Informationsintegration

Local-as-View Anfrageplanung

Ulf Leser

Inhalt dieser Vorlesung

- Anfragekorrespondenzen – Formale Definition
  - Korrespondenztypen und -arten
  - GaV erklärt
- Local as View
- Query Containment
- Semantische Korrektheit von Anfrageplänen
- Später
  - Algorithmen zum Query Containment
  - Answering Queries using Views
  - GLaV – Global and Local as View

Anfrageplan revisited

- Definition
  Gegeben eine globale Anfrage q. Ein Anfrageplan p für q ist eine Anfrage der Form $q_1 \bowtie \ldots \bowtie q_n$ so dass
  - *Jedes q_i kann mit Hilfe der Quellen ausgeführt werden*
  - *Jedes von p berechnete Tupel ist eine semantisch korrekte Antwort für q*
- Bemerkungen
  - „Semantisch korrekt" haben wir noch nicht definiert
  - In der Regel gibt es viele Anfragepläne
  - Die q_i heißen Teilanfragen oder Teilpläne

Anfrageergebnis

- Definition
  Gegeben eine globale Anfrage q. Sei p_1, ..., p_n die Menge aller (semantisch korrekter) Anfragepläne für q. Dann ist das Ergebnis von q definiert als

$$result(q) = \bigcup_{i=1..n} result(p_i)$$

- Bemerkungen
  - In der Informationsintegration sollte UNION Duplikate entfernen
    - Problem der Ergebnisintegration
  - Wie das Ergebnis berechnet wird, ist Sache der Anfrageoptimierung
    - Identische / überlappende Teilanfragen erkennen oder nicht
    - Ergebnisse cachen oder nicht
    - …

Anfragekorrespondenzen

- Anfrageplanung übersetzt zwischen verschiedenen „Sprachen“ im selben Datenmodell
  - Zielschema und Quellschemata
- Beziehungen zwischen den Sprachelementen sind Grundlage der semantischen Korrektheit von Plänen
  - Beziehungen: Homonyme, Synonyme, Hyperonyme, etc.
  - Bei echten Sprachen zwischen: Wörter, Sätze, Texte
  - Bei Schemata: Attribute, Relationen, Anfragen
- Beziehungen werden durch Korrespondenzen ausgedrückt

Übersetzung

- The dog barked and went away
- Der Hund bellte und ging weg

Strukturelle und semantische Heterogenität

- Last summer we went to greece spending a year‘s income
- Wir sind letzten Sommer nach Griechenland gefahren und haben ein Jahreseinkommen auf den Kopf gehauen

