Informationsintegration

Schema SQL: Multidatenbanksprachen am Beispiel

Ulf Leser

Wo sind wir?

- Architekturen und Kriterien
  - Verteilung, Autonomie, Heterogenität, Transparenz
  - Architekturen
    - Mediator-basierte Systeme
    - Data Warehouses
    - Multidatenbanksprachen, SchemaSQL
- Techniken zur Anfrageplanung in föderierten Systemen
- Verteilte Anfrageoptimierung
- Schemamanagement
- Datenintegration
- Semantische Integration

Buch

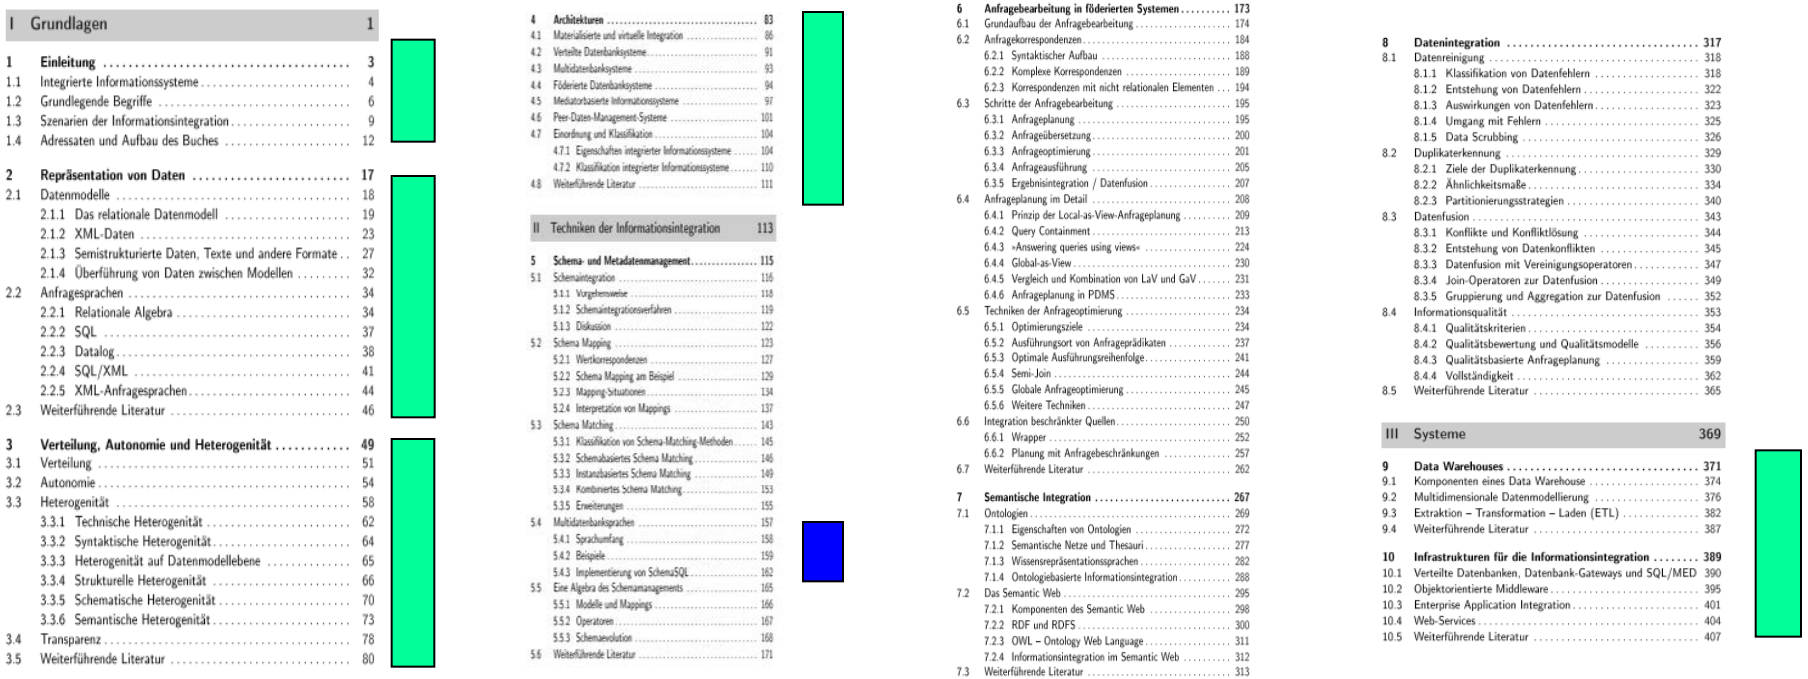

Inhalt dieser Vorlesung

- Multidatenbanksprachen
- SchemaSQL
- Ausklang

Enge versus lose Kopplung

- Enge Kopplung
  - Festes und integriertes Schema
  - Für Benutzer einheitliche Sicht
  - Automatische Anfrageübersetzung
  - System muss Änderungen der Quellen kompensieren

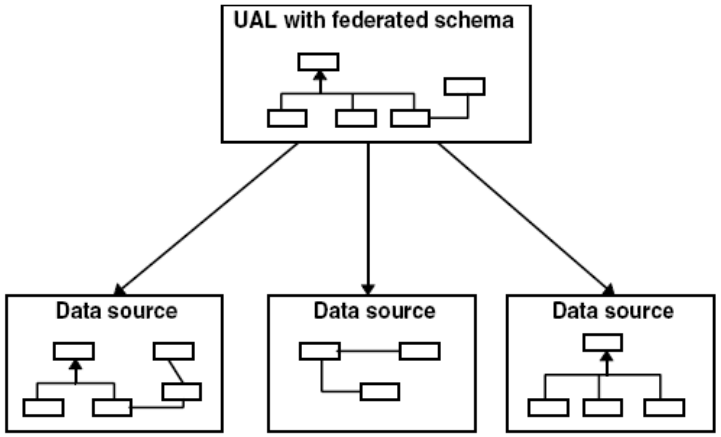

- Lose Kopplung
  - Kein integriertes Schema
  - Struktur / Semantik: Nutzer
  - Technische / Datenmodell-heterogenität ist gelöst
  - Änderungen gelangen zum Benutzer

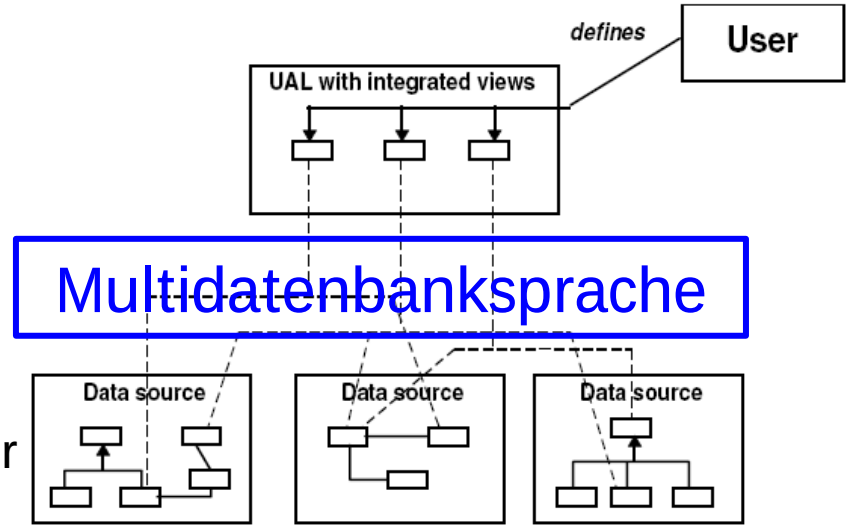

Strukturelle Heterogenität

- Schematisch: Unterschiedliche Modellelemente
  - Relation vs. Attribut
  - Attribut vs. Wert
  - Relation vs. Wert

SchemaSQL

- Unterschiedliche Verteilung von Werten auf Tabellen / Attribute
  - Unterschiedlicher Normalisierungsgrad
  - Fehlende/neue Attribute
  - Unterschiedliche Granularität
  - Unterschiedliche Fremdschlüssel

SQL

Anforderungen an Multidatenbanksprachen

- Schemaunabhängigkeit: Queries gegen „beliebige“ Schema
  - Zugriff auf alle (Meta-)daten
  - SQL Anfragen nur innerhalb eines Schemas gültig
    - Semantischer Check
- Umstrukturierungsmöglichkeiten
  - Inklusive Wechsel des Modellelements (Relation, Attribut, Wert)
- Syntaktische Abwärtskompatibilität mit SQL
- Technische Abwärtskompatibilität mit existierenden RDBMS
  - Anfragen sollten in SQL-Programme übersetzbar sein
- Effiziente Ausführung

Inhalt dieser Vorlesung

- Multidatenbanksprachen
- SchemaSQL
  - Grundlegende Syntax
  - Zugriff auf Metadaten
  - Horizontale Aggregation
  - Dynamische Sichten
  - Implementierung
- Ausklang

SchemaSQL [LSS96, LSS99, LSS01]

