

Grundlagen: Datenbanken WS 15/16

2. Zentralübung / Wiederholung / Fragestunde

Harald Lang

gdb@in.tum.de

Diese Folien finden Sie online.

Die Mitschrift erhalten Sie im Anschluss.

Termine

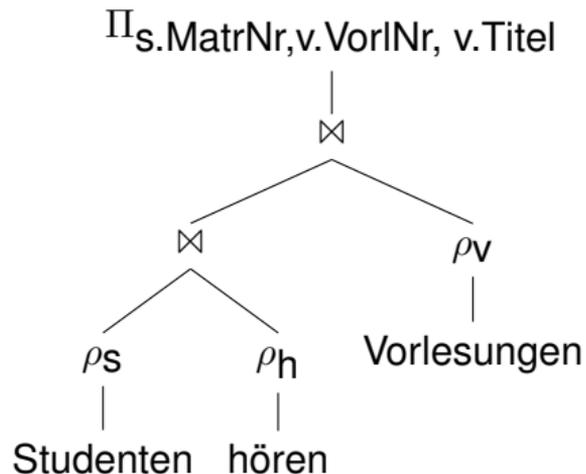
- ▶ Klausur
 - ▶ 24.02.2016, 10:30 - 12:30 Uhr
 - ▶ Anmeldung bis 15.01.2016
- ▶ Weihnachtsferien
 - ▶ 24.12.2015 - 6.1.2016
 - ▶ HINWEIS: **Ein** Übungsblatt für die Wochen 21.-23.12 (Mo-Mi) und 7.-8.1. (Do, Fr).

Agenda

- ▶ Relationale Anfragesprachen
 - ▶ Anmerkungen zur relationalen Algebra
 - ▶ Anmerkung: Natural-Join vs. allgemeiner Theta-Join
 - ▶ Kalkül: Freie vs. gebundene Variablen
 - ▶ SQL
 - ▶ Anmerkung zu Unteranfragen
 - ▶ Gruppierung / Aggregation
 - ▶ All-Quantifizierung
- ▶ Relationale Entwurfstheorie
 - ▶ ...

Anmerkungen zur relationalen Algebra

- ▶ Geklammerter Ausdruck vs. Operatorbaum
- ▶ Umbenennung



Anmerkung: Natural-Join vs. allgemeiner Theta-Join

	Natural	Theta
Inner	\bowtie	\bowtie_{θ}
Outer	\bowtie, \ltimes, \rhd	$\bowtie_{\theta}, \ltimes_{\theta}, \rhd_{\theta}$
Semi	\ltimes, \rhd	$\ltimes_{\theta}, \rhd_{\theta}$
Anti	$\triangleright, \triangleleft$	$\triangleright_{\theta}, \triangleleft_{\theta}$

► Natural

- Implizite Gleichheitsbedingung auf gleichnamigen Attributen
- Die gleichnamigen Attribute tauchen im Ergebnis nur einmal auf (inner und outer).

► Theta

- Explizite (beliebige) Joinbedingung: θ .
- Im Falle von Inner- und Outer-Join werden alle Attribute der beiden Eingaberelationen in das Ergebnis projiziert.

Kalkül: Freie vs. gebundene Variablen (1/2)

$$R : \{[a, b, c]\}, S : \{[d, e, f]\}$$

$$\text{Relationale Algebra: } Q_1 := R \bowtie_{a=d} S$$

$$\text{Tupelkalkül: } Q_1 := \{ r \circ s \mid r \in R \wedge s \in S \wedge r.a = s.d \}$$

$$\text{Domänenkalkül: } Q_1 := \{ [a, b, c, a, e, f] \mid [a, b, c] \in R \wedge [a, e, f] \in S \}$$

Kalkül: Freie vs. gebundene Variablen (2/2)

$$R : \{[a, b, c]\}, S : \{[d, e, f]\}$$

$$\text{Relationale Algebra: } Q_2 := R \bowtie_{a=d} S$$

$$\text{Tupelkalkül: } Q_2 := \{ r \mid r \in R \wedge \exists s \in S (r.a = s.d) \}$$

$$\text{Domänenkalkül: } Q_2 := \{ [a, b, c] \mid [a, b, c] \in R \wedge \exists e, f ([a, e, f] \in S) \}$$

Alle Domänen- / Tupelvariablen tauchen entweder in der Projektion auf, oder wurden explizit quantifiziert.

Anmerkung zu Unteranfragen in SQL

```
select * from R
where R.x = (select y from S where ... )
```

Die Unteranfrage muss **genau einen skalaren Wert** ausgeben.

```
select * from R
where R.x in (select y from S where ... )
```

Die Unteranfrage muss **eine Menge von skalaren Werten** ausgeben.

