



Datenbankanwendung

Wintersemester 2014/15

Prof. Dr.-Ing. Sebastian Michel
TU Kaiserslautern

smichel@cs.uni-kl.de

Recovery

Transaktionsverwaltung

Normalformen



Übersicht

Planung

Übersicht, Motivation, Wiederholung

- Motivation
- Organisation der VL und Regeln zum Übungsbetrieb
- Wiederholung aus Infosys (Tabellen, relationale Algebra, SQL)

Entwurfstheorie

- Konzeptioneller Entwurf
- Normalformenlehre
- Synthese von Relationen

Übersicht

Anfrageverarbeitung

- Implementierung von Operatoren (Joins, externes Sortieren, ...)
- Kostenschätzung
- Histogramme, Sketches

Indexstrukturen

- Wiederholung B+ Baum und Varianten
- Multidimensionale Indexstrukturen
- Hashing
- Ähnlichkeitssuche

Übersicht

Anfrageoptimierung

- Prinzip und Regelbasierte Optimierung (Wiederholung Infosys)
- Dynamische Programmierung, Greedy Algorithmen

Weitere SQL Konzepte, JDBC, PL/pgSQL, Trigger

- SQL Fensteranfragen und Rekursion
- JDBC
- Trigger und PL/pgSQL

Übersicht

Transaktionsverwaltung

- Transaktionskonzept, Ablauf von Transaktionen
- Commit-Protokolle

Serialisierbarkeit

- Anomalien im Mehrbenutzerbetrieb
- Theorie der Serialisierbarkeit
- Klassen von Historien

Synchronisation und Sperrverfahren

- Sperrprotokolle
- Nicht sperrende Protokolle
- Zweiphasen-Sperrprotokolle

Übersicht

Logging und Recovery

- Fehlermodelle und Recovery-Arten
- Logging-Strategien
- ...

(Materialisierte) Sichten

- Sichten
- Materialisierte Sichten und Updates

Datenschutz und Zugriffskontrolle

- Technische Probleme des Datenschutzes
- Konzepte der Zugriffskontrolle, Zugriffskontrolle in SQL
- Sicherheitsprobleme in statischen Datenbanken

Literaturliste

- A. Kemper und A. Eickler. Datenbanksysteme. Oldenbourg-Verlag, 2012.
- T. Härder und E. Rahm. Datenbanksysteme. Springer. 2011.
- H. Samet. Foundations of Multidimensional and Metric Data Structures. Morgan Kaufmann Publishers. 2006.
- G. Weikum und G. Vossen. Transactional Information Systems. Morgan Kaufmann Publishers. 2002.

Organisatorisches

Vorlesung

- 4 SWS Vorlesung: Wöchentlich, Dienstags und Freitags.
 - Dienstags, Raum 42-110, 11:45 bis 13:15 Uhr
 - Freitags, Raum 46-210, 11:45 bis 13:15 Uhr
- 2 SWS Übung: Wöchentlich, Donnerstags, 15:30 bis 17:00. Raum 13-222. **Übungsgruppenleiter Johannes Schildgen.**

Klausur

- Abschlussklausur am 20. März 2015 (Stand der Planung)
- Für die Zulassung zur Klausur bedarf es einer erfolgreichen Teilnahme am Übungsbetrieb.

Regeln zum Übungsbetrieb

- Es gibt 13 Übungsblätter, die in der wöchentlich stattfindenden Übung besprochen werden.
- Auf diesen Übungsblättern gibt es 40 Aufgaben, die Sie in Vorbereitung auf die Übung lösen müssen.
- Auf diese 40 Aufgaben gibt es jeweils einen Punkt.
- Sie müssen insgesamt 20 Punkte erreichen, um für die Klausur zugelassen zu werden. Die Punktevergabe funktioniert wie folgt:
- Zu Beginn der Übung markieren Sie auf einer Teilnehmerliste, welche der verbindlichen Aufgaben Sie gelöst haben und in der Übungsstunde präsentieren können.
- In der Übungsstunde wählt der Übungsleiter unter allen markierten Lösungen einen oder mehrere Studierende aus, die entsprechende Aufgabe zu präsentieren. Die Auswahl erfolgt auf Gutdünken des Übungsgruppenleiters.

Regeln zum Übungsbetrieb (2)

- Falls eine Aufgabe durch einen Studierenden als gelöst markiert wird, dieser bei der Aufforderung zur Präsentation passt oder die Präsentation der Aufgabe zeigt, dass sich der Studierende nicht ausreichend mit dem Thema befasst hat, erhält der Studierende 3 Minuspunkte.
- Ist die Lösung korrekt oder hat nur leichte Mängel, ist aber auf dem richtigen Weg zur korrekten Lösung, gibt es den vollen Punkt.
- Die Vergabe der Punkte erfolgt durch subjektive Einschätzung des Übungsleiters und muss nicht begründet werden.