Auf Schemaebene

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

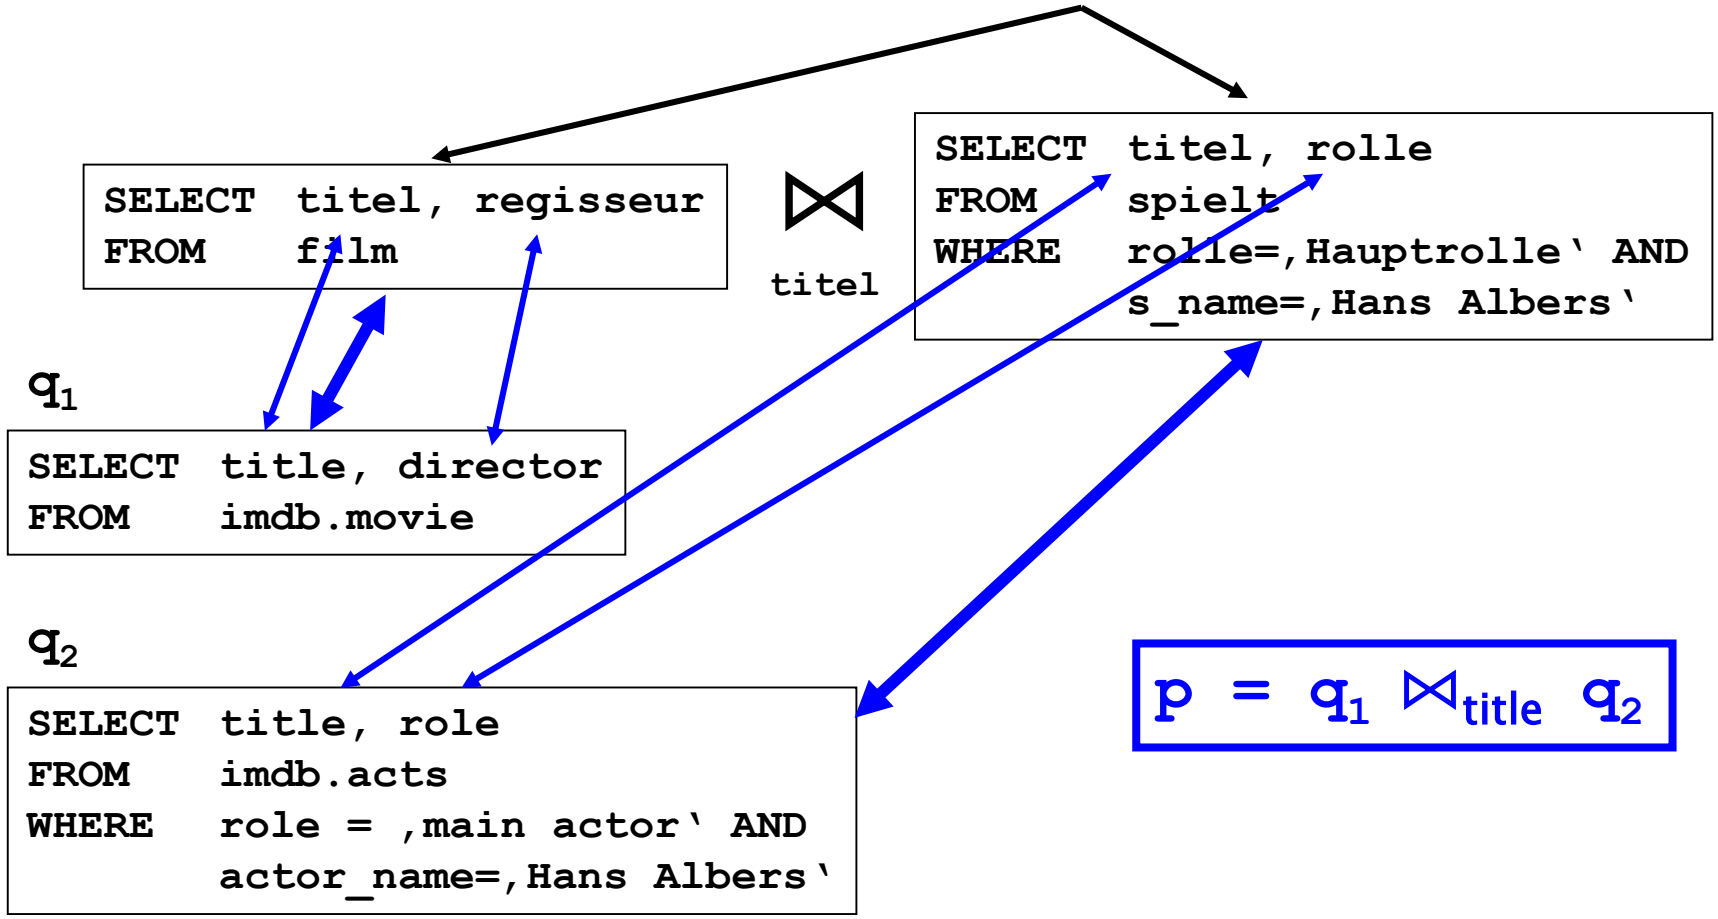

Viele Fragen

- Welche Attribute entsprechen welchen Attributen?
- Wie bricht man die globale Anfrage am besten auf?
- Für welche Teile der globalen Anfrage gibt es äquivalente Anfragen an Wrapper?
- Wie drückt man dies durch Korrespondenzen aus?
- Wie kann man mit beschränkten Quellen umgehen?
- …

Inhalt dieser Vorlesung

- Anfragekorrespondenzen
  - Korrespondenztypen und -arten
  - GaV erklärt
- Local as View
- Query Containment
- Semantische Korrektheit von Anfrageplänen

Drei Korrespondenzarten

- Beziehungen zwischen Attributen
  - Eher einfach zu finden
  - Reicht nicht zur Anfrageplanung
- Beziehungen zwischen Relationen
  - „Natürliche" Ebene – Anfrageplanung wird zur Ersetzung von Relationennamen
  - Aber Relationen eines Quellschemas entsprechen meist nicht 1:1 den Relationen eines anderen Schemas
- Beziehungen zwischen Anfragen
  - Subsumiert beide vorherigen Konzepte, sehr flexibel
  - Schwierigere Anfrageplanung

Korrespondenztypen 1

- Sei q_1 ein Element des globalen Schemas und q_2 ein Element eines lokalen Schemas
  - Element = Anfrage/Relation/Attribut

- Exklusion: $q_1 \cap q_2 = \emptyset$
  - Extensionen von q_1 und q_2 sind überlappungsfrei
    - Bedingt auch intensionale Überlappungsfreiheit
  - Das ist der Normalfall und wird angenommen, wenn keine Korrespondenz zwischen zwei Elementen angegeben wird

Korrespondenztypen 2

- Sei q_1 ein Element des globalen Schemas und q_2 ein Element eines lokalen Schemas

- Inklusion: $q_1 \supseteq q_2$
  - Extension von q_2 ist in der von q_1 enthalten
  - Mediator-Architekturen: Extension der Wrapperanfragen (q_2) ist in der Extension der globalen Anfrage (q_1) enthalten
    - Besser: „soll enthalten sein“
  - Beachte: q_1 kann in vielen Korrespondenzen vorkommen
    - Wenn es viele Quellen gibt, die zu q_1 beitragen
    - Wenn es viele Elemente in einer Quellen gibt, die zu q_1 beitragen

Korrespondenztypen 2

- Äquivalenz: $q_1 \equiv q_2$
  - Die Extensionen von q_1 und q_2 sind identisch
  - Interpretation: q_2 ist die einzig mögliche Datenquelle von q_1
  - Es darf also keine weitere Regel der Art $q_i \supseteq q_2$ oder $q_i \equiv q_2$ geben
  - Betrachten wir im folgenden nicht weiter
- Spiegel-Inklusion: $q_1 \subseteq q_2$: Siehe Überlappung
- Überlappung: $q_1 \cap q_2 \neq \emptyset \wedge \neg(q_1 \subseteq q_2) \wedge \neg(q_1 \supseteq q_2)$
  - Die Extensionen von q_1 und q_2 überschneiden sich, ohne das eine die andere enthält
  - Damit sind manche Ergebnisse von q_2 nicht in der Extension von q_1 enthalten – falsche Ergebnisse
  - Diese Korrespondenzen nützen uns nichts
  - Vorgehen: Finde einen `filter` von q_2 so, dass $q_1 \supseteq$ `filter(`q_2`)`

Korrespondenzen

- Definition
  Eine (Anfrage-)korrespondenz ist eine Regel der Art

$$q_1 \supseteq q_2$$

  - *q_1 ist eine Anfrage an das globale Schema*
  - *q_2 ist eine ausführbare Anfrage an das Exportschema eines Wrappers*
- Bemerkung
  - Wir verwenden ab jetzt nur noch $\supseteq$ - Korrespondenzen
  - Aussage über die Extensionen von Anfragen
  - Also über die Beziehungen von Tupelmengen, die durch Anfragen in unterschiedlichen Schemata berechnet werden
  - Ist also eine Aussage über die (formale) Semantik von Anfragen

