

Datenbanken
Wintersemester 06/07
 Prof. Dr. W. May

2. Übungsblatt: Algebra

Besprechung am 22.11./29.11.

Aufgabe 1 (Division mit Basisoperationen) Beweisen Sie, daß die in der Vorlesung angegebene Darstellung der Division durch relationale Basisoperatoren als

$$r \div s = \pi[Z](r) - \pi[Z](\underbrace{(\pi[Z](r) \bowtie s) - r}_{(***)})$$

(mit $r(X)$, $s(Y)$ und $Z = X \setminus Y$ äquivalent zu der gegebenen Definition

$$r \div s = \{\mu \in \text{Tup}(Z) \mid \{\mu\} \bowtie s \subseteq r\}$$

ist.

Betrachte

$$r \div s = \pi[Z](r) - \underbrace{\pi[Z](\underbrace{(\pi[Z](r) \bowtie s) - r}_{(***)})}_{(*)} \quad (*)$$

Nach Definition der Division ist

$$r \div s = \{\mu \in \text{Tup}(Z) \mid \{\mu\} \bowtie s \subseteq r\} \quad (**)$$

(1) $(**) \subseteq (*)$:

Sei $\mu \in (**)$, also $\{\mu\} \bowtie s \subseteq r$. Für alle $\nu \in s$ ist also $\mu\nu \in r$.

Damit also erstmal $\mu \in \pi[Z](r)$.

Zu zeigen: $\mu \notin (***)$.

Annahme: $\mu \in (***)$ – also gäbe es ein ν' , so dass $\mu\nu' \in (\pi[Z](r) \bowtie s) - r$ ist. Der Anteil $\pi[Z](\mu\nu')$ ist gerade μ , also müsste $\nu' \in s$ sein, damit dies erfüllt ist, und $\mu\nu' \notin r$ – im Widerspruch zu oben.

Also $\mu \in (*)$.

(2) $(*) \subseteq (**)$:

Sei $\mu \in (*)$.

Annahme: $\mu \notin (**)$, d.h. $\{\mu\} \bowtie s \not\subseteq r$.

Dann gibt es also ein $\nu \in s$, so dass $\mu\nu \notin r$.

$\mu \in \pi[Z](r)$ nach Konstruktion von $(*)$

Schauen wir uns wieder $(***)$ an: Da $\mu \in \pi[Z](r)$ ist, ist $\mu\nu \in \pi[Z](r) \bowtie s$ und ja $\notin r$, also $\mu\nu \in (\pi[Z](r) \bowtie s) - r$ und damit $\mu = \pi[Z](\text{diesem}) = (***)$.

Womit μ nicht in $(*)$ ist. Widerspruch zur Voraussetzung.

Aufgabe 2 (Algebra: Minimale- und Maximale Anzahl von Tupeln) Die Relationen $R(\bar{X})$ und $S(\bar{Y})$ enthalten n bzw. m Tupel. Wie groß ist die maximale und minimale Anzahl von Tupeln, die das Ergebnis folgender Operationen (bei geeigneten \bar{X}, \bar{Y}) enthalten kann?

- a) $R \cup S$
 b) $R \bowtie S$
 c) $\sigma[C](R) \times S$, für eine Bedingung C
 d) $\pi[Y](R) - S$
 e) $R \div S$