- Erweiterung von SQL
- Ziel: Überbrückung aller Arten struktureller Heterogenität
  - Zugriff auf Tabellen in verschiedenen Schemata
  - Daten und Metadaten werden gleich behandelt
  - Umstrukturierungen innerhalb der Anfrage
  - Dynamische Sichten
    - Ergebnisschema hängt vom Zustand der Datenbank ab
  - Horizontale Aggregation (über mehrere Spalten)

Beispiel

- Ziel: Integrierte Sicht mit Schema der ersten Quelle
  - Alle Filmtypen der ersten Quelle sollen im Ergebnis vorhanden sein
  - Diese sind durch Werte von **TYP** definiert
  - Tauchen als Tabellennamen in q2 auf

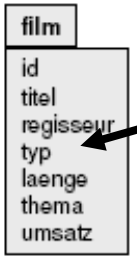


```
CREATE VIEW q1_q2
SELECT id, title, regisseur, typ
FROM   q1.film
UNION
SELECT F2.id, F2.title, F2.regisseur, A
FROM   q1::Film.typ F1, q2->A, q2::Film F2
WHERE  A = F1 AND
       F2.id = A.film_id
```

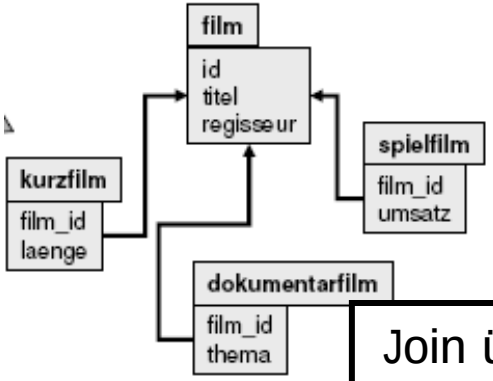

Join über Attributwerte in q1 und Tabellennamen in q2

Alle verschiedenen Werte von q1.film.typ

Iteriert über alle Relationennamen von q2

SQL: Semantik

- Variablendeklaration in FROM Klausel
- Variablenverwendung in SELECT und WHERE Klauseln
- Implizites „FORALL“ über alle Tupel einer Relation
  - Joins: Geschachtelte Schleifen
  - Implementierung kann anders vorgehen (z.B. Sort-Merge etc.)

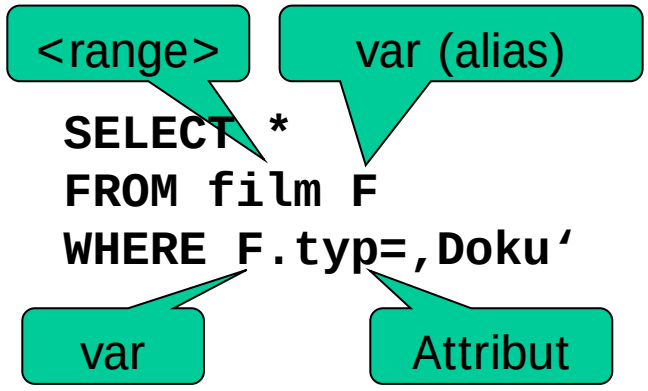

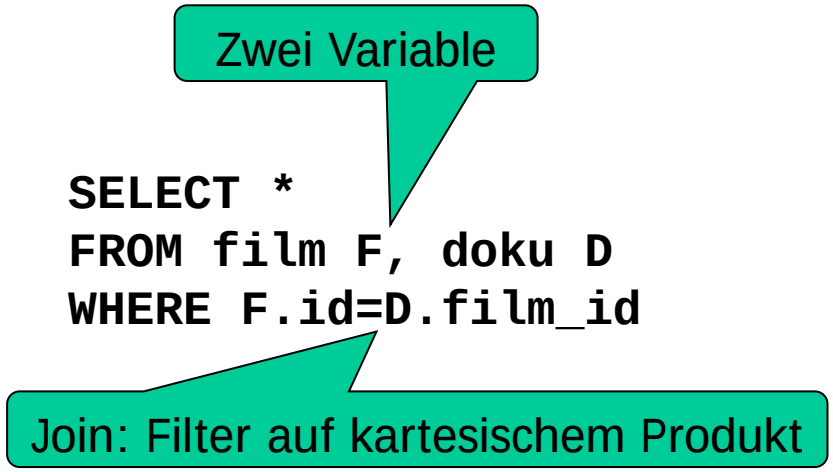

SchemaSQL: Syntax

- Grundlegende Syntax wie SQL
  - **`SELECT … FROM … WHERE`**
- Deklaration in FROM Klausel durch <range> <var>
- Variablen über fünf Wertbereichstypen
  - **`->`** Alle Datenbanknamen der Multidatenbank
  - **`db->`** Alle Relationennamen einer Datenbank **`db`**
  - **`db::rel->`** Alle Attributnamen einer Relation **`rel`** in **`db`**
  - **`db::rel`** Alle Tupel einer Relation **`rel`** in **`db`** (SQL)
  - **`db::rel.attr`** Alle verschiedenen Werte von **`attr`** in **`rel`** in **`db`**
- Geschachtelte Deklarationen
  - Spätere Deklarationen der FROM Klausel referenzieren frühere
  - Machen Queries nicht gerade sehr gut lesbar

Beispiel

- Multidatenbank aus mehreren Universitätsdatenbanken
  - **`univ-A, univ-B, univ-C, univ-D`**
- Information über Angestellte
  - Kategorie (**`category`**) – Prof, Technician, ...
  - Gehalt (**`salFloor`**)
  - Abteilung (**`dept`**) – Math, CS, ...

SchemaSQL – Beispiel

univ-A

salInfo

category	dept	salFloor
Prof	CS	65,000
AssocProf	CS	50,000
Technician	CS	45,000
Prof	Math	60,000
AssocProf	Math	55,000
Technician	Math	45,000

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

Gleiche Semantik (salary)

