
Einführung in Datenbanksysteme

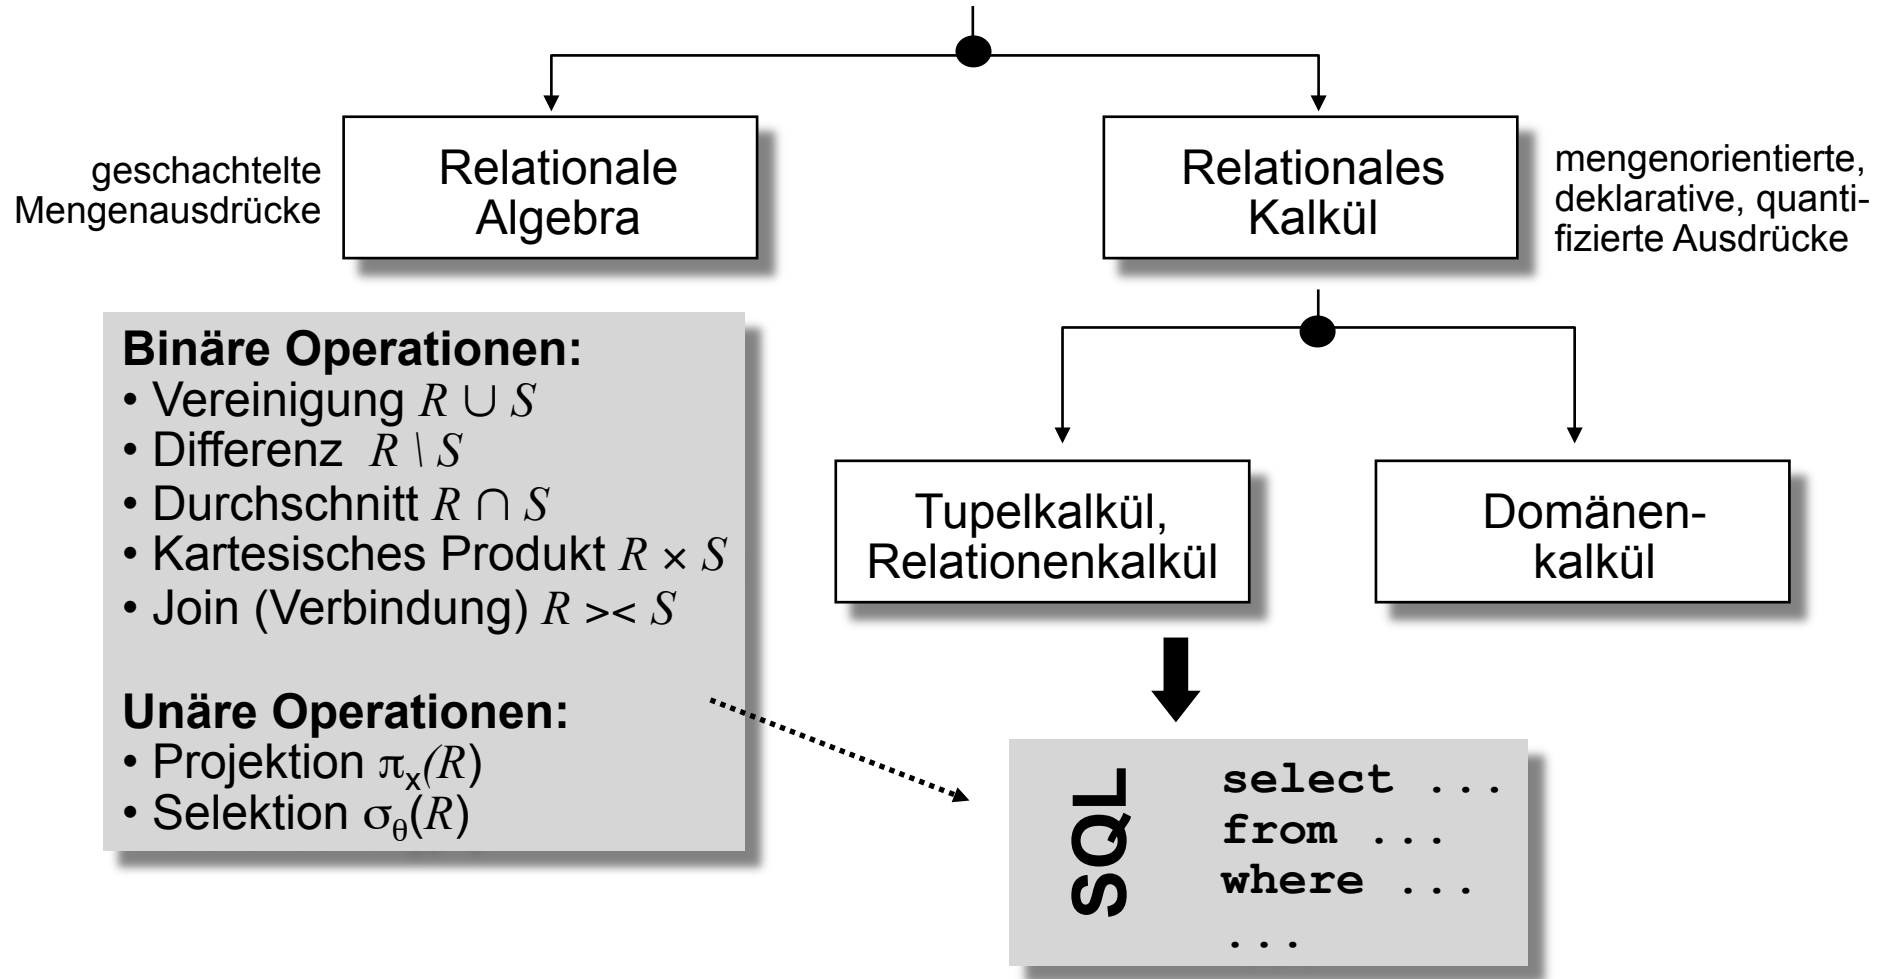
Prof. Dr. Ralf Möller

TUHH

Relationale Entwurfstheorie

RDM: Anfragen

Relationale Anfragesprachen im Überblick:



Wiederholung: „Schlechte“ Relationenschemata

| 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 |

Update-Anomalien

- Sokrates zieht um, von Raum 226 in R. 338. Was passiert?

Einfüge-Anomalien

- Neue/r Prof ohne Vorlesungen?

Löschanomalien

- Letzte Vorlesung einer/s Profs wird gelöscht? Was passiert?

Wiederholung: Funktionale Abhängigkeiten

Schema

$$\square \mathcal{R} = \{A, B, C, D\}$$

Ausprägung R

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

$\alpha \rightarrow \beta$ genau dann wenn $\forall r, s \in R$ mit $r.\alpha = s.\alpha \Rightarrow r.\beta = s.\beta$

| 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 |

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

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

$$\text{Nicht: } \{B\} \rightarrow \{C\}$$

Notationskonvention:

$$CD \rightarrow B$$

Wiederholung: Schlüssel

$\alpha \subseteq \mathcal{R}$ ist ein Super-Schlüssel, falls folgendes gilt:

$$\square \alpha \rightarrow \mathcal{R}$$

Wir nennen α **Super-Schlüssel**, weil noch nichts darüber ausgesagt wird, daß der Schlüssel α minimal ist.