Regeln zum Übungsbetrieb (3)

- Gruppenarbeit generell sinnvoll. Aber: Trotzdem ist die “Abgabe” der Lösungen nicht als Gruppe möglich, sondern pro Studierendem. Jeder Teilnehmer einer Gruppe muss in der Lage sein, die als gelöst markierten Aufgaben zu präsentieren.
- Neben den 40 verbindlichen Aufgaben gibt es weitere Aufgaben, deren Bearbeitung freiwillig ist. Wir wünschen und natürlich trotzdem rege Beteiligung bei der Präsentation der Lösungen. **Alle Aufgaben sind verbindlich sofern nicht als freiwillig markiert.**
- Für Aufgaben bei denen nur ein oder zwei Studierende eine Lösung markiert haben, gibt es zwei zusätzliche Bonuspunkte.

Vorlesungsfolien und Übungsblätter

Vorlesungsfolien

- Werden in der Regel einen Tag vor der Vorlesung online gestellt.
- Werden nach der Vorlesung evtl. aktualisiert (Typos, Anmerkungen, ...).

Übungsblätter

- Ausgabe Dienstags in der Vorlesung.
- Besprechung in Übung der folgenden Woche (auf Übungsblatt angegeben)

Wiederholung Infosys: So ging es los ...

Abilden eines Teilaspekts der realen Welt

- Was wollen wir Abbilden?
- Welcher Grad an Details?
- Welche Entitäten spielen eine Rolle?
- Und welche Rolle spielen sie?
- Wie sind Entitäten miteinander verbunden?

Anforderungsanalyse

Reale Welt: Universität

→ Anforderungsanalyse

Pflichtenheft

- „Studenten hören Vorlesungen“
- „Professoren halten Vorlesungen“
- „Studenten könnten anhand ihrer Matrikelnummer eindeutig identifiziert werden“
- ...

Entity/Relationship-Modellierung




How the customer explained it



How the Project Leader understood it

Quelle: www.fuki.ch


Entity/Relationship-Modellierung




Quelle: www.fuki.ch

Entity/Relationship-Modellierung

1. Entität → Entitätstyp
2. Beziehung → Beziehungstyp
3. Attribut (Eigenschaft)
4. Schlüssel (Identifikation)
5. Rolle



Beispiel: Universitätsschema



Relationales Modell

Abbilden des ER-Modells in Relationen:

Zum Beispiel:

- **Kunden**(ID, Telefon, Adresse, Name)
- **Kaufen**(Wert, Datum, Preis, Verkäufer, Auto, Kunde)
- **Verkaufen**(Datum, Wert, Kommission, Kunde, Verkäufer, Auto)
- ...

oder ...

- **Studenten** (MatrNr, Name)
- **Hören** (MatrNr, VorlNr)
- **Vorlesungen** (VorlNr, Titel)

Beispiel: Die relationale Uni-DB

Professoren			
PersNr	Name	Rang	Raum
2125	Sokrates	C4	226
2126	Russel	C4	232
2127	Kopernikus	C3	310
2133	Popper	C3	52
2134	Augustinus	C3	309
2136	Curie	C4	36
2137	Kant	C4	7

Studenten		
MatrNr	Name	Semester
24002	Xenokrates	18
25403	Jonas	12
26120	Fichte	10
26830	Aristoxenos	8
27550	Schopenhauer	6
28106	Carnap	3
29120	Theophrastos	2
29555	Feuerbach	2

Vorlesungen			
VorlNr	Titel	SWS	gelesen von
5001	Grundzüge	4	2137
5041	Ethik	4	2125
5043	Erkenntnistheorie	3	2126
5049	Mäeutik	2	2125
4052	Logik	4	2125
5052	Wissenschaftstheorie	3	2126
5216	Bioethik	2	2126
5259	Der Wiener Kreis	2	2133
5022	Glaube und Wissen	2	2134
4630	Die 3 Kritiken	4	2137

voraussetzen	
Vorgänger	Nachfolger
5001	5041
5001	5043
5001	5049
5041	5216
5043	5052
5041	5052
5052	5259

hören	
MatrNr	VorlNr
26120	5001
27550	5001
27550	4052
28106	5041
28106	5052
28106	5216
28106	5259
29120	5001
29120	5041
29120	5049
29555	5022
25403	5022

Assistenten			
PersNr	Name	Fachgebiet	Boss
3002	Platon	Ideenlehre	2125
3003	Aristoteles	Sylogistik	2125
3004	Wittgenstein	Sprachtheorie	2126
3005	Rhetikus	Planetenbewegung	2127
3006	Newton	Keplersche Gesetze	2127
3007	Spinoza	Gott und Natur	2126

prüfen			
MatrNr	VorlNr	PersNr	Note
28106	5001	2126	1
25403	5041	2125	2
27550	4630	2137	2

Die Operatoren der relationalen Algebra

- Selektion σ
- Projektion π
- Kreuzprodukt \times
- Join (Verbund) \bowtie
- Umbenennung ρ
- Differenz $-$
- Division \div
- Vereinigung \cup
- Schnitt \cap
- Semi-Join (linker) \ltimes
- Semi-Join (rechter) \rtimes
- linker äußerer Join $\ltimes\bowtie$
- rechter äußerer Join $\rtimes\bowtie$
- äußerer Join $\ltimes\bowtie\rtimes$

Grundlagen der relationalen Algebra

Achtung:

Es gibt Relationen (Ausprägungen: $R \subseteq D_1 \times D_2 \times \dots \times D_n$)
und Relationenschema: $\{[\text{attributname1: datentyp1, attributname2: datentyp2, ...}]\}$.

