Hasso Plattner Institut

IT Systems Engineering | Universität Potsdam

Informationsintegration

Global-as-View: GaV

26.6.2008

Felix Naumann

Überblick

- Motivation
- Korrespondenzen
- Übersicht Anfrageplanung
- Global as View (GaV)
  - Modellierung
  - Anfragebearbeitung
- Local as View (LaV)
  - Modellierung
  - Ausblick: Anfragebearbeitung
- Global Local as View (GLaV)
- Vergleich

Das Problem

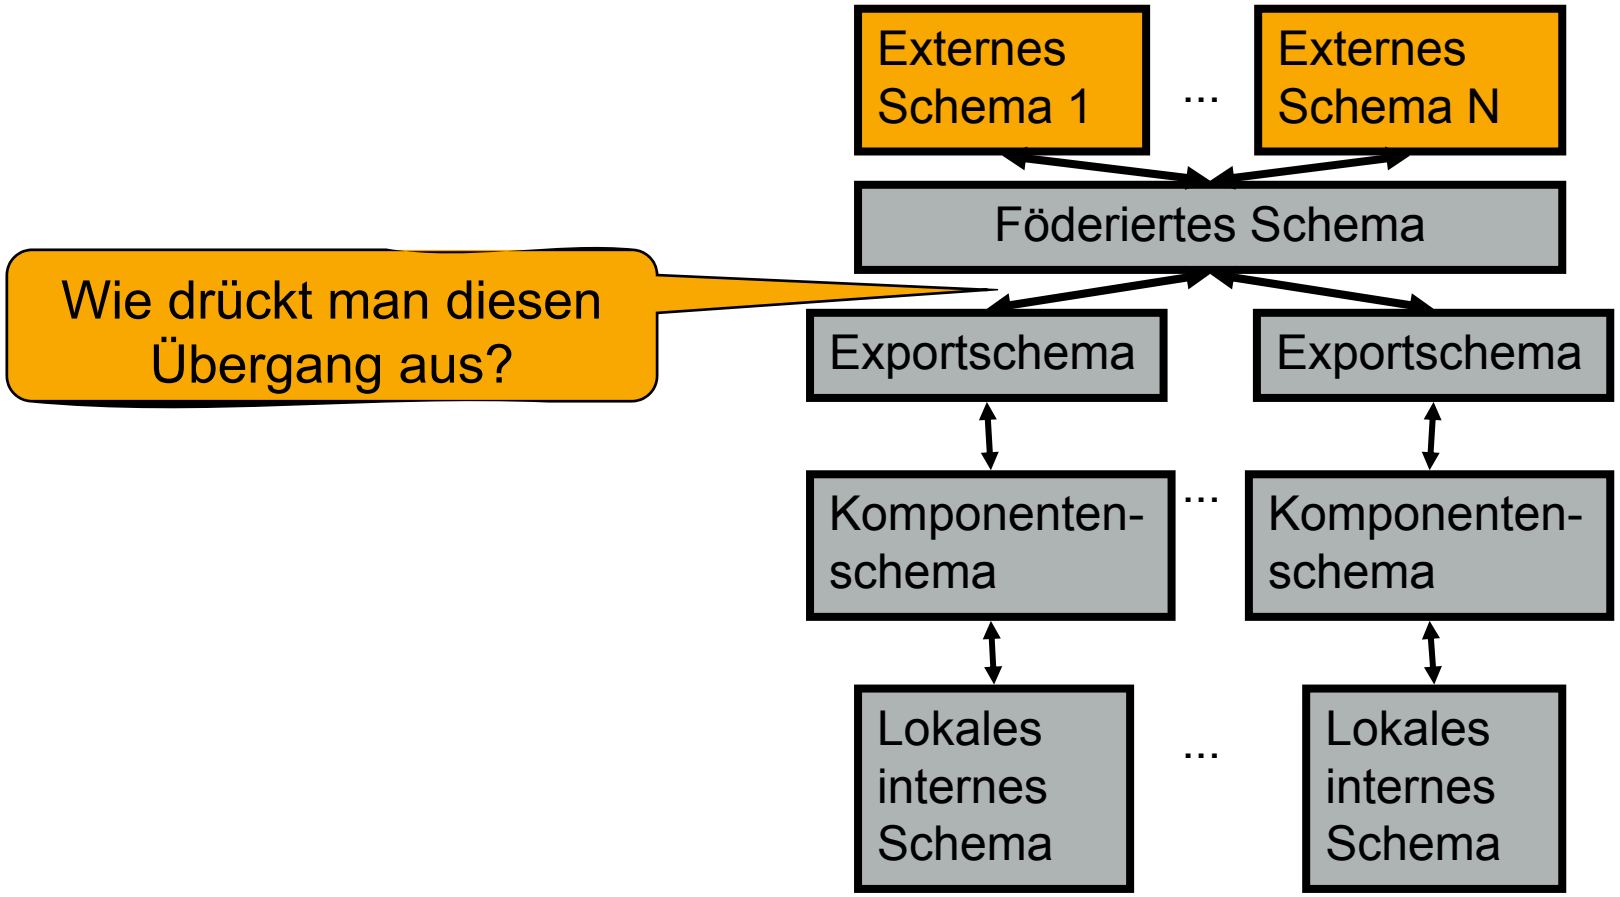
Externes Schema 1
...
Externes Schema N
Föderiertes Schema
Wie drückt man diesen Übergang aus?
Exportschema
Exportschema
Komponenten-schema
...
Komponenten-schema
Lokales internes Schema
...
Lokales internes Schema

Das Problem

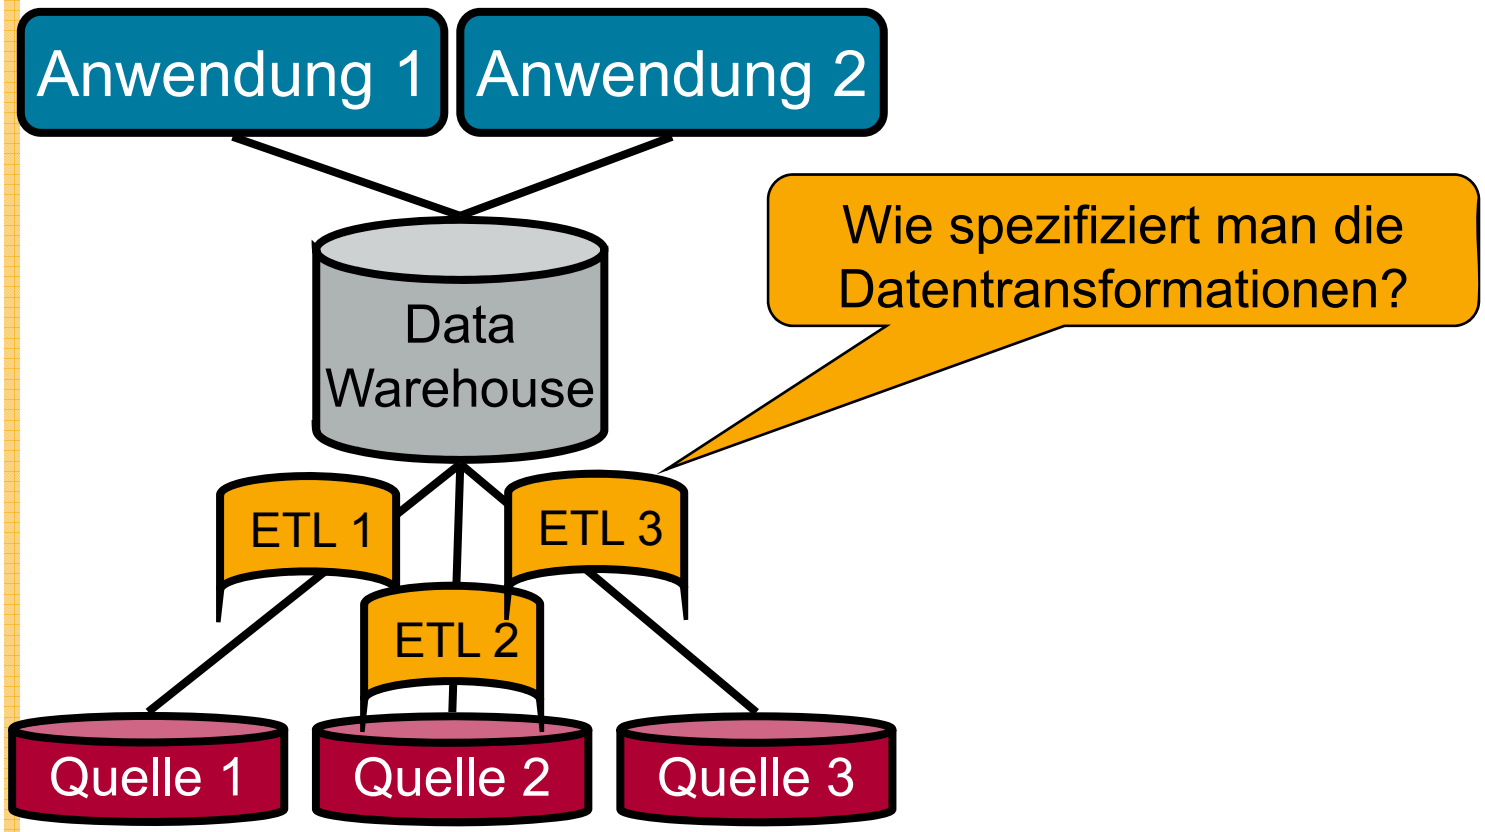
Anwendung 1
Anwendung 2
Data Warehouse
Wie spezifiziert man die Datentransformationen?
ETL 1
ETL 2
ETL 3
Quelle 1
Quelle 2
Quelle 3

