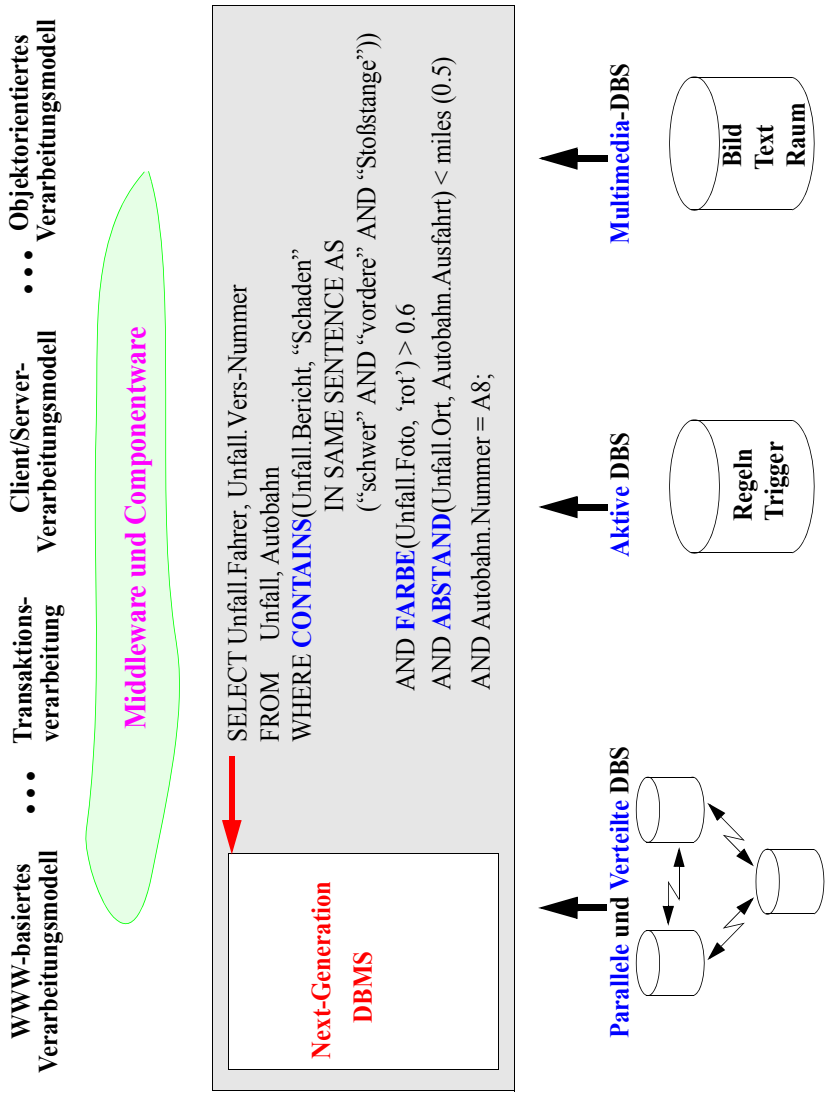

# Ein weiteres Paradigma – „Alles fließt (panta rhei)[5]“

- **Vertauschte Rollen**

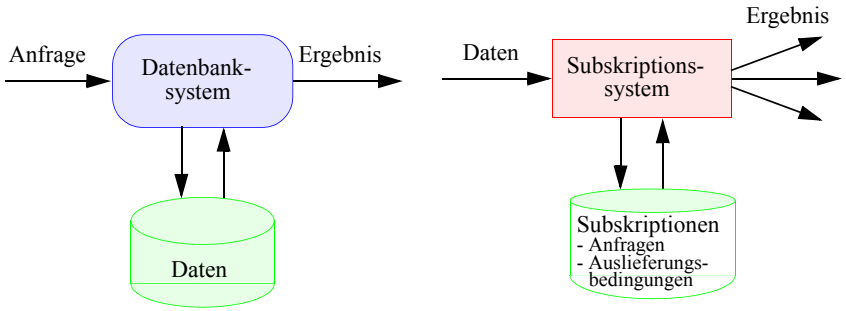


  - statt Auswertung von gespeicherten Daten Filterung, Verknüpfung und Transformation von Datenströmen
  - zentrale Bedeutung für die individuelle Informationsversorgung, insbesondere bei einer immer weiter fortschreitenden Verwendung vieler kleiner und damit mobiler Endgeräte

