

# Implementation of Database Systems

A Quick Introduction  
to Relational Databases

Ulf Leser

Wissensmanagement in der  
Bioinformatik



# Inhalt dieser Vorlesung

---

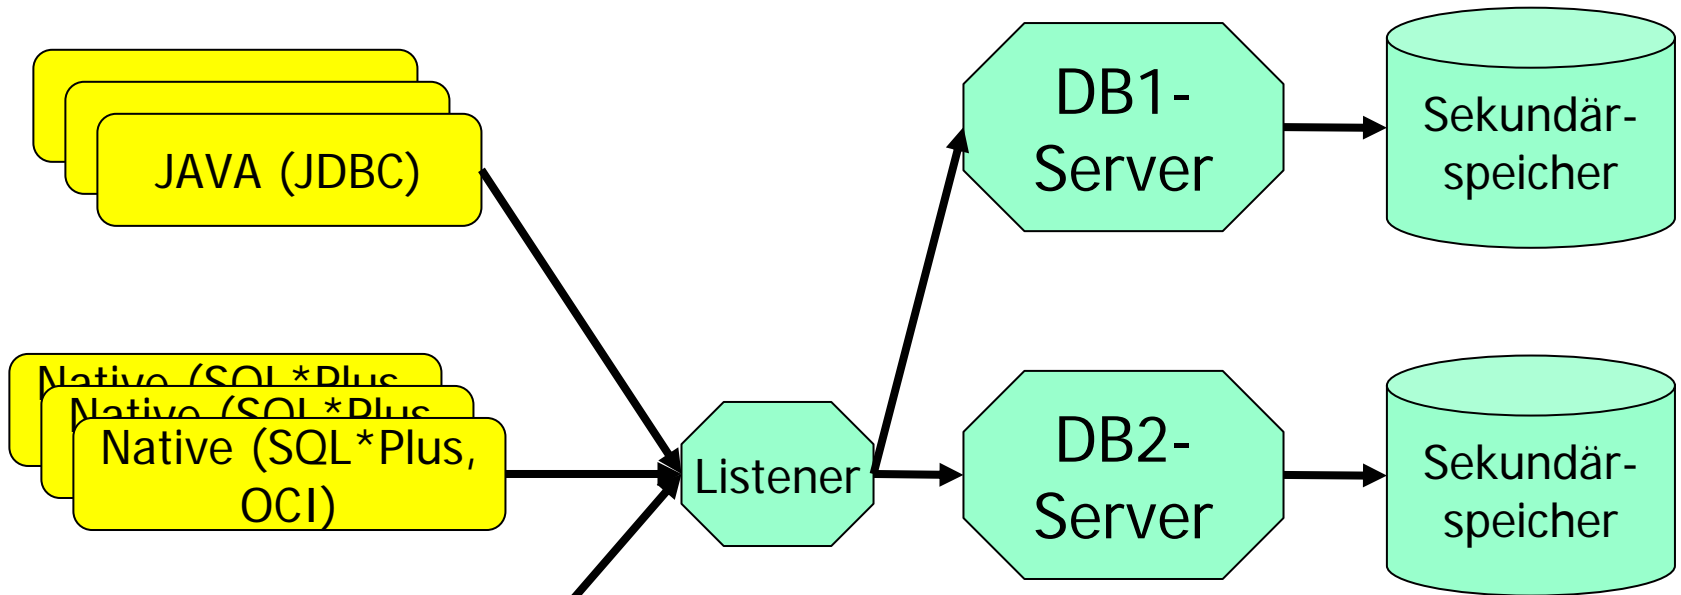
- Relationale Datenbanken
- Relationales Modell und Datenbankentwurf
- Relationale Operatoren & Algebra
- SQL
- Anfragebearbeitung
- Indexstrukturen
- Normalformen

# Relationale Datenbank

---

- **Relationale Datenbank Management Systeme (RDBMS)**
  - Serverbasierte Software
  - Ein RDBMS – viele RDB
  - Aufgaben des Servers
    - Hauptspeicher- und Sekundärspeicherverwaltung
    - Transaktionsmanagement
    - Anfragebearbeitung und –optimierung
    - Backup und Recovery
    - Datenkonsistenz
    - Userverwaltung
  - Systeme
    - Oracle, DB2 (Informix), Sybase, NCR Terada, SQL-Server
    - PostgreSQL, Interbase, Berkley-DB, DB4Objects, MySQL, Ingres, SAP-DB, Monet-DB, ...

# Client-Server



Konsistenz  
Parallelisierung  
Recovery  
Lastverteilung  
Authentifizierung  
Autorisierung

# Relationales Datenmodell

---

- Repräsentation aller Daten in Tabellen
  - Tabellenname
  - Attribute
  - Datentypen
- Vergleich zu UML Datenmodellen?

Mitarbeiter		Spalten/Attribute		
P_ID	Vorname	Nachname	Alter	Adresse
1	Peter	Müller	32	10101 Berlin
2	Stefanie	Meier	34	11202 Berlin
5	Petra	Weger	28	80223 München
7	Andreas	Zwickel	44	80443 München
...	...	...	...	...

Zeilen/  
Rows/  
Tupel

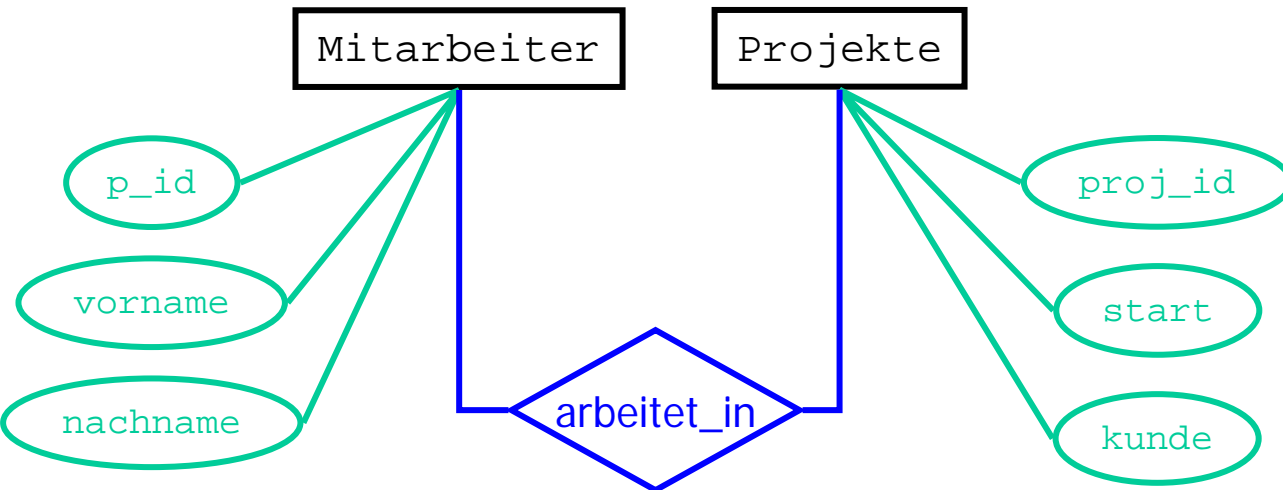
# ER-Modellierung

- Relationales Modell „semantikarm“
- Modellieren in Tabellen wenig intuitiv
- Modellierungssprachen: ER, EER, UML, ...
- Entity-Relationship Modell