Das Problem

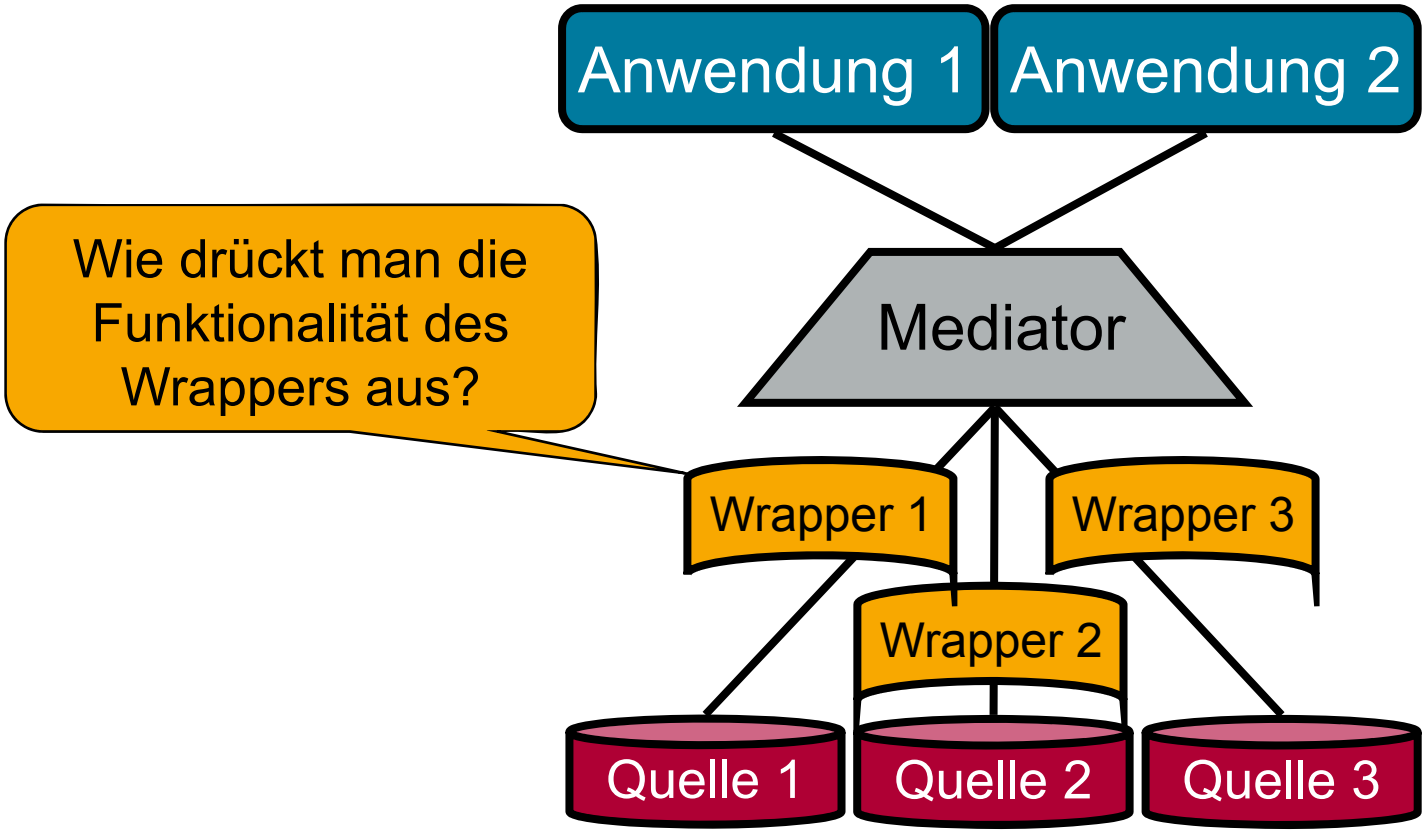
Anwendung 1
Anwendung 2
Wie drückt man die Funktionalität des Wrappers aus?
Mediator
Wrapper 1
Wrapper 3
Wrapper 2
Quelle 1
Quelle 2
Quelle 3

Das Problem

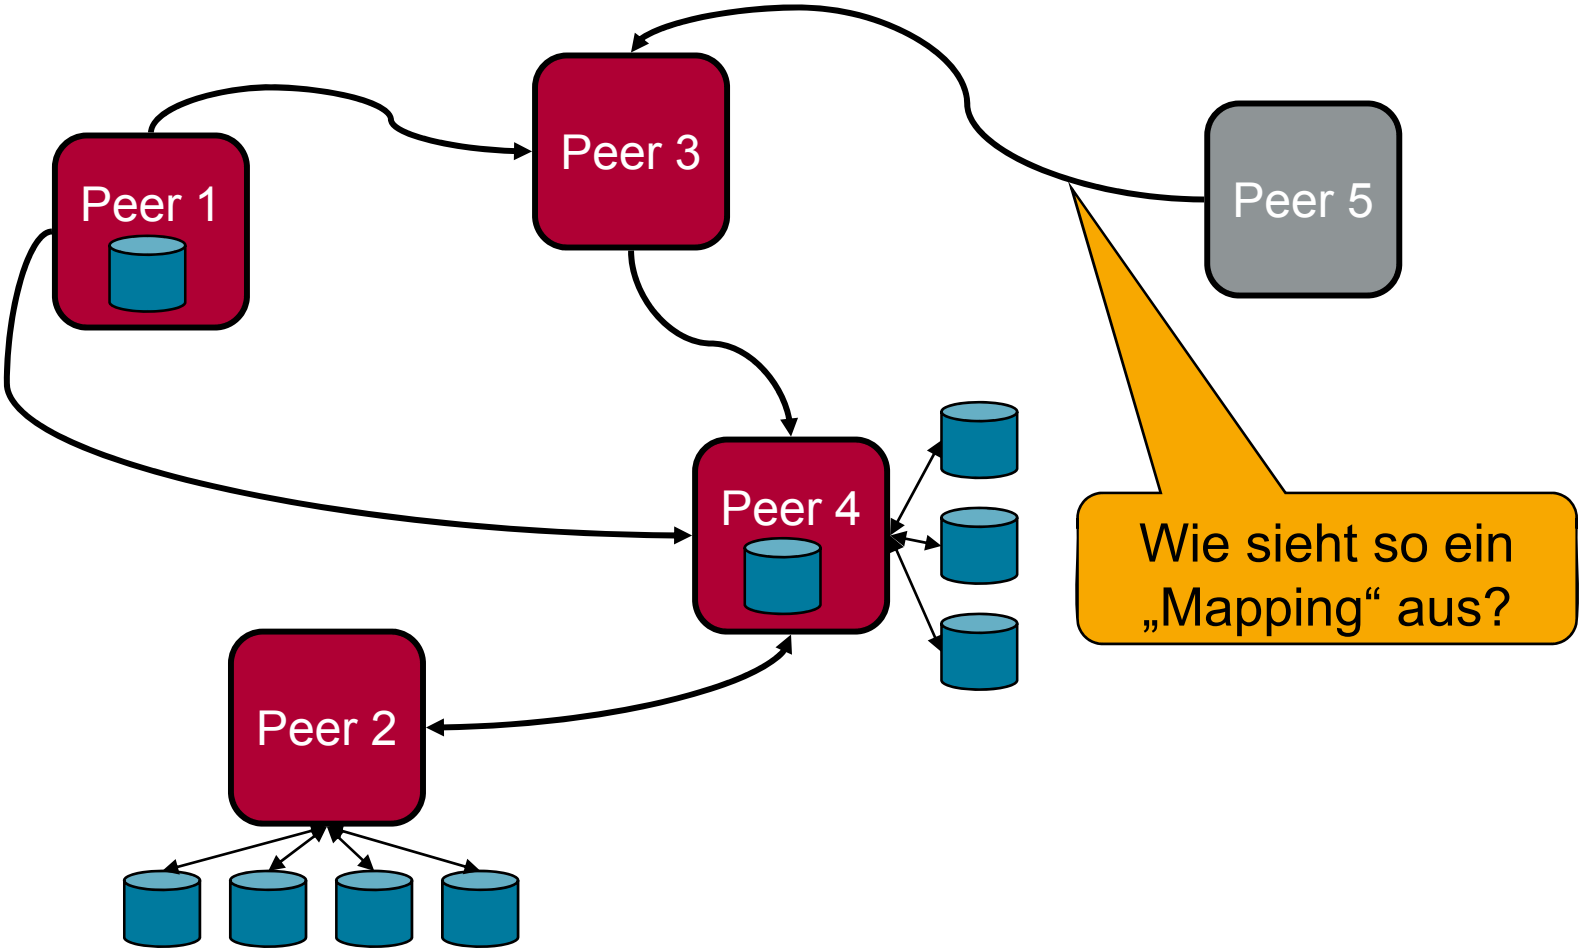

Abstrakter

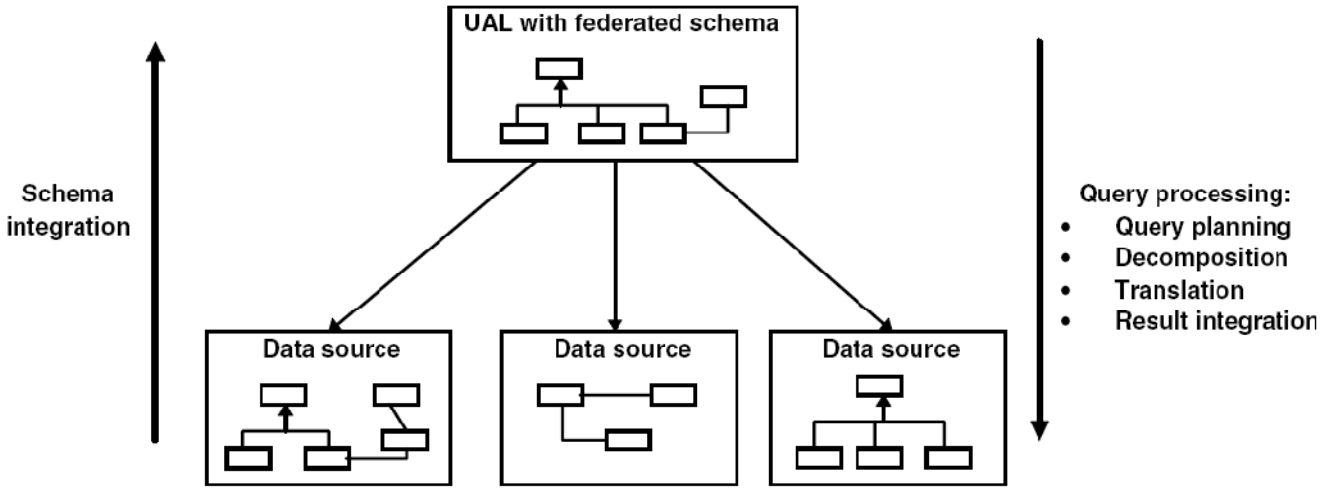

Wenn das integrierte System ein globales Schema zur Verfügung stellt

- Wie beschreibt man die Beziehungen zwischen dem globalen und den verschiedenen lokalen Schemata?
- Wie benutzt man diese Beziehungen zur Anfrageplanung?
- (Kann man aus solchen Beziehungen das integrierte Schema erzeugen?)

