

## 2.5 Relationale Algebra

### 2.5.1 Überblick

#### Codd-vollständige relationale Sprachen

- Relationale Algebra
  - Abfragen werden durch exakte Angabe der auf den Relationen durchzuführenden Operationen formuliert
- Relationenkalküle
  - Abfrageergebnis wird durch seine Eigenschaften beschrieben ohne Angabe einer Berechnungsprozedur

Codd hat gezeigt, dass Relationale Algebra, Tupelkalkül und Domänenkalkül gleich ausdrucksstark sind

"Leistungsmaßstab" ist Relationale Algebra:  
mindestens so mächtige Sprache ist *Codd-vollständig*

1

## 2.5.1 Überblick RA (3)

### Bedeutung der Relationalen Algebra

- Formale Sprache für den Berechnungsweg von Abfrageergebnissen
- mathematische Rechenregeln ermöglichen
  - Abfrageoptimierung durch algebraische Umformung
- auch geeignet zur Formulierung von
  - Integrity Constraints

3

## 2.5.1 Überblick RA (2)

### Wie verhält sich SQL dazu?

#### Beispiel Algebra-Elemente:

```
SELECT nr, name FROM produkt
WHERE hnr IN (SELECT nr FROM hersteller);
```

#### Beispiel Kalkül-Element:

```
SELECT nr, name FROM produkt
WHERE EXISTS (SELECT ' ' FROM hersteller
WHERE hersteller.nr=produkt.hnr);
```

- SQL basiert hauptsächlich auf Relationaler Algebra, enthält aber einzelne Elemente des Relationalen Kalküls.
- SQL ist nicht nur Codd-vollständig, sondern *mächtiger* als die Relationale Algebra
- SQL kann zwar optional Relationen (Mengen) erzeugen (*distinct*), arbeitet aber ansonsten mit Bags (ungeordneten Listen)

2

## 2.5.1 Überblick RA (4)

### Was ist eine Algebra?

- besteht aus atomaren *Operanden* und *Operatoren*
- Regelwerk um daraus *Ausdrücke* zu bilden; dabei
  - im allgemeinen Gruppierung durch Klammern nötig

### Beispiel: Algebra der Arithmetik

- Operanden: Variablen (z.B.  $x$ ) und Zahlenkonstanten (z.B. 42)
- Operatoren: arithmetische Operatoren (+, -, \*, /)
- Beispiele für Ausdrücke in dieser Algebra:

$$(x + 2*y) * z$$
$$(x + 5)/(y - 2) + x$$

4

## 2.5.1 Überblick RA (5)

### Operanden der Relationalen Algebra

- Relationen-Variablen
- Relationen-Constanten

### Operatoren der Relationalen Algebra

- übliche Mengenoperationen (Vereinigung, Schnitt, Differenz)
- Extraktionsoperatoren "Selektion" und "Projektion"
- Kombinationsoperatoren "Cartesisches Produkt" und "Joins"
- Umbenennung ("Rename")

Ausdrücke der RA heißen *Queries* (Abfragen)  
Relationenänderung durch Zuweisung, z.B.

$$A := A \setminus \sigma_{nr = 'H2'}(A)$$

5

## 2.5.2 RA Operatoren (1)

### Mengen versus Bags

- Relationales Modell ursprünglich (Codd 1970)  
mit Relationen als *Mengen* definiert
  - keine Doubletten zulässig
  - Operatoren inperformant (warum?)
- Moderne Implementierungen bevorzugen *Bags*  
(ungeordnete Listen)
  - Tupel ungeordnet, aber Doubletten möglich
  - Operatoren performant implementierbar

Operatoren der Relationalen Algebra haben  
eine Mengen- und eine Bag-Version

7

## 2.5.1 Überblick RA (6)

### Themen zur Relationalen Algebra:

- Operatoren und Rechenregeln
  - Welche Basis-Operatoren werden benötigt für Abfragen?
  - Unterschied *Relationen* versus *Bags*
- Dreiwertige Logik
  - Behandlung von *NULL*-Werten
- Eigenschaften der Operatoren
  - Berechnungskomplexität, begrenzte Ausdrucksstärke
- Algebraische Umformungen
  - Äquivalenz algebraischer Ausdrücke, Abfrageoptimierung
- Formulierung von Constraints mit RA