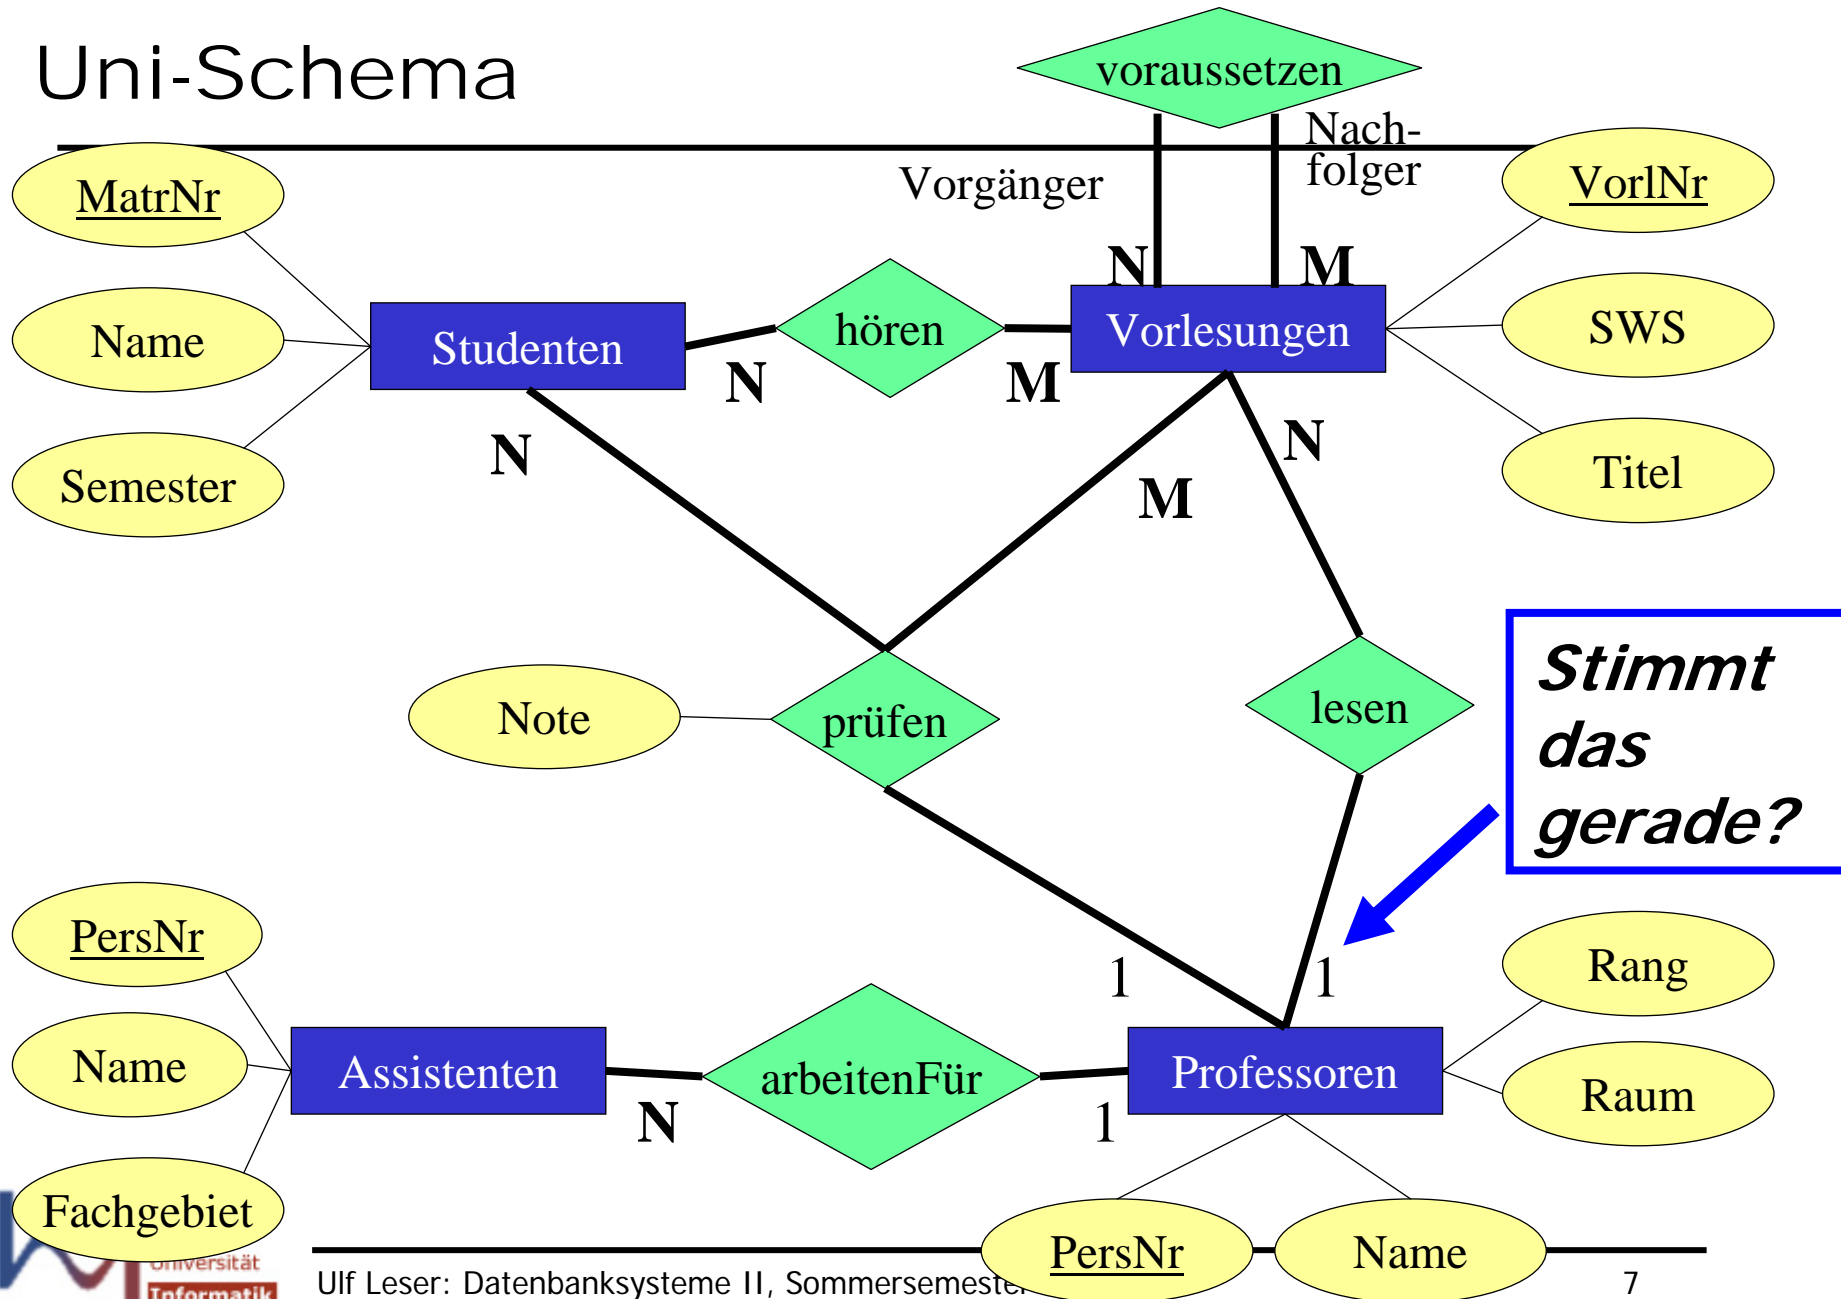
– Entitytypen

– Attribute

– Beziehungen




# Uni-Schema



# Entwicklung des relationalen Schemas

---



## 1:N-Beziehung

- Initial-Entwurf

*Vorlesungen* : { VorlNr, Titel, SWS }<sub>1</sub>

*Professoren* : { PersNr, Name, Rang, Raum }

*lesen*: { VorlNr, PersNr }

# Verfeinerung des relationalen Schemas

---

## 1:N-Beziehung

- Initial-Entwurf

*Vorlesungen* : { VorNr, Titel, SWS }

*Professoren* : { PersNr, Name, Rang, Raum }

*lesen*: { VorNr, PersNr }

- Verfeinerung durch Zusammenfassung

*Vorlesungen* : { VorNr, Titel, SWS, *gelesenVon* }

*Professoren* : { PersNr, Name, Rang, Raum }


## Regel

Relationen mit gleichem Schlüssel kann man zusammenfassen  
**aber nur diese und keine anderen!**

# Ausprägungen

Professoren			
PersNr	Name	Rang	Raum
2125	Sokrates	C4	226
2126	Russel	C4	232
2127	Kopernikus	C3	310
2133	Popper	C3	52
2134	Augustinus	C3	309
2136	Curie	C4	36
2137	Kant	C4	7


Vorlesungen			