Überblick

- Motivation
- Korrespondenzen
- Übersicht Anfrageplanung
- Global as View (GaV)
  - Modellierung
  - Anfragebearbeitung
- Local as View (LaV)
  - Modellierung
  - Ausblick: Anfragebearbeitung
- Global Local as View (GLaV)
- Vergleich

Korrespondenzen

- Korrespondenz
  - Spezifikation semantisch äquivalenter Teile in Quell- und Zielschema
- Regeln mit zwei Teilen
  - Erster Teil: Anfrage an Quelle
  - Zweiter Teil: Zielorte im Zielschema
  - Dazwischen: Datentransformation und Restrukturierung
- Kann unterschiedliche „Sprachen“ benutzen
  - Global-as-View, Local-as-View, …
- Wir wollen deklarative Korrespondenzen
  - Auch ein XSLT Programm macht Datentransformation
  - Kann aber nicht zur Anfrageplanung benutzt werden
- Woher kommen die Korrespondenzen?
  - Manuell spezifizieren
  - (Semi-)automatisch Finden: Schema Matching

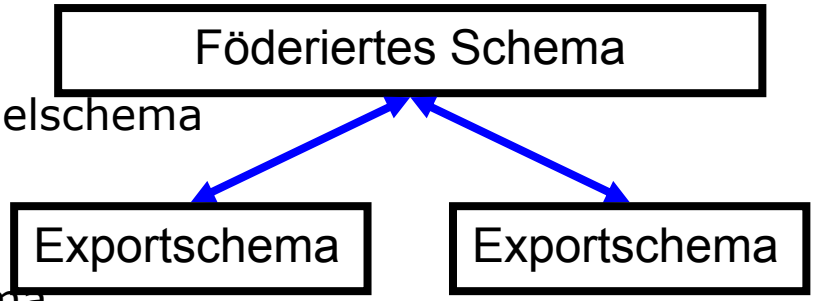

Beispiel

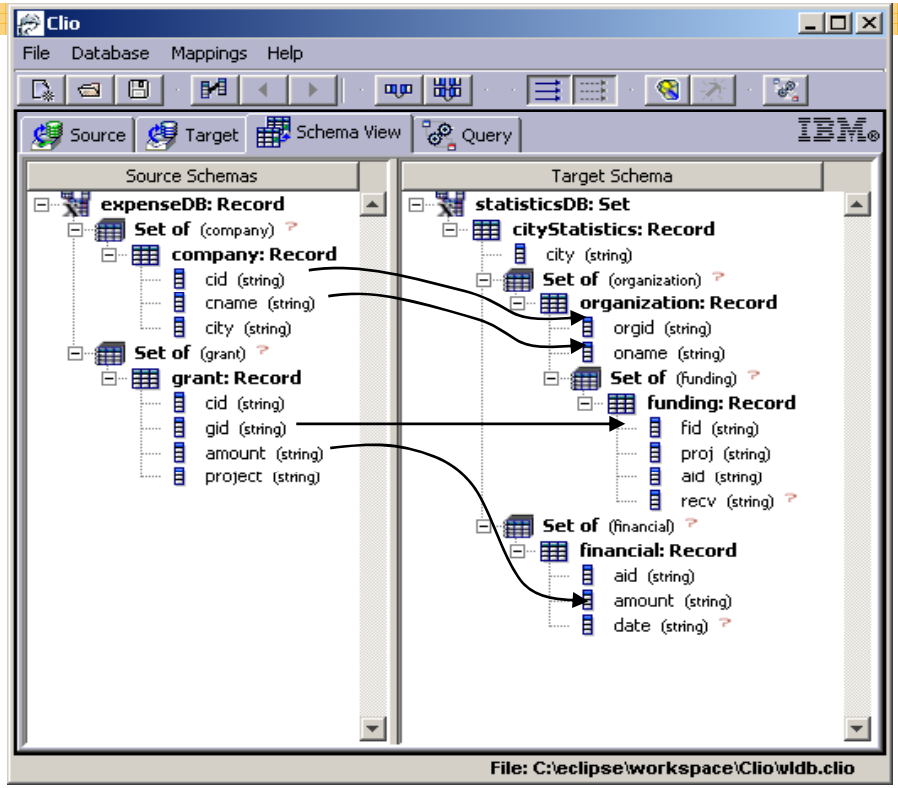

company.cid ≡ cityStatistics.organization.orgID

company.cname ≡ cityStatistics.organization.oname

grant.gid ≡ cityStatistics.organization.funding.fid

grant.amount ≡ cityStatistics.financial.amount

Extensionale Formulierung

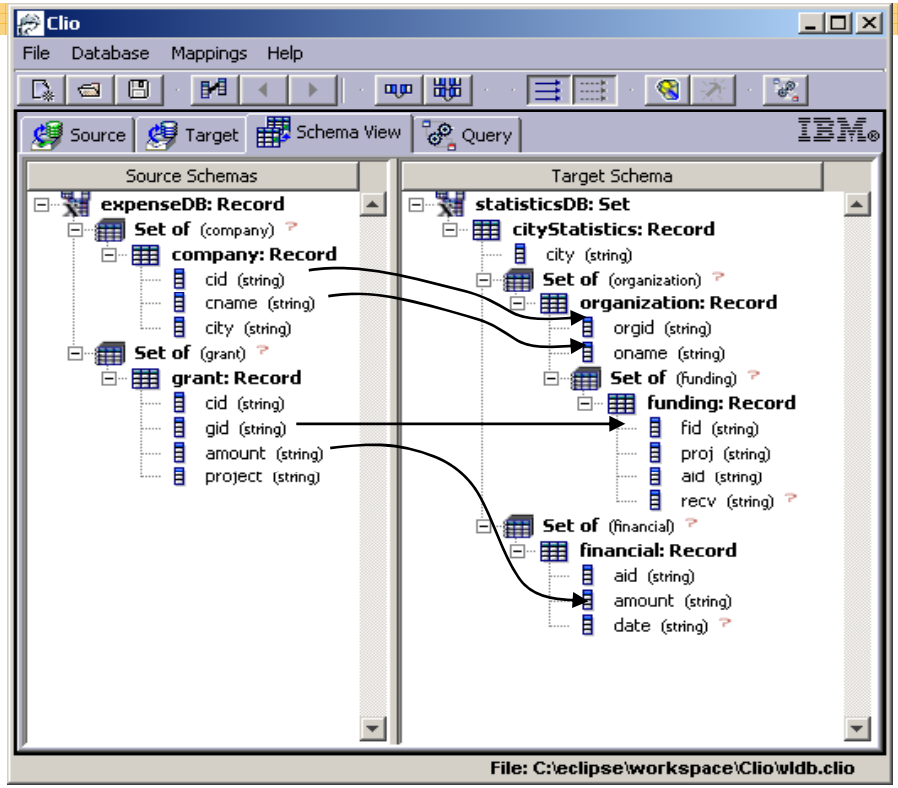


```
SELECT cid, cname          ⊆   SELECT orgid, oname
FROM company                   FROM
                               cityStatistics/organization

SELECT amount              ⊆   SELECT amount
FROM grant                     FROM cityStatistics/financial
```

Virtuell und Materialisiert

- Anfragen übersetzen (virtuell)
  - Gegeben Anfrage an Zielschema
  - Finde semantisch äquivalente Sequenz von Anfragen an Quellschemata
  - Entfällt bei materialisierten Ansätzen
- Daten von der Quelle zum Ziel transformieren
  - Gegeben Ergebnisse der Teilanfragen
    - Oder auch den ganzen Datenbestand - Migration
  - Transformation in das Zielschema
  - Anpassung der Werte an Konventionen des Zielschemas
  - Offline (ETL, DWH) oder Online (Föderation)
- Beide Richtungen sollen dieselben Korrespondenzen benutzen können.

Überblick

- Motivation
- Korrespondenzen
- Übersicht Anfrageplanung
- Global as View (GaV)
  - Modellierung
  - Anfragebearbeitung
- Local as View (LaV)
  - Modellierung
  - Ausblick: Anfragebearbeitung
- Global Local as View (GLaV)
- Vergleich

Aufgabe

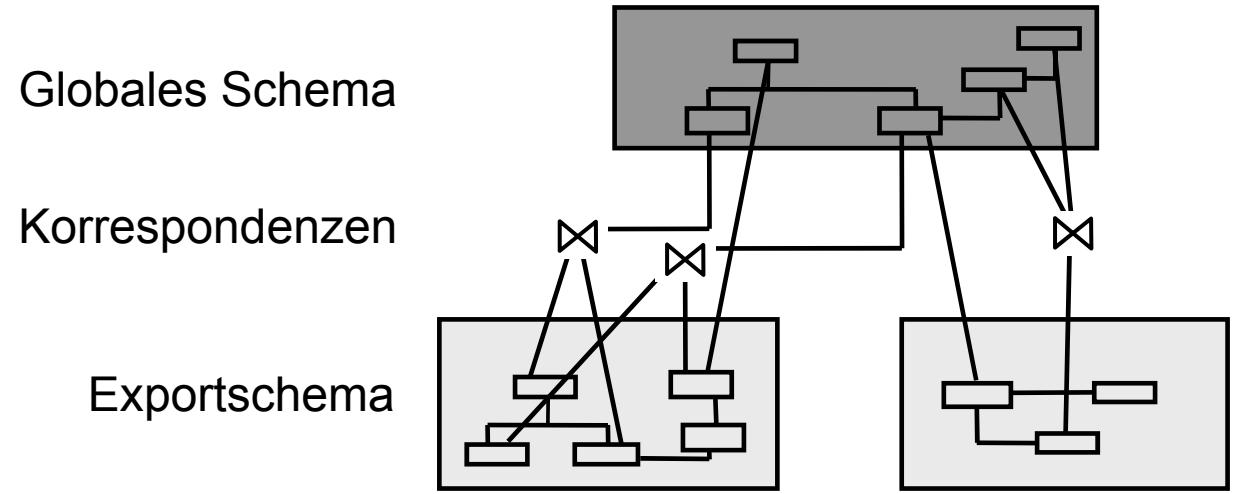

Aufgabe der Anfragebearbeitung

- Gegeben eine Anfrage q gegen das globale Schema
- Gegeben eine Menge von Korrespondenzen zwischen globalem und lokalen Schemata
- Finde alle Antworten auf q.

