Datenintegration

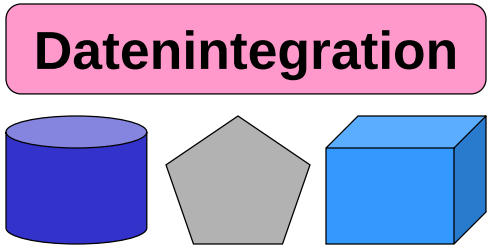

Kapitel 5: Anfrageverarbeitung

Dr. Anika Groß
Sommersemester 2016

Universität Leipzig
Institut für Informatik
http://dbs.uni-leipzig.de

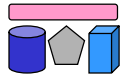

Inhalt

- Multidatenbanksprachen am Beispiel von SchemaSQL
  - Grundlegende Syntax inklusive Zugriff auf Metadaten
  - Horizontale Aggregation und dynamische Umstrukturierung
- Global-as-View (GaV) und Local-as-View (LaV)
  - GaV: Modellierung und Anfragebearbeitung
  - LaV: Modellierung
  - Vergleich
- LaV-Anfragebearbeitung
  - Query Containment
  - Answering Queries using Views
  - Quellen mit beschränkten Anfragemöglichkeiten

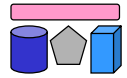

Enge vs. lose Kopplung

- Lose Kopplung
  - Kein festes Schema
    - Nutzer müssen Semantik der Quellen kennen
    - Integrierte Sichten helfen
  - Multidatenbanksprachen

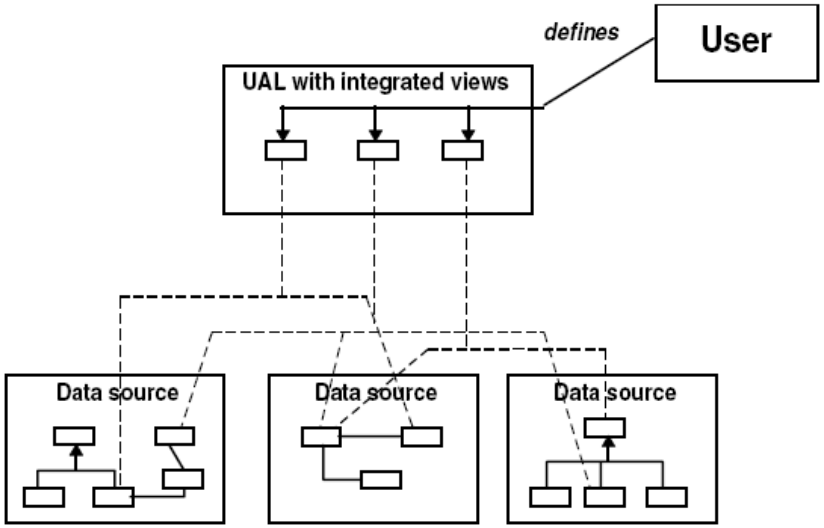

- Enge Kopplung
  - Globales / integriertes / föderiertes Schema
    - Nutzer stellen Anfrage bzgl. globalem Schema
    - Nutzer müssen Schema / Semantik der Quellen nicht kennen
  - Globas-As-View (GaV)
  - Local-As-View (LaV)

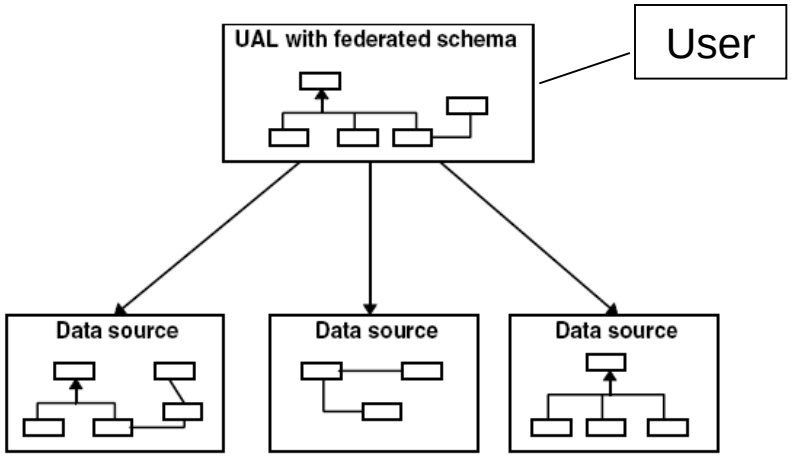

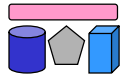

Wdh: Multidatenbanken [VAh]

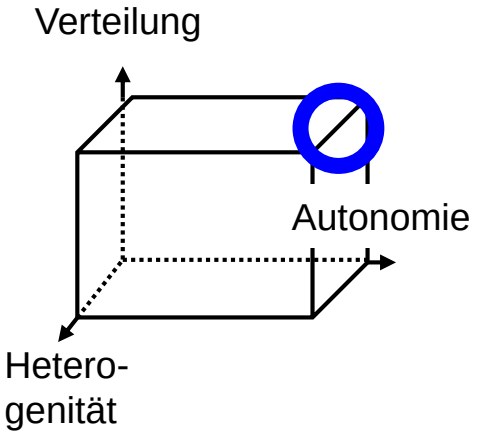

- Verteilt, autonom, und „etwas“ heterogen
  - Keine technische Heterogenität
  - Keine Datenmodellheterogenität
  - Schemata können strukturell und semantisch heterogen sein
  - Verteilte Systeme benutzen gleiche Techniken (RDBMS)
  - Autonomie bleibt bewahrt, aber Zugriff muss möglich sein (Kommunikationsautonomie)
- Kein globales Schema $\rightarrow$ Zugriff über Multidatenbanksprachen
- Ziel: Globaler Zugriff auf mehrere (lokale) Datenbanken
- Verwendung
  - Beantwortung von Anfragen
  - Erstellung integrierter Sichten

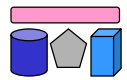

Multidatenbanken: Beispiel

- Zwei Universitätsdatenbanken
- Ziel: Integrierte Sicht mittels “SQL-Definition”

univ-A

salInfo

category	dept	salFloor
Prof	CS	65.000
AssocProf	CS	50.000
Technican	CS	45.000
Prof	Math	60.000
AssocProf	Math	55.000
Technican	Math	45.000

univ-B

salInfo

category	CS	Math
Prof	55.000	65.000
AssocProf	50.000	55.000
Technican	43.000	44.000

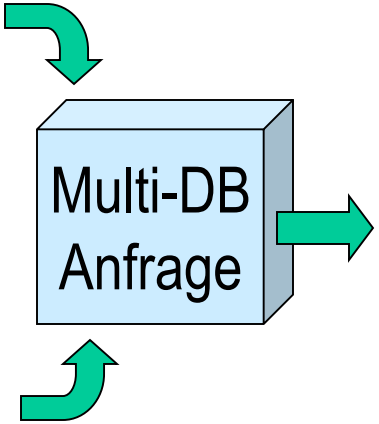

univ-All

salInfo

univ	category	dept	salFloor
univ-A	Prof	CS	65.000
univ-A	AssocProf	CS	50.000
univ-A	Technican	CS	45.000
univ-A	Prof	Math	60.000
univ-A	AssocProf	Math	55.000
univ-A	Technican	Math	45.000
univ-B	Prof	CS	55.000
univ-B	AssocProf	CS	50.000
univ-B	Technican	CS	43.000
univ-B	Prof	Math	65.000
univ-B	AssocProf	Math	55.000
univ-B	Technican	Math	44.000

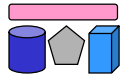

Multidatenbanksprachen

- Anforderungen
  - Schemaunabhängigkeit, d.h. Struktur darf nicht Ausdrucksfähigkeit beeinflussen
  - Umstrukturierung, d.h. Anfrageergebnisse müssen neue Struktur erhalten können
  - Verständlichkeit bei hoher Ausdrucksfähigkeit
  - Abwärtskompatibilität mit SQL
  - Implementierbar
    - Möglichst ohne Veränderung des DBMS
  - Alle Anfragen müssen in SQL / Programme übersetzbar sein
  - Effiziente Ausführung
- Beispiele
  - SchemaSQL [Lakshmanan et. al: SchemaSQL – A Language for Interoperability in Relational Multi-database Systems. VLDB'96]
  - FRAQL [Sattler et. al.: Adding Conflict Resolution Features to a Query Language for Database Federations. EFIS'00]
  - MSQL [Grant et. al.: Query Languages for Relational Multidatabases. VLDB Journal '93]
  - Kommerzielle Implementierungen (z.B. IBM Data Joiner / Information Integrator)

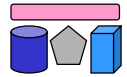

Strukturelle Heterogenität

- Heterogenität erfordert Ausdrucks-mächtigkeit in MultiDB-Sprache

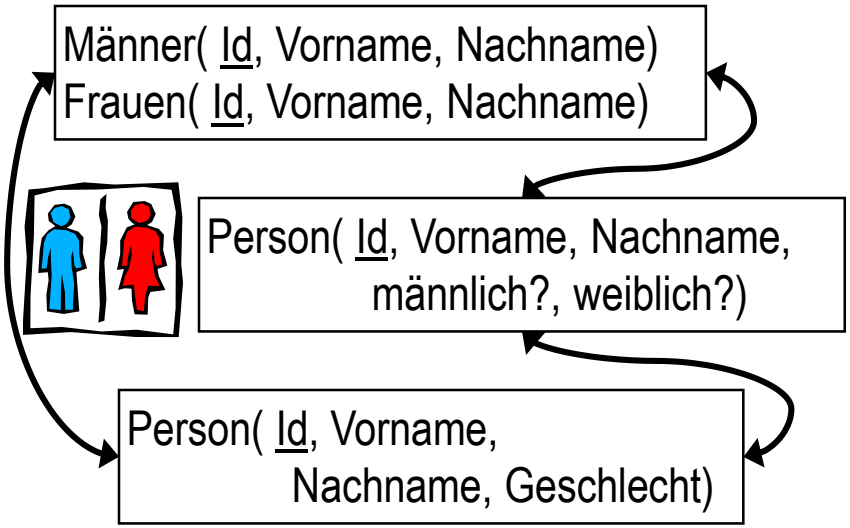

- Vergleich von Modellelementen
  - Relation vs. Attribut
  - Attribut vs. Wert
  - Relation vs. Wert
- Zugriff auf Namen
  - Relationen
  - Attribute