Das Schema einer Relation wird auch mit $sch(R)$ oder \mathcal{R} beschrieben.

Die Operatoren und ihre Verwendung:

- Eingabe eines Operators ist eine oder mehrere Relationen.
- Ausgabe ist auch wieder eine Relation.
- D.h., Operatoren sind kombinierbar (mit gewissen Regeln).

Z.B. Selektion

Selektion $\sigma_{Semester > 10}(Studenten)$

$\sigma_{Semester > 10}(Studenten)$		
MatrNr	Name	Semester
24002	Xenokrates	18
25403	Jonas	12

- Allgemein: σ_F
- Selektionsprädikat F besteht aus
 - Operatoren: \vee (oder) \wedge (und) \neg (nicht)
 - Arithmetischen Vergleichsoperatoren: $<$, \leq , $=$, $>$, \geq , \neq
 - ... und natürlich aus Attributnamen der Argumentrelation oder Konstanten als Operanden

Kartesisches Produkt (Kreuzprodukt)

Gegeben zwei Relationen R und S :

$$R \times S$$

beinhaltet **ALLE!** $|R| * |S|$ möglichen Paare von Tupeln aus R und S .

Enthält viele (oft auch viele unsinnige) Kombinationen!

Das resultierende Schema $sch(R \times S) = sch(R) \cup sch(S) = \mathcal{R} \cup \mathcal{S}$.

Beim Referenzieren der Attribute des resultierenden Schemas wird $R.X$ und $S.Y$ verwendet, insbesondere bei Überlappungen der einzelnen Schemata (=keine Unklarheiten was gemeint ist).

Der natürliche Verbund (Join)

Gegeben zwei Relationen (+ Schemata)

- $R(A_1, \dots, A_m, \mathbf{B}_1, \dots, \mathbf{B}_k)$
- $S(\mathbf{B}_1, \dots, \mathbf{B}_k, C_1, \dots, C_n)$

$$R \bowtie S = \pi_{A_1, \dots, A_m, R.B_1, \dots, R.B_k, C_1, \dots, C_n} (\sigma_{R.B_1=S.B_1 \wedge \dots \wedge R.B_k=S.B_k} (R \times S))$$

$R \bowtie S$											
$\mathcal{R} - \mathcal{S}$				$\mathcal{R} \cap \mathcal{S}$				$\mathcal{S} - \mathcal{R}$			
A_1	A_2	...	A_m	B_1	B_2	...	B_k	C_1	C_2	...	C_n
...

Mehrere Joins zusammen

- Es können beliebig viele Relationen durch Join Operatoren verknüpft werden.
- Die Reihenfolge spielt dabei keine Rolle (Joins sind kommutativ und assoziativ).

$(\textit{Studenten} \bowtie \textit{hoeren}) \bowtie \textit{Vorlesungen}$

$(\textit{Studenten} \bowtie \textit{hoeren}) \bowtie \textit{Vorlesungen}$						
MatrNr	Name	Semester	VorlNr	Titel	SWS	gelesenVon
26120	Fichte	10	5001	Grundzüge	4	2137
27550	Jonas	12	5022	Glaube und Wissen	2	2134
28106	Carnap	3	4052	Wissenschaftstheorie	3	2126
...

Allgemeiner Join (Theta-Join)

Gegeben zwei Relationen (+ Schemata)

- $R(A_1, \dots, A_n)$
- $S(B_1, \dots, B_m)$

θ ist ein beliebiges Prädikat über den beteiligten Attributen.

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

$R \bowtie S$							
\mathcal{R}				\mathcal{S}			
A_1	A_2	...	A_n	B_1	B_2	...	B_m
...

Equi-Join: Join-Prädikat θ darf nur auf Gleichheit (=) prüfen.

Weitere Join Typen: Äußere Joins

Diese Join Typen spezifizieren wie mit Tupeln umgegangen wird, die keinen Joinpartner gefunden haben.