Anfragebearbeitung

- Schritt 1: Anfrageplanung (in den nächsten Wochen)
  - 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 (später)
  - Finde geeignete Reihenfolge der Ausführung der Teilanfragen
  - Wer führt was aus (Pushen)?
  - Wer kann was ausführen (Kompensation)?
- Schritt 4: Anfrageausführung
  - Monitoring, Puffern, Cachen
  - Dynamische Reoptimierung
- Schritt 5: Ergebnisintegration (noch später)
  - Duplikaterkennung und Konfliktauflösung

Schritt 1 & 2

Anfrage-planung	**Eingabe**: Benutzeranfrage und Anfragekorrespondenzen **Aufgabe**: Berechnet Anfragepläne. Ein Anfrageplan ist eine Menge von logischen Anfragen an Datenquellen, in der Regel verknüpft durch Join-Prädikate. Jeder Plan muss ausführbar sein und nur semantisch korrekte Ergebnisse berechnen. Sollten mehrere Anfragepläne existieren, ist es auch Aufgabe der Anfrageplanung zu entscheiden, welche davon ausgeführt werden sollen. **Ergebnis**: Ein oder mehrere Anfragepläne
Anfrage-übersetzung	**Eingabe**: Ein Anfrageplan **Aufgabe**: Ein Anfrageplan besteht aus Teilanfragen, die jeweils genau eine Datenquelle adressieren. Diese Teilanfragen sind syntaktisch auf die Integrationsschicht zugeschnitten. Die Anfrageübersetzung muss jede Teilanfrage in einen unmittelbar von der betreffenden Datenquelle ausführbaren Befehl übersetzen. **Ergebnis**: Ein übersetzter Anfrageplan

Schritt 3 & 4

Anfrage-optimierung	**Eingabe**: Ein übersetzter Anfrageplan **Aufgabe**: Anfragepläne bestehen aus Teilanfragen, für die noch nicht feststeht, in welcher Reihenfolge sie berechnet und wo in ihnen enthaltene oder sie verbindende Anfrageprädikate ausgeführt werden. Die Festlegung dieser Punkte ist die Aufgabe der Anfrageoptimierung, deren Ergebnis ein (physischer) Ausführungsplan ist. **Ergebnis**: Ein Ausführungsplan
Anfrage-ausführung	**Eingabe**: Ein Ausführungsplan **Aufgabe**: Ein Ausführungsplan kann unmittelbar ausgeführt werden, muss aber in seiner Ausführung überwacht werden, da Netzwerkverbindungen oftmals unzuverlässig sind. Außerdem müssen Prädikate der Benutzeranfrage, deren Ausführung nicht an eine Datenquelle delegiert wurden, im Integrationssystem ausgeführt werden. **Ergebnis**: Eine Menge von Ergebnistupeln

Schritt 5

Ergebnis-integration	**Eingabe**: Pro Ausführungsplan eine Menge von Ergebnistupeln **Aufgabe**: Die Ergebnisse der einzelnen Ausführungspläne sind oftmals redundant oder uneinheitlich. Während der Ergebnisintegration werden die einzelnen Ergebnisse zu einem Gesamtergebnis integriert, was insbesondere Duplikaterkennung und Auflösen von Widersprüchen in den Daten erfordert. **Ergebnis**: Das Ergebnis der Benutzeranfrage

Beispiel

- Filmwelt
- Vereinfachende Annahmen
  - Quellen bestehen nur aus einer (Export-)Relation.
  - Keine Datenmodellheterogenität
    - Nehmen wir jetzt immer an
    - Aufgabe des Wrappers
  - Zunächst vereinfachend: Keine strukturelle oder schematische Heterogenität
  - Keine semantische Heterogenität
    - Gleiche Namen = gleiche Konzepte
    - Nur offensichtliche Schreibvarianten

Beispiel

Globales Schema

```
film( titel, regisseur)
schauspieler( schauspieler_name, nationalitaet)
spielt( titel, schauspieler_name, rolle)
```

Datenquellen

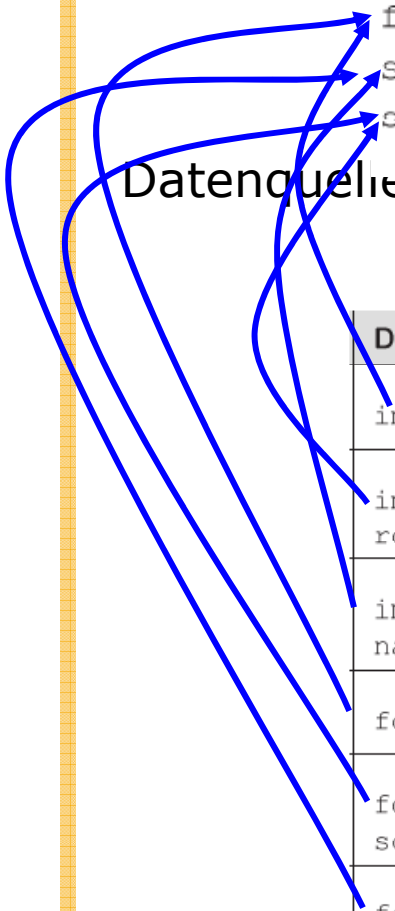

Datenquelle und exportierte Relation	Beschreibung	Globale Relation
`imdb.movie( title, director)`	Alle Filme der IMDB	`film`
`imdb.acts( title, actor_name, role)`	Zuordnung von Schauspielern zu Filmen der IMDB	`spielt`
`imdb.actor( actor_name, nationality)`	Alle Schauspieler der IMDB	`schauspieler`
`fd.film( titel, regisseur)`	Alle Filme des Filmdienstes	`film`
`fd.spielt( titel, schauspieler_name, rolle)`	Zuordnung von Schauspielern zu Filmen des Filmdienstes	`spielt`
`fd.schauspieler( schauspieler_name, nationalitaet)`	Alle Schauspieler des Filmdienstes	`schauspieler`

Anfrageplanung

- Globale Anfrage
  - „Alle Filme, in denen Hans Albers eine Hauptrolle spielte“

```
SELECT titel, regisseur, rolle
FROM   film, spielt
WHERE  spielt.schauspieler_name = 'Hans Albers'
       AND spielt.rolle = 'Hauptrolle'
       AND spielt.titel = film.titel;
```

- Welche Quellen kommen infrage?
  - **`film`**: Quellen **`imdb.movie`** und **`fd.film`**
  - **`spielt`**: Quellen **`imdb.acts`** und **`fd.spielt`**
- Ergibt vier Anfragepläne

Plan	Anfrage
p_1	SELECT title, director, role FROM imdb.movie, imdb.acts WHERE imdb.acts.actor_name = 'Hans Albers' AND imdb.acts.role = 'main actor' AND imdb.acts.title = imdb.movie.title;
p_2	SELECT title, director, rolle FROM imdb.movie, fd.spielt WHERE fd.spielt.schauspieler_name = 'Hans Albers' AND fd.spielt.rolle = 'Hauptrolle' AND fd.spielt.titel = imdb.movie.title;
p_3	SELECT titel, regisseur, role FROM fd.film, imdb.acts WHERE imdb.acts.actor_name = 'Hans Albers' AND imdb.acts.role = 'main actor' AND fd.film.titel = imdb.acts.title;
p_4	SELECT titel, regisseur, rolle FROM fd.film, fd.spielt WHERE fd.spielt.schauspieler_name = 'Hans Albers' AND fd.spielt.rolle = 'Hauptrolle' AND fd.film.titel = fd.spielt.titel;

- Jeder Plan besteht aus zwei Teilplänen
  - Auch p_1 und p_4
  - Jeder Teilplan ist quellspezifisch
  - Kann von einer Quelle ausgeführt werden
- Wer führt die Joins zwischen den Teilplänen aus?
- System kann auswählen
  - Alle Pläne? (teuer, vollständig)
  - Schnellster Plan?
  - Billigster Plan?
  - Plan mit dem größten Ergebnis?

FAQ

- Kann man nicht **`imdb.movie ⋈ imdb.acts`** gemeinsam betrachten?
  - Doch – aber wir nehmen noch Quelle = „1 Relation“ an
  - Später (GaV)
- Warum sollte man **`imdb.movie`** und **`fd.spielt`** zusammen in einem Plan benutzen?
  - Weil Quellen Fehler (fehlende Werte) enthalten
  - Kombination kann neue (und wichtige!) Tupeln produzieren
  - Annahme: Gleiche Werte in den Joinattributen
    - Hier: Filmnamen, Schauspielernamen
- Vorsicht vor impliziten Konsistenzannahmen

Beispiel


```
SELECT titel, regisseur, rolle
FROM   film, spielt
WHERE  spielt.schauspieler_name = 'Hans Albers'
       AND spielt.rolle = 'Hauptrolle'
       AND spielt.titel = film.titel;
```