GaV und LaV

- Definition
  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*
  - *LaV (Local-as-View), wenn q_2 (Wrapperschema) eine einzelne Relation ohne Selektionen oder Joins ist*
  - *Sonst heißt sie GLaV (Global-local-as-view)*
    - *Oder BaV: „both-as-view"*

Inhalt dieser Vorlesung

- Anfragekorrespondenzen
  - Korrespondenztypen und -arten
  - GaV erklärt
- Local as View
- Query Containment
- Semantische Korrektheit von Anfrageplänen

Global-as-View erklärt

- Eine GaV-Korrespondenz besteht also aus
  - Einer Relation q_1 des globalen Schemas
    - Query q_1 mit Projektion, aber ohne Selektionen oder Joins
  - Einer ausführbaren Anfrage q_2 an ein Quellschema
  - q_2 hat dieselbe Intension wie q_1
- Beispiel
  - $\pi_{\texttt{titel,regisseur}}\texttt{(film)} \supseteq \pi_{\texttt{title,director}}\texttt{(imdb.movie)}$
  - $\pi_{\texttt{titel,rolle,s\_name}}\texttt{(spielt)} \supseteq \pi_{\texttt{title,role,actor\_name}}\texttt{(imdb.acts)}$

GaV Planung

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

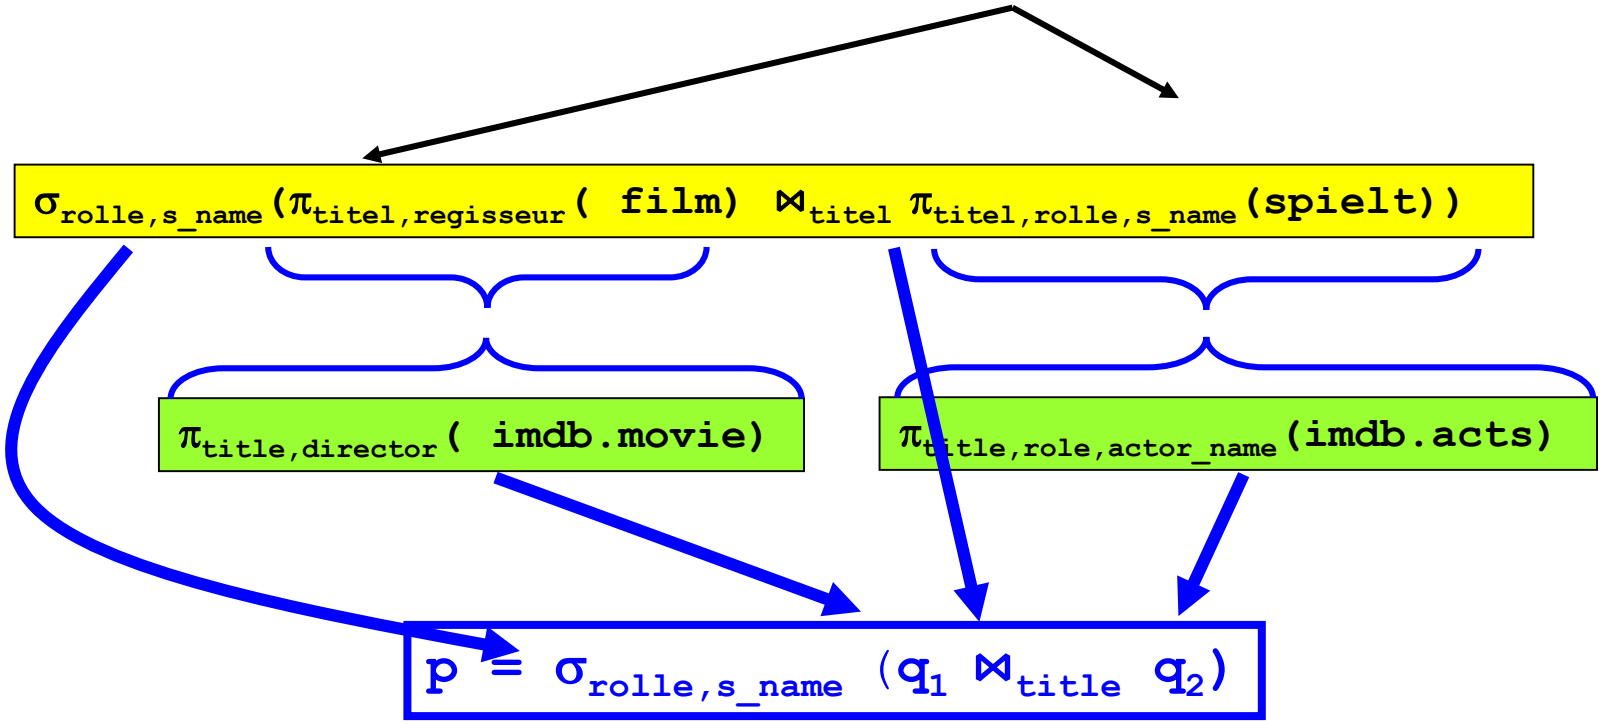

Spezifischere Korrespondenzen

- Man könnte auch andere Regeln spezifizieren
  - q_1: $\pi_{titel,regisseur}(film) \supseteq \pi_{title,director}(imdb.movie)$
  - q_2: $\pi_{titel,rolle,s\_name}(spielt) \supseteq \sigma_{role=„HR“,actor\_name=„HA“}(\pi_{title,role,actor\_name}(imdb.acts))$
- Damit
  - q: $\pi_{titel,regisseur}(film) \bowtie_{titel} \sigma_{rolle,s\_name}(\pi_{titel,rolle,s\_name}(spielt))$
  - q: $q_1 \bowtie q_2$
- Vorteil: Selektionen werden implizit (durch Regeldefinition) gepushed
- Nachteil: Regel ist gut für diese q – für andere Anfragen schlecht
  - Wir brauchen exponentiell mehr Regeln
  - Deklarativer Charakter von Korrespondenzen geht verloren
- Ziel: Generische Korrespondenzen, den Rest macht die Anfrageplanung
  - So wenig Einschränkungen wie möglich vornehmen