- linker äußerer Join (\bowtie): auch “partnerlose” Tupel der linken Relation bleiben erhalten
- rechter äußerer Join (\bowtie): auch “partnerlose” Tupel der rechten Relation bleiben erhalten
- vollständiger äußerer Join (\bowtie): die “partnerlosen” Tupel beider Relationen bleiben erhalten

Natürlicher Join und linker äußerer Join

Natürlicher Join

L		
A	B	C
a_1	b_1	c_1
a_2	b_2	c_2

 \bowtie

R		
C	D	E
c_1	d_1	e_1
c_3	d_2	e_2

 $=$

Resultat				
A	B	C	D	E
a_1	b_1	c_1	d_1	e_1

Linker äußerer Join

L		
A	B	C
a_1	b_1	c_1
a_2	b_2	c_2

 \ltimes

R		
C	D	E
c_1	d_1	e_1
c_3	d_2	e_2

 $=$

Resultat				
A	B	C	D	E
a_1	b_1	c_1	d_1	e_1
a_2	b_2	c_2	—	—

Rechter äußerer und äußerer Join

Rechter äußerer Join

L		
A	B	C
a ₁	b ₁	c ₁
a ₂	b ₂	c ₂

 \bowtie

R		
C	D	E
c ₁	d ₁	e ₁
c ₃	d ₂	e ₂

 $=$

Resultat				
A	B	C	D	E
a ₁	b ₁	c ₁	d ₁	e ₁
—	—	c ₃	d ₂	e ₂

Äußerer Join

L		
A	B	C
a ₁	b ₁	c ₁
a ₂	b ₂	c ₂

 \bowtie

R		
C	D	E
c ₁	d ₁	e ₁
c ₃	d ₂	e ₂

 $=$

Resultat				
A	B	C	D	E
a ₁	b ₁	c ₁	d ₁	e ₁
a ₂	b ₂	c ₂	—	—
—	—	c ₃	d ₂	e ₂

Weitere Join Typen: Semi Joins

Idee: Finde alle Tupel der linken Relation die Joinpartner in der rechten Relation haben.

$$L \bowtie R = \pi_{\mathcal{L}}(L \bowtie R)$$

$L \bowtie R$ ist analog definiert.

Es gilt:

$$L \bowtie R = R \bowtie L$$

allerdings sind Semi-Joins sowie die linken und rechten äußeren Joins **nicht kommutativ!**

Semi-Joins

Semi-Join von L mit R

L		
A	B	C
a_1	b_1	c_1
a_2	b_2	c_2

 \times

R		
C	D	E
c_1	d_1	e_1
c_3	d_2	e_2

 $=$

Resultat		
A	B	C
a_1	b_1	c_1

Semi-Join von R und L

L		
A	B	C
a_1	b_1	c_1
a_2	b_2	c_2

 \times

R		
C	D	E
c_1	d_1	e_1
c_3	d_2	e_2


 $=$

Resultat		
C	D	E
c_1	d_1	e_1

Operatorbaum-Darstellung

Alternative Darstellung von Ausdrücken der relationalen Algebra. Gerade für größere Ausdrücke viel übersichtlicher.

Beispiel:



SQL

- **deklarative** Anfragesprache (“was” nicht “wie”)
- setzte sich aus drei Sprachen zusammen:
- Datendefinitions (DDL)-Sprache:
 - erstellt/ändert das Schema
 - create, alter, drop
- Datenmanipulations (DML)-Sprache
 - ändert Ausprägungen
 - insert, update, delete
- Anfragesprache:
 - berechnet Anfragen auf den Ausprägungen
 - select * from where ...

Relationen vs. Tabellen

- bisher hatten wir Relationen (=Mengen) betrachtet
- in SQL betrachten wir aber Tabellen (=Bags)
- was ist der Unterschied?
- Relationen versus Tabellen:
 - Tabellen können Duplikate enthalten
 - Tabellen können eine Ordnung haben
 - Tabellen haben nicht unbedingt einen Schlüssel

Einfache Datendefinitionen in SQL

Datentypen

- **character** (n), **char** (n)
- **character varying** (n), **varchar** (n)
- **numeric** (p,s), **integer**
- **blob** oder **raw** für sehr große binäre Daten
- **clob** für sehr große String-Attribute
- **date** für Datumsangaben
- **xml** für XML-Dokumente

Datendefinitions (DDL) Sprache

Tabellen erstellen:

```
create table Professoren(  
    PersNr    integer not null,  
    Name      varchar (10) not null  
    Rang      character (2) );
```

Tabellen verändern:

```
alter table Professoren  
    add (Raum integer);
```

```
alter table Professoren  
    modify (Name varchar(30));
```

Datendefinitions (DDL) Sprache

Tabellen löschen:

```
drop table Professoren;
```

Datenmanipulationssprache: insert

```
insert into Studenten (MatrNr, Name)  
  values (28121, 'Archimedes');
```

```
insert into Studenten (Name)  
  values ('Meier');
```

```
insert into hören  
  select MatrNr, VorlNr  
  from Studenten, Vorlesungen  
  where Titel = 'Logik';
```


Anfragesprache

```
select <Liste von Spalten>  
  from <Liste von Tabellen>  
  where <Bedingung>;
```

select * wählt alle verfügbaren Spalten aus!