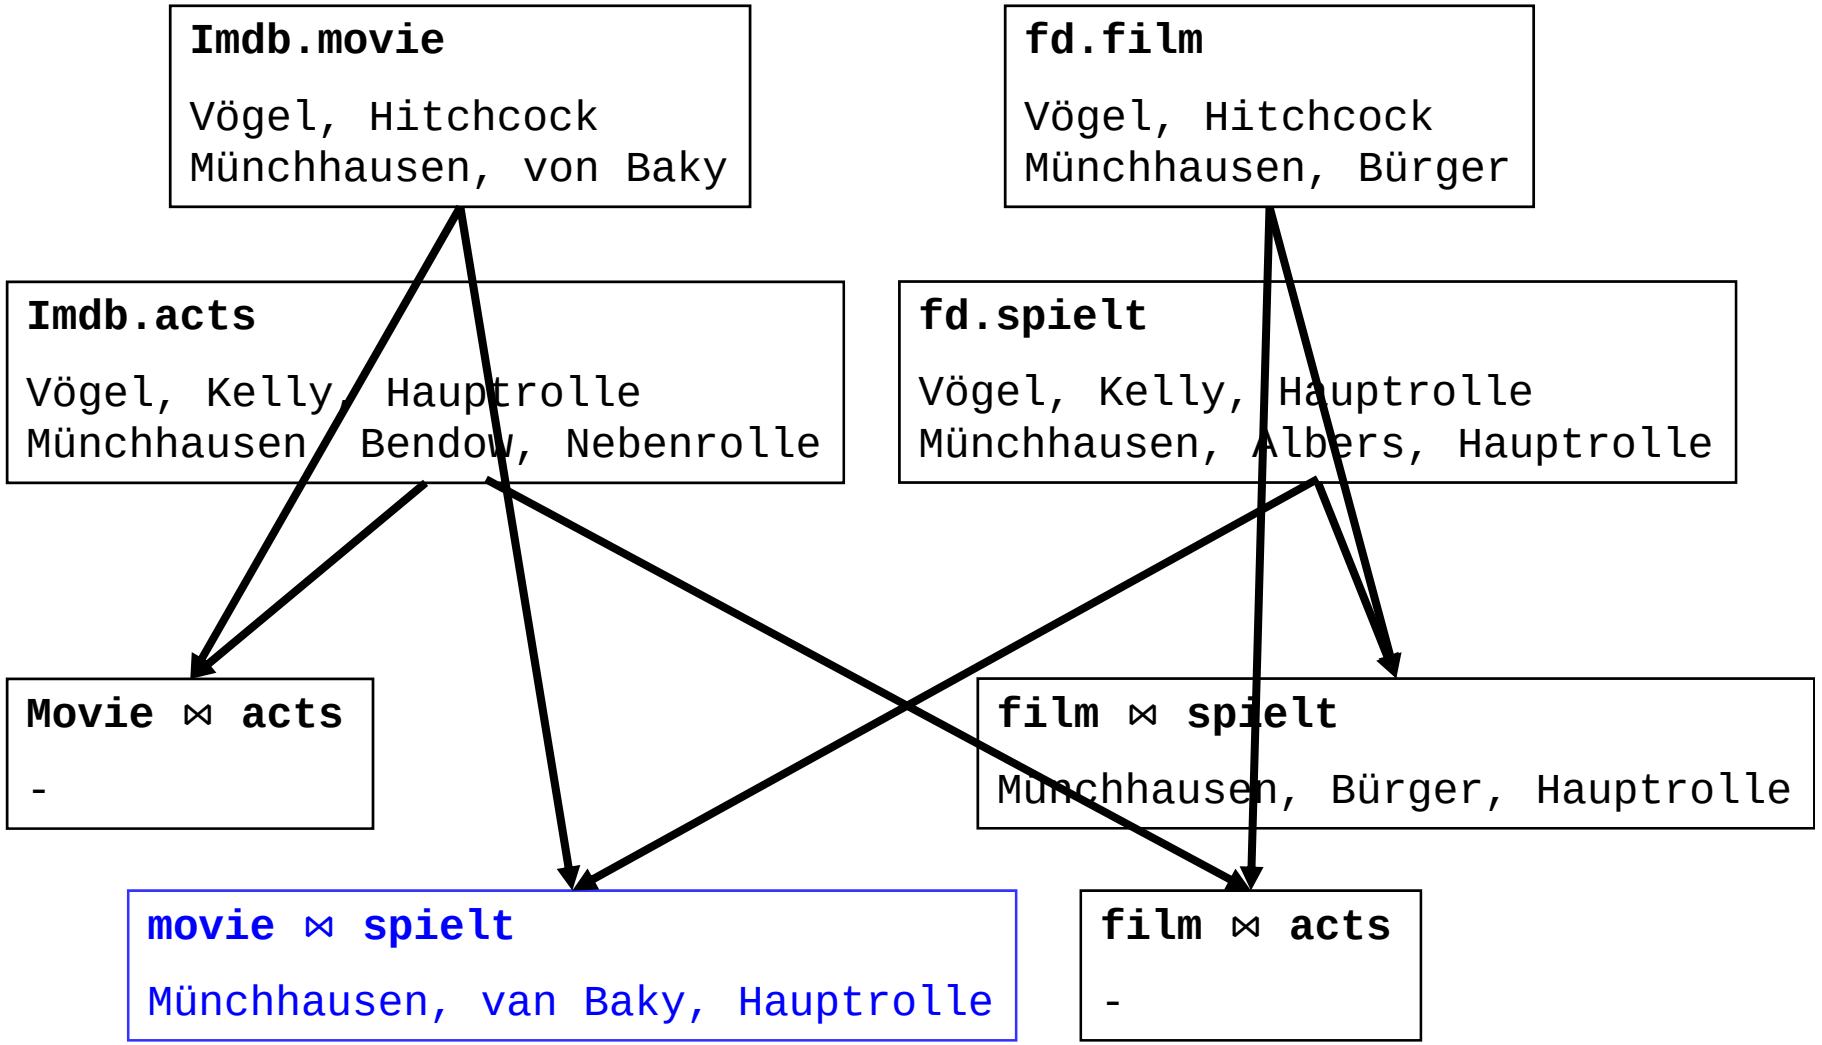

Anfrageübersetzung

Jeder Teilplan kann an genau eine Quelle geschickt werden.

- Übersetzung der Schemaelementnamen
- Übersetzung einer SQL Anfrage in einen Web-Service, HTTP-Aufruf, XQuery, …
- Übersetzung von Konstanten in einer Query
  - Was heißt „Hauptrolle“ in der imdb?

```
SELECT  titel, rolle
FROM    spielt
WHERE   schauspieler_name=,Hans Albers‘
AND     rolle=,Hauptrolle‘
```

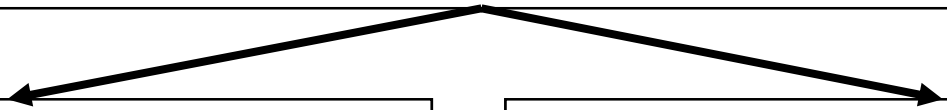

```
SELECT  title, role
FROM    imdb.acts
WHERE   actor_name=,Hans Albers‘
AND     role=,main role‘;
```

```
SELECT  title, role
FROM    imdb.acts
WHERE   actor_name=,Hans Albers‘;
```

Anfrageoptimierung

- Lokale Optimierung: Jeder Plan einzeln
  - Globale Optimierung: Gesamtmenge aller Pläne gemeinsam betrachten (später)
- Fragen
  - Optimale Reihenfolge der Ausführung der Teilpläne?
  - Möglicherweise parallele Ausführung?
  - Bedingungen global oder lokal ausführen?

```
SELECT  title, director, role
FROM    imdb.movie, imdb.acts
WHERE   imdb.acts.actor_name = 'Hans Albers'
        AND imdb.acts.role = 'main actor'
        AND imdb.acts.title = imdb.movie.title;
```

```
TP1:
SELECT  title, director
FROM    imdb.movie;
```

```
TP2:
SELECT  title, role
FROM    imdb.acts
WHERE   actor_name=,Hans Albers'
AND     role=,main role';
```

Möglichkeiten

- Erst TP1, dann TP2, dann Join im Mediator
  - Verlangt nach Download aller Filme der IMDB
  - Vermutlich sehr teuer
- Besser: TP1 und TP2 parallel
  - Ergebnis von TP1 ist für TP2 unerheblich
  - Immer noch sehr teuer
- Erst TP2, dann TP1 umschreiben, Join im Mediator
  - TP2: nur wenige Tupel
  - Pushen dieser Tupel an TP1 „WHERE TITLE in (…)“
    - Passing bindings
  - Keine Parallelisierung mehr möglich
  - Viel kleinere Zwischenergebnisse, vermutlich viel schneller
- …

Anfrageausführung

- Jeder der vier Pläne wurde optimiert und übersetzt
- Teilpläne müssen ausgeführt werden
  - Anfrage abschicken, Ergebnis abwarten, lokale puffern
  - Time-Outs überwachen
  - Müssen alle Teilpläne ausgeführt werden?
    - Wenn wir P1-P4 betrachten und keine Joinbedingungen pushen können
    - Ergibt 8 Teilpläne - aber nur 4 verschiedene Teilpläne
    - Optimierungspotential
    - Entweder global optimieren oder dynamisch durch Caching erkennen
- Fehlende Operationen müssen im Mediator ausgeführt werden.
  - Nicht-pushbare Selektionen
  - Joins zwischen Relationen verschiedener Quellen

Ergebnisintegration

- Jeder Plan liefert eine Menge korrekter Ergebnisse.
- Trotzdem kann es Probleme geben
  - Duplikate: Objekte sind in mehreren Quellen vorhanden
  - Konflikte: Objekte sind mehrmals mit widersprüchlichen Angaben vorhanden

Imdb.movie

```
Vögel, Hitchcock
Münchhausen, von Baky
```

Imdb.acts

```
Vögel, Kelly, Hauptrolle
Münchhausen, Bendow, Nebenrolle
```

fd.film

```
Vögel, Hitchcock
Münchhausen, Bürger
```

fd.spielt

```
Vögel, Kelly, Hauptrolle
Münchhausen, Albers, Hauptrolle
```

… ⋈ … UNION … ⋈ … UNION …

```
-
Münchhausen, Bürger, Hauptrolle
Münchhausen, von Baky, Hauptrolle
-
```

Überblick

- Motivation
- Korrespondenzen
- Übersicht Anfrageplanung
- Global as View (GaV)
  - Modellierung
  - Anfragebearbeitung
- Local as View (LaV)
  - Modellierung
  - Ausblick: Anfragebearbeitung
- Global Local as View (GLaV)
- Vergleich

Modellierung von Datenquellen

- Kernidee
  - Modellierung strukturell heterogener Quellen in Bezug auf ein globales Schema als Views (Sichten)
  - Relationales Modell
- Allgemein:
  - 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
- Jetzt: Unterscheidung lokales und globales Schema

Global as View / Local as View

- 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.

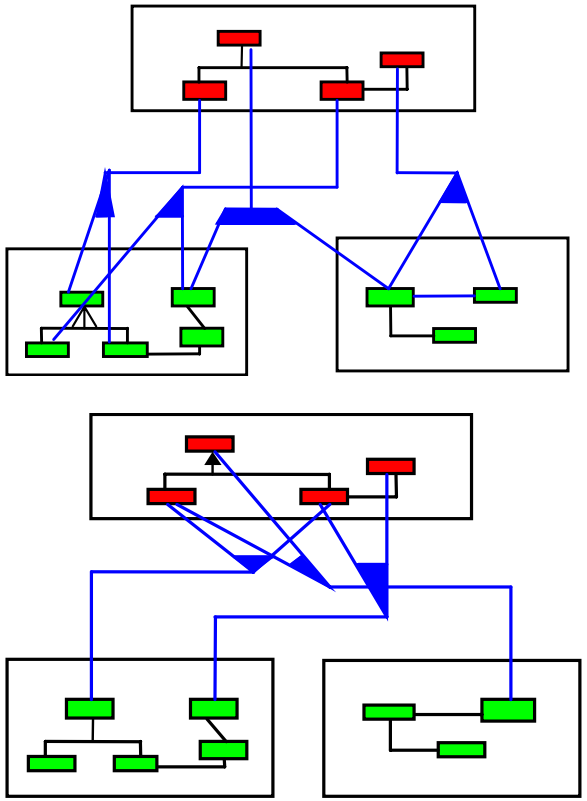

Global as View (GaV) – Beispiel

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

S1: IMDB(Titel, Regie, Jahr, Genre)
S2: MyMovies(Titel, Regie, Jahr, Genre)
S3: RegieDB(Titel, Regie)
S4: GenreDB(Titel, Jahr, Genre)

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

Typisches Merkmal bei GaV

Join über mehrere Quellen (Anfragebearbeitung!)