- **Wichtige Unterschiede**

| Eigenschaft | Datenbankbasierte Informationssysteme | Subskriptionssysteme |
|---|---|---|
| Verarbeitungs-charakteristik | zustandsorientiert (globaler Zustand) | konsumorientiert (evtl. lokaler temporärer Zustand) |
| Anfragesemantik | isolierte Anfrage | stehende Anfragen (‘standing query’) |
| Zugriffscharakteristik | systemzentriert (‘row-set-model’) | dokumentenzentriert (‘document-model’) |
| Auswertungssemantik | komplexe Analysen | informativ, Auslöser detaillierter Analysen |
| Schemaaspekt | Existenz eines globalen Schemas | Zugriff auf lokale Schemata der partizipierenden Datenquellen |

5. fälschlicherweise Heraklit zugeschriebene Formel für sein Weltbild



# Datenströme – Auswertungsmodell

- **Daten strömen und sind nicht in einer DB gespeichert[6]**

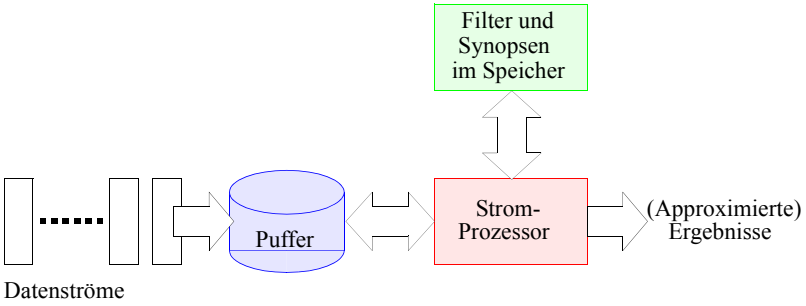


  - Analyse von flachen Datenströmen (z. B. sensorgeneriert)
  - strombasierte Analyse von XML-Dokumenten
  - Wie funktionieren Selektionen und Joins?

- **Beispiel für einen Online-Transaktionsfluß**
  - Warenkorb-AW: Kunden kaufen Waren, die als Ströme zu analysieren sind
  - Bestimmung der Häufigkeit von Mustern (frequent pattern identification) ist offensichtlich sehr schwierig!

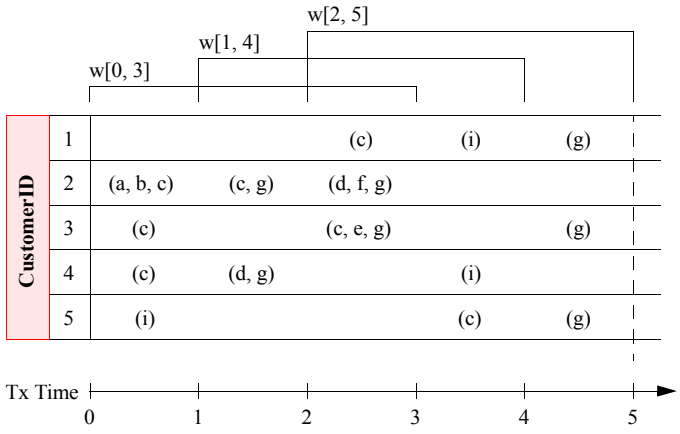


6. Aktuelles Forschungsthema im Rahmen der dynamischen Informationsfusion

## A Dozen Long-Term Systems Research Problems (J. Gray)[7]

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.

7. J. Gray is the recipient of the 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.