Inhalt dieser Vorlesung

- Anfragekorrespondenzen
- Local as View
  - Notation: Datalog
  - Local-as-View Korrespondenzen
- Query Containment
- Semantische Korrektheit von Anfrageplänen

Konjunktive Anfragen

- Wir betrachten im Folgenden nur konjunktive Anfragen
  - Equi-joins und Bedingungen mit =,<,> zwischen Attribut und Wert
  - Kein NOT, EXISTS, GROUP BY, ≠, X>Y, ...
- LaV Planung idR schwieriger für andere Anfrageklassen
  - Gegenstand vieler Forschungsarbeiten

Kürzere Schreibweise

- Schreibweise: Datalog (Prolog)
  - `q(T,R,O) :- film(T,R,J),spielt(T,N,O),N=„Hans Albers“;`
- SELECT Klausel: Regelkopf, „Exported Variables“
  - Auch: „Distinguished variables“ – von außen unterscheidbar
- FROM Klausel: Prädikate stehen für Relationen
  - Attribute werden über Position statt Name adressiert
- WHERE Klausel
  - Joins: dieselbe Variable an mehreren Stellen
  - Bedingungen mit „>“,“<„ werden explizit angegeben
  - Gleichheitsbedingungen „Attribut = Wert“ werden durch Konstante im Literal angegeben oder explizit

SQL – Datalog

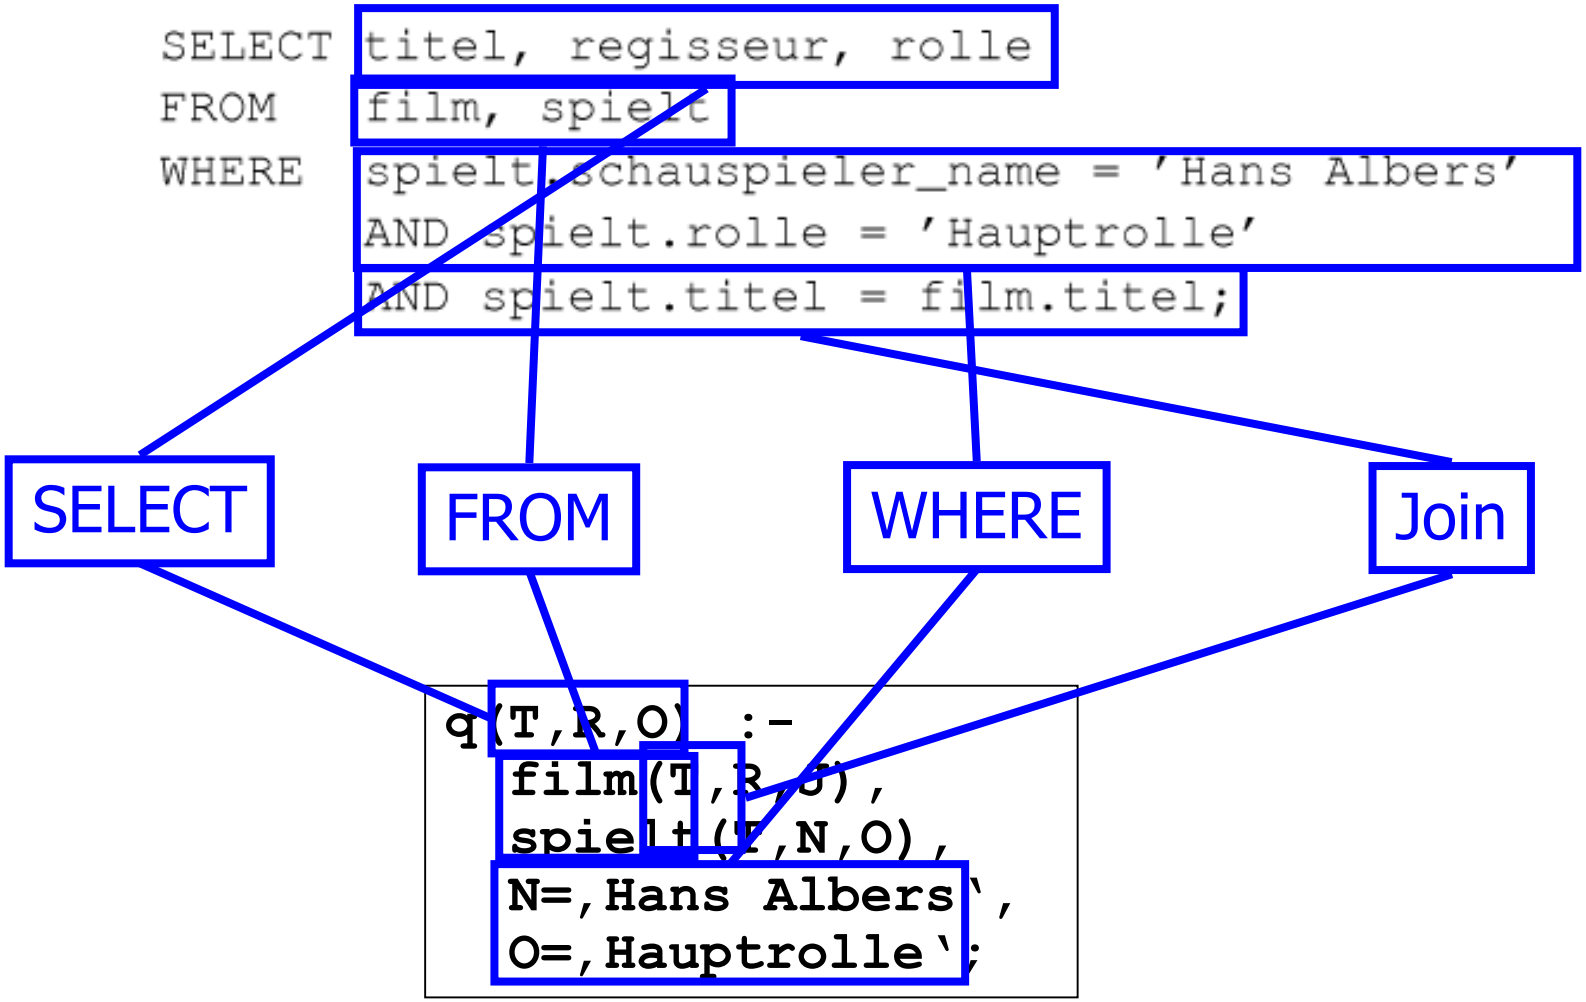
SELECT titel, regisseur, rolle
FROM film, spielt
WHERE spielt.schauspieler_name = 'Hans Albers'
AND spielt.rolle = 'Hauptrolle'
AND spielt.titel = film.titel;
SELECT
FROM
WHERE
Join
q(T,R,O) :-
film(T,R,J),
spielt(T,N,O),
N=,Hans Albers',
O=,Hauptrolle';