Relationale Algebra \rightarrow SQL

- Projektion $\pi \rightarrow$ select
- Kreuzprodukt $\times \rightarrow$ from
- Selektion $\sigma \rightarrow$ where

Select from where ...

```
select PersNr, Name
from Professoren
where Rang = 'C4';
```

Professoren	
PersNr	Name
2125	Sokrates
2126	Russel
2136	Curie
2137	Kant

Professoren			
PersNr	Name	Rang	Raum
7 2125	Sokrates	C4	226
2126	Russel	C4	232
2127	Kopernikus	C3	310
2133	Popper	C3	52
2134	Augustinus	C3	309
2136	Curie	C4	36
2137	Kant	C4	7

Anmerkung:

SQL legt nicht fest in welcher Reihenfolge Selektion, Projektion oder Join ausgeführt werden.

Anfragen über mehrere Relationen

Welcher Professor liest "Mäeutik"?

```
select Name, Titel  
from Professoren, Vorlesungen  
where PersNr = gelesenVon and Titel = 'Mäeutik'
```

In der relationalen Algebra sieht das wie folgt aus:

$$\pi_{Name, Titel}(\sigma_{PersNr=gelesenVon \wedge Titel='Mäeutik'}(Professoren \times Vorlesungen))$$


Übersetzung von SQL in die relationale Algebra

Allgemeine Form einer
(ungeschachtelten) SQL-Anfrage:

select A_1, \dots, A_n
from R_1, \dots, R_k
where P ;

Übersetzung in die relationale Algebra:

$$\pi_{A_1, \dots, A_n}(\sigma_P(R_1 \times \dots \times R_k))$$



Anfragen über mehrere Relationen

Welche Studenten hören welche Vorlesungen?

```
select Name, Titel  
from Studenten, hören, Vorlesungen  
where Studenten.MatrNr=hören.MatrNr and  
        hören.VorlNr = Vorlesungen.VorlNr;
```

Alternativ:

```
select s.Name, v.Titel  
from Studenten s, hören h, Vorlesungen v  
where s.MatrNr=h.MatrNr and  
        h.VorlNr = v.VorlNr;
```

Relationale Entwurfstheorie

ProfVorl						
PersNr	Name	Rang	Raum	VorlNr	Titel	SWS
2125	Sokrates	C4	226	5041	Ethik	4
2125	Sokrates	C4	226	5049	Mäeutik	2
2125	Sokrates	C4	226	4052	Logik	4
...
2132	Popper	C3	52	5259	Der Wiener Kreis	2
2137	Kant	C4	7	4630	Die 3 Kritiken	4

Wieso ist dies ein schlechtes Schema?

ProfVorl						
PersNr	Name	Rang	Raum	VorlNr	Titel	SWS
2125	Sokrates	C4	226	5041	Ethik	4
2125	Sokrates	C4	226	5049	Mäeutik	2
2125	Sokrates	C4	226	4052	Logik	4
...
2132	Popper	C3	52	5259	Der Wiener Kreis	2
2137	Kant	C4	7	4630	Die 3 Kritiken	4

Wieso ist dies ein schlechtes Schema?

- **Änderungsanomalien:** Sokrates zieht um, von Raum 226 in Raum 338. Was passiert?
- **Einfügeanomalien:** Neuer Professor ohne Vorlesungen?
- **Löschanomalien:** Letzte Vorlesung eines Profs wird gelöscht. Was passiert?

Funktionale Abhängigkeiten

Functional Dependency (FD)

- Schema $\mathcal{R} = \{A, B, C, D\}$
- Ausprägung R
- Seien $\alpha \subseteq \mathcal{R}$ und $\beta \subseteq \mathcal{R}$
- $\alpha \rightarrow \beta$ genau dann, wenn $\forall r, s \in R$ gilt: $r.\alpha = s.\alpha \Rightarrow r.\beta = s.\beta$
- D.h. die α -Werte bestimmen die β -Werte funktional (=eindeutig)

R			
A	B	C	D
a4	b2	c4	d3
a1	b1	c1	d1
a1	b1	c1	d2
a2	b2	c3	d2
a3	b2	c4	d3

$$\{A\} \rightarrow \{B\}$$

$$\{A\} \rightarrow \{C\}$$

$$\{C, D\} \rightarrow \{B\}$$

Aber nicht $\{B\} \rightarrow \{C\}$

Notation: $CD \rightarrow B$

Einhaltung funktionaler Abhängigkeiten

Alternative Formulierung

- Die FD $\alpha \rightarrow \beta$ ist in R erfüllt, wenn für jede mögliche Ausprägung von α gilt:

$$|\pi_{\beta}(\sigma_{\alpha=c}(R))| \leq 1$$

- “die Menge aller Tupel von R mit $\alpha = c$ (für beliebiges c) projiziert auf β enthält keinen oder genau einen Wert“
- ansonsten wäre es auch keine “Funktion”

Daraus folgt ein einfacher Algorithmus:

```

boolean giltFD(Relation R, FD  $\alpha \rightarrow \beta$ ) {
  sortiere R nach  $\alpha$  Werten
  für jede Gruppe  $G_i \subseteq R$  von Tupeln mit Wert  $\alpha_i$  aus  $\alpha$ :
    falls nicht alle  $\beta_i$  aus  $\beta$  identisch sind:
      return falsch;
  return wahr;
}
  
```

Schlüssel

- $\alpha \subseteq \mathcal{R}$ ist ein Superschlüssel, falls gilt: $\alpha \rightarrow \mathcal{R}$
- trivial: es gilt $\mathcal{R} \rightarrow \mathcal{R}$
- Allerdings sind Superschlüssel nicht notwendigerweise minimal!