SchemaSQL

  - Werte
- Behandlung unterschiedlicher Verteilung von Attributen
  - Z.B. Normalisiert vs. Denormalisiert
  - Fehlende/neue Attribute
  - Geschachtelt vs. Fremdschlüssel

SQL

Schema SQL

- Erweiterung von SQL

- Zugriff auf Tabellen in verschiedenen Schemata
- Daten und Metadaten werden gleich behandelt
- Umstrukturierungen innerhalb der Anfrage
  - Daten zu Metadaten und umgekehrt
- Dynamische Sicht-Definition
  - Ergebnisrelation hängt vom Zustand der Datenbank ab
- Horizontale Aggregation
  - Über mehrere Spalten hinweg
- Überbrückung struktureller Heterogenität

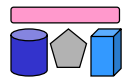

SchemaSQL: Syntax

- Grundlegende Syntax wie SQL
  - **`SELECT` … `FROM` … `WHERE`**
- Deklaration in `FROM` Klausel durch `<range> <var>`
- Variablen laufen über fünf verschiedene 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`
  - `db::rel.attr` Alle Werte eines Attributs `attr` in `rel` in `db`
- Weiterer Unterschied: Geschachtelte Deklarationen
  - Spätere Deklarationen referenzieren frühere
  - In SQL sinnlos

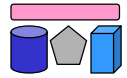

Beispiel: Universitätsdatenbanken

univ-A

salInfo

category	dept	salFloor
Prof	CS	65.000
AssocProf	CS	50.000
Technican	CS	45.000
Prof	Math	60.000
AssocProf	Math	55.000
Technican	Math	45.000

univ-B

salInfo

category	CS	Math
Prof	55.000	65.000
AssocProf	50.000	55.000
Technican	43.000	44.000

univ-C

CS

category	salFloor
Prof	60.000
AssocProf	55.000
Technican	42.000

Math

category	salFloor
Prof	70.000
AssocProf	60.000
Technican	46.000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75.000	60.000	40.000
Math	60.000	45.000	38.000

- Multidatenbank aus mehreren Universitätsdatenbanken
  - univ-A, …, univ-D
- Informationen über Angestellte
  - Kategorie (category)
  - Gehalt (salInfo, salFloor)
  - Abteilung (dept)
- Informationen verteilt auf
  - Attributwerte
  - Attributnamen
  - Relationsnamen

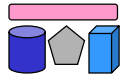

Anfragebeispiel 1

univ-A

salInfo

category	dept	salFloor
Prof	CS	65.000
AssocProf	CS	50.000
Technican	CS	45.000
Prof	Math	60.000
AssocProf	Math	55.000
Technican	Math	45.000

univ-B

salInfo

category	CS	Math
Prof	55.000	65.000
AssocProf	50.000	55.000
Technican	43.000	44.000

- Alle Abteilungen in univ-A, die Technikern mehr zahlen als gleiche Abteilungen in univ-B
- Lösungsweg:
  - Join zwischen beiden Tabellen (über welches Attribut?)
  - Selektionen jeweils auf `Technician`
  - Vergleich der Gehälter
- SchemaSQL-Anfrage

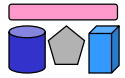

Anfragebeispiel 2

univ-C

CS

category	salFloor
Prof	60.000
AssocProf	55.000
Technican	42.000

Math

category	salFloor
Prof	70.000
AssocProf	60.000
Technican	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
- Lösungsweg:
  - Join zwischen beiden Tabellen (über welches Attribut?)
  - Selektionen jeweils auf `Technician`
  - Vergleich der Gehälter
- 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 Variablen

Iteration über Tupel beider Tabellen in univ-C

Join zwischen Relationennamen und Attributwert

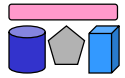

Anfragebeispiel 2: Ausführung (1)

```
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
```

univ-C

CS

category	salFloor
Prof	60.000
AssocProf	55.000
Technican	42.000

Math

category	salFloor
Prof	70.000
AssocProf	60.000
Technican	46.000

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75.000	60.000	40.000
Math	60.000	45.000	38.000

RelC

D

C

Anfragebeispiel 2: Ausführung (2)

Kartesisches Produkt

RelC	C		D			
	category	salFloor	dept	Prof	AssoP	Techn
CS	Prof	60.000	CS	75.000	60.000	40.000
CS	Prof	60.000	MATH	60.000	45.000	38.000
CS	AssoP	55.000	CS	75.000	60.000	40.000
CS	AssoP	55.000	MATH	60.000	45.000	38.000
CS	Techn	42.000	CS	75.000	60.000	40.000
CS	Techn	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	AssoP	60.000	CS	75.000	60.000	40.000
MATH	AssoP	60.000	MATH	60.000	45.000	38.000
MATH	Techn	46.000	CS	75.000	60.000	40.000
MATH	Techn	46.000	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
```

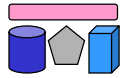

Aggregation in SQL

- Aggregationsfunktionen
  - AVG, COUNT, SUM, MIN, MAX, (STDDEV, VARIANCE, …)
- Gruppierung und Aggregation sind vertikal
  - Aggregation: Werte einer Spalte werden zusammengefasst
    - Beispiel: Anzahl aller Departments

univ-A

salInfo

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

  - Gruppierung: Teilmengen von Werten einer Spalte werden zusammengefasst
    - Beispiel: Durchschnittliches Gehalt pro Category

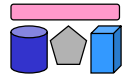

SchemaSQL: Horizontale Aggregation

- Ziel: Aggregation über Werte mehrerer Spalten
  - die evtl. in verschiedenen Tabellen liegen
- Beispiel 1: Durchschnittliches Gehalt in univ-B pro Kategorie für alle Abteilungen

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

Wird Liste von Werten

Iteration über alle Attribute

Iteration über alle Werte

univ-B

salInfo

category	CS	Math
Prof	55.000	65.000
AssocProf	50.000	55.000
Technican	43.000	44.000

- Beispiel 2: Durchschnittliches Gehalt in univ-C pro Kategorie für alle Abteilungen

univ-C

CS

category	salFloor
Prof	60.000
AssocProf	55.000
Technican	42.000

Math

category	salFloor
Prof	70.000
AssocProf	60.000
Technican	46.000

SchemaSQL: Blockweise Aggregation

- Ziel: Aggregation über einen Block
  - “Horizontal + Vertikal”
- Beispiel 3: Durchschnittliches Gehalt aller Angestellten pro Fakultät