VorlNr	Titel	SWS	Gelesen Von
5001	Grundzüge	4	2137
5041	Ethik	4	2125
5043	Erkenntnistheorie	3	2126
5049	Mäeutik	2	2125
4052	Logik	4	2125
5052	Wissenschaftstheorie	3	2126
5216	Bioethik	2	2126
5259	Der Wiener Kreis	2	2133
5022	Glaube und Wissen	2	2134
4630	Die 3 Kritiken	4	2137



# So geht es NICHT

Professoren				
PersNr	Name	Rang	Raum	liest
2125	Sokrates	C4	226	5041
2125	Sokrates	C4	226	5049
2125	Sokrates	C4	226	4052
...	...	...	...	...
2134	Augustinus	C3	309	5022
2136	Curie	C4	36	??

Vorlesungen		
VorlNr	Titel	SWS
5001	Grundzüge	4
5041	Ethik	4
5043	Erkenntnistheorie	3
5049	Mäeutik	2
4052	Logik	4
5052	Wissenschaftstheorie	3
5216	Bioethik	2
5259	Der Wiener Kreis	2
5022	Glaube und Wissen	2
4630	Die 3 Kritiken	4



# Folgen: Anomalien

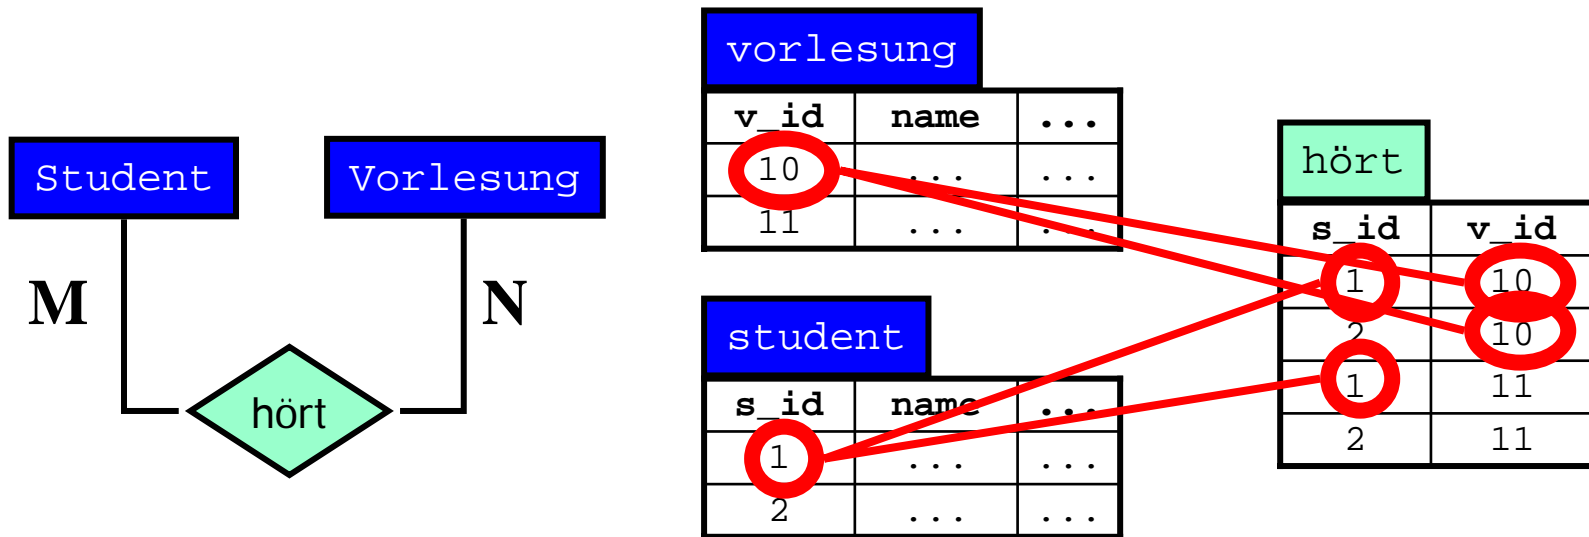
Professoren				
PersNr	Name	Rang	Raum	liest
2125	Sokrates	C4	226	5041
2125	Sokrates	C4	226	5049
2125	Sokrates	C4	226	4052
...	...	...	...	...
2134	Augustinus	C3	309	5022
2136	Curie	C4	36	??