6

## 2.5.2 RA Operatoren (2)

### a) Extraktionsoperatoren

- Projektion  
 $\pi_{a_1, \dots, a_n}(R)$  = Auswahl der Spalten  $a_1, \dots, a_n$
- Selektion  
 $\sigma_{\text{Bedingung}}(R)$  = Auswahl Tupel, die *Bedingung* erfüllen

<i>pnr#</i>	<i>name</i>	<i>preis</i>	<i>hnr</i>
P1	Pritt	2.50	H1
P2	Füller	12.98	H2
P3	Tinte	3.20	H2

Diagramm zur Projektion ( $\pi_{name, preis}$ ) und Selektion ( $\sigma_{preis > 3}$ ):  
Die Projektion  $\pi_{name, preis}$  ist durch eine gestrichelte blaue Box über den Spalten *name* und *preis* dargestellt.  
Die Selektion  $\sigma_{preis > 3}$  ist durch eine gestrichelte rote Box über den Zeilen P2 und P3 dargestellt.

8

## 2.5.2 RA Operatoren (3)

Bemerkungen:

- Verhalten des Selektionsoperators  $\sigma$  für Bags und Mengen identisch (Warum?)
- Projektionsoperator  $\pi$  für Bags und Mengen verschieden

Wie verhält sich SQL-Befehl *select* dazu?

- Kombination von Selektion und Projektion:

SELECT name FROM produkt WHERE preis > 3;  
entspricht  
 $\pi_{name}(\sigma_{preis > 3}(\text{produkt}))$

- normalerweise Bagoperation, mit Modifier *distinct* aber Mengenoperation

9

## 2.5.2 RA Operatoren (5)

Definition von  $\cup$ ,  $\cap$  und  $\setminus$  für Mengen altbekannt. Aber was ist bei Bags?

$R$  enthalte Tupel  $t$   $n$ -mal  
 $S$  enthalte dasselbe Tupel  $t$   $m$ -mal

- $R \cup S$  enthält Tupel  $t$  dann  $(n+m)$ -mal
- $R \cap S$  enthält Tupel  $t$  dann  $\min(n, m)$ -mal
- $R \setminus S$  enthält Tupel  $t$  dann  $\max(0, n-m)$ -mal

$R$	$S$	$R \cup S$	$R \cap S$	$R \setminus S$	$S \setminus R$
$a \mid b$	$a \mid b$	$a \mid b$	$a \mid b$	$a \mid b$	$a \mid b$
$1 \mid 2$	$1 \mid 2$	$1 \mid 2$	$1 \mid 2$	$1 \mid 1$	$1 \mid 2$
$1 \mid 1$	$1 \mid 2$	$1 \mid 1$	$1 \mid 1$	$1 \mid 2$	$1 \mid 2$
$1 \mid 1$	$1 \mid 2$	$1 \mid 2$	$1 \mid 1$	$1 \mid 2$	$1 \mid 2$

11

## 2.5.2 RA Operatoren (4)

### b) Mengenoperatoren

- Vereinigung:  $R \cup S$
- Schnitt:  $R \cap S$
- Differenz:  $R \setminus S$

Bemerkungen:

- Voraussetzung: identische Attributnamen in  $R$  und  $S$
- Schnittoperator eigentlich überflüssig wegen

$$R \cap S = (R \cup S) \setminus ((R \setminus S) \cup (S \setminus R))$$

10

## 2.5.2 RA Operatoren (6)

Achtung:

- Rechenregeln für Mengen- und Bag-Version können unterschiedlich sein:
  - $R \cup S = S \cup R$  gilt für Mengen und Bags
  - $(R \cup S) \setminus T = (R \setminus T) \cup (S \setminus T)$  gilt für Mengen, aber nicht Bags

Mengenoperationen in SQL

- *union*, *intersect* und *except* für  $\cup$ ,  $\cap$  und  $\setminus$  nur möglich bei gleichen Rückgabetypen der verknüpften *select*-Statements
- normalerweise Mengenoperation (!), Bagoperation mit Modifier *all*, z.B. *select ... except all select ...*;

12

## 2.5.2 RA Operatoren (7)

### c) Umbenennung

Rename-Operator:

$$\varrho_{S(B_1, \dots, B_n)}(R) = \text{Kopie von } R \text{ mit anderen Namen}$$

Wozu braucht man das?