```
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
```

univ-D

salInfo

dept	Prof	AssocProf	Technician
CS	75.000	60.000	40.000
Math	60.000	45.000	38.000
Phys	40.000	35.000	30.000

faculty

dname	fname
CS	MatNat 1
Math	MatNat 1
Phys	MatNat 2

Aggregation über eine (Kategorie-) Liste von (Department-) Listen

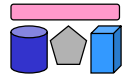

SchemaSQL: Umstrukturierung

- Erstellung integrierter Sichten hilfreich
- Anforderungen
  - Definition eines Output-Schemas (evtl. dynamisch)
  - Umstrukturierung der Daten

- Beispiel: Repräsentation der Daten von univ-B im Schema von univ-A und umgekehrt

univ-A

salInfo

category	dept	salFloor
Prof	CS	65.000
AssocProf	CS	50.000
Technican	CS	45.000
Prof	Math	60.000
AssocProf	Math	55.000
Technican	Math	45.000

univ-B

salInfo

category	CS	Math
Prof	55.000	65.000
AssocProf	50.000	55.000
Technican	43.000	44.000

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

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

Dynamische Schemadefinition: Liste von Werten einer Variable (D) wird zu Spalten d_1, d_2, …, d_n expandiert

SchemaSQL: Implementation

- Ziele
  - *Non-intrusive*
  - Ausnutzung vorhandener RDBMS
  - Übersetzung von Schema-SQL in Sequenz von (verteilten) SQL Befehlen
  - Optimierung
  - Metadatenverwaltung
- Vorgehen (grob)
  - Phase 1: Variablen instanziieren
    - Zugriff auf Metadaten durch entsprechende Systemtabellen, welche das Schema (Metadaten) einer Datenbank generisch mit Datensätzen (Instanzdaten) repräsentiert $\rightarrow$ vergleiche Erstellung eines generischen globalen Schemas
  - Phase 2: SchemaSQL-Anfrage in (mehrere) SQL-Anfragen umschreiben und auf den instanziierten Variablen ausführen
    - Senden von “normalen” SQL-Anfragen an die beteiligten DBMS

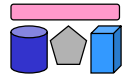

Enge vs. lose Kopplung (Wdh.)

- Lose Kopplung
  - Kein festes Schema
    - Nutzer müssen Semantik der Quellen kennen
    - Integrierte Sichten helfen
  - Multidatenbanksprachen

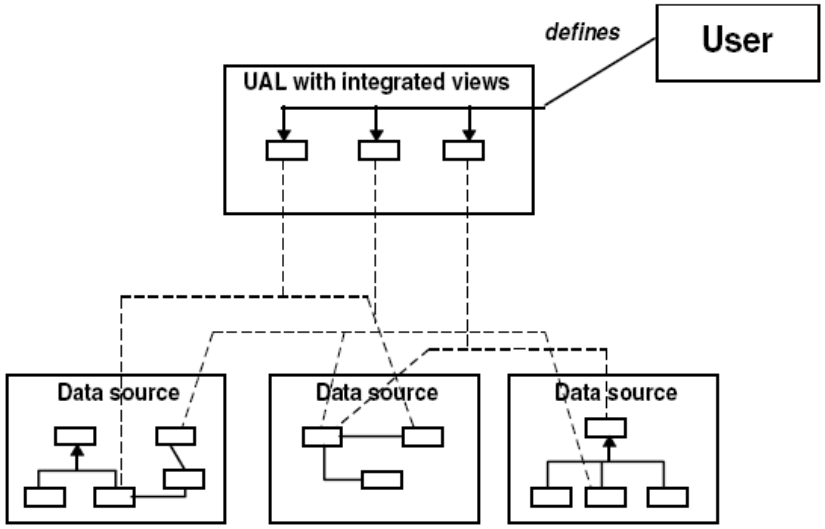

- Enge Kopplung
  - Globales / integriertes / föderiertes Schema
    - Nutzer stellen Anfrage bzgl. globalem Schema
    - Nutzer müssen Schema / Semantik der Quellen nicht kennen
  - Globas-As-View (GaV)
  - Local-As-View (LaV)

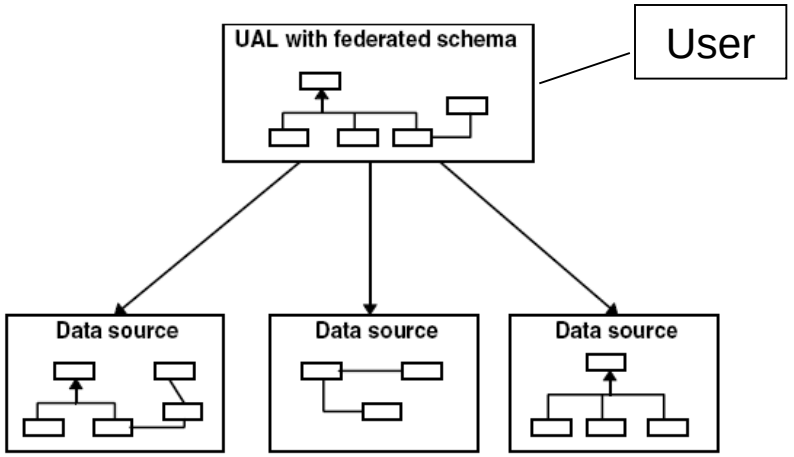

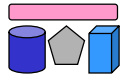

Problem

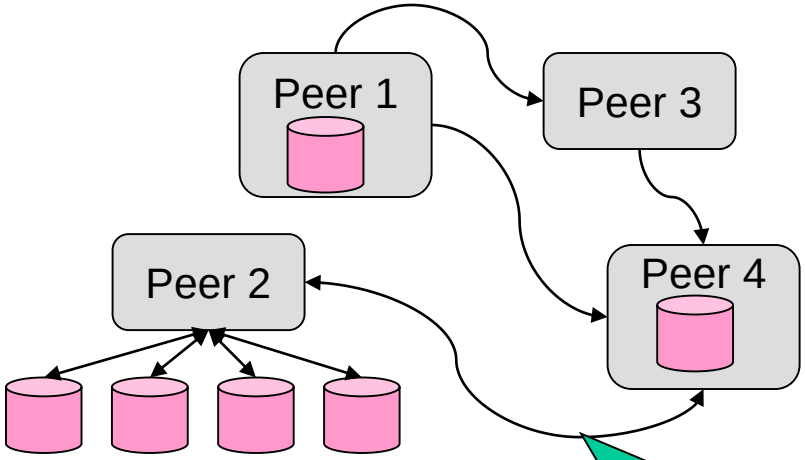

Wie sieht so ein Mapping aus?

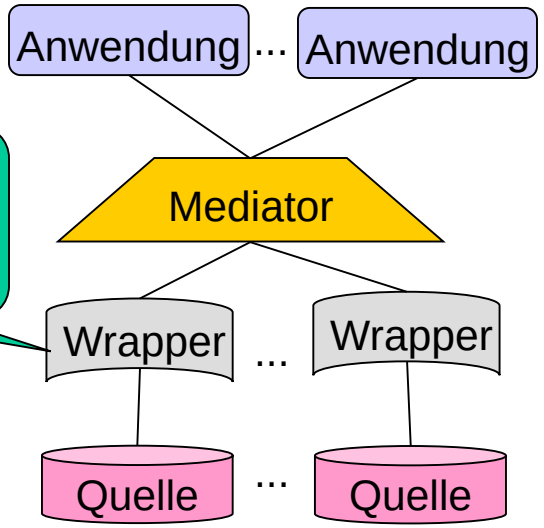

Wie drückt man die Wrapper-Funktionalität aus?

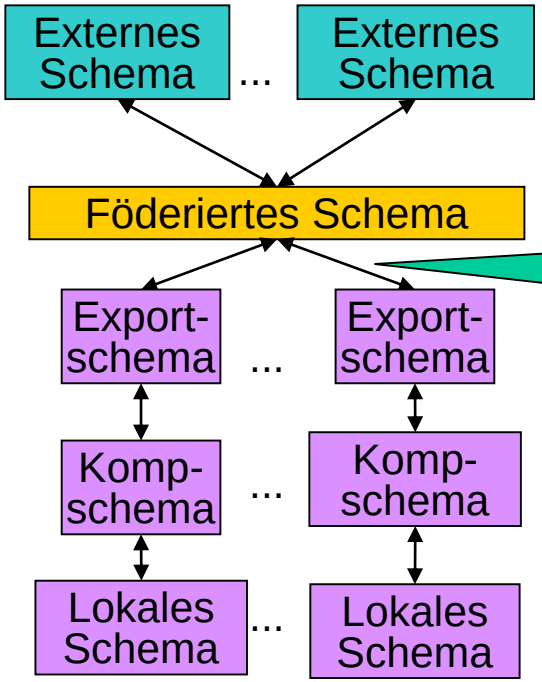

Wie drückt man diesen Übergang aus?

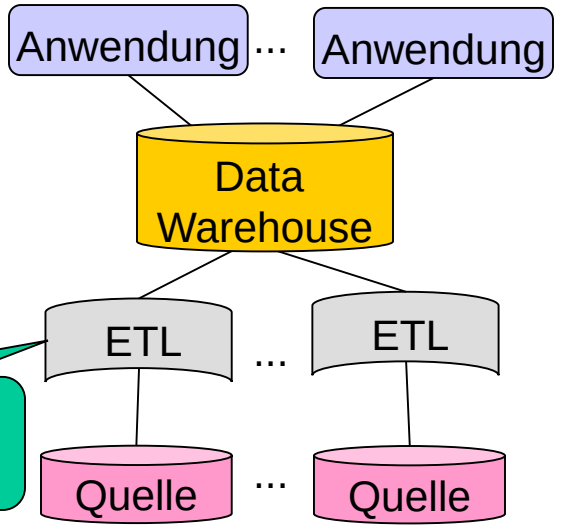

Wie spezifiziert man Datentransformation?

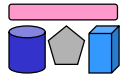

Problem und Teilprobleme

- Gegeben: Zwei heterogene Schemata
  - Quellschema: Hier sind die Daten
  - Zielschema: Hiergegen wird die Anfrage gestellt
- Teilproblem 1: Beziehungen zwischen Schemata finden
  - Spezifikation semantisch äquivalenter Zeile in Quell- und Zielschema
  - Korrespondenzen zwischen Schemaelementen (Mappings)
- Teilproblem 2: Anfrage übersetzen
  - Gegeben Anfrage an Zielschema
  - Finde semantisch äquivalente Sequenz von Anfragen an Quellschemata
  - Entfällt bei materialisierten Ansätzen (z.B. Data Warehouse)
- Teilproblem 3: Daten von der Quelle zum Ziel transformieren
  - Gegebene Ergebnisse der Teilanfragen (oder ganzer Datenbestand)
  - Transformation in das Zielschema
  - Anpassung der Werte an Konventionen des Zielschemas
  - Offline (ETL, DWH) oder Online (Föderation)

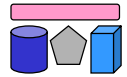

Anfragebearbeitung

- Schritt 1: Anfrageplanung
  - Welche Quellen können / sollen / müssen benutzt werden?
  - Welche Teile der Anfrage sollen an welche Quelle geschickt werden?
- Schritt 2: Anfrageübersetzung
  - Übersetzung aus der Sprache der Föderation in die Sprache der Quellen
- Schritt 3: Anfrageoptimierung
  - Finde geeignete Reihenfolge der Ausführung der Teilanfragen
  - Wer führt was aus (Pushen)?
  - Wer kann was ausführen (Kompensation)? → Beschränke Anfragemöglichkeiten
- Schritt 4: Anfrageausführung
  - Monitoring, Puffern, Cachen
  - Dynamische Reoptimierung
- Schritt 5: Ergebnisintegration
  - Duplikaterkennung und Konfliktauflösung

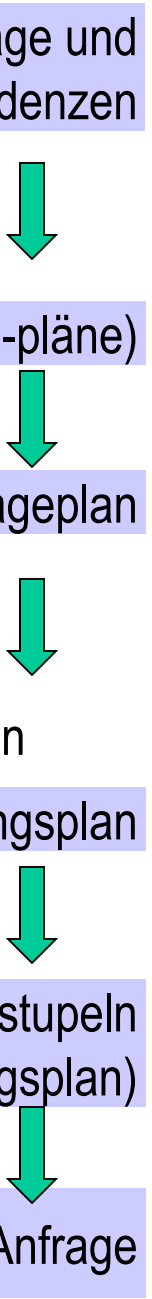

Global-as-View vs. Local-as-View

- Modellierung strukturell heterogener Quellen in Bezug auf ein globales Schema als Views (Sichten)
  - Eine Sicht verknüpft mehrere Relationen und produziert eine Relation
- Sichten zur Verknüpfung von Schemata
  - Sicht definiert auf Relationen eines Schemas und produziert eine Relation des anderen Schemas
- Global as View
  - Relationen des globalen Schemas werden als Sichten auf die lokalen Schemas der Quellen ausgedrückt
- Local as View
  - Relationen der Schemas der Quellen werden als Sichten auf das globale Schema ausgedrückt

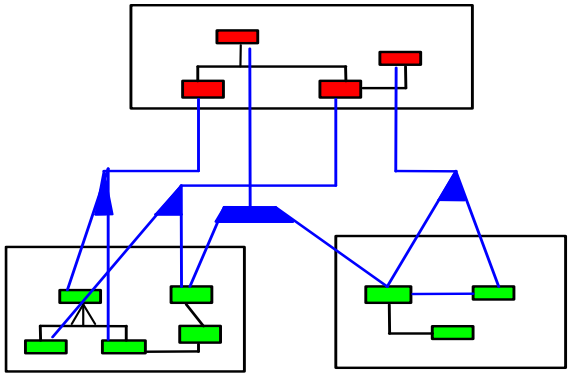

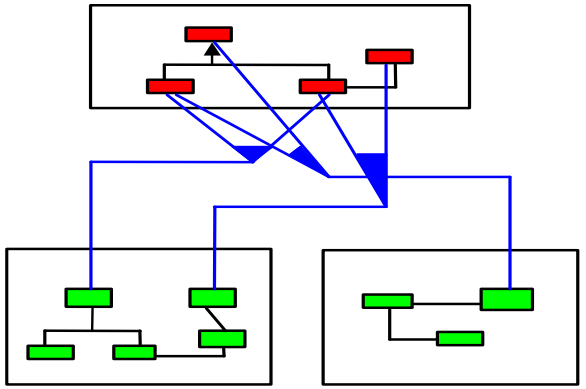

GaV und LaV: Beispiel

Globales Schema
Film(Titel, Regie, Jahr, Genre)

Lokale Schemata:
S1: IMDB(Titel, Regie, Jahr, Genre)
S2: MyMovies(Titel, Regie, Genre)
S3a: RegieDB(Titel, Regie)
S3b: GenreDB(Titel, Jahr, Genre)

Global as View