- a) max: $n + m$ (keine gemeinsamen Tupel)
 min: $\max\{n, m\}$ (Teilmengenbeziehung)
- b) max: $n * m$, wenn entweder $\bar{X} \cap \bar{Y} = \emptyset$ oder im natürlichen Join jede Spalte aus X mit jeder Spalte aus Y zusammenpasst.
 min: 0 (natürliches Join mit $\bar{X} \cap \bar{Y} \supsetneq \emptyset$, bei dem aber nichts übrigbleibt, da die Einträge der gemeinsamen Spalte(n) nicht zusammenpassen.
 Hinweis: man sieht, dass ein Join also die Ergebnismenge sowohl deutlich vergrößern, als auch einschränkend wirken kann.
- Verhältnis zwischen $|R \bowtie S|$ und $|R|$ bezeichnet man als *Selektivität* des Joins (bzgl. R).
 - ist $\bar{X} \cap \bar{Y}$ z.B. Schlüssel von S und damit Fremdschlüssel in R , so hat man $|R \bowtie S| = |R|$.
- c) max: $n * m$ (alle Tupel in R erfüllen C)
 min: 0 (kein Tupel in R erfüllt C)
- d) max: n ($S = \emptyset$, oder zumindest $S \cap \pi[Y](R) = \emptyset$)
 min: 0 ($\pi(Y)(R) \subseteq S$)
- e) max: n/m wenn alle Werte $\pi[\bar{X} \setminus \bar{Y}]R$ mit jedem der Werte aus S R vorkommen.
 min: 0 ... wenn eben kein Wert die durch die Division bzgl. S gestellte "für alle"-Bedingung erfüllt.

Aufgabe 3 (Äquivalenz von Ausdrücken) Gegeben seien folgende Relationen:

- $R(A,B,C)$
- $S(A,E,F)$
- $T(A,H)$

Die Wertebereiche aller nicht namensgleichen Attribute seien voneinander verschieden. Gegeben sei nun folgender relationaler Ausdruck:

$$\pi[E, H](\sigma[B = 10]((R \bowtie T) \bowtie S))$$

Sind die folgenden Ausdrücke äquivalent zu obigem Ausdruck? Begründen Sie Ihre Antwort.

- a) $\pi[E, H](\sigma[B = 10](R) \bowtie (\pi[A, E](S) \bowtie T))$
 b) $\pi[E, H](\sigma[B = 10](((\pi[B](R) \bowtie (\pi[A, E](S))) \bowtie (\pi[A, H](T))))$
 c) $\pi[E, H](\sigma[B = 10](R) \bowtie (\pi[A](S) \bowtie T))$

a) ist äquivalent:

Der ursprüngliche Ausdruck:

$$\pi[E, H](\sigma[B = 10]((R \bowtie T) \bowtie S))$$

Join ist assoziativ:

$$\pi[E, H](\sigma[B = 10](R \bowtie (T \bowtie S)))$$

Attribut B existiert nur in Relation R , daher kann Selektion vor Join ausgeführt werden:

$$\pi[E, H](\sigma[B = 10]R \bowtie (T \bowtie S))$$

Von S werden nur die Attribute A (im Join mit T) und E (in der abschließenden Projektion) benötigt, man kann die Projektion also auch gleich auf S ausführen:

$$\pi[E, H](\sigma[B = 10]R \bowtie (T \bowtie (\pi[A, E]S)))$$

Join ist auch kommutativ:

$$\pi[E, H](\sigma[B = 10]R \bowtie ((\pi[A, E]S) \bowtie T))$$

Der letzte Ausdruck zeigt dass die Äquivalenz gilt.

Hinweis: in diesem Ausdruck werden alle π und σ so früh wie möglich ausgeführt.

b) nicht äquivalent: $\pi[B](R)$ eliminiert das für den Join mit S und T wichtige Attribut A , hier wird stattdessen das Kreuzprodukt ausgeführt.

$\pi[A, E](S)$ ist wie in a) gezeigt zulässig. $\pi[A, H](T)$ ist nutzlos (Identität), stört aber keinen.

c) nicht äquivalent: $\pi[A](S)$ eliminiert das Attribut E , was in der Ausgabe enthalten sein soll.

Aufgabe 4 (Äquivalenzen: Join, Schnitt) Seien $R(X), S(Y), T(Z)$ Relations-Schemata. Zeigen Sie die folgenden Äquivalenzen:

a) $R \bowtie R \equiv R$.

b) wenn $X = Y$, dann gilt $R \bowtie S \equiv R \cap S$.

c) $(R \bowtie S) \bowtie T = S \bowtie (R \bowtie T)$.