Vorlesungen		
VorlNr	Titel	SWS
5001	Grundzüge	4
5041	Ethik	4
5043	Erkenntnistheorie	3
5049	Mäeutik	2
4052	Logik	4
5052	Wissenschaftstheorie	3
5216	Bioethik	2
5259	Der Wiener Kreis	2
5022	Glaube und Wissen	2
4630	Die 3 Kritiken	4

- Update-Anomalie
  - Was passiert wenn Sokrates umzieht?
- Lösch-Anomalie
  - Was passiert wenn „Glaube und Wissen“ wegfällt
- Einfügeanomalie
  - Curie ist neu und liest noch keine Vorlesungen


# Beziehung „hören“

- m:n Beziehung
- „Brückentabelle“ mit zwei Fremdschlüsseln



# Beziehung „betreuen“

---



betreuen : Professoren x Studenten → Seminarthemen

betreuen : Seminarthemen x Studenten → Professoren

# Erzwungene Konsistenzbedingungen

---


1. Studenten dürfen bei demselben Professor bzw. derselben Professorin nur ein Seminarthema „ableisten“
2. Studenten dürfen dasselbe Seminarthema nur einmal bearbeiten – sie dürfen also nicht bei anderen Professoren ein schon einmal erteiltes Seminarthema nochmals bearbeiten.

Es sind aber folgende Datenbankzustände möglich:

- Professoren können dasselbe Seminarthema „wiederverwenden“ – also dasselbe Thema auch mehreren Studenten erteilen.
- Ein Thema kann von mehreren Professoren vergeben werden – aber an unterschiedliche Studenten.

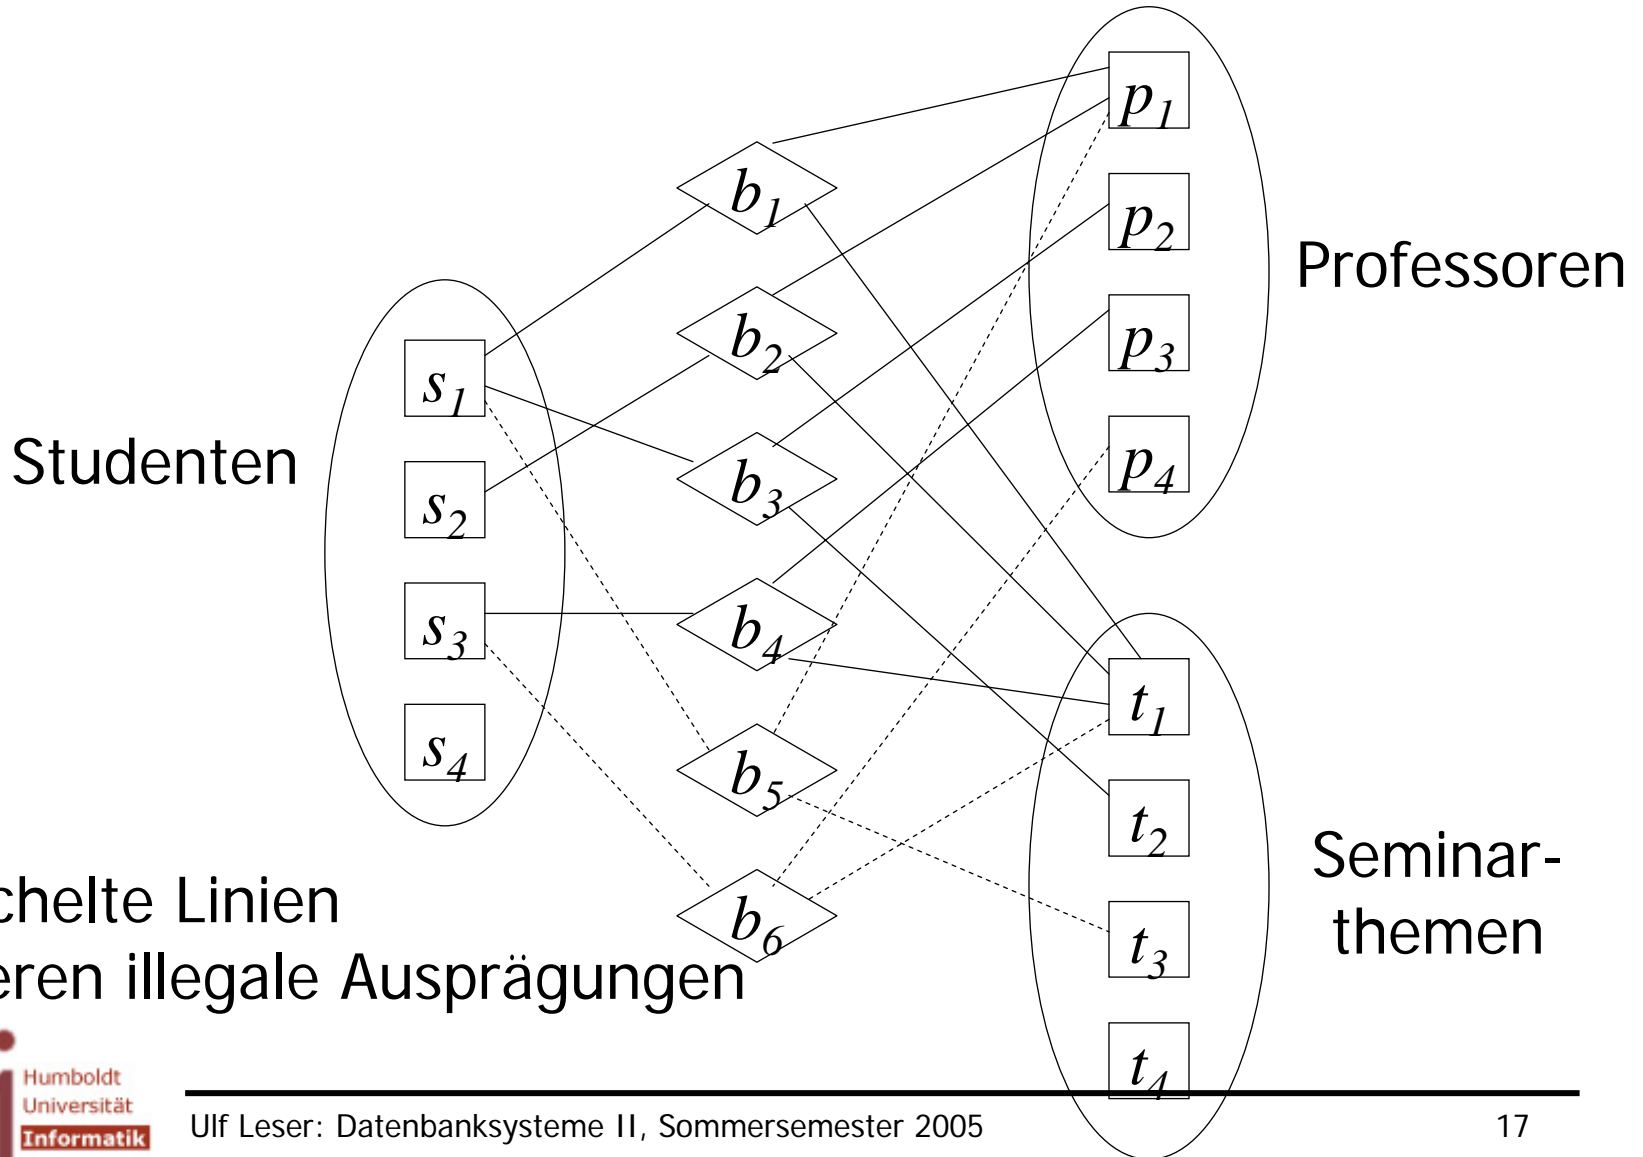
# Wie sieht das relationale Schema aus?