```
CREATE VIEW Film AS
SELECT * FROM IMDB
UNION
SELECT Titel, Regie, NULL AS Jahr, Genre
FROM MyMovies
UNION
SELECT RegieDB.Titel, RegieDB.Regie,
       GenreDB.Jahr, GenreDB.Genre
FROM RegieDB, GenreDB
WHERE RegieDB.Titel = GenreDB.Titel
```

Typisches GaV-Merkmal

Fehlendes Attribut

Join über mehrere Quellen

Local as View

```
CREATE VIEW S1 AS
SELECT * FROM Film

CREATE VIEW S2 AS
SELECT Film.Titel, Film.Regie, Film.Genre
FROM Film
```


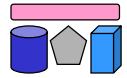

GaV: Globale Nebenbedingung

Globales Schema
NeuerFilm (Titel, Regie, Jahr, Genre)
Nebenbedingung: Jahr > 2000

Lokale Schemata:
S1: IMDB (Titel, Regie, Jahr, Genre)
S2: MyMovies (Titel, Regie, Jahr, Genre)

```
CREATE VIEW NeuerFilm AS
SELECT *
FROM IMDB
WHERE Jahr > 2000
UNION
SELECT *  AS Jahr, Genre
FROM MyMovies
WHERE Jahr > 2000
```

Globale Nebenbedingung kann modelliert werden

Lokale Schemata:
S1: AlleFilmeNett (Titel, Regie, Jahr, Genre)
S2: AlleFilmeBöse (Titel, Regie,Genre)

```
CREATE VIEW NeuerFilm AS
SELECT *
FROM AlleFilmeNett
WHERE Jahr > 2000
UNION
SELECT Titel, Regie, NULL AS Jahr, Genre
FROM MyMovies
WHERE ____ > 2000
```

S2 kann nicht mit globaler Nebenbedingung modelliert werden

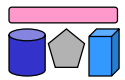

GaV: Lokale Nebenbedingung

Globales Schema
Film (Titel, Regie, Jahr, Genre)

S1: AlleFilmeNett(Titel, Regie, Jahr, Genre)
S2: AlleFilmeBöse(Titel, Regie, Genre)
S3: NeueFilmeNett(Titel, Regie, Jahr, Genre)
(Nebenbedingung: Jahr > 2000)
S4: NeueFilmeBöse(Titel, Regie, Genre)
(Nebenbedingung: Jahr > 2000)
S5: AktuelleFilme(Titel, Regie, Genre)
(Nebenbedingung: Jahr = 2008)

- Eigenschaften
  - Jede Quelle kann modelliert werden
  - Jede Sicht exportiert Daten der Quelle
  - Lokale Nebenbedingung kann nicht immer modelliert werden (S4)

```
CREATE VIEW Film AS
SELECT *
FROM AlleFilmeNett
UNION
SELECT Titel, Regie, NULL, Genre
FROM AlleFilmeBöse
UNION
SELECT *
FROM NeueFilmeNett
WHERE Jahr > 2000
UNION
SELECT Titel, Regie, NULL, Genre
FROM NeueFilmeBöse
UNION
SELECT Titel, Regie, 2008, Genre
FROM AktuelleFilme
```


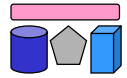

GaV: Beitrag zum Anfrageergebnis (Beispiel)

CREATE VIEW Film AS

SELECT *
FROM AlleFilmeNett

UNION

SELECT Titel, Regie, NULL, Genre
FROM AlleFilmeBöse

UNION

SELECT * FROM NeueFilmeNett
WHERE Jahr > 2000

UNION

SELECT Titel, Regie, NULL, Genre
FROM NeueFilmeBöse

UNION

SELECT Titel, Regie, 2008, Genre
FROM AktuelleFilme

SELECT * FROM Film WHERE		
Jahr > 2001	Jahr = 2001	Jahr < 1950

GaV: Modellierung

- Fehlende Attribute in Quellenschemata durch NULL-Werte ersetzt
  - Darstellung im Endergebnis hängt von Datenfusionsmethode ab
- Nebenbedingungen im globalen Schema können Integration behindern
  - wenn die Bedingung nicht geprüft werden kann (siehe fehlendes Attribut)
- Nebenbedingungen in lokalen Schemata können modelliert werden, wenn
  - sie auf exportierten Attributen gelten
  - sie auf globalen Attributen gelten und die Form “Attribut = Konstante” haben
- Quellen tragen evtl. nicht zum Anfrageergebnis bei, wenn Nebenbedingung nicht modelliert wurde

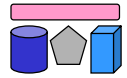

GaV: Anfrageverarbeitung

- Gegeben:
  - Anfrage an globales Schema, d.h. auf Relationen des globalen Schemas
  - Für jede globale Relation genau eine Sicht auf lokale Quellen
- Gesucht:
  - Alle Tupel, die die Anfragebedingungen erfüllen
  - Aber: Daten sind in lokalen Quellen gespeichert
- Idee: Ersetze jede Relation der Anfrage durch ihre Sicht (Sichtentfaltung, View Expansion, Query Unfolding) → Geschachtelte Anfrage

Globales Schema
Film(Titel, Regie, Jahr, Genre)

Lokale Schemata:
S1: IMDB(Titel, Regie, Jahr, Genre)
S3a: RegieDB(Titel, Regie)
S3b: GenreDB(Titel, Jahr, Genre)

```
SELECT * FROM Film

SELECT * FROM (
    SELECT * FROM IMDB
    UNION
    SELECT RegieDB.Titel, RegieDB.Regie,
           GenreDB.Jahr, GenreDB.Genre
    FROM RegieDB, GenreDB
    WHERE RegieDB.Titel = GenreDB.Titel
) AS Film
```

GaV Film

GaV: Anfrageverarbeitung (Beispiel)

Globales Schema
Film(Titel, Regie, Jahr, Genre)
Programm (Kino, Titel, Zeit)

Lokale Schemata:
S1: IMDB(Titel, Regie, Jahr, Genre)
S3a: RegieDB(Titel, Regie)
S3b: GenreDB(Titel, Jahr, Genre)
S7: KinoDB (Kino, Titel, Zeit)

Anfrage an globales Schema
„Alle Filme mit Regie und Zeit, die nach 20 Uhr laufen“

```
SELECT  F.Titel, F.Regie, P.Zeit
FROM    Film AS F, Programm AS P
WHERE   F.Titel = P.Titel
AND     P.Zeit > 20 Uhr
```

View Expansion