Use the definition of the natural join:

$$R \bowtie S = \{\mu \in \text{Dup}(XY) \mid \mu[X] \in R \wedge \mu[Y] \in S\}$$

(a)

$$\begin{aligned} R \bowtie R &= \{\mu \in \text{Dup}(X, X) \mid \mu[X] \in R \wedge \mu[X] \in R\} \\ &= \{\mu \in \text{Dup}(X) \mid \mu[X] \in R\} \\ &= \{\mu \in \text{Dup}(X) \mid \mu \in R\} \\ &= R \end{aligned}$$

(b) Es gelte $X = Y$.

$$\begin{aligned} R \bowtie S &= \{\mu \in \text{Dup}(X, Y) \mid \mu[X] \in R \wedge \mu[Y] \in S\} \\ &= \{\mu \in \text{Dup}(X) \mid \mu \in R \wedge \mu \in S\} \quad (X = Y) \\ &= R \cap S \end{aligned}$$

(c)

$$\begin{aligned} (R \bowtie S) \bowtie T &= \{\mu \in \text{Dup}(XY) \mid \mu[X] \in R \wedge \mu[Y] \in S\} \bowtie T = \\ &= \{\mu \in \text{Dup}(XYZ) \mid \mu[XY] \in \{\mu[X] \in R \wedge \mu[Y] \in S\} \wedge \mu[Z] \in T\} = \\ &= \{\mu \in \text{Dup}(XYZ) \mid \mu[XY] \in \{\nu \mid \nu[X] \in R \wedge \nu[Y] \in S\} \wedge \mu[Z] \in T\} = \\ &= \{\mu \in \text{Dup}(XYZ) \mid (\mu[XY])[X] \in R \wedge (\mu[XY])[Y] \in S \wedge \mu[Z] \in T\} = \\ &= \{\mu \in \text{Dup}(XYZ) \mid \mu[X] \in R \wedge \mu[Y] \in S \wedge \mu[Z] \in T\} \end{aligned}$$

Analogously, show that

$$S \bowtie (R \bowtie T) = \{\mu \in Tup(YXZ) \mid \mu[Y] \in S \wedge \mu[X] \in R \wedge \mu[Z] \in T\}$$

which is the same by commutativity of \wedge .

Aufgabe 5 (Relationale Anfragen an Mondial) Geben Sie Ausdrücke der relationalen Algebra für die folgenden Anfragen an die Mondial-Datenbank an:

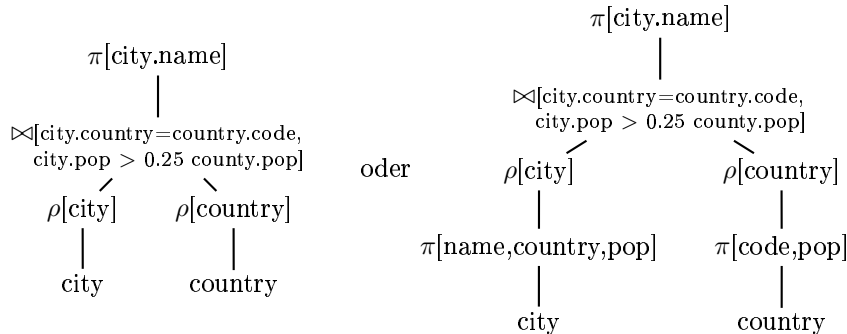
- Die Namen aller Städte, in denen mehr als 25% der Bevölkerung des jeweiligen Landes leben.
- Die Namen aller Organisationen, die auf jedem Kontinent mindestens ein Mitgliedsland haben.
- Alle Landescodes von Ländern, in denen eine Sprache gesprochen wird, die auch in der Schweiz gesprochen wird.
- Alle Landescodes von Ländern, in denen ausschliesslich Sprachen gesprochen werden, die in der Schweiz nicht gesprochen werden.
- Alle Landescodes von Ländern, in denen nur Sprachen gesprochen werden, die auch in der Schweiz gesprochen werden.
- Alle Landescodes von Ländern, in denen alle Sprachen gesprochen werden, die in der Schweiz gesprochen werden.