Begriffe

Definition 2.2
Sei V eine Menge von Variablensymbolen und C eine Menge von Konstanten. Eine *konjunktive Datalog-Anfrage* q ist eine Anfrage der Form:

$$q(v_1, v_2, \ldots, v_n) \quad :- \quad r_1(w_{1,1}, \ldots, w_{1,n_1}), r_2(w_{2,1}, \ldots w_{2,n_2}), \ldots, r_m(w_{m,1}, \ldots, w_{m,n_m}), k_1, \ldots, k_l;$$

mit extensionalen Prädikaten $r_1, r_2, \ldots r_m$, $v_i \in V$, $w_{i,j} \in V \cup C$ und $\forall v \in V : \exists i, j : w_{i,j} = v$ und $\forall c \in C : \exists i, j : w_{i,j} = c$. Alle k_i haben für beliebige $v_1, v_2 \in V$ und $c \in C$ die Form $v_1 < c$, $v_1 > c$, $v_1 = c$ oder $v_1 = v_2$. Dann ist:

- $head(q) = q(v_1, v_2, \ldots, v_n)$ der Kopf von q,
- $body(q) = r_1(w_{1,1}, \ldots), r_2(w_{2,1}, \ldots), \ldots, r_m(w_{m,1}, \ldots)$ der Rumpf von q,
- $exp(q) = \{v_1, v_2, \ldots, v_n\}$ die Menge der *exportierten Variablen* von q,
- $var(q) = V$ die Menge aller Variablen von q,
- $const(q) = C$ die Menge aller Konstanten von q,
- $sym(q) = C \cup V$ die Menge aller Symbole von q,
- $r_1, r_2, \ldots r_m$ sind die *Literale* von q, und
- $cond(q) = k_1, \ldots k_l$ sind die Bedingungen von q. ■

Beispiel

```
q(T,R,O) :-
  film(T,R,_),
  spielt(T,N,O),
  N=,Hans Albers‘,
  O=,Hauptrolle‘;
```

- `film, spielt, ..` sind Prädikate
  - Relationen des Schemas
- `film( T,R,J), spielt(T,N,O)` sind Literale
  - Eine Anfrage kann mehrere Literale desselben Prädikats enthalten
- Variablen, die nicht interessieren, kürzt man mit „_“ ab
  - Kein Join, keine Bedingung, nicht exportiert
- Definition: *q ist sicher, wenn jede exportierte Variable im Rumpf vorkommt*

Kein echtes Datalog

- Keine Disjunktion und Vereinigung
- Keine Joins außer Equi-Joins
- Keine rekursiven Anfragen
  - Extensional predicates: Prädikate, deren Extension in der Datenbank vorliegen
  - Intensional predicates: Prädikate, die zur Laufzeit berechnet werden
    - SQL: Views
  - Verwendet ein intensionales Prädikat sich selber im Rumpf, wird dadurch eine rekursive Anfrage definiert
    - „Normales" SQL: Verboten
    - Rekursives SQL: Views mit Namen

Inhalt dieser Vorlesung

- Anfragekorrespondenzen
- Local as View
  - Notation: Datalog
  - Local-as-View Korrespondenzen
- Query Containment
- Semantische Korrektheit von Anfrageplänen

Warum Local-as-View?