```
SELECT  F.Titel, F.Regie, P.Zeit
FROM (
   SELECT * FROM IMDB
   UNION
   SELECT RegieDB.Titel, RegieDB.Regie,
          GenreDB.Jahr, GenreDB.Genre
   FROM RegieDB, GenreDB
   WHERE RegieDB.Titel = GenreDB.Titel
) AS F, (
   SELECT *
   FROM KinoDB
) AS P
WHERE   F.Titel = P.Titel
AND     P.Zeit > 20 Uhr
```

GaV Film

GaV Programm

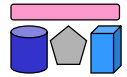

GaV: Anfrageverarbeitung (Ausführung)

- Konzeptionell
  - "Sichten einsetzen" → beliebig tiefe Schachtelungen
  - Ausführung der Anfragen von innen nach außen und Speicherung in temporären Relationen
- Tatsächlich: Optimierungspotential durch Umschreiben der Anfrage
- Entschachtelung
  - Schachtelung wird i.d.R. bei entfernten Quellen belassen
  - Schachtelung wird i.d.R. bei materialisierten Sicht aufgelöst
- Bildung von Teilanfragen in WHERE-Bedingungung
  - Beispiel (skalare Teilanfrage): Relation MovieDB wird nur benutzt, um einen Wert (Id) zu ermitteln; Anfrageergebnis erhält nur Daten aus Relation RegieDB

```
SELECT   Regie
FROM     RegieDB, MovieDB
WHERE    Titel = ‚Star Wars‘
AND      RegieDB.movieID = MovieDB.ID
```

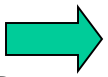

```
SELECT   Regie
FROM     RegieDB
WHERE    movieID = (
           SELECT  ID
           FROM    MovieDB
           WHERE   Titel = ‚Star Wars‘)
```


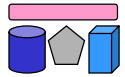

GaV und LaV: Beispiel

Globales Schema
Film(Titel, Regie, Jahr, Genre)

Lokale Schemata:
S1: IMDB(Titel, Regie, Jahr, Genre)
S2: MyMovies(Titel, Regie, Genre)
S3a: RegieDB(Titel, Regie)
S3b: GenreDB(Titel, Jahr, Genre)

Global as View

```
CREATE VIEW Film AS
SELECT * FROM IMDB
UNION
SELECT Titel, Regie, NULL AS Jahr, Genre
FROM MyMovies
UNION
SELECT RegieDB.Titel, RegieDB.Regie,
       GenreDB.Jahr, GenreDB.Genre
FROM RegieDB, GenreDB
WHERE RegieDB.Titel = GenreDB.Titel
```

Local as View

```
CREATE VIEW S1 AS
SELECT * FROM Film
```

Je ein View pro lokale Relation

```
CREATE VIEW S2 AS
SELECT Film.Titel, Film.Regie, Film.Genre
FROM Film

CREATE VIEW S3a AS
SELECT Film.Titel, Film.Regie FROM Film

CREATE VIEW S3b AS
SELECT Film.Titel, Film.Jahr, Film.Genre
FROM Film
```


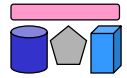

Warum LaV?

- Beispiel: Es gibt in der Welt eine Menge von Filmen, Schauspielern, …
- Das globale Schema modelliert diese Welt
- Theoretisch steht damit die Extension (d.h. alle Datensätze) fest
  - Aber niemand kennt sie
  - Informationsintegration versucht sie herzustellen
- Quellen speichern Sichten auf die globale Extension
  - Also Ausschnitte der realen Welt
- Nur die können wir verwenden

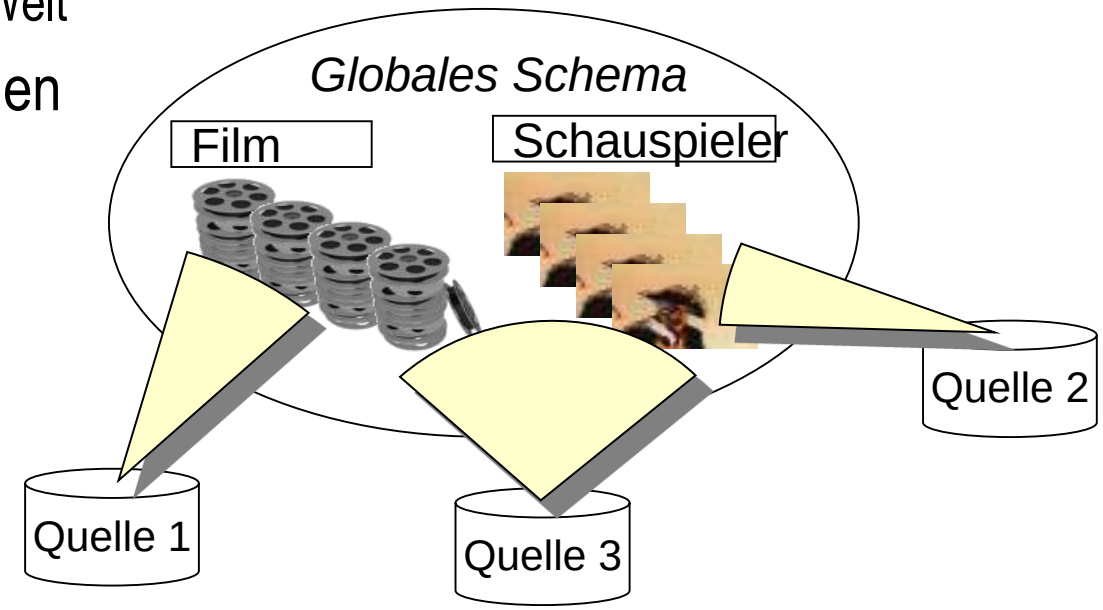

LaV: Globale Nebenbedingung

Globales Schema
NeuerFilm (Titel, Regie, Jahr, Genre)
Nebenbedingung: Jahr > 2000

Lokale Schemata:
S1: IMDB (Titel, Regie, Jahr, Genre)
S2: MyMovies (Titel, Regie, Jahr, Genre)

```
CREATE VIEW S1 AS
SELECT * FROM NeuerFilm
WHERE Jahr> 2000

CREATE VIEW S2 AS
SELECT * FROM NeuerFilm
WHERE Jahr> 2000
```

Globale Nebenbedingung kann modelliert werden

Lokale Schemata:
S1: AlleFilmeNett (Titel, Regie, Jahr, Genre)
S2: AlleFilmeBöse (Titel, Regie,Genre)

```
CREATE VIEW AlleFilmeNett AS
SELECT * FROM NeuerFilm
WHERE Jahr > 2000
```

```
CREATE VIEW AlleFilmeBöse AS
SELECT Titel, Regie, Genre
FROM NeuerFilm
WHERE _____ > 2000
```

S2 kann nicht mit globaler Nebenbedingung modelliert werden

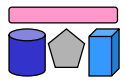

LaV: Lokale Nebenbedingung

Globales Schema
Film (Titel, Regie, Jahr, Genre)

S1: AlleFilmeNett(Titel, Regie, Jahr, Genre)
S2: AlleFilmeBöse(Titel, Regie, Genre)
S3: NeueFilmeNett(Titel, Regie, Jahr, Genre)
(Nebenbedingung: Jahr > 2000)
S4: NeueFilmeBöse(Titel, Regie, Genre)
(Nebenbedingung: Jahr > 2000)
S5: AktuelleFilme(Titel, Regie, Genre)
(Nebenbedingung: Jahr = 2008)

- Eigenschaften
  - Jede Quelle kann modelliert werden
  - Lokale Nebenbedingung können modelliert werden, dienen jedoch “nur” der Optimierung

```
CREATE VIEW S1 AS
SELECT * FROM Film

CREATE VIEW S2 AS
SELECT Titel, Regie, Genre
FROM Film

CREATE VIEW S3 AS
SELECT * FROM Film
(WHERE Jahr > 2000)

CREATE VIEW S4 AS
SELECT Titel, Regie, Genre
FROM Film
(WHERE Jahr > 2000)