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

SchemaSQL – Beispiel

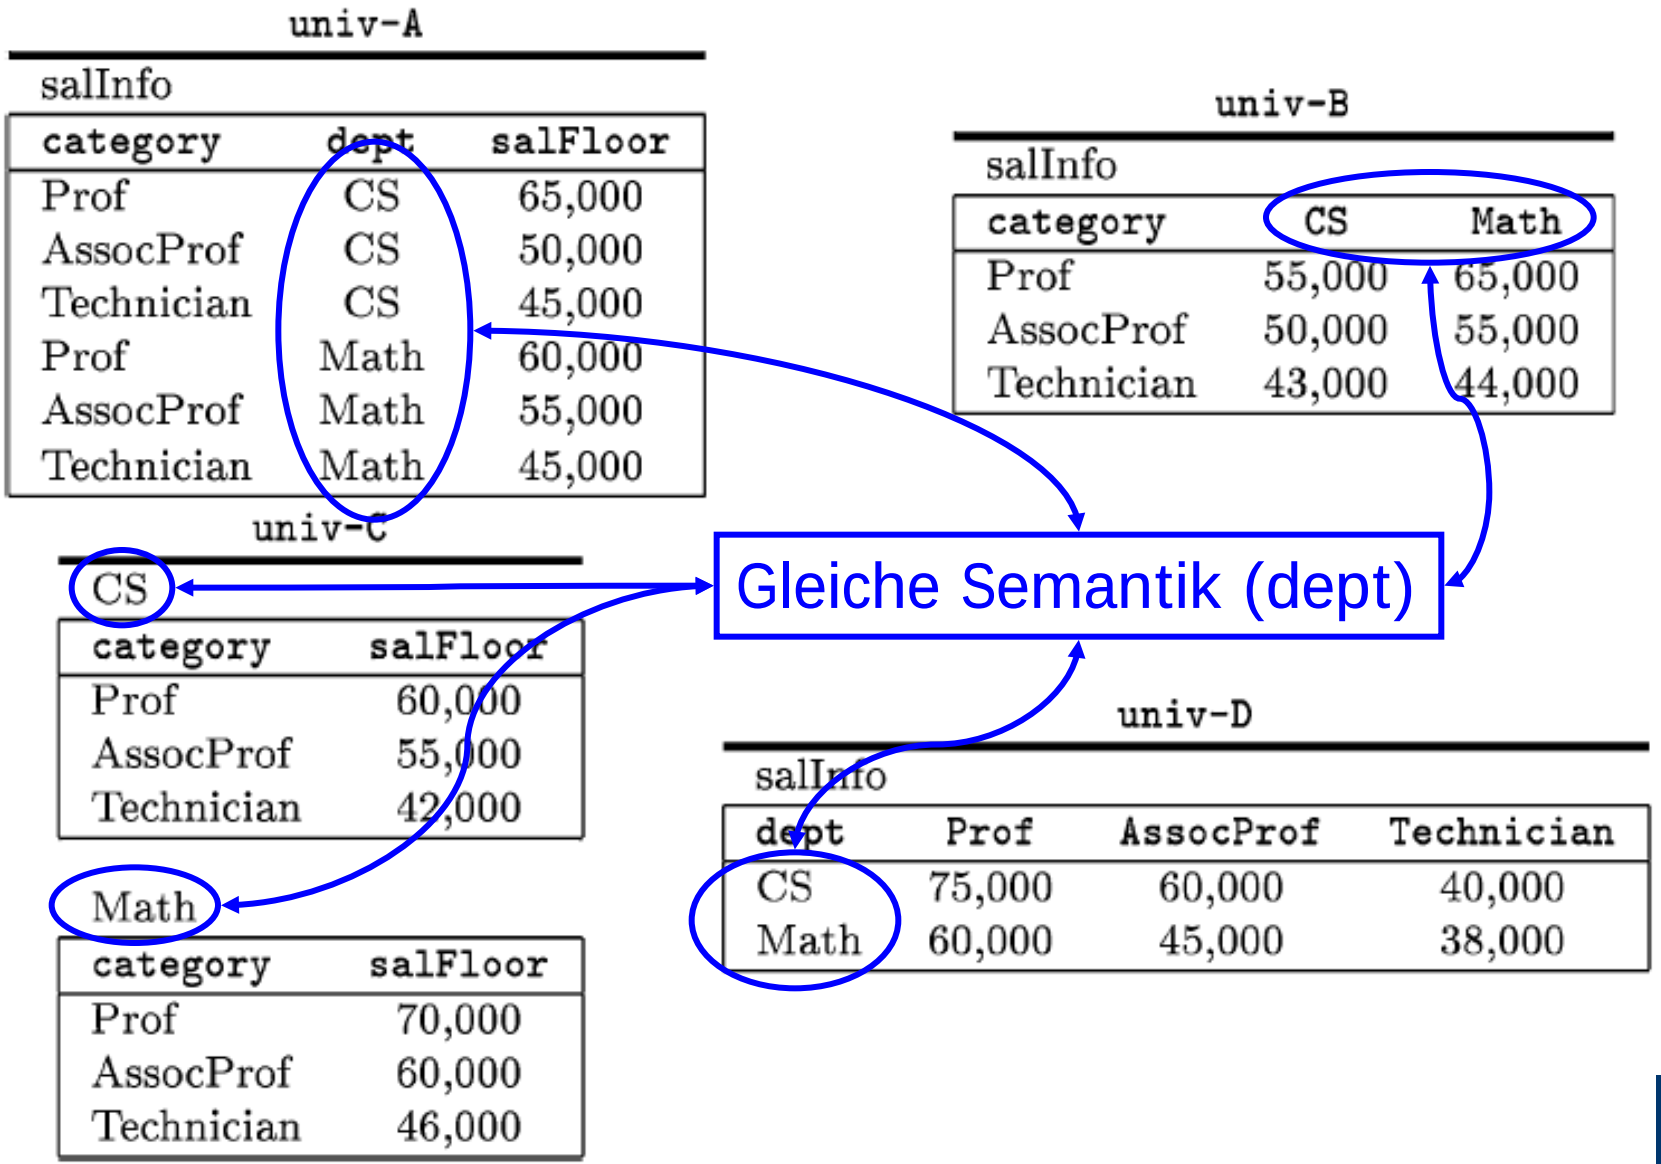

SchemaSQL – Beispiel

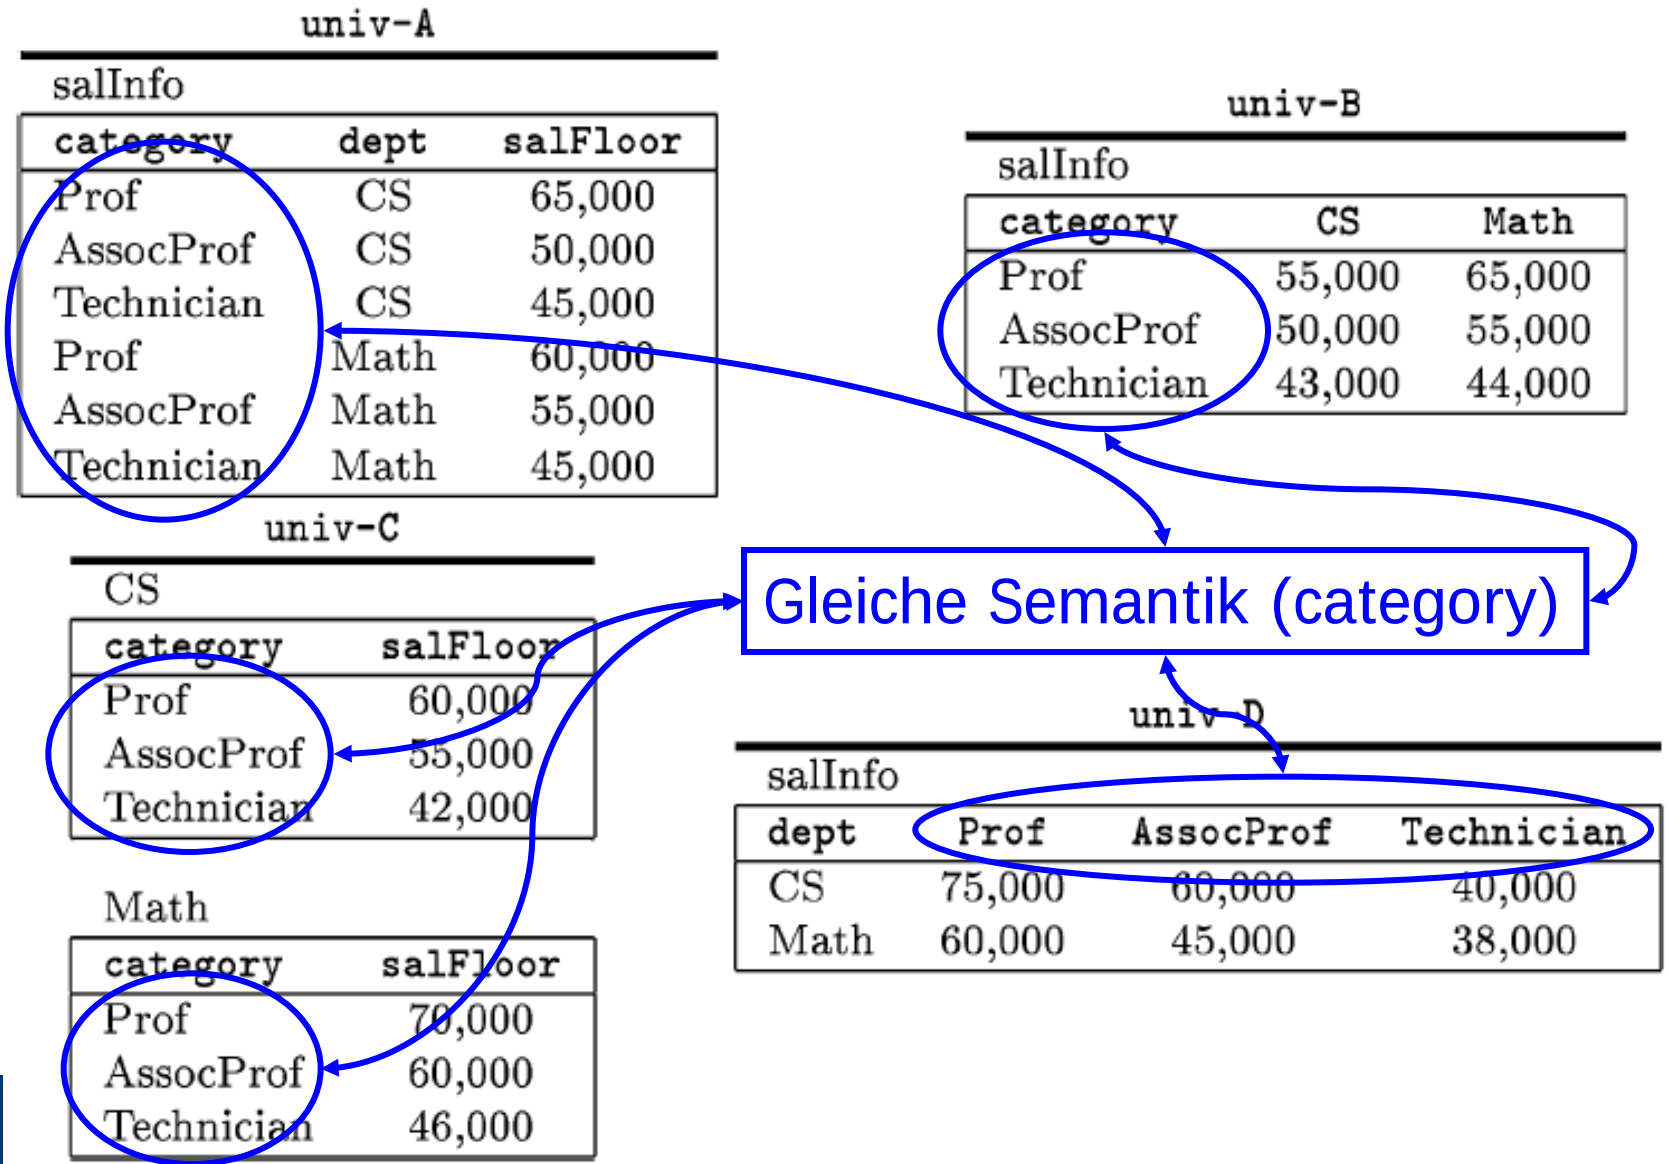

Beispiel 1

univ-A

salInfo

category	dept	salFloor
Prof	CS	65,000
AssocProf	CS	50,000
Technician	CS	45,000
Prof	Math	60,000
AssocProf	Math	55,000
Technician	Math	45,000

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

- Gesucht: Alle Abteilungen in univ-A, die Technikern mehr zahlen als gleiche Abteilungen in univ-B
- Anforderungen
  - Selektionen jeweils auf `Technician`
  - Vergleich der Gehälter
  - Join zwischen beiden Tabellen
    - Verschiedene DBs
    - Über welches Attribut?