- Andere Sichtweise
  - Es gibt in der Welt eine Menge von Filmen, Schauspielern, …
  - Das globale Schema modelliert diese Welt
  - Theoretisch steht damit die globale Extension fest
    - Aber niemand kennt sie
    - Informationsintegration versucht sie herzustellen
  - Quellen speichern Ausschnitte der realen Welt
    - Sichten auf die globale Extension
  - Nur die können wir verwenden

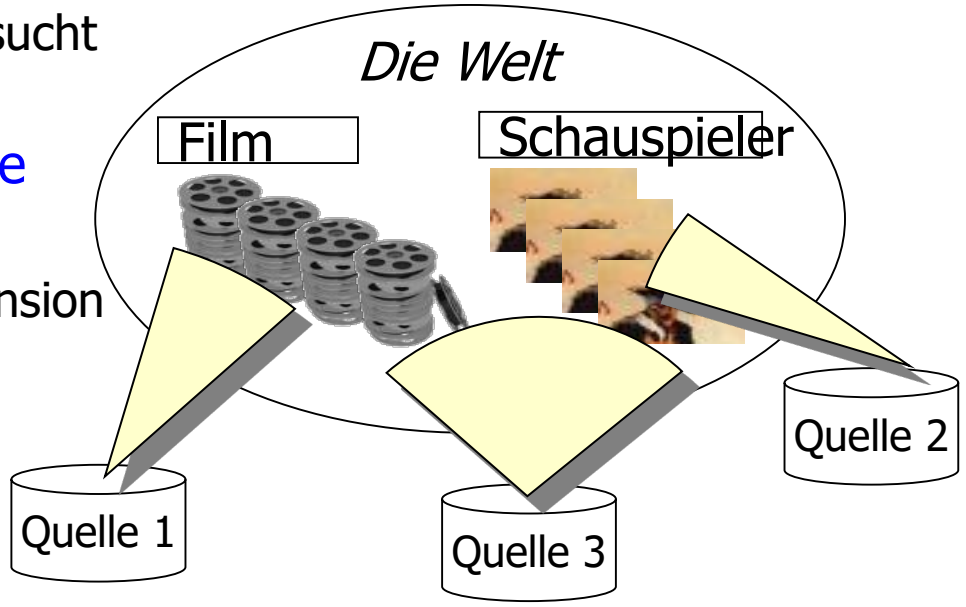

LaV – Beispiel

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

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

```
CREATE VIEW S1 AS
SELECT  *
FROM    Film

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

CREATE VIEW S3 AS
SELECT  F.Titel, F.Regie
FROM    Film F

CREATE VIEW S4 AS
SELECT  F.Titel, F.Jahr,
        F.Genre
FROM    Film F
```

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

Uninteressante lokale Attribute

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

```
CREATE VIEW S9 AS
SELECT  Titel, Jahr
FROM    Film
```

```
S9: ActorDB(Titel, Schauspieler, Jahr)
```

- `schauspieler` gibt es im globalen Schema nicht
- Wird im View projeziert

Assoziationen im globalen Schema

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

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

```
S7: KinoDB(Kino, Genre)
```

- Assoziationen des globalen Schemas können in der Sicht dargestellt werden – auch ohne Werte für das Join-Attribut

Assoziationen im lokalen Schema

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

```
CREATE VIEW S9.Filme AS
SELECT  Titel, Jahr
FROM    Film

CREATE VIEW S9.Regie AS
SELECT  Regie
FROM    Film
```

```
S9: Filme(Titel, Jahr, Ort, RegieID);
    Regie(ID, Regisseur);
```

- Assoziationen des lokalen Schemas können nicht abgebildet werden, wenn Join-Attribute im globalen Schema nicht vorhanden sind oder von der Quelle nicht exportiert werden
  - Das ging aber bei GaV

Lokale Integritätsconstraints

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

```
CREATE VIEW S8 AS
SELECT  Titel, Regie, Genre
FROM    Film
WHERE   Jahr > 2000
```

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

- Integritätsconstraint auf der Quelle kann modelliert werden, wenn das Attribut im globalen Schema existiert
- IC müssen in der Quelle nicht explizit definiert sein
  - Auch implizite Einschränkungen können in den View

Globale Integritätsconstraints

```
Film(Titel, Regie, Jahr, Genre)
Programm(Kino, Titel, Zeit)
Jahr > 2000
```

```
CREATE VIEW S1 AS
SELECT  *
FROM    Film
(WHERE  Jahr> 2000)??
```

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

- ICs auf dem globalen Schema können nicht modelliert werden
  - Das ging aber bei GaV

Komplexere Beispiele

Datenquelle	Beschreibung
`spielfilme(titel, regisseur, laenge)`	Informationen über Spielfilme, die mindestens 80 Minuten Länge haben.
`kurzfilme(titel, regisseur)`	Informationen über Kurzfilme. Kurzfilme sind höchstens 10 Minuten lang.
`filmkritiken(titel, regisseur, schauspieler, kritik)`	Kritiken zu Hauptdarstellern von Filmen
`us_spielfilme(titel, laenge, schauspieler_name)`	Spielfilme mit US-amerikanischen Schauspielern
`spielfilm_kritiken(titel, rolle, kritik)`	Kritiken zu Rollen in Spielfilmen
`kurzfilm_rollen(titel, rolle, schauspieler_name, nationalitaet)`	Rollenbesetzungen in Kurzfilmen

```
film(titel,typ,regisseur,laenge);
schauspieler(schauspieler_name,nationalitaet);
spielt(titel,schauspieler_name,rolle,kritik);
```

```
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='Hauprolle'          ⊇  filmkritiken(T,R,S,K)
film(T,Y,_,L),spielt(T,S,_,_),
schauspieler(S,N), N='US',Y='Spielfilm'              ⊇  us_spielfilm(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)
```

Anfragebearbeitung - Probleme

- Alle Filme kürzer als 100 Minuten
  - **spielfilme** (filtern) ∪ **kurzfilme** (vollständig) ∪ **us_spielfilm** (filtern)
- Alle Filme, die länger als 60 Minuten sind
  - **spielfilme** (vollständig) ∪ **us_spielfilm** (filtern)
- Besetzungen von Hauptrollen in Filmen unter 100 Minuten
  - **spielfilme ⋈ filmkritiken ?**
  - **spielfilme ⋈ spielfilm_kritiken ?**
  - **spielfilme ⋈ us_spielfilm ?**
  - **spielfilme ⋈ kurzfilm rollen ?**

```
                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='Hauprolle'        ⊇  filmkritiken(T,R,S,K)
                film(T,Y,_,L),spielt(T,S,_,_),
   schauspieler(S,N), N='US',Y='Spielfilm'         ⊇  us_spielfilm(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)
```