---



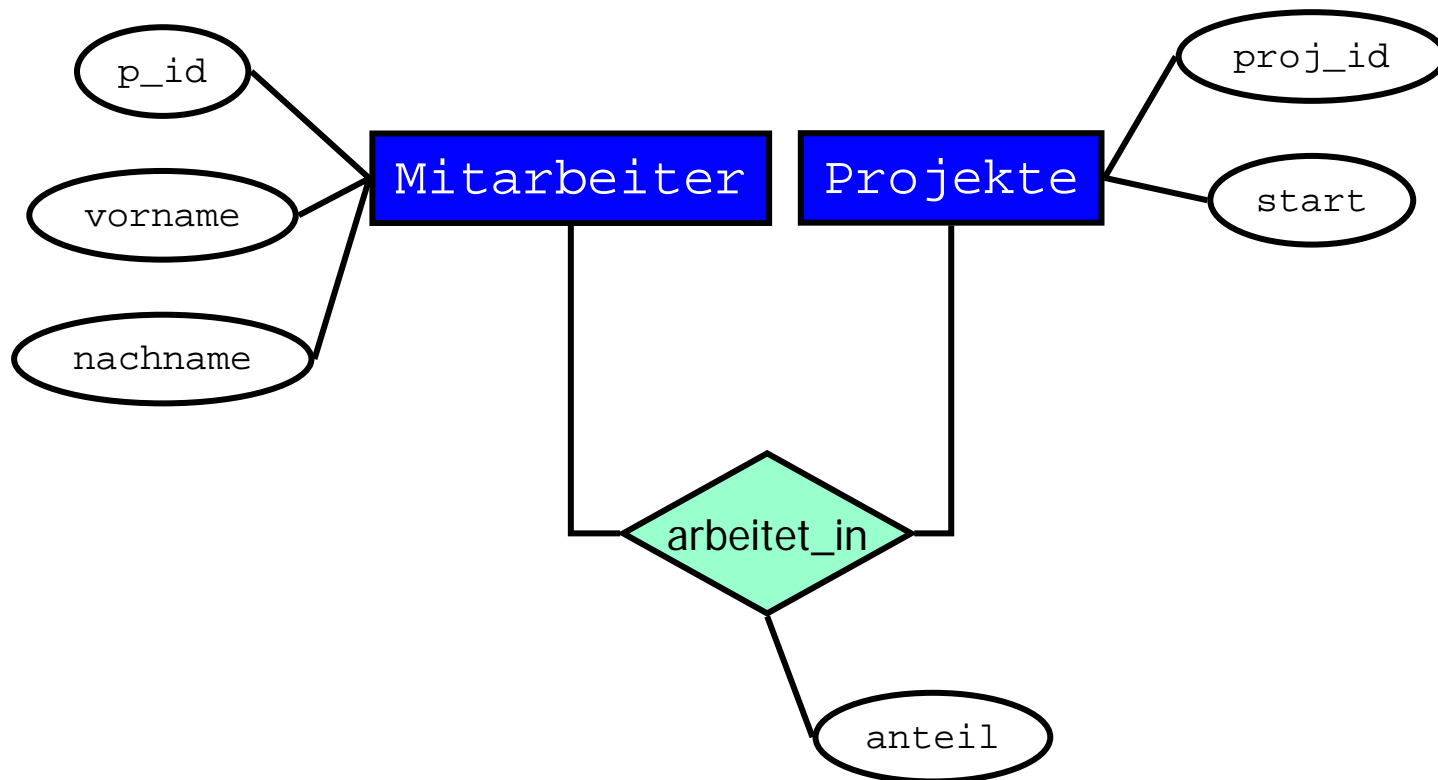
- `betreuen{ student, professor, thema, note }`
- `unique( student, professor )`
  - Jeder Student nur ein Thema pro Professor
- `unique( student, thema )`
  - Jedes Thema nur einmal pro Student

# Ausprägung der Beziehung *betreuen*



---

- Relationale Operationen



# Operationen auf Relationen/Tabellen

---

- Selektion
  - Alle Zeilen von `Mitarbeiter` mit `Alter > 40` und `Name = „Müller“`
- Projektion
  - Nur die `Mitarbeiter`-Spalten `Vorname`, `Nachname`
- Kartesisches Produkt
  - Alle Zeilen von `Mitarbeiter` verknüpft mit jeweils allen Zeilen von `Arbeitet_in`
- Komposition von Operationen
  - Die Spalten `Nachname` und `Proj_id` aller Zeilen des kartesischen Produkts von `Mitarbeiter` und `Arbeitet_in`, bei denen `Mitarbeiter.P_ID = Arbeitet_in.P_ID` mit Anteil größer als 10%