Quelle: VL „Data Integration“, Alon Halevy, University of Washington, 2002

Zwei Arten von GaV Regel

- Einfache GaV Regeln: Quellspezifisch
  - Lokale Anfrage adressiert nur eine Quelle
  - Verknüpfung über Quellen hinweg übernimmt die Anfrageplanung
  - Besser wartbar (Änderung einer Quelle kann nur wenige Sichten betreffen)
  - Einfacher zu erweitern (bestehende Views nicht anfassen)
- Komplexe GaV Regeln: Quellübergreifend
  - Lokale Anfrage ist eine Anfrage in einer Multidatenbanksprache
  - Eine Sicht fasst alle Objekte einer globalen Relation zusammen
    - Sicht film, schauspieler, …
  - Anfrageplanung übernimmt nur noch Verknüpfung zwischen verschiedenen Relationen, d.h., Joins in der globalen Anfrage
  - Weniger robust, schwerer zu erweitern
    - Änderung einer Quelle kann alle Sichten betreffen
  - Konfliktlösung kann in den View eingebaut werden

Global as View (GaV) – Beispiel

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

S5: MDB(Titel, Regie, Jahr)
S6: MovDB(Titel, Regie, Genre)

```
CREATE VIEW Film AS
SELECT Titel, Regie, Jahr, NULL AS Genre
FROM MDB
            UNION
SELECT Titel, Regie, NULL AS Jahr, Genre
FROM MovDB
```

Fehlende Attribute

Form des Ergebnisses; Datenfusion

Quelle: VL „Data Integration“, Alon Halevy, University of Washington, 2002

Global as View (GaV) – Beispiel

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

S7: KinoDB(Kino, Genre)

```
CREATE VIEW Film AS
SELECT NULL, NULL, NULL, Genre
FROM KinoDB

CREATE VIEW Programm AS
SELECT Kino, NULL, NULL
FROM KinoDB
```

Allenfalls interessant für passing bindings

Problem: Assoziationen werden getrennt

- Da Ergebnis einer Sicht nur eine globale Relation sein kann
- Lösung: Skolemfunktionen

Tritt auf, wenn

- Attribute verschiedener globaler Relationen in einer lokalen Relation liegen und der verbindende Key/FK lokal nicht existiert
- Nicht im umgekehrten Fall: einfach lokale Relationen joinen…

Quelle: VL „Data Integration“, Alon Halevy, University of Washington, 2002

Vorschau:
Local as View (LaV) – Beispiel

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

S7: KinoDB(Kino, Genre)

```
CREATE VIEW S7 AS
SELECT Programm.Kino, Film.Genre
FROM Film, Programm
WHERE Film.Titel = Programm.Titel
```

- Umgekehrte Betrachtung
- Assoziationen bleiben erhalten
  - Titel wird zwar nie instantiiert,
  - aber man weiß, dass es einen verbindenden Titel gibt.

Integritätsconstraints (ICs)

- Schränken Wertebereiche ein, schließen Werte aus, schließen Kombinationen von Werten aus, ...
- Dienen zur näheren Bestimmung der Intension einer Relation:
  - **teure_autos(auto, preis), preis>50.000**
  - **golfclub_mitglieder(name, alter), alter>55**
  - **film(title, type), type∈{spielfilm, doku, kurzfilm}**
  - …
- Für die Integration sehr wichtig

Global as View (GaV) – Gobale ICs

Globales Schema
NeuerFilm(Titel, Regie, Jahr, Genre)
Programm(Kino, Titel, Zeit)
IC: Jahr > 2000

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

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

- IC auf globalem Schema kann in diesem Fall in die Sichtdefinition aufgenommen werden
- Ausführung in der Quelle (push) oder im Mediator
- Gegenbeispiel?

Probleme mit globalen IC

Globales Schema

Neuerfilm(Titel, Regie, Jahr, Genre);
Programm(Kino, Titel, Zeit);
IC: Jahr > 2000

```
S1: IMDB( Titel, Regie, Jahr, Genre)
S2: MyOldOrNewMovies( Titel, Regie)
```

```
CREATE VIEW NeuerFilm AS
SELECT  *
FROM    IMDB
WHERE   Jahr > 2000
        UNION
SELECT Titel, Regie, NULL, NULL
FROM    MyOldOrNewMovies
WHERE   ??
```

- Quelle gibt keine Jahr-Informationen
- IC auf globalem Schema kann nicht überprüft werden
- Quelle kann nicht integriert werden

Global as View (GaV) – Lokale ICs

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

S8: NeueFilme(Titel,Regie, Genre)
(IC: Jahr > 2000)

```
CREATE VIEW Film AS
SELECT Titel, Regie, NULL, Genre
FROM NeueFilme
```

- Bekannte Nebenbedingung auf der Quelle kann nicht modelliert werden.
- Warum ist das schlecht?
  - **`SELECT * FROM film WHERE jahr < 1950`**

„Trick“

Globales Schema

```
Film( Titel, Regie, Jahr, Genre)
Programm( Kino, Titel, Zeit)
```

```
S8: NeueFilme( Titel, Regie, Jahr, Genre)
IC: Jahr > 2000
```

```
CREATE VIEW Film AS
SELECT  Titel, Regie, Jahr, Genre
FROM    NeueFilme
WHERE   Jahr > 2000
```

- IC in Quelle wird modelliert
  - Geht nur, wenn das Attribut in der Quelle instantiiert wird
- Die Bedingung ändert am Ergebnis nichts
  - Für eine lokale Anfrage wäre sie sinnlos
- Aber sie hilft dem Anfrageplaner
  - **`SELECT * FROM film WHERE jahr < 1950`**

Global as View (GaV) – globale ICs

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

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

```
CREATE VIEW NeuerFilm AS
SELECT * FROM AlleFilmeNett
WHERE Jahr > 2000
        oder
CREATE VIEW NeuerFilm AS
SELECT Titel, Regie, Genre FROM AlleFilmeNett
WHERE Jahr > 2000
```

Quelle S2 kann nicht modelliert werden!

Global as View (GaV) – lokale ICs

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 = 2007)

Jede Quelle kann modelliert werden!

Jede Sicht exportiert alle Daten der Quelle!

Modellierung nur für Optimierung

```
CREATE VIEW Film AS
SELECT *
FROM AlleFilmeNett
        UNION
SELECT Titel, Regie, N   L, Genre
FROM AlleFilmeBöse
        UNION
SELECT *
FROM NeueFilmeNett
(WHERE Jahr > 2000)
        UNION
SELECT Titel, Regie, NULL, Genre
FROM NeueFilmeBöse
        UNION
SELECT Titel, Regie, `2007´, Genre
FROM AktuelleFilme
```

Global as View (GaV) – ICs

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

```
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, 2004, Genre
FROM AktuelleFilme
```

Anfrage 1:
SELECT * FROM Film

```
SELECT * FROM
    (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, 2004, Genre
    FROM AktuelleFilme)
```

Global as View (GaV) – ICs

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

```
SELECT * FROM
      (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, 2004, Genre
      FROM AktuelleFilme)
WHERE Jahr > 2001
```

Anfrage 1:
SELECT * FROM Film
WHERE Jahr > 2001

Trägt voll zum Ergebnis bei

Trägt nicht zum Ergebnis bei, obwohl nützlich

Trägt voll zum Ergebnis bei

Trägt nicht zum Ergebnis bei, obwohl nützlich

Trägt voll zum Ergebnis bei

Global as View (GaV) – ICs

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

Anfrage 1:
SELECT * FROM Film
WHERE Jahr = 2001

```
SELECT * FROM
      (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, 2004, Genre
      FROM AktuelleFilme)
WHERE Jahr = 2001
```

Trägt voll zum Ergebnis bei

Trägt nicht zum Ergebnis bei, obwohl nützlich

Trägt voll zum Ergebnis bei

Trägt nicht zum Ergebnis bei, obwohl nützlich

Trägt nicht zum Ergebnis bei (2001 ≠ 2004)

Global as View (GaV) – ICs

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

```
SELECT * FROM
      (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, 2004, Genre
      FROM AktuelleFilme)
WHERE Jahr < 1950
```

Anfrage 1:
SELECT * FROM Film
WHERE Jahr < 1950

Trägt voll zum Ergebnis bei

Trägt nicht zum Ergebnis bei, obwohl nützlich

Trägt nicht zum Ergebnis bei (2000 > 1950)

Trägt nicht zum Ergebnis bei (zum Glück)

Trägt nicht zum Ergebnis bei (2004 > 1950)

Global as View (GaV) – globale und lokale ICs

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

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 = 2004)

Quelle S2 kann nicht modelliert werden!

```
CREATE VIEW Film AS
SELECT Titel, Regie, Genre
FROM AlleFilmeNett
WHERE Jahr > 2000
        UNION
???
        UNION
SELECT Titel, Regie, Genre
FROM NeueFilmeNett
(WHERE Jahr > 2000)
        UNION
SELECT Titel, Regie, Genre
FROM NeueFilmeBöse
        UNION
SELECT Titel, Regie, Genre
FROM AktuelleFilme
```

Global as View (GaV) – ICs

Fazit

- Nebenbedingungen (ICs) im globalen Schema
  - können die Integration von Quellen verhindern,
    - wenn die Bedingung nicht geprüft werden kann (fehlendes Attribut).
- Nebenbedingungen in den lokalen Schemas
  - können modelliert werden,
    - wenn sie auf exportierten Attributen gelten, oder
    - wenn sie auf globalen Attributen gelten und die Form attribute = <constant> haben.
  - tragen möglicherweise nicht zum Anfrageergebnis bei,
    - wenn Nebenbedingung nicht modelliert wurde.