Übung: Gruppierung/Aggregation in SQL

"Gute Studenten": Finde Studenten in höheren Semestern ($\text{sem} > 5$) mit einem Notenschnitt < 2.5 . Geben Sie **MatrNr**, **Name** und **Notenschnitt** aus.

Übung: All-Quantifizierung in SQL

Finde Studenten, die ALLE Vorlesungen gehört haben.

Relationale Entwurftheorie

Funktionale Abhängigkeiten (kurz FDs, für functional dependencies):

- ▶ Seien α und β Attributmengen eines Schemas \mathcal{R} .
- ▶ Wenn auf \mathcal{R} die FD $\alpha \rightarrow \beta$ definiert ist, dann sind nur solche Ausprägungen R zulässig, für die folgendes gilt:
 - ▶ Für alle Paare von Tupeln $r, t \in R$ mit $r.\alpha = t.\alpha$ muss auch gelten $r.\beta = t.\beta$.

Übung: Relationenausprägung vervollständigen

Gegen seien die folgende Relationenausprägung und die funktionalen Abhängigkeiten. Bestimmen Sie zunächst x und danach y , sodass die FDs gelten.

$$B \rightarrow A$$
$$AC \rightarrow D$$

A	B	C	D
7	3	5	8
x	4	2	8
7	3	6	9
1	4	2	y

Funktionale Abhängigkeiten

Seien $\alpha, \beta, \gamma, \delta \subseteq \mathcal{R}$

Axiome von Armstrong:

▶ *Reflexivität:*

Falls $\beta \subseteq \alpha$, dann gilt immer $\alpha \rightarrow \beta$

▶ *Verstärkung:*

Falls $\alpha \rightarrow \beta$ gilt, dann gilt auch $\alpha\gamma \rightarrow \beta\gamma$

▶ *Transitivität:*

Falls $\alpha \rightarrow \beta$ und $\beta \rightarrow \gamma$ gelten, dann gilt auch $\alpha \rightarrow \gamma$

Mithilfe dieser Axiome können alle *geltenden* FDs hergeleitet werden.

Sei F eine FD-Menge. Dann ist F^+ die Menge aller geltenden FDs (*Hülle von F*)

Funktionale Abhängigkeiten

Nützliche und vereinfachende Regeln:

▶ *Vereinigungsregel:*

Falls $\alpha \rightarrow \beta$ und $\alpha \rightarrow \gamma$ gelten, dann gilt auch $\alpha \rightarrow \beta\gamma$

▶ *Dekompositionsregel:*

Falls $\alpha \rightarrow \beta\gamma$ gilt, dann gilt auch $\alpha \rightarrow \beta$ und $\alpha \rightarrow \gamma$

▶ *Pseudotransitivitätsregel:*

Falls $\alpha \rightarrow \beta$ und $\gamma\beta \rightarrow \delta$ gelten, dann gilt auch $\gamma\alpha \rightarrow \delta$

Schlüssel

- ▶ Schlüssel identifizieren jedes Tupel einer Relation \mathcal{R} eindeutig.
- ▶ Eine Attributmengende $\alpha \subseteq \mathcal{R}$ ist ein **Superschlüssel**, gdw. $\alpha \rightarrow \mathcal{R}$
- ▶ Ist α zudem noch *minimal*, ist es auch ein **Kandidatenschlüssel** (meist mit κ bezeichnet)
 - ▶ Es existiert also kein $\alpha' \subset \alpha$ für das gilt: $\alpha' \rightarrow \mathcal{R}$
- ▶ I.A. existieren mehrere Super- und Kandidatenschlüssel.
- ▶ Man muss sich bei der Realisierung für einen Kandidatenschlüssel entscheiden, dieser wird dann **Primärschlüssel** genannt.
- ▶ Der triviale Schlüssel $\alpha = \mathcal{R}$ existiert immer.

Übung: Schlüsseleigenschaft von Attributmengen ermitteln

- ▶ Ob ein gegebenes α ein Schlüssel ist, kann mithilfe der Armstrong Axiome ermittelt werden (i.A. zu aufwendig!)
- ▶ Besser: Die **Attributhülle** $AH(\alpha)$ bestimmen.