Anders formuliert

- Globale Anfrage

```
q :-
film(T,_,_,L),spielt(T,S,O,_),O=,Hauptrolle‘,L<100;
```

- Plan 1
  - **spielfilme ⋈ filmkritiken**
  - Expandiert:

```
film(T,Y,R,L), L>79, Y=,Spielfilm‘, film(T‘,_,R‘),
spielt(T‘,S‘,O‘,_), O‘=,Hauptrolle‘, T=T‘
```

- Frage
  - Erzeugt

```
film(T,‘Spielfilm‘,R,L), L>79,
film(T,_,R‘,_), spielt(T,S‘,‘Hauptrolle‘,_);
```

nur richtige Antworten für q?

Anfrageplanung mit LaV

- Gegeben: Globales Schema S, Anfrage q an S, Menge von Sichten $v_1,...,v_n$ auf S
- Gesucht: Alle Kombinationen von v_i, die q beantworten
  - Es ist nicht trivial zu sehen, wie man q so zerlegt, dass jede Teilquery einer LaV-Regel entspricht
  - Planung ist schwieriger als bei GaV
- „Answering queries using views"
  - Anderes Bild: Eine DB und eine Menge materialisierter Sichten
  - Plötzlich: alle Relationen der DB weg, nur die Sichten sind noch da
  - Können wir eine Anfrage q nur mit den Sichten beantworten?

Inhalt dieser Vorlesung

- Anfragekorrespondenzen
- Local as View
- Query Containment
- Semantische Korrektheit von Anfrageplänen

Zwei Teilprobleme

- Problem: Welche Kombinationen von Views (also Quellen) liefern semantisch korrekte Antworten auf eine globale Anfrage
- Dafür zu bestimmen: Wann ist ein gegebener Plan semantisch korrekt?
  - Wir wissen nur, dass bestimmte Teilanfragen gegen das globale Schema intensional bestimmten Quellrelationen entsprechen
  - Wie kann man das auf beliebige Anfragen übertragen?
- Query Containment
  - Zunächst arbeiten wir nur mit einem View
  - Also: Wenn liefert ein View korrekte Ergebnisse für eine Query?

Query Containment

- Intuition: Ein View v liefert nur semantisch korrekte Antworten auf eine globale Anfrage q, wenn die Extension von v in der Extension von q enthalten ist
- Definition
  Sei S ein Datenbankschema, I eine Instanz von S und q_1, q_2 Anfragen gegen S. Sei q(I) das Ergebnis einer Anfrage q angewandt auf I. Dann ist

  q_1 enthalten in q_2, geschrieben $q_1 \subseteq q_2$

  gdw.

  $$q_1(I) \subseteq q_2(I) \text{ für alle } I$$

Äquivalenz

- Definition
  Sei S ein Datenbankschema, I eine Instanz von S und q_1, q_2 Anfragen gegen S. Sei q(I) das Ergebnis einer Anfrage q angewandt auf I. Dann ist

  q_1 äquivalent zu q_2, geschrieben $q_1 \equiv q_2$

  gdw.

  $q_1(I) \subseteq q_2(I)$ *und* $q_1(I) \supseteq q_2(I)$ *für alle I*

- Bemerkung
  - Wir beschäftigen uns nur mit enthaltenen Anfragen

Einfache Beispiele (Alle Variable seien exportiert)

$$\texttt{film(T,Y,R,L)} \subseteq \texttt{film(T,Y,R,L)}$$

$$\texttt{film(T,'Dokumentarfilm',R,L)} \subseteq \texttt{film(T,Y,R,L)}$$

$$\texttt{film(T,Y,R,L), L<100} \subseteq \texttt{film(T,Y,R,L)}$$

$$\texttt{film(T,Y,R,L),spielt(T,S,O)} \subseteq \texttt{film(T,Y,R,L)}$$

$$\texttt{film(T,Y,R,L)} \not\subseteq \texttt{spielt(T,S,O)}$$

$$\texttt{film(T,\_,\_,\_)} \not\subseteq \texttt{spielt(T,\_,\_)}$$

$$\texttt{spielt(T,\_,\_,\_)} \not\subseteq \texttt{film(T,\_,\_)}$$

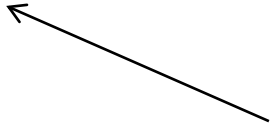

Bei bekannten FK-PK Constraints kann hier Containment gelten

Beispiel

- Offensichtlich muss eine Sicht mindestens jedes Prädikat der Anfrage enthalten
- Außerdem müssen die „richtigen" Attribute vorhanden sein
- Welche Quellen kommen für **`spielt`** in Frage?

```
SELECT titel, typ, rolle, kritik
FROM   film, spielt
WHERE  film.titel = spielt.titel;
```

```
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='Hauprolle'  ⊇  filmkritiken(T,R,S,K)
film(T,Y,_,L),spielt(T,S,_,_),
schauspieler(S,N), N='US',Y='Spielfilm'  ⊇  us_spielfilm(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)
```