Überblick

- Motivation
- Korrespondenzen
- Übersicht Anfrageplanung
- Global as View (GaV)
  - Modellierung
  - Anfragebearbeitung
- Local as View (LaV)
  - Modellierung
  - Ausblick: Anfragebearbeitung
- Global Local as View (GLaV)
- Vergleich

Anfragebearbeitung – GaV

- Gegeben:
  - Anfrage an globales Schema
    - Insbesondere: 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

GaV – Beispiel

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

S1: IMDB(Titel, Regie, Jahr, Genre)
S2: RegieDB(Titel, Regie)
S3: GenreDB(Titel, Jahr, Genre)

```
SELECT *
FROM Film
```

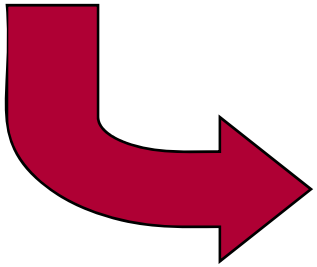

Globale Sicht für Film

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

GaV – Beispiel

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

S1: IMDB(Titel, Regie, Jahr, Genre)
S2: RegieDB(Titel, Regie)
S3: GenreDB(Titel, Jahr, Genre)

```
SELECT Titel, Jahr
FROM Film
WHERE Jahr = ‚2003‘
```

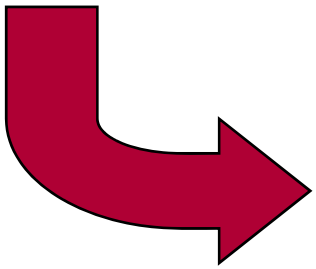

```
SELECT Titel, Jahr
FROM (      SELECT * FROM IMDB
                  UNION
            SELECT R.Titel, R.Regie, G.Jahr, G.Genre
            FROM RegieDB R, GenreDB G
            WHERE R.Titel = G.Titel
      )
WHERE Jahr = ‚2003‘
```

GaV – Beispiel


```
SELECT F.Titel, P.Kino
FROM   Film F, Programm P
WHERE F.Titel = P.Titel
AND      P.Zeit > 20:00
```

S1: IMDB(Titel, Regie, Jahr, Genre)
S2: RegieDB(Titel, Regie)
S3: GenreDB(Titel, Jahr, Genre)
S7: KinoDB(Titel, Kino, Genre, Zeit)

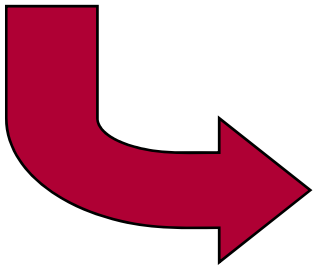

```
SELECT F.Titel, P.Kino
FROM (     SELECT * FROM IMDB
                  UNION
           SELECT R.Titel, R.Regie, G.Jahr, G.Genre
           FROM RegieDB R, GenreDB G
           WHERE R.Titel = G.Titel
      ) AS F,
      (     SELECT *
            FROM KinoDB
      ) AS P
WHERE F.Titel = P.Titel
AND      P.Zeit > 20:00
```

GaV - Schachtelung

Geschachtelte Anfragen

- Beliebig tiefe Schachtelung
- Bearbeitung
  - Konzeptionell:
    Ausführung der Anfragen von innen nach außen und Speicherung in temporären Relationen.
  - Tatsächlich:
    Optimierungspotential durch Umschreiben der Anfrage (Entschachtelung)
- Caching und Materialisierte Sichten (materialized views)

GaV - Schachtelung

Schachtelung

- i.d.R. Belassen bei entfernten Quellen
- i.d.R. Auflösung bei materialisierten Sichten

```
SELECT F.Titel, P.Kino
FROM (      SELECT * FROM IMDB
                        UNION
                SELECT R.Titel, R.Regie, G.Jahr, G.Genre
                FROM RegieDB R, GenreDB G
                WHERE R.Titel = G.Titel
        ) AS F,
        (       SELECT *
                FROM KinoDB
        ) AS P
WHERE F.Titel = P.Titel
AND       P.Zeit > 20:00
```

```
SELECT F.Titel, P.Kino
FROM    IMDB F, KinoDB P
WHERE F.Titel = P.Titel
AND       P.Zeit > 20:00

UNION

SELECT F1.Titel, P1.Jino
FROM    RegieDB F1, GenreDB F2, KinoDB P1
WHERE F1.Titel = F2.Titel
WHERE F1.Titel = P1.Titel
AND       P1.Zeit > 20:00
```

GaV - Schachtelung


```
SELECT F.Titel, P.Kino
FROM (      SELECT * FROM IMDB
                        UNION
                SELECT R.Titel, R.Regie, G.Jahr, G.Genre
                FROM RegieDB R, GenreDB G
                WHERE R.Titel = G.Titel
        ) AS F,
        (       SELECT *
                FROM KinoDB
        ) AS P
WHERE F.Titel = P.Titel
AND       P.Zeit > 20:00
```