Volle funktionale Abhängigkeit:

- β ist voll funktional abhängig von α (Notation: $\alpha \twoheadrightarrow \beta$) genau dann wenn gilt:
 - $\alpha \rightarrow \beta$
 - α kann nicht mehr verkleinert (=linksreduziert) werden, d.h.
 - $\forall A \in \alpha$ folgt, dass $(\alpha - \{A\}) \rightarrow \beta$ nicht gilt, bzw. alternativ:
 - $\forall A \in \alpha : \neg((\alpha - \{A\}) \rightarrow \beta)$
- $\alpha \subseteq \mathcal{R}$ ist ein **Kandidatenschlüssel**, falls gilt: $\alpha \twoheadrightarrow \mathcal{R}$

Ein Kandidatenschlüssel wird als **Primärschlüssel** ausgewählt!

Beispiel zur Schlüsselbestimmung

Städte			
Name	BLand	Vorwahl	EW
Frankfurt	Hessen	69	650000
Frankfurt	Brandenburg	335	84000
München	Bayern	89	1200000
Passau	Bayern	851	50000
Saarbrücken	Saarland	681	175000
Kaiserslautern	Rheinland-Pfalz	631	100000
...

Kandidatenschlüssel von Städte:

- {Name, BLand}
- {Name, Vorwahl}

Bestimmung funktionaler Abhängigkeiten

- Tabelle **Professoren**: {[PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, BLand, EW, Landesregierung]}
- {PersNr} \rightarrow {PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, BLand, EW, Landesregierung}
- {Ort, BLand} \rightarrow {EW, Vorwahl}
- {PLZ} \rightarrow {BLand, Ort, EW}
- {BLand, Ort, Straße} \rightarrow {PLZ}
- {BLand} \rightarrow {Landesregierung}
- {Raum} \rightarrow {PersNr}

Außerdem kann abgeleitet werden:

- {Raum} \rightarrow {PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, BLand, EW, Landesregierung}
- {PLZ} \rightarrow {Landesregierung}

Herleitung weiterer FDs

- Aus einer Menge F von FDs sind weitere FDs herleitbar
- F^+ wird Hülle (closure) von F genannt.
- F^+ besteht aus allen aus F herleitbaren FDs
- Inferenzregeln, die Amstrong Axiome, beschreiben die Herleitung

Die Armstrong-Axiome

$\alpha, \beta, \gamma, \delta$ sind Teilmengen der Attribute aus \mathcal{R}

- **Reflexivität:** Falls β eine Teilmenge von α ist ($\beta \subseteq \alpha$) dann gilt immer $\alpha \rightarrow \beta$.
Insbesondere gilt also immer $\alpha \rightarrow \alpha$.
- **Verstärkung:** Falls $\alpha \rightarrow \beta$ gilt, dann gilt auch $\alpha\gamma \rightarrow \beta\gamma$. Hierbei stehe z.B. $\alpha\gamma$ für $\alpha \cup \gamma$
- **Transitivität:** Falls $\alpha \rightarrow \beta$ und $\beta \rightarrow \gamma$ gilt, dann gilt auch $\alpha \rightarrow \gamma$.

Die Armstrong-Axiome sind **korrekt** und **vollständig**.

D.h. Mit Hilfe dieser Axiome können alle gültigen FDs hergeleitet werden.

Die Armstrong-Axiome (2)

Nicht notwendig, aber oftmals komfortabel für Herleitungen:

- **Vereinigungsregel:**

Wenn $\alpha \rightarrow \beta$ und $\alpha \rightarrow \gamma$ gelten, dann auch $\alpha \rightarrow \beta\gamma$.

- **Dekompositionsregel:**

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

- **Pseudotransitivitätsregel:**

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

Attributhülle

Die Attributhülle $\text{AttrHülle}(F, \alpha)$ einer Attributmengung α bzgl. FDs F ist die Menge von Attributen α^+ , für die gilt $\alpha \rightarrow \alpha^+$.

Gegeben:

- eine Menge F von FDs
- eine Menge von Attributen $\alpha \subseteq \mathcal{R}$

Algorithmus:

```
Erg :=  $\alpha$ ;  
while (Änderungen an  $Erg$ ) do  
  for each FD  $\beta \rightarrow \gamma$  in  $F$  do  
    if  $\beta \subseteq Erg$  then  $Erg := Erg \cup \gamma$ ;  
 $\alpha^+ := Erg$ ;
```

Beispielanwendung

Ziel:

Bestimme, ob κ einen Superschlüssel einer Relation \mathcal{R} bzgl. der FDs in F bildet.