->	alle Datenbanknamen
db->	alle Relationen in db
db::rel->	alle Attribute in rel (in db)
db::rel	alle Tupel in rel (in db)
db::rel.attr	alle Werte von Attribut attr

Lösung

univ-A

salInfo

category	dept	salFloor
Prof	CS	65,000
AssocProf	CS	50,000
Technician	CS	45,000
Prof	Math	60,000
AssocProf	Math	55,000
Technician	Math	45,000

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

- Gesucht: Alle Abteilungen in univ-A, die Technikern mehr zahlen als gleiche Abteilungen in univ-B
- SchemaSQL Anfrage

```
SELECT   A.dept
FROM     univ-A::salInfo A,
         univ-B::salInfo B,
         univ-B::salInfo-> AttB
WHERE    AttB <> `category` AND
         A.dept = AttB AND
         A.category = `Technician` AND
         B.category = `Technician` AND
         A.salFloor > B.AttB
```

Join zwischen Attributnamen und Spaltenwerten

Alle Attributnamen

Beispiel 2

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

- Gesucht: Alle Abteilungen in univ-C, die Technikern mehr zahlen als gleiche Abteilungen in univ-D
- Gleiche Anforderungen

->	alle Datenbanknamen
db->	alle Relationen in db
db::rel->	alle Attribute in rel (in db)
db::rel	alle Tupel in rel (in db)
db::rel.attr	alle Werte von Attribut attr

Lösung

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

- Gesucht: Alle Abteilungen in univ-C, die Technikern mehr zahlen als gleiche Abteilungen in univ-D
- SchemaSQL Anfrage

```
SELECT   RelC
FROM     univ-C-> RelC,
         univ-C::RelC C,
         univ-D::salInfo D
WHERE    RelC = D.dept AND
         C.category = `Technician` AND
         C.salFloor > D.Technician
```

Tabellenname als Ausgabe

Geschachtelte Deklaration: Tupel von C

Iteration über Tupel beider Tabellen in univ-C

Join zwischen Relationennamen und Spaltenwerten

Auswertung 1: Wertebereiche

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

```
SELECT  RelC
FROM    univ-C-> RelC,
        univ-C::RelC C,
        univ-D::salInfo D
WHERE   RelC = D.dept AND
        C.category = `Technician` AND
        C.salFloor > D.Technician
```

RelC

```
CS
MATH
```

C

```
[CS] Prof, 60.000
[CS] AssocProf, 55.000
[CS] Technician, 42.000
[MATH] Prof, 70.000
[MATH] AssocProf, 60.000
[MATH] Technician, 46.000
```

D

```
CS, 75.000, 60.000, 40.000
MATH, 60.000, 45,000, 38.000
```

Auswertung 2: Kartesisches Produkt

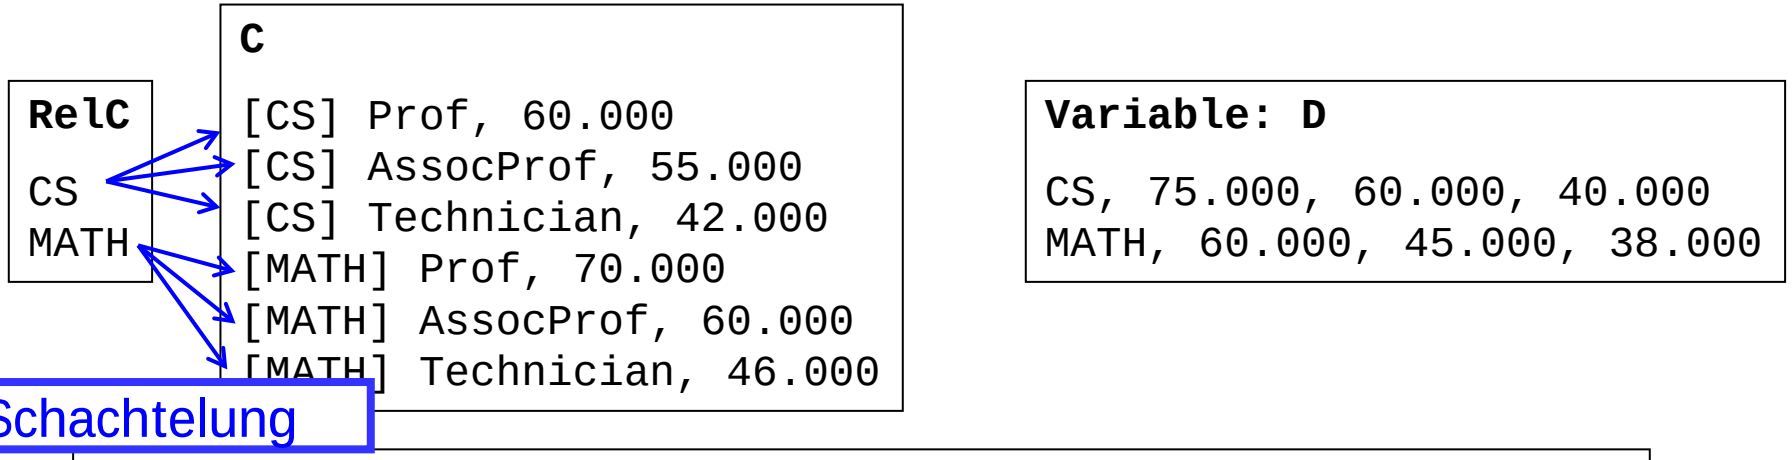

CS	Prof, 60.000	CS, 75.000, 60.000, 40.000
CS	Prof, 60.000	MATH, 60.000, 45.000, 38.000
CS	AssocProf, 55.000	CS, 75.000, 60.000, 40.000
CS	AssocProf, 55.000	MATH, 60.000, 45.000, 38.000
CS	Technician, 42.000	CS, 75.000, 60.000, 40.000
CS	Technician, 42.000	MATH, 60.000, 45.000, 38.000
MATH	Prof, 70.000	CS, 75.000, 60.000, 40.000
MATH	Prof, 70.000	MATH, 60.000, 45.000, 38.000
MATH	AssocProf, 60.000	CS, 75.000, 60.000, 40.000
MATH	AssocProf, 60.000	MATH, 60.000, 45.000, 38.000
MATH	Technician, 46.000	CS, 75.000, 60.000, 40.000
MATH	Technician, 46.000	MATH, 60.000, 45.000, 38.000

Auswertung 3: Join

```
SELECT      RelC
FROM        univ-C-> RelC,
            univ-C::RelC C,
            univ-D::salInfo D
WHERE       RelC = D.dept
AND         C.category = `Technician`
AND         C.salFloor > D.Technician
```

CS	Prof, 60.000	CS, 75.000, 60.000, 40.000
CS	Prof, 60.000	MATH, 60.000, 45.000, 38.000
CS	AssocProf, 55.000	CS, 75.000, 60.000, 40.000
CS	AssocProf, 55.000	MATH, 60.000, 45.000, 38.000
CS	Technician, 42.000	CS, 75.000, 60.000, 40.000
CS	Technician, 42.000	MATH, 60.000, 45.000, 38.000
MATH	Prof, 70.000	CS, 75.000, 60.000, 40.000
MATH	Prof, 70.000	MATH, 60.000, 45.000, 38.000
MATH	AssocProf, 60.000	CS, 75.000, 60.000, 40.000
MATH	AssocProf, 60.000	MATH, 60.000, 45.000, 38.000
MATH	Technician, 46.000	CS, 75.000, 60.000, 40.000
MATH	Technician, 46.000	MATH, 60.000, 45.000, 38.000

Auswertung 4: Bedingung 1

```
SELECT      RelC
FROM        univ-C-> RelC,
            univ-C::RelC C,
            univ-D::salInfo D
WHERE       RelC = D.dept
AND         C.category = `Technician`
AND         C.salFloor > D.Technician
```

~~CS~~	~~Prof, 60.000~~	~~CS, 75.000, 60.000, 40.000~~
~~CS~~	~~AssocProf, 55.000~~	~~CS, 75.000, 60.000, 40.000~~
CS	Technician, 42.000	CS, 75.000, 60.000, 40.000
~~MATH~~	~~Prof, 70.000~~	~~MATH, 60.000, 45.000, 38.000~~
~~MATH~~	~~AssocProf, 60.000~~	~~MATH, 60.000, 45.000, 38.000~~
MATH	Technician, 46.000	MATH, 60.000, 45.000, 38.000

Auswertung 5: Bedingung 2 und Projektion

```
SELECT      RelC
FROM        univ-C-> RelC,
            univ-C::RelC C,
            univ-D::salInfo D
WHERE       RelC = D.dept
AND         C.category = `Technician`
AND         C.salFloor > D.Technician
```

```
CS      Technician, 42.000    CS, 75.000, 60.000, 40.000
MATH    Technician, 46.000    MATH, 60.000, 45.000, 38.000
```

Einschub: Zugriff auf Metadaten?

