



# Informationssysteme

Sommersemester 2016

Prof. Dr.-Ing. Sebastian Michel  
TU Kaiserslautern

[smichel@cs.uni-kl.de](mailto:smichel@cs.uni-kl.de)

# Übersicht

## Kommende ~2 Vorlesungen

- Was ist ein guter relationaler Entwurf und wie kann ein schlechter Entwurf verbessert werden?

## Danach betrachten wir, wie ein Datenbanksystem aufgebaut ist bzw. im Kern funktioniert, zuerst bzgl. Performance.

- Wie werden Daten auf Festplatte abgelegt?
- Wie werden (SQL) Anfragen ausgeführt und welche Kosten fallen dabei an?
- Wie kann effizient auf Daten zugegriffen werden?
- Wie kann die Ausführung einer Anfrage optimiert werden?

Danach kommen weitere Aspekte, wie Transaktionsverwaltung (=Fehlerbehandlung sowie Mehrbenutzersynchronisation).

# 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  $\alpha$ -Werte bestimmen die  $\beta$ -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. auch ohne  $\{$  bzw  $\}$ :  
 $C, D \rightarrow B$  oder auch  $CD \rightarrow B$

# Einhaltung funktionaler Abhängigkeiten

## Alternative Formulierung

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

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

- “die Menge aller Tupel von  $R$  mit  $\alpha = c$  (für beliebiges  $c$ ) projiziert auf  $\beta$  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:

- $\beta$  ist voll funktional abhängig von  $\alpha$  (Notation:  $\alpha \twoheadrightarrow \beta$ ) genau dann wenn gilt:
  - $\alpha \rightarrow \beta$
  - $\alpha$  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
...	...	...	...

### Kandidatschlüssel 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  $\mathcal{F}$  von FDs sind weitere FDs herleitbar
- $\mathcal{F}^+$  wird **Hülle** (**closure**) von  $\mathcal{F}$  genannt.
- $\mathcal{F}^+$  besteht aus allen aus  $\mathcal{F}$  herleitbaren FDs
- Inferenzregeln, die **Armstrong Axiome**, beschreiben die Herleitung

# Die Armstrong-Axiome

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

- **Reflexivität:** Falls  $\beta$  eine Teilmenge von  $\alpha$  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  $\text{AttrHülle}(\mathcal{F}, \alpha)$  einer Attributmengung  $\alpha$  bzgl. FDs  $\mathcal{F}$  ist die Menge von Attributen  $\alpha^+$ , für die gilt  $\alpha \rightarrow \alpha^+$ .

Gegeben:

- eine Menge  $\mathcal{F}$  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  $\mathcal{F}$  do  
    if  $\beta \subseteq Erg$  then  $Erg := Erg \cup \gamma$ ;  
 $\alpha^+ := Erg$ ;
```

# Beispielanwendung

## Ziel:

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

## Lösung:

Durch Aufruf  $\text{AttrHülle}(\mathcal{F}, \kappa)$  erhalten wir  $\kappa^+$ .  
Falls  $\kappa^+ = \mathcal{R}$ :  $\kappa$  ist Superschlüssel von  $\mathcal{R}$ .

# Äquivalente FD-Mengen

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

## Beobachtung:

- $\mathcal{F}^+$  kann sehr groß sein
- viele redundanten Abhängigkeiten
- in der Praxis unübersichtlich

Ziel: **kleinstmögliche** Menge  $\mathcal{F}_c$  finden, so dass immer noch gilt:  
 $\mathcal{F}_c^+ = \mathcal{F}^+$ .



# Kanonische Überdeckung $\mathcal{F}_c$

## Folgende Eigenschaften müssen erfüllt sein:

1.  $\mathcal{F}_c \equiv \mathcal{F}$ , d.h.,  $\mathcal{F}_c^+ = \mathcal{F}^+$
2. **In  $\mathcal{F}_c$  existieren keine FDs  $\alpha \rightarrow \beta$ , bei denen  $\alpha$  oder  $\beta$  überflüssige Attribute enthalten.** D.h. es muss gelten:
  - (a)  $\forall A \in \alpha : (\mathcal{F}_c - (\alpha \rightarrow \beta) \cup ((\alpha - A) \rightarrow \beta)) \not\equiv \mathcal{F}_c$
  - (b)  $\forall B \in \beta : (\mathcal{F}_c - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B))) \not\equiv \mathcal{F}_c$
3. **Jede linke Seite einer funktionalen Abhängigkeit in  $\mathcal{F}_c$  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 $\mathcal{F}_c$

- Führe für jede FD  $\alpha \rightarrow \beta \in \mathcal{F}$  die Linksreduktion durch**, also:
  - Überprüfe für alle  $A \in \alpha$ , ob  $A$  überflüssig ist, d.h. ob  $\beta \subseteq \text{AttrHülle}(\mathcal{F}, \alpha - A)$
- Führe für jede (verbliebene) FD die Rechtsreduktion durch**:
  - Überprüfe für alle  $B \in \beta$ , ob  $B \in \text{AttrHülle}(\mathcal{F} - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B)), \alpha)$  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.
- Entferne die FDs der Form  $\alpha \rightarrow \emptyset$ , die im 2. Schritt entstanden sind.**
- 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

- $\mathcal{F} = \{A \rightarrow B, B \rightarrow C, AB \rightarrow C\}$
- **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  $\mathcal{F}_c = \{A \rightarrow B, B \rightarrow C\}$

# 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  $\mathcal{F}_{\mathcal{R}}$  sollten in den  $\mathcal{F}_{\mathcal{R}_1}, \mathcal{F}_{\mathcal{R}_2}, \dots, \mathcal{F}_{\mathcal{R}_n}$  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