CREATE VIEW S5 AS
SELECT Titel, Regie, Genre
FROM Film
(WHERE Jahr = 2008)
```


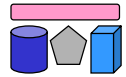

Vergleich: GaV vs. LaV

	Global-as-View	Local-as-View
globale Relation		
lokale Relation		
Anzahl der Sichten		
Typischer Aufbau der Sichtdefinition		
Nebenbedingungen	global: lokal:	global: lokal:
Anfrage-umschreibung	• View Unfolding • 1 große umgeschriebene Anfrage • schwierige Optimierung	• Answering Queries using Views • UNION vieler umgeschriebene Anfragen • sehr schwieriges Problem
Flexibilität		
Hinzufügen neuer Quellen		
Geeignet für		

Global-Local-as-View (GLAV)

- Kombination GaV und LaV, auch Both-as-View (BaV)

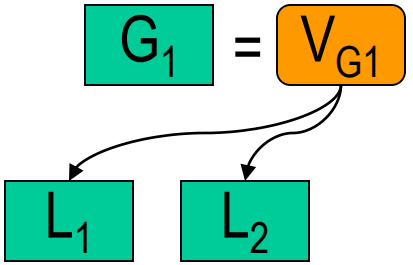

- GaV:
  - Globale Relation = **Sicht** auf lokale Relationen
  - (Globale Relation ⊇ **Sicht** auf lokale Relationen)
- LaV:
  - **Sicht** auf globale Relationen = lokale Relation
  - **Sicht** auf globale Relationen ⊇ lokale Relation
- GLaV:
  - **Sicht** auf globale Relationen = **Sicht** auf lokale Relationen
  - **Sicht** auf globale Relationen ⊇ **Sicht** auf lokale Relationen

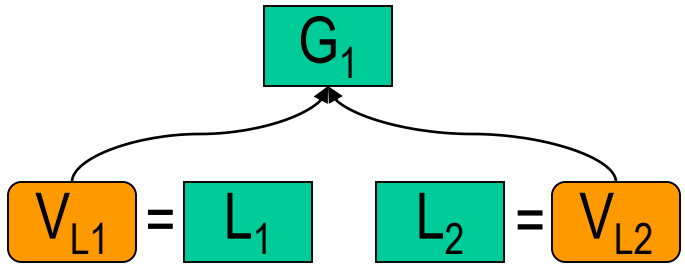

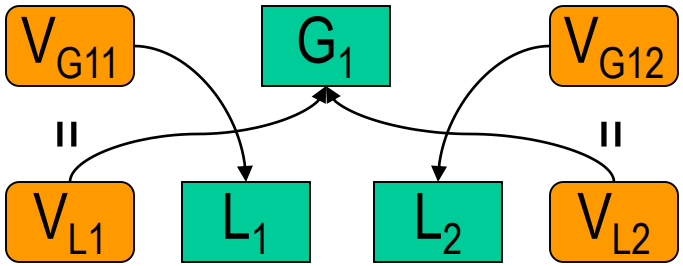

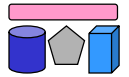

Vergleich: GaV, LaV und GLaV

	GaV	LaV	GLaV
Neben-bedingungen	Probleme bei lokalen NB	Probleme bei globalen NB	lokale und globale NB können modelliert werden
Spezialisierung von Konzepten	Konzept im globalen Schema spezieller als im lokalen Schema (ohne dass man eine Einschränkung im lokalen Schema angeben kann) → keine Integration	Konzept im lokalen Schema spezieller als im globalen Schema (ohne dass man eine Einschränkung im globalen Schema angeben kann) → keine Integration	Konzepte können lokal oder global eingeschränkt werden
Techniken der Anfrage-planung	View Unfolding	Query Containment und Answering Queries using Views (gleich)	erst wie bei LaV, dann Unfolding wie bei GaV

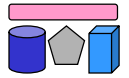

LaV-Anfrageverarbeitung

- Gegeben:
  - Anfrage an globales Schema, d.h. auf Relationen des globalen Schemas
  - Für jede lokale Relation genau eine Sicht auf globales Schema
- Gesucht:
  - Alle Tupel, die die Anfragebedingungen erfüllen
  - Aber: Daten sind in lokalen Quellen gespeichert.
- Idee: Answering Queries using Views
  - Anfrageumschreibung durch Einbeziehung der Sichten
  - Kombiniere geschickt die einzelnen Sichten zu einer Anfrage, so dass deren Ergebnis einen Teil der Anfrage (oder die ganze Anfrage) beantworten
  - Gesamtergebnis ist dann die UNION der Ergebnisse mehrerer Anfrageumschreibungen

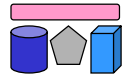

LaV-Anfrageverarbeitung: Beispiel

Globales Schema
Kurs (Titel, Dozent, Semester, Uni, Typ)

Quelle 1: Datenbankkurse
```
CREATE VIEW DB-Kurs AS
SELECT Titel, Dozent, Semester, Uni, Typ
FROM Kurs
WHERE Titel LIKE “%Datenbank%”
```

Quelle 2: Vorlesungen der Uni Leipzig
```
CREATE VIEW LE-VL AS
SELECT Titel, Dozent, Semester, Uni, Typ
FROM Kurs
WHERE Uni = “Leipzig” AND Typ = “VL”
```

Anfrage 1: Alle Leipziger DB-Kurse
```
SELECT *
FROM Kurs
WHERE Titel LIKE “%Datenbank%”
AND Uni = “Leipzig”
```

Umgeschriebene Anfrage 1
```
SELECT *
FROM DB-Kurs
WHERE Uni = “Leipzig”
```

Warum nur Quelle 1 verwenden?

Vollständige Antwort

Anfrage 2: Alle Leipziger Kurse
```
SELECT *
FROM Kurs
WHERE Uni = “Leipzig”
```

Umgeschriebene Anfrage 2
```
SELECT *
FROM DB-Kurs
WHERE Uni = “Leipzig”
UNION
SELECT *
FROM LE-VL
```

Warum hier auch Quelle 2 verwenden?

Maximale Antwort

Was fehlt hier?

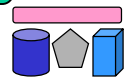

LaV-Anfrageverarbeitung: Visualisierung

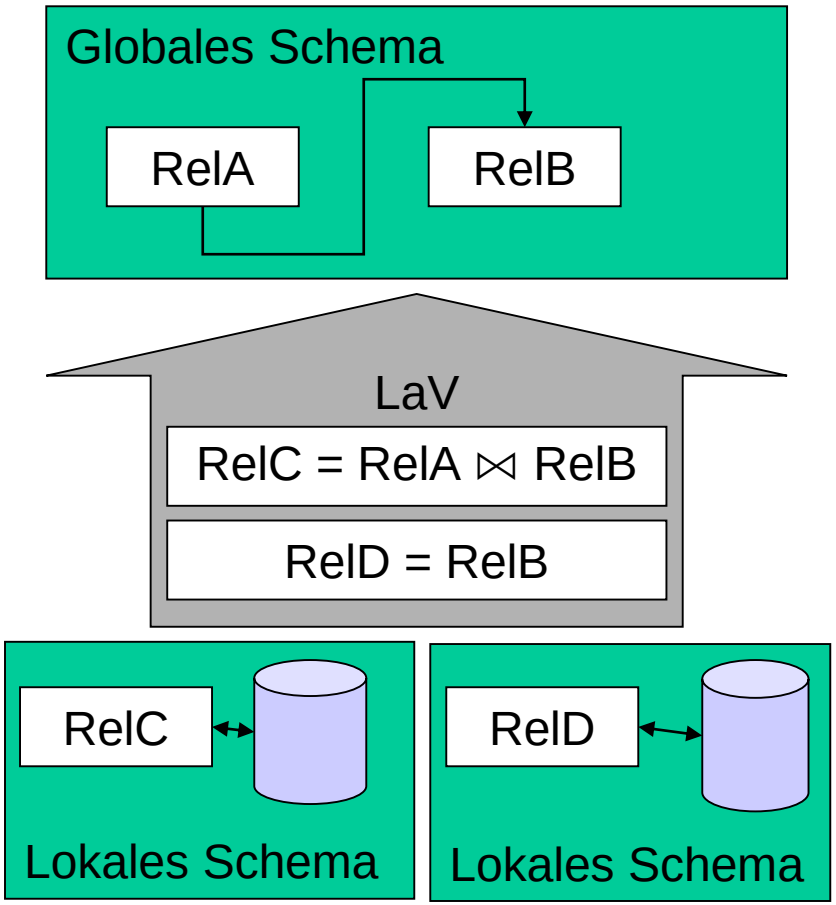

Nutzer-Anfrage

```
SELECT ???
FROM   RelB
WHERE  ???
```

Anfrage-umschreibung

Umgeschriebene Anfrage

```
SELECT ???
FROM   RelD
WHERE  ???
UNION
SELECT Attr(B)
FROM   RelC
WHERE  ???
```

Nutzer-Anfrage

```
SELECT ???
FROM   RelA, RelB
WHERE  ???
```

Anfrage-umschreibung

Umgeschriebene Anfrage

```
SELECT ???
FROM   RelC
WHERE  ???
```


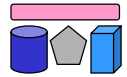

Ein Problem – viele Anwendungen

- Anfrageoptimierung unter Verwendung materialisierter Sichten
  - Welche Sichten helfen bei der Beantwortung einer Datenbankanfrage durch Vorberechnung von Prädikaten?
  - Nicht immer besser eine materialisiert Sicht zu verwenden (Indizes, Aktualisierung)
- Adaptive Erstellung materialisierter Sichten für ein Data Warehouse
  - Gegeben: Query workload = Menge von Anfragen mit Häufigkeiten
  - Welche Sichten materialisieren, um Query Workload optimal zu beantworten
- Semantisches Caching
  - Welche Daten im Cache können zur Beantwortung einer Anfrage verwenden?
  - Welche Daten müssen neu angefragt werden?
- Datenintegration: Beantwortung von Fragen an globales Schema ausschließlich unter Verwendung von Sichten auf lokale Quellen
  - Kann die Anfrage vollständig (extensional) beantwortet werden?
  - Unterschied zu Anfrageoptimierung: Keine Basistabellen verfügbar

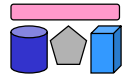

Korrespondenzen

- Anfragen werden bzgl. ihrer Extension (=Menge der Ergebnistupel) miteinander verglichen
  - Überlappungsfrei: $q_1 \cap q_2 = \varnothing$
  - Inklusion: $q_1 \supseteq q_2$
  - Äquivalenz: $q_1 \equiv q_2$
  - Überlappung: $\neg (q_1 \cap q_2 = \varnothing) \wedge \neg (q_1 \supseteq q_2) \wedge \neg (q_2 \supseteq q_1)$
- GaV und LaV-Modellierung durch Sichtendefinition mittels Anfragen
  - Beziehungen (Korrespondenzen) zwischen Anfragen q
- Eine Korrespondenz $q_1 \supseteq q_2$ heißt
  - GaV (Global-as-View), wenn q_1 (globales Schema) eine einzelne Relation ohne Selektionen oder Joins ist (Typ: Relation $\supseteq$ Anfrage)
  - LaV (Local-as-View), wenn q_2 (lokales Schema) eine einzelne Relation ohne Selektionen oder Joins ist (Typ: Anfrage $\supseteq$ Relation)
  - Sonst heißt sie GLaV (Global-local-as-view) (Typ: Anfrage $\supseteq$ Anfrage)

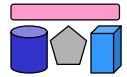

Query Containment

- Gegeben: Anfrage Q und Sichten V_1, ..., V_n
- Gesucht: Umgeschriebene Anfrage Q‘, die
  - bei Optimierung unter Verwendung materialisierter Views: äquivalent ist (Q = Q‘).
  - bei Integration: maximal enthalten ist.
    - D.h. $Q \supseteq Q‘$ und es existiert kein Q‘‘ mit $Q \supseteq Q‘‘ \supseteq Q‘$ wobei $Q‘‘ \neq Q‘$.
- Problem: Wie definiert und testet man Äquivalenz bzw. maximal containment?

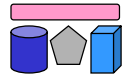

Query Containment (2)

- Query containment (Anfrage-“Enthaltensein“)
  - Sei S ein Schema. Seien Q und Q‘ Anfragen gegen S.
  - Eine Instanz von S ist eine beliebige Datenbank D mit Schema S.
  - Das Ergebnis einer Anfrage Q gegen S auf einer Datenbank D, geschrieben Q(D), ist die Menge aller Tupel, die die Ausführung von Q in D ergibt.
  - Q‘ ist contained (enthalten) in Q, geschrieben $Q' \subseteq Q$, gdw. $Q'(D) \subseteq Q(D)$ für jedes mögliche D.
- Query equivalence (Anfrageäquivalenz)
  - Q ist äquivalent mit Q‘, geschrieben $Q = Q'$, gdw. $Q(D) \subseteq Q'(D)$ und $Q'(D) \subseteq Q(D)$ für jede mögliche Datenbank D.
- Es zählt das Ergebnis einer Anfrage, nicht deren Syntax!

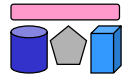

Query Containment: Beispiele