- um zwei Relation kompatibel für Mengenoperationen  $\cup, \cap$  oder  $\setminus$  zu machen
- Vermeidung doppelter Attributnamen im Cartesischen Produkt

13

## 2.5.2 RA Operatoren (9)

Join = Selektion auf Kartesischem Produkt

$$R \bowtie_{\text{Bed}} S = \sigma_{\text{Bed}}(R \times S)$$

Spezialfall "Natural Join":

Bei Bedingung der Form  $a=b$  entstehen Spalten, die in allen Werten identisch sind  
=> Vereinfachungskonvention *Natural Join*

- ▷ Joinbedingung ist Gleichheit gleichnamiger Attribute
- ▷ identische Ergebnisspalten nur einmal aufgeführt
- ▷ Notation durch Weglassen der Bedingung

Beispiel: Natural Join von  $R(a,b,c)$  und  $S(a,e,f)$ :

$$R \bowtie S = \pi_{a,b,c,e,f}(R \bowtie_{R.a=S.a} S)$$

15

## 2.5.2 RA Operatoren (8)

### d) Kombinationsoperatoren

Cartesisches Produkt (Kreuzprodukt):

$R \times S =$  Relation  $Q$  mit allen Attributen aus  $R$  und  $S$ , wobei jedes Tupel  $\in R$  mit jedem Tupel  $\in S$  kombiniert wird

$R$	$a$	$b$	$S$	$c$	$d$
	1	2		x	y
	3	4		x	z

$R \times S$	$a$	$b$	$c$	$d$
	1	2	x	y
	1	2	x	z
	3	4	x	y
	3	4	x	z

Tupelanzahl:  $|R \times S| = |R| \cdot |S|$

14

## 2.5.2 RA Operatoren (10)

Zusammenfassung

$\sigma_{\text{Bedingung}}, \pi_{\text{Spaltenliste}}$	Selektion, Projektion
$\cup, \cap$ und $\setminus$	Vereinigung, Schnitt und Differenz
$\varrho_{S(b_1, \dots, b_n)}$	Umbenennung
$\times, \bowtie_{\text{Bedingung}}$	Kreuzprodukt, Join

einige Rechenregeln

$$\sigma_{\text{Bed1}}(\sigma_{\text{Bed2}}(R)) = \sigma_{\text{Bed2}}(\sigma_{\text{Bed1}}(R))$$

$$R \cup (S \cap T) = (R \cup S) \cap (R \cup T)$$

$$\pi_Y(\sigma_{\text{Bed}}(R)) = \sigma_{\text{Bed}}(\pi_Y(R))$$

wenn in *Bed* nur Attribute aus  $Y$  vorkommen

$$\sigma_{\text{Bed1}}(R \bowtie_{\text{Bed2}} S) = \sigma_{\text{Bed1}}(R) \bowtie_{\text{Bed2}} \sigma_{\text{Bed1}}(S)$$

wenn in *Bed1* nur Attribute aus  $\text{attr}(R) \cap \text{attr}(S)$  vorkommen

16

## 2.5.2 RA Operatoren (11)

### Darstellung von Queries

"Was sind die Produkte des Herstellers 'H1', die mehr als 3 Euro kosten?"

#### a) Verkettung der Operatoren

$$\pi_{nr, name} \left( \sigma_{preis > 3}(\text{produkt}) \cap \sigma_{hnr = 'H1'}(\text{produkt}) \right)$$

#### b) Definition temporärer Variablen

$$R(nr, name, hnr, preis) := \sigma_{preis > 3}(\text{produkt})$$

$$S(nr, name, hnr, preis) := \sigma_{hnr = 'H1'}(\text{produkt})$$

$$T := R \cap S$$

$$\text{Ergebnis}(nr, name) := \pi_{nr, name}(T)$$

17

## 2.5.3 Dreiwertige Logik (1)

- Behandlung von NULL-Werten bei Vergleichsoperatoren und logischen Verknüpfungen?

#### a) Vergleichsoperatoren

logischer Wert von  $(a \sim b)$  ist "unbekannt" ( $\omega$ ), wenn  $a$  oder  $b$  den Wert NULL (unbekannt) hat

#### b) Logische Verknüpfungen

AND	F	$\omega$	T	OR	F	$\omega$	T
F	F	F	F	F	F	$\omega$	T
$\omega$	F	$\omega$	$\omega$	$\omega$	$\omega$	$\omega$	T
T	F	$\omega$	T	T	T	T	T


Not (F) = T  
Not (T) = F  
Not ( $\omega$ ) =  $\omega$

19

## 2.5.2 RA Operatoren (12)

"Was sind die Produkte des Herstellers 'H1', die mehr als 3 Euro kosten?"