Beispiel

- **`filmkritiken`**
  - Korrekt; Einschränkung auf Hauptrolle macht Tupel nicht falsch
- **`us_spielfilm, kurzfilm_rollen`**
  - Inkorrekt: Keine Kritiken
- **`spielfilm_kritiken`**
  - Korrekt

```
SELECT titel, typ, rolle, kritik
FROM   film, spielt
WHERE  film.titel = spielt.titel;
```

$$
\begin{aligned}
\text{film}(T,Y,R,L), L>79, Y=\text{'Spielfilm'} &\supseteq \text{spielfilme}(T,R,L)\\
\text{film}(T,Y,R,L), L<11, Y=\text{'Kurzfilm'} &\supseteq \text{kurzfilme}(T,R)\\
\text{film}(T,\_,R,\_), \text{spielt}(T,S,O,K), O=\text{'Hauprolle'} &\supseteq \text{filmkritiken}(T,R,S,K)\\
\text{film}(T,Y,\_,\_), \text{spielt}(T,S,\_,\_), & \\
\text{schauspieler}(S,N), N=\text{'US'}, Y=\text{'Spielfilm'} &\supseteq \text{us\_spielfilm}(T,L,S)\\
\text{film}(T,Y,\_,\_), \text{spielt}(T,\_,O,K), Y=\text{'Spielfilm'} &\supseteq \text{spielfilm\_kritiken}(T,O,K)\\
\text{film}(T,Y,\_,\_), \text{spielt}(T,S,O,\_), & \\
\text{schauspieler}(S,N), Y=\text{'Kurzfilm'} &\supseteq \text{kurzfilm\_rollen}(T,O,S,N)
\end{aligned}
$$

Immer so einfach?

- Anfragen an Graphen
  - Relation `edge(X,Y)` speichert Kanten von X nach Y
  - Wir suchen Subgraphen

```
q(C,B)  :-  edge(A,B),edge(C,A),edge(B,C),edge(A,D)
p(X,Z)  :-  edge(X,Y),edge(Y,Z)
```

- Ist p in q enthalten oder umgedreht?

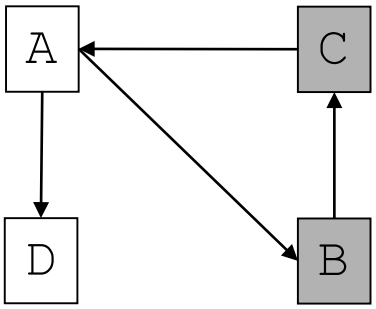

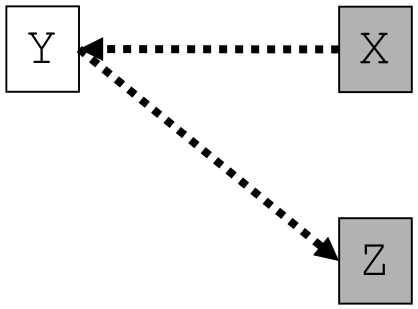

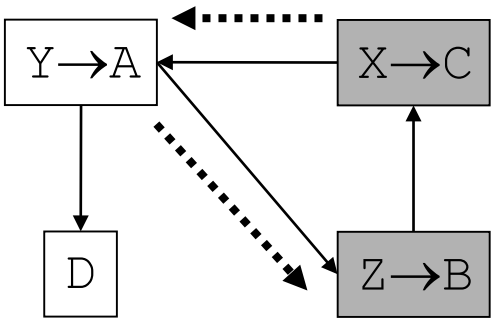

Inhalt dieser Vorlesung

- Anfragekorrespondenzen
- Local as View
- Query Containment
- Semantische Korrektheit von Anfrageplänen

Semantische Korrektheit

- Wir können jetzt definieren, wann ein Plan semantisch korrekt ist (aber das noch nicht testen)
- Definition
  Sei S ein globales Schema, q eine Anfrage gegen S, und p ein Join von Views $v_1,\ldots,v_n$ gegen S, die als rechte Seite von LaV Korrespondenzen definiert sind. Dann ist

  p semantisch korrekt für q

  gdw.

  $$p \subseteq q$$
- Bemerkung
  - Die Extension von q gibt es zum Anfragezeitpunkt nicht
  - Erinnerung: Das komplette Ergebnis verlangt Beachtung aller semantisch korrekter Pläne

Verblüffende Effekte

- Eine Quelle für Graphkanten
- Eine Korrespondenz
  - **edge(A,B),edge(B,C) ⊇ threewaypaths(A,B,C)**
- Nehmen wir die folgende Extension einer Quelle an

From (A)	Via (B)	To (C)
1	3	3
2	3	4

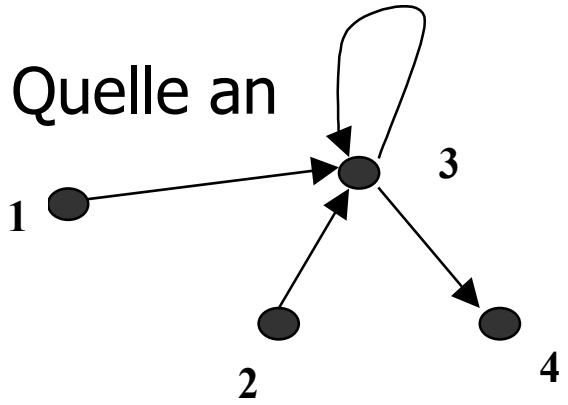

- Nun führen wir darauf aus
  q: **edge(A,B),edge(B,C)**

from	via	to
1	3	3
1	3	4
3	3	3
3	3	4
2	3	3
2	3	4

Verblüffende Effekte

- Was ist nun unser Ergebnis? Die komplette Tabelle
- Wenn die Korrespondenz richtig ist
  - Dann muss die Quelle unvollständig sein
  - Wir können das im Mediator „reparieren“
- Wie kriegen wir das rechnerisch?
  - Sei v die linke Seite der Korrespondenz, q die globale Query
  - Dann ist v „auf verschiedene Weisen“ in q enthalten
  - Die werden wir auch alle berechnen
- Ergibt sich aus unserer Semantik der Anfrage