β ist voll funktional abhängig von α genau dann wenn gilt

$$\square \alpha \rightarrow \beta \text{ und}$$

$$\square \alpha \text{ kann nicht mehr verkleinert werden, d.h.}$$

- $\forall A \in \alpha$ folgt, dass $(\alpha - \{A\}) \rightarrow \beta$ nicht gilt, oder kürzer
- $\forall A \in \alpha: \neg((\alpha - \{A\}) \rightarrow \beta)$

Notation für volle funktionale Abhängigkeit: $\alpha \rightarrow^{\bullet} \beta$
 $\alpha \subseteq \mathcal{R}$ ist ein **Kandidaten-Schlüssel**, falls folgendes gilt:

$$\square \alpha \rightarrow^{\bullet} \mathcal{R}$$

Schlüsselbestimmung

| Städte | | | |
|-----------|-------------|---------|---------|
| Name | BLand | Vorwahl | EW |
| Frankfurt | Hessen | 069 | 650000 |
| Frankfurt | Brandenburg | 0335 | 84000 |
| München | Bayern | 089 | 1200000 |
| Passau | Bayern | 0851 | 50000 |
| ... | ... | ... | ... |

Kandidatenschlüssel von *Städte*:

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

Kandidatenschlüssel lassen sich nicht aus Beispielen bestimmen!

Funktionale Abhängigkeiten zählen.

Schlüssel sollen FDs umsetzen!

Beachte, dass 2 kleinere Städte dieselbe Vorwahl haben können

Widerholung: Bestimmung funktionaler Abhängigkeiten

Professoren: {[PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, Bland, EW, Landesregierung]}

- ❑ {PersNr} → {PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, Bland, EW, Landesregierung}
- ❑ {Ort,BLand} → {EW, Vorwahl}
- ❑ {PLZ} → {Bland, Ort, EW}
- ❑ {Bland, Ort, Straße} → {PLZ}
- ❑ {Bland} → {Landesregierung}
- ❑ {Raum} → {PersNr}

Zusätzliche Abhängigkeiten, die aus obigen abgeleitet werden können:

- ❑ {Raum} → {PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, Bland, EW, Landesregierung}
- ❑ {PLZ} → {Landesregierung}

Hülle Funktionaler Abhängigkeiten

Sei F eine Menge von Funktionalen Abhängigkeiten (FDs)

F^+ bezeichnet die Menge aller aus F ableitbaren FDs und wird *Hülle* genannt.

Im allgemeinen gibt es unterschiedliche Mengen von FDs, deren Hülle gleich sind. In diesem Fall schreiben wir: $F_1 \equiv F_2$ (F_1 und F_2 sind äquivalent)

Def: F^+ ist Hülle von F , d. h. Menge von funktionalen Abhängigkeiten, die durch F impliziert werden (Folge von F sind)

Erläuterung: $R (A_1, \dots, A_n)$ Schema,
 $F = \{X_1 \rightarrow Y_1, X_2 \rightarrow Y_2, \dots, X_k \rightarrow Y_k\}$

Seien R_i beliebige Instantiierungen von R , d. h. konkrete Relationen, die F erfüllen.

Die Menge aller solcher Instantiierungen sei $\mathfrak{S} (R, F)$

Eine funktionale Abhängigkeit $X \rightarrow Y$ heißt **von F impliziert** (bzw. Folge von F), wenn

$\forall R_i \in \mathfrak{S} (R, F)$ gilt auch $X \rightarrow Y$

Vergleiche auch Begriffe aus Logik:

Interpretation: beliebige Instantiierungen R_j für R ,
ohne daß F gelten muß.

Modell: $R_i \in \mathfrak{S}(R, F)$
logische Folge: von F implizierte funktionale Abhängigkeit

$\Rightarrow \mathfrak{S}(R, F)$ ist Menge der Modelle für F mit Schema R ,
 F^+ ist Menge der logischen Folgerungen von F

Wie kann man F^+ methodisch bestimmen?

- Kalkül: Armstrong-Axiome

Herleitung funktionaler Abhängigkeiten: Armstrong-Axiome

Reflexivität

- ❑ Falls β eine Teilmenge von α ist ($\beta \subseteq \alpha$) dann gilt immer $\alpha \rightarrow \beta$. Insbesondere gilt 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 $\alpha \rightarrow \gamma$.

Diese drei Axiome sind vollständig und korrekt (ohne Beweis).
Zusätzliche Axiome erleichtern die Herleitung:

- ❑ Vereinigungsregel:

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

William W. Armstrong
Dependency Structures of
Data Base Relationships
1974

Armstrong Axiome

- Der Kalkül, der sich durch sättigende Anwendung der Armstrong-Axiome ergibt, ist korrekt und vollständig
- Beweisargumente: siehe Übung

Schlüsselbestimmung

Manuelle Bestimmung der Kandidatenschlüssel

- ist aufwendig und
- bei vielen FDs fehleranfällig.

Automatisierbar?

Bestimmung der Hülle einer **Attributmenge**

Bei der Schlüsselbestimmung ist man nicht an der gesamten Hülle einer Menge F von FDs interessiert, sondern nur an der Menge von Attributen, die von α gemäß F funktional bestimmt werden (sog. Attributhülle).

Eingabe: eine Menge F von FDs und eine Menge von Attributen α .

Ausgabe: die vollständige Menge von Attributen α^+ , für die gilt $\alpha \rightarrow \alpha^+$.

AttrHülle(F, α)

□ Erg := α

□ **While** (Änderungen an Erg) **do**

Foreach FD $\beta \rightarrow \gamma$ **in** F **do**

If $\beta \subseteq \text{Erg}$ **then** Erg := Erg \cup γ

□ Ausgabe $\alpha^+ = \text{Erg}$

Nutzen der Attributhülle

- Mit Hilfe der Attributhülle kann man bestimmen, ob eine Menge von Attributen κ einen Superschlüssel für ein Relationenschema \mathcal{R} darstellt:
 - Bestimme κ^+ und prüfe ob $\kappa^+ = \mathcal{R}$
- Mit Hilfe der Attributhülle kann man die Kandidatenschlüssel für ein Relationenschema bestimmen:
 - Bestimme alle bzgl. Mengeninklusion minimalen Mengen κ , so dass $\kappa^+ = \mathcal{R}$, und damit $\kappa \rightarrow \mathcal{R}$

Herleitung von Relationenschemata aus FDs

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

Welche Relationenschemata sollen verwendet werden, so dass FDs durch Schlüsselbedingung geprüft werden können?

- Professoren: $\{[PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, Bland, EW, Landesregierung]\} ???$
- Für jede FD ein Schema???

Vermeidung von Redundanz

- In den Daten:
 - Können wir doppelte repräsentierte Daten vermeiden?
- In der Modellierung:
 - Sind einige der aufgeschriebenen FDs überflüssig?

Redundanzfreie Darstellung von FDs

Kanonische Überdeckung

- F_c heißt kanonische Überdeckung von F , wenn die folgenden Kriterien erfüllt sind:
 - $F_c \equiv F$, d.h. $F_c^+ = F^+$
 - In F_c existieren keine FDs, die überflüssige Attribute enthalten. D.h. es muß folgendes gelten:
 - $\forall A \in \alpha: (F_c - (\alpha \rightarrow \beta) \cup ((\alpha - \{A\}) \rightarrow \beta)) \not\equiv F_c$
 - $\forall B \in \beta: (F_c - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - \{B\}))) \not\equiv F_c$
 - 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.

Berechnung der kanonischen Überdeckung

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

- $\beta \subseteq \text{AttrHülle}(F, \alpha - A)$

gilt. Falls dies der Fall ist, ersetze $\alpha \rightarrow \beta$ durch $(\alpha - A) \rightarrow \beta$.