#### c) Baumdiagramm



18

## 2.5.3 Dreiwertige Logik (2)

#### Beispiele:

$$(a > \text{NULL}) \text{ AND } (1 = 2) \longrightarrow \text{unwahr (F)}$$

$$(\text{NULL} = \text{NULL}) \text{ OR } (1 = 2) \longrightarrow \text{unbekannt } (\omega)$$

Bei Duplikatslöschung (z.B. bei  $\cup$  nötig) werden NULL-Werte wie normale Werte behandelt

$R$	$a$	$b$	$S$	$a$	$b$	$S \cup R$	$a$	$b$
	1	NULL	1	NULL		1	NULL	
	NULL	NULL	1	2		NULL	NULL	
						1	2	

(ausführliche Diskussion in E.F. Codd: *Extending the Relational Model*. ACM Transactions on Database Systems (4) 1979, p 397-434)

20

## 2.5.4 Eigenschaften der RA


An der Tafel vorgeführt:

- Komplexität der Operatoren
  - Operationen *effizient* (vgl. THI, 4. Semester) durchführbar
  - Bagoperatoren geringere Komplexität als Mengenoperatoren
- Grenzen der Relationalen Algebra
  - es gibt Abfragen, die nicht in RA möglich sind (z.B. Berechnung der *transitiven Hülle*)
  - Grund: RA ist *nicht Turing-vollständig* (vgl. THI)

21

## 2.5.5 Algebraische Optimierung (2)

- Ausdrücke (1) und (2) sind *äquivalent*,
- d.h. liefern dasselbe Ergebnis



- Selektion wird in (2) früher durchgeführt
- => kleinere Zwischenergebnisse => performanter

23

## 2.5.5 Algebraische Optimierung (1)

Beispiel:

Lieferant (A)	Produkt (B)	Lieferung (C)
lnr#	pnr#	nr#
lieferant	produkt	lnr
	preis	pnr
		menge

Die Abfrage

$$\pi_{\text{lieferant, produkt}} (\sigma_{\text{lieferant}='Henkel'} (A \bowtie B \bowtie C)) \quad (1)$$

kann wegen  $A \bowtie B = B \bowtie A$ ,  $\sigma_C(R \bowtie S) = \sigma_C(R) \bowtie S$  und  $(A \bowtie B) \bowtie C = A \bowtie (B \bowtie C)$  umgeformt werden in

$$\pi_{\text{lieferant, produkt}} (C \bowtie (\sigma_{\text{lieferant}='Henkel'} (A) \bowtie B)) \quad (2)$$

22

## 2.5.5 Algebraische Optimierung (3)

Allgemeine Optimierungsstrategie

- Selektionen zu Blättern verschieben
  - Selektionen verkleinern Zwischenergebnisse => möglichst früh durchführen
  - Joins sind besonders teuer. Nutze Regel
 
$$\sigma_{\text{Bed}}(R \sim S) = \sigma_{\text{Bed}}(R) \sim S \quad \text{für } \sim \in \{\times, \bowtie, \cap\}$$
 wenn  $R$  alle Attribute aus  $\text{Bed}$  enthält
- zusätzliche Projektionen einfügen
  - nicht benötigte Spalten können entfernt werden => nicht weniger Tupel, aber weniger Attribute

(siehe Garcia-Molina, Ullman, Widom: *Database Systems - The Complete Book*. Prentice Hall 2002. Kapitel 16.2)

24

## 2.5.6 RA für Constraints (1)

Integritätsbedingungen durch (Un-) Gleichungen der Relationalen Algebra formulierbar:

$$A1 = \emptyset \quad A1 = A2 \quad A1 \subseteq A2$$

wobei A1, A2 Ausdrücke der Relationalen Algebra

Beispiel a)

· NOT NULL Constraint auf Attribut  $a$  in  $R$ :


$$\sigma_{a \text{ is } NULL} ( R ) = \emptyset$$

25

## 2.5.6 RA für Constraints (2)

Beispiel b)

Foreign Key  
Constraint



$$\pi_{hnr}(\text{produkt}) \subseteq \pi_{hnr}(\text{hersteller})$$

oder  $\pi_{hnr}(\text{produkt}) \setminus \pi_{hnr}(\text{hersteller}) = \emptyset$

Bemerkungen:

- Projektionen oben sind *Mengen*-Operationen (warum?)
- Ungleichung immer als Gleichung formulierbar wegen

$$R \subseteq S \iff R \setminus S = \emptyset$$

26