# Die relationale Algebra

---

- $\sigma$  Selektion
- $\pi$  Projektion
- $\times$  Kreuzprodukt
- $\bowtie$  Join (Verbund)
- $\rho$  Umbenennung
- $-$  Mengendifferenz
- $\div$  Division
- $\cup$  Vereinigung
- $\cap$  Mengendurchschnitt
- $\ltimes$  linker Semijoin
- $\rtimes$  rechter Semijoin
- $\ltimes\bowtie$  Left outer join
- $\bowtie\rtimes$  Right outer join
- $\bowtie\bowtie$  Full outer join

# Der natürliche Verbund (Join)

Gegeben seien:


- $R(A_1, \dots, A_m, B_1, \dots, B_k)$
- $S(B_1, \dots, B_k, C_1, \dots, C_n)$

$$R \bowtie S = \Pi_{A_1, \dots, A_m, R.B_1, \dots, R.B_k, C_1, \dots, C_n} (\sigma_{R.B_1=S.B_1 \wedge \dots \wedge R.B_k=S.B_k} (R \times S))$$

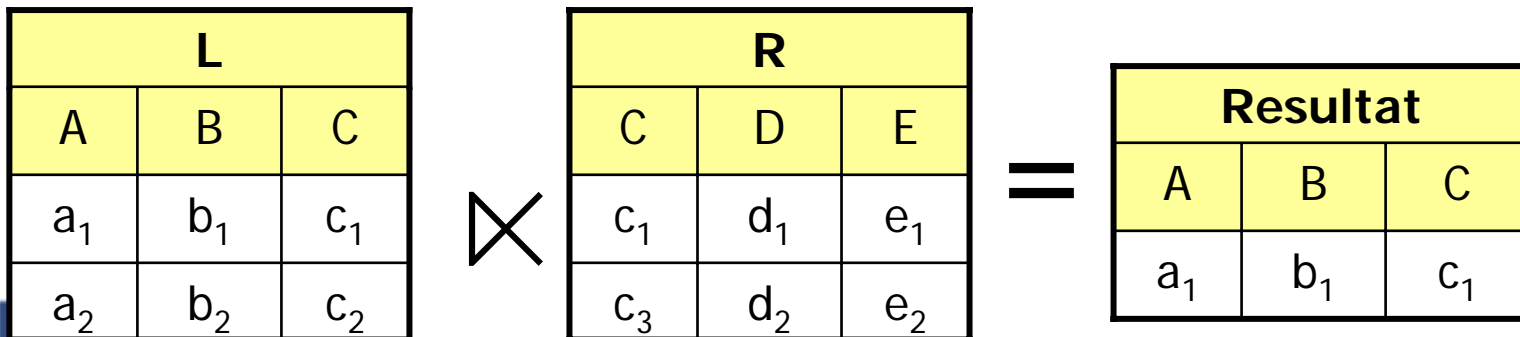
R $\bowtie$ S											
R – S				R $\cap$ S				S – R			
A <sub>1</sub>	A <sub>2</sub>	...	A <sub>m</sub>	B <sub>1</sub>	B <sub>2</sub>	...	B <sub>k</sub>	C <sub>1</sub>	C <sub>2</sub>	...	C <sub>n</sub>
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

# Andere Join-Arten

- Rechter äußerer Join (Full outer join?)



- Rechter Semi-Join



# SQL – Grundkonzepte

---

```
SELECT    M.nachname, A.arbeitet_in
FROM      mitarbeiter M, arbeitet_in A
WHERE     M.p_id = A.p_id AND
          A.anteil > 0.1
```

- SQL: Structured Query Language
- ANSI-SQL, SQL-92, SQL-99, SQL-3
- **Deklarativer Charakter**: Was, nicht wie
- Vier Grundbefehle: Insert, Update, Delete, Select
- DDL versus DML
- Andere Sprachen
  - Tupel/Domänenkalkül, relationale Algebra, QBE, Datalog

# Insert

---

- Einfügen von Werten in Tabelle
- Prinzipiell ein Tupel pro Insert

```
INSERT INTO mitarbeiter VALUES  
    (1, „Peter“, „Müller“, 38, „10101 Berlin“);
```

```
INSERT INTO projekte (proj_id, name, kunde) VALUES  
    (1, „Stammhaus-BMW“, „BMW“);
```

- Erweiterungen
  - Bulk-Insert  
INSERT INTO ... SELECT ...
  - Konditionales Insert in mehrere Tabellen  
INSERT INTO ... INTO ... INTO ...

# Update

---

- **Ändern von Werten** in Tabellen
- Mengensemantik: Ändert mehrere Werte

```
UPDATE projekte
SET status = „abgebrochen“,
    kunde = kunde || „-insolvent“
WHERE kunde=„Grundig“
```

- Typisches Muster

```
UPDATE tabelle
SET ... = (SELECT ... FROM ... WHERE)
WHERE id in (SELECT ... FROM ... WHERE)
```

- Erweiterungen
  - UPSERT / MERGE

# Delete

---

- Löschen von Tupeln in einer Tabellen

```
DELETE FROM projekte
WHERE status=„abgeschlossen“
```

- Typisches Muster

```
DELETE FROM projekte
WHERE id in (SELECT ... FROM ... WHERE)
```

- Löschen ist eine **performancekritische Operation**
  - DELETE, DROP TABLE, TRUNCATE, Partitionen, ...

# Select

---

- **Selektieren von Werten** aus mehreren Tabellen

```
SELECT      M.nachname, A.anteil
FROM        mitarbeiter M, arbeitet_in A
WHERE       M.p_id = A.p_id AND
            a.anteil > 0.1
```

```
SELECT      M.nachname, P.name, A.anteil
FROM        mitarbeiter M, projekte P, arbeitet_in A
WHERE       M.p_id = A.p_id AND
            A.proj_id = P.proj_id
```

```
SELECT      M.nachname, A.anteil
FROM        mitarbeiter M, arbeitet_in A
WHERE       M.p_id = A.proj_id
```



- Ergebnis ist Tabelle
- Ausführung ist Sache des RDBMS - Optimierung

# Varianten

---

- Subqueries

- Korreliert oder nicht
- Unkorrelierte Form ?

```
SELECT      vorname, nachname
FROM        mitarbeiter M
WHERE       EXISTS (
            SELECT A.p_id
            FROM   arbeitet_in A
            WHERE  A.p_id = M.p_id
```

- Self-Join

- „Begrenzte Rekursion“

```
SELECT P1.name, P2.name
FROM   projekte P1, projekte P2
WHERE  P1.vorgaenger=p2.proj_id AND
       P2.status=„abgeschlossen“
```

- SQL in FROM Klausel

- „In-Line Views“
- Nützlich bei Top-Ten /  
Sortieranfragen
- Top Ten Anfragen ?

```
SELECT X.nachname, X.status
FROM   (
        SELECT M.nachname, p.status
        FROM   mitarbeiter, projekte, arbeitet_in
        WHERE  M.p_id=A.p_id AND
               A.proj_id=P.proj_id
        ) X
WHERE  X.status=„Akquisition“
```