Führe für jede (verbliebene) FD die Rechtsreduktion durch, also:

□ Überprüfe für alle $B \in \beta$, ob

- $B \in \text{AttrHülle}(F - (\alpha \rightarrow \beta) \cup (\alpha \rightarrow (\beta - B)), \alpha)$

gilt. Falls dies der Fall ist, ist B auf der rechten Seite überflüssig und kann eliminiert werden, d.h. ersetze $\alpha \rightarrow \beta$ durch $\alpha \rightarrow (\beta - B)$.

Entferne die FDs der Form $\alpha \rightarrow \emptyset$, die im 2. Schritt möglicherweise entstanden sind.

Fasse mittels der 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.

Nutzung der kanonischen Überdeckung

Naiver Ansatz:

- Bilde relationales Schema für jede FD der kanonischen Überdeckung
 - Eventuell immer noch zu viele Relationen
 - Beispiel:
 - FDs = $\{A \rightarrow B, D \rightarrow ABCD\}$
 - Zwei Relationen?
- Mehrere FDs einem relationalem Schema zuordnen?

Vereinbarungen

FDs, die von jeder Relationenausprägung automatisch immer erfüllt werden, nennen wir *trivial*. Nur FDs der Art $\alpha \rightarrow \beta$ mit $\beta \subseteq \alpha$ sind trivial.

Attribute eines Relationenschemas, die Elemente eines Kandidatenschlüssels des Relationenschemas sind, heißen "*prim*". Alle anderen Attribute des Relationenschemas nennen wir "*nicht prim*".

\mathcal{R} steht für ein Relationenschema, $F_{\mathcal{R}}$ ist die zugeordnete Menge von FDs. Wenn \mathcal{R} klar ist, dann wird meist nur F geschrieben.

Vermeidung von Redundanz in den Daten

Beispiel:

$\mathcal{R} = \{[A, B, C, D]\}$, $F = \{A \rightarrow B, D \rightarrow ABCD\}$, Schlüsselkandidat: $\{D\}$

| R | | | |
|---|---|---|---|
| A | B | C | D |
| 3 | 4 | 5 | 1 |
| 3 | 4 | 6 | 2 |

Do not represent the same fact twice

Allgemeiner Fall: $\alpha \rightarrow \beta \in F$, dann: α Superschlüssel oder FD ist trivial

ggf. Dekomposition notwendig (verlustfrei und abhängigkeitsbewahrend)

Zerlegung (Dekomposition) von Relationen

Es gibt zwei Korrektheitskriterien für die Zerlegung von Relationenschemata:

- Verlustlosigkeit
 - Die in der ursprünglichen Relationenausprägung R des Schemas \mathcal{R} enthaltenen Informationen müssen aus den Ausprägungen R_1, \dots, R_n der neuen Relationenschemata $\mathcal{R}_1, \dots, \mathcal{R}_n$ rekonstruierbar sein.
- Abhängigkeitserhaltung
 - Die für \mathcal{R} geltenden funktionalen Anhängigkeiten müssen auf die Schemata $\mathcal{R}_1, \dots, \mathcal{R}_n$ übertragbar sein.

Kriterien für die Verlustlosigkeit einer Zerlegung

$$\mathcal{R} = \mathcal{R}_1 \cup \mathcal{R}_2$$

$$\square \mathcal{R}_1 := \Pi_{\mathcal{R}_1}(\mathcal{R})$$

$$\square \mathcal{R}_2 := \Pi_{\mathcal{R}_2}(\mathcal{R})$$


Eine 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:

$$\square R = R_1 \bowtie R_2$$

Hinreichende Bedingung für die Verlustlosigkeit einer Zerlegung

$$\square (\mathcal{R}_1 \cap \mathcal{R}_2) \rightarrow \mathcal{R}_1 \text{ oder}$$

$$\square (\mathcal{R}_1 \cap \mathcal{R}_2) \rightarrow \mathcal{R}_2$$



Biertrinker-Beispiel

| <i>Biertrinker</i> | | |
|--------------------|-------------|-------------|
| <i>Kneipe</i> | <i>Gast</i> | <i>Bier</i> |
| Kowalski | Kemper | Pils |
| Kowalski | Eickler | Hefeweizen |
| Innsteg | Kemper | Hefeweizen |

„Verlustige“ Zerlegung

| <i>Biertrinker</i> | | |
|--------------------|-------------|-------------|
| <i>Kneipe</i> | <i>Gast</i> | <i>Bier</i> |
| Kowalski | Kemper | Pils |
| Kowalski | Eickler | Hefeweizen |
| Innsteg | Kemper | Hefeweizen |

$\Pi_{\text{Kneipe, Gast}}$

$\Pi_{\text{Gast, Bier}}$

| <i>Besucht</i> | |
|----------------|-------------|
| <i>Kneipe</i> | <i>Gast</i> |
| Kowalski | Kemper |
| Kowalski | Eickler |
| Innsteg | Kemper |

| <i>Trinkt</i> | |
|---------------|-------------|
| <i>Gast</i> | <i>Bier</i> |
| Kemper | Pils |
| Eickler | Hefeweizen |
| Kemper | Hefeweizen |

| <i>Biertrinker</i> | | |
|--------------------|-------------|-------------|
| <i>Kneipe</i> | <i>Gast</i> | <i>Bier</i> |
| Kowalski | Kemper | Pils |
| Kowalski | Eickler | Hefeweizen |
| Innsteg | Kemper | Hefeweizen |

| <i>Besucht</i> | |
|----------------|-------------|
| <i>Kneipe</i> | <i>Gast</i> |
| Kowalski | Kemper |
| Kowalski | Eickler |
| Innsteg | Kemper |

| <i>Trinkt</i> | |
|---------------|-------------|
| <i>Gast</i> | <i>Bier</i> |
| Kemper | Pils |
| Eickler | Hefeweizen |
| Kemper | Hefeweizen |

Π_{\dots}

$|><|$

| <i>Besucht A Trinkt</i> | | |
|-------------------------|-------------|-------------|
| <i>Kneipe</i> | <i>Gast</i> | <i>Bier</i> |
| Kowalski | Kemper | Pils |
| Kowalski | Kemper | Hefeweizen |
| Kowalski | Eickler | Hefeweizen |
| Innsteg | Kemper | Pils |
| Innsteg | Kemper | Hefeweizen |

\neq

Erläuterung des Biertrinker-Beispiels

Unser Biertrinker-Beispiel war eine „verlustige“ Zerlegung und dementsprechend war die hinreichende Bedingung verletzt. Es gilt nämlich nur die eine nicht-triviale funktionale Abhängigkeit

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

Wohingegen keine der zwei möglichen, die Verlustlosigkeit garantierenden FDs gelten

□ $\{Gast\} \rightarrow \{Bier\}$

□ $\{Gast\} \rightarrow \{Kneipe\}$

Das liegt daran, dass die Leute (insbes. Kemper) in unterschiedlichen Kneipen unterschiedliches Bier trinken. In derselben Kneipe aber immer das gleiche Bier

□ (damit sich die KellnerInnen darauf einstellen können?)