```
SELECT Titel, Dozent, Semester Uni, Typ
FROM Kurs
WHERE Titel LIKE “%Datenbank%”
AND Uni = “LE”
```

```
SELECT Titel, Dozent, Semester Uni, Typ
FROM Kurs
WHERE Titel LIKE “%Datenbank%”
```

```
SELECT Titel, Dozent, Semester Uni, Typ
FROM Kurs JOIN Person
ON (Kurs.Dozent = Person.Name)
WHERE Titel LIKE “%Datenbank%”
```

```
SELECT Titel, Dozent, Semester Uni, Typ
FROM Kurs
WHERE Titel LIKE “%Datenbank%”
```

```
SELECT Titel, Dozent
FROM Kurs
WHERE Titel LIKE “%Datenbank%”
```

```
SELECT Titel, Uni, Typ
FROM Kurs
WHERE Titel LIKE “%Datenbank%”
```

```
SELECT Titel, Dozent, Semester Uni
FROM Kurs
WHERE Typ IN (“VL”, “Praktikum”)
```

```
SELECT Titel, Dozent, Semester Uni
FROM Kurs
 WHERE Typ IN (“Praktikum”, “Seminar”)
```


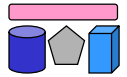

Prüfung auf Query Containment

- Prüfung von Containment durch Prüfung aller möglichen Datenbanken?
  - Definition: "... für jedes mögliche D" $\rightarrow$ zu komplex!
- Prüfung von Containment durch Existenz eines Containment Mapping.
  - NP-vollständig in |Q|+|Q'| nach
    Chandra & Merlin. Optimal implementation of conjunctive queries in relational data bases. ACM Symposium on Theory of Computing, 1977.
  - Mehrere Algorithmen
- Syntaktische Analyse (der Anfrage / View-Definition), um semantische Aussage ("Stets alle Tupel von Q in Q' enthalten?") zu treffen
  - Containment Mapping = Symbolmapping
  - CM von q_2 nach q_1 bdeutet, dass $q_1 \subseteq q_2$ durch
  - Idee (intuitiv): Nachweis, dass q_1
    - nicht mehr Tupel berechnet (mehr Joins, strengere Bedingungen)
    - nicht weniger Spalten berechnet (evtl. mehr durch andere Projektion)

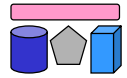

Anfrageplanung mittels Query Containment

- Basis: Algorithmus zum Containment zweier Queries
- Anfrageplanung “light”
  - Globale Anfrage q, für deren Beantwortung die Verwendung einer LaV-Korrespondenz ausreicht (ohne JOIN)
  - Menge von Korrespondenzen K (LaV-Korrespondenzen)
  - Deren globaler Anfrageteil ist eine Menge von Views V
  - Query-Containment-Test für jedes $v \in V$: Gilt $v \subseteq q$?
  - Die v, für die das zutrifft, berechnen nur korrekte Tupel für q
  - Ihre Vereinigung ist das (bestmögliche) Ergebnis
- Anfrageplanung “real-world”
  - Einbeziehung mehrerer Korrespondenzen
  - Answering Queries using Views: Antworten durch Kombination von Views
  - Welche Views sollen wie miteinander verknüpft werden?

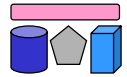

Korrespondenzen: LaV-Beispiel

- Beispiel: Filmdatenbank
  - globales und lokale Schema
  - LaV-Regeln in Datalog-Notation

Globales Schema
film (titel, typ, regisseur, laenge)
schauspieler (schauspieler_name, nationalitaet)
spielt (titel, schauspieler_name, rolle, kritik)

Datenquelle	Beschreibung
spielfilme (titel, regisseur, laenge)	Spielfilme mit mind. 80min Länge
kurzfilme (titel, regisseur)	Kurzfilme; sind max. 10min lang
filmkritiken (titel, regisseur, schauspieler, kritik)	Kritiken zu Hauptdarstellern von Filmen
us_spielfilme (titel, laenge, schauspieler_name)	Spielfilme mit US-Schauspielern
spielfilm_kritiken (titel, rolle, kritik)	Kritiken zu Rollen in Spielfilmen
kurzfilm_rollen (titel, rolle, schauspieler_name, nationalitaet)	Rollenbesetzungen in Kurzfilmen

film (T,Y,R,L), L>79, Y='Spielfilm'	⊇	spielfilme (T,R,L)
film (T,Y,R,L), L<11, Y='Kurzfilm'	⊇	kurzfilme (T,R)
film (T,_,R,_), spielt (T,S,O,K), O='Hauptrolle'	⊇	filmkritiken (T,R,S,K)
film (T,Y,_,L), spielt (T,S,_,_), schauspieler (S,N), N='US', Y='Spielfilm'	⊇	us_spielfilme (T,L,S)
film (T,Y,_,_), spielt (T,_,O,K), Y='Spielfilm'	⊇	spielfilm_kritiken (T,O,K)
film (T,Y,_,_), spielt (T,S,O,_), schauspieler (S,N), Y='Kurzfilm'	⊇	kurzfilm_rollen (T,O,S,N)

```
SELECT titel, regisseur, laenge
FROM film
WHERE laenge>79
AND typ = 'Spielfilm'
```

```
SELECT f.titel, f.regisseur, s.schauspieler_name, s.kritik
FROM film f JOIN spielt s ON (f.titel = s.titel)
WHERE s.rolle = 'Hauptrolle'
```

LaV: Anfragen

- Alle Filme kürzer als 100 Minuten
  - spielfilme (filtern) und kurzfilme (direkt) und us_spielfilm (filtern)
- Alle Filme, die länger als 60 Minuten sind
  - spielfilme (filtern), us_spielfilm (filtern)
- Schauspieler von Hauptrollen in Filmen unter 100 Minuten
  - spielfilme ⋈ filmkritiken ? Ok, da nur Hauptrollen kritisiert werden
  - spielfilme ⋈ spielfilm_kritiken ? Ok, aber ohne Schauspielernamen
  - spielfilme ⋈ us_spielfilm ? Ok, aber Rolle fehlt
  - spielfilme ⋈ kurzfilm_rollen ? Nutzlos, da JOIN leere Menge ergibt

```
SELECT titel, 'Spielfilm', regisseur, laenge
FROM spielfilm
WHERE laenge < 100