- Liegen immer im Data dictionary (Katalog)
  - [Oracle]: Alle Attributnamen und –typen im eigenen Schema

```
SELECT attribute_name, attribute_type, table_name
FROM user_attributes;
```

  - Tabellennamen, Integritätsconstraints, Berechtigungen, ...
- Können in Anfragen verwendet werden
  - [Oracle] Alle Tabellen, die ein Attribut enthalten, dass denselben Namen hat wie ein Wert in **person2.geschlecht**

```
SELECT t.table_name
FROM user_tables t, person p2
WHERE t.attribute_name = p2.geschlecht;
```

```
person1( Id, vorname, nachname,
         maennlich, weiblich)
```

```
person2( Id, vorname, nachname,
         geschlecht)
```

- Kein dyn. Zugriff auf Tabellen „hinter“ den Metadaten
- Kein Standard

Einschub: Was sind Daten, was sind Metadaten?

- Universal database schema
  - Annahme: Datenbankweit eindeutige Tupel-IDs

```
tables( table_ name);
attribute( table_name, attribute_name, attribute_type);
tuple( table_name, tuple_id);
value( tuple_id, attribute_name, value);
```

- Kann prinzipiell alles ausdrücken, was ein beliebiges relationales Schema ausdrücken kann
  - Erweiterungen für IC‘s, Datentypkonformität, ...
- Schemaevolution wird zur Datenmanipulation
  - Neue Spalte: `INSERT INTO attribute VALUES( …)`

Warum brauchen wir mehr?

- Vorteile
  - Sehr flexibel
  - Sehr gut für theoretische Analysen (... über alle Schemata ...)
  - Einfach implementierbar
- Aber ...
  - Konzeptionelle Verwirrung – Daten / Metadaten?
  - Unverständlich – wo ist mein Schema? (meine Daten?)
  - Konsistenzhaltung sehr aufwändig
  - Viele Anfragen werden extrem kompliziert (`SELECT * FROM person`)
  - Schlechte Performanz
    - Alle Daten stehen in einer Spalte einer Tabelle
    - Keine separate Indexierung möglich
    - Keine differenzierte Selektivitätsabschätzungen möglich

Inhalt dieser Vorlesung

- Multidatenbanksprachen
- SchemaSQL
  - Grundlegende Syntax
  - Zugriff auf Metadaten
  - Horizontale Aggregation
  - Dynamische Sichten
  - Implementierung
- Ausklang
  - Andere Multidatenbanksprachen
  - Pivot-Operator

Aggregation in SQL

- Gruppierung und Aggregation in SQL ist immer vertikal
- Aggregation: Mehrere Werte einer Spalte zusammenfassen

```
SELECT COUNT(*)
FROM   mitarbeiter
```

- Gruppierung: Werte einer Spalte zu Gruppen formen

```
SELECT     m.id, SUM(p.Budget), MAX(p.Budget)
FROM       mitarbeiter m, projekt p
WHERE      m.p_id = p.p_id
GROUP BY   m.id
```

Horizontale Aggregation 1

- Ges: Durchschnittliches Gehalt in univ-B pro Kategorie über alle Abt.
  - Durchschnitt über Werte in zwei Spalten

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

```
SELECT   T.category, avg(T.D)
FROM     univ-B::salInfo-> D
         univ-B::salInfo T
WHERE    D <> `category`
GROUP BY T.category
```

->	alle Datenbanknamen
db->	alle Relationen in db
db::rel->	alle Attribute in rel (in db)
db::rel	alle Tupel in rel (in db)
db::rel.attr	alle Werte von Attribut attr

Semantik: Geschachtelte Projektion: Aggregation über Werte der Attribute T.D im aktuellen Tupel

Erklärung

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

D

~~Category~~
CS
MATH

T

Prof, 55, 65
AssocProf, 50, 55
Technician, 43, 44

```
SELECT   T.category, avg(T.D)
FROM     univ-B::salInfo-> D,
         univ-B::salInfo T
WHERE    D <> `category`
GROUP BY T.category
```

D x T

CS, P, 55, 65
Math, P, 55, 65
CS, AP, 50, 55
Math, AP, 50, 55
CS, T, 43, 44
Math, T, 43, 44

Group-by

P, CS, 55, 65
Math, 55, 65
AP, CS, 50, 55
Math, 50, 55
T, CS, 43, 44
Math, 43, 44

Horiz-AVG

P, CS, 55
Math, 65
AP, CS, 50
Math, 55
T, CS, 43
Math, 44

Result

P, 60
AP, 52.5
T, 43.5

Horizontale Aggregation 2

- Ges: Durchschnittliches Gehalt in univ-C pro Kategorie über alle Abt
  - Durchschnitt über Werte in zwei Spalten in verschiedenen Tabellen

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

```
SELECT   T.category, avg(T.salFloor)
FROM     univ-C-> D,
         univ-C::D T
GROUP BY T.category
```

Normale Aggregation über Liste von Attributwerten

->	alle Datenbanknamen
db->	alle Relationen in db
db::rel->	alle Attribute in rel (in db)
db::rel	alle Tupel in rel (in db)
db::rel.attr	alle Werte von Attribut attr

Tafel

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

```
SELECT      T.category, avg(T.salFloor)
FROM        univ-C-> D,
            univ-C::D T
GROUP BY T.category
```

D

CS
MATH

T

[CS], P, 65
[CS], AP, 55
[CS], T, 42
[math], P, 70
[math], AP, 60
[math], T, 46

D x T + schachtelung

CS, P, 65
CS, AP, 55
CS, T, 42
math, P, 70
math, AP, 60
math, T, 46

Group-by

P, CS, 65
   math, 70
AP, CS, 55
    match, 60
T, CS, 42
   math, 46

Gewöhnliche agg

P, 67.5
AP, 57.5
T, 44

Blockweise: Mehrere Spalten, mehrere Tupel

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

faculty

dname	fname
Math	MatNat II
Physics	MatNat I
CS	MatNat II

- Durchschnittliches Gehalt in univ-D aller Angestellten pro Fakultät
  - Aggregation über einen Block
  - Mehrere Zeilen, mehrere Spalten

```
SELECT F.fname, AVG(T.C)
FROM   univ-D::salInfo-> C,
       univ-D::salInfo T,
       univ-D::faculty F
WHERE  C <> „dept“ AND
       T.dept = F.dname
GROUP  BY F.fname
```

Semantik: Aggregation über Liste von Listen

Lösung

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

faculty

dname	fname
Math	MatNat II
Physics	MatNat I
CS	MatNat II

F

M, MNII
P, MNI
C, MNII

T

CS, 75, 60, 40
Math, 60, 45, 38

C

~~Debt~~
Prof
AssocProf
Tech

```
SELECT F.fname, AVG(T.C)
FROM       univ-D::salInfo-> C,
           univ-D::salInfo T,
           univ-D::faculty F
WHERE      C <> „dept“ AND
           T.dept = F.dname
GROUP      BY F.fname
```

T ⋈ F

CS, 75, 60, 40, MNII
Math, 60, 45, 38, MNII

(T join F) x C

CS, 75, 60, 40, MNII, P
CS, 75, 60, 40, MNII, AP
CS, 75, 60, 40, MNII, T
Math, 60, 45, 38, MNII, P
Math, 60, 45, 38, MNII, AP
Math, 60, 45, 38, MNII, T

Group-by

MNII, CS, 75, 60, 40, P
CS, 75, 60, 40, AP
CS, 75, 60, 40, T
Math, 60, 45, 38, P
Math, 60, 45, 38, AP
Math, 60, 45, 38, T

Horizon Agg

MNII, CS, 75
CS, 60
CS, 40
Math, 60
Math, 45
Math, 38

Result

MNII, …

Inhalt dieser Vorlesung

- Multidatenbanksprachen
- SchemaSQL
  - Grundlegende Syntax
  - Zugriff auf Metadaten
  - Horizontale Aggregation
  - Dynamische Sichten
  - Implementierung
- Ausklang
  - Andere Multidatenbanksprachen
  - Pivot-Operator

Sichten zur Umstrukturierung

univ-A

salInfo

category	dept	salFloor
Prof	CS	65,000
AssocProf	CS	50,000
Technician	CS	45,000
Prof	Math	60,000
AssocProf	Math	55,000
Technician	Math	45,000