Verlustfreie Zerlegung

| <i>Eltern</i> | | |
|---------------|---------------|-------------|
| <i>Vater</i> | <i>Mutter</i> | <i>Kind</i> |
| Johann | Martha | Else |
| Johann | Maria | Theo |
| Heinz | Martha | Cleo |

$\Pi_{\text{Vater, Kind}}$

$\Pi_{\text{Mutter, Kind}}$

| <i>Väter</i> | |
|--------------|-------------|
| <i>Vater</i> | <i>Kind</i> |
| Johann | Else |
| Johann | Theo |
| Heinz | Cleo |

| <i>Mütter</i> | |
|---------------|-------------|
| <i>Mutter</i> | <i>Kind</i> |
| Martha | Else |
| Maria | Theo |
| Martha | Cleo |

Erläuterung der verlustfreien Zerlegung der Eltern-Relation

Eltern: {[Vater, Mutter, Kind]}

Väter: {[Vater, Kind]}

Mütter: {[Mutter, Kind]}

Verlustlosigkeit ist garantiert

Es gilt nicht nur eine der hinreichenden FDs, sondern gleich beide

❑ {Kind} → {Mutter}

❑ {Kind} → {Vater}

Also ist {Kind} natürlich auch der Schlüssel der Relation Eltern

Die Zerlegung von Eltern ist zwar verlustlos, aber auch ziemlich unnötig, da die Relation in sehr gutem Zustand ist → Normalform (s.u.)

Abhängigkeitsbewahrung

\mathcal{R} ist zerlegt in $\mathcal{R}_1, \dots, \mathcal{R}_n$

$F_{\mathcal{R}} = (F_{\mathcal{R}_1} \cup \dots \cup F_{\mathcal{R}_n})$ bzw. $F_{\mathcal{R}^+} = (F_{\mathcal{R}_1} \cup \dots \cup F_{\mathcal{R}_n})^+$

Beispiel für Abhängigkeitsverlust

- ❑ Geg. Schema PLZverzeichnis: {[Straße, Ort, Bland, PLZ]}

Annahmen

- ❑ Orte werden durch ihren Namen (Ort) und das Bundesland (Bland) eindeutig identifiziert
- ❑ Innerhalb einer Straße ändert sich die Postleitzahl nicht
- ❑ Postleitzahlengebiete gehen nicht über Ortsgrenzen und Orte nicht über Bundeslandgrenzen hinweg

Daraus resultieren die FDs

- ❑ {PLZ} \rightarrow {Ort, Bland}
- ❑ {Straße, Ort, Bland} \rightarrow {PLZ}

Betrachte die Zerlegung

- ❑ Straßen: {[PLZ, Straße]}
- ❑ Orte: {[PLZ, Ort, Bland]}

Zerlegung der Relation PLZverzeichnis

| <i>PLZverzeichnis</i> | | | |
|-----------------------|--------------|---------------|------------|
| <i>Ort</i> | <i>BLand</i> | <i>Straße</i> | <i>PLZ</i> |
| Frankfurt | Hessen | Goethestraße | 60313 |
| Frankfurt | Hessen | Galgenstraße | 60437 |
| Frankfurt | Brandenburg | Goethestraße | 15234 |

$\Pi_{PLZ, Straße}$

$\Pi_{Ort, BLand, PLZ}$

| <i>Straßen</i> | |
|----------------|---------------|
| <i>PLZ</i> | <i>Straße</i> |
| 15234 | Goethestraße |
| 60313 | Goethestraße |
| 60437 | Galgenstraße |

| <i>Orte</i> | | |
|-------------|--------------|------------|
| <i>Ort</i> | <i>BLand</i> | <i>PLZ</i> |
| Frankfurt | Hessen | 60313 |
| Frankfurt | Hessen | 60437 |
| Frankfurt | Brandenburg | 15234 |

Die FD $\{Straße, Ort, BLand\} \rightarrow \{PLZ\}$ ist im zerlegten Schema nicht mehr enthalten \rightarrow Einfügen inkonsistenter Tupel möglich

Einfügen zweier Tupel, die die FD $\text{Ort, Bland, Straße} \rightarrow \text{PLZ}$ verletzen

| <i>PLZverzeichnis</i> | | | |
|-----------------------|--------------|---------------|------------|
| <i>Ort</i> | <i>BLand</i> | <i>Straße</i> | <i>PLZ</i> |
| Frankfurt | Hessen | Goethestraße | 60313 |
| Frankfurt | Hessen | Galgenstraße | 60437 |
| Frankfurt | Brandenburg | Goethestraße | 15234 |

$\Pi_{\text{PLZ, Straße}}$

$\Pi_{\text{Stadt, Bland, PLZ}}$

| <i>Straßen</i> | |
|----------------|---------------|
| <i>PLZ</i> | <i>Straße</i> |
| 15234 | Goethestraße |
| 60313 | Goethestraße |
| 60437 | Galgenstraße |
| 15235 | Goethestrasse |

| <i>Orte</i> | | |
|-------------|--------------|------------|
| <i>Ort</i> | <i>BLand</i> | <i>PLZ</i> |
| Frankfurt | Hessen | 60313 |
| Frankfurt | Hessen | 60437 |
| Frankfurt | Brandenburg | 15234 |
| Frankfurt | Brandenburg | 15235 |

Einfügen zweier Tupel, die die FD $\text{Ort, Bland, Straße} \rightarrow \text{PLZ}$ verletzen

| <i>PLZverzeichnis</i> | | | |
|-----------------------|--------------|---------------|------------|
| <i>Ort</i> | <i>BLand</i> | <i>Straße</i> | <i>PLZ</i> |
| Frankfurt | Hessen | Goethestraße | 60313 |
| Frankfurt | Hessen | Galgenstraße | 60437 |
| Frankfurt | Brandenburg | Goethestraße | 15234 |
| Frankfurt | Brandenburg | Goethestraße | 15235 |

|><|

| <i>Straßen</i> | |
|----------------|---------------|
| <i>PLZ</i> | <i>Straße</i> |
| 15234 | Goethestraße |
| 60313 | Goethestraße |
| 60437 | Galgenstraße |
| 15235 | Goethestrasse |

| <i>Orte</i> | | |
|-------------|--------------|------------|
| <i>Ort</i> | <i>BLand</i> | <i>PLZ</i> |
| Frankfurt | Hessen | 60313 |
| Frankfurt | Hessen | 60437 |
| Frankfurt | Brandenburg | 15234 |
| Frankfurt | Brandenburg | 15235 |

Gütekriterien für Relationenschemata

- Redundanzfreiheit in den Daten
- Prüfung der einem Relationenschema zugeordneten FDs möglichst nur durch Schlüsselbedingung

→ Normalformen

Erste Normalform: nur „einfache“ Domänen

Beispiel:

| <i>Eltern</i> | | |
|---------------|---------------|---------------|
| <i>Vater</i> | <i>Mutter</i> | <i>Kinder</i> |
| Johann | Martha | {Else, Lucie} |
| Johann | Maria | {Theo, Josef} |
| Heinz | Martha | {Cleo} |

1 NF

| <i>Eltern</i> | | |
|---------------|---------------|-------------|
| <i>Vater</i> | <i>Mutter</i> | <i>Kind</i> |
| Johann | Martha | Else |
| Johann | Martha | Lucie |
| Johann | Maria | Theo |
| Johann | Maria | Josef |
| Heinz | Martha | Cleo |

Exkurs: NF²-Relationen

Non-First Normal-Form-Relationen

Geschachtelte Relationen

| <i>Eltern</i> | | | |
|---------------|---------------|---------------|---------------|
| <i>Vater</i> | <i>Mutter</i> | <i>Kinder</i> | |
| | | <i>KName</i> | <i>KAlter</i> |
| Johann | Martha | Else | 5 |
| | | Lucie | 3 |
| Johann | Maria | Theo | 3 |
| | | Josef | 1 |
| Heinz | Martha | Cleo | 9 |