# Unkorrelierte versus korrelierte Unteranfragen

---

## Korrelierte Formulierung – Umformung ?

```
select s.*  
from Studenten s  
where exists  
    (select p.*  
     from Professoren  
     where p.GebDatum > s.GebDatum);
```

## Besser: Äquivalente unkorrelierte Formulierung

```
select s.*  
from Studenten s  
where s.GebDatum <  
    (select max (p.GebDatum)  
     from Professoren p);
```

- Unteranfrageergebnis kann materialisiert werden
- Unteranfrage braucht nur einmal ausgewertet zu

# Weitere Operationen

---

- Aggregation und GROUP BY

```
SELECT      proj_id, COUNT(*), SUM(alter)/COUNT(*)
FROM        mitarbeiter M, arbeitet_in A, projekte P
WHERE       M.p_id=A.p_id AND A.proj_id=P.proj_id
GROUP BY    P.proj_id
```



```
SELECT      proj_id, P.name, COUNT(*)
FROM        mitarbeiter M, arbeitet_in A, projekte P
WHERE       M.p_id=A.p_id AND A.proj_id=P.proj_id
GROUP BY    P.proj_id
```

- ORDER BY

```
SELECT      P.name, M.nachname
FROM        mitarbeiter M, arbeitet_in A, projekte P
WHERE       M.p_id=A.p_id AND A.proj_id=P.proj_id
ORDER BY    P.name, M.nachname
```

# Views

---

- Definition von „benannten“ Queries

```
CREATE VIEW proj_pers AS
  SELECT      P.proj_id, P.name,
             M.P_id, M.name, M.alter,
  FROM        mitarbeiter M, arbeitet_in A, projekte P
  WHERE       M.p_id=A.p_id AND A.proj_id=P.proj_id
```

- Können viel Schreibarbeit sparen

```
SELECT      proj_id, COUNT(*), SUM(alter)/COUNT(*)
FROM        proj_pers
GROUP BY    proj_id
```

- Verwendung für tupelgenauen Zugriffsschutz
- Views werden i.d.R. syntaktisch expandiert
- Erweiterungen
  - Materialisierte Sichten
  - Rekursive Views



# DDL

---

- DML: Data Manipulation Language
- DDL: Data Definition Language
- Definition von
  - Tabellen, Indexen, Views, ...
  - Administration: Tablespaces, Segmente, Rollen
  - Benutzerverwaltung: User, Gruppen, Rechte, ...

```
CREATE TABLE mitarbeiter (  
    p_id          NUMBER,  
    vorname       VARCHAR2(100),  
    nachname      VARCHAR2(100),  
    alter         NUMBER(2) CHECK (alter>0 AND alter<150),  
    adresse       VARCHAR2(1000)  
);
```

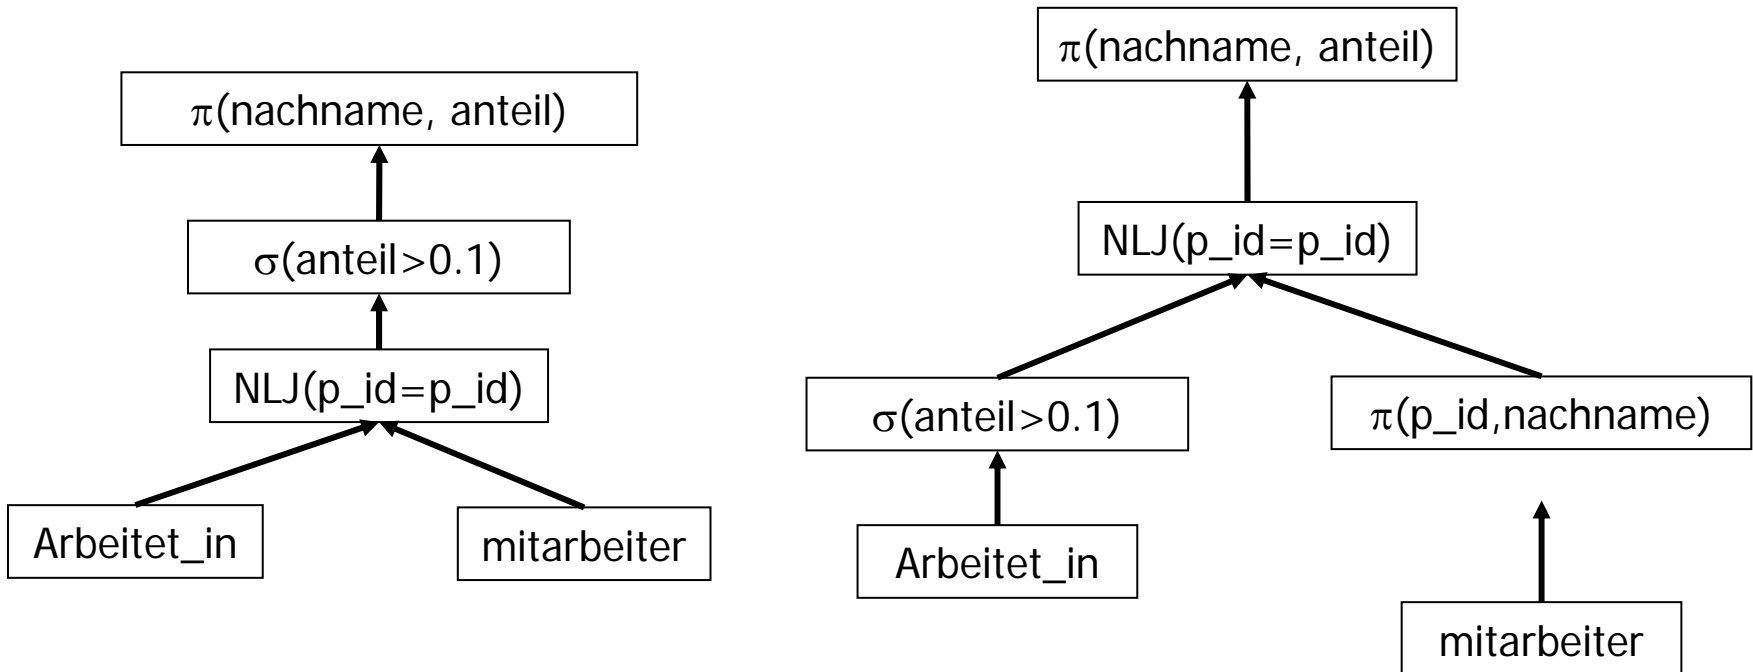
# Anfrageübersetzung und -optimierung

---

- Prinzipieller Ablauf
  - Parsen der Anfrage (Syntax)
  - Überprüfen der Schemaelemente („Semantik“)
  - Expandieren von Views
  - Berechnung von Ausführungsplänen
    - Exponentiell viele
  - Wahl des optimalen Ausführungsplans
    - Regelbasierter Optimierer
    - Kostenbasierter Optimierer - Statistik
  - Ausführung
    - Dynamisches Re-Planen?