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

- Gesucht: Umstrukturierung aller Daten aus univ-B in das Schema von univ-A
- Zwei Schritte
  - Definition des Outputschemas
  - Umstrukturierung der Daten
  - Schema steht hier fest

```
CREATE VIEW BtoA AS
SELECT T.category AS category,
       D AS dept,
       T.D AS salFloor
FROM   univ-B::salInfo-> D,
       univ-B::salInfo T
WHERE  D <> `category`
```

Dynamische Sichten (siehe auch PIVOT)

univ-A

salInfo

category	dept	salFloor
Prof	CS	65,000
AssocProf	CS	50,000
Technician	CS	45,000
Prof	Math	60,000
AssocProf	Math	55,000
Technician	Math	45,000

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

- Gesucht: Umstrukturierung der Daten aus univ-A in das Schema von univ-B
  - Dynamische Schemaerzeugung

Domain: Alle distinct Werte von univ-A::A.dept

```
CREATE VIEW AtoB::salInfo(category, D) AS
SELECT  A.category, A.salFloor
FROM    univ-A::salInfo A,
        univ-A::A.dept D
```

Semantik: Domainvariable in Output-Schema-Definition eines Views wird dynamisch expandiert zu D_1, D_2,..., D_n

Erklärung

univ-A

salInfo

category	dept	salFloor
Prof	CS	65,000
AssocProf	CS	50,000
Technician	CS	45,000
Prof	Math	60,000
AssocProf	Math	55,000
Technician	Math	45,000

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

```
CREATE VIEW AtoB::salInfo(category, D) AS
SELECT  A.category, A.salFloor
FROM    univ-A::salInfo A,
        univ-A::A.dept D
```

D

CS
Math

A

```
Prof, CS, 65.000
AssocProf, CS, 50.000
Technician, CS, 45.000
Prof, Math, 60.000
AssocProf, Math, 55.000
Technician, Math, 45.000
```

```
Prof, CS, 65.000                CS
AssocProf, CS, 50.000           CS
Technician, CS, 45.000          CS
Prof, Math, 60.000              Math
AssocProf, Math, 55.000         Math
Technician, Math, 45.000        Math
```

Magie 1

- Geschachtelte Deklaration
  - Kein Kartesisches Produkt

Erklärung 2

```
CREATE VIEW AtoB::salInfo(category, D) AS
SELECT  A.category, A.salFloor
FROM    univ-A::salInfo A,
        univ-A::A.dept D
```

```
Prof, CS, 65.000                CS
AssocProf, CS, 50.000           CS
Technician, CS, 45.000          CS
Prof, Math, 60.000              Math
AssocProf, Math, 55.000         Math
Technician, Math, 45.000        Math
```

```
Prof, CS, 65.000                CS
      Math, 60.000              Math
AssocProf, CS, 50.000           CS
           Math, 55.000         Math
Technician, CS, 45.000          CS
           Math, 45.000         Math
```

Magie 2

– Gruppiere nach salInfo.category

partment. Intuitively, all tuples in **univ-A::salInfo** corresponding to the same category are grouped together and "merged" to produce one output tuple.

Another aspect of this restructuring view is the use

Erklärung 3

```
CREATE VIEW AtoB::salInfo(category, D) AS
SELECT  A.category, A.salFloor
FROM    univ-A::salInfo A,
        univ-A::A.dept D
```

```
Prof, CS, 65.000                CS
      Math, 60.000              Math
AssocProf, CS, 50.000           CS
           Math, 55.000         Math
Technician, CS, 45.000          CS
           Math, 45.000         Math
```

Category	CS	Math
Prof	65.000	60.000
AssocProf	50.000	55.000
Technician	45.000	45.000

Magie 3

- Jeder Wert von D wird eine Spalte des Ausgabeschemas
- Übernimmt implizit Werte von salFloor entsprechend Werten von A.dept = D
- Das ist nicht gut lesbar ...

Inhalt dieser Vorlesung

- Multidatenbanksprachen
- SchemaSQL
  - Grundlegende Syntax
  - Zugriff auf Metadaten
  - Horizontale Aggregation
  - Dynamische Sichten
  - Implementierung
- Ausklang
  - Andere Multidatenbanksprachen
  - Pivot-Operator

Ziele

- „Non-intrusive“
- Ausnutzung vorhandener RDBMS
- Übersetzung von Schema-SQL in Sequenz von (verteilten) SQL Befehlen
- Optimierung
- Metadatenverwaltung

Ablauf

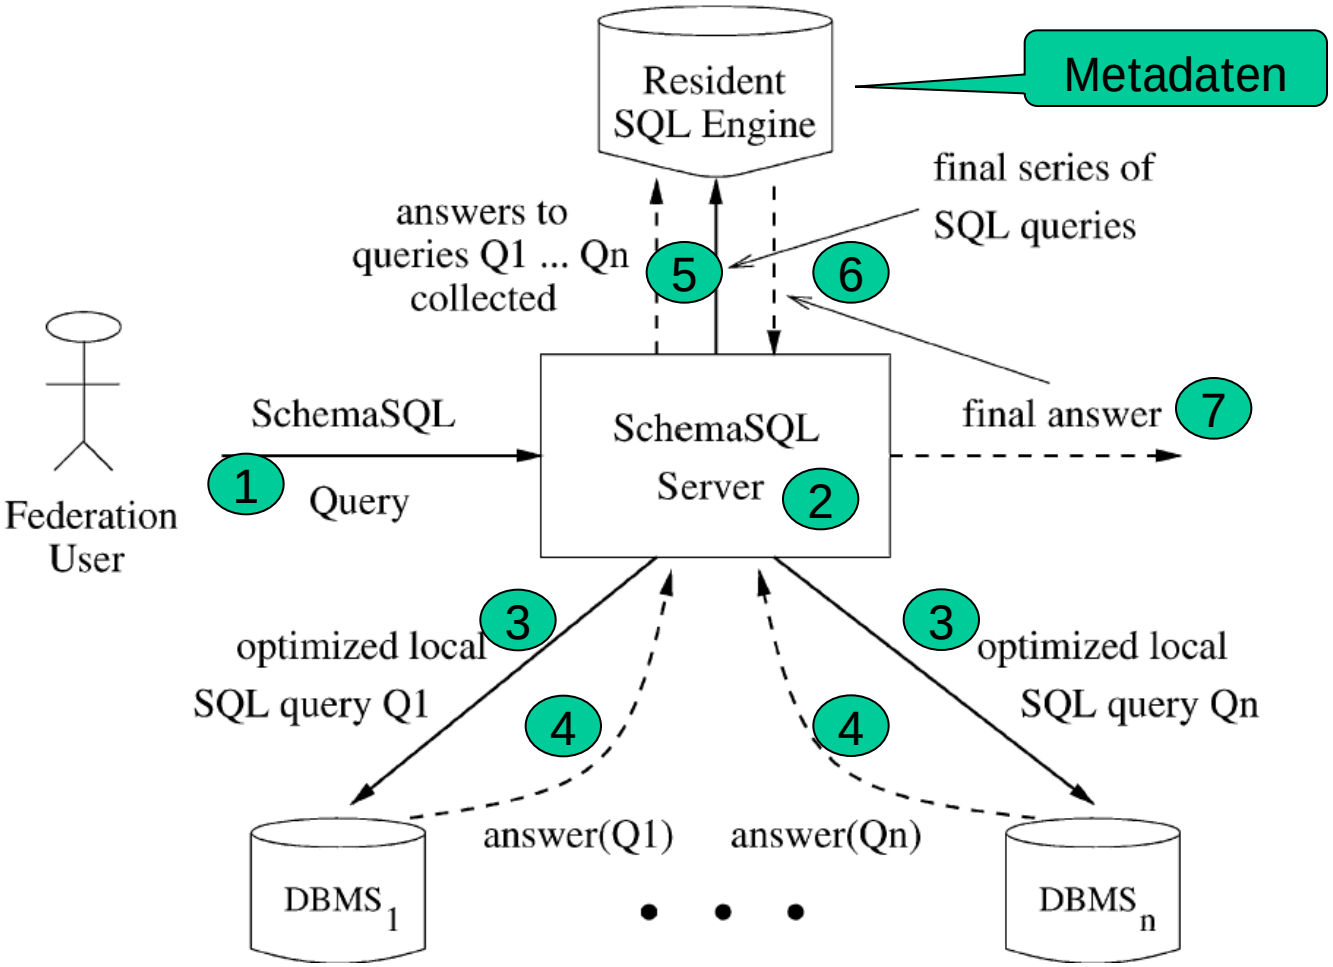
Resident
SQL Engine
Metadaten
final series of
SQL queries
answers to
queries Q1 ... Qn
collected
5
6
Federation
User
SchemaSQL
1
Query
SchemaSQL
Server
2
final answer
7
3
optimized local
SQL query Q1
3
optimized local
SQL query Qn
4
4
answer(Q1)
answer(Qn)
DBMS 1
DBMS n