Lösung:

Durch Aufruf $\text{AttrHülle}(F, \kappa)$ erhalten wir κ^+ .

Falls $\kappa^+ = \mathcal{R}$: κ ist Superschlüssel von \mathcal{R} .

Äquivalente FD-Mengen

- Im Allgemeinen: es gibt viele unterschiedliche äquivalente Mengen von funktionalen Abhängigkeiten.
- Zwei Mengen F und G heißen äquivalent (Notation: $F \equiv G$), wenn ihre Hüllen gleich sind, d.h. $F^+ = G^+$.
- **Bedeutung:** die gleichen Mengen von FDs müssen herleitbar sein.

Beobachtung:

- F^+ kann sehr groß sein
- viele redundanten Abhängigkeiten
- in der Praxis unübersichtlich

Ziel: **kleinstmögliche** Menge F_c finden, so dass immer noch gilt:
 $F_c^+ = F^+$.

Kanonische Überdeckung F_c

Folgende Eigenschaften müssen erfüllt sein:

1. $F_c \equiv F$, d.h., $F_c^+ = F^+$
2. In F_c existieren keine FDs $\alpha \rightarrow \beta$, bei denen α oder β überflüssige Attribute enthalten. D.h. es muss gelten:
 - (a) $\forall A \in \alpha : (F_c - (\alpha \rightarrow \beta) \cup ((\alpha - A) \rightarrow \beta)) \not\equiv F_c$
 - (b) $\forall B \in \beta : (F_c - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B))) \not\equiv F_c$
3. Jede linke Seite einer funktionalen Abhängigkeit in F_c ist einzigartig. Dies kann durch sukzessive Anwendung der Vereinigungsregel auf FDs der Art $\alpha \rightarrow \beta$ und $\alpha \rightarrow \gamma$ erzielt werden, so dass die beiden FDs durch $\alpha \rightarrow \beta\gamma$ ersetzt werden.

Algorithmus zur Bestimmung von F_c

1. Führe für jede FD $\alpha \rightarrow \beta \in F$ die Linksreduktion durch, also:
 - Überprüfe für alle $A \in \alpha$, ob A überflüssig ist, d.h. ob $\beta \subseteq \text{AttrHülle}(F, \alpha - A)$
2. Führe für jede (verbliebene) FD die Rechtsreduktion durch:
 - Überprüfe für alle $B \in \beta$, ob $B \in \text{AttrHülle}(F - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B)), \alpha)$ gilt. In diesem Fall ist B auf der rechten Seite überflüssig und kann eliminiert werden, d.h. $\alpha \rightarrow \beta$ wird durch $\alpha \rightarrow (\beta - B)$ ersetzt.
3. Entferne die FDs der Form $\alpha \rightarrow \emptyset$, die im 2. Schritt entstanden sind.
4. Fasse mittels Vereinigungsregel FDs der Form $\alpha \rightarrow \beta_1, \dots, \alpha \rightarrow \beta_n$ zusammen, so dass $\alpha \rightarrow (\beta_1 \cup \dots \cup \beta_n)$ verbleibt.

Beispiel für Herleitung einer kanonischen Überdeckung

- $F = \{A \rightarrow B, B \rightarrow C, AB \rightarrow C\}$
- **Schritt 1:** Linksreduktion ersetzt $AB \rightarrow C$ durch $A \rightarrow C$
- **Schritt 2:** Rechtsreduktion ersetzt $A \rightarrow C$ durch $A \rightarrow \emptyset$
- **Schritt 3:** eliminiere $A \rightarrow \emptyset$
- **Schritt 4:** keine Zusammenfassungen notwendig
- Damit ist $F_c = \{A \rightarrow B, B \rightarrow C\}$

Normalisierung von Relationen

Um Qualitätsprobleme im ursprünglichen Entwurf zu beheben, wird das bestehende Relationenschema \mathcal{R} in mehrere Relationenschemata $\mathcal{R}_1, \dots, \mathcal{R}_n$ zerlegt, die dann "besser" sind.

- Die Güte einer Zerlegung wird mit **Normalformen** beschrieben.
- Normalformen: 1NF, 2NF, 3NF, BCNF, 4NF, ...

Korrektheitskriterien für Zerlegung:

- **Verlustlosigkeit:** Die in der ursprünglichen Relationenausprägung R des Schemas \mathcal{R} enthaltenen Daten müssen aus den Ausprägungen R_1, \dots, R_n der neuen Relationenschemata $\mathcal{R}_1, \dots, \mathcal{R}_n$ rekonstruierbar sein.
- **Abhängigkeitsbewahrung:** Alle FDs in $F_{\mathcal{R}}$ sollten in den $F_{\mathcal{R}_1}, F_{\mathcal{R}_2}, \dots, F_{\mathcal{R}_n}$ bewahrt bleiben.