UNION

SELECT titel, 'Kurzfilm', regisseur, NULL
FROM kurzfilm

UNION

SELECT titel, 'Spielfilm', NULL, laenge
FROM us_spielfilme
WHERE laenge<100
```

film (T,Y,R,L), L>79, Y='Spielfilm'	⊇	spielfilme (T,R,L)
film (T,Y,R,L), L<11, Y='Kurzfilm'	⊇	kurzfilme (T,R)
film (T,_,R,_), spielt (T,S,O,K), O='Hauptrolle'	⊇	filmkritiken (T,R,S,K)
film (T,Y,_,L), spielt (T,S,_,_), schauspieler (S,N), N='US', Y='Spielfilm'	⊇	us_spielfilme (T,L,S)
film (T,Y,_,_), spielt (T,_,O,K), Y='Spielfilm'	⊇	spielfilm_kritiken (T,O,K)
film (T,Y,_,_), spielt (T,S,O,_), schauspieler (S,N), Y='Kurzfilm'	⊇	kurzfilm_rollen (T,O,S,N)

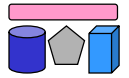

LaV: Anfrageumschreibung

- Prinzipiell: Prüfe jede Kombination an Sichten auf Containment
  - Unendlich viele Kombinationen, da eine Sicht auch mehrfach in eine Umschreibung eingehen kann.
- Verbesserung: Umschreibung mit maximal so vielen Sichten wie Relationen in Anfrage (ist ausreichend)
  - Beweis: *Levy, Mendelzon, Sagiv, Srivastava: Answering Queries Using Views. PODS 1995*
  - Geschickte Vorauswahl der Sichten: Nutzbarkeit
- Frage 1: Wann sind Sichten nutzbar? (informell)
  - Mindestens eine Relation mit Anfrage gemeinsam
  - Mindestens einige Attribute der Anfrage
  - Prädikate sind schwächer oder gleich (äquivalente Umschreibung)
  - Prädikate sind stärker (contained Umschreibung)
- Frage 2: Wann sind Sichten nützlich?
  - Bei Optimierung mit MVs: Schnellere Ausführung
  - Bei Integration mit LaV: zusätzliche Tupel, zusätzliche Attribute

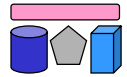

Beschränkte Quellen

- Quellen, die nicht alle Anfragen an ihr Exportschema beantworten können
  - Webquellen hinter Formularen
  - Web Services, CORBA, RPC, …
  - Legacy Systeme

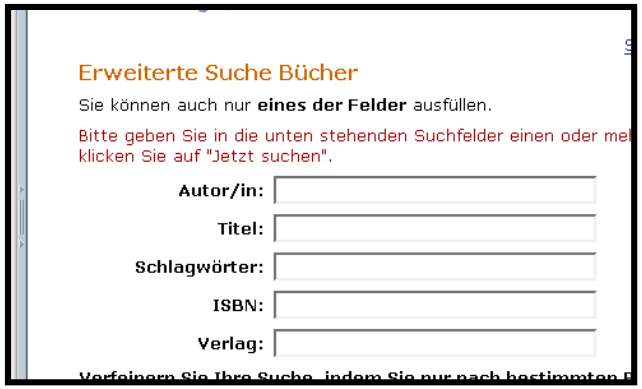

- Quellen verlangen bestimmte Bedingungen
  - SELECT * FROM BOOK ... geht nicht
  - SELECT * FROM BOOK WHERE AUTHOR like … geht
  - SELECT * FROM BOOK WHERE TITLE like … geht
- Variablen und Bindungen. Ein Attribut …
  - … heißt frei (f), wenn es in einer Anfrage nicht belegt sein muss (aber sein kann)
  - … heißt gebunden (b), wenn es in einer Anfrage belegt sein muss
  - … heißt unbindbar (n), wenn es in einer Anfrage nicht belegt sein darf
- Belegung = Selektion der Art „V=c“ oder „V in [c1,…cn]“
  - Verallgemeinerung auf andere Prädikate möglich (siehe Literatur)

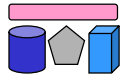

Auswirkungen

- Manche Anfragepläne sind nicht mehr ausführbar (SELECT * FROM BOOK)
- Pläne sind nicht mehr in jeder Reihenfolge ausführbar

```
order (OID,Title)
• keine Einschränkung
info (OID,Name,Age,Role)
• Suche nach OID oder Name
```

- Beispiel (rechts)
  - Alle Titel von Filmen, bei denen ein 90jähriger Schauspieler mitspielt
  - Anfrage: q(T) :- order(O,T), info(O,_,A,_), A=90
- Plan A: “erst info(O,_,A,_), A=90, dann order”
  - Gut wegen hoher Selektivität der Bedingung
  - Aber: nicht ausführbar
- Plan B: “erst order, dann info, dann A=90”
  - Schlecht wegen sehr teurem SELECT * FROM ORDER, aber ausführbar
  - Dann Bindungen von OID “pushen”
  - Bedingung A=90 erst im Mediator auswerten

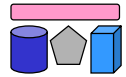

Binding Patterns

- Binding Pattern (BP) = Die Menge der Einschränkungen pro Attribut einer Anfrage

```
order (OID,Title)
```
• Suche nur nach Title

```
info (OID,Name,Age,Role)
```
• Suche nach OID oder Name (nach genau einem)

- Beispiel (rechts): order (O^n , T^b)
- Ist info (O^f , N^f, A^n, R^n) korrekt?
  - Nein, hier auch Anfrage ohne Bindung und Anfrage nach OID und Name möglich
- Darstellung durch zwei (i.A. mehrere) Binding Patterns

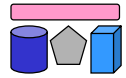

Anfrageplanung mit Binding Patterns

- BP müssen während der Planung zunächst nicht beachtet werden
  - Anfrage q $\rightarrow$ korrekter Anfrageplan p
- Für eine gegebene Ausführungsreihenfolge von p kann man nun testen, ob sie ausführbar ist
  - Kostenbasierte Optimierung wählt unter allen ausführbaren Reihenfolgen die beste
- Beispiel (rechts)
  - `order` nur Titelsuche, `info` wie vorher
- Algorithmus: Initialisierung
  - Vektor k mit einer Position für jedes Attribut in p
  - Initialwert: Bindet q eine Variable v, dann “b”, sonst “f”

```
order(O^n, T^b)
info1(O^n, N^b, A^n, R^n)
info2(O^b, N^n, A^n, R^n)
```

Anfrage: `q(T,N) :- order(O,T), info(O,N,A,_), T="Marnie"`

Vektor: `k [O,T,N,A,R] =`

Rajaraman, Sagiv und Ullman: Answering Queries using Templates with Binding Patterns. PODS 1995

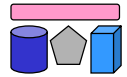

Anfrageplanung mit Binding Patterns (2)

- Analyse jedes Plans p = <q_1,…q_n>
- Jedes q_i hat ein Binding Pattern b_i
- FOR i=1 TO n DO $k_{neu} = k_{alt} \lozenge b_i$

- Berechnung der Verknüpfung ◊
  - Sei x=k_{alt}[j] und y= b_i[j]
  - j referenziert in beiden Vektoren die gleiche Variable
  - IF x=„b“ und y=„n“ → Plan nicht ausführbar, da Bindung nicht weitergegeben werden kann
  - IF x=„f“ und y=„b“ → Plan nicht ausführbar, da notwendige Bindung nicht vorhanden ist
  - k_{neu}[j]=b, wenn Variable zu j in q_i exportiert wird, sonst k‘[j]=k[j]

Plan A: order (O^n, T^b), info1 (O^n , N^b, A^n, R^n)
Plan B: order (O^n, T^b), info2 (O^b , N^n, A^n, R^n)

Init: `k = fbfff`

Plan A1: order, info1

- `fbfff ◊ nb___ = bbfff`
- `bbfff ◊ n_bnn` ↯ `(b→n)`

Plan A2: info1, order

- `fbfff ◊ n_bnn` ↯ `(f→b)`

Plan B1: order, info2

Plan B2: info2 , order

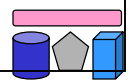

Post-Processing

- Mediator kann nicht ausführbare Pläne durch Nachverarbeitung "simulieren"
- Übergang: b → n
  - Bindung kann nicht an Quelle weitergegeben werden
- Workaround:
  - Führe eine Anfrage ohne Bindung aus
  - Falls im Plan schon eine Bindung entstanden ist, teste diese im Mediator während eines Post-Processings
- Auswirkung: „n" kann wie „f" behandelt werden
  - Es entstehen aber teure Pläne ohne Pushen von Selektionen

info3 (O^n, N^f, A^f, R^f)
Plan C1: order, info3
- `fbfff ◊ nb___ = bbfff`
- `bbfff ◊ n_fff ↯ (b→n)`

info3 (O^n, N^f, A^f, R^f)
Plan C1: order, info3
- `fbfff ◊ nb___ = bbfff`
- `bbfff ◊ f_fff = bbfff`

- Suche mit Titel in order
- Hole alle info-Tupel (teuer)
- Join (über O) in Mediator

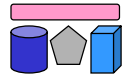

Erweiterungen / Weitere BP-Anwendungen

- Anhänge (adornments = Verzierungen)
  - f: free = Kann in Anfrage spezifiziert werden, muss aber nicht
  - n: unspecifiable = Kann nicht spezifiziert werden
  - b: bound = Muss spezifiziert werden
  - c[s]: constant = Auswahl aus einer Menge s von Konstanten (free)
  - o[s]: optional = Auswahl aus einer Menge s von Konstanten (bound)
  - Behandlung
    - Im Prinzip: „c“ wie „b“ und „o“ wie „f“
    - Weitere Einschränkungen über die Wertemengen bei „c“ und „s“ möglich

Checken!!

- Berechnung von BP einer globalen Relation aus BP der Quellen
  - Wenn ein Mediator beschränkte Quellen integriert – welchen Beschränkungen unterliegt er dann selber?
  - Erstellung eines Anfrageformulars im Mediator aus denen der Quellen

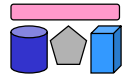

Zusammenfassung

- Multidatenbanksprachen
  - Lose Kopplung: Nutzer integriert durch Anfragen die mehrere Quellen involvieren
  - Verwendung u.a. zur Erstellung integrierter Sichten
  - SchemaSQL: Syntax, horizontale Aggregation und dynamische Umstrukturierung
- Global-as-View (GaV) und Local-as-View (LaV)
  - Enge Kopplung: Anfragebearbeitung durch System auf Basis von Korrespondenzen
  - Automatische Erstellung von Korrespondenzen $\rightarrow$ Kap. 6
  - Vergleich GaV- und LaV-Modellierung sowie GLaV
- LaV-Anfragebearbeitung
  - Erstellung eines Anfrageplans
    - Query Containment, Answering Queries using Views
  - Erstellung eines Ausführungsplans
    - Binding Patterns für Quellen mit beschränkten Anfragemöglichkeiten
  - Integration der Ergebnisse $\rightarrow$ Kap. 7