Anfragebearbeitung

- Phase 1
  - Variablen der FROM Klausel instantiieren
    - VITs (Variable instantiation table)
  - Unter Verwendung der Metadaten
    - FST (Federation System Table)
    - Schema
      `FST( dbname, relationname, attributename)`
- Phase 2
  - SchemaSQL Anfrage in lokale Query gegen VITs umschreiben
  - Umgeschriebene Anfrage in der Resident SQL Engine ausführen

Beispielanfrage

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

Alle Abteilungen in univ-C, die Technikern mehr zahlen als gleiche Abteilungen in univ-D

```
SELECT  RelC, salFloor
FROM    univ-C-> RelC,
        univ-C::RelC C,
        univ-D::salInfo D
WHERE   RelC = D.dept
AND     C.category = `Technician`
AND     C.salFloor > D.Technician
```

Phase 1

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	4

Math

category	sa
Prof	7
AssocProf	60,000
Technician	46,000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

```
FST(dbname, relname, attname)
```

```
SELECT    RelC, salFloor
FROM      univ-C-> RelC,
          univ-C::RelC C,
          univ-D::salInfo D
WHERE     RelC = D.dept
AND       C.category = `Technician`
AND       C.salFloor > D.Technician
```

- VIT_{RelC}(RelC)
  - Anfrage an Metadaten

```
SELECT DISTINCT relname
FROM   FST
WHERE  dbname = ,univ-C‘;
```

- VIT_{C}(RelC, C.category, C.salFloor):
  - Alle Werte von VIT_{ReclC}

```
SELECT RelC FROM VIT_RelC;
```

  - Zu einer Query an univ-C kompilieren

```
SELECT ,CS‘ AS RelC,
       category as Ccategory
       salFloor AS CsalFloor
FROM   univ-C.CS
  UNION ... UNION
SELECT ,MATH‘ AS RelC ,
       category as Ccategory,
        salFloor AS CsalFloor
FROM   univ-C.MATH;
```

- VIT_{D}(D.dept, D.technician)
  - Anfrage direkt an univ-D

```
SELECT dept AS Ddept,
       technician AS D
FROM   univ-D.salInfo;
```

Optimiert: Selektionen pushen

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	4

Math

category	sa
Prof	7
AssocProf	60,000
Technician	46,000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

```
FST(dbname, relname, attname)
```

```
SELECT    RelC, salFloor
FROM      univ-C-> RelC,
          univ-C::RelC C,
          univ-D::salInfo D
WHERE     RelC = D.dept
AND       C.category = `Technician`
AND       C.salFloor > D.Technician
```

- VIT_{RelC}(RelC)
  - Anfrage an Metadaten

```
SELECT DISTINCT relname
FROM   FST
WHERE  dbname = ,univ-C‘;
```

- VIT_{C}(RelC, C.salFloor):
  - Alle Werte von VIT_{ReclC}

```
SELECT RelC FROM VIT_RelC;
```

  - Zu einer Query an univ-C kompilieren

```
SELECT ,CS‘ AS RelC,
       salFloor AS CsalFloor
FROM   univ-C.CS
WHERE  category=,Technician‘
  UNION ... UNION
SELECT ,Math‘ AS RelC,
       salFloor AS CsalFloor
FROM   univ-C.Math
WHERE  category=,Technician‘;
```

- VIT_{D}(D.dept, D.technician)
  - Anfrage direkt an univ-D

```
SELECT dept AS Ddept,
       technician AS D
FROM   salInfo;
```

Werte in den VIT

- VIT_{RelC}(RelC)
  - {(Math), (CS)}
- VIT_{C}(RelC, C.salFloor)
  - {([CS], 42.000), ([Math], 46.000)}
- VIT_{D}(D.dept, D.technician)
  - {(CS, 40.000), (Math, 38.000)}

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75,000	60,000	40,000
Math	60,000	45,000	38,000

```
SELECT  RelC, salFloor
FROM    univ-C-> RelC,
        univ-C::RelC C,
        univ-D::salInfo D
WHERE   RelC = D.dept
AND     C.category = `Technician`
AND     C.salFloor > D.Technician
```

Phase 2

- VITs sind in lokaler Datenbank materialisiert
- SchemaSQL Anfrage so umschreiben, dass das Endergebnis auf den materialisierten VITs berechnet wird

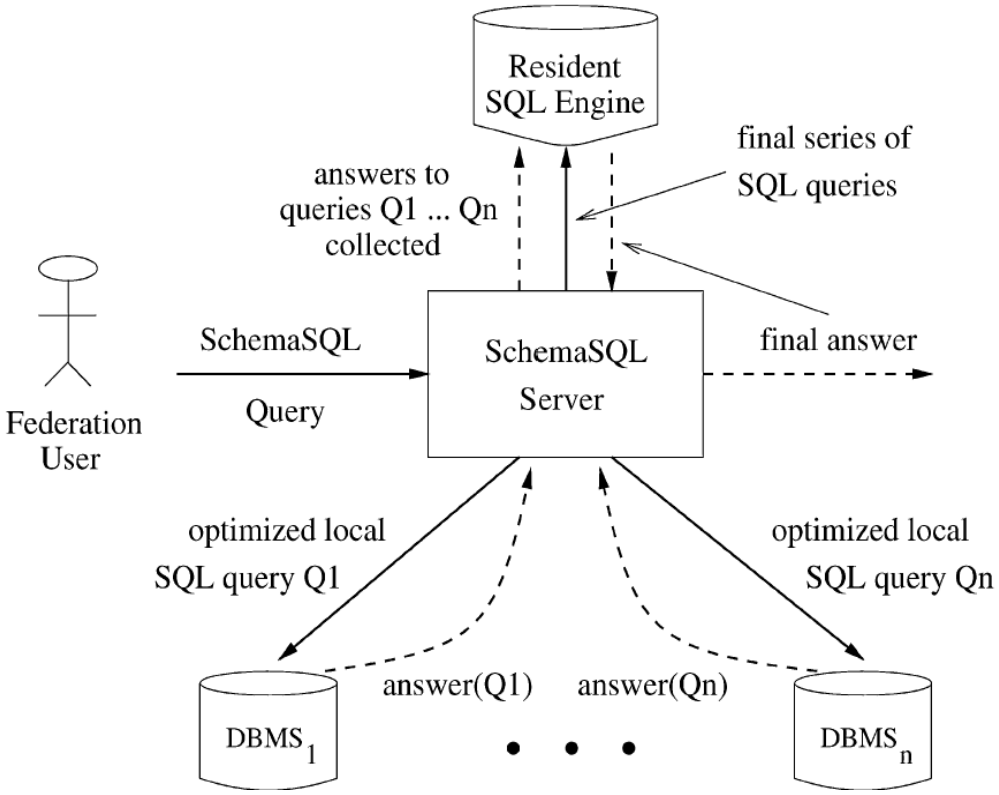

Umgeschriebene Anfrage

VIT_{RelC}

RelC
CS
Math

VIT_C

RelC	CsalFloor
CS	42,000
Math	46,000

VIT_D

Ddept	Dtechnician
CS	40,000
Math	38,000

- Zusätzlicher Natural Join über alle VITs bei geschachtelten Deklarationen

```
CREATE VIEW JVIT(RelC, CsalFloor, Ddept, Dtechnician) AS
SELECT  VIT_RelC.RelC, VIT_C.CsalFloor, VIT_D.Ddept, VIT_D.Dtechnician
FROM    VIT_RelC, VIT_C, VIT_D
WHERE   VIT_RelC.RelC = VIT_D.Ddept AND
        VIT_C.CsalFloor > VIT_D.Dtechnician AN
        VIT_RelC.RelC = VIT_C.RelC
```

```
SELECT   RelC, salFloor
FROM     univ-C-> RelC,
         univ-C::RelC C,
         univ-D::salInfo D
WHERE    RelC = D.dept
AND      C.category = `Technician'
AND      C.salFloor > D.Technician
```

Schon bei Erzeugung der VITs

Endergebnis

- Noch mal die umgeschriebene Anfrage

```
CREATE VIEW JVIT(RelC, CsalFloor, Ddept, Dtechnician)
AS
SELECT  VITRelC.RelC, VITC.CsalFloor,
        VITD.Ddept, VITD.Dtechnician
FROM    VITRelC, VITC, VITD
WHERE   VITRelC.RelC = VITD.Ddept AND
        VITC.CsalFloor > VITD.Dtechnician AND
        VITRelC.RelC = VITC.RelC
```

- Endgültige Anfrage
  - Projektionen, Sortierungen, etc.

```
SELECT  RelC, CsalFloor
FROM    JVIT
```

Optimierungspotential

- Selektionen und Projektionen zu den Quellen pushen
- Kombinierte VIT
  - Wenn mehrere Variablen zu einer Datenbank gehören und die Verknüpfung in SQL ausdrückbar ist („normaler“ Join)
  - Verknüpfte Anfrage an Quelle schicken
  - Das kombinierte Ergebnis in einer kombinierten VIT speichern
- Ergebnisse einer VIT in die Berechnung der späteren pushen
  - Also gezieltere Anfragen erzeugen – weniger Datentransfer, komplexere Anfragelogik
  - Reihenfolgeproblem (Heuristik: Metadatenzugriffe zuerst)