Für spätere Übungsblätter:


- Geben Sie dieselben Anfragen in SQL an.
- Geben Sie dieselben Anfragen im relationalen Kalkül an.

Sei allgemein $\rho[alias]$ die Umbenennung, die alle Attribute mit dem Präfix X qualifiziert.

a) Join mit Zusatzbedingung:




b) Division:



$is_member(org, country, type)$ und $encompasses(country, continent, percent)$ werden über $country$ gejoint. Davon wird nur $(organisation, continent)$ (*) benötigt. Das wird dann durch die Menge der Namen der Kontinente geteilt, womit alle Organisationen übrig bleiben, die in (*) mit jedem Kontinent genannt werden.

c) Join zur Formulierung einer "Auswahlbedingung". Verwende Tabelle $language(country, name, percent)$, z.B. (CH, "german", 65).




Der linke Ast ergibt die Tabelle


| language |
|----------|
| name |
| german |
| french |
| italian |
| romansch |

Diese wird mit language gejoint (Join-Attribut "name"), womit genau die Einträge aus language übrigbleiben, die eine der aufgeführten Sprachen enthalten.


d) Genau alle Länder, die eben nicht aufgezählt wurden:



e) Löst man in mehreren Schritten. Erst alle Sprachen bestimmen, die nicht in CH gesprochen werden. Das Ergebnis wird mit language gejoint, und übrig bleiben die Einträge, die nicht-schweizer Sprachen beschreiben. Die Länder (bzw. Landescodes), in denen irgendeine nicht-schweizer Sprache gesprochen wird, bekommt man also folgendermassen:




Bleibt nun, die Komplementmenge, eben die Länder in denen nur schweizer Sprachen gesprochen werden, zu bestimmen:



... schönes Beispiel dafür, wie man Subqueries in der WHERE-Klausel in der Algebra durch Joins realisiert.

f) "alle" – also mal wieder Division. $\pi[\text{country}, \text{name}](\text{language})$ durch die Menge der schweizer Sprachen dividieren. Übrig bleiben die Länder die mit allen diesen Sprachen genannt werden:



Aufgabe 6 (Transitive Hülle) Gegeben sei eine Relation $R(A,B)$. Skizzieren Sie einen Algorithmus, der, bestehend aus Operationen der relationalen Algebra und einer while-Schleife, die transitive Hülle der Relation R berechnet.

Hinweis: Die transitive Hülle einer Relation R , bezeichnet als R^* ergibt sich wie folgt: betrachte z.B. eine Relation $R(\text{von}, \text{nach})$ von Flugverbindungen. R^2 ist dann die Menge aller Verbindungen, die über eine Zwischenlandung zustandekommen, etc; R^n sind also diejenigen, Verbindungen, die sich aus n Teilverbindungen zusammensetzen. Die unendliche Vereinigung $R \cup R^2 \cup R^3 \cup \dots$ für $R \rightarrow \infty$ wird dann als R^* bezeichnet. In einer endlichen Datenbasis benötigt man nur endlich viele Schritte um diese zu berechnen. Ein anderes beliebtes Beispiel ist die aus $\text{Kind}(x,y)$ berechnete Vorfahren-Relation.

Problem der Algebra und SQL: jedes R^n kann ausgedrückt werden - aber die beliebig große Vereinigung nicht. Man weiß nicht, wo man abbrechen soll.

Über $R(A,B)$ soll die transitive Hülle gebildet werden. T und S sind binäre Relationen über A und B .

```

S := ∅
T := R
while T - S ≠ ∅ do
  begin
    S := T;
    T := T ∪ π[T.A, R.B](σ[T.B = R.A](T × R));
  end.

```

In diesem Programm enthält S jeweils den Wert von T aus der letzten Iteration der Schleife. Die Berechnung endet, wenn S und T übereinstimmen, d.h. während der zuletzt ausgeführten Iteration wurden keine weiteren Tupel mehr zu T hinzugefügt.