Zweite Normalform


Eine Relation \mathcal{R} mit zugehörigen FDs $F_{\mathcal{R}}$ ist in zweiter Normalform, falls jedes Nichtschlüssel-Attribut $A \in \mathcal{R}$ voll funktional abhängig ist von jedem Kandidatenschlüssel der Relation.

| StudentenBelegung | | | |
|-------------------|--------|--------------|----------|
| MatrNr | VorlNr | Name | Semester |
| 26120 | 5001 | Fichte | 10 |
| 27550 | 5001 | Schopenhauer | 6 |
| 27550 | 4052 | Schopenhauer | 6 |
| 28106 | 5041 | Carnap | 3 |
| 28106 | 5052 | Carnap | 3 |
| 28106 | 5216 | Carnap | 3 |
| 28106 | 5259 | Carnap | 3 |
| ... | ... | ... | ... |

Studentenbelegung mit Schlüssel $\{\text{MatrNr}, \text{VorlNr}\}$ ist nicht in zweiter NF

- ❑ $\{\text{MatrNr}\} \rightarrow \{\text{Name}\}$
- ❑ $\{\text{MatrNr}\} \rightarrow \{\text{Semester}\}$

Zweite Normalform



Einfügeanomalie: Was macht man mit Studenten, die keine Vorlesungen hören?

Updateanomalien: Wenn z.B. Carnap ins vierte Semester kommt, muss man sicherstellen, dass alle vier Tupel geändert werden.

Löschanomalie: Was passiert wenn Fichte ihre einzige Vorlesung absagt?

Zerlegung in zwei Relationen

❑ hören: {[MatrNr, VorlNr]}

❑ Studenten: {[MatrNr, Name, Semester]}

Beide Relationen sind in 2 NF – erfüllen sogar noch „höhere“ Gütekriterien ~ Normalformen.

Weitere Normalisierung: Motivation

Beispiel:

$R = \{[A, B, C, D]\}$, $F = \{A \rightarrow B, D \rightarrow ABCD\}$, Schlüsselkandidat: $\{D\}$

| R | | | |
|---|---|---|---|
| A | B | C | D |
| 3 | 4 | 5 | 1 |
| 3 | 4 | 6 | 2 |

Do not represent the same fact twice

Allgemeiner Fall: $\alpha \rightarrow \beta \in F$, dann: α Superschlüssel oder FD ist trivial

ggf. Dekomposition notwendig (verlustfrei und abhängigkeitsbewahrend)

Boyce-Codd-Normalform

Die Boyce-Codd-Normalform (BCNF) stellt nochmals eine Verschärfung der zweiten Normalform dar.


Ein Relationenschema \mathcal{R} mit FDs F ist in BCNF, wenn für jede für \mathcal{R} geltende funktionale Abhängigkeit der Form $\alpha \rightarrow \beta \in F$ mindestens **eine** der folgenden zwei Bedingungen gilt:

- ❑ $\beta \subseteq \alpha$, d.h., die Abhängigkeit ist trivial oder
- ❑ α ist Superschlüssel von \mathcal{R}

Man kann jede Relation **verlustlos** in BCNF-Relationen zerlegen

Manchmal läßt sich dabei die **Abhängigkeiterhaltung** aber **nicht** erzielen

Beispiel



Prüfung der FDs durch Schlüsselbedingung nicht möglich

Funktionale Abhängigkeiten:

- ❑ {PLZ} → {Ort, Bland}
- ❑ {Straße, Ort, Bland} → {PLZ}

Betrachte die Zerlegung

- ❑ Straßen: {[PLZ, Straße]}
- ❑ Orte: {[PLZ, Ort, Bland]}

Diese Zerlegung

- ❑ ist verlustlos aber
- ❑ Nicht abhängigkeiterhaltend (die zweite FD kann keiner Subrelation zugeordnet werden)

Was, wenn Boyce-Codd-Normalform nicht möglich?

Beispiel:

$R = \{[A, B, C, D]\}$

$F = \{A \rightarrow D, CD \rightarrow ABCD\}$

Schlüsselkandidaten: $\{AC\}, \{DC\}$

Codd 71: Schema „ganz gut“, wenn es keine „transitiven Abhängigkeiten“ gibt: 3. Normalform

FD $A \rightarrow D$ im obigen Schema wäre tolerierbar

Dritte Normalform (formuliert nach Zaniolo 82)

Ein Relationenschema \mathcal{R} ist in dritter Normalform, wenn für **jede für \mathcal{R} geltende** funktionale Abhängigkeit der Form $\alpha \rightarrow B$ mit $\alpha \subseteq \mathcal{R}$ und $B \in \mathcal{R}$ mindestens **eine** von drei Bedingungen gilt:

- ❑ $B \in \alpha$, d.h., die FD ist trivial
- ❑ α ist Superschlüssel von \mathcal{R}
- ❑ Das Attribut B ist in einem Kandidatenschlüssel von \mathcal{R} enthalten
(B ist prim)

Man beachte: Es wird **jede für \mathcal{R} geltende FD** betrachtet wird \rightarrow FD-Hülle!

Warum ist Zaniolos Formulierung interessant?

Frage

- Können wir relationale Schemata finden, so dass alle FDs einem Schema zugeordnet werden können (Abhängigkeitserhaltung) und wenigstens die dritte Normalform gegeben ist?

Synthesealgorithmus

Wir geben jetzt einen sogenannten Synthesealgorithmus an, mit dem zu einem gegebenen Relationenschema \mathcal{R} mit funktionalen Anhängigkeiten F eine Zerlegung in $\mathcal{R}_1, \dots, \mathcal{R}_n$ ermittelt wird, die alle drei folgenden Kriterien erfüllt.

- $\mathcal{R}_1, \dots, \mathcal{R}_n$ ist eine verlustlose Zerlegung von \mathcal{R} .

- Die Zerlegung $\mathcal{R}_1, \dots, \mathcal{R}_n$ ist abhängigkeiterhaltend.

- Alle $\mathcal{R}_1, \dots, \mathcal{R}_n$ sind in dritter Normalform.

Synthesealgorithmus

Bestimme die kanonische Überdeckung F_c zu F . Wiederholung:

- Linksreduktion
- Rechtsreduktion
- Entfernung von FDs der Form $\alpha \rightarrow \emptyset$
- Zusammenfassung gleicher linker Seiten

Für jede funktionale Abhängigkeit $\alpha \rightarrow \beta \in F_c$:

- Kreiere ein Relationenschema $\mathcal{R}_\alpha := \alpha \cup \beta$
- Ordne \mathcal{R}_α die FDs $F_\alpha := \{\alpha' \rightarrow \beta' \in F_c \mid \alpha' \cup \beta' \subseteq \mathcal{R}_\alpha\}$ zu.