- ▶ Beispiel: $\mathcal{R} = \{ A , B , C , D \}$, mit $F_{\mathcal{R}} = \{ AB \rightarrow CD, B \rightarrow C, D \rightarrow B \}$

$AH(\{D\})$:

$AH(\{A, D\})$:

$AH(\{A, B, D\})$:

Normalformen: 1NF \supset 2NF \supset 3NF \supset BCNF \supset 4NF

- ▶ **1. NF:** Attribute haben nur atomare Werte, sind also nicht mengenwertig.
- ▶ **2. NF:** Jedes Nichtschlüsselattribut (NSA) ist voll funktional abhängig von jedem Kandidatenschlüssel.
 - ▶ β hängt **voll funktional** von α ab ($\alpha \xrightarrow{\bullet} \beta$), gdw. $\alpha \rightarrow \beta$ und es existiert kein $\alpha' \subset \alpha$, so dass $\alpha' \rightarrow \beta$ gilt.
- ▶ **3. NF:** Frei von transitiven Abhängigkeiten (*in denen NSAe über andere NSAe vom Schlüssel abhängen*).
 - ▶ für alle geltenden nicht-trivialen FDs $\alpha \rightarrow \beta$ gilt entweder
 - ▶ α ist ein Superschlüssel, oder
 - ▶ jedes Attribut in β ist in einem Kandidatenschlüssel enthalten
- ▶ **BCNF:** Die linken Seiten (α) aller geltenden nicht-trivialen FDs sind Superschlüssel.
- ▶ **4. NF:** Die linken Seiten (α) aller geltenden nicht-trivialen MVDs sind Superschlüssel.

Übung: Höchste NF bestimmen

$\mathcal{R} : \{ [A, B, C, D, E] \}$

$A \rightarrow BCDE$

$AB \rightarrow C$

- 1. NF
- 2. NF
- 3. NF
- 4. NF
- BCNF
- keine der angegebenen

Übung: Höchste NF bestimmen (2)

$\mathcal{R} : \{ [A, B, C, D, E] \}$

$A \rightarrow BCDE$

$B \rightarrow C$

- 1. NF
- 2. NF
- 3. NF
- 4. NF
- BCNF
- keine der angegebenen

Schema in 3. NF überführen

Synthesealgorithmus

▶ Eingabe:

▶ **Kanonische Überdeckung** \mathcal{F}_c

- ▶ Linksreduktion
- ▶ Rechtsreduktion
- ▶ FDs der Form $\alpha \rightarrow \emptyset$ entfernen (sofern vorhanden)
- ▶ FDs mit gleicher linke Seite zusammenfassen

▶ Algorithmus:

1. Für jede FD $\alpha \rightarrow \beta$ in \mathcal{F}_c forme ein Unterschema $\mathcal{R}_\alpha = \alpha \cup \beta$, ordne \mathcal{R}_α die FDs $\mathcal{F}_\alpha := \{\alpha' \rightarrow \beta' \in \mathcal{F}_c \mid \alpha' \cup \beta' \subseteq \mathcal{R}_\alpha\}$ zu
2. Füge ein Schema \mathcal{R}_κ mit einem Kandidatenschlüssel hinzu
3. Eliminiere redundante Schemata, d.h. falls $\mathcal{R}_i \subseteq \mathcal{R}_j$, verwerfe \mathcal{R}_i

▶ Ausgabe:

- ▶ Eine Zerlegung des ursprünglichen Schemas, wo alle Schemata in 3.NF sind.
- ▶ Die Zerlegung ist **abhängigkeitsbewahrend** und **verlustfrei**.

Übung: Synthesealgorithmus (1)

$$\mathcal{R} : \{ [A, B, C, D, E, F] \}$$

$$B \rightarrow ACDEF$$

$$EF \rightarrow BC$$

$$A \rightarrow D$$

Übung: Synthesealgorithmus (2)

$$\mathcal{R} = \{A, B, C, D, E, F, G\}, F_{\mathcal{R}} = \{A \rightarrow BCDE, E \rightarrow FB, F \rightarrow A\}$$

Schema in BCNF überführen

BCNF-Dekompositionsalgorithmus

- ▶ Starte mit $Z = \{\mathcal{R}\}$
- ▶ Solange es noch ein $\mathcal{R}_i \in Z$ gibt, das nicht in BCNF ist:
 - ▶ Finde eine FD $(\alpha \rightarrow \beta) \in F^+$ mit
 - ▶ $\alpha \cup \beta \subseteq \mathcal{R}_i$
 - ▶ $\alpha \cap \beta = \emptyset$
 - ▶ $\alpha \rightarrow \mathcal{R}_i \notin F^+$
 - ▶ Zerlege \mathcal{R}_i in $\mathcal{R}_{i.1} := \alpha \cup \beta$ und $\mathcal{R}_{i.2} := \mathcal{R}_i - \beta$
 - ▶ Entferne \mathcal{R}_i aus Z und füge $\mathcal{R}_{i.1}$ und $\mathcal{R}_{i.2}$ ein, also $Z := (Z - \{\mathcal{R}_i\}) \cup \{\mathcal{R}_{i.1}\} \cup \{\mathcal{R}_{i.2}\}$

BCNF-Dekompositionsalgorithmus

$$\mathcal{R} = \{A, B, C, D, E, F\}, F_{\mathcal{R}} = \{B \rightarrow AD, DEF \rightarrow B, C \rightarrow AE\}$$