Inhalt dieser Vorlesung

- Multidatenbanksprachen
- SchemaSQL
- Ausklang
  - Andere Multidatenbanksprachen
  - Pivot-Operator

Andere Multidatenbanksprachen

- Vorläufer
  - F-Logic, SchemaLog, Pegasus, SQL/M, ...
  - Beispiel F-Logic: Logische Sprache (wie Tupelkalkül) mit Vererbung, strukturierten und mengenwertigen Attributen, Tupel-ID, ...
  - Zugriff auf Strukturdaten (Metadaten) in einer Anfrage
  - „Semantically First-Order, but syntactically second-order“
- Nachfolger: FISQL/FIRA (Wyss & Wyss 2007, Wyss & Robertson 2005)
  - Basiert auf erweiterter relationaler Algebra – sauberer Entwurf
  - Generischer: Dynamische Schema, Subqueries, etc.
    - Keine horizontale Aggregationen
  - Regelbasierter Optimierer
    - Ziel: Größtmögliche SQL-Teilqueries direkt an Quellen schicken
  - Vollständig implementiert (angeblich)

First-Order Queries

```
SELECT  C.CS
FROM    salInfo C
WHERE   C.category=‚Technician‘;
```

$$\{Y \mid salInfo(X, Y, Z) \wedge X = 'Technician'\}$$

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

Syntactically second-order

```
SELECT  B.C
FROM    univ-C-> C,
        univ-B::salInfo B;
```

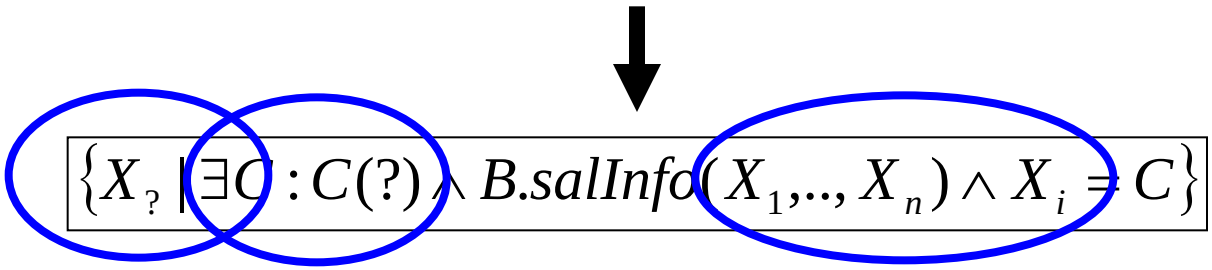

$$\{X_? \mid \exists C : C(?) \wedge B.salInfo(X_1,..,X_n) \wedge X_i = C\}$$

?

univ-B

salInfo

category	CS	Math
Prof	55,000	65,000
AssocProf	50,000	55,000
Technician	43,000	44,000

univ-C

CS

category	salFloor
Prof	60,000
AssocProf	55,000
Technician	42,000

Math

category	salFloor
Prof	70,000
AssocProf	60,000
Technician	46,000

... semantically first-order ...

- Schemata sind endlich
- Zum Zeitpunkt der Anfrage stehen alle möglichen Instanzen der Variablen fest
  - Bzw. während der Ausführung bei geschachtelten Deklarationen
- Umschreiben in UNIONs von First-Order Anfragen möglich
  - Genau diese Strategie implementiert SchemaSQL

```
SELECT  B.C
FROM    univ-C-> C,
        univ-B::salInfo B;
```

```
get_values( univ-C->);
construct_query(

SELECT  B.CS
FROM    univ-B::salInfo B
UNION
SELECT  B.Math
FROM    univ-B::salInfo B
);
…
```

Beispiel weitere Operatoren: Pivot

- Existiert in diversen Systemen
  - Excel, Access, ...
- Vertauscht Spalten und Zeilen einer Tabelle
  - Pivot: „Ausklappen“ aller DISTINCT Werte einer Spalte als eigene Spalte
    - Ergebnis hat mehr Spalten, aber weniger Zeilen
  - Unpivot: „Einklappen“ aller Spalten als zusätzliches Zeilenpräfix
    - Ergebnis hat weniger Spalten, aber mehr Zeilen
- Voraussetzung: Eindeutigkeit
  - Nur ein Wert pro Monat/Jahr
  - Sonst „Data Collision“

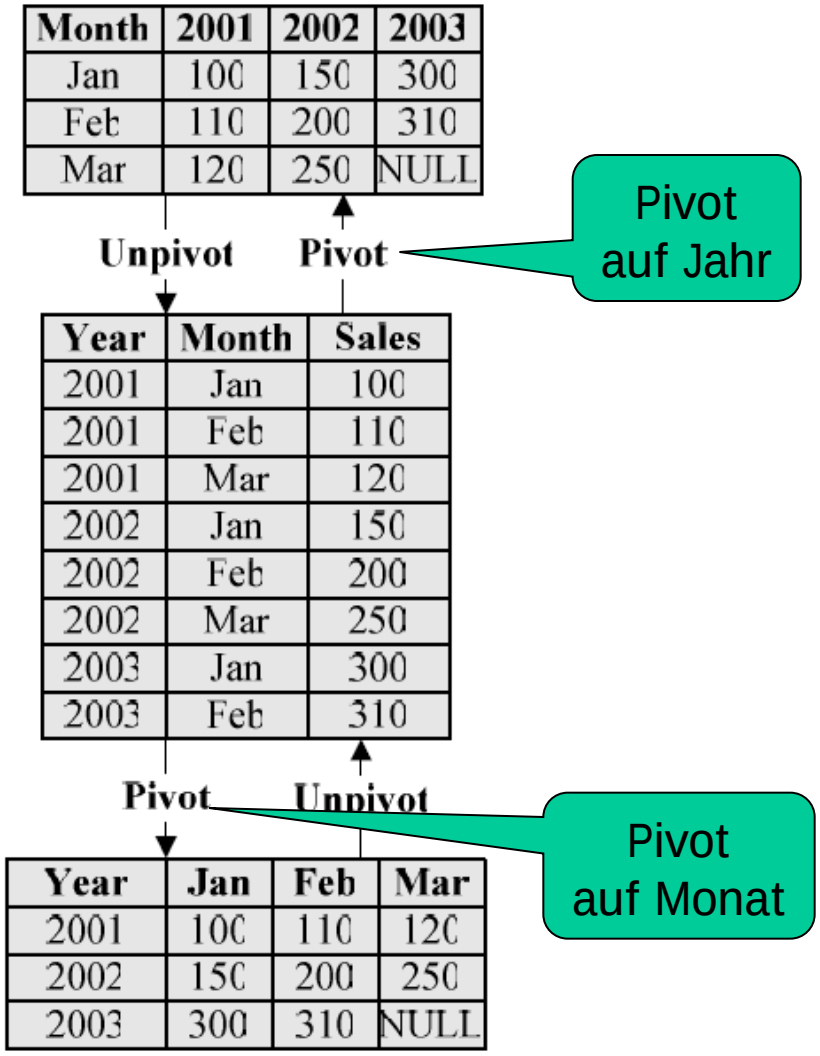

Pivot in SQL

- Ist in SQL ausdrückbar
  - Komplizierte Anfragen
  - Hängen von Attributwerten ab
    - Syntactically second-order
  - Schwierig zu optimieren
- Raum für eigene Operatoren
  - Pivot-Operator seit ~2009 in kommerziellen RDBMS

Year	Month	Sales
2001	Jan	100
2001	Feb	110
2001	Mar	120
2002	Jan	150
2002	Feb	200
2002	Mar	250
2003	Jan	300
2003	Feb	310

Pivot

Unpivot

Year	Jan	Feb	Mar
2001	100	110	120
2002	150	200	250
2003	300	310	NULL

```
SELECT
Year,
(SELECT Sales FROM SalesTable AS T2 WHERE Month = 'Jan' AND T2.Year = T1.Year) AS 'Jan',
(SELECT Sales FROM SalesTable AS T2 WHERE Month = 'Feb' AND T2.Year = T1.Year) AS 'Feb',
(SELECT Sales FROM SalesTable AS T2 WHERE Month = 'Mar' AND T2.Year = T1.Year) AS 'Mar'
FROM SalesTable AS T1
GROUP BY Year
```

Literatur

- SchemaSQL
  - [LSS01] Laks V. S. Lakshmanan, Fereidoon Sadri, Subbu N. Subramanian: SchemaSQL: An extension to SQL for multidatabase interoperability. ACM Trans. Database Syst. 26(4): 476-519 (2001)
  - [LSS96] Lakshaman, Sadri, Subramanian: SchemaSQL – A Language for Interoperability in Relational Multidatabase Systems, in VLDB 1996
  - [LSS99] Lakshaman, Sadri, Subramanian: On Efficiently Implementing SchemaSQL on a SQL Database System, in VLDB 1999
- Pivot
  - [CGGL04] C Cunningham, G Graefe, CA Galindo-Legaria: PIVOT and UNPIVOT: Optimization and Execution Strategies in an RDBMS, in VLDB 2004