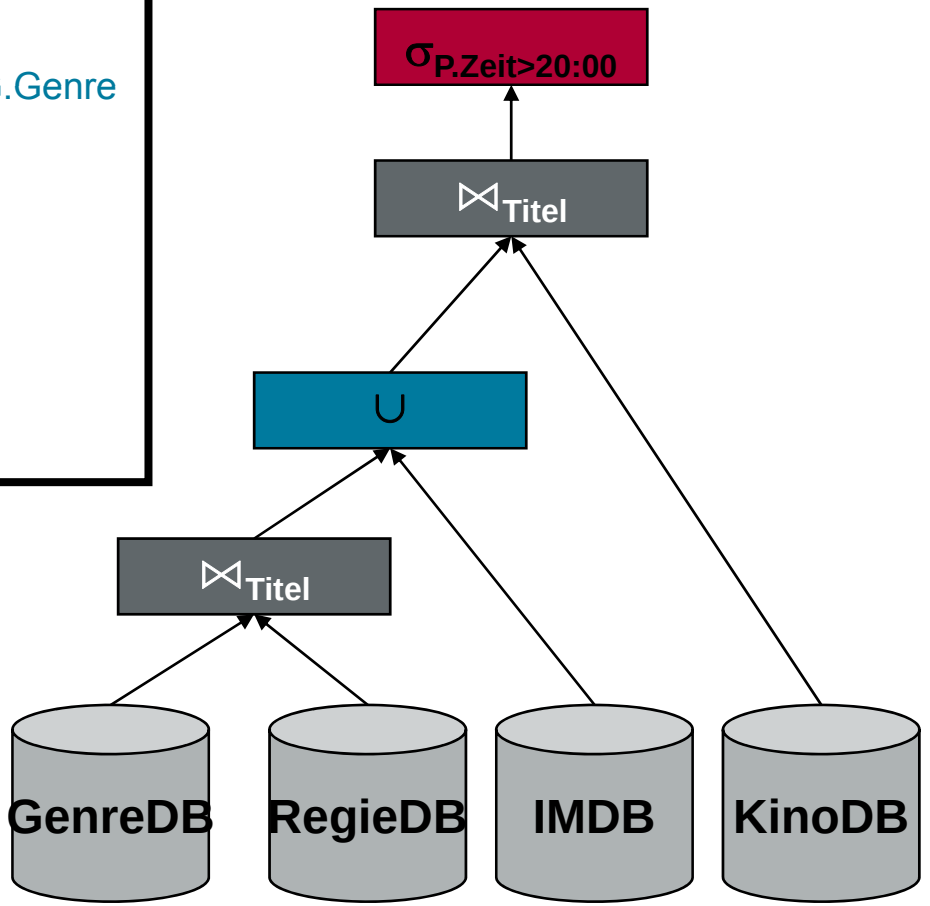

GaV - Schachtelung

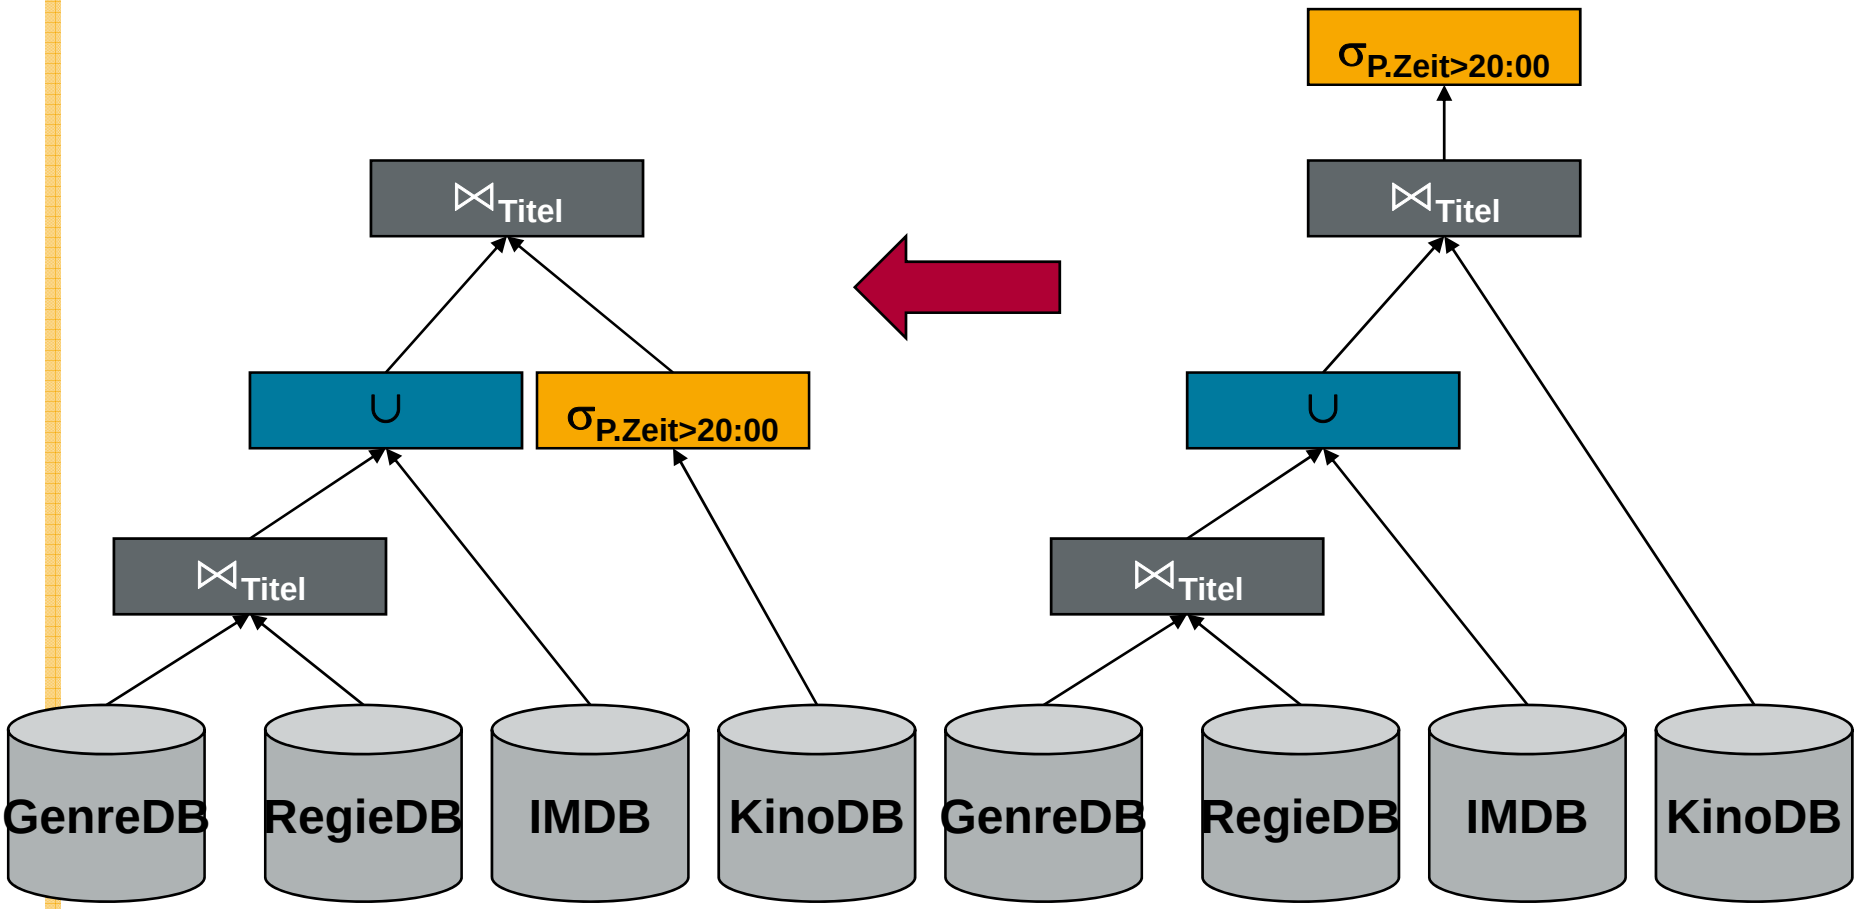

GaV - Schachtelung

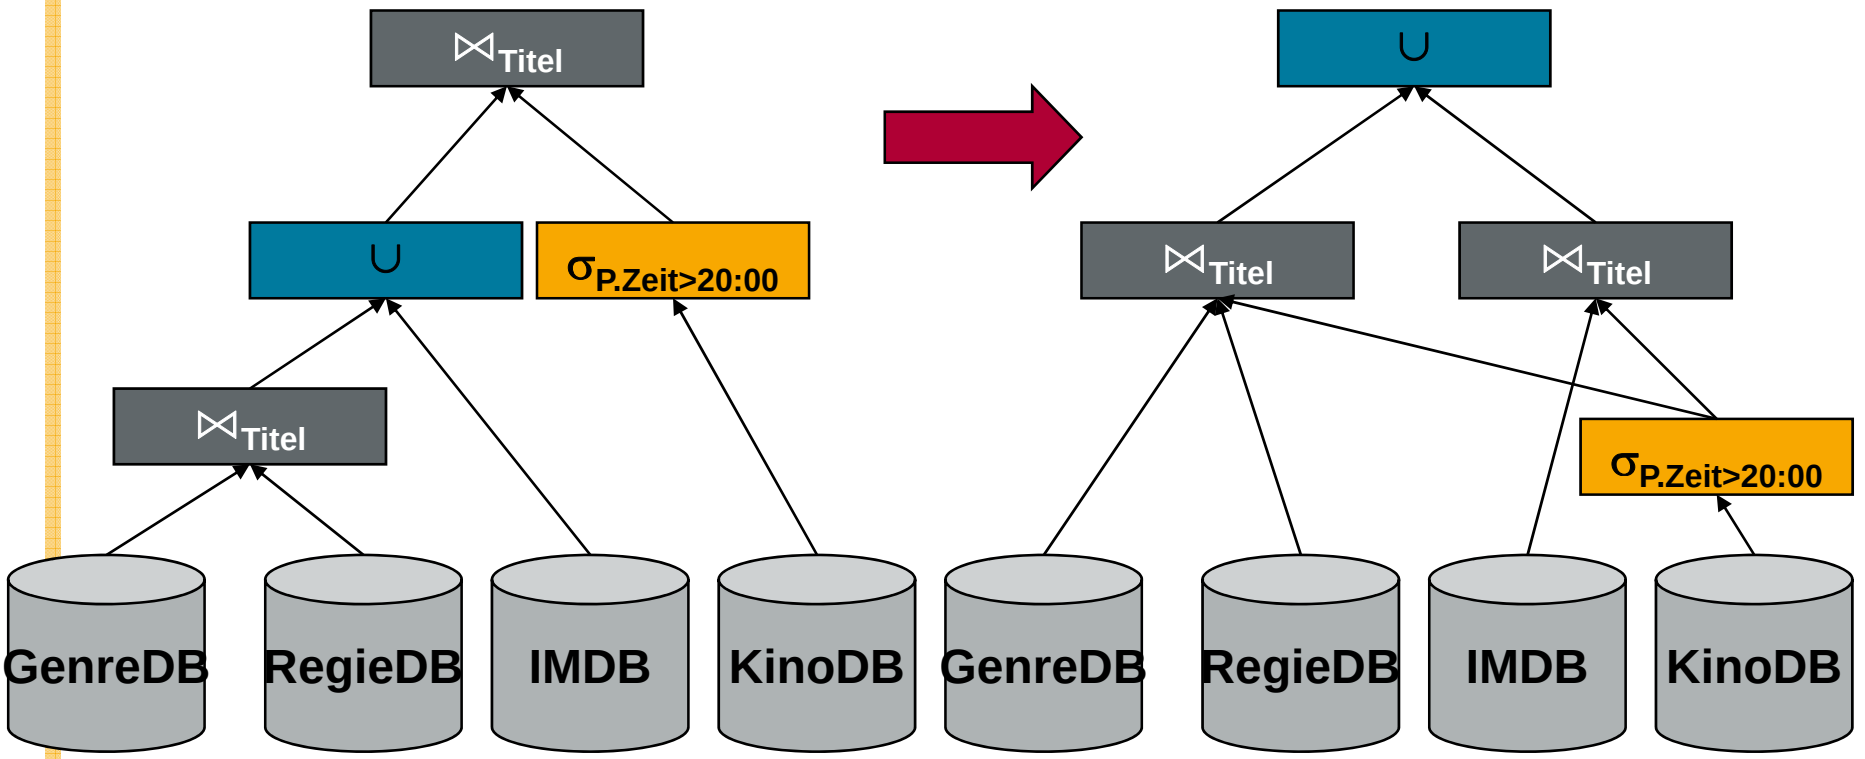

GaV - Schachtelung

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

S5: MDB(Titel, Zeit, Regie)
S6: MovDB(Kino, Genre, Titel)

```
CREATE VIEW Film AS
SELECT Titel, Regie, Genre
FROM MDB, MovDB
WHERE MDB.Titel = MovDB.Titel

CREATE VIEW Programm AS
SELECT Kino, Titel, Zeit
FROM MovDB, MDB
WHERE MDB.Titel = MovDB.Titel
```

```
SELECT F.Titel, P.Kino
FROM   Film F, Programm P
WHERE F.Titel = P.Titel
AND      P.Zeit > 20:00
```

```
SELECT F.Titel, F.Jahr
FROM (     SELECT Titel, Regie, Genre
           FROM MDB, MovDB
           WHERE MDB.Titel = MovDB.Titel
      ) AS F,
      (    SELECT Kino, Titel, Zeit
           FROM MovDB, MDB
           WHERE MDB.Titel = MovDB.Titel
      ) AS P
WHERE F.Titel = P.Titel
AND      P.Zeit > 20:00
```

GaV - Schachtelung


```
SELECT F.Titel, F.Jahr
FROM (      SELECT Titel, Regie, Genre
            FROM MDB, MovDB
            WHERE MDB.Titel = MovDB.Titel
      ) AS F,
      (     SELECT Kino, Titel, Zeit
            FROM MovDB, MDB
            WHERE MDB.Titel = MovDB.Titel
      ) AS P
WHERE F.Titel = P.Titel
AND   P.Zeit > 20:00
```

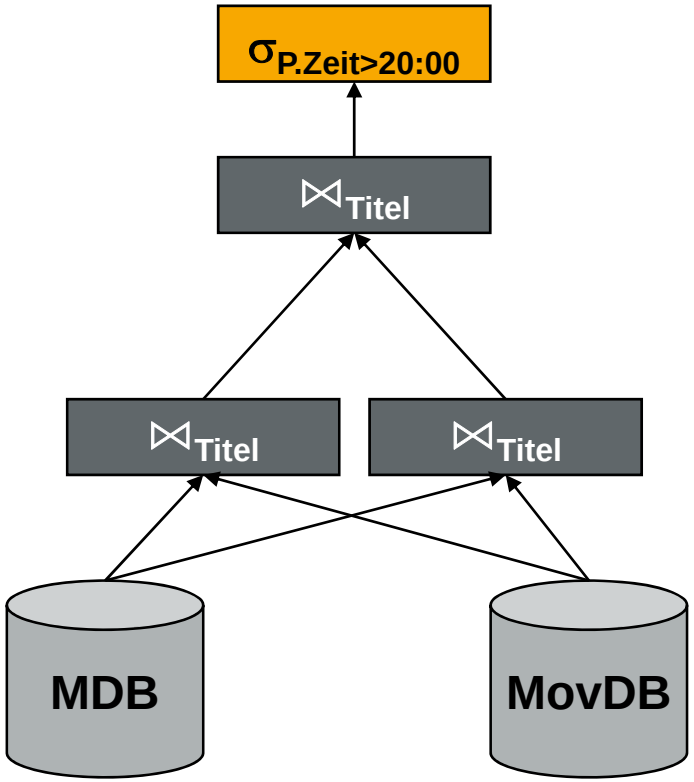

GaV - Schachtelung