Falls eines der in Schritt 2. erzeugten Schemata einen Kandidatenschlüssel von \mathcal{R} bzgl. F_c enthält, sind wir fertig. Sonst wähle einen Kandidatenschlüssel $\kappa \subseteq \mathcal{R}$ aus und definiere folgendes Schema:

- $\mathcal{R}_\kappa := \kappa$
- $F_\kappa := \emptyset$

Eliminiere diejenigen Schemata \mathcal{R}_α , die in einem anderen Relationenschema $\mathcal{R}_{\alpha'}$ enthalten sind, d.h.,

- $\mathcal{R}_\alpha \subseteq \mathcal{R}_{\alpha'}$

Beispiel 1: Anwendung des Synthesealgorithmus

ProfessorenAdr: {[PersNr, Name, Rang, Raum, Ort, Straße, PLZ, Vorwahl, BLand, EW, Landesregierung]}

- ❑ {PersNr} → {Name, Rang, Raum, Ort, Straße, BLand}
- ❑ {Raum} → {PersNr}
- ❑ {Straße, BLand, Ort} → {PLZ}
- ❑ {Ort, BLand} → {EW, Vorwahl}
- ❑ {BLand} → {Landesregierung}
- ❑ {PLZ} → {BLand, Ort}

Professoren: {[PersNr, Name, Rang, Raum, Ort, Straße, BLand]}

PLZverzeichnis: {[Straße, BLand, Ort, PLZ]}

Orteverzeichnis: {[Ort, BLand, EW, Vorwahl]}

Regierungen: {[BLand, Landesregierung]}

Boyce-Codd-Normalform (2)

Wiederholung:

Ein Relationenschema \mathcal{R} mit FDs F ist in BCNF, wenn für jede für \mathcal{R} geltende funktionale Abhängigkeit der Form $\alpha \rightarrow \beta \in F$ mindestens **eine** der folgenden zwei Bedingungen gilt:

- $\beta \subseteq \alpha$, d.h., die Abhängigkeit ist trivial oder
- α ist Superschlüssel von \mathcal{R}

Man kann jede Relation **verlustlos** in BCNF-Relationen zerlegen

Manchmal läßt sich dabei die **Abhängigkeiterhaltung** aber **nicht** erzielen

Städte ist in 3NF, aber nicht in BCNF

Städte: {[Ort, BLand, Ministerpräsident/in, EW]}

Geltende FDs:

- ❑ {Ort, BLand} → {EW}
- ❑ {BLand} → {Ministerpräsident/in}
- ❑ {Ministerpräsident/in} → {BLand}

Schlüsselkandidaten:

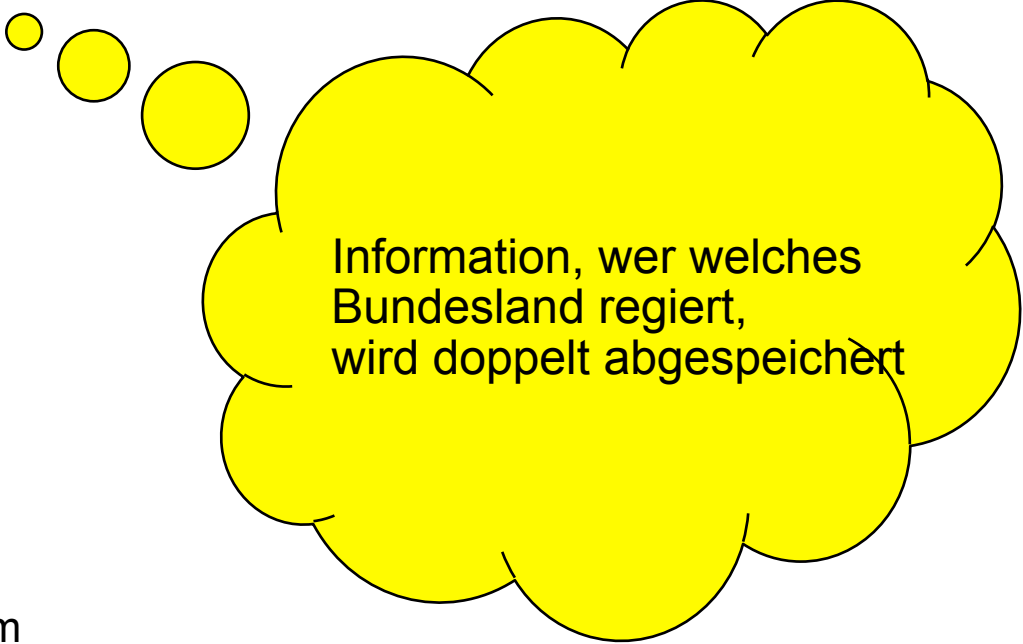
- ❑ {Ort, BLand}
- ❑ {Ort, Ministerpräsident/in}

3NF:

- ❑ {Ort, BLand} ist Superschlüssel
- ❑ BLand und Ministerpräsident/in sind prim

Nicht BCNF:

- ❑ {BLand} kein Superschlüssel
- ❑ {Ministerpräsident/in} kein Superschlüssel



Information, wer welches Bundesland regiert, wird doppelt abgespeichert

Frage

- Sollten wir nicht wenigstens versuchen, Boyce-Codd-Normalform herzustellen?

Dekomposition

Man kann grundsätzlich jedes Relationenschema \mathcal{R} mit funktionalen Abhängigkeiten F so in $\mathcal{R}_1, \dots, \mathcal{R}_n$ zerlegen, dass gilt:

- $\mathcal{R}_1, \dots, \mathcal{R}_n$ ist eine verlustlose Zerlegung von \mathcal{R} .
- Alle $\mathcal{R}_1, \dots, \mathcal{R}_n$ sind in BCNF.
- Es kann leider nicht immer erreicht werden, dass die Zerlegung $\mathcal{R}_1, \dots, \mathcal{R}_n$ abhängigkeiterhaltend ist.

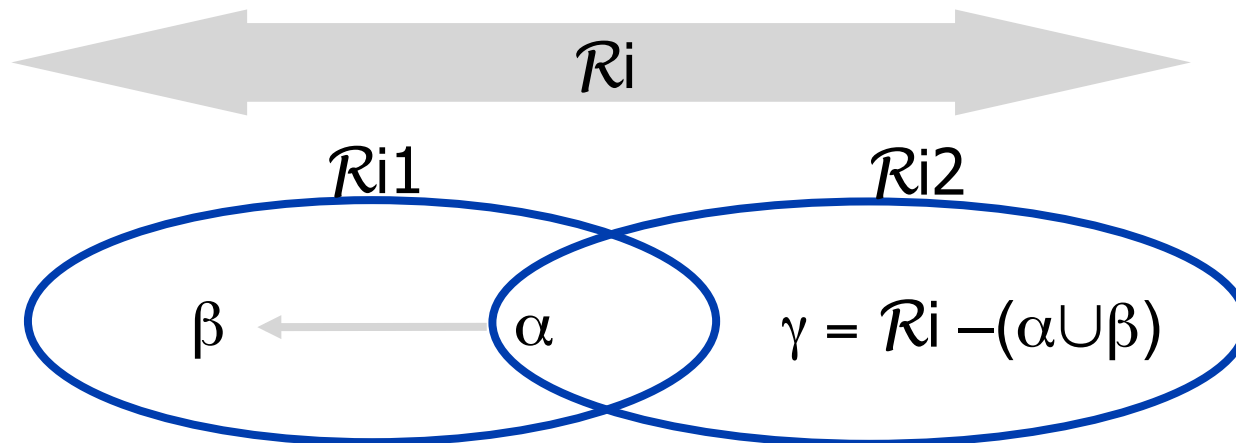
Dekompositions-Algorithmus

Starte mit $Z = \{\mathcal{R}\}$

Solange es noch ein Relationenschema \mathcal{R}_i in Z gibt, das nicht in BCNF ist, mache folgendes:

- ❑ Es gibt also eine für \mathcal{R}_i geltende nicht-triviale funktionale Abhängigkeit $(\alpha \rightarrow \beta)$ mit
 - $\alpha \cap \beta = \emptyset$
 - $\neg(\alpha \rightarrow \mathcal{R}_i)$
- ❑ Finde eine solche FD
 - Man sollte sie so wählen, dass β alle von α funktional abhängigen Attribute $B \in (\mathcal{R}_i - \alpha)$ enthält, damit der Dekompositionsalgorithmus möglichst schnell terminiert.
- ❑ Zerlege \mathcal{R}_i in $\mathcal{R}_{i1} := \alpha \cup \beta$ und $\mathcal{R}_{i2} := \mathcal{R}_i - \beta$
- ❑ Entferne \mathcal{R}_i aus Z und füge \mathcal{R}_{i1} und \mathcal{R}_{i2} ein, also
 - $Z := (Z - \{\mathcal{R}_i\}) \cup \{\mathcal{R}_{i1}\} \cup \{\mathcal{R}_{i2}\}$

Veranschaulichung der Dekomposition



Dekomposition der Relation Städte in BCNF-Relationen

Städte: {[Ort, BLand, Ministerpräsident/in, EW]}

Geltende FDs:

- ❑ {BLand} → {Ministerpräsident/in}
- ❑ {Ort, BLand} → {EW}
- ❑ {Ministerpräsident/in} → {BLand}

\mathcal{R}_1 :


- ❑ Regierungen: {[BLand, Ministerpräsident/in]}

\mathcal{R}_2 :

- ❑ Städte: {[Ort, BLand, EW]}

Zerlegung ist verlustlos und auch abhängigkeiterhaltend – Glück gehabt!

Dekomposition des PLZverzeichnis in BCNF-Relationen



Funktionale Abhängigkeiten:

- ❑ {PLZ} → {Ort, Bland}
- ❑ {Straße, Ort, Bland} → {PLZ}

Betrachte die Zerlegung

- ❑ Straßen: {[PLZ, Straße]}
- ❑ Orte: {[PLZ, Ort, Bland]}

Diese Zerlegung

- ❑ ist verlustlos aber
- ❑ Nicht abhängigkeiterhaltend
- ❑ Siehe oben

Weitere verwendbare Einschränkungen

Gibt es weitere sinnvolle Einschränkungen (Dependencies)?

- Enthaltensein-Einschränkungen (Inclusion Dependencies)
 - Relationale Kodierung notwendig (z.B. gleiche Primärschlüssel)
- Mehrwertige Abhängigkeiten (Multiple-Value Dependencies)

Mehrwertige Abhängigkeiten: ein Beispiel

| Fähigkeiten | | |
|-------------|------------|-------------|
| PersNr | Sprache | ProgSprache |
| 3002 | griechisch | C |
| 3002 | lateinisch | Pascal |
| 3002 | griechisch | Pascal |
| 3002 | lateinisch | C |
| 3005 | deutsch | Ada |

Mehrwertige Abhängigkeiten dieser Relation:

- ❑ $\{PersNr\} \twoheadrightarrow \{Sprache\}$ und
- ❑ $\{PersNr\} \twoheadrightarrow \{ProgSprache\}$

MVDs führen zu Redundanz und Anomalien

Mehrwertige Abhängigkeiten

| R | | | |
|----|-----------------------|------------------------|-------------------------|
| | α A1 ... Ai | β Ai+1 ... Aj | γ Aj+1 ... An |
| t1 | a1 ... ai | ai+1 ... aj | aj+1 ... an |
| t2 | a1 ... ai | bi+1 ... bj | bj+1 ... bn |
| t3 | a1 ... ai | bi+1 ... bj | aj+1 ... an |
| t4 | a1 ... ai | ai+1 ... aj | bj+1 ... bn |

$\alpha \twoheadrightarrow \beta$ gilt genau dann wenn

- ❑ es zu zwei Tupel t1 und t2 mit gleichen α -Werten
- ❑ auch zwei Tupel t3 und t4 gibt mit
 - $t3.\alpha = t4.\alpha = t1.\alpha = t2.\alpha$
 - $t3.\beta = t2.\beta, t4.\beta = t1.\beta$
 - $t4.\gamma = t2.\gamma, t3.\gamma = t1.\gamma$

"Zu zwei Tupeln mit gleichem α - Wert kann man die β -Werte vertauschen, und die Tupel müssen auch in der Relation sein"

MVDs

Tuple-generating dependencies

- Man kann eine Relation MVD-konform machen, indem man zusätzliche Tupel einfügt
- Bei FDs geht das nicht!!

Mehrwertige Abhängigkeiten

| R | | |
|---|----|----|
| A | B | C |
| a | b | c |
| a | bb | cc |
| a | bb | c |
| a | b | cc |

$A \twoheadrightarrow B$

$A \twoheadrightarrow C$

Mehrwertige Abhängigkeiten: ein Beispiel

| Fähigkeiten | | |
|-------------|------------|-------------|
| PersNr | Sprache | ProgSprache |
| 3002 | griechisch | C |
| 3002 | lateinisch | Pascal |
| 3002 | griechisch | Pascal |
| 3002 | lateinisch | C |
| 3005 | deutsch | Ada |

$\Pi_{\text{PersNr, Sprache}}$


| Sprachen | |
|----------|------------|
| PersNr | Sprache |
| 3002 | griechisch |
| 3002 | lateinisch |
| 3005 | deutsch |

$\Pi_{\text{PersNr, ProgSprache}}$

| ProgSprachen | |
|--------------|-------------|
| PersNr | ProgSprache |
| 3002 | C |
| 3002 | Pascal |
| 3005 | Ada |

Mehrwertige Abhängigkeiten: ein Beispiel

| Fähigkeiten | | |
|-------------|------------|-------------|
| PersNr | Sprache | ProgSprache |
| 3002 | griechisch | C |
| 3002 | lateinisch | Pascal |
| 3002 | griechisch | Pascal |
| 3002 | lateinisch | C |
| 3005 | deutsch | Ada |



| Sprachen | |
|----------|------------|
| PersNr | Sprache |
| 3002 | griechisch |
| 3002 | lateinisch |
| 3005 | deutsch |

| ProgSprachen | |
|--------------|-------------|
| PersNr | ProgSprache |
| 3002 | C |
| 3002 | Pascal |
| 3005 | Ada |

Verlustlose Zerlegung bei MVDs: **hinreichende + notwendige Bedingung**

$$\mathcal{R} = \mathcal{R}_1 \cup \mathcal{R}_2$$

- $\mathcal{R}_1 := \Pi_{\mathcal{R}_1}(\mathcal{R})$
- $\mathcal{R}_2 := \Pi_{\mathcal{R}_2}(\mathcal{R})$

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:

$$\square R = R_1 \bowtie R_2$$

Die Zerlegung von \mathcal{R} in \mathcal{R}_1 und \mathcal{R}_2 ist verlustlos **genau dann wenn**

$$\square \mathcal{R} = \mathcal{R}_1 \cup \mathcal{R}_2$$

und mindestens eine von zwei MVDs gilt:

$$\square (\mathcal{R}_1 \cap \mathcal{R}_2) \twoheadrightarrow \mathcal{R}_1 \text{ oder}$$

$$\square (\mathcal{R}_1 \cap \mathcal{R}_2) \twoheadrightarrow \mathcal{R}_2$$

Triviale MVDs ...

