

## Datenbanktheorie

- 1 Enthaltensein-Problem konjunktiver Anfragen
- 2 Minimierung und Chase
- 3 Auswertung von Verbundausdrücken

Literatur: Abiteboul, S., R. Hull und V. Vianu, *Foundations of Databases*, Addison-Wesley 1995.

## Enthaltensein-Problem

Formale Basis einer Anfrageminimierung.

### Formalisierung: Konjunktive Anfragen

Eine *konjunktive Anfrage*  $Q$  zu einem Datenbank-Schema  $\mathcal{R}$  hat die Form

$$\text{ans}(\vec{U}) \leftarrow R_1(\vec{U}_1), \dots, R_n(\vec{U}_n),$$

wobei für  $1 \leq i \leq n$

- die  $R_i$  Relationsbezeichner aus  $\mathcal{R}$  und
- $\vec{U}$  und die  $\vec{U}_i$  Vektoren von Variablen und Konstanten sind;
- die Variablen in  $\vec{U}$  treten unter den Variablen in den  $\vec{U}_i$  auf.
- Der Teil links vom  $\leftarrow$  heißt *Kopf* der Anfrage, und der Teil rechts ihr *Rumpf*.

## Motivation: Anfrageoptimierung

### Beispiel

Sei

$$\begin{aligned} & \text{Sales}(PName, SName, CName), \\ & \text{Part}(PName, Type), \\ & \text{Cust}(CName, CAddr), \\ & \text{Supp}(SName, SAddr). \end{aligned}$$

Sind die folgenden zwei Anfragen  $Q, Q'$  äquivalent?

$Q$ : <pre>SELECT Type FROM Sales NATURAL JOIN      Part NATURAL JOIN      Cust NATURAL JOIN Supp WHERE CAddr = SAddr</pre>	$Q'$ : <pre>SELECT Type FROM Sales S1 NATURAL JOIN      Part P1 NATURAL JOIN      Cust NATURAL JOIN Supp,      Sales S2, Part P2 WHERE CAddr = SAddr AND      S2.PName = P2.PName AND      P1.Type = P2.Type</pre>
---	--

Falls ja, dann ist  $Q$  der Version  $Q'$  offensichtlich vorzuziehen.

$\Rightarrow$  Ziel ist eine *Minimierung* von Anfragen.

### Beispiel

Sei

$$\begin{aligned} & \text{Sales}(PName, SName, CName), \\ & \text{Part}(PName, Type), \\ & \text{Cust}(CName, CAddr), \\ & \text{Supp}(SName, SAddr). \end{aligned}$$

$$Q : \quad \text{ans}(T) \leftarrow \text{Sales}(P, S, C), \text{Part}(P, T), \text{Cust}(C, A), \text{Supp}(S, A)$$

## Antwortmenge

- Die Antwortmenge  $ans$  zu  $Q$  ergibt sich durch folgende Kalkül-Anfrage:

$$\{\vec{U} \mid \exists X_1, \dots, X_k (R_1(\vec{U}_1) \wedge \dots \wedge R_n(\vec{U}_n))\},$$

wobei die  $X_1, \dots, X_k$  alle Variablen im Rumpf der Anfrage  $Q$  sind, die nicht im Kopf auftreten.

- Die Menge der Antworten zu  $Q$  bzgl. einer Instanz  $\mathcal{I}$  ist  $Q(\mathcal{I})$ .
- Für  $\vec{U} \in Q(\mathcal{I})$  schreiben wir auch  $ans(\vec{U}) \in Q(\mathcal{I})$ .



## Beispiel

Sei

$$\begin{aligned} &Sales(PName, SName, CName), \\ &Part(PName, Type), \\ &Cust(CName, CAddr), \\ &Supp(SName, SAddr). \end{aligned}$$

Die folgenden zwei Anfragen  $Q, Q'$  sind äquivalent:

$$Q : \quad ans(T) \leftarrow Sales(P, S, C), Part(P, T), Cust(C, A), Supp(S, A)$$

$$Q' : \quad ans(T) \leftarrow Sales(P, S, C), Part(P, T), Cust(C, A), Supp(S, A), \\ Sales(P', S', C'), Part(P', T)$$


## Probleme

Seien  $Q, Q_1, Q_2$  konjunktive Anfragen.

**Enthaltensein:** Gilt  $Q_1 \sqsubseteq Q_2$ , d.h., gilt  $Q_1(\mathcal{I}) \subseteq Q_2(\mathcal{I})$  für jede Instanz  $\mathcal{I}$ ?

**Äquivalenz:** Gilt  $Q_1 \equiv Q_2$ , d.h., gilt  $Q_1 \sqsubseteq Q_2$  und  $Q_2 \sqsubseteq Q_1$ ?

**Minimierung:** Finde zu  $Q_1$  eine äquivalente konjunktive Anfrage  $Q_2$ , die höchstens so viele Literale im Rumpf hat wie  $Q_1$  und die minimal ist in dem Sinn, dass jede zu  $Q_2$  äquivalente konjunktive Anfrage  $Q_3$  mindestens so viele Literale im Rumpf hat wie  $Q_2$ .

$Q_2$  heißt *minimal*.



## Lemma

Seien

$$\begin{aligned} Q_1 : \quad &ans(\vec{U}) \leftarrow R_1(\vec{U}_1), \dots, R_n(\vec{U}_n) \\ Q_2 : \quad &ans(\vec{U}) \leftarrow S_1(\vec{V}_1), \dots, S_m(\vec{V}_m) \end{aligned}$$

konjunktive Anfragen, wobei

$$\{R_1(\vec{U}_1), \dots, R_n(\vec{U}_n)\} \supseteq \{S_1(\vec{V}_1), \dots, S_m(\vec{V}_m)\}$$

Dann  $Q_1 \sqsubseteq Q_2$ .