# Ausführungspläne

```
SELECT      M.nachname, A.anteil
FROM        mitarbeiter M, arbeitet_in A
WHERE       M.p_id = A.p_id AND
           a.anteil > 0.1
```



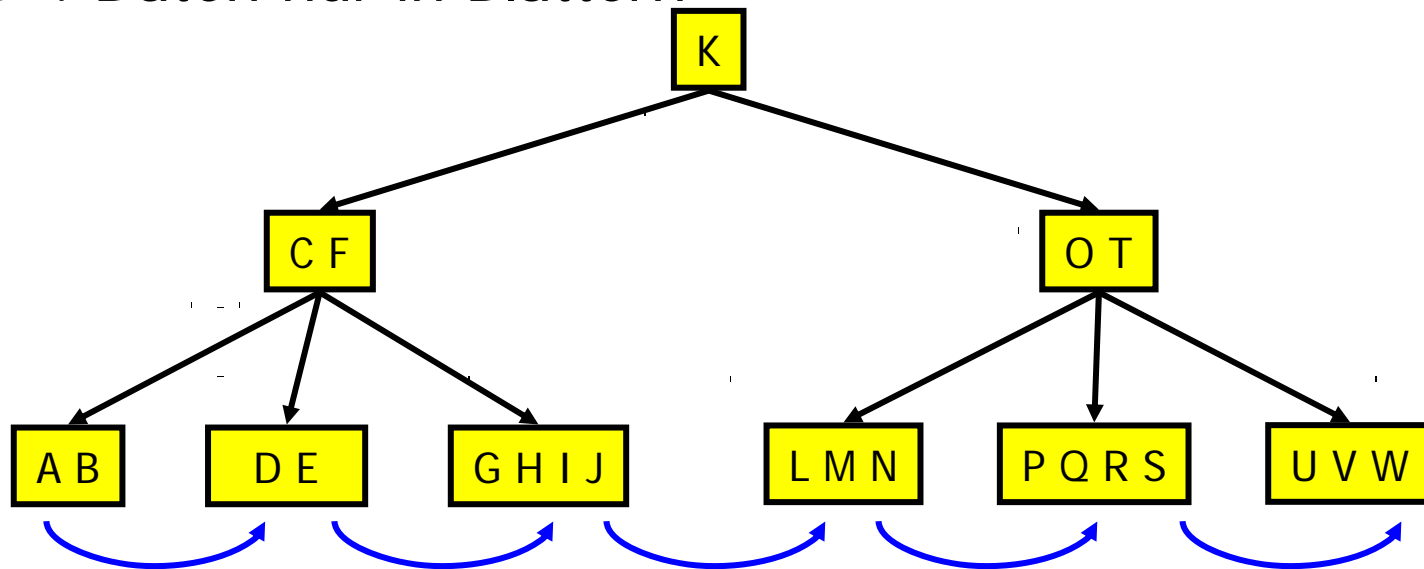
# Ausführungspläne

---

- Freiheitsgrade
  - Algebraische Anfrageumformung
  - Joinreihenfolge
  - Joinmethode (Nested Loop, Sort-Merge, Hash ...)
  - Access path: Indexzugriff (welcher?), Full-Table-Scan
    - 3,5,7% Regel (?)
  - Operatorreihenfolge
- Kostenbasierter Optimierung
  - Einbeziehung von Werteverteilungen, Tabellengrößen, Anzahl NULL-Werten, Histogrammen, Selektivität, ...
- Heuristische Ziele
  - Minimierung von Zwischenergebnissen
  - Minimierung von Sekundärspeicherzugriff

# Balancierter B und B\* Baum

- Knoten enthalten höchstens  $2m$  Schlüssel
- Knoten enthalten mindestens  $m$  Schlüssel, die Wurzel mindestens 1 Schlüssel
- Knoten mit  $x$  Schlüsseln hat  $x+1$  Kinder
- Balancierter Baum: Alle Blätter haben gleiche Tiefe
- B\*: Daten nur in Blättern



# Indexstrukturen

---

- + Sehr schneller Zugriff auf einzelne Elemente ( $O(\log(n))$ )
- + Schnelle Bereichsanfragen im B\* Baum
- + Indexierung von Attributkombinationen
  
- Elemente müssen geordnet werden können
- Degenerieren bei vielen Duplikaten
- Sequentieller Blockzugriff eventuell schneller (<5%)
- Zusammengesetzte Indexe duplizieren Tabellen
- Indexaktualisierung kostet Zeit
- Auch Indexe müssen gesperrt werden

# Integrität

---

- **Semantisch konsistenter** Zustand der Daten
  - Kann nur im Anwendungskontext definiert werden
- Überwachung nach Möglichkeit durch RDBMS
  - Datenmodell selber (Kardinalitäten)
  - Referentielle Integrität (**Fremdschlüssel**)
  - CHECK Constraints in DDL
  - Trigger
- Zeitpunkt der Überwachung?
  - Nach jeder Operation
  - Nach jeder Transaktion

# Normalformen

---

- Attribute hängen funktional voneinander ab
  - `p_id` → Vorname, Nachname, Alter ...
  - `proj_id` → Kunde, Status, ...
- Schlüsselkandidaten
  - Menge von Attributen, die alle anderen Attribute einer Tabelle funktional bestimmen
- Zerlegung nach funktionalen Abhängigkeiten
  - Datenbankentwurf
  - Armstrongkalkül
  - Ziel: Redundanzfreies Schema ohne Anomalien
  - Aber: Performanzsteigerung macht oftmals Denormalisierung notwendig

# Normalformen (nicht exakt ...)

---

- Relationenschema  $R$ , Primärschlüssel  $P$
- Erste Normalform (1NF)
  - Alle Attribute von  $R$  sind atomar (Adresse!)
- Zweite Normalform (2NF)
  - $R$  ist in 1NF
  - Kein Attribut  $A$  hängt von  $P' \subset P$  funktional ab
  - Schlecht: `lehrt(p_id, s_id, termin, stud_name)`
- Dritte Normalform (3NF)
  - $R$  in 1NF
  - Kein Attribut  $A$  hängt von  $A' \notin P$  ab
  - Schlecht: `mitarbeiter(p_id, plz, ort)`