... sind solche, die von jeder Relationenausprägung erfüllt werden

Eine MVD $\alpha \twoheadrightarrow \beta$ ist trivial genau dann wenn

- $\beta \subseteq \alpha$ oder
- $\beta = R - \alpha$

Vierte Normalform

Eine Relation \mathcal{R} ist in 4 NF wenn für jede MVD $\alpha \twoheadrightarrow \beta$ eine der folgenden Bedingungen gilt:

- Die MVD ist trivial **oder**
- α ist Superschlüssel von \mathcal{R}

Dekomposition in 4 NF

Starte mit der Menge $Z := \{\mathcal{R}\}$

Solange es noch ein Relationenschema \mathcal{R}_i in Z gibt, das nicht in 4NF ist, mache folgendes:

□ Es gibt also eine für \mathcal{R}_i geltende nicht-triviale MVD $(\alpha \twoheadrightarrow \beta)$, für die gilt:

- $\alpha \cap \beta = \emptyset$

- $\neg(\alpha \rightarrow \mathcal{R}_i)$


□ Finde eine solche MVD

□ Zerlege \mathcal{R}_i in $\mathcal{R}_{i1} := \alpha \cup \beta$ und $\mathcal{R}_{i2} := \mathcal{R}_i - \beta$

□ Entferne \mathcal{R}_i aus Z und füge \mathcal{R}_{i1} und \mathcal{R}_{i2} ein, also


- $Z := (Z - \{\mathcal{R}_i\}) \cup \{\mathcal{R}_{i1}\} \cup \{\mathcal{R}_{i2}\}$

Dekomposition in 4 NF



Beispiel-Zerlegung

Assistenten': {[PersNr, Name, Fachgebiet, Boss, Sprache, ProgrSprache]}

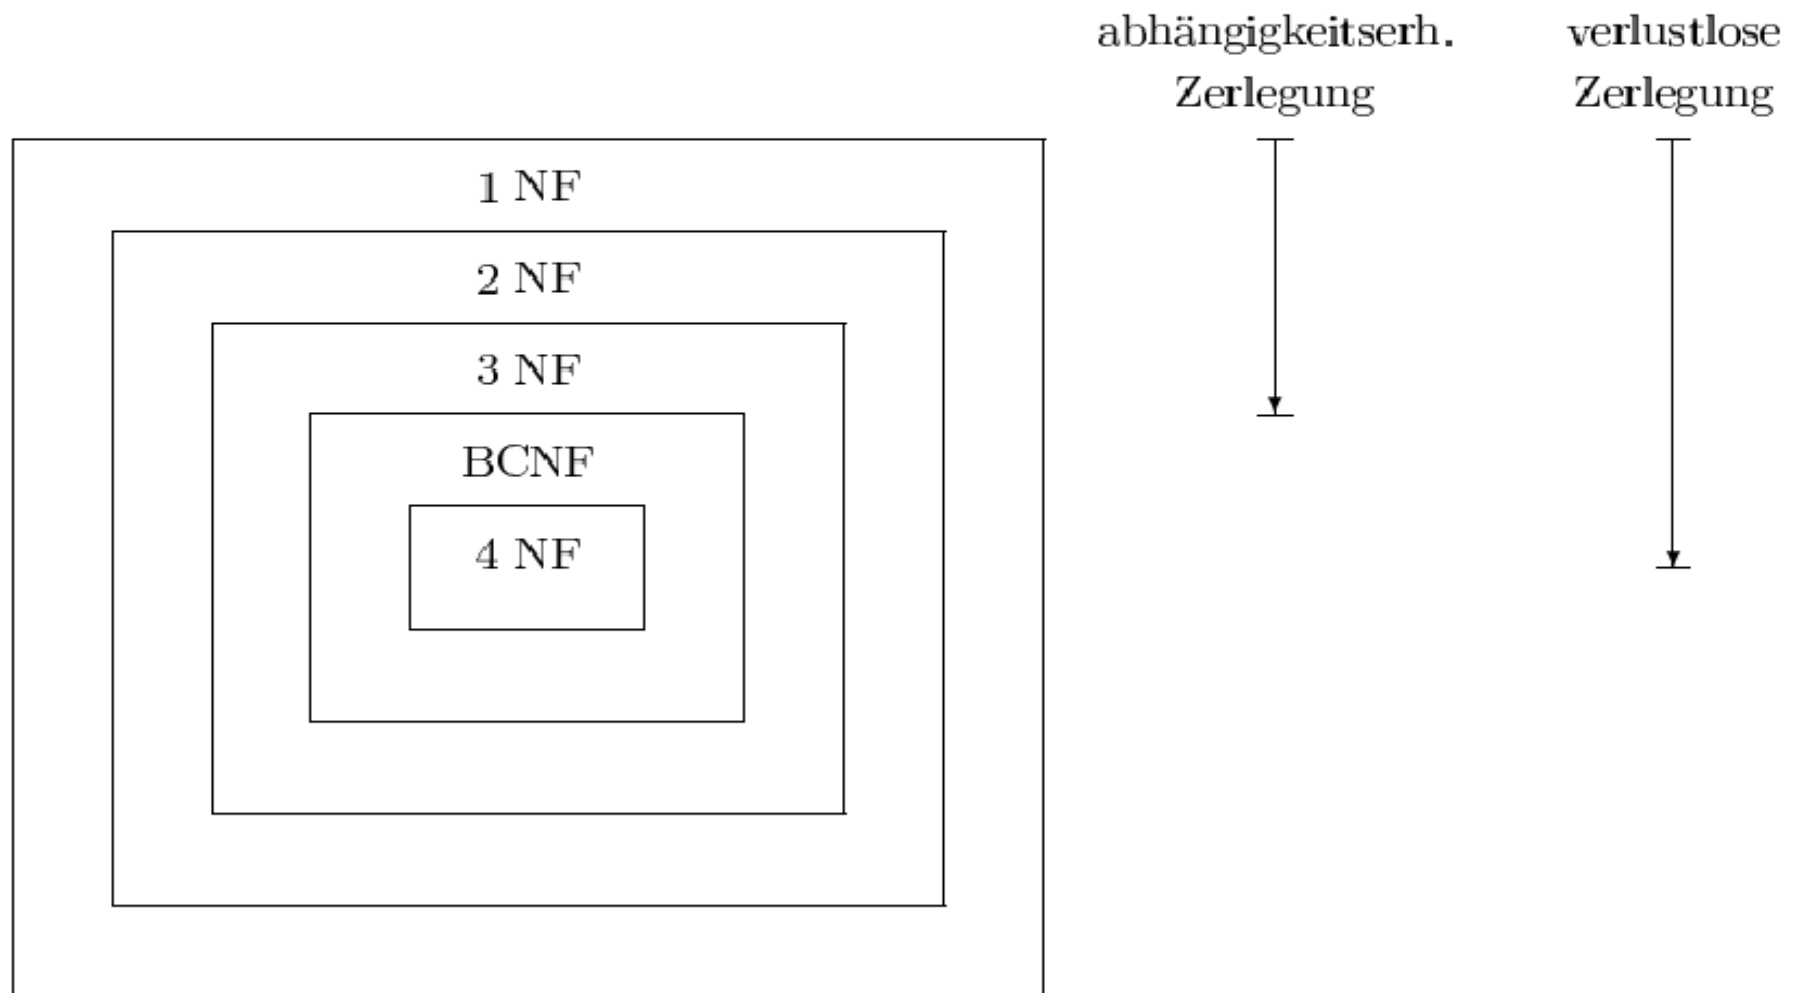


- Assistenten: {[PersNr, Name, Fachgebiet, Boss]}
- Fähigkeiten: {[PersNr, Sprache, ProgrSprache]}
- Sprachen: {[PersNr, Sprache]}
- ProgrSprachen: {[PersNr, ProgrSprache]}

Zusammenfassung

Die Verlustlosigkeit ist für alle Zerlegungsalgorithmen in alle Normalformen garantiert

Die Abhängigkeitserhaltung kann nur bis zur dritten Normalform garantiert werden



Acknowledgments