## Substitution

- Eine *Substitution*  $\theta$  über einer Variablenmenge  $\mathcal{V}$  ist eine Abbildung von  $\mathcal{V}$  nach  $\mathcal{V} \cup \text{dom}$ , wobei  $\text{dom}$  ein relevanter Wertebereich.
- Der Definitionsbereich einer Substitution  $\theta$  ist erweitert auf die Konstanten  $a \in \text{dom}$  und Relationsbezeichner  $R \in \mathcal{R}$ , wobei  $\theta(a) = a$ , bzw.  $\theta(R) = R$ .
- Substitutionen verallgemeinern Variablenbelegungen.



## Beispiel

Betrachte

$$Q : \text{ans}(T) \leftarrow \text{Sales}(P, S, C), \text{Part}(P, T), \text{Cust}(C, A), \text{Supp}(S, A)$$

$$Q' : \text{ans}(T) \leftarrow \text{Sales}(P, S, C), \text{Part}(P, T), \text{Cust}(C, A), \text{Supp}(S, A), \\ \text{Sales}(P', S', C'), \text{Part}(P', T)$$

und  $\theta$  wie folgt:

$X$	$P$	$P'$	$S$	$S'$	$C$	$C'$	$T$	$A$
$\theta(X)$	$P$	$P$	$S$	$S$	$C$	$C$	$T$	$A$



## Enthaltensein-Abbildung

Seien

$$Q_1 : \text{ans}(\vec{U}) \leftarrow R_1(\vec{U}_1), \dots, R_n(\vec{U}_n)$$

$$Q_2 : \text{ans}(\vec{V}) \leftarrow S_1(\vec{V}_1), \dots, S_m(\vec{V}_m)$$

konjunktive Anfragen.

Eine Substitution  $\theta$  ist eine *Enthaltensein-Abbildung* (engl. *containment mapping*) von  $Q_2$  in  $Q_1$  genau dann, wenn  $Q_2$  mittels  $\theta$  in eine Teilmenge von  $Q_1$  umgewandelt wird:

- $\theta(\text{ans}(\vec{V})) = \text{ans}(\vec{U})$ ,
- für jedes  $i = 1, \dots, m$  existiert ein  $j \in \{1, \dots, n\}$ , so dass  $\theta(S_i(\vec{V}_i)) = R_j(\vec{U}_j)$ .

Beachte dass somit  $S_i = R_j$ ! Beachte weiter, dass Relationsbezeichner in  $Q_1$  und  $Q_2$  jeweils mehrfach auftreten können.



## Beispiel

Betrachte noch einmal

$$Q : \text{ans}(T) \leftarrow \text{Sales}(P, S, C), \text{Part}(P, T), \text{Cust}(C, A), \text{Supp}(S, A)$$

$$Q' : \text{ans}(T) \leftarrow \text{Sales}(P, S, C), \text{Part}(P, T), \text{Cust}(C, A), \text{Supp}(S, A), \\ \text{Sales}(P', S', C'), \text{Part}(P', T)$$

und  $\theta$  wie folgt:

$X$	$P$	$P'$	$S$	$S'$	$C$	$C'$	$T$	$A$
$\theta(X)$	$P$	$P$	$S$	$S$	$C$	$C$	$T$	$A$

$\theta$  ist eine Enthaltensein-Abbildung.



**Satz**

Seien

$$Q_1 : \quad \text{ans}(\vec{U}) \leftarrow R_1(\vec{U}_1), \dots, R_n(\vec{U}_n)$$

$$Q_2 : \quad \text{ans}(\vec{V}) \leftarrow S_1(\vec{V}_1), \dots, S_m(\vec{V}_m)$$

konjunktive Anfragen.

$Q_1 \sqsubseteq Q_2$  genau dann, wenn eine Enthaltensein-Abbildung  $\theta$  von  $Q_2$  nach  $Q_1$  existiert.

$$Q_1 : \quad \text{ans}(\vec{U}) \leftarrow R_1(\vec{U}_1), \dots, R_n(\vec{U}_n)$$

$$Q_2 : \quad \text{ans}(\vec{V}) \leftarrow S_1(\vec{V}_1), \dots, S_m(\vec{V}_m)$$

**Beweis " $\Leftarrow$ ":**

Es existiert eine Enthaltensein-Abbildung  $\theta$  von  $Q_2$  nach  $Q_1$ .

Sei  $\mathcal{I}$  eine Instanz zu  $Q_1$  und sei  $\mu \in Q_1(\mathcal{I})$ .

Es existiert dann eine Substitution  $\tau$ , so dass  $\tau(\vec{U}_j) \in \mathcal{I}(R_j)$ ,  $j \in \{1, \dots, n\}$  und  $\mu = \tau(\vec{U})$ .

Betrachte dann die Substitution  $\tau' = \theta \circ \tau$  und weiter  $\tau'(S_i(\vec{V}_i))$ .

Es gilt dann  $\tau'(\vec{V}_i) \in \mathcal{I}(S_i)$ ,  $i \in \{1, \dots, m\}$  und damit auch  $\mu = \tau'(\vec{V})$ .

D.h.,  $\mu \in Q_2(\mathcal{I})$ .