Verlustlosigkeit

- Zerlegung ist gültig, wenn: $\mathcal{R} = \mathcal{R}_1 \cup \mathcal{R}_2$
- D.h. alle Attribute aus \mathcal{R} bleiben in der Zerlegung erhalten
- Wir definieren:
 - $R_1 := \pi_{\mathcal{R}_1}(R)$
 - $R_2 := \pi_{\mathcal{R}_2}(R)$
- die Zerlegung von \mathcal{R} in \mathcal{R}_1 und \mathcal{R}_2 ist **verlustlos**, falls für jede mögliche (gültige) Ausprägung R von \mathcal{R} gilt:

$$R = R_1 \bowtie R_2$$

Die Zerlegung muss also durch einen natürlichen Verbund (Join) rekonstruierbar sein.

D.h. $\mathcal{R}_1 \cap \mathcal{R}_2 \neq \emptyset$

“sinnvoller” Schlüssel existiert

Formale Charakterisierung Verlustloser Zerlegungen

- Gegeben Zerlegung von \mathcal{R} in \mathcal{R}_1 und \mathcal{R}_2
- $F_{\mathcal{R}}$ ist die Menge der FDs in \mathcal{R}
- Zerlegung ist verlustlos, wenn mindestens **eine** der folgenden FDs herleitbar ist:
 - $(\mathcal{R}_1 \cap \mathcal{R}_2) \rightarrow \mathcal{R}_1 \in F_{\mathcal{R}}^+$ **oder** d.h. Schlüssel bestimmt \mathcal{R}_1
 - $(\mathcal{R}_1 \cap \mathcal{R}_2) \rightarrow \mathcal{R}_2 \in F_{\mathcal{R}}^+$ d.h. Schlüssel bestimmt \mathcal{R}_2

Beispiel:

- Seien α, β und γ paarweise disjunkte Attributmengen
- $\mathcal{R} = \alpha \cup \beta \cup \gamma$, $\mathcal{R}_1 = \alpha \cup \beta$, $\mathcal{R}_2 = \alpha \cup \gamma$, $\mathcal{R}_1 \cap \mathcal{R}_2 = \alpha$
- Dann muss eine der Bedingungen gelten:
 - $\beta \subseteq \text{AttrHülle}(F_{\mathcal{R}}, \alpha)$ **oder**
 - $\gamma \subseteq \text{AttrHülle}(F_{\mathcal{R}}, \alpha)$

D.h. die gemeinsamen Joinattribute α müssen \mathcal{R}_1 oder \mathcal{R}_2 bestimmen.

Dies ist eine hinreichende aber nicht notwendige Bedingung!

Beispiel für Verlust

Biertrinker		
Kneipe	Gast	Bier
Kowalski	Kemper	Pils
Kowalski	Eickler	Hefeweizen
Innsteg	Kemper	Hefeweizen

wird zerlegt in ...

$\pi_{Kneipe,Gast}$

Besucht	
Kneipe	Gast
Kowalski	Kemper
Kowalski	Eickler
Innsteg	Kemper

$\pi_{Gast,Bier}$

Trinkt	
Gast	Bier
Kemper	Pils
Eickler	Hefeweizen
Kemper	Hefeweizen

Beispiel für Verlust: Wiederherstellung

 $\pi_{Kneipe, Gast}$

Besucht	
Kneipe	Gast
Kowalski	Kemper
Kowalski	Eickler
Innsteg	Kemper

 $\pi_{Gast, Bier}$

Trinkt	
Gast	Bier
Kemper	Pils
Eickler	Hefeweizen
Kemper	Hefeweizen

Mit Join verbunden gibt ..

Biertrinker		
Kneipe	Gast	Bier
Kowalski	Kemper	Pils
Kowalski	Kemper	Hefeweizen
Kowalski	Eickler	Hefeweizen
Innsteg	Kemper	Pils
Innsteg	Kemper	Hefeweizen

Erläuterung des Biertrinker-Beispiels

- User Biertrinker-Beispiel war **keine verlustlose Zerlegung**.
- Es gibt in Biertrinker nämlich nur die folgende nicht-triviale funktionale Abhängigkeit:

$$\{Kneipe, Gast\} \rightarrow \{Bier\}$$

- $\mathcal{R} = \{Kneipe\} \cup \{Gast\} \cup \{Bier\}$
- $\mathcal{R}_1 = \{Kneipe\} \cup \{Gast\}$, $\mathcal{R}_2 = \{Gast\} \cup \{Bier\}$,
 $\mathcal{R}_1 \cap \mathcal{R}_2 = \{Gast\}$.
- Dann muss eine der Bedingungen gelten:
 - $\{Kneipe\} \subseteq AttrHülle(\{Kneipe, Gast\} \rightarrow \{Bier\}, \{Gast\})$ **oder**
 - $\{Bier\} \subseteq AttrHülle(\{Kneipe, Gast\} \rightarrow \{Bier\}, \{Gast\})$
- Das ist nicht der Fall!
- Keine der zwei möglichen, die Verlustlosigkeit garantierenden FDs gilt:

$$\{Gast\} \rightarrow \{Bier\}$$

$$\{Gast\} \rightarrow \{Kneipe\}$$